Model izbora vitkih alata pri restrukturiranju poduzeća

Lekšić, Ivan

Doctoral thesis / Disertacija

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:235:847649

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-07-27**

Repository / Repozitorij:

Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zagrebu

Fakultet strojarstva i brodogradnje

Ivan Lekšić

MODEL IZBORA VITKIH ALATA PRI RESTRUKTURIRANJU PODUZEĆA

DOKTORSKI RAD

Zagreb, 2020.

Sveučilište u Zagrebu

Fakultet strojarstva i brodogradnje

Ivan Lekšić

LEAN TOOL SELECTION MODEL IN COMPANY RESTRUCTURING PROCESS

DOKTORSKI RAD

Mentor: prof. dr. sc. Nedeljko Štefanić

Zagreb, 2020.

University of Zagreb

Faculty of Mechanical Engineering and Naval Architecture

Ivan Lekšić

LEAN TOOL SELECTION MODEL IN COMPANY RESTRUCTURING PROCESS

DOCTORAL DISSERTATION

Supervisor: Prof. Nedeljko Štefanić, Ph.D.

Zagreb, 2020

PODACI ZA BIBLIOGRAFSKU KARTICU

Ključne riječi:	vitka proizvodnja, vitki alati, eliminacija gubitaka
Znanstveno područje:	tehničke znanosti
Znanstveno polje:	strojarstvo
Institucija:	Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje
Mentor:	prof. dr. sc. Nedeljko Štefanić (FSB, Zagreb)
Broj stranica:	372
Broj slika:	237
Broj tablica:	35
Broj bibliografskih jedinica:	245
Datum obrane:	2.10.2020.
Povjerenstvo:	prof. dr. sc. Goran Đukić (FSB, Zagreb) predsjednik doc. dr. sc. Miro Hegedić (FSB, Zagreb) član prof. emer. dr. sc. Ivica Veža (FESB, Split) član
Institucija u kojoj je rad pohranjen:	Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu Nacionalna i sveučilišna knjižnica u Zagrebu

ZAHVALA

Veliku zahvalnost dugujem prvenstveno svom mentoru, prof. dr. sc. Nedeljku Štefaniću, koji mi je tijekom studija nesebično prenio veliko znanje o vitkoj proizvodnji. Njegovi su savjeti i smjernice bile od presudne važnosti prilikom pokretanja ovog istraživanja te me neumorno motivirao, pratio i usmjeravao do samog kraja. Tijekom cijelog studija prof. dr. sc. Nedeljko Štefanić prenosio je svoj entuzijazam, optimizam i kulturu vitke proizvodnje te je svojim pohvalama i kritikama dao potpuno novu dimenziju kako mom životu tako i ovom istraživanju.

Zahvaljujem prof. dr. sc. Ivici Veži koji mi je svojim savjetima pomogao pri izradi i objavi istraživanja usko vezanog uz temu doktorskog rada. Njegovo iskustvo i dugogodišnji znanstveni rad bili su od velike pomoći i neizostavne važnosti.

Cjelokupnom nastavnom osoblju Fakulteta strojarstva i brodogradnje zahvaljujem na trudu, pomoći, praćenju i prenošenju specifičnog, ali zanimljivog znanja.

Na kraju, veliko hvala mojoj obitelji koja je moje školovanje pratila od samih početaka.

SAŽETAK

Svaka organizacija želi stvarati profitabilne proizvode i usluge. Međutim, konkurencija je velika i neki proizvod ili uslugu gotovo uvijek nudi više proizvođača što dovodi do borbe za tržištem. Prilikom osvajanja tržišta ne postoji jedinstvena „kuharica“, ali zato postoje strategije kojima se menadžment može koristiti kako bi se organizacija našla u stanju bolje konkurentnosti i profitabilnosti. Jedna od takvih strategija je vitka proizvodnja.

Vitka proizvodnja preslika je japanske kulture i životne filozofije koja se oslanja na eliminaciju gubitaka i stvaranju učinkovitog okruženja gdje su svi zadovoljni, od dobavljača pa do krajnjeg kupca. Budući da je takvu kulturu u jednoj organizaciji nemoguće usaditi preko noći, vodeći su autori i zagovaratelji ovog poslovnog modela tijekom dugog niza godina opisivali jedan po jedan segment ove kulture. Tako je svaki segment te kulture pretočen u neki vitki alat. Međutim, postoji više od stotinu vitkih alata i pitanje je koje vitke alate upotrijebiti, u kojem trenutku i u kojem opsegu jer će svaka odluka dovesti do drugačijeg ishoda. Velik broj vitkih inicijativa završava neuspješno jer prilikom operativnog provođenja vitke filozofije menadžment luta. Cilj ovog rada bio je definirati kada i koji alat implementirati kako bi poboljšanje bilo ostvarivo, optimalno i održivo.

Vitka filozofija temelji se na eliminaciji gubitaka te je gubitak definiran kao sve ono što krajnji kupac ili tržište ne želi i neće platiti. Prema Taiichiju Ohnou postoji nekoliko vrsta gubitaka koje generira svaka organizacija te je pravo umijeće iste smanjiti, pa čak i eliminirati. Vrste gubitaka su sljedeće: prekomjerna proizvodnja, nepotrebne zalihe, čekanje, prekomjerna obrada, škart, prekomjeran transport, nepotrebni pokreti i nedovoljna iskorištenost potencijala zaposlenika. Svaka organizacija u relativno kratkom roku može utvrditi svoje gubitke. Međutim, drugi je par rukava kako operativno inicirati i voditi eliminaciju gubitaka. Restrukturiranje organizacije pomoću vitke filozofije podrazumijeva utvrđivanje gubitaka na svim razinama i pravovremenu implementaciju odgovarajućih vitkih alata. Pregledom literature ustanovljeno je da postoji dvadeset pet temeljnih vitkih alata. Preciznije rečeno, te alate menadžment najčešće primjenjuje prilikom restrukturiranja pomoću vitke filozofije te je bilo logično ustanoviti kako pojedini alati sami ili u paru s drugim vitkim alatima utječu na smanjenje pojedinih gubitaka.

Istraživanje o izboru vitkih alata pri restrukturiranju poduzeća napravljeno je teorijski, pregledom literature, te eksperimentalno, uzimajući i analizirajući žive podatke iz vitkih organizacija. Pregledom literature ustanovljeno je što je vitka proizvodnja, koje su njezine elementarne značajke koje su pokazane kroz Toyotin proizvodni sustav i na se koji način se ona implementira i integrira u postojeće poslovne procese. Najveća važnost dana je vitkim alatima te su svi alati pomno opisani i definirani na temelju knjiga i značajnijih znanstvenih radova.

Istraživački dio rada napravljen je u obliku ankete koja je sustavno provođena među organizacijama koje posluju u Hrvatskoj. Ostvaren je kontakt s gotovo 300 organizacija te su utvrđene 63 organizacije koje su koristile ili koriste vitku filozofiju u reorganizaciji poslovanja. Sama anketa podijeljena je u nekoliko dijelova kako bi se dobila cjelokupna slika

o vitkim poduzećima. Anketom su utvrđeni motivi i ciljevi, sustavno su kvantificirani gubitci u organizacijama prije i nakon uvođenja vitke proizvodnje te su zabilježeni vitki alati koji se koriste pri restrukturiranju. Pritom je potrebno naglasiti da je dobivena jasna slika o tome koji su se alati uvodili, jesu li ti alati imali nekakav subjektivno i objektivno pozitivan učinak te kojim su se redoslijedom istoimeni alati implementirali. Dobiveni podaci pripremili su se za statističku analizu te je napravljeno nekoliko tipova statističkih testova kako bi se dobila što šira i jasnija slika o izboru vitkih alata pri restrukturiranju poduzeća.

Ključne riječi: vitka proizvodnja, vitki alati, eliminacija gubitaka.

EXTENDED SUMMARY

I Lean Production and Tools

Lean Production (LP) is a well-known business strategy which relies on eliminating waste and continuous improvement. The strategy is literally a model of Japanese culture and the concept of living in which everything has to be done perfectly and with respect to market needs. Although LP is described and documented in many publications, some organisations still face failures during lean implementation. There are various critical factors for lean implementation success, but the essential part of every lean implementation are lean tools. The reason for that lies in the fact that new culture cannot be adopted without visible practices. One needs something solid, something people will follow and something that will eventually become organisational culture. Lean tools are nothing more than visible practices.

There are more than a hundred lean tools and they each represent a small fragment of Japanese culture. Lean tools implementation sequence can define whether or not your restructuring strategy will be successful. The trick is to launch a certain lean tool or a pair of lean tools at a certain time to keep the momentum of continuous improvement. If you miss launching a proper lean tool at a proper time, you will stop the progress and lose the momentum. The real magic is to launch just the right lean tool at just the right time.

II Study on Lean Tool Implementation

The essence of LP is to eliminate waste, with each waste reduction effort being supported with lean tools. The question is this: will some lean tools reduce certain types of waste better and faster than others and when? Taiichi Ohno has classified several distinct types of waste. Specifically, every organisation generates eight types of waste: surplus production, excess transport, waiting, excess processing, redundant stock, unnecessary movements, fallouts and insufficient use of employee potential. It is the responsibility of the company management to strive to and achieve continuous reduction of all types of waste.

Each lean implementation is driven by a different lean toolbox since every organisation has its own objectives. However, literature review has revealed that some lean tools are more frequently used than others. Those tools are: 5S, Bottleneck Analysis, Continuous Flow, Value Stream Mapping (VSM), Heijunka (level scheduling), Hoshin Kanri (policy deployment), Jidoka (autonomination), Just-In-Time (JIT), Kaizen (continuous improvement), Kanban (pull system), Key Performance Indicators (KPIs), Muda (waste), Andon, Overall Equipment Effectiveness (OEE), Plan-Do-Check-Act analysis (PDCA), Poka-Yoke (error proofing), Root Cause Analysis, Single-Minute-Exchange of Dies (SMED), Visual Factory, SMART goals, Standardised Work, Takt Time, Total Productive

Maintenance (TPM), Gemba (the real place) and Six Big Losses. To put it simply, there are twenty-five basic lean tools.

The guiding concept of this study was to address major operational features of the lean implementation process, with the ultimate goal of detecting the best lean tools for reducing waste, in accordance to Taiichi Ohno's eight types of waste. The research was conducted in Croatia during 2017 and 2018, in the form of a questionnaire which narrowly focused on the relations between the twenty-five basic tools and eight types of waste. The questionnaire was divided in four segments, each of which was designed to reveal a certain aspect of lean:

(1) The first segment of the questionnaire was aimed at revealing the data about the size, maturity, starting time of going lean, motivation, goals and type of restructuring process organisations wanted to achieve.
(2) The second segment of the questionnaire was made in the form of a scoreboard, where respondents gave information about their waste prior to lean implementation, according to Taiichi Ohno's types of waste.
(3) The third segment of the questionnaire was based on the lean tool implementation framework, where respondents gave information on the sequence of lean tool implementation.
(4) The last segment of the questionnaire was made in the same form as the second segment, as a scoreboard used by respondents to answer questions about improvements they noticed, all in accordance with Taiichi Ohno's types of waste. This segment of the questionnaire was designed to function as feedback about the lean implementation success.

Altogether, three hundred organisations were contacted and only sixty-three of them reported they had used or still use lean philosophy. The study involved all the sixty-three organisations, and all the statistical analyses were conducted in SPSS.

III Results

There are numerous reasons why lean philosophy should be made an industrial standard. This study has confirmed and revealed the following:

- Lean philosophy is generally used for operative restructuring;
- Organisations predominantly try to increase their efficiency, profitability and productivity through lean;
- Most frequently used lean tools are Standardized Work, 5S, Kaizen (continuous improvement), Key Performance Indicators (KPIs), Value Stream Mapping (VSM), Bottleneck Analysis, SMART goals, etc.;
- Statistically significant lean tools for waste reduction are: Total Productive Maintenance (TPM), Poka-Yoke (error proofing), Kaizen (continuous improvement), 5S, Kanban (pull system), Six Big Losses, Heijunka (level scheduling), Takt Time,

Andon, Overall Equipment Effectiveness (OEE), Single-Minute-Exchange of Dies (SMED) and Key Performance Indicators (KPIs);

- Best lean tools that reduce several types of waste are: TPM, Poka-Yoke, Kaizen, 5S and Kanban;
- Best lean tools for reduction of surplus production are TPM and Six Big Losses;
- Best lean tools for reduction of excess transport are Poka-Yoke, 5S, Heijunka and Kanban;
- Best lean tools for reduction of waiting time are Takt Time, Andon, 5S and TPM;
- Best lean tools for reduction of excess processing are Poka-Yoke and TPM;
- Best lean tools for reduction of redundant stock are OEE, Kanban and TPM;
- Best lean tools for reduction of unnecessary movements are SMED, Kaizen and KPIs;
- Best lean tools for reduction of fallouts are Poka-Yoka and Kaizen;
- Best lean tools for reduction of insufficient use of employee potential are TPM and Kaizen.

Key words: Lean production, lean tools, waste elimination

SADRŽAJ

1. UVOD 30
1.1. Definicija vitke proizvodnje 30
1.2. Cilj i hipoteza rada 33
1.3. Metodologija i plan istraživanja 34
1.4. Očekivani znanstveni doprinos 38
2. VITKA PROIZVODNJA 39
2.1. Sustav vitke proizvodnje 39
2.2. Gubitci vitke proizvodnje 42
2.2.1. Prekomjerna proizvodnja 45
2.2.2. Škart 45
2.2.3. Nepotrebne zalihe 45
2.2.4. Prekomjerna obrada 45
2.2.5. Prekomjeran transport 46
2.2.6. Čekanja 46
2.2.7. Nepotrebni pokreti 46
2.2.8. Nedovoljna iskorištenost potencijala zaposlenika 47
2.3. Vitko vodstvo 47
2.4. TPS 48
2.4.1. JIT 49
2.4.2. *Kanban* 51
2.4.3. Brze izmjene alata 52
2.4.4. *Jidoka* 53
2.4.5. *Andon* 53
2.4.6. Načela TPS-a 54
2.5. Implementacija vitke proizvodnje 58
2.5.1. Čimbenici koji utječu na implementaciju vitke proizvodnje 58
2.5.2. Motivi i ciljevi implementacije vitke proizvodnje 61
2.5.3. Metode implementacije vitke proizvodnje 63
2.5.4. Rezultati vitke proizvodnje 69
3. VITKI ALATI 72
3.1. Definicija vitkih alata 72
3.2. Vitki alati u velikim svjetskim poduzećima 74
3.3. Vitki alati u srednje velikim poduzećima 76
3.4. Temeljni vitki alati 78
3.4.1. 5S 81

3.4.2. *Andon* ... 83
3.4.3. Analiza uskih grla ... 85
3.4.4. Kontinuirani tok ... 88
3.4.5. *Gemba* ... 91
3.4.6. *Heijunka* ... 93
3.4.7. *Hoshin kanri* ... 96
3.4.8. *Jidoka* ... 100
3.4.9. JIT ... 102
3.4.10. *Kaizen* ... 107
3.4.11. *Kanban* ... 112
3.4.12. Ključni indikatori učinkovitosti ... 115
3.4.13. *Muda* ... 120
3.4.14. OEE ... 124
3.4.15. PDCA ... 127
3.4.16. *Poka-yoke* ... 129
3.4.17. Analiza glavnog uzroka ... 133
3.4.18. SMED ... 136
3.4.19. Šest velikih gubitaka ... 139
3.4.20. Pametni ciljevi ... 142
3.4.21. Standardizacija rada ... 145
3.4.22. Taktno vrijeme ... 149
3.4.23. TPM ... 153
3.4.24. VSM ... 158
3.4.25. Vizualna tvornica ... 163
4. ISTRAŽIVANJE O VITKOJ PROIZVODNJU U RH ... 166
4.1. Općenito o istraživanju ... 167
4.1.1. Metodologija istraživanja ... 167
4.1.2. Kriteriji za odabir poduzeća ... 168
4.2. Rezultati istraživanja ... 169
4.2.1. Opći podaci o anketiranim vitkim poduzećima ... 169
4.2.2. Klasifikacija vitkih poduzeća prema djelatnosti ... 173
4.2.3. Duljina primjene vitke proizvodnje u RH ... 176
4.2.4. Motivi za uvođenje vitke proizvodnje u RH ... 177
4.2.5. Vrste restrukturiranja koje se provode vitkom proizvodnjom u RH ... 178
4.2.6. Ciljevi prilikom uvođenja vitke proizvodnje u RH ... 179
4.2.7. Gubitci u hrvatskim poduzećima prije uvođenja vitke proizvodnje ... 181
4.2.8. Implementacija vitkih alata u hrvatskim poduzećima ... 183

4.2.9. Poboljšanja u hrvatskim poduzećima nakon uvođenja vitke proizvodnje 188
4.3. Analiza rezultata 190
4.3.1. Povezanost vremenske duljine primjene vitke proizvodnje s ukupnim napretkom 190
4.3.2. Povezanost vremenske duljine primjene vitke proizvodnje s napretkom u određenoj kategoriji gubitka 191
4.3.3. Vitki alati koji su najpogodniji za smanjenje određenog gubitka 195
4.3.4. Vitki alati koji najbolje smanjuju određene gubitke 200
5. ZAKLJUČAK 203
5.1. Potvrda hipoteze istraživanja 207
5.2. Ostvareni znanstveni doprinos 208
5.3. Ograničenja provedenog istraživanja 209
5.4. Smjernice za daljnja istraživanja 209
LITERATURA 210
PRILOZI 232
PRILOG 1: duljina primjene vitke proizvodnje i smanjenje prekomjerne proizvodnje 234
PRILOG 2: duljina primjene vitke proizvodnje i smanjenje prekomjernog transporta 241
PRILOG 3: duljina primjene vitke proizvodnje i smanjenje čekanja 248
PRILOG 4: duljina primjene vitke proizvodnje i smanjenje prekomjerne obrade 257
PRILOG 5: duljina primjene vitke proizvodnje i smanjenje nepotrebnih zaliha 266
PRILOG 6: duljina primjene vitke proizvodnje i smanjenje nepotrebnih pokreta 275
PRILOG 7: duljina primjene vitke proizvodnje i smanjenje škarta 284
PRILOG 8: duljina primjene vitke proizvodnje i smanjenje nedovoljne iskorištenosti potencijala zaposlenika 293
PRILOG 9: 5S i eliminacija gubitaka 300
PRILOG 10: *andon* i eliminacija gubitaka 302
PRILOG 11: analiza uskih grla i eliminacija gubitaka 304
PRILOG 12: kontinuirani tok i eliminacija gubitaka 306
PRILOG 13: VSM i eliminacija gubitaka 308
PRILOG 14: *heijunka* i eliminacija gubitaka 310
PRILOG 15: *hoshin kanri* i eliminacija gubitaka 312
PRILOG 16: *jidoka* i eliminacija gubitaka 314
PRILOG 17: JIT i eliminacija gubitaka 316
PRILOG 18: *kaizen* i eliminacija gubitaka 318
PRILOG 19: *kanban* i eliminacija gubitaka 320
PRILOG 20: ključni indikatori učinkovitosti i eliminacija gubitaka 322
PRILOG 21: *muda* i eliminacija gubitaka 324
PRILOG 22: OEE i eliminacija gubitaka 326
PRILOG 23: PDCA i eliminacija gubitaka 328

PRILOG 24: *poka-yoke* i eliminacija gubitaka 330
PRILOG 25: analiza glavnog uzroka i eliminacija gubitaka 332
PRILOG 26: SMED i eliminacija gubitaka 334
PRILOG 27: vizualna tvornica i eliminacija gubitaka 336
PRILOG 28: pametni ciljevi i eliminacija gubitaka 338
PRILOG 29: standardizacija rada i eliminacija gubitaka 340
PRILOG 30: taktno vrijeme i eliminacija gubitaka 342
PRILOG 31: TPM i eliminacija gubitaka 344
PRILOG 32: *gemba* i eliminacija gubitaka 346
PRILOG 33: Šest velikih gubitaka i eliminacija gubitaka 348
PRILOG 34: vitki alati koji najbolje smanjuju prekomjernu proizvodnju 350
PRILOG 35: vitki alati koji najbolje smanjuju prekomjeran transport 353
PRILOG 36: vitki alati koji najbolje smanjuju čekanje 355
PRILOG 37: vitki alati koji najbolje smanjuju prekomjernu obradu 358
PRILOG 38: vitki alati koji najbolje smanjuju nepotrebne zalihe 360
PRILOG 39: vitki alati koji najbolje smanjuju nepotrebne pokrete 363
PRILOG 40: vitki alati koji najbolje smanjuju škart 366
PRILOG 41: vitki alati koji najbolje smanjuju nedovoljnu iskorištenost potencijala zaposlenika 369
ŽIVOTOPIS 371
BIOGRAPHY 372

POPIS SLIKA

Slika 1. Sedam vrsta gubitaka [12] ... 43
Slika 2. Dimenzije sustava vitke proizvodnje te veza s gubitcima [13] ... 44
Slika 3. Razlika između proizvodnje po načelu „guranja“ (a) i „povlačenja“ (b)[20] ... 50
Slika 4. Skupina proizvodnih operacija u kojoj se primjenjuje andon [19] ... 54
Slika 5. Jedan dio poduzeća s kojima Vorne Industries surađuje [38] ... 79
Slika 6. Vitka kuća prema Jeffreyju K. Likeru koja predstavlja temeljne vitke alate [37] ... 80
Slika 7. 5S organizacija alata [45] ... 83
Slika 8. Andon održavanje strojeva u pogonu [47] ... 84
Slika 9. Prekid toka proizvodnje uslijed uskog grla na S3 [51] ... 86
Slika 10. Linijska proizvodnja [54] ... 88
Slika 11. U-linijski raspored strojeva [55] ... 89
Slika 12. Funkcionalnost U-linijskog sustava [56] ... 89
Slika 13. Pitanja koja se postavljaju tijekom gembe [63] ... 93
Slika 14. Prikaz niveliranja proizvodnje kako bi se postigla stabilnost sustava [68] ... 95
Slika 15. Heijunka ploča koja sadrži sve važne informacije o proizvodnji za svaki dan [69] ... 95
Slika 16. Hoshin kanri ciljevi [74] ... 97
Slika 17. Način funkcioniranja hoshin kanrija [75] ... 98
Slika 18. Implementacija jidoke [79] ... 100
Slika 19. McDonald'sov JIT sustav usluge [92] ... 106
Slika 20. Kaizen sustav u 12 koraka [95] ... 108
Slika 21. Razlika između dnevnog kaizena i kaizen događaja [97] ... 109
Slika 22. Kaizen ploča u bolnici u Clevelandu [103] ... 112
Slika 23. Kanban sustav na primjeru trgovine [109] ... 114
Slika 24. Kanban s dvije kartice na primjeru proizvodnog pogona [110] ... 114
Slika 25. Kanban ploča za planiranje proizvodnje [112] ... 115
Slika 26. Ploča s ključnim indikatorima učinkovitosti [116] ... 118
Slika 27. Kategorizacija ključnih indikatora učinkovitosti u proizvodnji [117] ... 119
Slika 28. Odnosi između različitih kategorija gubitaka [125] ... 121
Slika 29. OEE sustav metrike[127] ... 125
Slika 30. PDCA logika [139] ... 127
Slika 31. PDCA ciklus [140] ... 128
Slika 32. Najboljih pet poka-yoke metoda u proizvodnji [158] ... 132
Slika 33. Primjer Ishikawa dijagrama [166] ... 135
Slika 34. Radni okvir metode „pet zašto“ [167] ... 135
Slika 35. Provođenje SMED-a [170] ... 136
Slika 36. Pametni cilj [190] ... 145
Slika 37. Standardizacija rada [192] ... 146
Slika 38. Kontinuirani napredak i standardizacija rada [198] ... 148
Slika 39. Taktno vrijeme [203] ... 149
Slika 40. Niveliranje proizvodnje prema taktnom vremenu [205] ... 151
Slika 41. Proizvodnja automobila uz taktno vrijeme i standardizaciju rada [206] ... 151
Slika 42. Prednosti komadne naspram serijske proizvodnje [213] ... 153
Slika 43. Primjer TPM kontrolnog lista koji radnik ispunjava svaki dan prije početka rada [214] ... 156

Slika 44. TPM ploča za edukaciju radnika o održavanju strojeva [225] 157
Slika 45. Osam stupova TPM-a [226] 157
Slika 46. Proces mapiranja toka vrijednosti [229] 159
Slika 47. Primjer mapiranja procesa izrade vratila [232] 161
Slika 48. Primjer mapiranja procesa razvoja softvera [233] 162
Slika 49. Vizualna ploča s bitnim informacijama o radnoj ćeliji [239] 165
Slika 50. Vizualno sučelje koje operatera obavještava na koji će način provesti svoj rad [240] 165
Slika 51. Struktura anketiranih vitkih poduzeća prema veličini 170
Slika 52. Sektor djelatnosti vitkih poduzeća 172
Slika 53. Sektor djelatnosti vitkih poduzeća 172
Slika 54. Područja djelatnosti vitkih poduzeća 174
Slika 55. Odjeljak djelatnosti hrvatskih vitkih poduzeća 175
Slika 56. Koliko se dugo vitki koncept primjenjuje u pojedinim hrvatskim poduzećima 176
Slika 57. Rast primjene vitke filozofije u hrvatskim poduzećima 177
Slika 58. Glavni motivi za primjenu vitkog koncepta u hrvatskim poduzećima 178
Slika 59. Vrste restrukturiranja za koje se koristi vitki koncept u RH 179
Slika 60. Ciljevi koji se žele postići uvođenjem vitke filozofije 180
Slika 61. Pozitivan utjecaj vitkih alata 184
Slika 62. Boxplot grafikon duljine primjene vitke proizvodnje i napretka u eliminaciji gubitaka 190
Slika 63. Uzorak u SPSS-u 234
Slika 64. Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u 234
Slika 65. Grupiranje u SPSS-u 234
Slika 66. Mjerenje svih važnih statističkih parametara u SPSS-u 235
Slika 67. Test normalne razdiobe podataka u SPSS-u 236
Slika 68. Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju prekomjerne proizvodnje (SPSS) 237
Slika 69. Boxplot graf duljine primjene vitke proizvodnje i napretka u smanjenju prekomjerne proizvodnje 238
Slika 70. Test homogenosti varijanci u SPSS-u 238
Slika 71. ANOVA test u SPSS-u 239
Slika 72. Turkey HSD test u SPSS-u 239
Slika 73. Turkey HSD test u SPSS-u 240
Slika 74. Uzorak u SPSS-u 241
Slika 75. Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u 241
Slika 76. Grupiranje u SPSS-u 241
Slika 77. Mjerenje svih važnih statističkih parametara u SPSS-u 242
Slika 78. Test normalne razdiobe podataka u SPSS-u 243
Slika 79. Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju prekomjernog transporta (SPSS) 244
Slika 80. Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju prekomjernog transporta 245
Slika 81. Test homogenosti varijanci u SPSS-u 245
Slika 82. ANOVA test u SPSS-u 246
Slika 83. Turkey HSD test u SPSS-u 246
Slika 84. Turkey HSD test u SPSS-u 247

Slika 85. Uzorak u SPSS-u 248
Slika 86. Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u 248
Slika 87. Grupiranje u SPSS-u 248
Slika 88. Mjerenje svih važnih statističkih parametara u SPSS-u 249
Slika 89. Test normalne razdiobe podataka u SPSS-u 250
Slika 90. Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju čekanja (SPSS) 251
Slika 91. Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju čekanja252
Slika 92. Test homogenosti varijanci u SPSS-u 252
Slika 93. Kruskal-Wallisov test u SPSS-u 253
Slika 94. Kruskal-Wallisov test u SPSS-u 253
Slika 95. Kruskal-Wallisov test u SPSS-u 253
Slika 96. Odbacivanje nulte hipoteze u SPSS-u 254
Slika 97. Mann-Whitneyev test 254
Slika 98. Mann-Whitneyev test 254
Slika 99. Mann-Whitneyev test 255
Slika 100. Mann-Whitneyev test 255
Slika 101. Mann-Whitneyev test 256
Slika 102. Mann-Whitneyev test 256
Slika 103. Uzorak SPSS-u 257
Slika 104. Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u 257
Slika 105. Grupiranje u SPSS-u. 257
Slika 106. Mjerenje svih važnih statističkih parametara u SPSS-u 258
Slika 107. Test normalne razdiobe podataka u SPSS-u 259
Slika 108. Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju prekomjerne obrade (SPSS) 260
Slika 109. Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju prekomjerne obrade 261
Slika 110. Kruskal-Wallisov test u SPSS-u 262
Slika 111. Kruskal-Wallisov test u SPSS-u 262
Slika 112. Kruskal-Wallisov test u SPSS-u 262
Slika 113. Odbacivanje nulte hipoteze u SPSS-u 263
Slika 114. Mann-Whitneyev test 263
Slika 115. Mann-Whitneyev test 263
Slika 116. Mann-Whitneyev test 264
Slika 117. Mann-Whitneyev test 264
Slika 118. Mann-Whitneyev test 265
Slika 119. Mann-Whitneyev test 265
Slika 120. Uzorak u SPSS-u 266
Slika 121. Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u 266
Slika 122. Grupiranje u SPSS-u 266
Slika 123. Mjerenje svih važnih statističkih parametara u SPSS-u 267
Slika 124. Test normalne razdiobe podataka u SPSS-u 268
Slika 125. Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju nepotrebnih zaliha (SPSS) 269

Slika 126. Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju nepotrebnih zaliha ... 270
Slika 127. Kruskal-Wallisov test u SPSS-u ... 271
Slika 128. Kruskal-Wallisov test u SPSS-u ... 271
Slika 129. Kruskal-Wallisov test u SPSS-u ... 271
Slika 130. Odbacivanje nulte hipoteze u SPSS-u ... 272
Slika 131. Mann-Whitneyev test ... 272
Slika 132. Mann-Whitneyev test ... 272
Slika 133. Mann-Whitneyev test ... 273
Slika 134. Mann-Whitneyev test ... 273
Slika 135. Mann-Whitneyev test ... 274
Slika 136. Mann-Whitneyev test ... 274
Slika 137. Uzorak u SPSS-u ... 275
Slika 138. Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u ... 275
Slika 139. Grupiranje u SPSS-u ... 275
Slika 140. Mjerenje svih važnih statističkih parametara u SPSS-u ... 276
Slika 141. Test normalne razdiobe podataka u SPSS-u ... 277
Slika 142. Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju nepotrebnih pokreta (SPSS) ... 278
Slika 143. Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju nepotrebnih pokreta ... 279
Slika 144. Kruskal-Wallisov test u SPSS-u ... 280
Slika 145. Kruskal-Wallisov test u SPSS-u ... 280
Slika 146. Kruskal-Wallisov test u SPSS-u ... 280
Slika 147. Odbacivanje nulte hipoteze u SPSS-u ... 281
Slika 148. Mann-Whitneyev test ... 281
Slika 149. Mann-Whitneyev test ... 281
Slika 150. Mann-Whitneyev test ... 282
Slika 151. Mann-Whitneyev test ... 282
Slika 152. Mann-Whitneyev test ... 283
Slika 153. Mann-Whitneyev test ... 283
Slika 154. Uzorak u SPSS-u ... 284
Slika 155. Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u ... 284
Slika 156. Grupiranje u SPSS-u ... 284
Slika 157. Mjerenje svih važnih statističkih parametara u SPSS-u ... 285
Slika 158. Test normalne razdiobe podataka u SPSS-u ... 286
Slika 159. Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju škarta (SPSS) ... 287
Slika 160. Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju škarta 288
Slika 161. Kruskal-Wallisov test u SPSS-u ... 289
Slika 162. Kruskal-Wallisov test u SPSS-u ... 289
Slika 163. Kruskal-Wallisov test u SPSS-u ... 289
Slika 164. Odbacivanje nulte hipoteze u SPSS-u ... 290
Slika 165. Mann-Whitneyev test ... 290
Slika 166. Mann-Whitneyev test ... 290
Slika 167. Mann-Whitneyev test ... 291

Slika 168. Mann-Whitneyev test 291
Slika 169. Mann-Whitneyev test 292
Slika 170. Mann-Whitneyev test 292
Slika 171. Uzorak u SPSS-u 293
Slika 172. Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u 293
Slika 173. Grupiranje u SPSS-u 293
Slika 174. Mjerenje svih važnih statističkih parametara u SPSS-u 294
Slika 175. Test normalne razdiobe podataka u SPSS-u 295
Slika 176. Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju nedovoljne iskorištenosti potencijala zaposlenika (SPSS) 296
Slika 177. Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju nedovoljne iskorištenosti potencijala zaposlenika 297
Slika 178. Kruskal-Wallisov test u SPSS-u 298
Slika 179. Kruskal-Wallisov test u SPSS-u 298
Slika 180. Kruskal-Wallisov test u SPSS-u 298
Slika 181. Prihvaćanje nulte hipoteze u SPSS-u 299
Slika 182. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila 5S te razlika u napretku kod smanjenja određenog gubitka 301
Slika 183. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila andon te razlika u napretku kod smanjenja određenog gubitka 303
Slika 184. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila analizu uskih grla te razlika u napretku kod smanjenja određenog gubitka 305
Slika 185. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila kontinuirani tok te razlika u napretku kod smanjenja određenog gubitka 307
Slika 186. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila VSM te razlika u napretku kod smanjenja određenog gubitka 309
Slika 187. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila heijunku te razlika u napretku kod smanjenja određenog gubitka 311
Slika 188. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila hoshin kanri te razlika u napretku kod smanjenja određenog gubitka 313
Slika 189. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila jidoku te razlika u napretku kod smanjenja određenog gubitka 315
Slika 190. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila JIT te razlika u napretku kod smanjenja određenog gubitka 317
Slika 191. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila kaizen te razlika u napretku kod smanjenja određenog gubitka 319
Slika 192. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila kanban te razlika u napretku kod smanjenja određenog gubitka 321
Slika 193. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila ključne indikatore učinkovitosti te razlika u napretku kod smanjenja određenog gubitka 323
Slika 194. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila sustav muda te razlika u napretku kod smanjenja određenog gubitka 325
Slika 195. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila OEE te razlika u napretku kod smanjenja određenog gubitka 327
Slika 196. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila PDCA te razlika u napretku kod smanjenja određenog gubitka 329

Slika 197. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila poka-yoke te razlika u napretku kod smanjenja određenog gubitka 331
Slika 198. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila analizu glavnog uzroka te razlika u napretku kod smanjenja određenog gubitka 333
Slika 199. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila SMED te razlika u napretku kod smanjenja određenog gubitka 335
Slika 200. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila vizualnu tvornicu te razlika u napretku kod smanjenja određenog gubitka 337
Slika 201. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila pametne ciljeve te razlika u napretku kod smanjenja određenog gubitka 339
Slika 202. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila standardizaciju rada te razlika u napretku kod smanjenja određenog gubitka 341
Slika 203. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila taktno vrijeme te razlika u napretku kod smanjenja određenog gubitka 343
Slika 204. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila TPM te razlika u napretku kod smanjenja određenog gubitka 345
Slika 205. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila gembu te razlika u napretku kod smanjenja određenog gubitka 347
Slika 206. Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila logiku šest velikih gubitaka te razlika u napretku kod smanjenja određenog gubitka 349
Slika 207. Najbolji prediktori dobiveni SMLR modelom 350
Slika 208. Koeficijenti korelacije i determinacije za odabrane prediktore 350
Slika 209. Provjera značajnosti varijabli (prediktora) 351
Slika 210. Najbolji modeli za smanjenje prekomjerne proizvodnje 351
Slika 211. Najbolji prediktori dobiveni SMLR modelom 353
Slika 212. Koeficijenti korelacije i determinacije za odabrane prediktore 353
Slika 213. Provjera značajnosti varijabli (prediktora) 354
Slika 214. Najbolji prediktori dobiveni SMLR modelom 355
Slika 215. Koeficijenti korelacije i determinacije za odabrane prediktore 355
Slika 216. Provjera značajnosti varijabli (prediktora) 356
Slika 217. Najbolji modeli za smanjenje čekanja 357
Slika 218. Najbolji prediktori dobiveni SMLR modelom 358
Slika 219. Koeficijenti korelacije i determinacije za odabrane prediktore 358
Slika 220. Provjera značajnosti varijabli (prediktora) 359
Slika 221. Najbolji modeli za smanjenje prekomjerne obrade 359
Slika 222. Najbolji prediktori dobiveni SMLR modelom 360
Slika 223. Koeficijenti korelacije i determinacije za odabrane prediktore 360
Slika 224. Provjera značajnosti varijabli (prediktora) 361
Slika 225. Najbolji modeli za smanjenje nepotrebnih zaliha 362
Slika 226. Najbolji prediktori dobiveni SMLR modelom 363
Slika 227. Koeficijenti korelacije i determinacije za odabrane prediktore 363
Slika 228. Provjera značajnosti varijabli (prediktora) 364
Slika 229. Najbolji modeli za smanjenje nepotrebnih pokreta 365
Slika 230. Najbolji prediktori dobiveni SMLR modelom 366
Slika 231. Koeficijenti korelacije i determinacije za odabrane prediktore 366
Slika 232. Provjera značajnosti varijabli (prediktora) 367

Slika 233. Najbolji modeli za smanjenje škarta 368
Slika 234. Najbolji prediktori dobiveni SMLR modelom 369
Slika 235. Koeficijenti korelacije i determinacije za odabrane prediktore 369
Slika 236. Provjera značajnosti varijabli (prediktora) 370
Slika 237. Najbolji modeli za smanjenje škarta 370

POPIS TABLICA

Tablica 1. Vitki alati koji su sagledani i analizirani u ovom istraživanju [9] 35
Tablica 2. Stupovi i elementi na kojima „leži“ sustav vitke proizvodnje [10] 36
Tablica 3. Rang poduzeća prema broju prodanih automobila [24]..... 57
Tablica 4. Čimbenici koji utječu na implementaciju LP-a istraženi u 33 znanstvena rada [25].. 60
Tablica 5. Glavni razlozi za uvođenje vitke proizvodnje [26]..... 61
Tablica 6. Težnja poduzeća prilikom implementacije vitke proizvodnje [26] 62
Tablica 7. Metode implementacije vitke proizvodnje prema različitim studijama [25] 64
Tablica 8. Učestalost praksi koje su povezane s vitkom proizvodnjom [25]..... 68
Tablica 9. Rezultati vitke proizvodnje koji su dokumentirani u trideset studija [25]..... 71
Tablica 10. Šest vitkih ponašanja prema ustanovi McKinsey Global Institute [33]..... 72
Tablica 11. Najvažniji alati vitke filozofije prema vodećim autorima [34]..... 73
Tablica 12. *Proizvodni sustavi, odnosno modeli trideset svjetskih poduzeća [34]*..... 74
Tablica 13. Vitke prakse (alati) koji se najviše koriste u trideset svjetskih poduzeća [34] 75
Tablica 14. Vitki alati kojima bi se trebalo koristiti u srednje velikim poduzećima [35]..... 77
Tablica 15. Razlika između automatizacije i jidoke [82]..... 102
Tablica 16. Rang vitkih alata u automobilskoj industriji [136] 127
Tablica 17. Klasifikacija grešaka u uslužnim djelatnostima [149] 131
Tablica 18. Šest velikih gubitaka [129] 140
Tablica 19. Šest velikih gubitaka i njihove protumjere [183]..... 141
Tablica 20. Postavljanje jasnih ciljeva u poduzeću prema Peteru Druckeru [185]..... 142
Tablica 20. Postavljanje jasnih ciljeva u poduzeću prema Peteru Druckeru [185] (nastavak).. 143
Tablica 21. Prednosti TPM-a [217, 218]..... 154
Tablica 22. Implementacija TPM-a prema Hartmannu [223]..... 155
Tablica 23. Vizualna tvornica [237] 164
Tablica 24. Broj vitkih poduzeća prema veličini 171
Tablica 25. Vrste i veličine gubitaka u poduzećima prije uvođenja vitke proizvodnje..... 182
Tablica 26. Vitki alati koji su prisutni u hrvatskim poduzećima 183
Tablica 27. Redoslijed uvođenja vitkih alata prema ispitanicima 187
Tablica 28. Vrste i veličine poboljšanja nakon uvođenja vitke proizvodnje 189
Tablica 29. Statistička značajnost između duljine primjene vitke proizvodnje i smanjenja određene kategorije gubitka 192
Tablica 30. Vitki alati i smanjenje gubitaka 196
Tablica 31. Statistička značajnost između poduzeća koja primjenjuju i ne primjenjuju određeni vitki alat u smanjenju određenog gubitka 197
Tablica 32. Statistički značajna razlika srednjih vrijednosti napretka u smanjenju gubitka između poduzeća koja su koristila i koja nisu koristila određeni vitki alat 198
Tablica 33. Vitki alati koji su najpogodniji za smanjenje gubitaka 199
Tablica 34. Vitki alati koji najbolje smanjuju gubitke..... 201
Tablica 35. Vitki alati koji najbolje smanjuju određene gubitke 202

POPIS KRATICA

Kratica	Opis
BDP	bruto domaći proizvod
BPR	reinženjering poslovnih procesa (engl. *Business Process Re-engineering*)
CAD	oblikovanje pomoću računala (engl. *Computer-Aided Design*)
CI	kontinuirano poboljšanje (engl. *Continuous Improvement*)
CIP	kontinuirano poboljšanje procesa (engl. *Continuous Improvement Process*)
CNC	računalno upravljanje i kontrola (engl. *Computer Numerical Control*)
EBIT	dobit prije rashodnih kamata i poreza (engl. *Earnings Before Interest and Taxes*)
EBITDA	dobit prije rashodnih kamata, poreza i amortizacije (engl. *Earnings Before Interest, Taxes, Depreciation and Amortization*)
ERP	sustav upravljanja resursima (engl. *Enterprise Resource Planning*)
EPEI	proizvodnja svih dijelova u svakom periodu (engl. *Every part every period*)
EVA	ekonomska dodana vrijednost (engl. *Economic Value Added*)
FCF	slobodni novčani tok (engl. *Free Cash Flow*)
GM	korporacija General Motors
JIT	pravovremena proizvodnja, proizvodnja bez zaliha (engl. *Just In Time*)
KPI	ključni indikatori učinkovitosti (engl. *Key Performance Indicators*)
LP	vitka proizvodnja (engl. *Lean Production*)
LPS	sustav vitke proizvodnje (engl. *Lean Production System*)
MBO	menadžment ciljeva (engl. *Management By Objectives*)
QCDE	sustav razvoja kvalitete, cijene, organizacijskih procesa i edukacije (engl. *Quality, Cost, Delivery, Education*)
OEE	cjelokupna učinkovitost opreme (engl. *Overall Equipment Effectiveness*)
PDCA	planiraj, učini, provjeri i djeluj (engl. *Plan-Do-Check-Act*)
PDSA	planiraj, učini, prouči, djeluj (engl. *Plan-Do-Study-Act*)
P/E	omjer trenutačne tržišne cijene i zarade po dionici (engl. *Price-to-Earnings ratio*)
PLC	programibilni logički kontroler (engl. *Programmable Logic Controller*)
RCA	analiza glavnog uzroka (engl. *Root cause analysis*)
ROA	povrat na imovinu (engl. *Return On Asset*)

ROE	povrat na kapital (engl. *Return on Equity*)
ROI	povrat od ukupnog uloženog kapitala (engl. *Return on Investment*)
ROS	povrat od prometa (engl. *Return on Sales*)
SMART	konkretni, mjerljivi, dostižni, relevantni i vremenski određeni ciljevi (engl. *Specific, Measurable, Attainable, Relevant and Time-Specific goals*)
SMED	brza izmjena alata (engl. *Single-Minute Exchange of Die*)
SPSS	statistički program za društvene znanosti (engl. *Statistical Package for the Social Science*)
TPM	cjelovito produktivno održavanje (engl. *Total Productive Maintenance*)
TPS	Toyotin proizvodni sustav (engl. *Toyota Production System*)
TQM	cjelovito upravljanje kvalitetom (engl. *Total Quality Management*)
VSM	mapiranje toka vrijednosti (engl. *Value Stream Mapping*)
WIP	poluproizvod koji čeka doradu (engl. *Work In Proces*)

1. UVOD

U ovome poglavlju dan je kratak uvid u vitku proizvodnju te su istaknuti cilj i hipoteza rada, metodologija i plan istraživanja te očekivani znanstveni doprinos.

1.1. Definicija vitke proizvodnje

Vitka proizvodnja (engl. *lean production*) je suvremeni koncept optimalnog upravljanja procesima, ljudima, operacijama, informacijama i ostalim aktivnostima na odgovarajući i pravovremen način, s krajnjim ciljem pronalaska savršenog tijeka svih navedenih resursa i aktivnosti. Jednostavnije rečeno, to je beskonačna potraga za savršenstvom. Sanjarenje savršenstva je zabavno, ali isto tako i korisno jer se otkriva stvarni potencijal te se postiže više od očekivanog. Međutim, iako vitko razmišljanje čini traganje za savršenstvom mogućim na duže razdoblje, većina nas, općenito gledajući, živi i radi u kratkom životnom razdoblju. Postavlja se pitanje samo po sebi: koje su prednosti vitkog razmišljanja koje se mogu shvatiti i primijeniti odmah?

Na temelju studija sustavnog vrednovanja (engl. *benchmarking*) organizacija u cijelom svijetu dobivene su sljedeće jednostavne zakonitosti koje pokazuju smjer i rezultate vitkog razmišljanja:

1) Pretvorba klasične masovne proizvodnje u kontinuiranu proizvodnju koja je orijentirana na kupca, udvostručit će produktivnost na svim razinama. To znači da će produktivnost biti povećana po pitanju upravljanja, rukovođenja i samog rada. Očekivano smanjenje vremena proizvodnje i zaliha može biti do 90 %.
2) Greške i škart upola se smanjuju, ali isto tako i ozljede koje proizlaze iz rada.
3) Vrijeme potrebno za plasman novih proizvoda na tržište upola se smanjuje, a različiti proizvodi unutar proizvodnih grupa mogu biti ponuđeni po manjim dodatnim troškovima.
4) Nužna kapitalna ulaganja bit će mala i neznatna te nekada neće ni postojati jer nepotrebna imovina može biti oslobođena i prodana pritom stvarajući novu vrijednost.

Sva ta načela vitkog razmišljanja tek su početak, odnosno ona predstavljaju ono što u Japanu nazivaju *kaikaku*, to jest temeljne i radikalne promjene. Ono što slijedi i što je vrlo zahtjevno, kontinuirane su promjene koje vode do poboljšanja, odnosno, kako to u Japanu nazivaju, *kaizen*. Tvrtke koje pokrenu i dovrše radikalna restrukturiranja obično udvostruče produktivnost te malenim kontinuiranim koracima smanje zalihe, pogreške i vrijeme proizvodnje unutar tri godine. Rezultat *kaikakua* i *kaizena* stvaranje je pozitivnih promjena [1].

Sustav vitke proizvodnje (engl. *Lean Production System*, LPS) postao je svojevrsno posljednje dostignuće u kontekstu upravljanja organizacijama. Unatoč toj činjenici, tek nekolicina poduzeća uspjela je uspješno implementirati održivo kontinuirano poboljšanje procesa (engl. *Continuous*

Improvement Process, CIP). Često se ljudi previše usredotoče na same metode poboljšanja procesa jer su one jedine vidljive sastavnice sustava vitke proizvodnje. Međutim, ključna su sastavnica kontinuiranog napretka ljudi i kultura ophođenja prema poslu. Metode i alati vitke proizvodnje veoma su važni, no oni ne mogu postići puni uspjeh ako vodeći ljudi ne poznaju i dubinski ne osjećaju vitku proizvodnju. Implementacija metoda i alata vitke proizvodnje doista je lakši dio posla prilikom tranzicije poduzeća prema vitkim načelima, ali najveći je izazov promjena ponašanja, mentaliteta i kulture kako zaposlenika tako i vodećih ljudi. Najveća razlika između pristupa vitke i masovne proizvodnje upravo je uloga zaposlenika. U bazičnoj filozofiji vitke proizvodnje ne postoji razlika između intelektualnih i manualnih radnika, odnosno proces optimizacije poslovnih procesa decentraliziran je u nadi da se prešutno stečeno znanje radnika o operativnim problemima iskoristi na najbolji način te se izvuče maksimalna dobit od istih [2].

Posebno mjesto u sustavu vitke proizvodnje ima vrijednost koju njeguje i traži kupac. Kupac je taj koji određuje ima li neka aktivnost dodanu ili nikakvu vrijednost. Generalno gledajući, kupac je taj koji plaća ispravnost, kvalitetu, oblik i dizajn proizvoda, a njega ne zanimaju organizacijske aktivnosti proizvođača niti kako proizvodni pogoni proizvođača izgledaju. Uzimajući u obzir tu činjenicu, stil rukovođenja kao aktivnost nikada ne može stvoriti dodanu vrijednost za kupca, preciznije rečeno, rukovoditelji vitkog menadžmenta ne dodaju novu vrijednost proizvodu. Vrijednost proizvodu daju upravo radnici, a rukovoditelji su samo kreatori optimalnog radnog okruženja. Održiva implementacija vitke proizvodnje zahtijeva promjene u temeljnim dnevnim aktivnostima koje se odvijaju između radnika i rukovoditelja poslova. Kako bi se postigla bolja radna i organizacijska kultura, upravo direktori, rukovoditelji i voditelji svojim primjerom trebaju pokazivati željeno stanje [2].

Postoje jasni dokazi i činjenice da su vitke metode i alati uvelike pomogle proizvodnim poduzećima poboljšati njihove procese i aktivnosti. Međutim, stvarni učinci vitkih alata prema suvremenim parametrima operativne učinkovitosti kao što su cijena, brzina, pouzdanost, kvaliteta i fleksibilnost, još uvijek nisu jasni i dovoljno istraženi. U studiji koja je obuhvatila ovu tematiku i pet osnovnih vitkih alata, kao što su pravovremena proizvodnja (engl. *Just In Time,* JIT), cjelovito produktivno održavanje (engl. *Total Productive Maintenance,* TPM), *jidoka* (engl. *autonomation*), mapiranje toka vrijednosti (engl. *Value Stream Mapping,* VSM) i kontinuirano poboljšanje (jap. *kaizen*), došlo se do zaključaka koji se nalaze u nastavku [3].

JIT i *jidoka* najviše utječe na parametre operativne učinkovitost te bi se oni morali implementirati s velikom pažnjom. *Kaizen* utječe na mnoštvo parametara operativne učinkovitosti, ali pritom ima vrlo skromnu značajnost na brzinu i kvalitetu. TPM i VSM vrlo slabo utječu na sve navedene parametre. Takav je rezultat zapanjujući te, u neku ruku, i proturječan jer je velik broj znanstvenih autora dokazao da su TPM i VSM vrlo učinkoviti kod ostvarenja optimalne učinkovitosti unutar poduzeća [3].

Vitka proizvodnja superioran je koncept upravljanja procesima koji omogućava proizvodnju boljih proizvoda i usluga, većih varijacija, ali po nižoj cijeni [4a].

Kada su Henry Ford i Alfred Sloan osmislili masovnu proizvodnju, ta ideja proizvodnje ubrzo je postala uključena u svaku poru poslovnog svijeta. Cijeli je svijet shvatio da je proizvodnja koja se temelji na obrtima dotakla svoju granicu. Ono što je još važnije, mnogi segmenti sustava masovne proizvodnje bili su nehotice testirani mnogo prije prave pojave masovne proizvodnje. Tako su se u mesnoj industriji već potkraj 19. stoljeća koristile montažne proizvodnje linije za preradu mesa te je ta industrija u neku ruku pionir masovne proizvodnje. Isto tako, 1890. godine industrija bicikala razvila je neke tehnike obrade metala i strojne alate koje je Henry Ford kasnije samo preuzeo. Još su i prije toga interkontinentalne željeznice razvile mnoge organizacijske mehanizme za operativno upravljanje poduzećima na širokom prostoru. No Ford i Sloan ipak su bili prvi koji su usavršili cijeli sustav takve proizvodnje (sustav postrojenja, koordinacija s dobavljačima, horizontalno i vertikalno upravljanje unutar organizacije) te su sve to uparili s novim konceptom tržišta i novim sustavom distribucije. Na taj je način autoindustrija postala simbol masovne proizvodnje te pionir novog sustava zadovoljavanja tržišta. Cijeli se sustav brzo raširio na ostale industrijske grane u SAD-u dvadesetih godina prošlog stoljeća te je vrlo brzo bio općeprihvaćen kao novi smjer u gotovo cijeloj proizvodnoj industriji. Povrh toga, masovna proizvodnja bez previše uspjeha iskušana je u jednoj jedinstvenoj industriji, a to je stanogradnja, gdje su pojedini poduzetnici krenuli stopama Henryja Forda [4b].

Ideja masovne proizvodnje u Europi bila je problem na samo za autoindustriju, već i za ostale grane industrija. Intelektualci, posebno ljevičari, na jednoj su razini prihvatili ideju masovne proizvodnje u namjeri da podignu životni standard širokih masa. Ubrzo su slike masovne i suvremene proizvodnje postale središnja tema cijele Europe. Međutim, u tvornicama u bilo kojoj grani proizvodnje, slaba i spora prilagodba na masovnu proizvodnju, kako od strane radnika tako i od strane rukovoditelja, bila je svakidašnjica. Nedostatak integriranog europskog tržišta također je predstavljao nepremostivu zapreku za potpuni razvoj masovne proizvodnje. Tek nakon Drugog svjetskog rata masovna proizvodnja postala je općeprihvaćena diljem Europe, na način da se počela uvoziti radna snaga iz slabije razvijenih zemalja koja je bila voljna raditi u teškim i monotonim uvjetima masovne proizvodnje [4b].

Baš kao što su Henry Ford i Paul Sloan plovili morima novih ideja, poslijeratni kaos u Japanu iznjedrio je plodno tlo za nove ideje i promišljanja. Mnoge tehnike koje su u sustav vitke proizvodnje kreirali i ugradili Eiji Toyoda i Taiichi Ohno, u isto su vrijeme razvijane i testirane i u drugim industrijama. Tako je, na primjer, ideja povećanja udjela kvalitetnih proizvoda koju je zagovarao poznati američki savjetnik William Edward Deming, bila istovremeno uvođena u SAD-u i Japanu u raznim industrijama. Ne treba zanemariti ni to da su tvorci novih suvremenih principa proizvodnje isto tako bili prisiljeni prihvatiti i neke nove društvene okolnosti, preciznije, više nije bilo moguće zapošljavati i otpuštati radnike na dnevnoj bazi (engl. *hire-and fire-policy*), već se radnici prvi put pojavljuju u ekonomskom pojmu kao fiksni troškovi, a njihova prava iz

dana u dan postaju sve bolja. Ono što je pak genijalno kod vitke proizvodnje upravo je to što ona sadrži najbolje elemente od masovne, ali i od obrtničke proizvodnje. Bolje rečeno, primjenom vitke proizvodnje tvrtka ima mogućnost smanjenja cijene proizvoda te u isto vrijeme povećanja kvalitete proizvoda te se u konačnici otvara mogućnost proizvodnje više različitih proizvoda. Vitka proizvodnja upravo je ta poveznica koja nedostaje između obrtničke i masovne proizvodnje te je upravo zato vitka proizvodnja sadašnjost i budućnost suvremene proizvodnje [4b].

Gotovo sva razvijenija društva počela su primjenjivati model vitke proizvodnje krajem prošlog stoljeća te se ovaj model upravljanja proizvodnim i uslužnim djelatnostima pokazao uspješnim na globalnoj razini. Za širenje masovne proizvodnje diljem svijeta bilo je potrebno više od pola stoljeća, a predstoji vidjeti koliko će vremena i napora biti potrebno da se vitka proizvodnja raširi diljem svijeta.

1.2. Cilj i hipoteza rada

Mnoge organizacije pokušavaju implementirati i adaptirati sustav vitke proizvodnje. Iako su temeljne pretpostavke vitke proizvodnje poznate te su metode i alati vitke proizvodnje egzaktni i dokumentirani, brojne organizacije ne uspijevaju poboljšati poslovne procese pomoću sustava vitke proizvodnje. Problem je taj što je implementacija vitke proizvodnje u organizaciju složen, dug i zamoran postupak. Jedan od uzroka ovog problema proizlazi iz činjenice da je postupak implementacije vitke proizvodnje difuzno i nejasno prikazan u različitim literaturama [5]. No najveći problem prilikom implementacije sustava vitke proizvodnje upravo je slijepo kopiranje vitkih alata iz literature te primjena u poduzećima. Temelj vitke proizvodnje upravo je to što se vitki alati prilagođavaju proizvodnim sustavima te što se isti kreiraju i prilagođavaju na razini mikrolokacija. Kontinuirano unaprjeđenje, kao jedan od temeljnih stupova vitke proizvodnje, mora imati jaku lokalnu primjenu kako bi se poboljšanje dogodilo. Motivacija za kontinuirano poboljšanje gradi se na zajedničkim i jasnim ciljevima, ali i entuzijazmu vodećih ljudi. Upravo su vodeći ljudi organizacija ključni za promicanje i implementaciju vitke filozofije. Poduzeća u biti trebaju pružati kvalitetne i edukativne radionice o vitkim metodama i alatima kako bi zaposlenici postali što samostalniji te kako bi se poslovni procesi događali po samoj sili inercije. Jednako tako poduzeća trebaju snažno raditi na pojednostavljivanju poslovnih procesa kako bi protok svih resursa bio što prirodniji. Također, ne treba zanemariti snagu radničkih sindikata koji mogu uvelike pomoći kod osnaživanja i prenošenja svih načela vitke proizvodnje te je prirodno mijenjati kulturu ophođenja i discipline prema radu kroz sindikalna tijela. Ono što se nameće samo po sebi je da upravitelji moraju koncizno naglašavati smjer kretanja poduzeća, a radnici moraju imati i razumjeti željeni cilj [6].

Uspješna implementacija vitke proizvodnje zahtjeva integrirano i usporedno uvođenje vitkih elemenata te pravovremeno uvođenje pojedinih vitkih alata. Savršena implementacija vitke

proizvodnje može se dogoditi samo pomoću optimalnog redoslijed uvođenja određenih elemenata [7].

Cilj rada glasi:

pronaći najpogodnije osnovne vitke alate te njihov redoslijed implementacije prilikom restrukturiranja poduzeća kako bi se poslovanje dovelo u bolje operativno i financijsko stanje.

Hipoteza rada glasi:

postupak implementacije vitke metodologije prilikom restrukturiranja poduzeća učinkovit je ako postoji pravilan izbor i redoslijed uvođenja pojedinih alata vitkog menadžmenta.

Prihvaćanje sustava vitke proizvodnje pitanje je osjećaja za upravljanje, ali i pitanje zdravorazumske logike. Čovjek mora bezuvjetno i trajno vjerovati u implementaciju vitkih principa i alata te ih primijeniti za esencijalno postojanje organizacije. Sustav vitke proizvodnje ne čine samo vitke metode i alati, već ta filozofija mora postati način razmišljanja, vjerovanja, ponašanja i temeljnih vrijednosti. Glavne zadaće prilikom stvaranja vitke kulture trebale bi biti izgradnja vizije, brzo provođenje vizije, promoviranje i poticanje vitke edukacije, stvaranje obveze i privrženosti prema vitkoj proizvodnji te pridobivanje naklonosti rukovoditelja poslova prema sustavu vitke proizvodnje. Ono što bi svakako mogle biti olakotne okolnosti prilikom implementacije vitkog sustava proizvodnje upravo činjenice su da se ljudi vole educirati te vole da ih se shvaća kao osobe koje žele napredovati. Nadalje, česta praksa vitke filozofije novčano je nagrađivanje zaposlenika za integriranje vitkih načela u njihov svakodnevni posao, što može biti izuzetno stimulirajuće i zabavno kako na kratke tako i na duge staze. Stvarajući atmosferu nagrađivanja za realnu primjenu vitkih metoda, zaposlenici ne dobivaju samo novčanu nagradu, već i osjećaj ponosa jer je ta ideja njihovo vlasništvo. S druge pak strane, prilikom adaptacije sustava vitke proizvodnje mogu nas sputavati situacije kao što su mentalitet masovne proizvodnje, strah od nepoznatog, loša komunikacija, nedostatak znanja o vitkoj proizvodnji, strah od krajnjeg ishoda, ali i razmišljanje zaposlenika kako vizija poduzeća nema nikakve veze s njima samima [8].

1.3. Metodologija i plan istraživanja

Ovo istraživanje sastoji se od iscrpnog pregleda istraživačkih radova iz područja vitke proizvodnje u proteklih nekoliko godina i anketnog dijela rada, u kojem su svi dobiveni rezultati analizirani i evaluirani kako bi se došlo do krajnjeg optimalnog zaključka. Sistematizacija vitkih alata napravljena je prema snazi alata, implementacijskom razdoblju te održivosti samih alata u pojedinim situacijama i okolnostima. Cilj ovog razmišljanja bilo je dobiti kvalitativne i kvantitativne podatke iz postupka restrukturiranja proizvodnih sustava. Potrebno je naglasiti da se koncept ovog rada većinom temelji na provedenoj anketi o implementacijskom postupku vitke

proizvodnje te je ona provedena kako bi se došlo do novih egzaktnih podataka o implementacijskom postupku u realnim poduzećima. U ovome radu je sagledano i analizirano 25 osnovnih vitkih alata koji su prikazani u Tablici 1.

Tablica 1. Vitki alati koji su sagledani i analizirani u ovom istraživanju [9]

VITKI ALAT	OPIS	UTJECAJ
5S **(uređenje prostora)**	Organizacija radnog prostora prema pravilima: 1) sortiranje (engl. *Sort*) – eliminacija svih nepotrebnih stvari za rad 2) red (engl. *Set in Order*) – organizacija preostalih radnih stvari prema prioritetu i potrebi 3) čišćenje (engl. *Shine*) – držati radni prostor čistim i urednim te ga povremeno preispitati 4) standardizacija (engl. *Standardize*) – uspostavljanje standardnih rutina za prethodne korake 5) samodisciplina (engl. *Sustain*) – redovita primjena propisanih procedura za rad te prilagodba novonastalim situacijama.	Eliminacija gubitaka koji su rezultat loše organizacije i radnog prostora (npr. gubitci uslijed traženja potrebnog alata).
ANDON (jap. lampa)	Vizualni povratni sustav proizvodnog pogona koji pokazuje status proizvodnje, upozorava kada je potrebna pomoć te ukazuje operateru na to kada treba prekinuti proizvodni proces.	Djeluje kao komunikacijski alat u stvarnom vremenu koji odmah ukazuje na probleme koji se pojave kako bi se odmah mogli locirati i riješiti.
ANALIZA USKIH GRLA (engl. *Bottleneck analysis*)	Određuje koji dio proizvodnog procesa ograničava ukupnu propusnost proizvodnje te poboljšava učinkovitost tog dijela procesa.	Poboljšava propusnost proizvodnog procesa jačanjem najslabije karike proizvodnog procesa.
KONTINUIRANI TOK (engl. *Continuous flow*)	Proizvodnja u kojoj se procesi odvijaju glatko uz minimalne ili nikakve zastoje između operacija proizvodnog procesa.	Eliminacija mnogih oblika gubitaka (npr. zalihe, transport, zastoji...).
GEMBA (engl. *The real place*)	Filozofija koja potiče odlazak iz ureda i sagledavanje stvarne situacije u proizvodnom pogonu.	Promovira se duboko i cjelokupno razumijevanje proizvodnih problema na način da se problemi vide iz „prve ruke“.
HEIJUNKA **(niveliranje proizvodnje)** (engl. *Level scheduling*)	Model planiranja i organizacije proizvodnje u kojem se namjerno proizvodi u manjim serijama na način da se kombiniraju različiti poluproizvodi unutar istog proizvodnog procesa.	Smanjuje se vodeće vrijeme (svaki se proizvod češće proizvodi) i zalihe (jer su serije manje).
HOSHIN KANRI **(politika razvoja)** (engl. *Policy deployment*)	Usklađivanje ciljeva poduzeća (strategije) s ciljevima srednjeg menadžmenta (taktike) i obavljanja rada u proizvodnim pogonima (akcije).	Osigurava se dosljedan i sveobuhvatan napredak prema strateškim ciljevima na način da se eliminira gubitak koji proizlazi iz loše komunikacije i nedosljedne orijentacije.
JIDOKA **(parcijalna automatizacija)** (engl. *Autonomation*)	Projektiranje opreme na način da se djelomično automatizira proces proizvodnje (znatno jeftinija od potpune automatizacije) i automatsko zaustavi kada se otkriju nedostaci.	Nakon implementacije *jidoke* radnici mogu nadgledati nekoliko radnih stanica (smanjenje troškova rada) te se problemi vezani uz kvalitetu detektiraju odmah (poboljšanje kvalitete).
JIT **(pravovremena proizvodnja)** (engl. *Just in Time*)	Povlačenje dijelova kroz proizvodnju temeljeno na zahtjevu kupca, umjesto guranja dijelova kroz proizvodnju na osnovi potražnje. Ovaj alat oslanja se na mnoge vitke alate kao što su kontinuirani tok, *heijunka*, *kanban*, standardizirani rad i taktno vrijeme.	Izuzetno učinkovit alat za smanjenje zaliha na različitim razinama. Ovaj alat povećava novčani tok (engl. *cash flow*) te smanjuje zahtjeve vezane uz radni prostor.

Tablica 1. Vitki alati koji su sagledani i analizirani u ovom istraživanju [9] (nastavak)

KAIZEN (kontinuirano poboljšanje) (engl. *Continuous improvement*)	Strategija u kojoj radnici zajedno aktivno i kontinuirano rade na postizanju promjena i poboljšanja u proizvodnom sustavu.	Ovaj alat kombinira različite organizacijske talente te kreira svojevrstan motor za kontinuirano smanjenje gubitaka u proizvodnom procesu.
***KANBAN* (metoda za regulaciju robe i zaliha)** (engl. *Pull system*)	Metoda za regulaciju i uređenje protoka robe unutar proizvodnog pogona te vanjskih dobavljača i kupaca. Temelji se na automatskom nadopunjavanju kroz signalne kartice koje ukazuju na to kada je potrebno više robe.	Eliminira se gubitak vezan uz zalihe i prekomjernu proizvodnju. Može se eliminirati potreba za fizičkim zalihama (oslanjajući se na signalne kartice koje ukazuju na potrebu za robom).
Ključni indikatori učinkovitosti (engl. *Key Performance Indicators*)	Metrika dizajnirana za praćenje i poticanje napretka prema ključnim ciljevima organizacije. Snažno promovirani indikatori učinkovitosti mogu biti izniman pokretač ponašanja te je stoga važno da se odaberu vrlo pažljivo kako bi se željeno ponašanje ostvarilo.	Najbolji ključni indikatori učinkovitosti u proizvodnji su: 1) indikatori koji su usklađeni s najvažnijim strateškim ciljevima 2) indikatori koji su učinkoviti u otkrivanju i kvantificiranju gubitaka (jako dobar primjer toga je OEE alat) 3) indikatori koji izravno i brzo utječu na zaposlenike u proizvodnom pogonu.
***MUDA* (uklanjanje gubitka)** (engl. *Waste*)	Uklanjanje svih gubitaka u proizvodnom sustavu, što iz perspektive kupca nema dodanu vrijednost.	Eliminiranje gubitaka primarni je fokus sustava vitke proizvodnje.
OEE (cjelokupna učinkovitost opreme) (engl. *Overall Equipment Effectiveness*)	Ovaj alat okvir je za mjerenje proizvodnih gubitaka u određenom procesu proizvodnje. Prate se tri kategorije gubitaka: 1) dostupnost stroja ili opreme (npr. vrijeme ispada iz rada) 2) učinkovitost stroja (npr. sporost ciklusa) 3) kvaliteta proizvoda (npr. udio škarta).	Ovaj alat osigurava referentu točku, to jest temelj za praćenje napretka pri eliminaciji gubitaka u proizvodnom procesu. Kada je OEE 100 %, to znači da je stanje proizvodnog procesa savršeno (proizvode se samo ispravni proizvodi, brzina proizvodnje je najveća moguća te nema zastoja).
PDCA (engl. *Plan, Do, Check, Act*)	Ovo je iterativna metoda za implementaciju poboljšanja: 1) planiraj (uspostavi plan i željene rezultate) 2) učini (implementiraj plan) 3) provjeri (kontrola postignutih i željenih rezultata) 4) djeluj (preispitaj i reagiraj na promjene u sustavu te to ponavljaj).	Primjenjuje se znanstveni pristup za poboljšanje: 1) planiraj (razvij hipotezu) 2) učini (izvedi eksperiment) 3) provjeri (procjeni rezultate) 4) djeluj (usavrši eksperiment te ga izvedi ponovno).
***POKA-YOKE* (izbjegavanje pogreške)** (engl. *Error proofing*)	Projektiraj sustav za detekciju i prevenciju grešaka u proizvodnom sustavu s ciljem postizanja proizvodnje bez grešaka.	Izuzetno je teško i skupo pronaći sve nedostatke kontrolama te je ispravljanje grešaka znatno skuplje sa svakom sljedećom fazom proizvodnje.
ANALIZA GLAVNOG UZROKA (engl. *Root cause analysis*)	Metoda rješavanja problema u kojoj se fokusira na korijen problema, a ne na brze popravke i površne simptome problema. Uobičajen pristup je postaviti si pet puta pitanje zašto se nešto dogodilo, svaki put se sve više približavajući korijenu problema.	Ovaj alat pomaže kod osiguranja da je problem uistinu eliminiran te da su korektivne radnje uistinu kvalitetno odrađene.

Tablica 1. Vitki alati koji su sagledani i analizirani u ovom istraživanju [9] (nastavak)

SMED **(brza izmjena alata)** (engl. *Single-Minute Exchange of Die*)	Ovaj alat omogućava izmjenu ili podešavanje alata unutar deset minuta. Tehnike koje to omogućuju su: - pretvaranje svih mogućih aktivnosti kod zamjene alata u vanjske, tj. sve aktivnosti vezane uz izmjenu alata trebaju se odvijati dok stroj još radi - pojednostavljivanje unutarnjih aktivnosti (one aktivnosti koje se odvijaju dok stroj stoji) - eliminacija nebitnih operacija - kreiranje standardiziranih radnih uputa.	Omogućava se fleksibilnija proizvodnja u malim serijama, smanjuju se zalihe te se poboljšava odziv na zahtjev kupca.
ŠEST VELIKIH GUBITAKA (engl. *Six Big Losses*)	Ovaj alat kategorizira šest gubitaka u proizvodnji, koji se gotovo univerzalno pojavljuju u proizvodnom sustavu: - kvarovi i zatajenja - montaže, izmjene i podešavanja - kratki zastoji - usporenja u proizvodnji - gubici tijekom uhodavanja stroja - proizvedeni udio nekvalitetnih proizvoda.	Osigurava radni okvir za smanjenje najčešćih uzroka gubitaka u proizvodnom procesu.
PAMETNI CILJEVI (engl. *Specific, Measurable, Attainable, Relevant and Time-Specific goals*)	Ciljevi koji su konkretni, mjerljivi, dostižni, relevantni i vremenski određeni.	Pomaže osigurati učinkovitost ciljeva.
STANDARDIZACIJA RADA (engl. *Standardized work*)	Dokumentirane procedure u proizvodnji koje obuhvaćaju najbolje prakse (uključujući i vrijeme za izvršenje svakog zadataka). Moraju biti „žive“ procedure koje se lako mijenjaju.	Eliminacija gubitaka stalnom uporabom najboljih praksa. Oblikuje se referentna točka za buduće aktivnosti poboljšanja procesa.
TAKTNO VRIJEME (engl. *Takt time*)	Ovaj alat prati i određuje ritam proizvodnje (npr. svakih 36 sekundi napravimo jedan specifičan proizvod) koji usklađuje proizvodnju sa zahtjevima kupaca. Računa se kao planirano vrijeme proizvodnje / zahtjev kupca.	Osigurava jednostavnu, dosljednu i intuitivnu metodu za određivanje ritma proizvodnje. Vrlo se lako primjenjuje kod osiguranja učinkovitih ciljeva u samim radionicama (stvaran broj proizvoda / ciljani broj proizvoda).
TPM **(cjelovito produktivno održavanje)** (engl. *Total Productive Maintenance*)	Cjelovit pristup održavanju koji je usmjeren na proaktivno i preventivno održavanje kako bi se maksimiziralo operativno vrijeme strojeva i opreme. TPM premašuje granicu i razliku između održavanja i proizvodnje, gdje se operatera potiče na održavanje opreme.	Stvara se zajednička odgovornost za stanje opreme te se potiče veće uključenje radnika u održavanje. U pravom okruženju ovaj alat može biti jako učinkovit za poboljšanje produktivnosti (povećavajući eksploatacijsko vrijeme strojeva, smanjenje radnih ciklusa te otklanjanje nedostataka).
VSM **(mapiranje toka vrijednosti)** (engl. *Value Stream Mapping*)	Alat koje se koristi za vizualizaciju toka proizvodnje. Prikazuje trenutno i buduće stanje proizvodnog procesa na način da se istaknu prilike za poboljšanje.	Ovaj alat ističe gubitke u sadašnjem proizvodnom procesu te osigurava put za poboljšanje istog procesa.
VIZUALNA TVORNICA (engl. *Visual factory*)	Vizualni indikatori i kontrola proizvodnog sustava koja omogućuje bolje informiranje i komunikaciju.	Osigurava se stanje u kojem je vrlo lako pratiti proizvodni sustav te svi imaju uvid u trenutno stanje.

1.4. Očekivani znanstveni doprinos

Očekuje se da će rad, koji se temelji na iscrpnom pregledu literature iz područja vitke proizvodnje te anketi i analizi, rezultirati sljedećim znanstvenim doprinosima:

1. definiranjem najpogodnijih osnovnih vitkih alata pri restrukturiranju poduzeća, to jest pronalaskom šireg spektra vitkih alata koji sami ili u paru pozitivno utječu na smanjenje određenih gubitaka
2. definiranjem najboljih temeljnih vitkih alata pri restrukturiranju poduzeća, to jest pronalaskom vitkih alata koji sami značajno utječu na smanjenje određenih gubitaka
3. modelom pravilnog redoslijeda uvođenja vitkih alata pri restrukturiranju poduzeća.

2. VITKA PROIZVODNJA

U ovome je poglavlju definiran sustav vitke proizvodnje, kategorizirani su gubitci, navedeni načini i čimbenici koji utječu na implementaciju te predstavljeni ciljevi i rezultati.

2.1. Sustav vitke proizvodnje

Vitka proizvodnja (engl. *Lean Production*, LP) je poslovna filozofija čiji je cilj postizanje izvrsnosti kod organizacijskih operacija i aktivnosti. Poduzeća se danas stalno bore s dva izazovna problema. Prvi je borba s učinkovitom implementacijom naprednih proizvodnih filozofija, a drugi je problem stalna borba s učestalim promjenama zahtjeva kupaca vezano uz veću kvalitetu, niže cijene i brže isporuke proizvoda. Uzimajući u obzir ta dva navedena izazova, poduzeća moraju ulagati velik napor i trud kako bi usvojili nove suvremene filozofije te kako bi naposljetku ostali konkurentan natjecatelj. Kada bismo morali definirati filozofiju sustava vitke proizvodnje, tada bismo mogli reći da cjelokupna vitka proizvodnja „leži“ na jedanaest stupova, odnosno jedanaest načela prikazanih u Tablici 2. [10].

Tablica 2. Stupovi i elementi na kojima „leži“ sustav vitke proizvodnje [10]

R. br.	STUP	ELEMENT
1	**Kontinuirano poboljšanje** (engl. *Continuous Improvements*)	• multifunkcionalni timovi • mapiranje toka vrijednosti (VSM) • fleksibilnost procesa • pojednostavljenje procesa i proizvoda • korištenje horizontalne hijerarhije • vitko sustavno vrednovanje • integriranje razvoja proizvoda i procesa.
2	**Standardizacija rada**	• standardizacija materijala • standardizacija proizvoda • standardizacija opreme i alata • 5S • standardizacija radnih procedura • *jidoka* • slične platforme i modularni dizajn sa standardiziranim dijelovima • vizualne kontrolne ploče.
3	**Sustav informacijske tehnologije**	• razmjena podataka između dobavljača i kupaca • ERP sustav • uporaba informacijskih tehnologija • razvoj standardiziranih tokova informacija kroz sustav nabave • brza izrada prototipova • modeliranje analiza i simulacijskih alata ili računalno podržanih programa (CAD) • računalno integrirani sustav održavanja.

Tablica 2. Stupovi i elementi na kojima „leži“ sustav vitke proizvodnje [10] (nastavak)

4	**Eliminacija gubitaka**	• osam gubitaka • smanjenje WIP-a • ćelijska organizacija proizvodnje • specijalizirana proizvodnja • smanjenje skladišta • sinkronizacija toka materijala i procesa s ciljem paralelnog izvođenja operacija • SMED • neometano odvijanje proizvodnje • ravnomjerno radno opterećenje.
5	**Konkurentan inženjering**	• uključenje dobavljača i kupaca u rani razvoj • menadžment raznolikosti proizvoda • menadžment redoslijeda poslova • analiza vrijednosti / inženjering vrijednosti • funkcija glavnog inženjera • projektiranje koje brine o proizvodnji i montaži • brza transformacija ideja u proizvod • reagiranje na greške i učinkovita analiza.
6	**Pravovremena proizvodnja** (engl. *Just in Time*)	• kontinuiran protok svakog proizvoda • proizvodnja u malim serijama • proizvodnja temeljena na sustavu povlačenja • *kanban* • JIT isporuke kroz cijeli sustav nabave • raspored proizvodnog pogona • svrha korištenja skladišta.
7	**Upravljanje ljudskim potencijalima**	• zaposlenici s više vještina • uključenost zaposlenika u svaki dio organizacije • inovativne inicijative zaposlenika te vlastiti razvoj • obuka i edukacija različitih vještina • stabilno i dugotrajno zaposlenje • obogaćenje posla • sustav nagrađivanja.
8	**Menadžment povezanosti s dobavljačima**	• aktivnosti razvoja i obuke dobavljača • evaluacija i ovjera dobavljača • povratna veza s dobavljačima • blizina dobavljača • jedinstveni i pouzdani dobavljači • dugoročno partnerstvo s dobavljačima • upravljanje dobavljačima kroz robne timove.
9	**Posvećenost vrhovnog menadžmenta**	• vitka misija i vizija • dugoročno poslovno razmišljanje • horizontalan i vertikalan sustav informiranja • specijalizirani karijerni put za menadžere u različitim poljima organizacije • stvaranje kulture učenja unutar organizacije • cjelovita strategija za integraciju sustava ili implementaciju organizacijske politike • učinkovito razvijanje upravljanja i vođenja.

Tablica 2. Stupovi i elementi na kojima „leži“ sustav vitke proizvodnje [10] (nastavak)

10	**Cjelovito upravljanje kvalitetom** (engl. *Total Quality Management*)	• krug poboljšanja kvalitete i timova • proizvodnja bez grešaka • statistička kontrola procesa • *poka-yoke* • analiza glavnog uzroka • analiza kvalitete proizvoda u pojedinim fazama, a ne samo kada je proizvod gotov • uključenje dobavljača i kupaca u program razvoja kvalitete • TPM.
11	**Odnos prema kupcima**	• JIT • kontinuirano vrednovanje povratnih informacija • grupne tehnologije • specifikacija vrijednosti iz pogleda kupca • usluge kupcima nakon prodaje • dugotrajna pomoć kupcima • strateško udruženje i dugoročno partnerstvo između kupaca i dobavljača.

Kada se pokušava opisati vitku proizvodnju, može se govoriti samo o vodećim načelima vitkog razmišljanja. Jedno od načela je vrijednost. Suprotno od konvencionalnog poslovnog pogleda, u slučaju vitke filozofije vrijednost definira kupac, a ne proizvođač. Kod načela vrijednosti proizvoda ili usluge vitka filozofija usmjerava na pitanje pridonosi li ta aktivnost izravno većem zadovoljstvu kupca te je li kupac voljan platiti tu aktivnost. Ako je odgovor na oba pitanja ne, tada treba postaviti pitanje zašto se to radi. Ovakav koncept i definicija vrijednosti dovode do dva ključna analitička pojma vitke filozofije, a to su aktivnosti koje dodaju vrijednost i aktivnosti koje ne dodaju vrijednost. Pojam dodana vrijednost odnosi se na transformacijske aktivnosti koje dovode kupčev proizvod u potpuniji i kompletniji oblik koji je on voljan platiti. Suprotno od toga, aktivnosti koje nemaju dodanu vrijednost one su koje ne povećavaju vrijednost proizvoda ili usluge (npr. ljudski troškovi, troškovi skladištenja itd.). Ovakva iskrena logika i razmišljanje u potpunosti se razlikuju od logike konvencionalnih poduzeća [11].

Sljedeće temeljno načelo vitke proizvodnje cjelokupan je i širok pogled pri evaluaciji poslovanja, preciznije pri evaluaciji toka vrijednosti poslovanja. Ovo je ključno odstupanje od konvencionalnog poslovanja. Tok vrijednosti predstavlja cjelokupan ciklus aktivnosti, od inicijalnog kontakta kupca do naplate potraživanja za proizvod koji je isporučen kupcu. Poduzeća se u većini slučajeva bore da snize svoje troškove 3 do 4 % na godišnjoj razni, no učinkovita primjena vitkih tehnika osigurava dvoznamenkasta poboljšanja operativne učinkovitosti. Tok vrijednosti omogućuje analizu poslovanja s potpuno drugačijeg gledišta, a pritom takav pristup ukazuje na to gdje su prilike te koji su prioriteti kod aktivacije kapitala [11].

Zatim dolazi princip toka (engl. *flow*) i povlačenja (engl. *pull*). Tok u idealnom stanju predstavlja neprekidan slijed aktivnosti kroz proces, bez zastoja, prekida, isključenja i povratnih izvođenja aktivnosti. S druge strane, koncept povlačenja znači da se aktivnosti trebaju odvijati samo kada postoji jasan zahtjev kupca, nikako ne prije. Povlačenje predstavlja sustav koji se pokreće na temelju uzroka potrošnje ili kupčevog zahtjeva, kao suprotnost sustavu predviđanja potreba i zahtjeva kupaca.

Bitno razmišljanje vitke proizvodnje neprekidna je i kontinuirana eliminacija gubitaka. Potrebno je naglasiti da postoje različiti tipovi gubitaka kojima se poduzeće treba baviti. Svrha eliminacije nepotrebnih aktivnosti oslobađanje je vremena i resursa kako bi ljudi bili posvećeniji aktivnostima koje stvaraju dodanu vrijednost. „Napravi više sa manje“ ne znači da ljudi trebaju radi teško ili da poduzeće treba dijeliti nerazumne otkaze. To znači da se treba proizvoditi više proizvoda s manje resursa, što u konačnici treba rezultirati većim zadovoljstvom kupca, rastom tržišnog udjela, većom profitabilnošću i stabilnošću tvrtke. Kako bi se ova načela implementirala u bilo koje poduzeće, njima mora upravljati vrhovni menadžment te ih moraju prihvatiti svi pojedinci unutar poduzeća. Pristup vitkoj filozofiji ne može biti fragmentaran, on mora biti cilj postojanja [11].

2.2. Gubitci vitke proizvodnje

Logička podloga koja stoji iza primjene vitke filozofije fokusirana je na otklanjanje svih mogućih gubitaka unutar poduzeća. Upravo to razmišljanje temeljno je kako bi se aktivnosti unutar poduzeća odvijale po načelu vitkog toka vrijednosti. Poboljšana produktivnost rezultira boljim izvođenjem operacija, što opet rezultira otklanjanjem sustavnih problema u pogledu gubitaka i kvalitete. Sustavan i metodičan napad na gubitke ujedno je i sustavan napad na čimbenike koji „leže“ iza loše kvalitete i temeljnog problema samog upravljanja. Shigeo Shingo, čovjek koji se smatra jednim od vodećih stručnjaka u području optimalizacije proizvodnih procesa i koji je detaljno opisao Toyotin proizvodni sustav (engl. *Toyota Production System*, TPS), utvrdio je sedam vrsta gubitaka koji su prikazani na Slici 1. [12].

Slika 1. *Sedam vrsta gubitaka [12]*

Pravi tvorac teorije o sedam vrsta gubitaka je Taiichi Ohno te je on prvi ukazao na problem gubitaka vezanih uz prekomjernu proizvodnju, škart, nepotrebne zalihe, prekomjernu obradu, prekomjeran transport, čekanje i zastoje te nepotrebne pokrete. Tek su kasnije ostali autori i stručnjaci u područja upravljanja proizvodnim procesima dodali još jedan gubitak, a to je nedovoljna iskorištenost potencijala zaposlenika. Na Slici 2. prikazana je veza između svih elemenata vitke proizvodnje i pripadajućih gubitaka [13].

Slika 2. Dimenzije sustava vitke proizvodnje te veza s gubitcima [13]

2.2.1. Prekomjerna proizvodnja

Kada se govori o problemu prekomjerne proizvodnje, tada se misli na to da nije potrebno proizvoditi više proizvoda nego što tržište želi ili proizvoditi prije nego što je to potrebno (tzv. proizvodnja za svaki slučaj). Prekomjerna proizvodnja omogućava rizik zastarijevanja proizvoda ili usluge koju više ne možemo plasirati, ali isto tako omogućava rizik proizvodnje krivih stvari (npr. gomilanje nepotrebne dokumentacije). To vodi pretjeranim zalihama, većim skladištima, dislokaciji WIP-a i gubitku vremena. [14].

2.2.2. Škart

Kada se spomene pojam škart, odmah se pomisli na fizički neispravne proizvode, no škart podrazumijeva greške u papirologiji, kasne isporuke, proizvodnju prema netočnim specifikacijama te uporabu previše sirovina ili resursa. Ono što treba naglasiti je da velik udio škarta izravno utječe na troškove prodane robe. Kada se neispravni proizvod pojavi, potrebno ga je preraditi, ako je moguće, ili će se u protivnom neispravni proizvod pretvoriti u otpad. Generiranje neispravnih proizvoda ne rezultira samo gubitkom materijala i radnih resursa, već stvara nedostatak materijala, blokiraju se planirani sastanci, dolazi do praznog hoda na daljnjim radnim stanicama te se produljuje proizvodno vodeće vrijeme [14].

2.2.3. Nepotrebne zalihe

Nepotrebnim zalihama smatraju se velike razine sirovina, poluproizvoda i gotovih proizvoda. Velike zalihe dovode do većih financijskih troškova skladištenja (npr. plaćanje većeg poreza), operativnih troškova skladištenja te porasta neispravnih proizvoda. Potrebe uslijed stvaranja velikih zaliha uključuju povećano vodeće vrijeme proizvodnje, prevenciju brzog utvrđivanja problema i povećane zahtjeve za prostorom. U cilju provođenja i uspostavljanja učinkovite nabave izrazito je važno smanjiti zalihe koje su nastale uslijed krivog izračuna vodećeg vremena proizvodnje [14].

2.2.4. Prekomjerna obrada

Odnosi se na rad koji kupac ne traži te nije spreman platiti. Primjeri takvog rada pretjerana su kvaliteta koju kupac ne traži, složen proizvod, točnije loše konstruiran proizvod te, na kraju, nedostatak potrebnih sredstava za rad (npr. strojevi). Prekomjerna obrada pojavljuje se u

situacijama u kojima se primjenjuju složena rješenja umjesto jednostavnih procedura. Složena obrada obeshrabruje zaposlenike pri izlaganju vlastitih rješenja proizvodnih operacija te izaziva nepotrebnu hiperprodukciju na strojevima kako bi se opravdala investicijska ulaganja u skupe strojeve [14].

2.2.5. Prekomjeran transport

Svako kretanje materijala koje ne stvara dodanu vrijednost na proizvodu, kao što je nepotrebno kretanje materijala između operacija, smatra se nepotrebnim transportom. Transport između operacija rezultira vremenskim produljenjem proizvodnog ciklusa te slabom učinkovitošću. Bilo koji transport u poduzeću može se sagledati kao gubitak. Višestruko rukovanje i pretjerani transport poluproizvoda ili proizvoda po svojoj prilici uzrokuje oštećenja i istrošenost poluproizvoda i proizvoda, ali istodobno dolazi i do lošeg prijenosa informacija [14].

2.2.6. Čekanja

Pod pojmom čekanja smatra se vrijeme kada je radnik besposlen ili je stroj u praznom hodu. Uzrok čekanja mogu biti operacije koje predstavljaju „usko grlo“ procesa ili pak loš protok proizvodnje unutar proizvodnog pogona. Kada se vrijeme ne koristi učinkovito, tada se javlja gubitak, odnosno javlja se nepotrebno čekanje. Čekanje kao gubitak javlja se gotovo uvijek kada se obradak ili proizvod ne kreće ili obrađuje. Ovakav gubitak podjednako utječe na ljude i cijenu proizvoda. Vrijeme dok je radnik besposlen može se puno bolje iskoristiti za edukaciju ili održavanje strojeva i opreme [14].

2.2.7. Nepotrebni pokreti

Ovaj gubitak odnosi se na suvišne fizičke pokrete ili kretanja radnika koja nemaju nikakve veze s trenutnim operacijama. Klasičan primjer bespotrebnog kretanja može biti traženje alata u proizvodnji, no još su bolji primjer nepotrebni ili teški fizički pokreti koji su rezultat loše ergonomije radnog mjesta, što u konačnici rezultira gubitkom vremena. Ono što treba izbjeći u proizvodnoj ergonomiji radnje su u kojima se radnici trebaju protegnuti, iskriviti ili sagnuti kako bi napravili neku radnju koja je dio proizvodnog procesa [14].

2.2.8. Nedovoljna iskorištenost potencijala zaposlenika

Ova vrsta gubitka ne spada pod standardne gubitke TPS-a te se sve češće pojavljuje u današnjem poslovnom okruženju. Nekorištenje ili nedovoljno korištenje ljudskih talenata, vještina i znanja može biti odlučujući faktor za samu organizaciju. Poduzeća mogu dobiti puno ako pravovremeno prepoznaju vještine i dobre ideje svojih zaposlenika, ali isto tako mogu pretrpjeti veliku štetu ako ne prepoznaju talent svojih zaposlenika. Primjeri loše iskorištenosti zaposlenika su [15]:

- dodjeljivanje zaposleniku krivih zadataka
- nepotrebni administrativni poslovi
- loša komunikacija
- nedostatak timskog rada
- loš menadžment i nedovoljno edukacije.

2.3. Vitko vodstvo

Vitka proizvodnja kakvu poznajemo danas razvila se iz Toyotinog proizvodnog sustava pa bi bilo logično opisati kakav se tip vodstva njegovao i još uvijek se njeguje unutar Toyotinog proizvodnog sustava. Toyota ima horizontalnu organizacijsku strukturu gdje postoji nekoliko slojeva i vrsta menadžmenta. Vođe igraju ključnu ulogu u uspjehu poduzeća, no pretjerani slojevi i vrste menadžmenta nisu potrebni jer vođe razvijaju i savjetuju ostale zaposlenike. Glavna je filozofija Toyotinog vodstva napraviti disperziju odgovornosti unutar poduzeća do najnižih mogućih grana, što u prijevodu znači dati više autonomije zaposlenicima. U Toyotinoj se filozofiji puno očekuje od vođa jer oni imaju veliku odgovornost pri kreiranju poslovnih procesa, ali i pri kreiranju kulture rada [16a].

Poduzeća se često fokusiraju na obveze i odgovornosti vođa, no trebala bi se više fokusirati na očekivanja koja žele postići. Ovo je slično pokušaju kada poduzeća pokušavaju uvesti vitke alate bez da shvate i integriraju vitku filozofiju i etiku rada. Ljudi su skloniji znati „što vođa grupe radi“, nego „koji su ciljevi i očekivanja od vođe grupe“. Ono što se očekuje u Toyotinim proizvodnim pogonima učinkovito je razvijanje zaposlenika kako bi se došlo u stanje stalnog poboljšanja. To se očekivanje postiže integriranjem Toyotine kulture u svakog zaposlenika, na način da se stalno ulaže u sposobne ljude, ali i fokusiranim naporom za jačanje TPS-a. Učinkovitost vođa mjeri se pomoću četiri ključna indikatora [16a]:

1) **sigurnost** – uključuje bolju ergonomiju i dizajn radnog mjesta te smanjene ozljeda na radu
2) **kvaliteta** – uključuje edukacije i treninge, procese poboljšanja te rješavanje problema
3) **produktivnost** – obuhvaća stalno ispunjavanje zahtjeva kupaca i upravljanje resursima
4) **trošak** – obuhvaća ispunjenje prethodna tri kriterija, ali pritom kontrolirajući i smanjujući troškove.

Znak učinkovitog vodstva uključuje visok moral te dosljedno ostvarenje ciljeva. Glavni fokus vodstva trebao bi biti na jačanju i rastu ljudi. Vođa mora ispuniti svoje dnevne zadatke, no fokus mora biti na razvoju sposobnih ljudi kako bi se postigli još već poslovni rezultati [16a].

Vitko vodstvo osigurava potpun i cjelovit pristup svakom pojedincu, skupini i organizaciji. Osnovna značajka takvog vodstva kontinuirano je poboljšanje proizvodnje, u kojoj se traže svi oni mehanizmi koji pridonose stvaranju dodane vrijednosti, a istodobno se minimiziraju i eliminiraju svi nepotrebni gubitci. Takva vrsta optimizacije unutar bilo kojeg sustava nije moguća bez učinkovitog vodstva. Vitko vodstvo svakoj organizaciji mora osigurati potrebnu transformaciju, stvarajući kreativno, inovativno i pozitivno okruženje. Dok vrhovni menadžment osigurava viziju, organizaciju, kontrolu i upravljanje, vitko vodstvo osigurava nužno potrebnu kompetentnost, to jest visoku razinu zajedništva i motivacije za postizanje zajedničkih ciljeva. Vitki vođe nisu sposobni samo preživjeti, već biti uspješni i prosperitetni u nemilosrdnoj i turbulentnoj poslovnoj okolini. Današnjem nepredvidivom, dinamičnom i globaliziranom svijetu potrebni su i novi vođe koji mogu dati valjane odgovore na izazove vremena. Vrijeme je za „vođe ratnike“ koji će zamijeniti umorne menadžere industrijskog doba. Ti novi ratnici su vitki vođe. Promjene i nepredvidivi izazovi jačaju njihove vještine i pomažu im da oni i njihove organizacije budu spremni za nove bitke. Oni ne gube vrijeme na nepotrebne rituale i njihovo je najjače oružje brzina. Obogaćuju se radeći u pozitivnom ozračju sa svojim kolegama. Oni se ne koriste bičem da bi pridobili sljedbenike. Vitki vođe svojim sljedbenicima pružaju prilike da i oni zadovolje svoje potrebe za razmišljanjem, kreativnošću i isticanjem kroz akcije. Stoga sljedbenici u ovom tipu vodstva ne mogu ne slijediti vođu. Vitki vođe ne griješe. Oni posjeduju sva ključna znanja koja se odnose na zaposlene i organizaciju. Oni vode na način koji povezuje pojedinačnu, skupnu i organizacijsku dinamiku. Ako želite opstati u današnjoj poslovnoj okolini, jednostavno morate biti najbolji u svemu pa i u vodstvu. [17].

2.4. TPS

Najvažnija značajka Japana nedostatak je prirodnih resursa zbog čega je Japan oduvijek bio primoran uvoziti velike količine resursa, uključujući i hranu. Upravo ta značajka stavlja Japan u nepovoljan položaj u pogledu dostupnosti i cijena sirovina u usporedbi sa SAD-om i europskim zemljama. Kako bi premostili ovu poteškoću, japanska industrija morala se fokusirati na proizvodnju koja se temelji na boljoj kvaliteti, većoj dodanoj vrijednosti te nižoj cijeni proizvodnje. Prva organizacija koja je prepoznala taj smjer bila je upravo Toyota [18].

Druga važna značajka Japana u odnosu na Europu i SAD bila je koncepcija rada, gdje su Japanci imali veću svijest, znanje i odgovornost prema poslu, što se kasnije pokazalo kao jedno od ključnih načela za brzi napredak. Glavne crte Japanaca su [18]:

1) grupna savjesnost, osjećaj za jednakost, želja za napretkom i marljivost
2) velika razina sposobnosti koja je rezultat visokog obrazovanja te želja za napretkom i

3) fokusiranje života na posao.

Upravo su se te značajke doslovno precrtale i na poduzeća. Tako japansku industriju obilježavaju sljedeće značajke [18]:

1) sustav cjeloživotnog zapošljavanja
2) sindikati rada u poduzećima
3) mala diskriminacija između radnika i visokoškolovanog osoblja (engl. *white-collar staff*)
4) mogućnost radnika da napreduju do rukovodećih položaja, što dovodi do stvaranja osjećaja jedinstva između radnika i poduzeća.

Toyotin proizvodni sustav osmislio je i razvio Toyotin dopredsjednik Taiichi Ohno te se taj sustav unutar Toyotine korporacije implementirao gotovo petnaest godina. U početku su u SAD-u taj sustav opisivali kao sustav toka proizvodnje i kontrole zaliha, no s vremenom je shvaćen cjelokupan koncept Toyotinog poslovanja. Toyotin proizvodni sustav nije obuhvaćao samo navedena područja, već i dizajn proizvoda, organizaciju posla, standardizaciju rada, ekonomične proizvodne serije, brze izmjene alata, JIT, *kanban*, *jidoku* i *andon*. [19].

2.4.1. JIT

Vjerojatno najvažniji aspekt TPS-a pravovremena je proizvodnja ili JIT (engl. *Just-In-Time*) jer se njome značajno smanjuju zalihe poluproizvoda i proizvoda. Primjenom ovog modela Toyota je došla u stanje gdje su se u njihovim skladištima nalazile zalihe za samo tri do četiri dana jer nisu proizvodili „za svaki slučaj“. Druga važna značajka JIT-a bila je skraćenje vodećeg vremena proizvodnje. Tako su u Toyotinim proizvodnim pogonima zabilježeni primjeri gdje su jutros odlijevani blokovi motora istoga dana u večernjim satima sklapani u gotov motor. Treća pak značajka JIT-a bilo je nestvaranje viška u poluproizvodima, već su svi poluproizvodi i dijelovi bili odmah sklapani u gotov proizvod koji je imao svog kupca. Takav pogled na proizvodnju bila je potpuna novost jer su ostala poduzeća u svijetu još uvijek proizvodila po principu „guranja“, a ne „povlačenja“ proizvoda. Povlačenje proizvoda od strane kupca rezultiralo je ogromnim uštedama u Toyoti jer nisu bila potrebna velika skladišta i zalihe [19]. Na Slici 3. prikazana je razlika između „guranja“ i „povlačenja“ proizvodnog procesa.

Slika 3. *Razlika između proizvodnje po načelu „guranja“ (a) i „povlačenja“ (b)[20]*

Temeljna razlika između proizvodnje po načelu „guranja“ i „povlačenja“ vidljiva je na Slici 3., gdje je vrlo jasno da su kod „guranja“ proizvodnje procesi uvjetovani dobavljačima, dok su kod „povlačenja“ proizvodnje procesi uvjetovani potražnjom kupaca. Prilikom sustava „guranja“ proizvodnje proizvodni pogoni rade na maksimalnim proizvodnim ograničenjima, dok se kod sustava „povlačenja“ proizvodnje ona zasniva na manjim serijama koje imaju svog kupca. Proizvodni sustavi u kojima je proizvodnja uvjetovana zahtjevom kupca smanjuju zalihe na skladištima te se stvara brži odziv na potrebe i zahtjeve tržišta. Kako bi sam proces tranzicije iz sustava „guranja“ u sustav „povlačenja“ proizvodnje uspio, potrebno je napraviti cjelokupnu

promjenu sustava rada i kulture što je Toyota uspjela tijekom svojeg kontinuiranog ulaganja u napredak.

2.4.2. *Kanban*

Toyota je dugi niz godina stvarala preduvjete za prelazak na JIT. Jedan od preduvjeta za uvođenje pravovremene proizvodnje bilo je stvaranje vitkog alata koji će podržavati takav sustav proizvodnje. Taj je alat bio *kanban*.

Kanban je japanska riječ za karticu koja je pričvršćena na posudu s materijalom ili skupinu dijelova na transportnoj traci. Osnovna uporaba *kanbana* stvaranje je sustava upravljanja proizvodnim informacijama kojim se ostvaruje sustav „povlačenja“ proizvodnje. Postoje dvije vrste *kanban* kartica. Prva su vrsta proizvodne *kanban* kartice, a druga transportne *kanban* kartice. Proizvodne *kanban* kartice koriste se za signalizaciju početka proizvodnog procesa, a transportne kanban kartice koriste se za signalizaciju nadopunjavanja ili uklanjanja materijala ili proizvoda sa zaliha [19].

U tradicionalnoj masovnoj proizvodnji plan proizvodnje pruža se svakoj radnoj operaciji te svaka radna operacija proizvodi prema danom planu proizvodnje. Točnije, proizvodi se bez vremenske povratne veze o stvarnim potrebama s prethodnim radnim operacijama. Umjesto toga *kanban* funkcionira kao alat za realno planirane proizvodnje koji povezuje i sinkronizira uzvodne i nizvodne operacije. Nadalje, u tradicionalnoj masovnoj proizvodnji kretanje materijala između operacija događa se samo kada uzvodna operacija dovrši svoj posao te se tako stvara učinak „guranja“ materijala prema nizvodnim radnim operacijama. Takvo „guranje“ materijala kroz proizvodnju pogubno je jer se ne poštuju i ne zadovoljavaju potrebe nizvodnih procesa. U suštoj suprotnosti s takvim planiranjem proizvodnje, *kanban* kontrolira tok materijala na način da uvažava vrijeme i količinu materijala koju trebaju nizvodni procesi. *Kanban* u biti kontrolira proizvodnju kontrolirajući tok materijala i informacija [21].

Četiri su glavna razloga za implementaciju *kanbana* [21]:

1) sprječavanje hiperprodukcije materijala između operacija
2) osiguranje jasnih proizvodnih zadaća između operacija na temelju načela nadopunjavanja (*kanban* to postiže upravljajući istodobno pravovremenim kretanjem materijala te procesom povlačenja pravovaljane količine materijala)
3) služi voditeljima proizvodnje kao alat za vizualnu kontrolu kako bi znali jesu li iza ili ispred planiranog plana proizvodnje
4) uspostavlja model za kontinuirano unaprjeđenje (svaka *kanban* kartica predstavlja određeni spremnik zaliha unutar lanca vrijednosti te smanjenje broja *kanban* kartica unutar sustava izravno odgovara smanjenju zaliha čime se proporcionalno smanjuje vodeće vrijeme proizvodnje).

U početku je samo mali broj japanskih poduzeća implementirao Toyotin *kanban* sustav s dvije kartice, no krajem 70-ih godina već je stotinu japanskih poduzeća imalo *kanban* sustav. U početku je većina japanskih poduzeća koristila *kanban* sustav s jednom karticom, preciznije, služili su se transportnim *kanban* karticama. Razlog takvog pristupa bila je lakša implementacija *kanbana* kako ne bi došlo do kaosa u organizaciji. Kod takvog *kanban* sustava proizvodi se prema dnevnom planu proizvodnje, no dostave prema kupcima vrše se transportnim *kanban* karticama. Generalno gledajući, *kanban* s jednom vrstom kartica u biti je bila proizvodnja po načelima „guranja“ procesa vezana sa sustavom isporuke i dostave po načelima „povlačenja“ procesa. Moglo bi se reći da je to bila neka vrsta tranzicijskog *kanbana*, no s vremenom su japanska poduzeća uvela i drugu vrstu kartice, što je dovelo do ostvarenja punog potencijala *kanbana* [22].

Proizvodnja i tok materijala u *kanban* sustavu događa se samo ako to *kanban* kartice signaliziraju. To znači da ne postoji problem hiperprodukcije i proizvodnje „za svaki slučaj“.

2.4.3. Brze izmjene alata

Toyoti je trebalo gotovo petnaest godina da implementira, prilagodi i usavrši TPS. Taj proces implementacije TPS-a u vlastitim proizvodnim pogonima bio je prožet usponima i padovima jer je Toyota bila pionir takvog organizacijskog sustava vođenja. Toyotin JIT bio je moguć samo ako su strojevi, oprema, ljudi, tok materijala i informacija bili usklađeni. Budući da su ljudi u proizvodnji po načelu „guranja“ bili naviknuti obavljati samo mali spektar radnih aktivnosti, jedan od Toyotinih problema bila je prilagodba ljudi i radnih mjesta na fleksibilnost. Drugi veliki problem s kojim se Toyota suočila bila je povećana potreba za izmjenom alata. Budući da se više nije proizvodilo po načelu maksimalnih proizvodnih kapaciteta, već se nastojala uvesti fleksibilnost procesa, došlo je do potrebe za bržom izmjenom alata na strojevima, opremi i radnim mjestima. Toyota je shvatila da će JIT biti moguć i održiv ako budu imali učinkovite i brze izmjene alata [19].

Općenito govoreći, Toyota se suočila sa sljedećim problemom; u masovnoj proizvodnji jedan stroj tijekom smjene proizvodi jednu vrstu dijela ili poluproizvoda te se izmjene alata javljaju rijetko. Suprotno tome, u vitkoj proizvodnji jedan stroj tijekom smjene proizvodi nekoliko vrsta dijelova ili poluproizvoda pa time raste i broj izmjena alata. Kako bi se problem pojednostavio, u vitkoj proizvodnji jedan stroj za lijevanje, ako na sebi ima montiranu kokilu za lopate, može lijevati lopate, ako pak ima montiranu kokilu za lijevanje grablji, može lijevati samo grablje. Problem je u tome što u pravovremenoj proizvodnji u jednom trenutku treba lijevati lopate, a u drugom grablje, a znamo da ako želimo prijeći s postupka lijevanja lopata, trebamo demontirati kokilu za lopate i montirati kokilu za grablje. Vrijeme za izmjenu alata, odnosno kokile, prema vitkim načelima čisti je gubitak jer taj rad nema dodanu vrijednost za kupca. Postupak skidanja stare i stavljanje nove kokile popraćen je radnjama kao što su odvijanje vijaka, dovlačenje mosne

dizalice, stezanje, grijanje itd. Taj sav rad troši vrijeme i taj rad se treba izvesti u što kraćem roku. Toyota se suočila upravo s tim problemom te napravila jedan niz standardnih procedura za operacije izmjene alata.

2.4.4. *Jidoka*

Većina Toyotinih ljudi i ostala japanska poduzeća smatrala su da su *jidoka* i JIT vjerojatno dva najvažnija aspekta novonastalog sustava proizvodnje. Budući da se JIT temelji na pravovremenom toku materijala, dijelova i proizvoda bez kašnjenja, bilo je vrlo važno osigurati da se unutar proizvodnog sustava ne pojavljuju neispravni proizvodi te da se oni pravovremeno prepoznaju. Toyotini inženjeri to su postigli tako što su uveli velik broj automatiziranih uređaja za kontrolu kvalitete te prepoznavanje materijala. Takav sustav funkcionirao je na način da kad god bi se prepoznao neispravan dio ili proizvod, *jidoka* bi to sustavno rješavala na način opisan u nastavku: kada se prepozna neispravan proizvod, stroj se automatski ugasi, upali se crvena lampa (*andon*) iznad uređaja koja signalizira radniku problem te radnik pristupa rješavanju problema. Važno je napomenuti kako je zadaća rješavanja uzroka problema zadaća svih zaposlenika, a ne samo najbližeg radnika te kako se problem treba rješavati u što kraćem vremenskom roku. Ako poduzeće nije u stanju rješavati probleme u vrlo kratkom vremenskom roku, tada poduzeće nije spremno za tranziciju s masovne na vitku proizvodnju. U Toyotinim se pogonima smatralo da crvena lampa (*andon*) ne smije biti upaljena nešto više od nekoliko sekundi, to jest radnici su trebali žurno rješavati uzroke problema [19].

2.4.5. *Andon*

Toyota je bila pionir novog sustava proizvodnje te se pri stvaranju i uvođenju TPS-a susrela s još jednim problemom, a to je pravovremena koordinacija radnog tempa. Kako bi riješili problem pravilnog toka materijala, dijelova i poluproizvoda između različitih operacija, poslužili su se *andon* svjetlosnim sustavom koji je signalizirao smetnje i nejednolikosti proizvodnog ritma. Cilj takvog sustava bio je da svaka operacija u proizvodnom procesu završi svoje radnje u zadanom vremenskom roku. Ako je neka operacija kasnila s izvršenjem svoje zadaće, tada je *andon* sustav signalizirao kašnjenje i gubitak proizvodnog ritma [19].

Slika 4. prikazuje klasičan primjer uporabe *andona* u Toyotinim proizvodnim pogonima. Operacije A, B i C proizvode dijelove ili sastavnice, a operacija D sastavlja navedene dijelove u nekakav sklop. Ciklusna vremena operacija A, B i C iznose 90, 95 i 105 sekundi, što dovodi do zaključka kako je operacija C sa svojim trajanjem od 105 sekundi najduža operacija te ona diktira radni tempo proizvodnje. Ako neka od operacija A, B, C i D premaši ciklusno vrijeme od 105 sekundi, tada će se upaliti crvene lampe (*andon*) na operacijama A, B, C i D. Preciznije

govoreći, operateri na navedenim operacijama moraju obaviti svoje zadaće unutar 105 sekundi te pritisnuti gumb kojim obavještavaju *andon* sustav kako je operacija završena. Ako ne uspiju obaviti zadaće u 105 sekundi, crvena lampa će se automatski upaliti na jednoj ili više operacija te će ostali radnici priskočiti u pomoć [19].

Slika 4. *Skupina proizvodnih operacija u kojoj se primjenjuje andon [19]*

2.4.6. Načela TPS-a

Vitka proizvodnja može se opisati kao filozofija, ali i kao set alata i tehnika kojima je cilj utvrditi i eliminirati sve gubitke unutar proizvodnog procesa. Istraživači i praktičari općenito se slažu da se vitka proizvodnja razvila iz TPS-ovih metoda i radnih praksi s korijenima u proizvodnji kontinuiranog toka po načelima Henryja Forda. Pojam vitke proizvodnje prvi je puta populariziran 1990-ih godina izdavanjem knjige „The Machine that Changed the World“. Autori te knjige bili su James P. Womack i Daniel T. Jones te su opisali uspjeh vitke proizvodnje u automobilskoj industriji. Kasnije su proširili svoju poruku o vitkoj proizvodnji te naglasili kako se vitka proizvodnja može implementirati u pregršt različitih industrija, bilo da se radi o proizvodnim ili uslužnim djelatnostima. Poruka koju su poslali Womack i Jones može se sažeti na pet vitkih načela, a to su [23]:

1) Precizno odredi vrijednost svih proizvoda.
2) Utvrdi tok vrijednosti za svaki proizvod.
3) Napravi protok vrijednosti bez smetnji i prekida.
4) Prepusti kupcu da povlači vrijednost od proizvođača.
5) Teži savršenstvu.

Cijela vitka filozofija može se sažeti u ovih pet načela te treba jasno naglasiti da je vrijednost sve ono za što je kupac spreman platiti. To znači da je tržište jedini faktor koji utječe na naše proizvodne ili uslužne aktivnosti. Budući da je vitka proizvodnja nastala iz TPS-a, potrebno je sagledati četrnaest načela na kojima se temeljio TPS [16b]:

1) **Temelji svoje odluke na dugoročnim planovima i ciljevima, čak i pod cijenu kratkoročnih financijskih rezultata**.
   Toyota je uvijek polazila od stvaranja vrijednosti za kupca, društvo i ekonomiju. To je načelo uvijek bio početak ne samo za proizvode, već i za svako djelovanje unutar Toyote. Odluke i djelovanja unutar Toyote nisu bile usmjerene prema kratkoročnim ciljevima, već su bile usmjerene na dugoročne planove.
2) **Kreiraj kontinuirane protočne procese kako bi na površinu isplivali problemi**.
   Procesi trebaju biti kontinuirani i protočni kako se ne bi gubilo dragocjeno vrijeme te kako ne bi bilo dokolice. Sve operacije koje ne dodaju vrijednost proizvodu ili usluzi trebaju biti minimalizirane ili, ako je to moguće, uklonjene.
3) **Proizvodnja se treba temeljiti na načelu „povlačenja“ od strane kupca kako bi se riješio problem prekomjerne proizvodnje**.
   Kupac je taj koji određuje količinu, potrebu i oblik proizvoda. Skladištenje sirovina, materijala, dijelova, poluproizvoda i proizvoda koje se temelji na prognoziranju potreba kupaca pogrešan je pristup jer to financijski i operativno umara poduzeće. Čak se i sam *kanban* smatra gubitkom koji se može teorijski eliminirati.
4) **Ujednači radno opterećenje (radi kao kornjača, a ne kao zec)**.
   Jedini način da se stvori kontinuirani protok je da postoji jednoliko radno opterećenje ili *heijunka*. Ako jednoliko radno opterećenje ne postoji, standardizacija nije moguća te će gubitci biti veliki. Neki današnji autori predlažu uvođenje fleksibilne radne snage kako bi se premostio ovaj problem jer se radnici zaposleni preko agencija za zapošljavanje mogu vrlo lako zapošljavati i otpuštati. Međutim, takvo se načelo kosi s Toyotinom filozofijom te je Toyota puno pametnije pristupala ovom problemu. Toyota je puno više ulagala u edukaciju zaposlenika i od njih učinila autonomne i multifunkcionalne jedinke.
5) **Stvori kulturu u kojoj se rješavaju problemi i u kojoj se kvaliteta postiže iz prvog puta.**
   Toyota je oduvijek koristila najbolje i najnovije metode osiguranja kvalitete. Toyotina filozofija kvalitete temeljila se na *jidoki* i žurnom rješavanju problema. Kada se problem pojavi u proizvodnji, on se mora rješavati odmah i ne smije se odgađati za kasnije.
6) **Standardizacija rada temelj je kontinuiranog poboljšanja i jačanja zaposlenika.**
   Poduzeće mora imati stabilne i ponovljive procese kako bi mogli predvidjeti izbor trenutka i vremenski raspon odvijanja pojedinih procesa. Predvidljivi i ponovljivi procesi temelj su TPS-a. Standardizacija omogućava dokumentiranje najboljih ideja i dokazanih praksi u proizvodnji. Ako se zaposlenik koji je donio neko poboljšanje na određenom radnom mjestu premjesti na drugo radno mjesto, tada će njegova dobra praksa ostati

dokumentirana kroz standardizaciju te će se uspješno prenijeti na nove zaposlenike. Standardizacija nikako ne guši motivaciju i kreativnost.

7) **Koristi se vizualnim kontrolama kako bi problemi bili vidljivi.**
   Poduzeće treba izbjegavati hiperprodukciju papirologije koju nitko ne čita te nitko ne kontrolira. U suvremenom informatičkom dobu težnja je imati poduzeće bez fizičke papirologije. U Toyotinim proizvodnim pogonima posvuda se nalaze natpisi i znakovi koji daju jasne upute zaposlenicima. Čovjek je vizualno biće i puno bolje reagira na vizualne podatke.
8) **Koristi samo pouzdane i pomno ispitane tehnologije koje služe kao potpora ljudima i procesima.**
   Prednost se uvijek daje procesima, a ne tehnologijama. Toyota je tijekom povijesti primjenjivala najnovije tehnologije, no više se puta ozbiljno opekla te više ne čini tu grešku. Budući da se Toyota oduvijek fokusirala na stabilnost, pouzdanost i predvidljivost, s vremenom je postala vrlo oprezna kod uvođenja novih tehnologija koje nisu kvalitetno i dovoljno ispitane. To ne znači da Toyota sporo implementira nove tehnologije, upravo suprotno, uvodi ih izuzetno brzo i učinkovito, no tek kada su sigurni u kvalitetu određene tehnologije.
9) **Razvijaj vlastite vođe koji razumiju rad i filozofiju vitkog rada te koji prenose svoja znanja na druge.**
   Toyota je oduvijek njegovala načelo stvaranja vođa iz vlastitih redova. Zapošljavanje menadžera i vođa koji ne razumiju i ne osjećaju Toyotinu filozofiju uistinu nema smisla te je to načelo Toyotu dovelo do uspjeha. Vođe su ti koji stvaraju duh i kulturu rada unutar poduzeća te prenose svoje obrasce ponašanja na druge.
10) **Puno ulaži u sposobne ljude i timove koji razumiju i žive filozofiju poduzeća.**
    Bilo koja organizacija koja je preživjela nekoliko stoljeća, kao što je primjerice Katolička Crkva, ima članove koji čvrsto razumiju svoju svrhu i dijele svoju kulturu ponašanja međusobno. Temelj Toyote čine iznimni ljudi i timovi koji rade po načelima TPS-a te postižu izvanredne rezultate. Alati TPS-a samo su alati te oni znače vrlo malo ako ne postoji odgovarajuća organizacijska kultura. Ako neko poduzeće u svoje poslovanje implementira *kanban* i *andon*, to ne znači da će postati vrhunska svjetska kompanija. Alati ne znače ništa ako s njima rade krivi ljudi. Pokretači svih promjena su ljudi, a ne alati i tehnike.
11) **Poštuj sve svoje partnere i dobavljače te ih motiviraj na razvoj i pomozi im da se poboljšaju.**
    Toyota ne iskorištava i ne zlorabi svoje partnere te ne izvlači njihove vrijednosti po najnižoj mogućoj cijeni. Partneri i dobavljači postaju izravan produžetak Toyote. Poštovanje partnera i dobavljača nužno je ako želimo kvalitetan i dugoročan odnos.
12) **Sagledaj problem na licu mjesta kako bi u potpunosti mogao razumjeti situaciju.**
    Probleme i prilike za poboljšanja nije moguće vidjeti ako čovjek sam ne ode na mjesto događaja te ne sagleda i analizira što se događa. Kada netko nudi rješenja na temelju

grafikona i podataka iz ureda, a da nije sam vidio problem, takav se pristup u Toyoti smatra lošim. U Toyoti se čak i visokopozicionirani menadžeri motiviraju i tjeraju da sami vide što više problema.

13) **Odluke donosi sporo, sporazumno i uz sagledavanje što više alternativa, a implementaciju i izvršenje odluke provedi brzo.**
Kada u Toyoti zaposlenik dođe ponuditi rješenje šefu, prvo pitanje koje se postavlja je „Kako znaš da je to stvarni problem?“, a drugo „S kim si razgovarao o problemu te slažu li se oni s rješenjem?“. To se zove *nemawashi*[1].

14) **Poduzeće treba učiti kontinuiranim napretkom i neumorno preispitivati svoje stanje.**
Kada poduzeće uspostavi stabilne procese, a problemi i nedostatci su javno vidljivi, kontinuirani napredak dolazi sam po sebi. Zapadni svijet kritike doživljava negativno, no Toyota u kritikama vidi mogućnost za poboljšanje i rast. U Toyotinoj je kulturi normalno čak i na kraju uspješnog projekta javno postavljati pitanja o problemima i greškama u tom projektu.

Toyota je implementacijom TPS-a postavila temelje ne samo vitke proizvodnje, već i smjer novog poslovnog razmišljanja. Mnoga poduzeća taj su pristup poslovanju prepoznala na vrijeme te su na vrijeme poboljšala svoje poslovanje. U Tablici 3. vidljiv je uspon Toyote na svjetskoj razini, gdje je jedno malo automobilsko poduzeće u pedeset godina uspjelo iz ničega doći na vodeće mjesto. Toyota je imala svoju viziju, nije kopirala ničije poslovne modele te je u konačnici napravila izuzetan poslovni rezultat.

Tablica 3. *Rang poduzeća prema broju prodanih automobila [24]*

Rang	1950.	1970.	2001.	2006.	2007.	2012.	2017.
1	GM	GM	GM	GM	**Toyota**	**Toyota**	**Toyota**
2	Ford	Ford	Ford	**Toyota**	GM	GM	VW
3	Chrysler	Chrysler	**Toyota**	Ford	VW	VW	Hyundai
4	Studebaker	VW	VW	Renault	Ford	Hyundai	GM
5	Nash	Fiat	Renault	VW	Hyundai	Ford	Ford
6	Kaiser-Fra.	**Toyota**	Daimler	Daimler	Honda	Nissan	Nissan
7	Morris	Nissan	Honda	Hyundai	PSA	Honda	Honda
8	Hudson	Renault	Hyundai	Honda	Nissan	PSA	Fiat
9	Austin	BL	Fiat	PSA	Fiat	Suzuki	Renault
10	Renault	Peugeot	Mitsubishi	Fiat	Renault	Renault	PSA
	…						
	Toyota						

[1] *Nemawashi* je načelo u kojem se razmišljanja različitih ljudi sagledavaju pojedinačno. Nema velikih sastanaka gdje dolazi do sukoba i oprečnih mišljena. Ovakvi procesi vremenski traju dugo, no implementacija rješenja je brza jer postoji jasan sporazum svih sudionika.

2.5. Implementacija vitke proizvodnje

Načela i alati vitke proizvodnje poznati su već nekoliko desetljeća, no u znanstvenoj i poslovnoj zajednici još uvijek ne postoji sporazum kako bi postupak implementacije vitke proizvodnje trebao izgledati. Mnogo autora bavilo se ovom tematikom, a svaki od njih bavio se određenim spektrom varijabli koje mogu značajno utjecati na uspješnost uvođenja LP-a. Postoji velik broj radova o vitkoj proizvodnji te je u zadnjih trideset godina došlo do povećanog zanimanja za ovu tematiku među znanstvenim i poslovnim autorima. Ovom tematikom ne bave se samo znanstveni autori, već i konzultanti te ostali poslovni ljudi. Neizbježno je da svako poduzeće ili organizacija posluje u različitom mikro i makrookruženju, a svi oni ne kreću iz iste operativne i financijske točke. Stoga implementacija vitke proizvodnje mora biti empirijski obrađena za određene zemlje, skupine industrije, ali i poduzeća.

2.5.1. Čimbenici koji utječu na implementaciju vitke proizvodnje

Velik broj znanstvenih autora bavio se tematikom implementacije vitke proizvodnje. Vjerojatno najbolji prikaz neslaganja relevantnih autora u području implementacije vitke proizvodnje prikazan je u Tablici 4. Upravo ta tablica preslikava stavove, razmišljanja i empirijske studije oko ključnih čimbenika koji utječu na implementaciju LP-a. Tablica 4. prikazuje 33 istraživanja iz područja implementacije vitke proizvodnje, a svako istraživanje ukazuje na neke bitne čimbenike prilikom uvođenja LP-a. Autori Tablice 4. pretražili su naime tri relevantne baze podataka kao što su „Emerald“, „Science Direct“ i „North Carolina State University Libraries“ te su sagledali 70 % najboljih radova iz područja uvođenja LP-a u danim bazama podataka. Isto tako, autori ovog istraživanja nisu u razmatranje ove studije uzeli druge baze podataka, knjige, novinske članke, doktorske disertacije i slabo rangirane znanstvene radove pa možemo reći da dano istraživanje prikazuje općenite ključne čimbenike za implementaciju vitke proizvodnje [25].

Tablica 4. prikazuje 25 čimbenika koji utječu na implementaciju LP-a te su ti čimbenici prepoznati u trideset i tri relevantne studije u različitim industrijskim granama. Pored čimbenika koji imaju utjecaj na implementaciju LP-a, 55 % studija pokazalo je da je najvažniji čimbenik za implementaciju vitke proizvodnje upravo posvećenost i podrška menadžmenta. No nijedna od tih 55 % studija ne pokazuje kako razlikovati menadžment koji je posvećen i daje podršku, od onog koji ne daje podršku i nije posvećen implementaciji LP-a. Kao drugi najvažniji čimbenik prilikom implementacijskog procesa LP-a pojavljuje se sposobnost, iskustvo i znanje da se implementira LP. Tako je 30 % studija pokazalo da su sposobnost, iskustvo i znanje potrebni za uvođenje LP-a vrlo značajan čimbenik za organizacije i poduzeća. Isto tako 21 % studija pokazalo je da je prilikom implementacije vitke proizvodnje vrlo važno da postoji organizacijska kultura koja je spremna i voljna na promjene. Sva tri navedena čimbenika vezana su isključivo

uz samo poduzeće ili organizaciju, što znači da implementacija vitke proizvodnja ne ovisi često o vanjskom okruženju ili o tehničkim aspektima poduzeća. Rezultat ove studije dao je kristalno jasnu sliku o implementaciji vitke proizvodnje, a to je da promjene u poduzeću moraju doći iznutra te da svi moraju biti uključeni u proces tranzicije. To možemo vidjeti i kod ostalih bitnih čimbenika kao što su postojanje srednjih i dugoročnih ciljeva u kompaniji, povjerenje prema LP-u, autonomnost zaposlenika te posvećenost i podrška radnika. Potrebno je naglasiti kako je 10 % studija za čimbenik na koji poduzeća ne mogu utjecati navelo čimbenik veličine poduzeća. Tako je u 10 % studija navedeno da su velika poduzeća uspješnija kod uvođenja vitke proizvodnje te da dostupnost financijskih i ljudskih resursa bitno utječe na uspješnost i održivost i LP-a [25].

Tablica 4. *Čimbenici koji utječu na implementaciju LP-a istraženi u 33 znanstvena rada [25]*

	Sektori u kojima su provođena istraživanja	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**	**13**	**14**	**15**	**16**	**17**	**18**	**19**	**20**	**21**	**22**	**23**	**24**	**25**	**26**	**27**	**28**	**29**	**30**	**31**	**32**	**33**	Suma
	Proizvodnja (općenito)			●		●	●	●							●	●			●	●			●		●	●			●	●		●			**14**
	Elektronička industrija								●		●											●												●	**4**
	Automobilska industrija												●				●	●															●		**4**
	Druge grane (uslužne djelatnosti, mala i srednja poduzeća, svemirska, poljoprivredna, keramička, prehrambena i tekstilna industrija	●	●							●		●									●			●			●	●							**8**
	Teoretska istraživanja				●									●														●			●				**4**
	Čimbenici																																		
Ljudi	Sposobnost, iskustvo i znanje potrebni za implementaciju vitke proizvodnja		●		●	●			●				●	●	●	●										●							●		**10**
	Mlada radna snaga																			●															**1**
Organizacija rada	Definirani srednji i dugoročni ciljevi	●				●																	●	●									●		**5**
	Otvorenost organizacijske prema promjenama		●			●	●			●					●											●	●								**7**
	Organizacijsko povjerenje u vitku filozofiju				●	●									●		●																		**4**
	Autonomnost zaposlenika				●	●																		●		●									**4**
	Posvećenost i podrška menadžmenta	●	●		●	●		●		●		●	●				●			●	●	●	●	●		●				●		●	●		**18**
	Podrška i posvećenost radnika			●						●																	●						●		**4**
	Sigurnost zaposlenja														●																		●		**2**
	Strategija i metrika učinkovitosti usklađene s vitkom filozofijom				●					●				●																				●	**4**
	Sustavan i usklađen plan restrukturiranja					●	●			●																									**3**
	Fokus na metrici operativne učinkovitosti, a ne na računovodstvu				●																			●					●						**3**
	Komunikacija i prenošenje znanja o procesima i promjenama																							●							●		●		**3**
	Tranzicija s masovne na vitku proizvodnju lakša je i bolja nego s obrtničke na vitku proizvodnju																								●										**1**
	Integracija s ostalim odjelima (npr. marketing, prodaja, razvoj)																										●								**1**
	Metode za dugoročno održanje implementacije																							●											**1**
	Sustav nagrađivanja dosljedan vitkoj filozofiji				●																														**1**
	Uključenost zaposlenika u procese poboljšanja																																●		**1**
Vanjsko okruženje	Veličina poduzeća: velika poduzeća uspješnija su kod LP-a					●					●							●	●																**4**
	Dostupnost financijskih i ljudskih resursa		●			●									●																	●			**4**
	Dominantan položaj poduzeća iz pogleda kupaca					●										●																			**2**
	Sindikalni sustav, nacionalna kultura i oblik proizvodnog pogona utječu na implementaciju vitke filozofije																													●					**1**
	Stupanj povezanosti s dobavljačima									●																									**1**
Tehnički aspekt	Mali broj proizvoda i njegovih varijacija																						●				●								**2**
	Tip proizvodnog sustava (npr. lakše je uvesti LP u proizvodne linije i ćelije nego u trgovine)																												●						**1**

2.5.2. Motivi i ciljevi implementacije vitke proizvodnje

Implementacija vitke proizvodnje vrlo je opsežan zahvat za bilo koje poduzeće jer takva poslovna transformacija zahtijeva veliki entuzijazam i napor. Postoje brojne teorijske i empirijske metode implementacije vitke proizvodnje te ne postoji konsenzus znanstvenih autora oko pravog pristupa implementaciji vitke proizvodnje.

Uvođenje vitke proizvodnje u organizaciju treba biti brz i odlučan potez jer je sama srž vitke kulture biti što kompetitivniji i prilagodljiviji tržišnim izazovima. Kako bi implementacija bila što uspješnija, potrebno je definirati i preispitivati kratkoročne i dugoročne ciljeve kako bi se osigurala organizacijska cjelovitost. Sam postupak provođenja i edukacije treba biti napravljen na način da se educiraju ključni ljudi te da oni šire svoja znanje diljem poduzeća ili pak angažiranjem vanjskih konzultantskih kuća koje potpomažu tranzicijskom procesu. Mnoge tranzicije u vitku proizvodnju propadnu ili ne budu uspješne jer ljudi ne vide poboljšanja i učinke LP-a. Stoga je vrlo važno da svi ljudi uključeni u postupak implementacije LP-a na svoje oči vide i shvate što vitka proizvodnja može postići te koju financijsku korist ovakva kultura može ostvariti. Ljudi moraju imati potpuno povjerenje u LP te ne smiju osjećati strah ili anksioznost od promjene. U ranoj fazi prelaska na vitku kulturu ljudi moraju shvatiti da LP nije samo komplet alata za poboljšanje, već su to ljudi čija će posvećenost i predanost rezultirati pozitivnom promjenom. Isto tako, jedan od gorućih problema prilikom prelaska na vitku filozofiju svakako je edukacija zaposlenika. U brojnim istraživanjima dokazano je da mnoga poduzeća uslijed lošeg edukacijskog sustava o LP-u ne uspijevaju radnicima prenijeti vitku kulturu i načela te na koncu posustaju i ne ostvaruju željene rezultate. Točnije rečeno, radnici moraju imati ciljeve, viziju i alate s kojima će postići organizacijsku promjenu [26].

U Velikoj Britaniji je 2012. godine napravljeno zanimljivo istraživanje u sedamdesetak poduzeća vezano uz uvođenje LP-a i krajnje rezultate. U Tablici 5. možemo vidjeti da je glavni motiv za uvođenje LP-a bila namjera poboljšanja učinkovitosti i pritisak konkurencije. Oba razloga za uvođenje LP-a vrijedila su neovisno o veličini poduzeća. Ostali bitni razlozi za uvođenje LP-a bili su pritisak kupaca, razvoj timskog duha, druga poduzeća, vlasnici itd. Uopćeno može se reći da je LP na tržištu prepoznat kao pravi alat za odgovor na nepredvidljivo i turbulentno tržište [26].

Tablica 5. *Glavni motivi za uvođenje vitke proizvodnje [26]*

Mala poduzeća		Srednja poduzeća		Velika poduzeća	
Poboljšanje učinkovitosti	98 %	Poboljšanje učinkovitosti	89 %	Poboljšanje učinkovitosti	89 %
Pritisak konkurencije	81 %	Pritisak konkurencije	83 %	Pritisak konkurencije	75 %
Timski duh	63 %	Timski duh	53 %	Pritisak kupaca	59 %
Pritisak kupaca	58 %	Pritisak kupaca	50 %	Razvoj timskog duha	57 %
Vlasnici/investitori	41 %	Pojedinci unutar poduzeća	46 %	Druga poduzeća	53 %

Navedeno istraživanje provedeno u Velikoj Britaniji nije se bavilo samo motivima uvođenja vitke proizvodnje, već su sagledavane težnje i ciljevi pojedinih poduzeća. Sagledavana poduzeća u tom istraživanju imala su različita očekivanja od vitke proizvodnje. Tako su manja poduzeća najviše htjela povećati konkurentnost, srednja poduzeća produktivnost, a velika poduzeća učinkovitost. Vidi se da ovdje izostaje konsenzus koji je postojao vezan uz uvođenje vitke proizvodnje. U Tablici 6. vidljivo je da veličina poduzeća igra ulogu kod ciljeva prilikom uvođenja vitke proizvodnje. Ipak, generalizirajući, vidljivo je da sva poduzeća žele povećati konkurentnost, učinkovitost, produktivnost, profitabilnost te smanjiti troškove proizvodnje.

Tablica 6. *Težnje i ciljevi poduzeća prilikom implementacije vitke proizvodnje [26]*

Mala poduzeća	%	**Srednja poduzeća**	%	**Velika poduzeća**	%
Povećati konkurentnost	97	Povećati produktivnost	97	Povećati učinkovitost	86
Povećati učinkovitost	96	Povećati profitabilnost	93	Povećati produktivnost	86
Povećati produktivnost	96	Smanjiti troškove proizvodnje	92	Povećati profitabilnost	85
Povećati profitabilnost	96	Eliminirati gubitke	87	Smanjiti troškove proizvodnje	83
Poboljšati učinkovitost zaposlenika	83	Poboljšati usluge korisnicima	84	Postići manje zaliha; sirovina, WIP-a i proizvoda	81
Smanjiti troškove proizvodnje	87	Povećati konkurentnost	84	Eliminirati gubitke	82
Eliminirati gubitke	80	Povećati učinkovitost	83	Poboljšati usluge korisnicima	77
Poboljšati timski rad	73	Postići bolju isporuku	76	Povećati konkurentnost	76
Poboljšati usluge korisnicima	72	Postići manje zaliha; sirovina, WIP-a i proizvoda	73	Smanjiti zastoje i prekide	75
Smanjiti zastoje i prekide	70	Poboljšati učinkovitost zaposlenika	72	Poboljšati upravljanje opskrbnim lancem	74
Postići manje zaliha; sirovina, WIP-a i proizvoda	69	Smanjiti zastoje i prekide	70	Postići bolju isporuku	71
Postići bolju isporuku	66	Poboljšati tržni udio	59	Poboljšati učinkovitost zaposlenika	69
Poboljšati upravljanje opskrbnim lancem	47	Poboljšati timski rad	56	Poboljšati timski rad	69
Poboljšati tržni udio	46	Poboljšati upravljanje opskrbnim lancem	53	Poboljšati tržni udio	58

2.5.3. Metode implementacije vitke proizvodnje

Literatura vezana uz vitku proizvodnju dostupna je i poznata, no mnoga poduzeća unatoč toj činjenici nisu bila uspješna u implementaciji vitkih načela i alata. Postoji mnogo studija vezanih uz uspješnu implementaciju vitke proizvodnje. Najčešće te studije obuhvaćaju nekoliko poduzeća te opisuju početne uspjehe prilikom implementacije vitkih principa i alata, no ta početno ugrađena vitka načela s vremenom nestanu te uvođenje vitke proizvodnje bude neuspješno [27].

Općenito govoreći, sve metode implementacije LP-a imaju neke sličnosti. Tako većina autora predlaže da se kod uvođenja LP-a poduzeće treba fokusirati na standardizaciju procesa i aktivnosti, angažiranje ljudi te na uporabu vitkih načela kako bi pojednostavili poslovne postupke. Neka novija razmišljanja vezana uz uvođenje LP-a predlažu pak malo drugačiji implementacijski okvir. Tako novije smjernice govore o tome da se u pojedinim razdobljima treba fokusirati na projekte i specifične alate [27].

Mnogo važnije pitanje od same metode implementacije vitke proizvodnje pitanje je organizacijske kulture. Organizacijska kultura manifestira se kroz svakodnevne implicitne vrijednosti i tradicije koje poduzeće njeguje. Kultura se odražava u ponašanju zaposlenika, njihovim očekivanjima od organizacije te u shvaćanju što je normalno ponašanje i kako treba pristupiti poslu. Ljudi koji su donositelji svih bitnih odluka unutar poduzeća moraju paziti kakav sustav vrijednosti njeguju jer se njihovo ponašanje izravno odražava na kulturu poduzeća. S kulturom se ne smije postupati kao sa svojevrsnim proizvodom poduzeća, već to treba biti postupak koji pokazuje smjer i srž same organizacije. Implementacija vitke proizvodnje predstavlja uspješnu integracija vitkih alata i metoda u kulturu i poslovanje poduzeća. Isto tako, vitka transformacija podrazumijeva besprijekornu integraciju društveno-tehničkog sustava. Važno je shvatiti da čimbenici i načela društveno-tehničkog sustava igraju ključnu ulogu u implementaciji vitke proizvodnje. Tehnički sustav unutar organizacije obuhvaća tehnologije, proces i opremu, dok društveni sustav obuhvaća ljude i njihove odnose. Kako bi se sagradio učinkovit i otporan sustav, tehnički i društveni sustav moraju biti integrirani na način da se povežu tehničke, političke i društvene prakse [27].

Vitka proizvodnja poznata je već nekoliko desetljeća i mnoga su poduzeća započela s vitkom transformacijom, no rezultati nisu bili ni približno zadovoljavajući. Uzrok tome vjerojatno je to što ne postoji idealno implementacijsko rješenje koje bi bilo primjenjivo na sva poduzeća. Svako poduzeće posluje u svome mikro i makrookruženju te svako poduzeće ima svoje operativne i kulturološke probleme koji tvore njihovu početnu poziciju. U Tablici 7. prikazani su različiti implementacijski modeli vitke proizvodnje te je vidljivo da svaka od tih studija daje neki svoj pogled na vitku transformaciju. Sama Tablica 7. sastoji se od trinaest važnih istraživanja iz područja uvođenja LP-a te je na prvu ruku vidljivo da šest od trinaest implementacijskih modela nije isprobano na stvarnim poduzećima, već se radi o teorijskim predlaganjima. Isto tako, kao što je već ranije naglašeno, vidljivo je da svaka skupina prilikom implementacije LP-a predlaže

različite korake. Stoga je nesumnjivo prilično jasno da u cijeloj poslovnoj zajednici ne postoji sporazum oko jasnih koraka prilikom uvođenja LP-a. No unatoč toj činjenici, iz Tablice 7. vidljivo je da je VSM prilično zastupljen u većini implementacijskih modela. VSM se u tim studijama ne spominje samo kao svojevrsni vitki alat, već se spominje i kao određeni korak u implementacijskom postupku. Stoga se može reći da je mapiranje toka vrijednosti (VSM) jedan važan stup prilikom implementacije LP-a. Kao krajnji zaključak može se reći da uporaba različitih vitkih praksi i alata daje različite rezultate, što je vidljivo iz studija koje su bile napravljene u realnim situacijama te na realnim poduzećima [25].

Tablica 7. *Metode implementacije vitke proizvodnje prema različitim studijama [25]*

	Metode implementacije i značajke	Opseg djelovanja	Je li takva metoda implementacije primijenjena u stvarnom slučaju? Koji su rezultati?
1	Mapirati tok vrijednosti(VSM) u četiri koraka: (1) izabrati skupinu proizvoda, (2) mapirati postojeće stanje, (3) dizajnirati buduće stanje i (4) osmisliti plan implementacije.	S radionice na cijeli proizvodni pogon	Da, poduzeća iz različitih sektora implementirala su VSM. Produktivnost se povećala, a vodeće je vrijeme smanjeno.
2	Izraditi klasifikacijski dijagram i plan koji će služiti kao poveznica između gubitaka u proizvodnji i vitkih alata. Uvoditi vitke alate koji najbolje smanjuju određene gubitke.	Radionice	Ne.
3	Implementacija u četiri koraka: (1) definirati zašto je vitka proizvodnja nužna, (2) napraviti preliminarni koncept i projekt, (3) napraviti detaljan dizajn i plan, (4) implementirati zamišljeni model i kontinuirano raditi na poboljšanjima.	Administracija i radionice	Da, u pet aeronautičkih poduzeća. Rezultati nisu bili predstavljeni.
4	Implementacija koja se temelji na aksiomatskom modelu u četiri koraka: (1) prepoznati potrebe kupaca, (2) odrediti funkcionalne zahtjeve, (3) projektirati parametre, (4) kontrolirati procesne varijable.	Administracija i radionice	Ne.
5	Preliminarni koraci: (1) educirati zaposlenike, (2) uključiti vrhovni menadžment u vitku transformaciju, (3) shvatiti financijski smisao vitke proizvodnje, (4) uvesti metriku učinkovitosti, (5) osnaživati zaposlenike, (6) definirati sustav nagrađivanja za srednji menadžment. Operativni koraci su: (1) nivelirati proizvodnju, (2) uspostaviti brze izmjene alata, (3) uspostaviti kontrolu kvalitete, (4) uspostaviti preventivno održavanje, (5) povlačiti materijal samo kada kupac to želi, (6) kontrolirati zalihe, (7) integrirati dobavljače, (8) automatizirati određene operacije (9) širiti vitko razmišljanje izvan granica poduzeća.	Administracija i radionice	Ne.
6	Implementacija u tri etape: (1) razviti vitku kulturu, (2) isticati predanost menadžmenta i (3) uvesti metriku učinkovitosti. Implementirati vitke alate kao što su „pull“ proizvodnja, *heijunka*, *jidoka*, VSM, vizualne kontrole i *kaizen*.	Radionice	Ne.
7	Implementacija se ne bi trebala temeljiti na detaljnim koracima, već na stvaranju potrebe za poboljšanjima, na način da zaposlenici samostalno rješavaju probleme koristeći se PDCA logikom.	Radionice	Da, dva proizvodna poduzeća. Došlo je do smanjenja WIP-a te poboljšanja dostave.
8	Metoda koja je razvijena za tekstilnu industriju i ima šest koraka: (1) definirati politiku razvoja, (2) uvesti vizualni menadžment, (3) raditi kontinuirana poboljšanja, (4) standardizirati rad, (5) uvesti „pull“ proizvodnju i (6) orijentirati se na želje kupaca. Implementacija svih navedenih koraka treba biti podržana VSM-om.	Radionice	Da, u sedam tekstilnih poduzeća. Došlo je do smanjenja vodećeg vremena proizvodnje.

Tablica 7. *Metode implementacije vitke proizvodnje prema različitim studijama [25] (nastavak)*

9	Metoda koja ima četiri koraka: (1) napraviti analizu tržišta, (2) mapirati procese, (3) analizirati tok vrijednosti iz perspektive kupca i (4) izraditi financijski model budućeg stanja.	Administracija i radionice	Da, u avioprijevozničkim poduzećima. Tržišni udio povećan za 50 %.
10	Metoda koja ima četiri koraka: (1) izmjeriti i utvrditi učinkovitost, (2) mapirati postojeće procese, (3) definirati nove procese koristeći se analitičkim hijerarhijskim procesima i (4) usporediti nove procese sa željenim stupnjem učinkovitosti.	Radionice	Ne.
11	Metoda implementacije koja pomaže pri odabiru vitkih alata. Ova metoda temelji se na analitičkim hijerarhijskim procesima, uključuje utvrđivanje kriterija kod odabira vitkih alata i definira težinske čimbenike za svaki kriterij.	Radionice	Da, u proizvodnim organizacijama koje proizvode modularne električne sklopke. Nisu mjereni rezultati uslijed uvedenih vitkih alata.
12	Metoda implementacije koja je razvijena za uslužna poduzeća te ima šest koraka: (1) uspostaviti linearni protok, (2) proizvoditi u malim serijama, (3) uspostaviti brzu izmjenu alata, (4) grupirati zadaće po radnim stanicama, (5) stvoriti multifunkcionalno osoblje i (6) uspostaviti osiguranje kvalitete u nekoliko faza proizvodnje.	Radionice	Da, u telekomunikacijskom poduzeću. Došlo je do smanjenja varijabilnosti te povećanja produktivnosti.
13	Vitke alate treba uvoditi usporedno, ali i pojedinačno. U početku se menadžment treba posvetiti trima usporednim zadaćama: (1) smanjiti hijerarhijske razine u organizaciji i uspostaviti proizvodnju bez neispravnih proizvoda, (2) uspostaviti proizvodne ćelije koje rade prema „pull“ proizvodnom sustavu i (3) uspostaviti vertikalni informacijski sustav i definirati vođe. Nakon toga potrebno je fokusirati se na inicijative vezane uz kontinuirano poboljšanje.	Radionice	Ne.

Implementacija vitke proizvodnje složen je pothvat i svako poduzeće ima svoj vlastiti pristup. Velik broj poduzeća pokušava uvesti vitke alate, no takvi projekti često završavaju neuspješno. Neki autori smatraju da je poduzeće postiglo vitku transformaciju ako uspješno implementira strateške sastavnice vitke proizvodnje. Najvažnije su sastavnice vitke proizvodnje posvećenost menadžmenta, autonomija zaposlenika, transparentnost informacija i prikladna radna kultura. Najčešća greška poduzeća uvođenje je vitkih načela, alata i kulture odozdo prema gore. Vrhovni i srednji menadžment mora biti u potpunosti posvećen i okupiran implementacijom vitkih alata na način da podržava i usmjerava ljude u provođenju vitke transformacije. Uvođenje vitkih alata ne može biti prepušteno radnicima i poslovođama, već ga treba sustavno pratiti i podržavati menadžment. Općenit govoreći, prvi korak kod uvođenja LP-a trebao bi se temeljiti na angažmanu cjelokupnog menadžmenta. Ako angažman i posvećenost menadžmenata unutar poduzeća nije vidljiv, uvođenje vitke filozofije neće biti uspješno. Drugi važan korak kod uvođenja LP-a stvaranje je formalnih mehanizama koji potiču i ohrabruju zaposlenike na autonomnost. Autonomnost zaposlenika važan je čimbenik kod LP-a jer su ljudi te njihove ideje i znanja najveći kapital koje poduzeće ima. Kapitalna ulaganja u vitku transformaciju ne znače ništa ako svi ljudi nisu uključeni u postupak transformacije. Treći važan korak LP-a otvoreno je izlaganje srednjoročnih i dugoročnih ciljeva. Svi ciljevi i odluke moraju biti transparentno predstavljeni zaposlenicima kako se poduzeće ne bi pretvorilo u jedan ogroman „pokvareni telefon“, gdje kolaju neistinite i nepravovremene informacije. Kod uvođenja LP-a često se

javljaju frustracije i nesigurnosti radnika od gubitka posla te im treba biti rečeno da se vitka proizvodnja integrira sa svrhom optimizacije procesa, a ne u svrhu otpuštanja radnika. Pri uvođenju vitkih alata i kulture zaposlenike treba motivirati i nagrađivati te se nikako ne smije stvarati kultura straha od gubitka posla jer će se tada stvoriti stanje bojkota. Četvrti korak treba se oslanjati na dugoročno održanje nastalih poboljšanja i promicanje LP-a. Preciznije rečeno, određeni ljudi unutar poduzeća trebaju se baviti isključivo LP-om te trebaju održavati postojeće i iskušavati nove vitke alate unutar poduzeća. Prilikom iskušavanja novih vitkih alata ljudi ne smiju biti kažnjavani za neuspjehe, već se trebaju ohrabrivati za nove projekte. Peti važan korak kod uvođenja LP-a prikaz je uspješnih vitkih poduzeća zaposlenicima. Na radionicama o vitkoj proizvodnji ljudi moraju vidjeti zašto se od njih traži da ulože napor. Ako radnici ne vide prednosti vitke proizvodnje, motivacija i samopouzdanje će izostati. Na *kaizen* radionicama zaposlenici trebaju biti upoznati s vitkim rješenjima drugih poduzeća kako bi sami dobili ideju kako riješiti određene probleme. Šesti i posljednji korak, ili stup vitke transformacije, kontinuirano je praćenje i evaluacija rezultata uslijed primjene LP-a. Neizbježno je da će poduzeće raditi greške i krive korake prilikom implementacije, no te greške trebaju biti vidljive i dokumentirane kako bi se na njih znalo reagirati. Uvijek mora postojati povratna veza kako bi se osigurao korektivni instrument za pravilno uvođenje vitke proizvodnje [28].

Uvođenje vitke proizvodnje i njezinih alata najčešće blokira neprikladna organizacijska kultura. Svako poduzeće prije uvođenja vitke proizvodnje treba analizirati i procijeniti svoju organizacijsku kulturu. Kada poduzeće utvrdi mjesta s lošom radnom kulturom, tada se treba fokusirati na kulturološku transformaciju u tim mjestima. U protivnome bi transformacija vitke proizvodnje mogla biti neuspješna. Drugim riječima, organizacija prije uvođenja LP-a treba locirati svoje najbolje ljudi i timove te pretočiti njihovu radnu etiku na ostale ljude kako bi očekivanja od LP-a bila optimalna. Prilikom uvođenja LP-a poduzeće se mora pripremiti na kulturološku promjenu unutar svojih redova. Ako ne postoji jasna kulturološka transformacija, tada implementacija vitkih alata neće biti moguća [29].

Poduzeća se tijekom transformacije trebaju oslanjati na puno vitkih alata kako bi u konačnici došla do stanja proizvodnje po vitkim načelima. U Tablici 8. prikazani su najrelevantniji vitki alati koji čine okosnicu vitke proizvodnje. Tablica 8. ne prikazuje samo vitke alate, već je napravljena i kategorizacija istih. Kategorizacija vitkih alata i principa napravljena je na način da je sagledano šesnaest znanstvenih istraživanja koja su se bavila temom vitke proizvodnje i njezinih alata. Tako je svaka skupina autora zagovarala i smatrala da određeni alati i načela pripadaju vitkoj proizvodnji te je iz Tablice 8. vidljivo da se razmišljanja negdje preklapaju, ali se isto tako i katkada razilaze. Najveći broj autora tako smatra da prakse navedene u nastavku pripadaju vitkoj proizvodnji [25]:

- JIT
- SMED
- TPM
- *heijunka*

- timski rad
- ćelijska proizvodnja
- *kaizen*
- *jidoka*
- kontinuirani tok
- multifunkcionalni timovi, edukacije i treninzi
- standardizacija rada
- vizualna tvornica
- proizvodnja u malim serijama
- osnaživanje zaposlenika (autonomija)
- praćenje učinkovitosti (produktivnost i kvaliteta)
- analiza glavnog uzroka
- 5S
- VSM.

Upravo su te navedene prakse okosnica vitkog razmišljanja i kulture te poduzeće prilikom implementacije vitke proizvodnje treba težiti tome da uvede što više vitkih praksi kako bi poslovanje bilo dovedeno u okvire vitkog razmišljanja.

Tablica 8. *Učestalost praksi koje su povezane s vitkom proizvodnjom [25]*

Godina istraživanja	1996.	1996.	1996.	1998.	2002.	2003.	2005.	2007.	2007.	2009.	2009.	2009.	2010.	2011.	2011.	2012.	
Istraživanje	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	Ukupno
Vitki alati																	
JIT	•			•	•	•	•	•	•	•	•	•	•	•	•	•	14
Brza izmjena alata (SMED)	•	•		•	•	•	•	•	•	•	•			•	•	•	13
Cjelovito produktivno održavanje (TPM)	•	•		•	•	•	•	•	•		•		•	•	•	•	13
Stabilna i ujednačena proizvodnja (*heijunka*)	•	•		•	•	•	•		•		•	•	•	•			11
Timski rad	•	•	•	•	•	•	•	•			•			•	•		11
Ćelijska proizvodnja			•	•		•	•		•	•	•		•	•	•	•	11
Kaizen	•	•	•	•	•	•		•	•	•				•		•	11
Parcijalna automatizacija (*jidoka*)	•			•	•		•			•	•		•	•	•	•	10
Kontinuirani tok (proizvodnja bez zastoja i smetnji)				•		•		•	•		•	•	•	•	•	•	10
Multifunkcionalni timovi, edukacije i treninzi	•		•	•	•	•	•	•		•	•			•			10
Standardizacija rada		•	•				•			•	•		•	•	•		8
Vizualna tvornica	•				•				•	•	•		•	•	•		8
Proizvodnja u malim serijama	•			•	•	•	•		•		•					•	8
Osnaživanje zaposlenika (autonomnost)		•	•	•		•					•		•	•	•		8
Praćenje učinkovitosti (produktivnost i kvaliteta)	•	•			•					•	•			•	•		7
Analiza glavnog uzroka						•		•	•				•	•	•	•	7
5S				•					•		•			•	•	•	6
Mapiranje toka vrijednosti (VSM)									•	•	•	•	•			•	6
Simultani inženjering		•		•			•				•			•			5
Uključenost kupaca		•		•				•		•			•				5
Uključenost dobavljača				•			•	•		•	•						5
Specijaliziranost tvornice		•						•	•		•			•			5
Standardizacija dijelova i proizvoda		•		•			•				•						4
Statistička kontrola procesa		•						•			•		•				4
Slanje povratnih informacija dobavljačima		•					•	•			•						4
Odziv i mogućnost proizvodnje različitih proizvoda		•		•		•									•		4
Sustav nagrađivanja zaposlenika									•		•		•		•		4
Dizajn proizvoda na način da se lako proizvodi				•			•				•						3
Kontrola kvalitete u svim fazama proizvodnje				•			•				•						3
Proizvodnja po načelu „povlačenja“				•				•			•						3
Voditelji timova	•				•									•			3
Sigurnost i zaštita na radu						•					•				•		3
Komercijalne aktivnosti koje stabiliziraju potražnju				•			•										2
Heijunka										•	•						2
Multifunkcionalni razvojni timovi		•		•													2
Standardizacija rada											•				•		2
Integrirani rad odjela		•															1

2.5.4. Rezultati vitke proizvodnje

Model vitke proizvodnje može strateški, operativno i financijski restrukturirati poslovanje poduzeća. Takav pristup poslovanju poduzeću pruža priliku da zadrži ili osvoji vodeću poziciju na tržištu u pogledu konkurentnosti i profitabilnosti. Kada se model vitke proizvodnje pravilno uvede u sustav poslovanja, rezultati će biti vidljivi i uspjeh neće izostati. Vitka proizvodnja ne utječe samo na strateško, operativno i financijsko poslovanje poduzeća. Ona također značajno utječe na odgovorno upravljanje okolišem i resursima. Dokazano je da vitki alati poput 5S-a, VSM-a, TPM-a, SMED-a i drugih, unaprjeđuju segment odgovornog upravljanja okolišem. Vitka proizvodnja stvara operativno i kulturološko okruženje koje je usmjereno na minimalizaciju gubitaka, ali i na odgovornu brigu za okolišem. Smisao LP-a nije maksimalizacija profita, već i društveno osviješteno i odgovorno dugoročno poslovanje [30].

Glavna svrha uporabe načela vitke proizvodnje eliminacija je svih vrsta nepotrebnih gubitaka. U Tablici 9. mogu se vidjeti neki od rezultata koji su postignuti primjenom vitke proizvodnje u različitim zemljama i sektorima. Tablica 9. jasno prikazuje da vitka proizvodnja ima velik utjecaj na poslovanje u pogledu [25]:

1) boljeg operativnog poslovanja
2) boljeg upravljanja financijama
3) boljeg upravljanja ljudima
4) boljeg osvajanja tržišta te
5) boljeg i odgovornijeg upravljanja okolišem.

Prednosti vitke proizvodnje vidljive su diljem svijeta u različitim industrijskim sektorima. Poduzeća koja su implementirala vitku proizvodnju u svoje poslovanje, dramatično su povećala kvalitetu proizvoda, smanjila vrijeme proizvodnje, smanjila zalihe poluproizvoda, poboljšala vrijeme isporuke, povećala dobit, smanjila troškove i zalihe, povećala ROE i ROA, povećala učinkovitost strojeva itd. Vitka proizvodnja na neki je način u poslovnim krugovima postala pomodna riječ. Poduzeća teže preuzimanju vitkih modela ponašanja i upravljanja kako bi ostala ukorak s nemilosrdnom konkurencijom i tržištem. Najvažniji učinci vitke proizvodnje na poduzeće su sljedeći[31]:

- smanjenje škarta za 20 % svake godine, s mogućnošću postizanja proizvodnje bez škarta
- smanjenje vremena isporuke proizvoda i usluga za 75 %
- poboljšanje isporuke na vrijeme za gotovo 99 %
- povećanje produktivnosti po zaposleniku za 15 – 35 % godišnje
- smanjenje svih vrsta zaliha za gotovo 75 %
- poboljšanje povrata na imovinu (ROA) za gotovo 100 %
- poboljšanje u pogledu korisnosti rada za 10 % ili više
- poboljšanje u pogledu neizravne koristi rada za gotovo 50 %

- povećanje kapaciteta postojećih proizvodnih pogona za 50 % ili više
- smanjenje radnog prostora za 80 %
- poboljšanje kvalitete za 50 %
- dostupnost strojeva od 95 %
- smanjenje vremena izmjene alata za 80 – 90 %
- smanjenje ciklusnog vremena proizvodnje za 60 %.

Tablica 9. *Rezultati vitke proizvodnje koji su dokumentirani u trideset studija [25]*

R. br.	**REZULTATI**	Lokacija/sektor	MJERA				
			Operativna	Financijska	Ljudska	Tržišna	Ekološka
1	Smanjenje zaliha, posebice WIP-a, neovisno o vrsti proizvoda.	Globalno/proizvodnja	•				
2	Pretjerano niske ili visoke razine zaliha imaju negativan utjecaj na operativnu učinkovitost.	SAD/proizvodnja	•				
3	Povećanje produktivnosti.	UK/građevinarstvo	•				
4	Povećanje operativne učinkovitosti. Međutim, nije bilo dokaza u pogledu smanjenja zaliha i serija.	Turska/autoindustrija	•				
5	Poboljšanje operativne učinkovitosti. Međutim, vitke prakse upravljanja lancem opskrbe nisu imale utjecaj na kvalitetu proizvoda.	Kina/proizvodnja	•				
6	Povećanje operativne učinkovitosti.	Indija/srednja poduzeća	•				
7	Poboljšanje učinkovitosti na više razina.	Brazil/poljoprivreda	•	•		•	
8	Poboljšanje učinkovitosti. Rezultati su puno bolji pri usporednom uvođenju nekoliko vitkih alata.	SAD/proizvodnja	•				
9	Poboljšanje učinkovitosti. Rezultati su puno bolji pri usporednom uvođenju nekoliko vitkih alata.	Globalno/elektronika	•				
10	Poboljšanje učinkovitosti. Rezultati su puno bolji pri usporednom uvođenju nekoliko vitkih alata.	Indija/srednja poduzeća	•				
11	Poboljšanje učinkovitosti, posebice produktivnosti, razine zaliha i vodećeg vremena.	UK/elektronika	•				
12	Povećanje produktivnosti i bolje korištenje raspoloživog prostora. Bolja ergonomija radnog mjesta.	SAD/autoindustrija	•				
13	Financijska dobit od uvođenja vitke filozofije u prosjeku je bila osam puta veća od investicije.	UK		•			
14	Smanjenje proizvodnih troškova.	SAD/avioindustrija		•			
15	Povećanje dobiti.	SAD/proizvodnja		•			
16	Vitka filozofija ne povećava nužno profitabilnost, ali omogućava približavanje tržišnim liderima.	Europa/proizvodnja		•		•	
17	Poboljšanje komunikacije među zaposlenicima.	SAD/elektronika			•		
18	Poboljšanje radnih uvjeta unatoč činjenici da vitka proizvodnja povećava intenzitet rada.	Brazil/poljoprivreda			•		
19	Vitka filozofija ne stvara stres. Razine stresa povezane su s odlukama na koji će se način implementirati i provesti vitka filozofija.	UK/proizvodnja			•		
20	Vitka filozofija ne stvara i nameće emotivnu povezanost zaposlenika s poduzećem. To je povezano, primjerice, s menadžmentom.	UK/proizvodnja			•		
21	Povećanje autonomije i zadovoljstva zaposlenika.	Europa/logistika			•		
22	Povećanje produktivnosti, smanjenje zaliha, bolja edukacija zaposlenika i veća sigurnost u pogonima.	Španjolska/keramika	•		•		
23	Povećanje tržišnog udjela prvoklasnih brendova, posebice razvojem proizvoda i boljim inženjeringom.	Japan, UK, SAD/proizvodnja				•	
24	Bolje korištenje prirodnih resursa (energenata), posebice bolje upravljanje otpadom i okolišem.	SAD, Japan/autoindustrija					•
25	Bolje upravljanje okolišem. Smanjenje otpada i zagađenja.	SAD/proizvodnja					•
26	Smanjenje troškova i povećanje operativne učinkovitosti.	SAD/obrazovanje	•				
27	Povećanje produktivnosti i kvalitete.	SAD/obrazovanje	•				
28	Povećanje profitnih marži zbog smanjenja gubitaka. Povećanje učinkovitosti i zadovoljstva kupaca.	UK/zabavni park	•				
29	Smanjenje operativnih troškova i povećanje zadovoljstva kupaca.	UK/telekomunikacije	•				
30	Povećanje kapaciteta i smanjenje neopravdanih dolazaka na zakazani pregled.	SAD/bolnice	•				

3. VITKI ALATI

U ovome poglavlju definirani su i opisani vitki alati koji se primjenjuju u vodećim međunarodnim poduzećima. Pritom su temeljni vitki alati sagledani ovim istraživanjem detaljnije opisani kako bi se dobio uvid u način njihovog djelovanja te zabilježili preduvjeti i situacije u kojima se isti implementiraju.

3.1. Definicija vitkih alata

Vitka proizvodnja temelji se na minimalizaciji gubitaka te stvaranju vrijednosti koju je tržište spremno platiti. Prema glavnom načelu vitke proizvodnje bilo kakva alokacija ili korištenje resursa koje kupcu ne predstavlja vrijednost, treba biti predmet promjene ili eliminacije. Vitka proizvodnja disciplina je koja se bavi eliminacijom gubitaka, stjecanjem kapitala, povećanjem prodaje i osvajanjem globalnog tržišta. Kratko rečeno, prilikom implementacije i održanja vitke proizvodnje kao poslovnog modela, poduzeće mora prepoznati svoje gubitke te primijeniti optimalne vitke prakse, odnosno alate koji će otkloniti ili eliminirati prepoznate gubitke. Vitki alati mogu se implementirati u različite industrije i poduzeća te integrirati u različite sektore poslovanja. Vitki se alati prilikom implementacije trebaju preinačiti i prilagoditi poduzeću i promatranom problemu [32]. Najčešći uzrok neuspješnog uvođenja vitkih alata neodgovarajuća je organizacijska kultura te bi poduzeća trebala njegovati ponašanja prikazana u Tablici 10.

Tablica 10. *Šest vitkih ponašanja prema ustanovi McKinsey Global Institute [33]*

VITKO PONAŠANJE	Primjer
1. Fokus na operativnim procesima Rukovoditelji trebaju prikazati važnost svih procesa i promicati standardizirani rad.	Provoditi regularne posjete pogonu te provjeravati proizvodi li se u skladu sa standardima rada i kvalitete te o problemima raspravljati s radnicima.
2. Rješavanje uzroka problema Rukovoditelji moraju žurno rješavati uzroke problema te se isti ne smatraju prilikama za učenje.	Poduzeti sve mjere da se problem riješi brzo i na odgovarajući način, a nakon toga treba izazvati svoj tim da riješi glavni uzrok problema.
3. Postavljanje jasnih razina učinkovitosti Na svim razinama rukovođenja trebaju postojati transparentni dijalozi vezani uz učinkovitost.	Osigurati da se vodeći rukovoditelji svaki dan na barem 10 minuta sastanu sa svojim vođama timova te da se na tom sastanku razgovara o produktivnosti i poboljšanjima.
4. Usklađeno vodstvo Poboljšanje procesa ne prestaje na funkcionalnim granicama poduzeća.	Kako bi se stvorilo stanje otvorenosti i suradnje, godišnje bonuse treba vezati uz ostvarenje ključnih indikatora učinkovitosti.
5. Smisao postojanja Mora postojati realna i shvatljiva veza između dnevnih aktivnosti i dugoročnih ciljeva.	Proizvođač medicinske opreme trebao bi dovesti liječnika koji bi radnicima pokazao važnost zahtijevane kvalitete.
6. Podupiranje zaposlenika Radnici se moraju osnaživati i ohrabrivati za donošenje odluka.	Jednom kada zaposlenik ovlada procesom, treba ga podupirati da samostalno donosi odluke.

Vitki alati su tehnike i metode koje smanjuju ili eliminiraju gubitke u poduzeću. Glavni vitki alati prema vodećim autorima prikazani su u Tablici 11.

Tablica 11. *Najvažniji alati vitke filozofije prema vodećim autorima [34]*

Vitki alati	**Ohno (1988.)**	**Womack & Jones (1996.)**	**Shah & Ward (2003.)**	**Liker (2004.)**
Jidoka	✓			✓
VSM	✓	✓		✓
Ključni indikatori učinkovitosti	✓		✓	
Kontinuirani tok	✓	✓	✓	
Kontinuirano poboljšanje / *kaizen*	✓	✓	✓	✓
Pravovremena proizvodnja / JIT	✓		✓	✓
Cjelovito upravljanje kvalitetom / TQM	✓		✓	✓
Vodstvo / *genchi genbutsu*	✓			✓
Cjeloživotno obrazovanje	✓		✓	✓
Uključenost zaposlenika	✓			✓
Timski rad	✓		✓	✓
Fleksibilnost	✓			
Heijunka	✓		✓	✓
Industrijsko inženjerstvo koje stvara profit	✓			
Nove i učinkovite tehnologije	✓		✓	
Vizualna tvornica	✓			✓
Komunikacija	✓			
Brze izmjene alata / SMED	✓		✓	✓
Smanjenje proizvodnih serija	✓		✓	
Standardizacija rada	✓			✓
Upravljanje zalihama	✓			
Taktno vrijeme	✓			✓
Cjelovito produktivno održavanje / TPM	✓		✓	
Proizvodnja po načelu „povlačenja“		✓	✓	✓
Fokus na kupca		✓		
Vrednovanje s obzirom na konkurenciju			✓	
Specijalizirane tvornice			✓	
Planiranje materijala i narudžbi			✓	
Zdravlje, sigurnost i briga za okoliš			✓	
Vitki sustav nabave				✓
Stabilnost i robusnost				✓
Vizija, kultura i vrijednosti				✓

3.2. Vitki alati u velikim svjetskim poduzećima

Proizvodna i uslužna poduzeća od svog početka pokušavaju poboljšati svoje poslovne procese i aktivnosti te nastoje integrirati najnovija i najbolja poslovna načela u svoje poslovanje. Toyotin proizvodni sustav (TPS) pokazao se dobrim načinom integriranja različitih proizvodnih načela u vlastiti model. Uspjeh TPS-a imao je velik odjek diljem planeta te su sva velika poduzeća uvidjela da sama moraju kreirati svoje poslovne i proizvodne modele koji će sadržavati određena vitka načela, odnosno alate. Glavno pitanje koje se samo po sebi nameće pri kreiranju poslovnog modela unutar poduzeća je može li se prekopirati nečiji tuđi dobar model ili je bolje napraviti svoj vlastiti model. Prošla su gotovo tri desetljeća otkada je James P. Womack napisao „The Machine that Changed the World“ te su mnoga poduzeća pokušala prekopirati ili razviti svoj vlastiti vitki model poslovanja. Svjetska poduzeća razvila su svoje vlastite poslovne modele, odnosno sustave koji su prikazani u Tablici 12. te su u Tablici 13. prikazane prakse, tj. alati od kojih se ti poslovni sustavi sastoje [24].

Tablica 12. *Proizvodni sustavi, odnosno modeli trideset svjetskih poduzeća [34]*

R. br.	Poduzeće	Proizvodni sustav	Industrija	Sjedište
1	Alfa Laval	*Alfa Laval Production System* (ALPS)	Grijanje	Švedska
2	Audi	*Audi Produktionssystem* (APS)	Autoindustrija	Njemačka
3	Bosch	*Bosch Production System* (BSP)	Elektronika	Njemačka
4	Elkem	*Elkem Business System* (EBS)	Materijali od silicija	Norveška
5	Fomel ZF	*Formel ZF Production System*	Autoindustrija	Njemačka
6	Haldex	*Haldex Way*	Autoindustrija	Švedska
7	Herman Miller	*Herman Miller Production System* (HMPS)	Pokućstvo	SAD
8	Hydro Aluminium	*Aluminium Metal Production System* (AMPS)	Aluminijska industrija	Norveška
9	John Deere	*John Deere Quality and Production System*	Teška vozila	SAD
10	Novo Nordisk	*cLean*	Kemijska industrija	Danska
11	REC	*REC Production System* (RPS)	Solarna energija	Norveška
12	Scania	*Scania Produktionssystem* (SPS)	Teška vozila	Švedska
13	Valeo	*Valeo Production System* (VPS)	Autoindustrija	Francuska
14	Volvo	*Volvo Production System* (VPS)	Teška vozila	Švedska
15	ZF Lemförder	*Lemförder Production System* (LPS)	Autoindustrija	Njemačka
16	Almatis	*The Almatis Business System* (ABS)	Aluminijska industrija	Njemačka
17	Boeing	*Boeing Production System* (BPS)	Zračna industrija	SAD
18	Caterpillar	*Caterpillar Production System* (CPS)	Teška vozila	SAD
19	Deutsche Edelstahlwerke	*Deutsche Edelstahlwerke Produktionssystem* (DPS)	Industrija čelika	Njemačka
20	Ecco	*Ecco Production System* (EPS)	Obuća	Danska
21	Electrolux	*Electrolux Manufacturing System* (EMS)	Bijela tehnika	Švedska
22	Gestamp Griwe	*Griwe Production System* (GPS)	Autoindustrija	Njemačka
23	Heidelberg	*Heidelberg Produktionssystem* (HPS)	Strojevi	Njemačka
24	JCB	*JCB Production System*	Teška vozila	Velika Britanija
25	Knorr Bremse	*Knorr-Bremse Production System* (KPS)	Autoindustrija	Njemačka
26	LEGO	*Lego Production System* (LPS)	Igračke	Danska
27	Mercedes	*Mercedes Production System*(MPS)	Autoindustrija	Njemačka
28	Trumpf	*SYNCHRO*	Strojevi	Njemačka
29	Viessmann	*Viessmann Produktionssystem* (ViPS)	Električne komponente	Njemačka
30	Whirlpool	*Whirlpool Production System* (WPS)	Bijela tehnika	SAD

Tablica 13. *Vitke prakse (alati) koji se najviše koriste u trideset svjetskih poduzeća [34]*

Rang	Vitke prakse / alati	Broj proizvodnih sustava koji se koriste ovim alatom	Postotak proizvodnih sustava koji se koriste ovim alatom
1	Standardizacija rada	28	93 %
2	Kontinuirano poboljšanje / *kaizen*	25	83 %
3	Cjelovito upravljanje kvalitetom / TQM	23	77 %
4	Proizvodnja po načelu "povlačenja" procesa	21	70 %
5	Kontinuirani tok	20	67 %
6	VSM	20	67 %
7	Uključenje zaposlenika	19	63 %
8	Vizualna tvornica	18	60 %
9	Fokus na kupca	17	57 %
10	Stabilnost i robusnost	15	50 %
11	Uređenje prostora / 5S	15	50 %
12	Pravovremena proizvodanja / JIT	14	47 %
13	Zdravlje, sigurnost i briga za okoliš	13	43 %
14	Timski rad	13	43 %
15	Niveliranje proizvodnje / *heijunka*	12	40 %
16	Podržavajuće vodstvo	12	40 %
17	Taktno vrijeme	12	40 %
18	Cjelovito produktivno održavanje / TPM	11	37 %
19	Vitki sustav nabave	9	30 %
20	Ključni indikatori učinkovitosti	9	30 %
21	Cjeloživotno obrazovanje	8	27 %
22	Fleksibilnost	6	20 %
23	Vizija, kultura i vrijednosti	5	17 %
24	Jasna i precizna komunikacija	4	13 %
25	Podržavajuća organizacijska struktura	4	13 %
26	Brza izmjena alata / SMED	4	13 %
27	Dizajn proizvoda na način da se lako proizvodi	3	10 %
28	Stvaranje dobiti	3	10 %
29	Inovacije	3	10 %
30	Upravljanje zalihama	3	10 %
31	*Jidoka*	3	10 %
32	Razvoj proizvoda	3	10 %
33	Smanjenje proizvodnih serija	3	10 %
34	Potpuna automatizacija	2	7 %
35	Primjena najnovijih tehnologija	2	7 %
36	Cjelovita učinkovitost opreme / OEE	2	7 %
37	Pravedne plaće	2	7 %
38	Učinkovita prodaja	2	7 %
39	Vrednovanje s obzirom na konkurenciju	1	3 %
40	Raspodjela ljudi prema radnom opterećenju	1	3 %
41	Planiranje narudžbi	1	3 %
42	Upravljanje cjeloživotnim ciklusom proizvoda	1	3 %
43	Brzi odziv sustava u realnom vremenu	1	3 %

Iz Tablice 13. vidljivo je da većina alata koji se koriste u svjetskim poduzećima pripada vitkoj proizvodnji. Vitki alati pokazali su se kao fenomenalan način za dugotrajno poboljšanje poslovnih procesa te su tržišni lideri prepoznali moć takvih alata. Iz Tablice 13. vidljivo je da vitki alati poput JIT-a i *jidoke* ne igraju glavnu ulogu u proizvodnim sustavima promatranih poduzeća. Takav je podatak zanimljiv jer su JIT i *jidoka* glavni stupovi TPS-a. Rezultati ovog istraživanja bili su prilično jasni te nisu nađena velika odstupanja u pogledu uporabe poslovnih alata. Većina sagledanih svjetskih poduzeća, neovisno o industriji, koristi slične alate u svom poslovanju, no postoje neke razlike, a to su:

- zračna industrija i industrija teških vozila stavljaju veći naglasak na smanjenje proizvodnih serija od proizvodnih sustava u drugim industrijskim granama
- procesna industrija ne koristi se uopće načelima „taktnog vremena“ i svoj fokus stavlja na niveliranje proizvodnje, preciznije rečeno, koristi vitki alat *heijunka*
- autoindustrija se vitkim alatom „timski rad“ koristi više od ostalih proizvodnih sustava u ostalim industrijskim granama
- proizvođači opreme najviše koriste načelo dizajna proizvoda na način da je taj proizvod lako izraditi.

Bez obzira na te navedene specifičnosti pojedinih industrija, sva poduzeća navedena u Tablici 12. koriste se načelima i alatima vitke proizvodnje. Iz toga možemo zaključiti da uspješna poduzeća primjenjuju vitke alate te ih prilagođavaju svojim poslovnim potrebama. Svaka je industrija specifična te ne postoji jedno rješenje kod odabira najpovoljnijih vitkih alata za sve industrije. Očigledno je da sva svjetska poduzeća stvaraju svoje proizvodne sustave prema vitkim principima te svoju motivaciju crpe iz TPS-a.

3.3. Vitki alati u srednje velikim poduzećima

Srednje velika poduzeća igraju veliku ulogu diljem svijeta te imaju bitnu ulogu u BDP-u svake zemlje. Sva takva poduzeća posluju u današnjem dinamičnom okruženju i pokušavaju slijediti i prepoznati potrebe i prilike kako na tržištu tako i kod velikih igrača. Postoji više od stotinu vitkih alata i mnogobrojna srednje velika poduzeća pokušavaju integrirati vitke alate u svoje poslovanje kako bi imali bolji odziv na tržišne promjene. Svako poduzeće treba procijeniti koje će vitke alate primijeniti i u kojem će opsegu u svoje poslovanje integrirati vitku filozofiju. Nerealno je očekivati da srednje velika poduzeća integriraju sto vitkih alata. Uvođenje velikog broja vitkih alata kod srednje velikih poduzeća može dovesti do konfuzije, neuspjeha ili dugoročne neodrživosti vitke proizvodnje [35].

Srednje velika poduzeća financijski su ograničena te njihova ulaganja moraju biti promišljena i pravovremena kako bi ishod bio pozitivan. Prilikom uvođenja vitkih alata ovakva bi se poduzeća trebala fokusirati na jeftine i jednostavne vitke alate koji imaju pozitivan učinak u vrlo kratkom

ili srednje dugom vremenskom roku. Kako bi se odredili jednostavni i učinkoviti vitki alati koji su visokoprimjenjivi u srednje velikim poduzećima, provedeno je istraživanje gdje je sagledano nekoliko radova iz područja primjene vitkih alata u srednje velikim poduzećima. Istraživanje je obuhvaćalo visokocitirane radove iz područja vitke proizvodnje te se došlo do zaključka da većina znanstvenih autora smatra poželjnim alate poput: multifunkcionalni zaposlenici, cjelovito upravljanje kvalitetom, SMED, 5S, *kanban*, kontinuirani tok, TPM, male proizvodne serije, *kaizen*, ćelijska proizvodnja, standardizacija rada, treninzi, specijaliziranost tvornice, vitko upravljanje nabavom i timski rad. U Tablici 14. prikazani su vitki alati koje su predlagale određene skupine autora te su ovi vitki alati najpogodniji za implementaciju u srednje velika poduzeća. Zanimljivo je da niti jedna skupina autora iz Tablice 14. nije predložila timski rad kao vitki alat, no kako su spomenuti alati poput multifunkcionalnih ljudi, upravljanja kvalitetom i *kaizena*, možemo zaključiti kako je i timski rad jedan od važnih vitkih alata u srednje velikim poduzećima [35].

Tablica 14. *Vitki alati kojima bi se trebalo koristiti u srednje velikim poduzećima [35]*

	Istraživanja									
Vitki alati	1	2	3	4	5	6	7	8	9	10
Multifunkcionalni ljudi		✓			✓	✓	✓		✓	✓
Cjelovito upravljanje kvalitetom / TQM		✓		✓	✓	✓			✓	✓
Brza izmjena alata / SMED		✓	✓			✓			✓	
5S	✓			✓		✓				
Kanban						✓	✓	✓		
Kontinuirani tok	✓					✓			✓	
Cjelovito produktivno održavanje / TPM		✓				✓			✓	
Male proizvodne serije	✓					✓			✓	
Cjelovito upravljanje kvalitetom		✓				✓				
Kontinuirano poboljšanje / *kaizen*		✓	✓							
Ćelijska proizvodnja			✓			✓				
Standardizacija rada	✓	✓								
Treninzi			✓				✓			
Specijaliziranost tvornica							✓			
Vitko upravljanje nabavom			✓							
Vizualna tvornica		✓								
Timski rad										

Najvažniji čimbenici prilikom implementacije vitke proizvodnje u srednje velikim poduzećima su financije, vodstvo, organizacijska kultura i stručnost zaposlenika. Vitka proizvodnja naveliko se koristi u velikim svjetskim poduzećima, no srednje velika poduzeća također mogu imati značajan profit od uvođenja vitkih načela. Primjena vitkih alata u srednje velikim poduzećima može dovesti do smanjenja zaliha, povećanja kvalitete, skraćenja vodećeg vremena proizvodnje, eliminacije nepotrebnih gubitaka i, u konačnici, sniženja troškova na svim razinama. Isto tako vitka proizvodnja u srednje velikim poduzećima može [36]:

- povećati tržišnu konkurentnost
- poboljšati kvalitetu rada i proizvoda
- poboljšati novčani tok
- povećati prodaju
- poboljšati produktivnost
- poboljšati moral i entuzijazam ljudi
- povećati profit.

Shigeo Shingo potiče na to da se implementacija vitke proizvodnje ostvaruje kroz vremenski plan s ključnim razdobljima, na način da poduzeće postavi jasne ciljeve koje će vitke alate primijeniti unutar jedne godine. Upravo takav oblik implementacije trebao bi se njegovati kod srednje velikih poduzeća. Poduzeća bi trebala imati kratkoročne i dugoročne ciljeve kojima teže, a neispunjenje tih ciljeva treba biti popraćeno odgovarajućim korektivnim radnjama [36]. Sve u svemu, srednje velika poduzeća plodno su tlo za primjenu vitke filozofije i takva poduzeća trebaju naći snagu za tranziciju u vitko poduzeće. Vitko razmišljanje ne osigurava samo bolje operativno poslovanje, već stvara preduvjete za osvajanje bolje tržišne pozicije i povećanje profita.

3.4. Temeljni vitki alati

Na današnjem tržištu koje se ubrzano mijenja, mnoge industrije i poduzeća pokušavaju pronaći pravi poslovni model i alate kojima bi unaprijedili svoje poslovanje. Vitki menadžment tijekom godina se pokazao kao pravi put koji može postići velike uspjehe prilikom ostvarenja zadanih ciljeva. Glavni problem svih poduzeća današnjice je kako isporučiti proizvod tražene kvalitete po što nižoj cijeni kako bi se ostvario što veći profit [37].

Vitki menadžment obuhvaća veliki broj tehnika i alata koje poduzeće može implementirati kako bi smanjilo ili eliminiralo svoje gubitke. Kada će poduzeće koristiti vitke tehnike i alate, koje tehnike i alate i u kojem obimu, izbor je svakog pojedinog poduzeća. Poduzeće treba implementirati pravovremeno određene vitke alate kako bi vitka transformacija bila uspješna. Pitanje koje se postavlja samo po sebi je koji se vitki alati najčešće koriste u vitkim poduzećima

te možemo li među njima prepoznati osnovne vitke alate koje bi svako poduzeće moralo implementirati.

Poduzeće „Vorne Industries“ iz SAD-a, koje posluje s gotovo svim svjetskim vitkim poduzećima, dalo je svoje mišljenje o tome koji su to osnovni vitki alati. Prema „Vorne Industries“ postoji 25 temeljnih vitkih alata i oni su**: 5S, *andon*, analiza uskih grla, *gemba*, *heijunka*, *hoshin kanri*, *jidoka*, JIT, *kaizen*, *kanban*, ključni indikatori učinkovitosti, *muda*, OEE, PDCA, kontinuirani tok, SMED, *poka-yoke*, analiza glavnog uzroka, šest velikih gubitaka, pametni ciljevi, standardizacija rada, taktno vrijeme, TPM, VSM i vizualna tvornica [37].** Na Slici 5. prikazan je jedan dio poduzeća s kojima „Vorne Industries“ surađuje, što daje jasan uvid u to da njihovo mišljenje o osnovnim vitkim alatima ima itekakvu vjerodostojnost.

Slika 5. *Jedan dio poduzeća s kojima Vorne Industries surađuje [38]*

Kako bi mišljenje poduzeća „Vorne Industries“ iz SAD-a bilo potkrijepljeno i znanstvenim slaganjima oko temeljnih vitkih alata, na Slici 6. prikazana je „vitka kuća“, čiji je autor Jeffrey K. Liker. Vitka kuća predstavlja najčešće vitke alate, odnosno osnovne vitke alate koje bi svako poduzeće trebalo implementirati u svoje poslovanje. Na Slici 6. vidimo da se Likerovi temeljni vitki alati i načela poklapaju s temeljnim vitkim alatima koje zagovara „Vorne Industries“ iz SAD-a.

Slika 6. *Vitka kuća prema Jeffreyju K. Likeru koja predstavlja temeljne vitke alate [37]*

* „Ringi“ sustav donošenja odluka potječe iz Japana i predstavlja sustav u kojem se o idejama i planovima raspravlja u svim odjelima te vođe odjela pišu konačno mišljenje iz svoga kuta gledišta. Takav sustav obuhvaća neslužbene sastanke koje najčešće pokreće viši menadžment, a vodi ih srednji menadžment. Time srednji menadžment dobiva priliku dokazati svoje sposobnosti i razinu znanja višem menadžmentu te je buduće provođenje odluka sporazumno i učinkovito. [39].

**„Genchi genbutsu“ je sustav rješavanja problema na način da kada problem nastane, zaposlenik fizički ode do mjesta nastanka problema i osobno vidi problem te sagleda sve važne parametre vezane uz nastali problem u suradnji s ostalim zaposlenicima.

Vitka kuća predstavlja način na koji se vitka transformacija treba odvijati. Tako temelj vitke kuće trebaju sačinjavati alati poput vizualne tvornice, standardizacije rade i *heijunke*. Upravo ovi nabrojani alati temelj su koji podupire ostale stupove kuće kako bi vitka kuća bila sagrađena. Kada je temelj kuće sagrađen, potrebno je napraviti stupove kuće te je sa Slike 6. vidljivo da Likerova kuća na lijevom stupu ima alate poput JIT-a, planiranja taktnog vremena proizvodnje, kontinuiranog toka, povlačenja procesa, SMED-a i integrirane logistike. Desni stup Likerove vitke kuće sačinjavaju alati poput *jidoke*, *andona*, cjelovite kontrole kvalitete i analize glavnog uzroka problema. Najvažniji dio vitke kuće odnosi se na kontinuirano poboljšanje koje se postiže ljudima i neprekidnom eliminacijom gubitaka, pa tako oni zauzimaju središnji položaj vitke kuće. Kada poduzeće ima temelje, stupove i središnji dio kuće, tada se gradi krov vitke kuće koji predstavlja krajnji cilj vitkog poduzeća. Krov vitkog poduzeća sagrađen je tek kada poduzeće kontinuirano istražuje najbolju kvalitetu, postiže najniže troškove, teži što kraćem vodećem vremenu te pruža sigurnost i visok moral svojim zaposlenicima. Kada poduzeće obuhvati sve segmente vitke kuće, tada možemo reći da je vitka transformacija odrađena uspješno i na odgovarajući način. U sljedećim su poglavljima opisani osnovni vitki alati kako bi se vidjela njihova moguća primjena i snaga kod eliminacije određenih gubitaka [37].

3.4.1. 5S

Većina ljudi podcjenjuje čistoću, red i sigurnost radnog prostora. No stručnjaci iz Toyote i Honde smatraju da 25 – 30% svih neispravnih proizvoda i abnormalnosti dolazi iz lošeg i prljavog radnog prostora. Upravo 5S omogućuje redovno i optimalno uređenje radnog prostora. 5S se sastoji od pet koraka koji se na japanskom zovu [40]:

1) *SEIRI* (engl. *sifting*) – sortiranje
2) *SEITON* (engl. *sorting*) – red
3) *SEISO* (engl. *sweeping*) – čišćenje
4) *SEIKETSU* (engl. *standardize*) – standardizacija
5) *SHITSUKE* (engl. *sustain*) – samodisciplina

Prvi korak 5S metode zove se *seiri* i odnosi se na sortiranje. Preciznije rečeno, u prvom koraku metode 5S potrebno je prepoznati sve stvari nepotrebne za rad te ih ukloniti iz radnog prostora. Zaposlenici trebaju prepoznati alat koji im je nužan za rad, a alat ili materijal koji se ne koristi često potrebno je odvojiti u zasebna spremišta kako radni prostor ne bi bio pretrpan nepotrebnim stvarima. Također, ako se neki alat ili materijal ne koristi te nema funkciju u budućnosti, tada taj alat ili materijal treba maknuti [41].

Drugi korak 5S metode zove se *seiton* i odnosi se na red. Drugi korak 5S metode nalaže da stvari budu sustavno posložene tako da se stvari mogu lako pronaći i koristiti. Alat ili materijal koji se često koristi treba biti smješten u blizini mjesta na kojem se koristi kako zaposlenik ne bi gubio vrijeme na pronalazak alata ili materijala koji se učestalo koristi. Isto tako, važno je da alat bude

spremljen prema onom redoslijedu kojim se i koristi te alat koji se koristi u paru, mora biti na istom mjestu. U vitkoj proizvodnji vrlo je važna ergonomija radnog mjesta pa tako često korišten alat mora biti smješten na lako dostupnom mjestu kako bi se izbjeglo saginjanje, istezanje ili pretjerano hodanje radnika. Možda najvažnija praksa ovog koraka sustavno je etiketiranje alata i materijala na način da označavanje bude razumljivo i jednostavno kako bi radnik brzo i lako skladištio alat ili materijal [41].

Treći korak 5S metode zove se *seiso* i odnosi se na čišćenje. U ovom koraku treba se fokusirati na postavljanje temelja za redovno čišćenje radnog prostora. Pritom ljudima treba naglašavati da prljavština i otpad na radnom mjestu nisu prihvatljivi [41].

Četvrti korak 5S metode zove se *seiketsu* i izrazito je zahtjevan jer je u tom koraku potrebno stvoriti pisane standardne postupke kako se ljudi ne bi vratili starim lošim navikama. Krajnji cilj pisanih standardnih postupaka uspostavljanje je dobrih navika, to jest kulture [41].

Peti korak 5S metode zove se *shitsuke* i on je najzahtjevniji od svih koraka jer se temelji na stvaranju samodiscipline među ljudima, s ciljem da se ljudi ne drže samo bitnih pisanih postupaka vezanih uz uređenje prostora, već se moraju sami naučiti prilagođavati novonastalim situacijama [41].

Ovaj vitki alat jedan je od najčešće korištenih vitkih alata, no organizacije iz Japana, SAD-a i Velike Britanije na ovaj alat gledaju potpuno drugačije. Preciznije rečeno, Japanci ovaj alat koriste kao strategiju izvrsnosti koja postupno ulazi u samog čovjeka, to jest oni ovaj alat koriste kako bi u ljude ugradili kulturološka načela. S druge strane, u SAD-u i Velikoj Britaniji je 5S samo još jedan alat koji ima svoja pravila i procedure. 5S se na zapadu smatra samo alatom za organizaciju radnog prostora i ništa više od toga [42]. Važno je napomenuti da je 5S izrazito jednostavan i ne zahtijeva velik angažman kapitala prilikom implementacije te su poboljšanja uslijed integriranja ovog alata vidljiva vrlo brzo. Kada se organizacija kreće u smjeru vitke strategije poslovanja, ovaj alat poželjno je uvesti u poslovanje što prije. Nakon što se uvede 5S, za očekivati je da je radno mjesto čišće te je sigurnost radnika i kvaliteta proizvoda veća [43].

5S je lako razumljiv alat, što je vidljivo sa Slike 7., jer su sva poboljšanja radnicima vidljiva odmah i iz prve ruke. Takav alat ne služi samo za promicanje organizacijske kulture, već je on i sredstvo komunikacije koje vodi do kontinuiranog poboljšanja. On se može implementirati u tvornicama, uredima, bolnicama, domovima, školama i drugim mjestima pa je vrlo zahvalan što se tiče područja primjene. Prilikom uvođenja i održavanja 5S alata nekoliko autora preporučuje da se stvore svojevrsni 5S timovi koji nadziru postignuta poboljšanja i po potrebi daju preporuke za daljnja djelovanja. Preispitivanje se treba raditi što je češće moguće, no takva preispitivanja trebala bi biti dokumentirana kako bi se napredak mogao promatrati s vremenskim odmakom [44].

Postoje složeni i jednostavni vitki alati prema različitim kriterijima, no 5S je jednostavan alat koji je logičan i prirodan pa je otpor pri uvođenju ovog alata mali. Ono što je potrebno naglasiti

još jednom: 5S nije vježba čišćenja radnog prostora! To je alat za promicanje nove kulture ophođenja prema radu kako u privatnom tako i u poslovnom životu. Isto tako, ovaj se alat među ljudima ne provodi silom i strahom, već je potrebno ljudima pristupiti entuzijastično i optimistično kako bi oni sami stvarali novi organizacijski identitet. Taj novi organizacijski identitet trebao bi biti satkan od discipline, proaktivnosti, timskog rada i težnje k savršenstvu.

Slika 7. *5S organizacija alata [45]*

3.4.2. *Andon*

Andon je jedan od osnovnih alata za otkrivanje grešaka kod automatiziranih procesa. Ovaj se alat temelji na signalnim lampama koje u proizvodnom pogonu jasno ukazuju na mjesto i veličinu problema na određenom radnom mjestu. Greške koje zabilježi *andon* sustav najčešće se dokumentiraju u nekom programu pa je nastale greške moguće kasnije analizirati kako bi se postigao bolji kontinuirani tok proizvodnje [46].

Andon je vitki alat koji daje informacije o abnormalnostima na određenim radnim mjestima u stvarnom vremenu, što je vidljivo sa Slike 8., no važno je istaknuti da ovaj alat ne rješava problem. Ono što ovaj vitki alat radi je[47]:

- obavještava osoblje o abnormalnostima u proizvodnji u stvarnom vremenu te daje općenite informacije o vrsti i veličini korektivne radnje koju je potrebno poduzeti
- omogućava učinkovitije praćenje ljudi i opreme
- stvara povratnu vezu između operatera i ljudi koji nadziru cjelokupnu proizvodnju.

Andon nije samo vizualni alat, već se on može postaviti na način da i zvukovno obavještava o abnormalnostima u proizvodnji. Međutim, najčešće se ovaj sustav postavlja u obliku vizualnih signala, u kojem zeleno svjetlo znači da postupak ide prema planu, žuto da operater treba pomoć, a crveno da je proizvodnja zaustavljena. Međutim, *andon* se može postaviti i s više boja koje bi ukazivale na određeno stanje u proizvodnji te se ovaj sustav najčešće postavlja s pet sljedećih boja [47]:

- CRVENA – velik problem, proizvodnja je zaustavljena
- BIJELA – kraj proizvodnje, proizvedena je zahtijevana količina
- ZELENA – rad je zaustavljen zbog nedostatka materijala ili sirovine
- PLAVA – proizveden je neispravni proizvod (škart)
- ŽUTA – zahtjev za izmjenu alata, prelazak na proizvodnju drugog proizvoda.

Slika 8. *Andon održavanje strojeva u pogonu [47]*

Andon se može kože koristiti u razne svrhe u proizvodnji, no njegova je glavna svrha da problemi budu vidljivi odmah i svima. *Andon* lampe najčešće se montiraju na strop ili stroj i važno je da se one nalaze na vidljivom mjestu.

3.4.3. Analiza uskih grla

Jedan od prvih i osnovnih koraka za povećanje proizvodnih kapaciteta uvođenje je analize uskih grla. Uska grla one su operacije koje ograničavaju ukupnu proizvodnju, odnosno to su radna mjesta ili strojevi koji imaju najdulje vrijeme obrade poluproizvoda unutar proizvodne linije koja proizvodi određeni tip proizvoda. Na prvu ruku za pretpostavti je da je takve operacije lako otkriti, ali svaki vitki praktičar zna da otkrivanje uskih grla iziskuje puno vremena, mjerenja i analize kako bi se samo otkrilo radno mjesto na kojem se događa određeno radno prigušenje [48].

Otkrivanje uskih grla procesa izrazito je složen postupak za koji je potrebno određeno iskustvo. Promatrajući samo jednu operaciju unutar proizvodne linije, nemoguće je pravilno prosuditi prigušuje li te ograničava ta operacija ukupnu proizvodnju. Vitki praktičari najčešće se koriste nekim drugim vitkim alatima kako bi otkrili usko grlo procesa. Jedan je od tih alata OEE (engl. *Overall Equipment Effectiveness*), pomoću kojeg praktičari mjere gubitke u svakoj pojedinoj operaciji. Preciznije rečeno, praktičari pomoću OEE alata na svakom stroju mjere dostupnost, učinkovitost i udio kvalitetnih proizvoda te gledaju da sve operacije imaju približno jednak OEE. Jednostavnije rečeno, ako je OEE u određenoj operaciji veći ili manji od prosjeka proizvodne linije, tada se može reći da ta operacija stvara usko grlo. Budući da je OEE vezan uz strojeve, vidljivo je da takvo otkrivanje uskih grla nije primjenjivo na operacije koje su vezane uz ljudski rad pa je analizi uskih grla teško pristupiti putem OEE alata tamo gdje se operacije oslanjaju na manualni rad operatera. Isto tako, mjerenjem OEE-a operacije se sagledavaju zasebno, što može rezultirati krivim zaključcima jer se ne sagledavaju međuodnosi između operacija [49].

Druga metoda za otkrivanje uskog grla mjerenje je procesnog vremena za određeni proizvod. Na taj se način bilježi vrijeme svih operacija te se najkraće vrijeme uzima kao referentno vrijeme proizvodnje. Ono što se time dobiva dokumentiranje je najkraćeg mogućeg procesnog vremena pa sve operacije trebaju težiti upravo tom vremenu proizvodnje. Takav pristup analizi uskih grla procesa daje cjelovitu sliku proizvodne linije za razliku od pristupa s OEE alatom. Međutim, sagledavanjem procesnog vremena određene proizvodne linije nije moguće pronaći problem. Ovakav pristup može samo potvrditi postojanje uskog grla.[49].

Novije se prakse prilikom otkrivanja uskih grla više temelje na ulasku vitkog praktičara u proizvodni pogon i otkrivanju koje se temelji na načelima koja su navedena u nastavku. Praktičari trebaju promatrati proizvodnu liniju cjelovito s naglaskom na međuodnose operacija. Preciznije rečeno, novije se metode temelje na vođama koji problem traže vlastitim očima i donose odluke odmah i brzo. Nema štoperica, snimanja, nepotrebnog bilježenja podataka jer je to sporo i nepotrebno [49].

Uz ove tri metode otkrivanja uskih grla postoji i pregršt rješenja znanstvenika koja se temelje na različitim algoritmima. Najčešće su ti algoritmi popraćeni složenim matematičkim aparatom te je nužno uključiti velik broj podataka kako bi se algoritam mogao upotrijebiti. Takva su rješenja

gotovo idealna, no u praksi velik broj poduzeća još nije zakoračio u digitalno doba. Pametne tvornice bilježe velik obujam podataka, no ti podaci ne znače ništa bez odgovarajućeg algoritma koji ih pretvara u informacije koje imaju neki značaj za donošenje odluka. Nakon što se algoritmima otkriju uska grla procesa, tada te operacije poprimaju prioritetni značaj. Tako potencijalna uska grla procesa imaju prvenstvo nad održavanjem, transportom i drugim važnim čimbenicima za besprijekorno odvijanje proizvodnje. Većina tih algoritama oslanja se na otkrivanje, a ne na predviđanje uskih grla procesa pa je vrlo teško izbjeći potencijalni problem prije same pojave u proizvodnji, što je vidljivo na Slici 9. [50].

Slika 9. *Prekid toka proizvodnje uslijed uskog grla na S3 [51]*

Općenito govoreći, metode za otkrivanje i analizu uskih grla mogu se podijeliti u dvije sljedeće kategorije [52]:

- ANALITIČKE – temelje se na statističkoj distribuciji podataka te su pogodne za dugoročne predikcije. U realnoj proizvodnji ovakvi su modeli teško primjenjivi jer se odluke moraju donositi vrlo brzo.
- SIMULACIJSKE – temelje se na stvaranju procesa u nekom od softverskih paketa, gdje je moguće predvidjeti uska grla s velikom točnošću. Takvi napredni softveri omogućuju predviđanje niza varijabli kao što su zastoji, čekanja, kvarovi itd. Ovakav se pristup češće koristi jer su problemi vidljivi prije kretanja u proizvodnju pa je moguće naći rješenje prije pojave problema.

Većina simulacijskih metoda povezuje se s autoindustrijom jer su takvi modeli odlučivanja najprisutniji u toj industriji. Tako General Motors (GM) za analizu uskih grla koristi softver C-MORE, dok Toyota koristi GARPOS Analyzer [52].

Neke od zvučnijih metoda za analizu uskih grla procesa su [52]:

- metoda aktivnog perioda (engl. *Active Period Method*)
- metoda preokreta (engl. *Turning Point Method*)

- metoda bazirana na strjelicama (engl. *Arrow-based method*)
- metoda kritičnih indikatora (engl. *Critically indicators based method*).

Analiza uskih grla alat je koji se može primijeniti na gotove sve industrije pa on nije limitiran samo na operacije unutar prerađivačke industrije. Tako je ovaj alat izuzetno zanimljiv u projektnom menadžmentu jer je vrijeme odvijanja projekta jedan od ključnih, ako ne i ključni parametar kod uspješnosti projekta. Ovim pristupom traže se operacije koje koče početak ili daljnje odvijanje procesa, no isto tako traže se procesi koji neprimjereno dugo traju i koje treba prioritetno smanjiti. Tako je istraživanje provedeno u građevinskom sektoru u Norveškoj rezultiralo zaključkom da su rukovođenje i koordiniranje te donošenje odluka najčešći uzroci usporavanja ili stajanja projekta. Ono što iz toga proizlazi to je da se u građevinarstvu organizacija mora usredotočiti na te dvije stavke kako bi projekt bio izveden u roku ili čak i prije [53]. To je samo jedan od primjera primjene analize uskih grla procesa. Naveden je iz razloga da se vidi kako je ovaj alat primjenjiv kako na mikro tako i na makrorazini te da nije usko vezan i da ga ne treba poistovjećivati samo s industrijom koja proizvodi fizički vidljive proizvode.

3.4.4. Kontinuirani tok

Uspostavljanje kontinuiranog toka u proizvodnji usluga i dobara vrlo je zahtjevan projekt koji iziskuje mnogo vremena, strpljenja, razumijevanja i znanja. Taiichi Ohno tvrdio je da ako se proizvod giba kontinuirano, s minimalnim stajanjima između operacija te sa što kraćim putem prevaljenim između operacija, tada će om biti napravljen učinkovito. Kontinuiranim tokom povećava se proizvodni kapacitet, ali se i smanjuje cijena serija te se otvara mogućnost za povećanjem kvalitete. Kontinuirani tok naziva se još i komadna proizvodnja (engl. *One-Piece Flow*) [16c].

Slika 10. *Linijska proizvodnja [54]*

Kod komadnog sustava proizvodnje strojevi se unutar radne ćelije slažu linijski prema redoslijedu izvođenja operacija. Najčešće se strojevi slažu na način prikazan na Slikama 10, 11 i 12. te se materijal nikada ne vraća na prethodnu operaciju. Implementacijom ovog vitkog alata postiže se:

- veća fleksibilnost
- problemi postaju vidljivi
- smanjuju se zalihe
- povećava se udio kvalitetnih proizvoda
- povećava se produktivnost
- oslobađa se radni prostor pogona
- jača se vitka kultura i moral.

Slika 11. *U-linijski raspored strojeva [55]*

Slika 12. *Funkcionalnost U-linijskog sustava [56]*

Najvažnija značajka kontinuiranog toka je da se svaki proizvod radi jedan po jedan, od početka do kraja bez prekida, a početak proizvodnje definiran je zahtjevom kupca. Stoga, ako neki stroj u proizvodnoj liniji stane, kontinuirani tok će se prekinuti. Mnogi znanstvenici bavili su se ovom tematikom pa je vitkim praktičarima dostupan velik broj algoritama i matematičkih modela za upravljanje proizvodnjom pomoću kontinuiranog toka [57].

Većina poduzeća radi prema načelu „guranja“ proizvodnje (engl. *Push systems*) jer takva organizacija proizvodnje iziskuje manji napor od modela „povlačenja“ proizvodnje (engl. *Pull systems*). Kod „push“ sustava proizvodi se što većom brzinom te je cilj omogućiti da nizvodne operacije ne stanu s radom. Ovakav se sustav temelji na predviđanju potreba kupaca, a cilj gomilanja proizvoda na skladištu je da poduzeće uvijek ima sve raznolike proizvode spremne za isporuku. Takav sustav može rezultirati visokim troškovima skladištenja proizvoda, lošim obrtajem kapitala, zastarijevanjem zaliha, lošom razinom usluge i, konačno, gubitkom profita. Kod „pull“ sustava proizvodnje zalihe su minimalne, razina usluge je veća i troškovi su bitno manji, što rezultira povećanjem profita. Stoga je stvaranje kontinuiranog toka na zahtjev kupca bitno za poboljšanje i racionalizaciju poslovanja [58].

Implementacija kontinuiranog toka trebala bi se odvijati na sljedeći način [59]:

1) Odabrati proizvod ili skupinu proizvoda.
2) Definirati vrstu ćelije u kojoj će se obrađivati proizvod ili skupina proizvoda (općenito govoreći, ćelije se mogu odnositi isključivo na jedan proizvod ili na različite proizvode).
3) Ako postoji velika potražnja kupca za jednim proizvodom, tada se stvara proizvodna ćelija koja proizvodi isključivo taj jedan proizvod.
4) Ako se vitki praktičar odluči na stvaranje ćelije u kojoj će biti obrađivani različiti proizvodi, tada treba paziti da se izmjene alata vrše standardizirano, brzo i u vremenskom roku koji ne bi trebao prelaziti taktno vrijeme operacije.
5) Potrebno je izračunati taktno vrijeme za izradu određene serije (taktno vrijeme je mjera potrebe kupaca izražena kroz vremensku jedinicu).
6) Potrebno je definirati radne operacije i vrijeme za izradu jednog komada (vitki praktičar treba nekoliko puta mjeriti vrijeme odvijanja svake operacije te je nužno zabilježiti najkraće radno vrijeme svake operacije).
7) Nakon toga treba vidjeti mogu li strojevi, oprema i alat izvršiti rad unutar taktnog vremena (vitki praktičar u to mora uračunati izmjenu alata, montažu, demontažu, zastoje itd.).
8) Potrebno je stvoriti vitki raspored strojeva i radnih mjesta (otvara se mogućnost za primjenu 5S alata).
9) Potrebno je paziti da transport, kretanje radnika i akumuliranje poluproizvoda između operacija bude najmanje moguće.
10) U-linijski raspored strojeva i radnih mjesta često je najbolje rješenje!
11) Potrebno je uravnotežiti proizvodni tok: svaka operacija mora imati jednako vrijeme obrade!

12) Izračunati koliko je operatera potrebno za ovu ćeliju i jasno definirati zadatke svakog operatera.
13) Potrebno je dodijeliti radniku jednu ili više operacija koje će izvoditi unutar ćelije.

3.4.5. *Gemba*

Gemba je jedan od ključnih vitkih alata unutar TPS-a, odnosno vitke proizvodnje. Taiichi Ohno, utemeljitelj TPS-a, rekao je sljedeće [60]:

„Ljudi koji ne razumiju brojke su beskorisni. *Gemba* gdje brojke nisu vidljive isto je loša. Međutim, ljudi koji gledaju samo brojke najgori su od svega.“

Ono što je Taiichi Ohno time želio reći je to da vođe trebaju biti vojnici na prvoj crti kontinuiranog poboljšanja. Oni moraju osjetiti proizvodnju svojim rukama i vidjeti procese svojim očima. Vođa ne smije biti otuđen od proizvodnje i radnika, on mora stvarati prilike za kontinuirani napredak. Svaka *gemba* mora rezultirati barem jednom idejom za poboljšanje. Gubitak se ne može smanjiti ili eliminirati ako on nije određen.

Gemba u prijevodu s japanskog znači „mjesto gdje se odvijaju aktivnosti“, preciznije rečeno to je mjesto gdje se stvara dodana vrijednost. Taiichi Ohno vjerovao je da se isključivo na takvim mjestima mogu sniziti troškovi proizvodnje te *gemba* u sprezi s *kaizenom* tvori jedan vrlo moćan alat za uklanjanje gubitaka. „Guranje“ tehničkog kadra u proizvodni pogon izvrsna je prilika za svako poduzeće da se stvori plodno tlo za poboljšanja. U mnogim studijama provedenima u Meksiku i Južnoj Americi dokazano je da *gemba* u sprezi s *kaizenom* povećava učinkovitost organizacije, kvalitetu proizvoda te smanjuje sirovine i WIP [61].

Gemba se ukratko svodi na odlazak do mjesta gdje se odvija aktivnost. *Gemba* vođe trebali bi se voditi sljedećim pravilima [62]:

1) Odrediti smjer i ciljeve.
2) Naučiti učinkovito primjećivati probleme, abnormalnosti i gubitke.
3) Educirati i trenirati suradnike kako bi sami bili učinkoviti i osnaživati ih da sami rješavaju probleme.
4) Biti uporan u ostvarenju svojih ciljeva te dobro uravnotežiti mogućnosti i realnost.
5) Uspostaviti metriku za evaluaciju napretka.

Gemba je moćan alat u kojem su brojke i metrika vrlo važne, no za mnoge probleme metrika nije moguća. Jedan od sjajnih primjera u kojem metrika nije bila moguća kako bi se otkrio gubitak, dolazi iz poduzeća koje spada u *Fortune 30*. Naime, tijekom šetnje u tom poduzeću primijećeno je da jedna operacija kasni za taktnim vremenom proizvodnje. Kada su pitali operatera u čemu je problem, on je rekao da ne stigne napraviti taj posao prema standardiziranoj proceduri. Njegov posao bio je da montira čahuru na određeni strojni dio, ali svaku čahuru bilo je potrebno prethodno izbrusiti kako bi se mogla montirati na taj strojni dio. Nikome nije bilo jasno zašto se

ta čahura ne može montirati izravno na strojni dio bez brušenja. Ono što je uslijedilo bilo je zapanjujuće. Ljudi koji su provodili *gembu* zatražili su da se preispitaju dimenzije čahure i došlo se do zaključka da je čahura predimenzionirana te da dimenzije mogu biti manje. I tu bi priči bio kraj da se naknadno još nije saznalo da se tako radilo 40 godina! Bolje rečeno, operater je 40 godina kasnio za taktnim vremenom radi krive tehničke dokumentacije čahure [62].

Važan segment *gembe* stvaranje je kulture otvorenog mišljenja. Nitko se ne smije sramiti izložiti problem i rješenje. Radnici koji rade u pogonu najbolje znaju svoje operacije pa, u skladu s time, najbolje vide probleme i prilike za poboljšanje. Njihovo je mišljenje vrlo važno i treba ih poticati da se ne srame izraziti ga, čak i ako je loše [62].

Iznošenje i otkrivanje problema vrlo je bitan segment *gembe* , no ne treba zanemariti i rješavanje problema. Tako je potrebno educirati i trenirati zaposlenike na način da svoje probleme rješavaju aktivno. Preporučljivo je tijekom šetnje postaviti sljedeća pitanja[62]:

- Što radite kada vidite problem?
- Koje protumjere primjenjujete za rješavanje problema?
- Koje ćete nove protumjere uvesti?
- Koliko dugo ćete testirati rješenje i koji kriterij će vam biti važan za odluku o uspješnosti rješenja?
- Jesu li neki drugi čimbenici, kao što su održavanje, kvaliteta, sigurnost, inženjering, važni za rješavanje tog problema?

Sva bi ta pitanja u konačnici trebala rezultirati boljom organizacijom i komunikacijom. Vođe trebaju jasno pokazati smjer promjena i aktivno poticati zaposlenike na promjene, no one trebaju doći od zaposlenika jer oni najbolje znaju mane i prednosti pogona ili radnog okvira [62]. Dobar primjer primjene *gembe* vidljiv je na Slici 13.

Slika 13. *Pitanja koja se postavljaju tijekom gembe [63]*

3.4.6. *Heijunka*

Heijunka ili niveliranje proizvodnje (engl. *level scheduling*) alat je koji je nastao prije pedeset godina u Toyoti. Ovaj alat ima vrlo važnu ulogu kod vitke proizvodnje te se vrlo često koristi u automobilskoj, prehrambenoj i procesnoj industriji. *Heijunka* je metoda kojom se definira redoslijed proizvodnje različitih proizvoda u mješovitoj proizvodnji. Tom se metodom nivelira proizvodnja na način da se osnažuje učinkovitost i fleksibilnost, uklanjajući gubitke i minimizirajući razlike u radnim opterećenjima. Uvođenje ovog alata omogućuje [64]:

- kontinuirani tok kroz cijeli opskrbni lanac
- eliminaciju vršnog opterećenja proizvodnje
- smanjenje zaliha
- izbjegavanje preopterećenja
- povećanje proizvodnog kapaciteta
- povećanje učinkovitosti
- povećanje konkurentnosti.

Implementacija ovog alata vrlo je zahtjevna, no može se opisati u sljedećim crtama [65]:

1) Kako bi se uvela *heijunka*, mora postojati plan proizvodnje. Plan proizvodnje mora se napraviti u koordinaciji s prodajom, proizvodnjom i marketingom.
2) Proizvodni kontinuirani tok trebao bi biti popraćen *kanban* karticama.
3) Potrebno je usredotočiti se na male serije i skraćenje vremena potrebnog za izmjenu alata (SMED).
4) Proizvodnja specijaliziranih i visokovrijednih proizvoda treba biti popraćena velikom pažnjom koristeći se *kanban* logikom.
5) Prodaja i marketing moraju biti u kontaktu s proizvodnjom, a bilo kakvu značajniju fluktuaciju u potražnji odmah prijaviti proizvodnji.
6) Jednom kada se *kanban* implementira u proizvodnju, on se mora redovito ažurirati kako bi se podudarao sa zahtjevima prodaje i programima kontinuiranog poboljšanja.
7) U konačnici bi se trebalo fokusirati na smanjenje *kanban* kartica jer one prema vitkim načelima predstavljaju gubitak.

Heijunka je alat kojim se proizvodnja „gura“ u što vitkiji okvir. Preciznije rečeno, organizacija se fokusira na eliminaciju gubitaka. Fokusirajući se tako na gubitke, najčešće se smanji odziv sustava na potražnju. Tako je izuzetno bitno ne ići u krajnost s *heijunkom* te ovaj alat kombinirati s JIT-om kako bi odziv na zahtjev kupca ostao zadovoljavajući [66]. Zahtjevi kupaca mogu dugoročno dolaziti i to je dobar preduvjet za predviđanje tržišnih potreba, no problem je varijabilnost zahtjeva u malom vremenskom roku. Uvođenjem *heijunke* organizacija nastoji varijabilnost zahtjeva kupaca pretvoriti u kratkoročni plan vitke proizvodnje (vidi Sliku 14.). Takav plan treba se stalno ažurirati kako bi precizno predstavljao tržišne potrebe te kako ne bi bilo preopterećenja u pojedinim vremenskim razdobljima (vidi Sliku 15.). Eliminacijom preopterećenja u proizvodnji eliminira se mogućnost nedostatka materijala ili sirovine jer se kod preopterećenja materijal troši izvan redovnog plana [67].

Slika 14. *Prikaz niveliranja proizvodnje kako bi se postigla stabilnost sustava [68]*

Slika 15. *Heijunka ploča koja sadrži sve važne informacije o proizvodnji za svaki dan [69]*

Heijunka je alat koji je posljednjih godina vrlo popularan jer niveliranje proizvodnje značajno pridonosi procesu optimizacije proizvodnje. Kod ovog alata postoje dva pristupa niveliranju. Prvi je pristup niveliranje potražnje, što je zadaća marketinga i prodaje, a drugi je pristup niveliranje proizvodnje. Upravo je niveliranje potražnje vrlo zanimljivo za današnje globalno tržište jer marketing i prodaja svojim aktivnostima mogu prema potrebi smanjiti ili povećati zahtjev tržišta. Ono što treba istaknuti kod *heijunke* je sljedeće. Prije uvođenja *heijunke* poželjno je da organizacija ima već implementirane alate poput [70]:

- taktnog vremena
- *kanbana* i
- SMED-a.

Isto tako, kod uvođenja *heijunke* važno je definirati temeljno razdoblje koji se naziva EPEI (engl. *Every Part Every Period*), što znači da se u svakom temeljnom razdoblju moraju proizvoditi sve inačice proizvoda [70].

Kod ovog se alata plan proizvodnje najčešće predstavlja i definira kroz *heijunka* ploču (vidi Sliku 15). Ta ploča sadrži informacije o obujmu proizvodnje i varijaciji proizvoda koji će se proizvoditi. Najčešće se izvodi na dnevnoj bazi, u kojoj je svaki sat proizvodnje definiran. Preciznije rečeno, za svaki je sat definiran obujam proizvodnje i varijacija proizvoda koja će biti nivelirana. Pritom je vrlo važno odrediti redoslijed proizvodnje različitih proizvoda jer je često prisutan problem različitih vremena izmjene alata za različite proizvode [71].

3.4.7. *Hoshin kanri*

Hoshin kanri je nastao u Japanu kasnih 60-ih godina prošlog stoljeća. Ovim alatom poduzeće stvara politiku, upravljanje i smjer budućeg poslovanja. *Hoshin kanri* je težnja da menadžment ispuni svoju osnovnu svrhu, a to je stvaranje sustava za osnaživanje cijele organizacije i usklađenje organizacijskih sposobnosti kroz stvaranje jedinstvenog plana i politike razvoja koja se svake godine revidira. Pritom ciljevi moraju biti jasni i mjerljivi. Iz navedenog se vidi da je ovaj alat srce i duša vitke proizvodnje pa se uvođenje treba pažljivo provoditi jer su posljedice „politike razvoja“ nekada pogubne [72]. Treba se samo sjetiti Kodaka i Nokije koji su bili tržišni lideri, ali su uslijed krivih odluka u politici razvoja otišli u ropotarnicu povijesti.

Hoshin kanri u prijevodu s japanskog sastoji se od četiriju elemenata [73]:

HO – znači SMJER

SHIN – znači FOKUS

KAN – znači USKLAĐENJE

RI – znači RAZUMNOST.

Mnoga poduzeća koja ne koriste *hoshin kanri* ili neku drugu sličnu metodu te nemaju definirane mjerljive ciljeve očekuju od rukovodećeg kadra da zna ciljeve poduzeća. No to je pogrešno jer ljudi imaju različita mišljenja i mogu različito percipirati organizacijske ciljeve. Ako ciljevi nisu mjerljivi, koncizni i provedivi, rukovodeći kadar neće se moći kretati u smjeru želja vlasnika ili dioničara, što je vidljivo na Slici 16. Većina poduzeća njeguje kulturu u kojoj se vođe obraćaju zaposlenicima samo kada nešto ode u potpuno krivom smjeru, a kada sve ide po planu, komunikacija i sustav nagrađivanja ne postoje [73].

Slika 16. *Hoshin kanri ciljevi [74]*

Hoshin kanri je, jednostavnije rečeno, politika razvoja koja se sastoji od ciljeva menadžmenta koji se prate i ostvaruju pomoću PDCA logike. Takvim se pristupom razvoja poduzeća koriste gotova sve multinacionalne organizacije u Japanu, dok zapadna poduzeća koriste *hoshin* planiranje. Neki od najpoznatijih *hoshin* sustava planiranja su [75]:

- *Hoshin planning* – Bank of America
- *Policy deployment* – Proctor & Gamble
- *Management by policy* – Donnelly
- *Managing for results* – Xerox Corporation
- *Strategy or goal deployment* – Caradoc
- *Strategy into action* – Unilever.

Hoshin kanri se oslanja na rad gdje svi malo pridonose napretku poduzeća. Takvi planovi razvoja mogu biti usmjereni na eliminaciju konkurencije, odgovor na financijsku krizu, rast prihoda itd. *Hoshin kanri* je produžena ruka *kaizena* jer se ovakvi planovi oslanjaju na kreativne pojedince koji kontinuirano pridonose jačanju cijele organizacije. Postupna kontinuirana poboljšanja i *hoshin kanri* mogu se izraziti kroz QCDE jezik [75]:

- Q – *Quality* – ciljevi koji su bitni za kupce
- C – *Cost* – ciljevi koji su bitni za učinkovitost i financije
- D – *Delivery* – ciljevi vezani uz organizacijske procese, logistiku i inovacije
- E – *Education* – ciljevi vezani uz razvoj ljudskih resursa, moral i sigurnost.

Hoshin kanri se sastoji od četiriju bitnih faza koje su vidljive i na Slici 17 [75]:

1) Vrhovni (top) menadžment stvara godišnji plan razvoja, tzv. *hoshins*. Takve planove stvara viši menadžment i oni su usmjereni na to da se sve aktivnosti između različitih sektora i odjela odvijaju bez smetnji. Specifičnost ovog koraka stvaranje je kontrolnih mehanizama koji će jamčiti harmoniju kod ostvarenja ciljeva.
2) Druga faza uvođenja *hoshin kanrija* fokusirana je na *hoshin* i kontrolne mehanizme u pogledu njihovih operativnih ostvarenja. Kod ove se faze dodjeljuju prioriteti te se oblikuje sustav za upravljanje resursima, inicijativama i dodjeljuju se odgovornosti.
3) Treća se faza temelji na stvaranju dnevnih aktivnosti i kontrolnih mehanizama gdje se sve oslanja na PDCA analizu.
4) Četvrta je faza povratna veza višem menadžmentu. Ovaj se korak oslanja na pregled kontrolnih mehanizama od strane višeg menadžmenta te po potrebi korigiranju godišnjeg plana.

Slika 17. *Način funkcioniranja hoshin kanrija [75]*

Pri implementaciji *hoshin kanrija* organizacija se treba fokusirati na sljedeće [76]:

1) Važno je uspostaviti kulturu kontinuiranog poboljšanja i stalnog učenja.
2) Razviti menadžment usmjeren na izazovne rezultate kako bi se stvorila značajna poboljšanja.
3) Aktivno uključenje vodstva u sve dijelove organizacije kako bi se promicala mobilizacija i angažman te kako bi rukovodeće metodologije bile učinkovite.
4) Koristiti načelo *nemawashi* kod donošenja odluka. *Nemawashi* je pristup u kojem se sukobi i razmišljanja svih zaposlenika sagledavaju pojedinačno. Preciznije rečeno, ako je zakazan projektni sastanak s više različitih odjela, tada vođe prije sastanka trebaju saslušati svaki od tih odjela i riješiti sukobe prije službenog sastanka svih sudionika. Time se izbjegavaju sukobi te su ljudi skloniji iznositi svoje probleme i razmišljanja.
5) Potrebno je stvoriti sustavan pogled na organizaciju. Svaki tim treba ostvarivati svoje ciljeve, no pritom ne smije ugrožavati ciljeve drugih timova ili cijele organizacije.
6) Potrebno je osnažiti suradnike u timu da rješavaju probleme i aktivno se uključe u sve procese poboljšanja.
7) Multifunkcionalni timovi moraju znati odrediti sustavne probleme.
8) Dugoročni ciljevi moraju biti jasni ljudima na svim hijerarhijskim razinama.
9) Dugoročni ciljevi moraju biti prevedeni u srednjoročne ciljeve za iduće 2 do 5 godina. Ti ciljevi moraju biti mjerljivi i poticati zaposlenike na kreativnost.
10) Srednjoročni ciljevi moraju se prevesti u ključne godišnje ciljeve. Ti ciljevi moraju biti usmjereni na rast organizacije, ali i na poboljšanje ključnih točaka.
11) Godišnji plan mora se stvoriti za svaku organizacijsku razinu. Godišnji plan za timove mora biti smislen, uravnotežen s mogućnostima organizacije i dovoljno izazovan da se postignu poboljšanja na razini cijelog sustava.
12) Sve osobe moraju biti uključene u postupak izrade godišnjeg plana kako bi privrženost i entuzijazam bili na visokoj razini. Pritom će ključni ljudi dati najveći obol godišnjem planu, dok će ostali dati neke manje bitne smjernice.
13) Svaka politika razvoja mora biti kreirana i donesena na demokratski način uz suglasnost svih odjela. Time se postiže dogovor oko smjera kretanja pa ne postoje sukobi kod provedbe plana.
14) Ciljevi i sredstva moraju biti definirani na temelju uzročno posljedične analize.
15) Ciljevi se moraju integrirati u dnevne rutine projektnog ili procesnog menadžmenta kako bi napredak bio mjerljiv.
16) Implementacija se mora odraditi na način da svaka razina organizacije ima definirane ljude i ciljeve te način na koji će postići ciljeve.
17) Potrebno je stvoriti samodisciplinu kod timova. Ciljeve se treba nastojati ostvarivati kroz dnevnu rutinu.
18) Potrebno je sastavljati periodična izvješća o napretku kako bi vođe s timovima mogle raspravljati o učinkovitosti, problemima i poboljšanjima.

19) Ključne informacije vezane uz strateško planiranje i izvedbu moraju biti istaknute i prisutne u svim radnim prostorijama. Time ljudi shvaćaju što se od njih očekuje i što treba raditi.
20) Analiza periodičnih izvještaja mora se odrađivati u prisutnosti višeg menadžmenta. Viši menadžment time dobiva pregled situacije i može po potrebi pravovremeno reagirati.

Hoshin kanri je poveznica između filozofije poboljšanja i organizacijske strategije. Međutim, ovaj je alat poprilično zanemaren kod uvođenja vitke filozofije. Istraživanje o bitnim čimbenicima za uspješnost implementacije vitke filozofije pokazalo je da menadžeri ovaj alat uopće ne smatraju bitnim. U tom istraživanju menadžeri su trebali rangirati 30 bitnih čimbenika za uspješno uvođenje vitke filozofije i *heijunka* je bila na 28. od mogućih 30 mjesta. Kao najvažnije čimbenike naveli su aktivno vodstvo i podršku vrhovnog menadžmenta, što je paradoksalno jer je *hoshin kanri* alat kroz koji se sve to operativno ostvaruje [77].

3.4.8. *Jidoka*

Jidoka je bitan alat za poboljšanje organizacijske učinkovitosti. Uz JIT, TPM, VSM i *kaizen*, *jidoka* je naveden kao jedan od pet najbitnijih alata za poboljšanje učinkovitosti [3]. Prema Taiichiju Ohnou *jidoka* i JIT dva su glavna stupa TPS-a. *Jidoka* je alat koji se pripisuje Sakichiju Toyodi koji je 1902. godine izumio napravu za otkrivanje slomljene ili oštećene niti na tkalačkim stanovima. Taj je izum omogućio operaterima da nadziru do 12 tkalačkih stanova te se povećao obujam i kvaliteta proizvodnje. Taj se alat može poistovjetiti s riječima kao što su automatizacija ili autonomnost, no pritom treba naglasiti da se ovaj alat i dalje oslanja na ljudski um te se postupci ne prepuštaju strojevima u potpunosti. Kod *jidoke* strojevi moraju imati mogućnost otkrivanja abnormalnosti, no ljudi i dalje nadziru cijeli sustav i reagiraju na abnormalnosti (vidi Sliku 18) [78].

Slika 18. *Implementacija jidoke [79]*

Ljudi su najvažniji čimbenik vitke filozofije jer mogu razmišljati o problemima i samostalno ih rješavati. Strojevi u vitkoj filozofiji nikada ne smiju biti ispred ljudi. Oni su tu da olakšaju rad i ljudima oslobode vrijeme za druge aktivnosti koje imaju dodanu vrijednost. Postoji odlična priča iz proizvodnog pogona u Georgetownu kada je novinar ušao u Toyotin proizvodni pogon i vidio da taj pogon ima manje robota nego konkurencija. Konkretno, radilo se o liniji u kojoj su se montirala vrata automobila te je novinar primijetio da je taj posao u Toyoti prepušten ljudima, a ne robotima kao kod konkurencije. Novinar je u tome vidio klasičan gubitak te mu nije bilo jasno zašto taj posao rade ljudi. Kada je novinar pitao direktora proizvodnje zašto taj posao ne rade roboti, on mu je rekao sljedeće: „Roboti su ograničeni. Oni ne mogu razmišljati i osjećati, a kod ovog je posla to bitno. Prilikom zatvaranja vrata automobila, vrata moraju lijepo sjesti i zvuk prilikom zatvaranja mora odisati sigurnošću. Za takav posao potreban je osjećaj prilikom montaže i to je u stanju napraviti samo čovjek. Naši kupci očekuju upravo taj zvuk kod zatvaranja vrata. Stoga ovaj rad nije gubitak nego dodana vrijednost za kupca. Tu vrijednost kupac je spreman platiti!“ [16d]

Jidoka je, kao što je prethodno rečeno, važan alat, a to proizlazi iz sljedećeg [18, 80]:

- Sprječava prekomjernu proizvodnju. Strojevi se programiraju na način da prestanu proizvoditi kada proizvedu zadanu količinu određenog tipa proizvoda. Time se omogućuje JIT načelo proizvodnje.
- Olakšava se otkrivanje abnormalnosti u proizvodnji. Ljudi ne moraju promatrati procese kako bi vidjeli abnormalnosti, već to rade strojevi. Time se povećava korištenje ljudskih potencijala jer se ljudi bave isključivo poboljšanjima, ali ne i bespotrebnim nadzorom sustava.

Najbolji japanski proizvođači uvijek su izbjegavali prekomjernu automatizaciju te su pažljivo integrirali *jidoku* u nove tehnologije. Većina ljudi rekla bi da se automatizacijom postiže veća konkurentnost i niža cijena proizvoda, no prevelika automatizacija procesa može rezultirati upravo suprotnim ishodom. Krajem 80-ih godina prošlog stoljeća japanska industrija imala je slabiji udio automatiziranih procesa od zapadne konkurencije, no unatoč tome Japanci su bili daleko konkurentniji na tržištu. Zapad je naglo i brzo uveo automatizirane procese i robote, dok je Japan vrlo pažljivo i postupno uvodio nove tehnologije. Do 90-ih godina prošlog stoljeća Japanci su se i dalje držali *jidoke* te je udio automatiziranih procesa narastao za 30 %. Time su Japanci još jedanput potvrdili da se više vode postupnim promjenama, a ne naglim i ishitrenim potezima. Zapadni proizvođači fokusirali su se na konkurentnost i zadovoljstvo kupaca, dok su se Japanci još k tome fokusirali na dionike, zaposlenike, dobavljače, zajednicu i ulagače. Zapadna je filozofija bila okrenuta divljem rastu, dok je Japanska vitka filozofija bila okrenuta integraciji i održavanju ravnoteže [81].

Prethodno je napomenuto da se *jidoka* s japanskog često prevodi kao automatizacija ili autonomnost, no postoje neke jasne razlike između *jidoke* i klasične automatizacije (vidi Tablicu 15).

Tablica 15. *Razlika između automatizacije i jidoke [82]*

Kategorija	**Automatizacija**	***Jidoka***
Ljudi	Manualni procesi postaju lakši, ali pogreške, rad i korekciju ciklusa nadziru ljudi.	Ljudi mogu nadzirati više postupaka i povećava se produktivnost.
Strojevi	Strojevi proizvode sve dok čovjek ne pritisne fizički gumb na stroju za prekid ciklusa proizvodnje.	Strojevi autonomno detektiraju kraj ciklusa.
Kvaliteta	Moguća je proizvodnja velikog broja neispravnih proizvoda te postoji mogućnost samouništenja stroja uslijed abnormalne proizvodnje.	Strojevi se ne mogu samouništiti jer postoji detekcija abnormalnosti te strojevi prekidaju rad kod određenih abnormalnosti.
Dijagnosticiranje pogrešaka	Abnormalnosti se otkrivaju kasnije, a analiza uzročno-posljedične veze s pogreškama radi se kasnije i duže.	Abnormalnosti se uočavaju odmah i korektivne se mjere provode brzo.

Jidoka nije vezana samo uz proizvodne pogone te je potrebno navesti neke primjere iz svakodnevnog života:

- Kada osoba želi pristupiti svom računu na bankomatu ili internetskim bankarstvom te više od tri puta upiše pogrešnu šifru, račun će se zaključati i bit će potrebno kontaktirati pripadajuću poslovnicu banke.
- Ako osigurači zabilježe preveliki tok struje, aktivirat će se i zaštiti električne uređaje.
- Dizalo u zgradi neće se kretati ako je težina putnika veća od dozvoljene, već će se otvoriti vrata i zvukovnim signalom signalizirati da svi putnici izađu van.
- Kada dođe do curenje plina u plinovodu, senzor će to zabilježiti, a ventili će zatvoriti dotok plina.
- Kada padne tlak u kabini aviona, maske s kisikom past će sa stropa na putnika kako bi putnici stavili maske.

3.4.9. JIT

JIT je vitki alat koji se oslanja na pojednostavljivanje procesa kako bi se smanjili gubitci. Fokus ovog alata je na učinkovitom korištenju resursa i smanjenju zaliha na svim razinama, a to se postiže:

- skraćenjem pripremno-završnih vremena
- kontrolom toka materijala i
- promoviranjem preventivnog održavanja.

Uspješna implementacija JIT-a ovisi o dobroj usklađenosti plana proizvodnje s pravovremenom isporukom dobavljača, gdje dobavljači moraju nuditi visoku razinu usluge u pogledu dobre kvalitete i pouzdane isporuke proizvoda [83]. Ovaj alat utječe na mnoge organizacijske aspekte, kao što je planiranje proizvodnje, planiranje nabave, planiranje kapaciteta i planiranje distribucije. Dokazano je da uspješna implementacija JIT-a zahtijeva smanjenje proizvodnih serija i dobru suradnju s lokalnim dobavljačima. Kod JIT-a je potrebno graditi kvalitetan odnos s dobavljačima u pogledu fer cijene i obostranog zadovoljstva. Kod dobavljača se ne smije gledati samo cijena proizvoda, već i vrijeme isporuke i tu su, dakako, u prednosti lokalni proizvođači [84].

Mnoge organizacije uz JIT su napravile vrhunske rezultate, a najveće prednosti JIT-a su [85]:

1) **Smanjenje zastoja**
   Kod JIT-a strojevi moraju uvijek biti spremni za rad jer kod JIT-a nema „proizvodnje za svaki slučaj“. To znači da se strojevi moraju održavati isključivo preventivno i kada za to postoji mogućnost.
2) **Smanjenje zaliha**
   Kod JIT-a dolazi do smanjenja zaliha na svim razinama. Redukcija sirovina i materijala posljedica je malih serija i učestalih dostava. Razina zaliha najbolji je indikator uspješnosti implementacije JIT-a. Postoje primjeri gdje je JIT rezultirao smanjenjem zaliha za 97 % i uštedama do 6 milijardi dolara.
3) **Smanjenje radnog prostora**
   Budući da kod JIT-a nema skladištenja sirovina, materijala, WIP-a i gotovih proizvoda, radni se prostor može reducirati. Za očekivati je da će se radni prostor uslijed uvođenja JIT-a smanjiti za 25 % do 50 %. Dovoljno je naglasiti da su japanski proizvodni pogoni triput manji od pogona iz SAD-a.
4) **Povećanje kvalitete**
   Kod JIT-a dolazi do povećanja kvalitete proizvoda jer su pogreške vidljive odmah i fokus poduzeća je na bilo kakvim abnormalnostima koje produljuju isporuku proizvoda. Također, JIT promovira multifunkcionalne zaposlenike koji su obučeni za različite poslove. U tom slučaju, ako dođe do problema s kvalitetom proizvoda, radnik je najčešće sam sposoban otkloniti problem te se neispravan proizvod ne mora slati na neku od prethodnih operacija.
5) **Povećanje korisnog rada**
   Kod JIT-a su radnici obučeni za različite poslove i za rad na različitim strojevima. Tako, ako nema posla na određenom radnom mjestu, radnika se može preusmjeriti na druge poslove. Ovakav pristup otvara mogućnost za smanjenje radnika, a da proizvodni kapacitet ostane isti.
6) **Učinkovito korištenje strojeva i opreme**
   Koristeći se preventivnim održavanjem, multifunkcionalnim zaposlenicima, manjim i fleksibilnijim strojevima, organizacija se dovodi u stanje učinkovitijeg korištenja strojeva

i opreme. Dovoljno je spomenuti primjer kompanije General Electric, gdje je pogon u Sjevernoj Karolini radio s tri proizvodne linije u tri smjene, a nakon uvođenja JIT-a taj isti pogon radio je s dvije proizvodne linije u jednoj smjeni s istim proizvodnim kapacitetom kao i prije.

7) **Bolja prodaja zaliha**
   Smanjenje zaliha i proizvodnih serija dovodi do povećanja prodaje. Kod JIT-a ne postoje velike zalihe, ali te zalihe imaju svoje kupce i kod JIT-a su one brzo naplative.

Općenito govoreći, prilikom uvođenja JIT-a od organizacije se očekuje da proizvodi proizvode ili usluge visoke kvalitete prema ritmu proizvodnje koji kupac želi te s malim ili nikakvim gubitcima. Studija napravljena na 769 organizacija koje koriste vitku filozofiju i JIT pokazala je da se nove informacijske tehnologije, kao što je ERP, bolje i brže integriraju u poduzećima gdje je prisutan JIT i vitka kultura [86]. JIT je sadašnjost i budućnost proizvodnje i nedvojbeno je da će se digitalne tehnologije bolje integrirati unutar organizacija koje posluju prema modelu vitkog koncepta. Hrvatska poduzeća vrlo će brzo krenuti u postupak digitalizacije i nedvojbeno je da će poduzeća s integriranim vitkim konceptom bolje i brže ući u proces digitalizacije.

JIT se često poistovjećuje sa samim konceptom vitke filozofije, no ovaj alat predstavlja samo jedan dio vitkog koncepta te njegovo uvođenje podrazumijeva implementaciju mnogih drugih vitkih alata i načela. Već je ranije naglašeno da dobavljači kod JIT-a igraju veliku ulogu. Najbolje je pogledati odnose automobilske industrije sa svojim dobavljačima. Proizvođači automobila svoje dobavljače doslovno integriraju u poslovne procese. Tako se proces konstruiranja automobilskih dijelova radi na način da dobavljači daju prijedloge i korekcije, što rezultira boljim proizvodom i bržom isporukom. Dobavljači znaju svoje tehnološke prednosti i mogućnosti te mogu iznaći najbolje rješenje za svoje kupce ako im se to dopusti. Odnos automobilske industrije i dobavljača fleksibilan je i sugestivan, a ne krut i zamršen. Takvi odnosi nisu izrabljivački, gdje se traži najniža cijena, već su to odnosi gdje se dobavljač gleda kao produžena ruka vlastite organizacije. Budući da ti odnosi nisu motivirani cijenom, JIT odnos s dobavljačima svojstven je za srednje i velike organizacije koje mogu financijski potpomagati razvoj i rast svojih kooperanata [87].

Mnoga istraživanja pokazala su da JIT povećava organizacijsku učinkovitost te je ovaj alat pogodan za proizvodne i uslužne djelatnosti. Istraživanje napravljeno na 95 poduzeća u SAD-u pokazalo je da su korisnici JIT-a najčešće organizacije koje imaju ponavljajuće procese. Preciznije, od navedenih 95 organizacija, 80 % su bile organizacije s ponavljajućim procesima. Mnogo se godina smatralo se da je JIT pogodan samo za autoindustriju u kojoj se proizvodi u velikom obujmu s malim izmjenama. Tek su kasnije organizacije uvidjele da se JIT može koristiti izvan autoindustrije te izvan proizvodnih pogona. Tako je JIT postupno ušao u područja poput nabave, logistike, planiranja, skladištenja itd. Općenito govoreći, JIT povećava učinkovitost kod male i velike varijabilnosti potražnje, no odziv sustava puno sporiji je kod velike varijabilnosti potražnje [88].

Implementacija JIT-a mukotrpan je posao, a najvažnije varijable pri uvođenju JIT-a su [89]:

1) ELIMINACIJA GUBITAKA
    - *kanban*
    - smanjenje gubitaka
    - smanjenje pripremno-završnih vremena
    - stabilna proizvodnja
    - U-ćelijski raspored strojeva
    - manje proizvodne serije
    - automatizacija
    - komadna proizvodnja
    - 5S.
2) UKLJUČIVANJE ZAPOSLENIKA
    - multifunkcionalni treninzi
    - timsko donošenje odluka
    - poticanje kulture rješavanja problema
    - osnaživanje zaposlenika
    - osiguranje radnog mjesta do mirovine.
3) UKLJUČIVANJE DOBAVLJAČA
    - učestale i pouzdane isporuke
    - kvalitetni dijelovi
    - male serije
    - dobra mreža dobavljača
    - konstruktivna komunikacija s dobavljačima
    - smanjenje vodećeg vremena dostave
    - blizina dobavljača
    - osnaživanje odnosa s glavnim dobavljačem
    - dugoročni ugovori s dobavljačima
    - treninzi i edukacije dobavljača.
4) CJELOVITA KONTROLA KVALITETE
    - kontinuirano poboljšanje kvalitete
    - zaposlenici trebaju sami kontrolirati svoj rad
    - prekidi proizvodnje moraju se minimalizirati
    - preventivno održavanje
    - *jidoka* i *poka-yoke*
    - vizualna tvornica
    - smanjenje varijacija
    - statistička kontrola procesa.

Uspjeh JIT-a ovisi o mnogo prethodno navedenih varijabli, no najvažnija varijabla za uspjeh JIT-a definitivno je sustavno i uspješno uveden *kanban*. Budući da postoji velik broj varijabli o kojima ovisi uspjeh uvođenja tog vitkog alata, nema potrebe naglašavati da je to dugoročan i težak pothvat koji zahtijeva velik angažman. Ukratko, za uvođenje tog alata organizacija mora biti spremna uložiti značajna financijska sredstva i dugoročno ulagati u edukaciju i treninge koji će u konačnici rezultirati pozitivnom promjenom [89].

JIT sustav nije ništa drugo nego „povlačenje“ procesa od kupca (engl. *pull system*). Ovaj model poslovanja svoj je procvat doživio 80-ih godina prošlog stoljeća kada su proizvođači iz SAD-a shvatili da kaskaju za Japancima te je velik broj stručnjaka i praktičara otišao u Japan, gdje su snimili sve boljke svojih konkurenata. Velik broj poduzeća iz SAD-a uspješno je implementirao JIT (vidi Sliku 19), no isto tako mnoga poduzeća, unatoč naporima i dobroj volji, nisu uspjela uvesti ovaj alat [89]. Koliko je važan JIT možda najbolje opisuje citat R. R. Inmana koji je rekao sljedeće: „Zalihe su cvijet zla, a varijabilnost je korijen tog zla.“ [91]

Slika 19. *McDonald'sov JIT sustav usluge [92]*

3.4.10. *Kaizen*

Kaizen je vrlo važan element LP-a i TQM-a. Ovaj se alat oslanja na znanje i entuzijazam radnika te je cilj da zaposlenici kontinuirano rade mala, ali značajna poboljšanja te da za ta poboljšanja budu nagrađeni. Mnogi autori smatraju da uspjeh japanske industrije leži upravo u *kaizenu* koji je omogućio kontinuirano poboljšanje i usavršavanje. Postoji mnogo definicija *kaizena*, no kod svih su definicija ključna ova tri elementa [93]:

1) *Kaizen* je kontinuirani proces poboljšanja kvalitete i učinkovitosti koji nikada ne prestaje. Kod *kaizena* nema kraja, uvijek se može bolje!
2) *Kaizen* je po prirodi postupan, što ga razlikuje od ostalih poslovnih modela koji se temelje na velikim zaokretima i reorganizacijama.
3) *Kaizen* je sustav upravljanja koji podrazumijeva sudjelovanje te koji implicira uključenje znanja i razmišljanja svih zaposlenika. Dobra razmišljanja nagrađuju se i integriraju u organizaciju.

Ovaj je alat vrlo jednostavan, što je na neki način prednost, ali i mana (vidi Sliku 20). Menadžeri i radnici često koriste *kaizen*, a da sami ne znaju što to znači jer je *kaizen* načelo traženja poboljšanja toliko duboko ukorijenjenog u ljudski um da ga je nemoguće izbjeći. Svaki čovjek ima potrebu napraviti poboljšanje i dokazati svoje znanje, a to je upravo *kaizen* način razmišljanja [93].

Često postoje dvije ili više ideja unutar organizacije te svaka od tih ideja ima svoje zagovornike. U takvima situacijama postoje tenzije koje mogu biti kontraproduktivne, no *kaizen* tu može odigrati veliku ulogu jer on mijenja samu srž razmišljanja kod zaposlenika. *Kaizen* omogućava puno lakše prihvaćanje radikalnih ideja i novih tehnologija na svim razinama organizacije, što pridonosi bržoj „evoluciji“ organizacije [93]. *Kaizen* događaji najčešći su pristup kontinuiranom poboljšanju, a najvažniji elementi *kaizen* događaja su sljedeći [94]:

- Timovi moraju biti autonomni i u stanju sami provesti promjenu. Studija provedena u SAD-u pokazala je da ako se timovima ne pruži autonomnost, promjena se ili neće moći provesti ili će biti neučinkovita.
- Ciljevi moraju biti jasni i definirani kako bi timovi znali što se od njih očekuje. Ciljevi moraju biti mjerljivi i sustavno vrednovani. Studije su pokazale da jasni ciljevi pridonose boljim promjenama.
- *Kaizen* događaj ili sastanak ne smije biti prezahtjevan ili neostvariv. Timovi moraju biti u mogućnosti koristiti druge vitke alate kako bi postigli željeni cilj. Studije su pokazale da se teško ostvarivi ciljevi rijetko rješavaju kroz *kaizen* događaje.
- Članovi tima moraju biti različitih struka i funkcija kako bi pogledi na isti problem bili različiti. Heterogenost tima povećava učinkovitost *kaizen* događaja. Timovi bi trebali uključivati direktore, rukovoditelje, inženjere, ekonomiste, operatere itd. Studije su

pokazale da takvi timovi donose bolje odluke, no pojedinačno zadovoljstvo rada u takvom timu dosta je nisko jer dolazi do različitih pogleda na isti problem.

- U *kaizen* događaje moraju biti uključeni ljudi koji su izravno povezani s tim problemom te imaju iskustvo u navedenom polju. Barem jedan od članova mora imati iscrpno iskustvo u navedenom polju.
- Voditelj tima mora obučiti sve sudionike da mogu učinkovito sudjelovati u timu. To znači da voditelj tima mora poznavati literaturu i modele rješavanja problema te predstaviti i prenijeti svoja znanja drugima.
- *Kaizen* događaji moraju biti kratki i učinkoviti jer je to razlika između *kaizena* i ostalih poslovnih modela. *Kaizen* događaj traje najčešće od 2 do 7 dana, a studije su pokazale da 86 % *kaizen* događaja ne traje dulje od 5 dana.
- Timovi moraju biti mali, od 3 – 4 člana do 14 – 15 članova. Studije su pokazale da veći tim ne znači bolje ili učinkovitije rješenje. Mogli bismo reći da je bitnije tko sjedi, a ne koliko ih sjedi u timu.

Slika 20. *Kaizen sustav u 12 koraka [95]*

Ma koliko *kaizen* izgledao jednostavno na prvi pogled, menadžment mora uložiti velik napor i aktivno sudjelovati u implementaciji *kaizena* jer će u protivnom uspjeh izostati. U japanskim tvornicama menadžment proizvodnje aktivno vodi ljude na način da sam silazi u pogon i objašnjava radniku što i kako treba raditi. Time se sprječava nastajanje problema i radnici jasno znaju što se od njih očekuje. Japanci se fokusiraju na lokalne probleme koje su sami vidjeli.

Gemba može odigrati veliku ulogu u kontinuiranom poboljšanju pa je važno koristiti ovaj alat kod *kaizen* događaja. Naprosto, komunikacija koja proizlazi iz šetnji daje toliko bitnih informacija da je grijeh ne spustiti se u pogon i osjetiti probleme iz prve ruke [96].

Slika 21. *Razlika između dnevnog kaizena i kaizen događaja [97]*

Kaizen je sam po sebi vrlo zbunjuć za predstaviti ljudima, a kamoli uvesti u srž organizacije. Menadžment često u nedostatku službenih znanja *kaizen* prepušta slučaju jer ni sami ne znaju postaviti ciljeve i operativne modele za provođenje kontinuiranog poboljšanja. Takvi pristupi rezultiraju malim promjenama koje vrlo brzo dovode do vraćanja na staro stanje. Organizacija mora poznavati svoje trenutne kulturološke mogućnosti i tražiti prilike za promjene koje će biti prihvaćene. Najčešća pogreška organizacija prepuštanje je *kaizena* određenim ljudima za koje se smatra da posjeduju znanje i kapacitet provoditi kontinuirano poboljšanje. No to se kosi s glavnim načelom *kaizena* koje govori o tome da svi trebaju biti uključeni u poboljšanja. Svi trebaju biti uključeni u kontinuirano poboljšanje u kojem je primjena *kaizena* na dnevnoj razini od vitalne važnosti jer će se nakon određenog vremena *kaizen* tako sam po sebi pretvoriti u kulturološko ponašanje. *Kaizenu* se ne može pristupiti kampanjski, od projekta do projekta, već se treba pristupiti kontinuirano. Izuzetak su jedino *kaizen* događaji sa Slike 21, gdje se pristupa selektivno u pogledu članova i opsega posla [98]. Međutim, kako god poduzeće pristupilo kontinuiranom poboljšanju, postoje neki ključni čimbenici za uspjeh, a to su [99]:

- angažman i motivacija ljudi
- podrška višeg menadžmenta
- osiguranje sredstava (kapital, vrijeme, mjesto itd.)
- vodstvo
- razvoj kulture kontinuiranog napretka
- postavljanje pravih ciljeva
- primjena odgovarajućih alata i metoda
- standardizacija rada i mjerenje procesa
- organizacija timova itd.

Svi navedeni ključni čimbenici moraju se pomno uzeti u obzir prilikom implementacije *kaizena* jer velik broj organizacija ima problem s realizacijom ove filozofije [98]. Većina brzorastućih ekonomija oslanja se na inovativnost, no nemaju sve kulture isti kapacitet i prilike te je stoga *kaizen* pravi alat za ići ukorak s konkurentnim gospodarstvima. *Kaizen* se oslanja na spor, ali stabilan i kontinuiran rast, što ga dugoročno stavlja u bolji položaj od ostalih metodologija konkurentnosti. Najteži dio *kaizena* je operativno ga provesti, no G. Wittenberg je dao dobar opis *kaizen* djelovanja, a on glasi [100]:

Kaizen

- *počinje s ljudima*
- *skreće pozornost na ljudski napor*
- *ljudi se bave procesima*
- *procesi se poboljšavaju*
- *poboljšani procesi rezultiraju boljim poslovnim rezultatima*
- *poboljšani rezultati ostvaruju želje kupaca.*

Vitku filozofiju odlikuje čitav niz načela i alata, no u tom difuznom arsenalu alata *kaizen* je nešto čime se udara temelj vitke filozofije u svakom poduzeću. Poslovni koncepti većinom se oslanjaju na kapital i velike reorganizacije, a *kaizen* radi upravo suprotno jer se oslanja isključivo na učinkovito korištenje ljudskog kapitala (vidi Sliku 22). Mnogi autori smatraju da je najveći udio u Toyotinom uspjehu odigrao upravo *kaizen*, i to upravo u obliku *kaizen* događaja. *Kaizen* događaji najčešće se provode na sljedeći način [101]:

<u>Prvi dan</u>

- *Kaizen* događaj započinje tako da ljudi koji su predložili sastanak iznose probleme.
- Nakon toga slijedi kratak trening svih sudionika kako bi svi mogli aktivno sudjelovati.
- Postojeći se proces mapira.
- Proces se sustavno vrednuje ako za to postoji mogućnost.
- Krajem dana se razmjenjuju ideje na temelju viđenog stanja.

Drugi dan

- Ideje se i dalje razmjenjuju, no one dobre se stavljaju u fazu pokusa te se sagledava postoji li mogućnost za takvo nešto.
- Izrađuje se implementacijski plan, čije se usvajanje opravdava.

Treći dan

- Većina dana posvećena je integraciji timskih prijedloga i rješenja u implementacijski plan.
- U slučajevima kada rješenje zahtijeva dugu implementaciju, potrebno je razraditi implementacijski plan do krajnjeg oblika.
- Tim priprema prezentaciju rješenja višem menadžmentu.

Općenito govoreći, možemo reći da *kaizen* događaj stavlja kreativnost ispred kapitala. Naime, *kaizen* događaj sam po sebi diskvalificira bilo kakve ideje koje su vezane uz angažman ili alokaciju značajnog kapitala [101]. Niti jedan alat ne stvara tolike prilike i kulturne promjene kao *kaizen* pa je implementacija i održivost ovog alata od vitalne važnosti za svaku organizaciju koja se želi nazivati vitkom. Implementacijom *kaizena* postiže se sljedeće[102] :

- smanjuje se udio neispravnih proizvoda
- razvija se kultura dugoročnog napretka
- smanjuju se zalihe
- smanjuje se transport
- smanjuju se nepotrebni pokreti
- stvara se motivacija i entuzijazam među ljudima
- povećava se produktivnost
- brže se uvode novi proizvodi
- stvara se bolji odziv na zahtjev kupca
- smanjuju se zastoji strojeva
- isporuka proizvoda ili usluga je vremenski kraća
- ergonomija i sigurnost rada je bolja
- osnažuje se timski rad
- osnažuje se komunikacija unutar organizacije u svim smjerovima.

Slika 22. *Kaizen ploča u bolnici u Clevelandu [103]*

3.4.11. *Kanban*

Kanban je dio TPS-a koji je stvoren kako bi se kontrolirale razine zaliha i sve sastavnice koje su vezane uz proizvodne aktivnosti. Ovaj alat stavlja tok materijala u stabilan okvir te se materijal kreće u pravo vrijeme i u pravoj količini do svojeg krajnjeg odredišta. Većina ljudi povezuje *kanban* s karticama koje sadrže informacije o proizvodnoj seriji, no to nije dobar i kvalitetan pogled na *kanban*. Većina poduzeća kontrolira svoje zalihe i proizvodnju kroz popise materijala, proizvodne naloge i dinamičke planove proizvodnje, no takvi modeli komunikacije ne predstavljaju *kanban* sustav [104]. *Kanban* na japanskom znači kartica i ta kartica služi za autorizaciju proizvodnje ili transporta točno određene količine materijala u točno određeno vrijeme. To znači da kartice ne služe samo za planiranje proizvodnje, već služe kao podrška sustavu proizvodnje po načelu „povlačenja“ procesa od strane kupca. Kod *kanbana* nema gomilanja materijala, što je najčešća greška većine organizacija. Uostalom, *kanban* se sam po sebi smatra jednom vrstom gubitka i s vremenom kartice treba ukloniti ako je to moguće [105].

Glavni preduvjeti za implementaciju *kanban* sustava su sljedeći [106]:

1) *Heijunka* – plan proizvodnje mora biti uravnotežen kako bi varijabilnost proizvoda bila mala od jednog do drugog razdoblja.
2) Hijerarhijska struktura kontrole mora biti jednostavna.
3) Tok informacija mora biti jednostavan.
4) Materijal se ne smije „povlačiti“ bez *kanbana*!
5) „Povlači“ se samo onaj materijal koji je potreban za trenutnu operaciju!
6) Neispravan materijal ne smije se slati na sljedeću operaciju.
7) Proizvodi se isključivo količina koja je zadana *kanbanom*.

Glavni je cilj *kanbana* dostaviti materijal u pravo vrijeme na pravo mjesto te idućoj operaciji proslijediti informaciju o tome što i koliko treba proizvoditi. *Kanbanom* se kontroliraju radne ćelije i transport između ćelija ili radnih mjesta. Općenito govoreći, možemo reći da postoji dvije vrste *kanban* sustava, a to su [107]:

- *kanban* s jednom karticom – kontrolira se samo proizvodnja na operacijama putem proizvodnih *kanbanova*, ali ne i transport iz jedne u drugu operaciju jer ne postoje transportni *kanbanovi*.
- *kanban* s dvije kartice – kontrolira se proizvodnja i transport materijala u svim operacijama pomoću proizvodnih i transportnih *kanbanova*.

Mora se istaknuti da *kanban* nije učinkovit kod proizvodnje u pravo vrijeme ako postoji velika varijacija i mješavina proizvoda. Kod *kanbana* je važno da su proizvodi ili serije ponavljajuće kako bi takav sustav pokazao svoj puni potencijal te iznjedrio bitna poboljšanja na organizacijskoj razini [108]. Najbolji primjer *kanbana* možda je trgovina u kojoj kupac određuje kada, koliko i koju će vrstu robu povući s police. Kada kupac kupi neku vrstu robe, transportni *kanban* signalizira da je kupac „povukao“ tu robu. Tada voditelj trgovine na temelju transportnog *kanbana* odlučuje hoće li dobavljaču poslati proizvodni *kanban* koji sadrži informacije o narudžbi te iste robe kako bi se zalihe nadopunile. Takav sustav predstavlja *kanban* s dvije kartice, a njegov sustav funkcioniranja vidljiv je na Slici 23 [109].

Slika 23. *Kanban sustav na primjeru trgovine [109]*

U proizvodnom okruženju, za razliku od trgovine, *kanban* s dvije kartice izgleda nešto drugačije. Proizvodni *kanban* govori prethodnoj operaciji o vrsti i količini materijala koje treba pripremiti za sljedeću operaciju. Suprotno tome, transportni *kanban* dopušta slanje materijala na sljedeću operaciju. Kada transportni *kanban* dođe na prethodnu operaciju, proizvodni se *kanban* miče iz kontejnera s materijalom te se na kontejner stavlja transportni *kanban*. Nakon toga kontejner na kojem se nalazi transportni *kanban* putuje do sljedeće operacije. Skinuti proizvodni *kanban* se pak stavlja na *kanban* ploču za planiranje proizvodnje (vidi Sliku 25). Nakon što operater završi trenutnu operaciju, preuzima novi kontejner i obrađuje materijal u kontejneru te istovremeno skida transportni *kanban* s kontejnera i stavlja ga na transportnu *kanban* ploču [110]. I tako ponovno u krug (vidi Sliku 24)

Slika 24. *Kanban s dvije kartice na primjeru proizvodnog pogona [110]*

Kanban je jednostavan, učinkovit i jeftin način kontrole proizvodnje i zaliha. Menadžeri proizvodnje često *kanban* vežu isključivo uz proizvodnju, no to je teška zabluda jer on može regulirati protok robe izvan granica same organizacije. Preduvjeti za uspješnu implementaciju *kanbana* su sljedeći [111]:

- multifunkcionalni timovi i radne ćelije
- standardizacija rada
- odgovarajuća kontrola kvalitete
- 5S
- *jidoka*
- optimizacija rasporeda strojeva
- *kaizen*
- SMED.

Slika 25. *Kanban ploča za planiranje proizvodnje [112]*

3.4.12. Ključni indikatori učinkovitosti

Svaki vođa ili menadžment želi postići poboljšanje, nešto po čemu će se taj menadžment pamtiti. Neki samo žele ostati na pravom putu, dok neki žele napraviti svojevrsni kvantni skok i poduzeće usmjeriti u drugom smjeru. Kako god bilo, organizacija mora postaviti metriku s ključnim indikatorima koja će sustavno informirati i adresirati organizacijske pomake, stagnacije i nazadovanja. Postavljanje ključnih indikatora učinkovitosti vrlo je važan postupak za svako poduzeće jer se njima može sustavno pratiti ostvarenje željenih ciljeva.

Ključni indikatori učinkovitosti fizičke su vrijednosti koje se koriste za mjerenje, uspoređivanje i upravljanje organizacijskim performansama. Indikatori najčešće mjere sljedeće [113]:

a) Kvalitetu proizvoda i/ili usluga – pouzdanost, izdržljivost, uporabivost, estetika, kvaliteta kako ju percipira kupac, pouzdanost strojeva, udio proizvoda koji trebaju doradu nakon proizvodnje, trošak integriranog sustav kvalitete, vraćena roba, kvaliteta sirovine i ulaznog materijala…
b) Trošak proizvoda i/ili usluga – trošak proizvodnje, produktivnost rada, produktivnost strojeva, produktivnost proizvodnog pogona, izravan trošak rada, neizravan trošak rada, trošak materijala, trošak zaliha, trošak škarta, trošak dorade i popravka, trošak kvalitete, trošak konstruiranja i dizajna, trošak distribucije, trošak transporta…
c) Financije – prodaja, profit, ROE, ROA, novčani tok, koliko se dana proizvodi drže u skladištu, prodaja po skupinama i vrstama proizvoda, poslovni prihodi, plaće, broj profitabilnih kupaca, stopa rasta prodaje, prihod po zaposleniku…
d) Fleksibilnost organizacije – odziv proizvodnog pogona kod prelaska na novu varijaciju proizvoda, vremenski ciklus proizvodnje, pripremno završno vrijeme, vrijeme izmjene alata, broj dnevnih izmjena alata, postotak programibilne opreme, postotak proizvoda koji se proizvode po načelu *pull* proizvodnje, vremenski postotak zastoja…
e) Sigurnost – broj nesreća, razina ljudske kooperativnosti, razina ponašanja menadžera i radnika prema sigurnim uvjetima rada, razina rizika od nesreća, razina zaštite informacija…
f) Zadovoljstvo zaposlenika – fleksibilnost radnog vremena, postotak zaposlenih preko preporuke nekog drugog zaposlenika, učinkovitost rješavanja prigovora zaposlenika, indeks osnaživanja zaposlenika, koliko su dugo radili zaposlenici koji su napustili poduzeće…
g) Brigu o okolišu i mišljenje društvene zajednice – proizvedeni škart i neuporabljivi proizvodi, koliko je novca donirano u zajednicu, postotak lokalnog stanovništva u ukupnom broju zaposlenika, broj i veličina sponzorstava, broj godišnjih prigovora vezanih uz okoliš i zbrinjavanje otpada, broj i značaj dobivenih nagrada vezanih uz zaštitu okoliša…
h) Zadovoljstvo kupaca – broj prigovora, broj novih kupaca, preporuke kupaca, tržišni udio u pogledu kupaca, broj dostava na vrijeme, kvaliteta proizvoda, broj aktiviranih garancija na proizvod, učestalost narudžbi…
i) Učenje i rast organizacije – (postotak menadžera koji su informatički i digitalno pismeni, postotak zaposlenika koji imaju potrebne formalne kvalifikacije za svoja radna mjesta, ulaganje u edukacije i treninge zaposlenika, broj promaknuća, broj novih zaposlenika, broj dana provedenih na edukaciji ili treningu po zaposleniku, broj istraživanja koja su rezultirala značajnim poslovnim poboljšanjima…)

Organizacije su najčešće usmjerene na neke od gore navedenih indikatora, no najvažnije je da svi oni predstavljaju svojevrsne vremenske kontrolne točke. Indikatori pokazuju menadžerima i

vođama kreće li se organizacija prema zacrtanom smjeru [98]. Međutim, indikatori nisu i ne smiju se koristiti isključivo kao povratna veza. Oni se moraju koristiti za donošenje odluka. Izbor indikatora i onoga što će se mjeriti mora biti pomno odabran kako bi se na temelju tih činjenica mogle donositi kvalitetne i održive odluke [114]. Kao što je vidljivo, postoji pregršt indikatora koji se mogu pratiti, no najbolji indikatori poslovanja oni su vezani uz financije. Tako su ulagači, dioničari i vodeći ljudi uglavnom fokusirani na financijske indikatore te ih općenito možemo podijeliti u sljedeće kategorije [115]:

1) Indikatori vezani uz PROFIT
    - neto dobit
    - dobit prije rashodnih kamata i poreza (EBIT) / operativni profit
    - dobit prije rashodnih kamata, poreza i amortizacije (EBITDA)
    - bruto dobit
    - ekonomska dodana vrijednost (EVA).
2) Indikatori vezani uz PROFITABILNOST
    - povrat od uloženog ukupnog kapitala (ROI)
    - povrat na imovinu (ROA)
    - povrat na kapital (ROE)
    - povrat od prometa (ROS).
3) Indikatori vezani uz NOVČANI TOK
    - slobodni novčani tok (FCF)
    - čisti novčani tok (engl. *net cash flow*)
    - operativni novčani tok (engl. *operating cash flow*).
4) Indikatori vezani uz LIKVIDNOST
    - koeficijent tekuće likvidnosti (engl. *current ratio*)
    - koeficijent ubrzane likvidnosti (engl. *quick ratio*).
5) Indikatori vezani uz SOLVENTNOST
    - stupanj kapitalizacije (engl. *equity ratio*)
    - odnos duga i vlasničke glavnice (engl. *debt to equity ratio*).
6) Indikatori vezani uz EKONOMIČNOST
    - koeficijent obrtaja imovine (engl. *asset turnover ratio*).
7) Indikatori vezani uz TRŽIŠTE KAPITALA
    - dividendni prinos (engl. *dividend yield*)
    - omjer trenutačne tržišne cijene i zarade po dionici (P/E).

Slika 26. *Ploča s ključnim indikatorima učinkovitosti [116]*

Financijski indikatori učinkovitosti izuzetno su važni za svako poduzeće, ali je vitka proizvodnja nastala u proizvodnim sustavima pa se prilikom implementacije i održavanja više prate indikatori koji su vezani uz temeljne proizvodne aktivnosti kao što su produktivnost, kvaliteta, zalihe, isporuka na vrijeme i tako dalje (vidi Sliku 26). Međutim, za proizvodni sustav ključni indikatori dijele se najčešće u tri kategorije, a to su kvaliteta, produktivnost i održavanje (vidi Sliku 27) [117].

Slika 27. *Kategorizacija ključnih indikatora učinkovitosti u proizvodnji [117]*

Postoji pregršt indikatora koji se mogu mjeriti i analizirati u proizvodnji. Tako se može mjeriti obujam proizvodnje u jedinici vremena, dostupnost strojeva, broj i vrijeme prekida strojeva, udio kvalitetnih proizvoda, učinkovitost rada itd. Svi su ti indikatori dobri i mogu pomoći kod donošenja odluka. Međutim, izuzetno je važno da organizacija prati odgovarajuće ključne indikatore učinkovitosti. Svako poduzeće ima različite ciljeve te prema tome mora pratiti i različite ključne indikatore. Tako, ako poduzeće želi povećati udio kvalitetnih proizvoda, mora pratiti indikatore kao što su udio škarta, udio vraćene robe od strane kupca, kvaliteta sirovine itd. Ključni indikatori učinkovitosti ne mogu i ne smiju biti nasumično i bezglavo izabrani. Oni moraju služiti ispunjenju zacrtanih ciljeva jer će se u protivnom ljudi iscrpiti mjereći nepotrebne podatke koje nitko ne treba i koji ništa ne pokazuju. S druge strane, ciljevi poduzeća moraju biti kristalno jasni i pomno odabrani kako bi se kreirao pravi set ključnih indikatora. Postoje prijedlozi nekih autora da se prije uvođenja ključnih indikatora učinkovitosti uvede vitki alat pametni ciljevi, a taj alat kaže da ciljevi moraju biti [117,118]:

- konkretni (engl. *Specific*)
- mjerljivi (engl. *Measurable*)
- dostižni (engl. *Attainable and aggressive*)
- relevantni (engl. *Realistic and result-oriented*)
- vremenski definirani (engl. *Time-sensitive*).

Tek kada poduzeće ima prave ciljeve, tada se mogu izabrati indikatori koji će se pratiti. Općenito govoreći, svi su indikatori dobri, no nekada određeni indikatori imaju prioritet i veći je fokus na njima jer poduzeće kroz njih želi ostvariti svoj krajnji cilj.

3.4.13. *Muda*

Muda na japanskom znači gubitak i cijela vitka proizvodnja može stati u tu jednu riječ. Cijeli vitki koncept može se definirati kao neprekidna eliminacija gubitka i upravo ta fokusiranost na gubitke rezultirala je da vitka proizvodnja aksiomatski postane najbolji poslovni model na slobodnom tržištu [119]. Većina organizacija ima 70 % do 90 % gubitka u svojim dostupnim radnim kapacitetima te se od toga 30 % gubitaka nalazi u operativnim procesima. Kada govorimo o gubitcima, Taiichi Ohno kategorizirao je gubitke u sljedeće kategorije [120]:

1) Prekomjerna proizvodnja
   Proizvodnja prije potražnje. Japanci ovo nazivaju „ubojica“.
2) Nepotrebne zalihe
   Svi dijelovi, poluproizvodi i proizvodi koji se ne obrađuju. Japanci ovo nazivaju „serijski ubojica“.
3) Čekanje
   Proizvodnja u kojoj se prekida kontinuirani tok.
4) Prekomjerna obrada
   Izvođenje radnji i aktivnosti koje nemaju dodanu vrijednost iz perspektive kupca.
5) Škart
   Sav rad koji se povezuje s prepoznavanjem i korekcijom abnormalnosti na proizvodu ili usluzi. Ovaj gubitak rezultira time da se proizvod ili usluga ne može prodati ili plasirati na tržište.
6) Prekomjeran transport
   Kretanje materijala ili informacija koje ne služi za izvođenje procesa.
7) Nepotrebni pokreti
   Kretanje ljudi ili materijala koje nije nužno za izvođenje operacije.

Uz sedam gubitaka Taiichija Ohnoa, mnogi su autori prepoznali i osmu kategoriju gubitka, a to je nedovoljna iskorištenost potencijala zaposlenika [121, 122]. Također postoji i deveta kategorija gubitaka, a to je pretjerano korištenje prirodnih resursa kao što je neracionalno korištenje energenata [123]. Sve te kategorije gubitaka usko su fokusirane na prepoznavanje gubitaka u proizvodnom okruženju pa su vitki praktičari napravili i kategorije gubitaka specifičnih za uslužne djelatnosti. Tako se, kada govorimo o uslužnim djelatnostima, gubitci mogu podijeliti na sljedeće kategorije [124]:

1) kašnjenja i odgode
2) dupliciranje
3) nepotrebna kretanja
4) nejasna komunikacija
5) krive zalihe
6) izgubljene prilike
7) pogreške.

Eliminacija gubitaka je kamen temeljac za uspostavu JIT sustava, jednostavnije rečeno, organizacija se mora fokusirati na smanjenje gubitaka ako želi doći u stanje proizvodnje u pravo vrijeme. Gubitci se ne smiju sagledavati pojedinačno jer je svaka kategorija gubitka u određenom odnosu s nekom drugom kategorijom gubitka kao što je vidljivo na Slici 28. Tako se, na primjer, prekomjerna proizvodnja smatra najopasnijom kategorijom gubitka jer jako utječe na ostale kategorije gubitaka. Evo kako određene kategorije gubitka utječu na druge kategorije gubitaka [125]:

Slika 28. *Odnosi između različitih kategorija gubitaka [125]*

PREKOMJERNA PROIZVODNJA

- Prekomjerna proizvodnja → nepotrebne zalihe
  Kod povećanja proizvodnje povećava se potreba za sirovinom pa je skladište pretrpano nepotrebnim materijalom. Isto tako, povećava se WIP pa je pogon zakrčen nepotrebnim poluproizvodima koji čekaju obradu.
- Prekomjerna proizvodnja → škart
  Kada radnici rade velike serije, njihova usredotočenost na kvalitetu je niska te se događa povećanje udjela nedovoljno kvalitetnih proizvoda.
- Prekomjerna proizvodnja → nepotrebni pokreti
  Prekomjerna proizvodnja dovodi do nepoštivanja standardnih procedura rada te se rade pokreti koji nisu predviđeni.
- Prekomjerna proizvodnja → prekomjeran transport
  Povećanjem proizvodnje tok materijala se ubrzava te dolazi do rasta nepotrebnog transporta.

NEPOTREBNE ZALIHE

- Nepotrebne zalihe → prekomjerna proizvodnja
  Povećanje materijala na skladištu može dovesti do toga da radnici nepotrebno ubrzaju rad i povećaju proizvodnju.
- Nepotrebne zalihe → škart
  Povećanje sirovine, WIP-a i gotovih proizvoda na skladištu može dovesti do neprikladnog i neodgovarajućeg skladištenja robe, što može rezultirati neuporabljivom robom.
- Nepotrebne zalihe → nepotrebni pokreti
  Povećanje robe na skladištu rezultira povećanim traženjem, biranjem, posezanjem i rukovanjem robom.
- Nepotrebne zalihe → prekomjeran transport
  Puno robe na skladištu zakrčit će prolaze u skladištu pa će se transport robe sa skladišta do radnog mjesta vremenski oduljiti.

ŠKART

- Škart → prekomjerna proizvodnja
  Kada dođe do povećanja neispravnih proizvoda, nastat će i potreba za povećanom proizvodnjom jer se mora proizvoditi više dijelova.
- Škart → nepotrebne zalihe
  Povećanjem udjela neispravnih proizvoda izravno se povećava udio WIP-a u pogonu jer neispravni proizvodi koji trebaju doradu nisu ništa drugo nego WIP.
- Škart → nepotrebni pokreti

Kod proizvodnje s povećanim udjelom neispravnih proizvoda raste i vrijeme traženja, biranja i kontrole proizvoda.

- Škart → prekomjeran transport
  Slanje neispravnih proizvoda na doradu rezultira nepotrebnim transportom.
- Škart → čekanje
  Dorada neispravnih proizvoda rezultira čekanjem jer se postojeći dijelovi ne mogu obrađivati dok se vrši dorada.

NEPOTREBNI POKRETI

- Nepotrebni pokreti → nepotrebne zalihe
  Nestandardizirane radne procedure dovode do povećanja WIP-a.
- Nepotrebni pokreti → škart
  Kada ne postoje standardizirane procedure rada i odgovarajući trening ljudi, dolazi do abnormalnosti.
- Nepotrebni pokreti → prekomjerna obrada
  Kada procesi nisu standardizirani, doći će do gubitaka jer se neće dostići najviši mogući tehnološki kapacitet.
- Nepotrebni pokreti → čekanje
  Kada ne postoji standardiziranost, trošit će se puno vremena na traženje, kretanje, rukovanje, sklapanje itd.

PREKOMJERAN TRANSPORT

- Prekomjeran transport → prekomjerna proizvodnja
  Povećava se proizvodnja kako bi transport robe bio jeftiniji. Kapacitet transporta popunjava se do najviše razine, no proizvodi se nepotrebno.
- Prekomjeran transport → nepotrebne zalihe
  Nedovoljan broj prijevoznih sredstava dovodi do povećanja zaliha jer materijal nepotrebno stoji na skladištu pripremljen za transport.
- Prekomjeran transport → škart
  Neodgovarajuća prijevozna sredstva mogu oštetiti dijelove i proizvode te ih učiniti neupotrebljivima.
- Prekomjeran transport → nepotrebni pokreti
  Kada se dijelovi transportiraju svugdje i često, događa se učinak duplog rukovanja robom.
- Prekomjeran transport → čekanje
  Kada transportna sredstva nisu odgovarajuća, dijelovi često čekaju transport.

PREKOMJERNA OBRADA

- Prekomjerna obrada → prekomjerna proizvodnja

Kako bi se smanjio trošak rada stroja, strojevi često rade cijelu smjenu bez zaustavljanja, što opet može rezultirati prekomjernom proizvodnjom.

- Prekomjerna obrada → nepotrebne zalihe
  Kako bi se smanjio WIP, često je dobro, ako je moguće, kombinirati dvije operacije na jednoj radnoj ćeliji.
- Prekomjerna obrada → škart
  Ako se strojevi ne održavaju na odgovarajući način, dolazi do povećanja udjela neispravnih proizvoda.
- Prekomjerna obrada → nepotrebni pokreti
  Kod uvođenja novih tehnologija i neodgovarajućeg treninga osoblja dolazi do gubitaka zbog nepotrebnih kretanja.
- Prekomjerna obrada → čekanje
  Kada se nove tehnologije koriste na neodgovarajući način, dolazi do izmjene alata, što rezultira čekanjem.

ČEKANJE

- Čekanje → prekomjerna proizvodnja
  Kada neka operacija čeka neki dio neke druge operacije, često će ta operacija krenuti dalje proizvoditi kako se ne bi stajalo, što će rezultirati prekomjernom proizvodnjom.
- Čekanje → nepotrebne zalihe
  Čekanje na kraju rezultira povećanom potražnjom, što u određenom trenutku dovodi do povećanih zaliha.
- Čekanje → škart
  Čekanje može rezultirati neispravnim proizvodom.

Eliminacija gubitaka osnovno je pitanje za svako poduzeće koje kreće na vitko putovanje te se praksa smanjenja gubitaka kad tad mora uvesti kako bi integracija vitkih alata bila bolja.

3.4.14. OEE

OEE (engl. *Overall Equipment Effectiveness*) vitki je alat koji je usmjeren na mjerenje učinkovitosti strojeva i prepoznavanje pripadajućih gubitaka te se kod implementacije TPM-a predlaže da uvođenje OEE-a bude prvi korak. OEE se računa kao [126]

$$\mathbf{OEE = dostupnost^{2} \times učinkovitost^{3} \times kvaliteta^{4}}$$

[2] Dostupnost (engl. *Availability*) je omjer između stvarnog i planiranog vremena proizvodnje.
[3] Učinkovitost (engl. *Performance*) je omjer između stvarnog i idealnog vremena proizvodnje.
[4] Kvaliteta (engl. *Quality*) je omjer proizvedenih dijelova dobre kvalitete i ukupnog broja proizvedenih dijelova.

Slika 29. *OEE sustav metrike[127]*

OEE se vrlo često koristi kao ključni indikator učinkovitosti za sustavno uspoređivanje pogona, strojeva i radnih mjesta te se pomoću njega može dobiti vrlo jasna slika o učinkovitosti poslovnih procesa (vidi Sliku 29.). Kod svakog poboljšanja procesa potrebno je izmjeriti postojeće stanje i postojeću učinkovitost. Upravo je OEE pragmatično rješenje za snimanje postojeće učinkovitosti. Jednom kada poduzeće izračuna OEE za sve strojeve i radna mjesta, tek tada može pristupiti procesima poboljšanja kako bi se upravo ta buduća poboljšanja mogla sustavno vrednovati i pratiti. OEE je dio TPM-a i ta dva alata kroz neko vrijeme mogu napraviti mnogo u pogledu povećanja produktivnosti. Neki autori zabilježili su da to povećanje produktivnosti može biti i do 30 %. Isto tako, postoje i autori koji prilično osporavaju OEE kao mjeru poslovne učinkovitosti jer je OEE usko vezan uz svaki pojedinačni stroj. OEE daje podatak o učinkovitosti stroja, ali je poprilično teško izvući neke značajnije zaključke na temelju OEE-ova svih strojeva u pogonu [128].

Općenito govoreći, OEE je naširoko korišten vitki alat koji dosljedno pokazuje je li neka pokrenuta vitka inicijativa bila uspješna ili ne. Tako, na primjer, ako uvodimo SMED, OEE će se povećati ako se naprave poboljšanja u smjeru brže i učinkovitije izmjena alata. Ako pak SMED inicijativa bude neuspješna, OEE će ostati isti i znat ćemo da SMED inicijativa nije dala nikakav doprinos boljem i učinkovitijem poslovanju [129]. OEE je dokazano najbolji način za mjerenje učinkovitosti na strojevima i opremi, ali i on ima svojih nedostataka. Svaka industrija ili, bolje rečeno, svaka organizacija prilagođava OEE svojim potrebama te tako mjere i različite podatke. Upravo zbog toga što se promatrani podaci kod OEE-a razlikuju od poduzeća do poduzeća, gotovo je nemoguće uspoređivati OEE dvaju ili više različitih poduzeća [130]. Međutim, iako se možda ne može uspoređivati OEE različitih poduzeća, postoje neke smjernice kojima bi trebala

težiti svaka organizacija. Tako je preporuka da OEE za svaku industriju ne bi trebao biti manji od 85 %, gdje [131, 132]:

- dostupnost mora biti veća od 90 %
- učinkovitost mora biti veća od 95 %
- udio kvalitetnih proizvoda treba biti veći od 99,9 %

Mnoga poduzeća ulažu u sustave za praćenje proizvodnje gdje je OEE središnji dio takvog sustava. Međutim, takvi sustavi prate velike količine podataka pa je vrlo bitno da ti podaci budu točni i dobro tumačeni. OEE ovisi o mnogo čimbenika kao što su operateri, planiranje proizvodnje, politika kontrole kvalitete itd. Svi ti čimbenici nisu izravno povezani sa strojem, ali neizravno utječu na samu učinkovitost stroja pa je pored OEE rezultata često potrebno sagledati i širu sliku kako bi se donijeli pravi zaključci [133]. Međutim, općenito prema veličini OEE indikatora možemo napraviti klasifikaciju među poduzećima [134]:

- 85 % < OEE < 100 % – vrhunska poduzeća
- 70 % < OEE < 85 % – prilično dobra poduzeća
- 55 % < OEE < 70 % – prosječna poduzeća
- 25 % < OEE < 55% – loša poduzeća
- 0% < OEE < 25% – neprihvatljivo.

OEE nije alat koji utječe samo na produktivnost, već i na održivost vitke inicijative. Bilo kakvo poboljšanje u pogledu dostupnosti, učinkovitosti i kvalitete, imat će i neizravan utjecaj na bolje očuvanje okoliša, zajednicu i, na kraju, samu ekonomičnost organizacije. Stoga OEE mora biti visok kako bi opstojnost same organizacije bila neupitna i opravdana [135]. Dovoljno je samo pogledati studiju napravljenu na uzorku od 91 tvornice automobila u kojoj se istraživala snaga 30 vitkih alata. Ono što je ustanovljeno tom studijom je da je OEE izuzetno pozitivan alat iz perspektive vitkih korisnika. Tako je OEE na ljestvici od 1 do 30 zauzeo čak drugo mjesto te ga skoro 87 % korisnika iz automobilske industrije smatra jako pozitivnim vitkim alatom (pogledati Tablicu 16). To ne znači da će OEE imati pozitivan utjecaj i u ostalim industrijama jer svaka industrija ima svoje prioritete, ali svakako svaka vitka inicijativa u određenom trenutku treba razmotriti uvođenje OEE-a kao bi napredak vitke filozofije bio vidljiv, jači i mjerljiv.

Tablica 16. *Rang vitkih alata u automobilskoj industriji [136]*

Vitki alat	Rang	Jako pozitivan utjecaj	Pozitivan utjecaj	Solidan utjecaj	Negativan utjecaj	Jako negativan utjecaj
5S	1	92,30 %	3,29 %	2,19 %	1,09 %	1,09 %
OEE	2	86,81 %	5,49 %	4,39 %	2,19 %	1,09 %
8 step problem solving method	3	89,01 %	4,39 %	3,29 %	2,19 %	1,09 %
Pareto Analysis	4	92,30 %	3,29 %	2,19 %	1,09 %	1,09 %
Elimination of waste	5	83,51 %	6,59 %	5,49 %	3,49 %	1,09 %
Kaizen	6	/	/	/	/	/
Setup time reduction	7	/	/	/	/	/
Process mapping	8	/	/	/	/	/
VSM	9	/	/	/	/	/

3.4.15. PDCA

PDCA je glavni mehanizam za promjene kod vitke filozofije. Nema te inicijative, plana ili djelovanja u vitkoj filozofiji koji se ne odvija po načelima PDCA logike (vidi Sliku 30). Bilo da su ciljevi dugoročni ili kratkoročni, sve u vitkoj filozofiji funkcionira prema PDCA načelima. Cijela Toyotina filozofija razvila se iz PDCA logike jer se Taiichi Ohno oslanjao na taj jednostavan, ali pragmatičan način kontinuiranog napretka. Toyota je svoje radnike naučila da se svako poboljšanje mora raditi prema načelima PDCA ciklusa [137]. PDCA ciklus ili Demingov ciklus sastoji se od faza [138]:

1) Planiraj (engl. *Plan*) – Isplaniraj buduće stanje.
2) Učini (engl. *Do*) – Implementiraj zamišljene promjene.
3) Provjeri (engl. *Check*) – Preispitaj uvedene promjene.
4) Djeluj (engl. *Act*) – Pretvori novo stanje u standardni proces (vidi Sliku 31).

Slika 30. *PDCA logika [139]*

Slika 31. *PDCA ciklus [140]*

Metoda PDCA nastala je u poslijeratnom Japanu te se njezinim ocem smatra W. Edwards Deming. Naime, po završetku Drugog svjetskog rata SAD je u razrušenom Japanu provodio program oživljavanja japanske industrije, tzv. TWI (engl. *Training Within Industry*), čiji je cilj bio brz i snažan opravak uništenog Japana. Početkom rata mnogi radnici otišli su u vojnu službu te se više nikad nisu vratili na svoja radna mjesta, što je rezultiralo nedostatkom kvalificirane radne snage nakon rata. Stoga je doslovno bilo potrebno podučiti nove ljude starom poslu. Program je provodila vlada generala McArthura, a obuhvatio je gotovo 1,6 milijuna japanskih radnika te se sastojao od tri J [137, 141]:

1. *Jobs instructon* – treniranje rada
2. *Job methods* – poboljšanje kvalitete
3. *Job relations* – učinkovit nadzor nad radom.

Jedna od osoba koje su podučavale Japance bio je upravo W. Edwards Deming koji je držao predavanja o statističkoj kontroli procesa. Deming je unutar te filozofije predstavio W. Shewhartov PDSA ciklus koji je isticao važnost stalne interakcije razvoja, konstruiranja, proizvodnje i prodaje kako bi se postigla dobra kvaliteta i zadovoljstvo kupaca. Japanci su taj PDSA razvili do krajnosti i prilagodili ga sustavnom rješavanju svih problema te je nastao PDCA. Toyotin TPM najveći je dokaz valjanosti PDCA u kojem je Taiichi Ohno, zahvaljujući PDCA logici, sustavno provodio *kaizen* i doveo Toyotu do perfekcionizma [137, 141, 142].

PDCA ciklus ima iterativan i rekurzivan karakter koji omogućuje da organizacija kontinuirano postiže svoje ciljeve [142]. Iako ju većina autora predstavlja kao glavni mehanizam za pokretanje *kaizena* ili kontinuiranog poboljšanja, PDCA se može koristiti za pokretanje i nekih drugih poslovnih metoda i ideja. Tako na primjer PDCA igra jednu od glavnih uloga u TQM-u, a nekoliko autora smatra da se TQM i *Six Sigma* praktički temelje na PDCA logici. Općenito možemo reći da bi, ako poduzeće želi implementirati *Six Sigmu* ili TQM, bilo dobro da je PDCA već integrirana u samu srž organizacije [143, 144].

PDCA nije samo alat kontinuiranog poboljšanja, već je dokazano da takav pristup ojačava i ubrzava trening ljudi za svoja radna mjesta. Tako je studija provedena u jednoj japanskoj firmi pokazala da PDCA ojačava komunikaciju među zaposlenicima te da naposljetku dolazi do bržeg i boljeg prijenosa znanja među zaposlenicima, što u krajnosti dovodi do vještih radnika [145]. PDCA naprosto pozitivno utječe na mnoge čimbenike i ovakva logika primjenjiva je ne samo u proizvodnim okruženjima, već i u građevinarstvu, bolnicama, edukacijskim ustanovama, projektnom menadžmentu itd. [146, 147, 148].

3.4.16. *Poka-yoke*

Poka-yoke je vitki alat koji je fokusiran na detekciju i prevenciju nastajanja grešaka. Shigeo Shingo definirao je tri vrste kontrole, a to su [149]:

1) Sukcesivna kontrola – osoba na sljedećoj operaciji daje informaciju operateru na prethodnoj operaciji ako primijeti abnormalnost na proizvodu.
2) Samokontrola – operater sam preispituje kvalitetu svog rada.
3) Kontrola izvora – operater preispituje abnormalnosti koje mogu uzrokovati neispravne proizvode.

Sve tri vrste Shingove kontrole trebale bi se raditi pomoću *poka-yoke* naprava ili procedura. *Poka-yoke* može biti izvedena u obliku *upozorenja* ili u obliku *kontrole*. *Poka-yoke* upozorenje upozorava operatera da postoji greška, dok *poka-yoke* kontrola upozorava, ali i prisiljava operatera da pogrešku otkloni. Na primjer, granični prekidači često se koriste na strojevima za pozicioniranje dijelova. Kod *poka-yoke* upozorenja granični prekidač svijetlio bi i upozoravao da dio nije dobro smješten na stroju. S druge strane, kod *poka-yoke* kontrole granični bi prekidač bio spojen izravno s napajanjem stroja te kada bi dio bio loše smješten na stroju, stroj bi se automatski isključio [149, 150].

Poka-yoke se temelji na mnogim napravama za kontrolu kao što su stezaljke, senzori pritiska, graničnici, šablone itd. Međutim, *poka-yoke* se može temeljiti na procedurama kao što su upute za sklapanje ili kontrolne liste kako bi se znao redoslijed sklapanja i broj dijelova koji se trebaju ugraditi. Prednost je *poka-yoke* nad ostalim sustavima kontrole cijena i jednostavnost [134].

Kod uslužnih djelatnosti *poka-yoke* greške mogu se podijeliti u dvije kategorije, a to su greške poslužitelja i greške kupaca (vidi Tablicu 17). Većina ljudi zna za čuvenu rečenicu: „Kupac je kralj!“ ili „Kupac je uvijek u pravu!“. No je li to doista tako? Istraživanje provedeno u uslužnim djelatnostima dovelo je do spoznaje da su kupci uzrok gotovo trećine grešaka kod pružanja usluge. Time se ne želi opravdati loša usluga, već se time želi istaknuti da svako poduzeće mora razviti model pružanja usluge u kojem kupac ne može pogrešno koristiti uslugu [149].

Poka-yoke nije nekakav apstraktan pojam s dalekog zapada. Taj je alat vrlo jednostavno provesti, a primjeri iz uslužnih djelatnosti su sljedeći [149]:

- McDonald's ima posebno sastavljen uređaj za soljenje pomfrita. Taj uređaj ne dopušta da se krumpir presoli te omogućuje da se sol podjednako rasporedi po pomfritu.
- Postavljanje prigodnog zvona na vrata prodavaonice kako bi prodavač znao da je kupac ušao. Time će kupac biti prije uslužen.
- U jednom korejskom tematskom parku novim zaposlenicima zašiveni su džepovi na službenoj odjeći. Tako zaposlenici ne mogu držati ruke u džepovima i posjetiteljima djelovati besposleno i neprofesionalno.
- Neki hoteli omataju čiste ručnike tankom papirnatom vrpcom tako da kada sobarica uđe u sobu gosta, zna koje ručnike treba zamijeniti, a koje ne.
- Naglašavanje pravila odijevanja u pozivnici sprječava da gosti dođu neodgovarajuće odjeveni.
- Programiranje bankomata da pri podizanju gotovine prvo izbaci karticu, a tek onda gotovinu. Tako se sprječava da korisnik ostavi karticu u bankomatu. Također, ako korisnik uzme karticu, ali ne i novac, bankomat za minutu povlači novac natrag kako ga netko ne bi ukrao.
- Neki vrtići stavljaju fotografiju uredne sobe na vrata. Tako djeci pokazuju kako uredna soba u vrtiću treba izgledati.
- Neke bolnice imaju posebne kutije za operacijske instrumente na kojima se vidi ako neki instrument nedostaje. Na taj se način izbjegava da neki instrument tijekom operacije ostane u pacijentu.

Tablica 17. *Klasifikacija grešaka u uslužnim djelatnostima [149]*

GREŠKE POSLUŽITELJA	GREŠKE KUPCA
Greške vezane uz zadatke kao što je, na primjer, loš i spor popravak automobila	Greške vezane uz pripremu susreta s prodavateljem
Rad koji je: • loše izveden • kupac nije tražio • izveden krivim redoslijedom • prespor.	Greške kao: • nedonošenje potrebne dokumentacije • nerazumijevanje usluge • traženje krive usluge.
Greške vezane uz lošu interakciju kao što je neprofesionalno ponašanje	Greške vezane uz susret s prodavateljem zbog nepažnje ili ravnodušnosti
Greške kao: • nepružanje zahvalnosti kupcu • nesaslušavanje kupca • neodgovarajuće ponašanje prema kupcu.	Greške kao: • zaboravljanje nekih koraka usluge • nedosljedno praćenje toka usluge • nespecificiranje očekivanja • nepridržavanje uputa.
Greške vezane uz fizičke značajke poslužitelja kao što su prljave čekaonice, nejasni računi itd.	Greške vezane uz rezultat usluge
Greške kao: • prljavi prostor • prljave radne uniforme • loše svjetlo, buka i neprikladna temperatura prostora • ispravljeni dokumenti i prezentacije.	Greške kao: • nepružanje mogućnosti kupcu da na odgovarajući način ocijeni uslugu • nemogućnost učenja na temelju mišljenja kupca.

Poka-yoke je moćan i jeftin alat koji je trenutno općeprihvaćen u industriji (vidi Sliku 32). Međutim, ovaj alat u počecima je bio izvan fokusa poslovne zajednice. Većina autora fokusirala se na statističku kontrolu procesa, dok je *poka-yoke* zajednici bio predstavljen samo kroz primjere iz realnog sektora. No unatoč tome što nije postojao implementacijski okvir, rješenja koja se temelje na *poka-yoke* filozofiji raširila su se neslućenom brzinom [151]. Mnogi su se pitali je li ovaj alat usmjeren samo na kvalitetu, no studija provedena u Yazakiju pokazala je da upravo ta fokusiranost na kvalitetu u većini slučajeva povećava profit jer nema reklamacija kupaca [152]. Nema sumnje da *poka-yoke* kao alat pripada vitkoj filozofiji, no ovaj alat može odigrati veliku ulogu u *Six Sigma* projektima [153]. *Six Sigma* je holistički pristup za postizanje savršenstva te je cilj postići proizvodnju s 3 – 4 nedostatka na milijun proizvoda. Budući da je cilj *poka-yoke* postići da udio neispravnih proizvoda bude 0 %, iz tih se podataka može lako iščitati koliko se ta dva alata međusobno nadopunjuju [154]. *Poka-yoke* nije poželjan samo kod provođenja *Six Sigme*. Neki autori tako predlažu da bilo kakva *jidoka* inicijativa treba biti temeljena na alatima kao što su *poka-yoke*, ali i *andon* [155]. Druga skupina autora pak govori kako je *poka-yoke* temelj JIT-a i TPM-a [156]. Međutim, postavlja se pitanje iz kojeg alata nastaje poka-yoke. Iz gore navedenog vidljivo je da bi se *poka-yoke* trebalo uvoditi prije ili usporedno sa *Six Sigmom*, *jidokom*, *andonom*, JIT-om i TPM-om, no što bi trebalo uvesti prije *poka-yoke*? Tako je prema nekima autorima standardizacija rada alat iz kojeg nastaje *poka-yoke*.

Inicijative standardizacije rada uključuju audite, rješavanje problema i uključivanje više ljudi u potencijalno *poka-yoke* rješenje [157].

1	**Vodilice i stezaljke koje ne dopuštaju stezanje obratka na radni stol u krivom položaju** Primjer: pozicioniranje stezaljki na radnom stolu na način da se obradak može stegnuti samo u jednom položaju.	
2	**Vizualni i zvučni sustavi za otkrivanje pogrešaka** Primjer: vizualni signali koji operateru govore koji materijal treba uzeti, kojim redoslijedom i u kojoj količini.	
3	**Uporaba kamera, krajnjih prekidača i senzora za otkrivanje abnormalnosti** Primjer: kontrola površine glave motora sa kamerom. Ako postoji puknuće, predmetni dio poslat će se na doradu u ranoj fazi .	
4	**Vizualni i numerički brojači** Primjer: obilježavanje dozvoljenih tlakova na barometrima zelenom bojom i nedozvoljenih tlakova crvenom bojom.	
5	**Vizualne upute za izvođenje pojedinih operacija** Primjer: primjena računalnih sučelja koji sustavno pokazuju operatoru kako treba odraditi svoj posao.	

Slika 32. *Najboljih pet poka-yoke metoda u proizvodnji [158]*

3.4.17. Analiza glavnog uzroka

Analiza glavnog uzroka postupak je kod kojega se pokušavaju prepoznati skrivene slabosti koje su dovele ili bi mogle dovesti do štetnih stanja ili događaja s namjerom da se nađu prilike za poboljšanja. Jednostavnije rečeno, analiza glavnog uzroka utvrđuje kako je nastao problem i što treba učiniti da se taj problem otkloni [159]. Postoji mnogo različitih alata za analizu uzroka problema, ali općenito se mogu podijeliti u sljedeće kategorije [160]:

1) Alati za razumijevanje
    - dijagram toka (engl. *flowchart*)
    - ključan incident (engl. *critical incident*)
    - pauk dijagram (engl. *spider chart*)
    - matrica učinkovitosti (engl. *performance matrix*).
2) Alati za protok ideja
    - oluja mozgova (engl. *brainstorming*)
    - metoda zapisivanja misli (engl. *brainwriting*)
    - je-nije ili biti će/neće biti matrica (engl. *is-is not matrix*)
    - tehnika nominalne grupe (engl. *nominal group technique*)
    - uspoređivanje parova (engl. *paired comparisons*).
3) Alati za prikupljanje podataka
    - ispitivanje (engl. *sampling*)
    - anketiranje (engl. *surveys*)
    - kontrolne liste (engl. *check sheet).*
4) Alati za analizu podataka
    - histogram (engl. *histogram*)
    - pareto dijagram (engl. *pareto chart*)
    - dijagram rasipanja (engl. *scatter chart*)
    - dijagram koncentracije problema (engl. *problem concentration diagram*)
    - dijagram odnosa (engl. *relations diagram*)
    - dijagram afiniteta (engl. *affinity diagram*).
5) alati za identifikaciju
    - Ishikawa dijagram (engl. *cause-and-effect chart*), vidi Sliku 33
    - matrični dijagram (engl. *matrix diagram*)
    - pet zašto (engl. *five whys*), vidi Sliku 34
    - analiza stabla pogreške (engl. *fault tree analysis*).
6) Alati za eliminaciju
    - metoda „šest šešira“ (engl. *the six thinking hats*)
    - TRIZ metoda (engl. *the theory of inventive problem solving*)
    - SIT metoda (engl. *systematic inventive thinking*).
7) Alati za implementaciju rješenja
    - dijagram stabla (engl. *tree diagram*)

- analiza sila utjecaja (engl. *force-field analysis*).

Kao što je vidljivo, postoji mnogo alata za provođenje analize glavnog uzroka pa se postavlja pitanje na koji bi se način trebalo koristiti navedene alate. Odgovor je sljedeći [160]:

- Ne smije se postati rob ili ovisnik jednog alata.
- Mora se zapamtiti da alat nije rješenje problema.
- Treba se upoznati sa što je moguće više alata.

Analiza glavnog uzroka retrospektivan je alat za pronalazak čimbenika koji utječu na stvaranje grešaka ili nepovoljnih događaja s ciljem da se naprave poboljšanja koja će spriječiti ponovno nastajanje problema. Prednost ovog alata uključenje je i osnaživanje ljudi da rješavaju probleme, čime se izbjegava „upiranje prsta“ u krivca i nastanak nepotrebnih tenzija. Kada govorimo o greškama ili problemima, možemo ih podijeliti u dvije skupine, a to su radne i latentne greške. Radne greške javljaju se u interakciji čovjeka sa složenim sustavima, dok su latentne greške vezane uz loš dizajn sustava [161].

Analiza glavnog uzroka nije samo jedan kotačić u kontinuiranom poboljšanju, već je dokazano da on ima značajan pozitivan utjecaj na poboljšanje produktivnosti i kvalitete prema načelima vitke filozofije [162]. Isto tako, analiza glavnog uzroka sastavni je dio nekih vitkih inicijativa kao što je npr. SMED. Preciznije rečeno, neki autori smatraju da analiza glavnog uzroka u sprezi s 5S-om i *poka-yokeom* doprinosi boljoj implementaciji i održivosti SMED-a [163, 164]. Provođenje analize glavnog uzroka u organizaciji je, takoreći, jednostavan proces i sastoji se od prikupljanja podataka, snimanja stanja, fotografiranja, analize i primjene raznih alata kako bi se došlo do važnih čimbenika nastanka greške. Cijeli taj postupak može se sažeti u nekoliko koraka, a to su [165]:

- snimanje i definiranje kako se promatrani rad izvodi
- utvrđivanje svih fizičkih značajki, ali i značajki vezanih uz rad ljudi, treninge i nepoštivanje propisanih procedura rada
- sustavna propitkivanja o tome kako je problem mogao nastati do najsitnijih detalja s nekim od alata
- uključenje svih važnih ljudi u sustav traženja uzroka
- potvrđivanje svih logičnih uzroka i odbacivanje svih nelogičnih uzroka problema.

Slika 33. *Primjer Ishikawa dijagrama [166]*

Slika 34. *Radni okvir metode „pet zašto“ [167]*

Analiza glavnog uzroka definitivno je dobar alat za sustavno rješavanje temeljnih uzroka problema i grešaka. Ovaj alat ne samo da utvrđuje uzroke problema već ih i sustavno klasificira u četiri kategorije iz kojih oni proizlaze. Te četiri kategorije iz kojih uzroci problema proizlaze su ljudi, strojevi, metode i materijali. Nesumnjivo, ovaj alat potiče ljude na razmišljanje i stvara bolji temelj znanja za tekuća i buduća poboljšanja [168].

3.4.18. SMED

SMED je alat koji je fokusiran na eliminaciju gubitaka prilikom izmjene alata. Neki autori smatraju da je SMED kamen temeljac svake JIT i TPM inicijative. Bolje rečeno, ako poduzeće želi imati fleksibilnu proizvodnju s malim serijama u pravo vrijeme, tada je SMED nešto što se neće moći izbjeći. SMED se temelji na vrlo jednostavnoj logici koja kaže da se prilikom izmjene alata aktivnosti mogu grupirati u:

- eksterne ili vanjske – sve radnje izmjene alata koje se odvijaju dok stroj još radi
- interne ili unutarnje – sve radnje izmjene alata koje se odvijaju dok stroj stoji.

Iz gore navedenog može se zaključiti da su interne aktivnosti izmjene alata čisti gubitak te ih treba smanjiti ili eliminirati ako je moguće. SMED je iterativan postupak smanjenja vremena izmjena alata u kojem se interne aktivnosti nastoje izbjeći na način da se pretvore u eksterne kako bi stroj što prije bio u postupku proizvodnje (vidi Sliku 35) [169].

Slika 35. *Provođenje SMED-a [170]*

SMED pristup razvio je Shigeo Shingo koji je zamislio i od svojih ljudi tražio da se svaka izmjena alata izvrši unutar deset minuta. Vrijeme prelaska, odnosno izmjena alata najčešće se

mjeri u minutama pa se iz samog imena ovog alata može iščitati da izmjena alata ne bi trebala biti duža od deset minuta [171]. Mnogi autori dokazali su učinkovitost ovog alata kod smanjenja gubitaka pa je tako jedna studija provedena u portugalskom poduzeću pokazala da SMED može smanjiti troškove do čak 2 % ukupnih prihoda od prodaje. Promatrano poduzeće primjenom SMED metode postiglo je uštedu od čak 360.000 eura [172].

Budući da je SMED fokusiran na smanjenje vremena potrebnog za izmjenu alata, potrebno je definirati što je to vrijeme izmjene alata. Tako je Euclides A. Coimbra u svoj knjizi „Total Flow Management: Achieving Excellence with Kaizen and Lean Supply Chains“ definirao vrijeme izmjene alata kao razdoblje između zadnjeg dobro proizvedenog proizvoda određene proizvodne serije do prvog proizvedenog proizvoda zadovoljavajuće kvalitete sljedeće proizvodne serije [173]. Nedvojbeno je da to vremensko razdoblje predstavlja čisti gubitak te je JIT sustav proizvodnje gotov nemoguć bez brzih i učinkovitih izmjena alata. Vitki praktičari i inženjeri to vrijeme nastoje smanjiti na sljedeće načine [174]:

1) Uklanjanjem potrebe za izmjenom alata. Ovakav pristup temelji se na redizajnu postojećih ili kupnji tehnološki naprednijih strojeva koji za izmjenu alata ne trebaju operatera. Ne treba naglašavati da ovakav pristup iziskuje značajnija financijska sredstva.
2) Optimizacijom sustava kretanja, odnosno montaže i demontaže alata. Tako neke organizacije uvode automatski vođena vozila za prijevoz alata i sredstava za montažu i demontažu alata, čime operater ne gubi vrijeme na traženje sredstava za rad i transport samog alata.
3) Pretvorbom internih aktivnosti izmjene alata u eksterne. Ovo je vjerojatno najučinkovitija metoda koja se oslanja na to da se sve aktivnosti vezane uz izmjenu alata većinom odrade dok stroj još proizvodi tekuću seriju proizvoda.
4) Boljim izborom osiguranja alata. Većina inženjera koja su se bavila tematikom izmjene alata preporučuje da se alat prilikom montaže i demontaže treba osiguravati spojnicama, stezaljkama i hvataljkama, a ne vijčanim spojevima. Osiguranje spojnicama omogućava brže izvođenje montaže, demontaže i osiguranja alata te takve spojnice često imaju višestruko bolji čimbenik sigurnosti od vijčanih spojeva. Nije naodmet napomenuti kako se kod osiguranja vijčanim spojem javljaju problemi kao što su korozija i oštećenje navoja uslijed učestalih montaža i demontaža, zatim potreba za različitim sredstvima rada prilikom pritezanja navoja i, na kraju krajeva, dugo razdoblje pritezanja.
5) Boljim sustavom podešavanja alata na stroj. Jednom kada organizacija uvede spojnice, stezaljke ili hvataljke na svoje strojeve i sredstva za osiguranje alata, javlja se drugi problem a to je precizno podešavanje alata na stroj. Tako je potrebno definirati skupine proizvoda koje se proizvode na određenim strojevima jer se pretpostavlja da će takvi alati biti vrlo slični i podešavanja prilikom izmjene alata bit će minimalna ili nikakva. Isto tako, vrlo je dobro koristiti CNC strojeve ili PLC-ove kako bi podešavanje alata bilo automatizirano na način da su svi parametri podešavanja pohranjeni u samom stroju te stroj takvo podešavanje radi autonomno.

6) Optimalnim čišćenjem alata. U kemijskoj, prehrambenoj i industriji plastike javlja se problem zagađenosti alata različitim materijalom. Shingo je kod injekcijskog prešanja polimera zahtijevao dnevni plan proizvodnje u kojem je cilj bilo napraviti redoslijed proizvodnje koji će početi injektiranjem svijetlih polimera, a završiti injektiranjem tamnih polimera. Na taj se način čišćenje alata prilikom promjene materijala može minimalizirati jer potencijalni ostaci svijetlog polimera u alatu neće previše utjecati na novi, tamniji proizvod.
7) Optimalnom konstrukcijom stroja. Konstrukcija stroja mora biti takva da montaža i demontaža alata bude brza, jednostavna i učinkovita. Shingo je zagovarao tezu da je bolje imati više strojeva na koje se mogu lako ugraditi određeni alati, nego jedan stroj na koji se mogu ugraditi svi alati. Problem kod strojeva na koje se može ugraditi veliki broj alata leži u tome da je montaža i demontaža često složena i teška zbog velikog broja i konfuznog dizajna prihvatnih mjesta.
8) Dobrim dizajnom proizvoda. Prilikom dizajna proizvoda mogu se napraviti velike uštede na način da se određeni dijelovi proizvoda standardiziraju ako je to moguće. Na taj je način manja varijacija različitih dijelova pa nestaje potreba za dodatnim alatima i nepotrebnim izmjenama alata.
9) Dobrim dizajnom alata. Najizraženiji primjer dobrog dizajna alata može se naći kod obrade odvajanjem čestica. Naime, većina novih tehnološki naprednih CNC strojeva ima više alata montirano na sam stroj (npr. revolver-držač alata), gdje stroj u isto vrijeme može imati preko 10 različitih alata te se izmjena alata vrši automatski bez požurivanja operatera u vremenu manjem od sekunde.
10) Urednim i čistim radnim prostorom (5S). Označavanje i numeriranje alata te držanje alata blizu stroja na kojem se koristi dobra je praksa. Isto tako, sva sredstva rada za izmjenu alata moraju biti na vidljivom mjestu i što je moguće bliže radnom mjestu na kojem se koriste.
11) Sustavnim provođenjem programa smanjenja vremena izmjene alata. Pri provođenju programa fokus treba biti na uskim grlima procesa te prvi korak mora biti trening i edukacija cjelokupnog osoblja u proizvodnom pogonu. Također, timovi koji provode program moraju imati mjerljive ciljeve. Neki od ciljeva mogu biti, npr. smanjenje vremena izmjene alata za 50 % unutar 6 mjeseci. Međutim, najvažniji aspekt izmjene alata mora biti standardizacija dobrih praksi i pretvaranje takvih praksi u ljudsku rutinu.

SMED je nesumnjivo dobra strategija za optimizaciju procesa izmjene alata, ali on djeluje mnogo šire nego što to inženjeri očekuju.

Budući da je dostupnost stroja kod OEE alata jedan od čimbenika učinkovitosti stroja, potrebno je napomenuti kako SMED utječe upravo na taj parametar. Tako da u slučaju da dođe do smanjenja vremena izmjene alata, doći će i do povećanja dostupnosti stroja, što će u krajnosti rezultirati većom učinkovitosti samog stroja [175, 129]. SMED iziskuje umjerena ulaganja te se vrijeme izmjene alata može smanjiti do čak 90 %. Time se eliminiraju sve aktivnosti koje iz

perspektive kupca nemaju dodanu vrijednost te se otvara mogućnost za povećanje proizvodnje ako za to postoji potreba. [176]. Općenito govoreći, SMED je moćan alat za eliminaciju uskih grla procesa te omogućuje proizvodnju u malim serijama, čime organizacija postaje fleksibilnija i konkurentnija [177].

3.4.19. Šest velikih gubitaka

U svakom vitkom poduzeću od vitalne je važnosti pronaći, kategorizirati i izmjeriti gubitke. Šest velikih gubitaka alat je koji se koristi uz OEE jer kategorizira gubitke u određene skupine i izravno utječe na jedan od tri čimbenika OEE alata. Prema definiciji šest velikih gubitaka u proizvodnji postoje sljedeći gubitci [178, 179, 180, 181]:

1) Zastoji i zatajenja strojeva kategoriziraju se kao gubitak vremena kada dolazi do smanjenja proizvodnje ili kada se proizvode neispravni proizvodi.
2) Podešavanje strojeva smatra se gubitkom kada stroj ne radi ili kada se pojave neispravni proizvodi pri prijelazu proizvodnje s jedne serije na drugu, preciznije rečeno, kada prilikom izmjene alata nova serija proizvoda nije zadovoljavajuće kvalitete.
3) Manji zastoji ili prazan hod strojeva smatra se gubitkom kada je proizvodnja poremećena uslijed manjih kvarova ili praznog hoda.
4) Smanjenje brzine rada strojeva smatra se gubitkom kada stroj proizvodi ispod svojih nazivnih tehničkih značajki.
5) Abnormalnosti na proizvodima za vrijeme uhodavanja u nominalan rad.
6) Neispravni proizvodi i dorada smatraju se gubitkom kada stroj ne proizvodi proizvode zadovoljavajuće kvalitete.

Svi ovi gubitci utječu na OEE, odnosno na cjelokupnu učinkovitost opreme. Pritom zastoji, zatajenja i podešavanja strojeva izravno utječu na dostupnost stroja. Manji zastoji, prazan hod i smanjena brzina proizvodnje utječu na učinkovitost stroja, a abnormalnosti na proizvodima pri uhodavanju, neispravni proizvodi i dorada utječu na udio kvalitetnih proizvoda. Iz svega toga proizlazi da je kategorizacija gubitaka važan proces bez kojeg mjerenje OEE-a nije moguće [178, 179, 180, 181]. Iako se šest velikih gubitaka najčešće povezuje s OEE alatom, potrebno je napomenuti kako je i TPM usko fokusiran na gubitke. Tako svaka TPM inicijativa započinje s fokusom na gubitke i povećanjem učinkovitosti [182].

Tablica 18. *Šest velikih gubitaka [129]*

OEE čimbenik	Kategorija šest velikih gubitaka	OEE kategorija gubitka	Primjer
Dostupnost	Zastoj ili zatajenje	Gubitak vremena	Zatajenje alata Neplanirano održavanje Generalno zatajenje Zatajenje opreme
	Podešavanje	Gubitak vremena	Izmjena alata Nedostatak materijala Nedostatak operatera Velika podešavanja Uhodavanje
Učinkovitost	Manji zastoj ili prazan hod	Gubitak brzine	Ometanje proizvodnog toka Ometanje montaže Zaglavljenja Blokiranje senzora Pretjerano podmazivanje Čišćenje/provjeravanje
	Smanjenje brzine rada	Gubitak brzine	Teško uhodavanje Rad ispod tehničkih karakteristika stroja Dotrajali stroj Dotrajala oprema
Kvaliteta	Abnormalnosti na proizvodima pri uhodavanju stroja	Gubitak kvalitete	Škart Dorada Oštećenja Istek roka trajanja Krivo sklapanje
	Neispravni proizvodi i dorada	Gubitak kvalitete	Škart Dorada Oštećenja Istek roka trajanja Krivo sklapanje

Budući da je vitka filozofija usko usmjerena na gubitke, ne treba ni napominjati kako je ovaj alat važan za potpunu implementaciju vitke filozofije u nekoj organizaciji. Međutim, postavlja se pitanje kako eliminirati šest velikih gubitka. Brown, Collins i McCombs dali su neke smjernice za rješavanje šest velikih gubitaka, a one su prikazane u Tablici 19.

Tablica 19. *Šest velikih gubitaka i njihove protumjere [183]*

Kategorija gubitka	Kako riješiti ovaj gubitak?
Zastoj ili zatajenje	• spriječiti propadanje strojeva • održavati dobre radne uvjete • spriječiti nepropisno krpanje strojeva • redovno servisirati strojeve i opremu.
Podešavanje	• alat i oprema za podešavanje moraju biti standardizirani i lako podesivi • upute za podešavanje moraju biti precizne te se treba izbjeći bilo kakvo oslanjanje na osjećaj i iskustvo operatera • kreirati i promicati standardizirane upute za podešavanje alata.
Manji zastoj ili prazan hod	• promatrati i bilježiti važne podatke uz zastoje, napraviti analizu glavnig uzroka te odrediti optimalne radne uvjete stroja kako bi kvaliteta bila neupitna.
Smanjenje brzine rada	• snimiti sve probleme pri uhodavanju i radu strojeva, napraviti analizu glavnog uzroka te kreirati i testirati standardiziranu proceduru rada.
Abnormalnosti na proizvodima pri uhodavanju stroja	• snimiti sve probleme pri uhodavanju strojeva, kvantificirati i odrediti vrstu neispravnih proizvoda, odrediti učestalost neispravnih proizvoda, dokumentirati rezultate i napraviti standardizirane procedure za uhodavanje strojeva.
Neispravni proizvodi i dorada	• prikupiti podatke o neispravnim proizvodima, napraviti pareto dijagram, odrediti učestalost abnormalnosti, napraviti poboljšanja i kreirati standardizirane procedure rada.

Šest velikih gubitaka alat je koji je prvi opisao Nakajima u svojoj knjizi „Introduction to TPM: Total Productive Maintenance“. Međutim, kasnije su ga neki autori, poput Smitha i Hawkinsa u svojoj knjizi „Lean Maintenance: Reduce Costs, Improve Quality, and Increase Market Share“, kategorizirali još opsežnije. Tako Smith i Hawkins u svojoj knjizi govore o jedanaest velikih gubitaka, a oni su [184]:

PLANIRANI ZASTOJI

1) vrijeme bez proizvodnje, pauze, promjena radnika (nova smjena)
2) planirano održavanje

NEPLANIRANI ZASTOJI

3) kvar ili zatajenje opreme
4) izmjena alata
5) namještanje alata
6) uhodavanje i prilagodba

SMANJENJE UČINKOVITOSTI

7) mali zastoji (manje od šest minuta)

8) smanjena brzina rada

SMANJENJE KVALITETE

9) otpad/*output*
10) neispravni proizvodi i dorada
11) pojava neispravnih proizvoda kod uhodavanja stroja.

Iz Smithove i Hawkinsove kategorizacije gubitaka vidljivo je da oni u srži ne donose ništa novo naspram Nakajiminih šest velikih gubitaka. Iz toga se može zaključiti da je Nakajima vrlo precizno detektirao probleme u proizvodnom okruženju te da su ti isti problemi još uvijek vruća tema u današnjim poduzećima.

3.4.20. Pametni ciljevi

Pametni ciljevi su alat koji se uvodi usporedno s ključnim indikatorima učinkovitosti te ljudi često ta dva alata „stavljaju u isti koš“. Međutim, samo ime tih alata govori nam na koji način ti alati djeluju. Osnovna je razlika u tome što ključni indikatori učinkovitosti indiciraju ili pokazuju hoće li se predviđeni pametni ciljevi ostvariti u danom vremenskom razdoblju ili ne te se prema tim indikatorima mogu, ali i ne moraju preispitati postavljeni ciljevi [118].

Postavljanje pametnih ciljeva postupak je od iznimne važnosti za svaku organizaciju te se pri postavljanju ciljeva treba voditi načelima vitke filozofije. Ocem pametnih ciljeva smatra se Peter Drucker te je on u svojoj knjizi „The Practice Management“ postavio temelje stvaranja organizacijskih ciljeva. Drucker je smatrao da svaka organizacija ima osam ključnih područja te vrhovni menadžment mora postaviti jasne ciljeve za svako od tih područja (vidi Tablicu 20) [185].

Tablica 20. *Postavljanje jasnih ciljeva u poduzeću prema Peteru Druckeru [185]*

Područje	Koji se ciljevi odnose na to područje?
Marketing	• tržišni udio • zadovoljstvo kupaca • vrste proizvoda • prodaja.
Istraživanje	• istraživanje i razvoj • lansiranje novih proizvoda • optimizacija procesa • nove tehnologije.
Produktivnost	• optimalno korištenje resursa • fokus na ključne aktivnosti • *output*.
Materijalni i financijski resursi	• Financije • Nabava • Financijski menadžment

Tablica 20. *Postavljanje jasnih ciljeva u poduzeću prema Peteru Druckeru [185] (nastavak)*

Profitabilnost	• profit • marža • ROI.
Menadžment	• struktura menadžmenta • razvoj i unaprjeđenje zaposlenika.
Zaposlenici	• organizacijska struktura • međuodnosi i odgovornosti zaposlenika • retencija zaposlenika.
Javna odgovornost	• zakonska usklađenost • društveno i etično djelovanje • korporativan društvena odgovornost.

Peter Drucker smatrao je da vrhovni menadžment mora postaviti ciljeve, a provođenje ciljeva treba nadgledati MBO (engl. *Management By Objectives*). Preciznije rečeno, menadžment ciljeva (MBO) mora operativno provesti politiku vrhovnog menadžmenta na način da uključi sve zaposlenike u ostvarenje zadanih ciljeva [185]. Međutim, prema vitkoj proizvodnji ti ciljevi moraju biti [118,185,186]:

1) KONKRETNI (engl. *Specific*)

Ciljevi moraju biti definirani i jasni svima odgovornima za njihovo ostvarenje.

- Što treba učiniti?
- Koji rezultat treba ostvariti?
- Zašto je ostvarenje ovog cilja važno?
- Tko je odgovoran?
- Koje osobe treba uključiti?
- Koji su uvjeti ili ograničenja?

2) MJERLJIVI (engl. *Measurable*)

Ciljevi ne smiju biti dvosmisleni, već konkretni i mjerljivi. Mjera može biti kvantitativna ili kvalitativna, no ona mora ispunjavati zadane uvjete i ograničenja. Ako neki cilj nije mjerljiv, tada se ostvarenjem tog cilja ne može niti upravljati.

3) DOSTIŽNI (engl. *Attainable and aggressive*)

Ciljevi ne moraju biti ambiciozni kako bi motivacija zaposlenika bila na razini, no istovremeno ti ciljevi moraju biti realno postavljeni kako bi bili ostvarivi.

- Je li ostvarenje ovog cilja pod mojom/našom kontrolom?
- Možemo li ovaj cilj ostvariti u zadanom vremenskom razdoblju?
- Jesu li jasna ograničenja i uvjeti?
- Možemo li ovaj cilj ostvariti uz dane resurse?

- Je li ovaj cilj realan i praktičan?

4) RELEVANTNI (engl. *Realistic and result-oriented*)

Ljudi moraju znati koja je njihova uloga. Na taj će način ljudi jasno vidjeti koliko doprinose ostvarenju cilja te neće doći do nadmetanja i tenzija, već međusobnog podržavanja i bodrenja.

5) VREMENSKI DEFINIRANI (engl. *Time-sensitive*)

Ciljevi moraju imati definirani početak i očekivani završetak. Na taj se način promiče stanje žurnosti i djelovanje postaje prioritetno.

- Kada će ovaj cilj biti ostvaren?

Uzimajući u obzir sve navedeno, uspostavljenje pametnih ciljeva nije nimalo lak zadatak, ali se uvijek treba voditi načelima navedenima na Slici 36.

Ciljevi u poduzeću moraju biti usklađeni sa strukturom i mogućnostima tima te je poželjno da vođa tima prije samog predstavljanja zadatka svojim članovima tima sve detalje i nejasnoće prođe s nadređenima. Na taj će način tim imati bolju viziju o tome što se od njih očekuje te s kojim resursima raspolažu [187]. Isto tako, timovi se moraju sastavljati prema svojim kompetencijama, a ne prema hijerarhijskom položaju u organizaciji. Međutim, najvažnije je od svega sustavno vrednovati i promicati ljude koji dosljedno ostvaruju ciljeve te se nagrađivanje mora izvršavati prema pojedinačnom doprinosu, a ne prema hijerarhiji [188].

Jedan od bitnih čimbenika kod postavljanja ciljeva je međuodnos teškoće cilja i učinkovitosti. Tako je jedno istraživanje pokazalo da ciljevi moraju biti umjereno teški kako bi učinkovitost ljudi bila optimalna. Ako su ciljevi i zadaci prelagani ili preteški, očekivani rezultati će izostati. Međutim, postavlja se logično pitanje kako ciljevi utječu na učinkovitost. Ciljevi utječu na učinkovitost četirima sljedećim mehanizmima [189]:

1) Ciljevi pružaju smjer željenog kretanja. Preciznije rečeno, oni skreću pozornost ljudi na bitne aktivnosti vezane uz željeni cilj te isto tako skreću pozornost s nebitnih aktivnosti.
2) Ciljevi imaju stimulativno svojstvo u pogledu napora i rada. Visoki ciljevi vode većem naporu, dok niski ciljevi vode manjem naporu.
3) Ciljevi utječu na ustrajnost.
4) Ciljevi neizravno utječu na aktivnost kroz poticanje, otkrivanje i korištenje znanja.

Slika 36. *Pametni cilj [190]*

3.4.21. Standardizacija rada

Vitka proizvodnja temelji se na jasnim uputama što radnik treba raditi, proizvodne serije optimalno su razrađene i cijela proizvodnja temelji se na *pull* signalima, no postavlja se pitanje kako osigurati stabilnost sustava, odnosno kako stvoriti sustav koji uvijek ima isti odziv na tržišne promjene. Odgovor leži upravo u dokumentiranju najboljih praksi rada te postupnim pretvaranjem standardnih radnih procedura u svakodnevno ponašanje radnika [191].

Standardizacija rada temelj je svake održive vitke promjene i bez ovog alata *kaizen* je besmislen. *Zašto je tome tako?* Ljudi neće mijenjati svoju rutinu dok netko ili nešto ne zahtijeva da ju promijene. Određena skupina ljudi može napraviti izvanredno poboljšanje putem *kaizen* događaja, no hoće li to poboljšanje postati svakodnevna rutina ovisi isključivo o kvaliteti procesa standardizacije novog rada. Nije dovoljno pokazati radniku kako će se od sada obavljati njegov posao, već je to potrebno i dokumentirati kako bi novi postupak bio jasan svim sudionicima. Cilj standardizacije rada nije suhoparno pisanje nečitljivih procedura rada, štoviše neki autori predlažu da bi takve procedure trebali biti vizualne. Cilj je naučiti ljude kako će se od sada izvoditi neki postupak kako bi s vremenom isti postao rutina [191]. Isto tako, procedure moraju biti razumljive radnicima. Ako radnik ne razumije novu proceduru rada i što se od njega traži, u većini slučajeva on će krenuti raditi na način na koji je to radio dosad [16e].

Slika 37. *Standardizacija rada [192]*

Standardizacija rada nije alat koji bi se trebao uvoditi na početku vitke transformacije. Organizacija mora imati određenu razinu zrelosti, točnije, proizvodni procesi i proizvodi moraju biti dovoljno zreli za standardizaciju. Jednostavno nema logike dokumentirati loše prakse (vidi Sliku 37). Isto tako, organizacija mora imati određen broj postupaka koji su ponovljivi jer standardizacija nije moguća u nepredvidljivim i nekontroliranim uvjetima. Sve u svemu, razvoj standardizacije mora se odraditi u osam sljedećih koraka [193]:

1) Utemelji timove za poboljšanje procesa.
2) Odredi taktno vrijeme.
3) Odredi ciklusno vrijeme.
4) Odredi redoslijed proizvodnje.
5) Odredi rad koji ćeš poboljšati.
6) Napravi standardizirani dijagram tijeka rada.
7) Napravi liste i tablice za standardizirani rad.
8) Kontinuirano radi na poboljšanjima.

Kontinuiran napredak nije moguć bez standardizacije rada. Vitka filozofija sama po sebi ne dopušta da zaposlenik sam proizvoljno bira kada će proizvoditi neku seriju proizvoda te kako će izvoditi neki rad. To bi se kosilo s jednim od glavnih načela vitke proizvodnje, a on nam kaže da varijabilnost mora biti svedena na minimum. Kod standardizacije rada bitnu ulogu igra vođa radne ćelije, bolje rečeno, vođa radne ćelije određuje kada će se nešto proizvoditi, kojim redoslijedom i koliko. S druge strane, standardne procedure određuju kako će se taj rad izvoditi. Stoga možemo reći da vođe radnih ćelija žive u svojevrsnoj simbiozi sa standardnim procedurama rada. Oni moraju poštivati način izvođenja rada, ali s druge strane ostavlja im se dovoljno fleksibilnosti da na temelju egzaktnih podataka i iskustva upravljaju proizvodnjom

[194]. Upravo to je vitka proizvodnja i ne treba naglašavati da tako funkcionira proizvodnja u Japanu. Japanski vođe timova kontroliraju proizvodnju, mjere učinkovitost i stavljaju proizvodni tok u stabilan okvir [195].

Standardizacija je važan element LP-a, no postoje i neki problemi vezani uz standardizaciju. Standardizacija može negativno utjecati na ljude ako oni ne znaju zašto se taj rad izvodi baš tako. Studija je pokazala da ljudi nemaju želju i boje se predložiti nova rješenja kada postoje krute standardizirane procedure rada. Ono što se ljudi pitaju je tko su oni da propitkuju kako će se to izvoditi. Međutim vitki praktičari predlažu da se to može izbjeći na način da radnici budu upoznati i uključeni u sam proces nastajanja standardnih procedura. Na taj će način njihove ideje i primjedbe biti sastavni dio standardnog rada te će iznošenje ideja biti prirodan i kontinuiran proces [196].

Budući da je promjena kulture jedno od prioritetnih pitanja kod vitke transformacije, treba vidjeti što se stvara standardizacijom. Tako prema nekim autorima standardizacija stvara disciplinu i promovira kulturu učenja te se ljude potiče da se koriste *poka-yoke* logikom kod poboljšanja. Općenito govoreći, standardizacija osigurava sljedeće [197]:

- smanjuje varijabilnosti i broj korektivnih radnji
- bolja sigurnost radnika
- bolja komunikaciju
- abnormalnosti su vidljive
- lakši i brži trening ljudi
- povećanje radne discipline
- bolji odziv na izazove
- ljudi znaju što se od njih očekuje
- poboljšanja postaju održiva (vidi Sliku 38).

Slika 38. *Kontinuirani napredak i standardizacija rada [198]*

Koncept vitke proizvodnje nastao je na temeljima TPS-a te su mnogi alati preuzeti iz TPS-a i redizajnirani za uporabu u različitim ekonomskim sektorima. Međutim, zna li se koji su alati privukli najveću pažnju znanstvene zajednice? Prema nekim autorima JIT, *jidoka*, *kanban*, 5S, *poka-yoke*, SMED i standardizacija rada najvažniji su vitki alati. Svi ti alati istinski su predstavnici vitkog poslovanja i za poduzeće se ne može reći da je vitko sve dok te alate ne integrira u svoje poslovanje. Prema tome standardizacija rada mora biti kvalitetno odrađena i nadograđivana kako bi poslovanje bilo profitabilnije i održivo. Koliko poslovanje kroz standardiziranost može postati profitabilnije i učinkovitije može se opisati na primjeru iz brazilske tvornice šasija za kamione. Tako je studija provedena u toj brazilskoj tvornici dokazala da ovaj alat može drastično smanjiti vrijeme sklapanja šasije te je nepotrebno kretanja radnika bilo smanjeno za 200 metara. Ne treba niti napomenuti kako je vrijeme proizvodnje jedne šasije smanjeno za gotovo 10 %, što je ogromna ušteda [199].

Standardizacija je nesumnjivo važna jer se veže na mnoge druge vitke alate. Ovaj se alat možda ne uvodi u prvom koraku, ali ga treba uvesti što prije kako bi nastala poboljšanja bila održiva. Tako su studije pokazale da je nakon 5S-a dobro napraviti standardiziranu proceduru održavanja prostora kako bi poboljšanje bilo održivo [200, 201]. Budući da je standardizacija rada jedan od temeljnih alata, ne treba previše naglašavati njegovu popularnost među poduzećima. Tako je studija provedena u Litvi koja je obuhvaćala 40 vitkih poduzeća i 15 vitkih alata dokazala da je standardizacija treći najkorišteniji alat u litavskim vitkim poduzećima [202]. Sve u svemu, to je moćan alat koji se ne smije izostaviti kod vitkog menadžmenta, ma koliko on na prvu ruku djelovao obično.

3.4.22. Taktno vrijeme

Studije su pokazale da 36 % proizvodnih poduzeća u SAD-u koristi vitki koncept poslovanja. Međutim, postavlja se pitanje koja su to uobičajena obilježja vitkih poduzeća i koju ulogu tu ima taktno vrijeme. Prema nekim su autorima glavna obilježja vitkih poduzeća sljedeća [203]:

- komadna proizvodnja
- eliminacija aktivnosti koje nemaju dodanu vrijednost iz perspektive kupca
- proizvodnja unutar planiranog vodećeg vremena
- alokacija resursa na mjesta gdje se najčešće koriste
- niveliranje proizvodnje kako bi se proizvodilo s taktnim vremenom.

Taktno vrijeme nije ništa drugo nego brzina kojom se proizvod provlači kroz svaki postupak proizvodnje kako bi se zahtjev kupca ispunio na vrijeme (vidi Sliku 39) [203]. Preciznije rečeno, to je sinkronizacija ritma jednog procesa s ritmom ostalih procesa kako bi tok proizvodnje bio uravnotežen [204].

Slika 39. *Taktno vrijeme [203]*

Taktno vrijeme računa se na sljedeći način [205]:

$$\text{Taktno vrijeme} = \frac{\text{Dostupno proizvodno vrijeme}}{\text{Zahtjev kupca}}$$

Dostupno proizvodno vrijeme računa se kao ukupno raspoloživo proizvodno vrijeme umanjeno za pauze, zastoje, održavanje, smjene radnika itd. S druge strane, zahtjev kupca računa se kao broj proizvoda koji kupac želi u određenom vremenskom razdoblju.

Na primjer, ako imamo proizvodnu liniju koja radi u dvije smjene pet radnih dana u tjednu, jedna radna smjena radi osam sati dnevno te ima dvije pauze od 15 minuta i postoji jedan zastoj proizvodnje od 20 minuta kod smjene radnika, dostupno proizvodno vrijeme računat će se na sljedeći način [205]:

$$\begin{aligned}
\text{Proizvodno vrijeme} &= 2 \times 8 \times 60 \\
\text{Dostupno proizvodno vrijeme} &= 960 - (2 \times 2 \times 15 + 20) \\
&= 960 - 80 \\
&= 880 \text{ minuta} \\
\text{Zahtjev kupca} &= 220 \text{ komada tjedno} \\
&= 220 / 5 \\
&= 44 \text{ komada dnevno} \\
\text{Taktno vrijeme} &= 880 \text{ minuta} / 44 \text{ komada} \\
&= 20 \text{ minuta}
\end{aligned}$$

Taktno vrijeme u ovom primjeru iznosi 20 minuta, što znači da svaki korak obrade mora izvršiti svoj dio posla unutar 20 minuta kako bi se ispunio zahtjev kupca. To znači da svi procesi u proizvodnji moraju biti vremenski sinkronizirani i uravnoteženi na odgovarajući način.

Najbolji primjer toga što znači nivelirati proizvodnju prema taktnom vremenu nalazi se na Slici 40 i 41. Tako se na prikazu (a) Slike 40 vidi da se proizvodnja sastoji od sedam koraka obrade te je četvrta operacija usko grlo proizvodnog toka. To znači da je radno opterećenje u četvrtoj operaciji preveliko te operateri na tom radnom mjestu ne mogu izvršiti svoj dio zadatka unutar taktnog vremena. Tada treba rasteretiti usko grlo procesa i dodijeliti te zadatke nekim prethodnim ili sljedećim operacijama kako bi se svi koraci proizvodili prema planiranom taktnom vremenu. U konačnici se na prikazu (b) Slike 40 vidi da su svi koraci obrade sinkronizirani te će zahtjev kupca biti ispunjen [205].

Slika 40. *Niveliranje proizvodnje prema taktnom vremenu [205]*

Slika 41. *Proizvodnja automobila uz taktno vrijeme i standardizaciju rada [206]*

Cijela ova priča s taktnim vremenom svodi se na to da ritam proizvodnje mora biti sinkroniziran s ritmom potražnje. Sinkronizacija proizvodnje i potražnje nije lagan proces, ali niveliranje proizvodnje po taktnom vremenu omogućuje da ritam proizvodnje bude baš onakav kakav tržište traži. Današnja proizvodnja svodi se na maloserijsku i fleksibilnu proizvodnju kojom je teško upravljati te je potrebno uložiti mnogo alata i truda kako bi poslovanje bilo stabilno. Proizvodnja po načelima „povlačenja“ procesa ostvaruje se taktnim vremenom i niveliranjem proizvodnje, ali je često potrebno integrirati SMED i *kanban* kako bi niveliranje proizvodnje bilo moguće. Stoga bi SMED i *kanban* trebali biti sastavni dio svake inicijative vezane uz proizvodnju prema načelima taktnog vremena [207]. Taktno vrijeme nije samo kruti izračun ritma proizvodnje, već radnici dobivaju osjećaj za tok proizvodnje i jasnu sliku kako cijela proizvodnja funkcionira. Štoviše, taktnom proizvodnjom vodeće vrijeme postaje fiksno, a poslovni procesi predvidljivi i stabilni [208]. Općenito govoreći, taktna proizvodnja ima sljedeće značajke [209]:

- Taktna proizvodnja smanjuje WIP.
- Taktna proizvodnja nema velik utjecaj na OEE i ne može ga poboljšati jer OEE ovisi o pouzdanosti i kvaliteti.
- Taktna proizvodnja može, ali ne mora poboljšati odziv na zahtjev kupca.
- Taktna proizvodnja stavlja u ravnotežu radno opterećenje, što znači da svi operateri imaju jednako vrijeme za izvršenje svojih zadataka.
- Taktna proizvodnja povećava ukupnu proizvodnu učinkovitost, ali se pritom treba fokusirati na komadnu proizvodnju (vidi Sliku 42).

Cilj svake taktne inicijative je da ciklusno vrijeme bude jednako taktnom vremenu. Što to znači? Ciklusno vrijeme uključuje sve aktivnosti koje imaju i koje nemaju dodanu vrijednost iz perspektive kupca te ono predstavlja ukupno vrijeme proizvodnje, od početka do kraja. Ako je ciklusno vrijeme manje od taktnog vremena, tada je radno opterećenje premalo, što znači da određene operacije nemaju posla, to jest postoji višak slobodnog vremena. Ako je pak ciklusno vrijeme veće od taktnog vremena, tada u proizvodnom toku postoji usko grlo procesa [210].

Svaka taktna inicijativa iziskuje određen stupanj vitke zrelosti te su često poduzeća primorana implementirati nove vitke alate kako bi taktna proizvodnja bila moguća. Međutim, postavlja se pitanje kako taktnu proizvodnju učiniti što učinkovitijom nakon što su mogući svi preduvjeti za taktno poslovanje. Proizvodnja definitivno mora biti ćelijska kako bi niveliranje proizvodnje bilo moguće, no postavlja se pitanje kakva bi trebala biti arhitektura ćelijske proizvodnje. Tako je studija provedena na linearnim i U-ćelijskim rasporedima pokazala da je U-ćelijski raspored bolji od linearnog. U-ćelijska arhitektura omogućava produktivnost veću za 10 do 33 % naspram linijske arhitekture [211]. Općenito govoreći, taktna proizvodnja i JIT izvode se kroz U ili L-ćelijsku arhitekturu [212].

Kod serijske će proizvodnje prvi proizvod biti gotov za 21 minutu,
a vrijeme za proizvodnju 10 komada iznosit će 30 minuta.

Kod komadne će proizvodnje prvi proizvod biti gotov za 3 minute,
a vrijeme za proizvodnju 10 komada iznosit će 12 minuta.

Slika 42. *Prednosti komadne naspram serijske proizvodnje [213]*

3.4.23. TPM

Proizvodna poduzeća snažno se fokusiraju na optimizaciju procesa i primjenu različitih modela poslovanja kako bi postigla bolju profitabilnost. Međutim, često svi ti modeli kreću od pretpostavke da je proizvodni pogon idealan. Malo je poslovnih strategija koje uzimaju u obzir dostupnost, učinkovitost i kvalitetu proizvodnih strojeva i pogona. Često je pitanje održavanja pogona marginalizirano, a menadžment nema spoznaju o tome da proizvodni strojevi rade ispod svojih tehničkih karakteristika. Mobleyeva studija provedena 1990. godine pokazala je da u prosjeku 30 % proizvodnih troškova otpada na održavanje strojeva i opreme. Stoga je važno shvatiti da je optimalno održavanje prioritetno pitanje za svaku organizaciju. Mobley je u svojoj studiji govorio o tri kategorije održavanja, a to su korektivno, plansko i preventivno održavanje. Ono je što je otkrio svojom studijom provedenom u SAD-u jest sljedeće: „Korektivno održavanje je triput skuplje od preventivnog!“ Zaključak je sljedeći: „Poduzeća moraju naći način da svoju opremu poprave prije pojave problema.“ [214]

Japan je mnogo prije SAD-a shvatio da je održavanje prioritetno pitanje te je 1971. godine predstavljen TPM koji je u mnogočemu različit i bolji od američkog preventivnog održavanja [179]. TPM je sastavni dio vitke filozofije te je fokusiran na optimizaciju pouzdanosti strojeva i opreme kako bi upravljanje organizacijskom imovinom bilo učinkovito [215]. Nakajima je u svojoj studiji 1989. godine TPM definirao kao strategiju koja uključuje sljedeće korake [179]:

- povećanje učinkovitosti strojeva i opreme na način da se dostupnost, produktivnost, učinkovitost i kvaliteta rada strojeva i opreme optimizira

- uspostavljenje strategije preventivnog održavanja za cjeloživotni ciklus strojeva i opreme
- uključenje različitih odjela u održavanje, posebice proizvodnje
- uključenje svih zaposlenika u postupak održavanja, od top menadžmenta do radnika
- promoviranje dobrih postignuća u održavanju.

TPM je alat koji se temelji na prikupljanju i analiziranju podataka vezanih uz učinkovitost strojeva i opreme te se analizom uzroka nastoji pronaći glavni uzrok potencijalnih ili nastalih problema. Kod TPM-a je važno ostvariti produktivnu sinergiju između različitih odjela i ljudi, gdje su u središtu zbivanja najviše operateri, proizvodni inženjeri, dobavljači strojeva i opreme te odjel održavanja. Zapadna filozofija više je usmjerena na to da je upravljanje imovinom odgovornost sektora održavanja, dok je japanska filozofija, odnosno TPM, više usmjeren na to da je upravljanje imovinom organizacijski problem. Tako u TPM-u operateri moraju prihvatiti neke nove odgovornosti kao što su dnevna kontrola strojeva i opreme, manja podešavanja, podmazivanje i zamjena dotrajalih dijelova. Cilj TPM-a je da se održavanje decentralizira jer ljudi koji rade sa strojevima i opremom najbolje znaju prednosti i mane sustava te mogu pravovremeno reagirati [216].

TPM se tijekom godina dokazao kao učinkovit način za upravljanje imovinom. Tako je jedna studija pokazala da TPM pozitivno utječe na OEE. Naime, poduzeća koja su imala OEE između 50 i 60 % prije implementacije TPM-a uspjela su nakon pet godina od uvođenja TPM-a povećati OEE na gotovo 85 % [203]. Tako se dolazi do zaključka da bi se TPM trebao uvoditi usporedno s OEE-om kako bi program kontinuiranog poboljšanja bio agresivniji i bolji.

Tablica 21. *Prednosti TPM-a [217, 218]*

Prednosti TPM-a
Izravne
• troškovi održavanja stavljaju se u planiran i kontroliran okvir te se smanjuju za 30 % • produktivnost se povećava za 1,5 do 2 puta • dolazi do smanjenja radnika vezanih isključivo uz održavanje jer se jedan dio tih poslova dodjeljuje proizvodnim radnicima • smanjuju se ozljede na radu i zagađenje okoliša • povećava se kvaliteta proizvoda.
Neizravne
• osnažuju se zaposlenici jer se uključuju u različite aktivnosti • radnicima su poznate tehnike i alati za održavanje strojeva te se problemi brže otklanjaju • radna su mjesta čista i ugodna za rad • iskustvo i znanje bolje se prenose • strojevi su pouzdaniji pa je planiranje proizvodnje stabilnije • vodeće vrijeme proizvodnje smanjuje se jer nema nepredvidivih prekida proizvodnog toka.

Strategija TPM-a svodi se na to da u proizvodnji ne smije doći do zastoja, abnormalnosti i incidenata. Takva strategija mora biti operativno izvedena kroz multifunkcionalne timove, rigorozno preventivno održavanje, optimizaciju svih aktivnosti vezanih uz održavanje i mnoge druge stvari [179, 219]. TPM nedvojbeno snižava i pod kontrolu stavlja troškove održavanja. Međutim, TPM utječe i na organizacijsku učinkovitost. Tako su studije pokazale da TPM osnažuje organizaciju na svim razinama te je veza između TPM-a i proizvodne učinkovitosti izrazito pozitivna [220, 221]. TPM je sam po sebi vrlo agresivan pristup održavanju, što je vidljivo iz Tablice 22. On nastoji uključiti sve ljude u održavanje (vidi Sliku 43 i 44) te je studija pokazala da je produktivan timski rad nužan preduvjet za uspješnu implementaciju TPM alata [222].

Tablica 22. *Implementacija TPM-a prema Hartmannu [223]*

1. FAZA	– optimizacija dostupnosti i učinkovitosti strojeva i opreme – fokus na poboljšanja.
• Utvrdi trenutno stanje dostupnosti i učinkovitosti strojeva i opreme (OEE). • Utvrdi stanje strojeva i opreme. • Utvrdi trenutne mjere održavanja na strojevima i opremi. • Analiziraj gubitke na strojevima i opremi. • Utvrdi prilike i prioritete za poboljšanje učinkovitosti strojeva i opreme. • Utvrdi prilike za poboljšanje izmjene alata. • Provedi prilike za poboljšanje u realnost. • Provjeri rezultate poboljšanja i nastavi s kontinuiranim poboljšanjem.	
2. FAZA	– održi dostupnost i učinkovitost strojeva i opreme na najvišoj mogućoj razini – autonomno održavanje, plansko održavanje, održavanje kvalitete.
• Razvij plansko održavanje, čišćenje i podmazivanje za svaki stroj ili opremu. • Izradi procedure i upute za plansko održavanje. • Izradi procedure za inspekciju svakog stroja ili opreme. • Provedi plansko održavanje u realnost. • Provjeri rezultate planskog održavanja i primjeni korektivne mjere po potrebi.	
3. FAZA	– uspostavi procedure za nabavku novih strojeva i opreme – razvij procese gdje je učinkovitost strojeva velika, a troškovi održavanja mali – preventivno održavanje.
• Utvrdi tehnološke specifikacije pogona. • Savjetuj se s radnicima o problemima vezanima uz proizvodne strojeve i opremu. • Savjetuj se s radnicima održavanja o problemima vezanima uz strojeve i opremu. • Prilikom nabavke nove opreme nastoj eliminirati sve probleme koji su postojali na prošlim strojevima ili opremi. • Uspostavi sustav dijagnostike za novu opremu. • Educiraj ljude za rad na novoj opremi prije nego što ona fizički stigne u pogon. • Kupuj opremu koja zadovoljava tehnološke specifikacije pogona.	

TPM nedvojbeno povećava produktivnost, učinkovitost i konkurentnost. Takav način upravljanja koriste uspješna poduzeća kao što su Procter & Gamble, Dupont, Eastman Chemicals, Ford, AT&T, Texas Instruments i drugi te svaki dan dokazuju da je TPM istinski put prema

konkurentnijem poslovanju. Velik broj studija pokazao je da takav pristup drastično smanjuje udio neispravnih proizvoda i broj zastoja te tako pozitivno utječe na produktivnost. Nissan je u prve tri godine od uvođenja TPM-a uspio smanjiti zastoje za 80 %, zalihe za 55 %, nedostatke za 85 % i nepotrebne radne sate za 50 %. Uvođenje TPM-a dugoročan je proces koji često traje više od pet godina. Ovaj alat daje izrazite rezultate, ali je izuzetno složen i možda nije najpovoljniji u počecima vitke tranzicije [223].

1	Provjeri razinu rashladnog sredstva (dodaj ako je potrebno).	
2	Provjeri ventilator izmjenjivača topline (lopatice se moraju gibati).	
3	Provjeri filter zraka izmjenjivača topline (promijeni ga ako nije bijele boje).	
4	Provjeri spremnik s mazivom (nadopuni ga ako je potrebno).	
5	Provjeri radi li kolektor vlage.	

Slika 43. *Primjer TPM kontrolnog lista koji radnik ispunjava svaki dan prije početka rada [214]*

Slika 44. *TPM ploča za edukaciju radnika o održavanju strojeva [225]*

Zaključno, TPM je implementacijski izuzetno složen alat pri kojem bi 5S već morao biti duboko ukorijenjen u sve pore organizacije. Ukratko, njegovo djelovanje usmjereno je na poboljšanja, autonomna i planska održavanja, treninge i edukacije, rano upravljanje imovinom, kvalitetno održavanje, administraciju, sigurnost radnika i brigu o okolišu (vidi Sliku 45).

Slika 45*. Osam stupova TPM-a [226]*

3.4.24. VSM

VSM je alat kojim se mapira proizvodni tok određene skupine proizvoda te se na temelju postojećeg stanja predlažu poboljšanja i stvara buduće stanje proizvodnog toka (vidi Sliku 46 i 47). Prilikom mapiranja prati se tok materijala, informacija i procesa ili ljudi. Glavne značajke ovog alata su sljedeće [227]:

- vizualizira proizvodni tok na više razina (npr. nabava – skladište – zavarivanje – sklapanje – lakiranje – montaža – transport)
- skreće pozornost na izvore gubitaka
- uspostavlja se zajednički jezik za raspravu o problemima
- povezuje razne alate i načela kako bi se poboljšao proizvodni tok
- stvara oblik budućeg stanja u kojem je sve dokumentirano i definirano, svi sudionici znaju što se od njih očekuje te na koji će se način odvijati procesi u budućnosti
- jedini vitki alat koji povezuje tok informacija i tok materijala
- kvalitativni alat koji jasno pokazuje što treba učiniti da bi proizvodni tok bio kontinuiran, bez prekida.

VSM je jednostavan alat za analizu proizvodnog toka koji zahtjeva samo papir i olovku. Međutim, ovaj alat bez podrške proizvodnje po načelima „povlačenja“, *kanbana*, JIT-a, *heijunke* i taktne proizvodnje ne može napraviti nikakvo poboljšanje. Stoga je važno naglasiti da VSM moraju podržati mnogi drugi alati kako bi potencijalno buduće stanje bilo izvedivo u stvarnosti [227]. VSM nije koncipiran na način da operativno rješava gubitke, već se temelji na čistom otkrivanju gubitka. Jednom kada se gubitci otkriju pomoću VSM-a, potrebno je uvesti različite vitke alate koji će operativno podržati željeno buduće stanje [227]. Statistička studija koja je provedena na servisu LinkedIn i koja je obuhvatila oko 150 iskusnih vitkih menadžera pokazala je sljedeće [228]:

- 5S i VSM su alati koji se najčešće implementiraju u prvom koraku vitke tranzicije. Ovom studijom došlo se do zaključka da je 5S bolji alat za početak vitke transformacije, dok je VSM drugi izbor iskusnih vitkih praktičara.
- VSM je lakše implementirati od TPM-a, JIT-a i *jidoke*. Preciznije rečeno, VSM edukacija i trening kraći su i manje naporni nego kod spomenutih alata.
- Ključni faktori za uspjeh VSM inicijative su podrška i uključenost menadžmenta, trening, stručnost ljudi, organizacijska kultura i kvalitetno nadgledanje VSM-a. Također, dokazano je da financijska sposobnost poduzeća vrlo malo utječe na uspješnost VSM-a.
- Najveće prepreke kod implementacije VSM-a nedovoljna su podrška menadžmenta, loše dokumentirani procesi i nedostatak treninga i edukacije.
- VSM je učinkovit kod otkrivanja gubitaka, ali ne i za smanjenje gubitaka. Za smanjenje gubitka puno su učinkovitiji alati poput TPM-a, JIT-a, *jidoke*, standardizacije rada ili 5S-a.
- Kako bi se kreirao vitki proizvodni tok, potrebno je uvesti druge vitke alate.

- VSM-om se može skratiti vodeće vrijeme proizvodnje (engl. *lead time*) i ciklusno vrijeme (engl. *cycle time*) te se mogu smanjti zalihe.

Potrebno je napomenuti kako je ova studija provedena na servisu LinkedIn potvrdila mnogobrojne tvrdnje i pretpostavke znanstvenih autora te su teorijska stajališta tako dobila čvrst oslonac u praksi.

Slika 46. Proces mapiranja toka vrijednosti [229]

Koncept VSM-a nastao je u Toyoti, a popularizirali su ga Roth i Shook krajem devedesetih godina. Budući da je VSM nastao u Toyoti, ne treba naglašavati da je upravo proizvodni sektor prvi počeo masovno koristiti VSM-om te se ovaj alat tek kasnije proširio na zdravstvo, građevinarstvo i uslužne djelatnosti. Studija koja je obuhvatila sva bitna istraživanja od 1999. do 2016. godine pokazala je da različiti sektori i industrije koriste različite vitke alate kako bi kreirali buduće procese. Proizvodni sektor primjenjuje najviše vitkih alata, a najčešće korišteni alati su taktno vrijeme, *kanban*, 5S, kontinuirani tok, *kaizen*, *heijunka*, standardizacija rada itd. [230]. Druga studija provedena u Njemačkoj na 147 iskusnih vitkih menadžera pokazala je da je krajnji rezultat mapiranja procesa sljedeći [231]:

- proces otkrivanja uskih grla je učinkovitiji
- ljudi se potiču na poboljšanja
- proizvodni proces je transparentan

- optimizira se tok materijala
- optimizira se tok informacija (sve postaje transparentno)
- ljudi se uključuju u procese poboljšanja
- vodeće vrijeme i zalihe se optimiziraju
- uvodi se proizvodnja po načelu „povlačenja“ od strane kupca itd.

Kazalo						
	VC	Vrijeme ciklusa	VČ	Vrijeme čekanja	BS	Brze stezaljke
	VIA	Vrijeme izmjena alata	UVC	Ukupno vrijeme ciklusa	ADS	Sustav za automtsko donošenje i skladištenje
	PV	Proizvodno vrijeme	5S	5S alat	FK	Fazna kontrola
	DV	Dostupno vrijeme	NLS	Napredni logistički sustavi	Z	Zalihe

Status	
	VČ = 19.449 min
	UVC = 525 min

Slika 47. *Primjer mapiranja procesa izrade vratila [232]*

Slika 48. *Primjer mapiranja procesa razvoja softvera [233]*

VSM je pragmatičan alat koji utvrđuje sve aktivnosti koje dodaju ili ne dodaju vrijednost krajnjem proizvodu ili usluzi. Prilikom mapiranja toka vrijednosti dobro je prvo napraviti općenito mapiranje, a tek kasnije detaljnije ući u sve procese (vidi Sliku 47 i 48). Budući da su procesi vrlo često složeni i uključuju dobavljače, razne odjele pa čak i kupce, vrlo je teško odmah uhvatiti sve podatke i shvatiti kako procesi funkcioniraju. Stoga je vrlo važno prvo napraviti općenito mapiranje koje bi trebalo uključiti sljedeće [234]:

- definirati zahtjev kupca
- vizualizirati tok vrijednosti
- utvrditi mjesta gubitaka
- integrirati vitka načela
- definirati implementacijske timove
- prikazati vezu između toka materijala, informacija i ljudi
- odrediti vodeće vrijeme proizvodnje i svakog procesa pojedinačno.

Takvom općenitom vizualizacijom ljudi stječu percepciju o proizvodnom toku te mogu donositi protumjere i prijedloge poboljšanja. Nakon općenitog mapiranjam neki autori predlažu ulaz u problematiku proizvodnog toka na puno dubljoj razini. Tako se kod detaljnog mapiranja toka vrijednosti predlaže korištenje različitih VSM alata za detaljno mapiranje procesa. To su alati poput: *process activity mapping, supply chain response matrix, production variety funnel, quality filter mapping, demand amplification mapping, decision point analysis i physical structure mapping.* Takvi alati daju novu dimenziju pri promatranju proizvodnog toka te su poboljšanja temeljena na njima u potpunosti opravdana [234].

3.4.25. Vizualna tvornica

Svaki vitki proizvodni pogon trebao bi sadržavati jednostavne i pragmatične informacije vezane uz proizvodne aktivnosti. Koncept osnovnog informiranja radnika najčešće uključuje znakove, dijagrame, slike koje ilustriraju proizvodnju, kodiranje bojom, *andon* lampe na strojevima, rezultate poboljšanja itd. S druge strane, napredniji pristup vizualiziranja proizvodnje uključuje interaktivne multimedijske sustave za podršku u stvarnom vremenu, naprednu statističku kontrolu procesa i mrežu koja osigurava informacije svim radnicima. Cilj je vizualizacije stvoriti otvorenu kulturu u kojoj se informacije dijele i lako su dostupne svima [235].

Vizualan radni prostor morao bi sadržavati najmanje sljedeće informacije [236]:

a) STANDARDNE INFORMACIJE
    - znakovi upozorenja označeni pripadajućim bojama
    - motivacijski znakovi i slogani, organizacijska misija, vizija itd.
    - osnovni znakovi sigurnosti, što se smije, a što ne smije raditi
    - slikovni dijagrami složenih i specijalnih instalacija
    - procedure rada
    - označavanje poda različitim bojama, prema funkciji
    - informativni znakovi
    - transportni znakovi i znakovi smjera kretanja
    - higijenske upute i procedure
    - upute i procedure čišćenja
    - procedure uključivanja i isključivanja strojeva i opreme
    - procedure za označavanje strojeva koji su u kvaru (engl. *lock and tag procedures*)
    - posteri s tlocrtom radnog prostora
    - evakuacijski putovi
    - standardne postavke
    - ograničenja i zabrane na strojevima i opremi.

b) VARIJABILNE INFORMACIJE
    - radne upute za proizvodnju svakog proizvoda
    - procedure za paletiziranje svakog proizvoda
    - procedure kontrole kvalitete za različite proizvode
    - tehničke specifikacije proizvoda
    - stopa trenutne proizvodnje i ciljana ili najbolja stopa proizvodnje
    - stopa gubitaka i ciljana stopa gubitaka
    - potrošnja energenata i ciljana potrošnja energenata
    - stopa zadovoljstva kupaca i ciljana ili najbolja stopa zadovoljstva kupaca
    - stopa incidenata i ozljeda na radu te ciljana stopa incidenata i ozljeda na radu

- varijabilne postavke vezane uz proizvode
- ograničenja i zabrane vezane uz proizvodnju različitih proizvoda.

Tablica 23. *Vizualna tvornica [237]*

Radno područje ćelije	1 – informacije o radnoj ćeliji 2 – informacije o aktivnostima, resursima i proizvodima 3 – informacije o radnom timu 4 – oznake na podu 5 – polica za odlaganje alata 6 – tehničko područje 7 – područje za komunikaciju i odmor 8 – ploča s uputama i novostima 9 – mjesto gdje stoje sva potrebna sredstva za čišćenje
Vizualno dokumentiranje proizvodnje	10 – upute za proizvodnju i tehničke procedure
Vizualna kontrola proizvodnje	11 – računalo 12 – plan proizvodnje 13 – plan održavanja 14 – mjesto gdje se odlažu zalihe i WIP
Vizualna kontrola kvalitete	15 – nadzor nad radom stroja (*andon* lampa) 16 – statistička kontrola procesa (SPC) 17 – dokumentiranje abnormalnosti
Izlaganje pokazatelja	18 – ciljevi, rezultati i odstupanja
Vizualno praćenje napretka	19 – aktivnosti poboljšanja 20 – organizacijska misija i tekući projekt poboljšanja

Vizualna komunikacija od vitalne je važnost za svako poduzeće te postoji mnogo vitkih alata koji se mogu operativno izvesti kroz vizualna rješenja. Vitki alati koji podržavaju vizualnu komunikaciju su, primjerice: 5S, *andon*, standardizacija rada, TPS, ključni indikatori učinkovitosti, ERP itd. Poželjno je integrirati različite vitke alate u vizualna rješenja jer su vizualna rješenja pragmatična i jasna radnicima. Nitko ne želi kreirati proizvodni pogon pun nepotrebnih tekstova i tablica koje nitko ne čita. Učinkovita vizualna komunikacija iziskuje uporabu postera, slika, shema, simbola, transparenata i računalnih sučelja kao na Slici 49 i 50 [238].

Slika 49. *Vizualna ploča s bitnim informacijama o radnoj ćeliji [239]*

Slika 50*. Vizualno sučelje koje operatera obavještava na koji će način provesti svoj rad [240]*

4. ISTRAŽIVANJE O VITKOJ PROIZVODNJU U RH

Vitka proizvodnja se pojavila u razvijenim zemljama gotovo prije trideset godina. Pojavom ove filozofije mnoge proizvodne organizacije odbacile su načela masovne proizvodnje te su pokušala uvesti vitke alate ili prakse u svoje poslovanje. Mnoge organizacije postale su tržišni lideri zahvaljujući vitkoj filozofiji, no mnoge nisu shvatile samu srž vitke proizvodnje te su vrlo brzo pokleknule i rezultati nisu bili zadovoljavajući.

Literatura o vitkoj proizvodnji dostupna je već dugi niz godina te su mnoga poduzeća pokazala i dokumentirala postignuta poboljšanja pomoću vitkog razmišljanja. Unatoč toj činjenici, hrvatska se poduzeća nisu odvažila primijeniti vitke principe dugi niz godina. Vitka filozofija u Hrvatskoj se pojavila prije nešto više od deset godina te danas mnoga poduzeća traže način za implementaciju vitkih principa u svoje poslovanje. Implementacija vitke proizvodnje, to jest vitke filozofije, složen je, težak i dug proces koji je praćen brojnim nedoumicama, propustima i greškama ako implementacijski okvir nije pravilan. Nekoliko je studija dokazalo da poduzeća kod uvođenja vitkih alata često lutaju te imaju problema s gubitkom entuzijazma uslijed neostvarenja zadanih ciljeva. Svaka promjena kreće od vrha pa ne treba naglašavati da menadžment mora biti aktivan i posjedovati znanje za implementaciju vitke proizvodnje. Uvođenje vitke proizvodnje ima tri razine a to su strategija, taktika i operativno djelovanje. Na razini strategije vitka proizvodnja je filozofija, na razini taktike ona predstavlja načela te se na razni operativnog djelovanja ona sastoji od vitkih alata ili praksi. Svaka od tih razina je bitna te svaka od tih razina mora biti jasna i definirana kako bi ljudi mogli znati što se od njih očekuje. Ako ljudi ne znaju što menadžment od njih traži, tada ne može doći do pozitivne promjene. Strateška i taktička razina prilikom uvođenja vitke proizvodnje mora biti pomno planirana, no ona je radnicima prilično nejasna jer te dvije razine predstavljaju filozofiju i načela. Ispravna filozofija i jasna načela su odlična, no udarna točka vitke proizvodnje vitki su alati jer vidljivo pokazuju željeni smjer promjena. Stoga izbor vitkih alata predstavlja važnu stavku kod uspješne implementacije vitke proizvodnje.

Mnogo je studija pokazalo da implementacijski okvir vitke proizvodnje predstavlja ključni segment kod uspješnosti i održanja poboljšanja. Postoji preko sto vitkih alata koji su dokumentirani i pomno opisani. Svaki od tih alata djeluje na različitoj operativnoj razini te je često poželjno uvođenje seta alata za smanjenje ili eliminaciju određenog gubitka. Budući da se u Hrvatskoj vitka proizvodnja primjenjuje više od deset godina, logično je bilo istražiti koji se vitki alati najviše koriste te kojim se redoslijedom oni uvode ovisno o različitim čimbenicima. Kako bi se definirali najbolji alati i implementacijski okviri za hrvatska poduzeća, provedeno je istraživanje u kojem je cilj bio dokumentirati sve podatke vezane uz uvođenje vitkih alata.

Velik broj istraživača odustao je od tematike vezane uz redoslijed uvođenja vitkih alata jer svaka organizacija ima različitu početnu točku, financijsku moć, menadžment, okruženje itd. Stoga jedinstveni optimalni implementacijski okvir uvođenja vitkih alata ne postoji te je uvođenje

vitke filozofije potrebno prilagoditi kontekstu organizacije. Ne postoji jedinstvena „kuharica“ uvođenja vitkih alata, no postoje određene zakonitosti koje je dobro slijediti prilikom vitke tranzicije. Kako hrvatska poduzeća ne bi radila već viđene greške, provedeno je istraživanje u kojem su zabilježene moguće važne informacije vezane uz redoslijed uvođenja vitkih alata.

4.1. Općenito o istraživanju

U ovome poglavlju je opisana metodologija istraživanja i kriteriji za odabir poduzeća.

4.1.1. Metodologija istraživanja

Uvođenje vitke proizvodnje postupak je koji nikada ne završava te je vrlo teško definirati ključne faktore za uspjeh vitke implementacije. Svako poduzeće koje kreće u projekt vitke implementacije prije ili kasnije susretne se s vitkim alatima te mora odlučiti s kojim će alatima krenuti u vitku transformaciju. Kako bi se dokumentirali svi bitni čimbenici vezani uz izbor vitkih alata, provedeno je istraživanje u hrvatskim poduzećima koja primjenjuju vitku filozofiju. Istraživanje je provedeno u obliku ankete koja se sastojala od četiriju cjelina. Svaka od tih cjelina bila je zamišljena na način da otkrije određene elemente implementacije vitkih alata. Te četiri cjeline bile su koncipirane na način da se dobiju sljedeći podaci:

1) Prva cjelina ankete bila je sastavljena na način da dokumentira sve bitne informacije vezane uz strateške i taktičke odluke koje je menadžment donio prije uvođenja vitkih alata. Tako su dokumentirani motivi, ciljevi, vrsta restrukturiranja te početak primjene vitke proizvodnje. Ovaj dio ankete temelji se na istraživanju provedenom u Velikoj Britaniji (Bhasin, 2012).
2) Druga cjelina bila je koncipirana na način da se prikaže stanje poduzeća prije vitke implementacije. Anketirana poduzeća rangirala su gubitke u svom okruženju prije početka primjene vitke proizvodnje. Snimljeni gubitci kasnije su bili kategorizirani u određene skupine iz kojih je bilo moguće iščitati koje su vrste gubitaka najprisutnije.
3) Treća cjelina ankete bila je koncipirana na način da je dan pregled 25 temeljnih vitkih alata te su ispitanici zaokružili alate koje su implementirali i dali svoje mišljenje o tome je li navedeni alat imao pozitivan učinak. Kako bi se snimio tijek vitke implementacije, ispitanici su ispunili Ganttov dijagram u kojem su napravili redoslijed uvođenja vitkih alata. Primarni cilj Ganttovog dijagram bilo je vidjeti koji se alati ili parovi alata koriste u ranim, srednjim i kasnim fazama vitke transformacije.
4) Zadnja cjelina zamišljena je kao povratna veza o uspješnosti vitke implementacije. Anketirana poduzeća rangirala su svoje gubitke nakon vitke transformacije. Ova cjelina vrlo je slična drugoj te daje uvid u smanjenje ili eliminaciju pojedinog gubitka.

Ta je anketa provedena na području Republike Hrvatske krajem 2017. i početkom 2018. godine. Početna ideja bila je pronaći jednak broj malih, srednjih i velikih vitkih poduzeća te usporediti njihove implementacijske okvire, no vrlo se brzo došlo do zaključka da su srednja i velika poduzeća najveći korisnici vitke filozofije. Ispitanici su bili vlasnici, top menadžeri ili ljudi usko vezani uz razvoj poslovanja te je time osigurana veća vjerodostojnost podataka jer je anketa temeljena na subjektivnom mišljenju anketiranih osoba.

4.1.2. Kriteriji za odabir poduzeća

Vitka proizvodnja nije općeprihvaćeni model poslovanja na području Republike Hrvatske te velik broj poduzeća nije nikada čuo za vitku filozofiju. Kako bi se utvrdila potencijalna vitka poduzeća napravljeni su sljedeći koraci:

1) U Hrvatskoj postoji samo jedna važna konferencija o vitkoj proizvodnji koja se održava jedanput godišnje. Navedena konferencija je GALP konferencija (*Green and Lean Production*) te je prvo utvrđivanje vitkih poduzeća napravljeno upravo na GALP konferenciji koja se održala krajem 2017. godine. Ovu konferenciju pohađalo je gotovo 150 ljudi iz različitih poduzeća u kojima se većina koristi ili se sprema uvesti vitku filozofiju. Na samoj konferenciji bilo je prisutno gotovo četrdeset poduzeća te je anketa predstavljena i podijeljena svim sudionicima ove konferencije. Ovim načinom prikupljeni su podaci iz 18 vitkih poduzeća koja se aktivno koriste vitkom filozofijom. Potrebno je naglasiti da je kasnijom analizom utvrđeno da su ovo najuspješnija poduzeća u primjeni vitke filozofije.
2) Drugo prikupljanje podataka napravljeno je uz pomoć Hrvatske gospodarske komore jer ova ustanova aktivno organizira prezentacije o vitkoj proizvodnji. Kontaktirane su podružnice u svim hrvatskim županijama te su zamoljene da pošalju podatke o poduzećima koja su bila prisutna na radionicama o vitkoj proizvodnji. Ovim načinom kontaktirano je gotovo sedamdeset poduzeća te je 13 poduzeća potvrdilo da se koristi vitkom proizvodnjom. Svih 13 poduzeća ispunilo je anketu te dalo iscrpne informacije o svojoj vitkoj tranziciji.
3) Zadnja faza prikupljanja podataka bila je izvedena na način da se utvrde najuspješnija hrvatska poduzeća u pojedinim županijama. Budući da je najčitaniji poslovni portal u Hrvatskoj *poslovni.hr* te da ovaj portal objavljuje popis najuspješnijih hrvatskih poduzeća po županijama, on je odabran za utvrđivanje daljnjih vitkih poduzeća. Kontaktirano je gotovo dvjesto poduzeća te su 32 poduzeća izjavila da se koriste vitkom filozofijom. Budući da većina poduzeća nije otvorena za ispunjavanje anketa te je vrlo teško doći do top menadžera kao anonimna osoba, većina ispitanika bila je upoznata s anketom kroz iste poznanike ili poslovne suradnike te su ispitanici time imali veću obvezu da ispune anketu i daju uistinu važne podatke. Ovim su načinom prikupljene 32 uspješno ispunjene ankete.

Istraživanje je trajalo gotovo godinu dana te je kontaktirano nešto više od 300 poduzeća. Prikupljeni su podaci o implementaciji vitkih alata u 63 poslovna subjekta. Daljnje utvrđivanje vitkih poduzeća bilo bi teško jer ne postoji niti jedan odgovarajući način za daljnje utvrđivanje vitkih poduzeća.

4.2. Rezultati istraživanja

Općenito gledajući, 20 % kontaktiranih poduzeća koristi se vitkom proizvodnjom. Kada bismo taj podatak gledali s odmakom od kriterija za utvrđivanje vitkih poduzeća, rekli bismo da je vitka proizvodnja uzela maha na području RH. No, znajući kriterije za utvrđivanje vitkih poduzeća, može se reći da vitka proizvodnja tek uzima maha na poslovnoj sceni. Istraživanje je bilo usmjereno na što brže otkrivanje vitkih poduzeća te su, unatoč tome, samo 63 poduzeća izjavila da uistinu primjenjuju vitke alate.

4.2.1. Opći podaci o anketiranim vitkim poduzećima

Istraživanje je provedeno na način da ispitanici daju podatke o svome poduzeću, ali ne i o njima samima. Sačuvana je anonimnost ispitanika kako bi podaci bili što objektivniji i kako bi zorno prikazali stanje prije i nakon vitke implementacije. Ispitanici su u anketi naveli ime, djelatnost i veličinu svog poduzeća, no kako bi se smanjile greške uslijed subjektivne klasifikacije veličine poduzeća, napravljena je dodatna provjera poslovnih subjekata o veličini poduzeća. Dodatna provjera o veličini poduzeća provedena je na internetskoj stranici Financijske agencije (FINA) te su ispravljene moguće greške uslijed subjektivne klasifikacije veličine poduzeća.

Prema važećem Zakonu o računovodstvu poduzetnici se svrstavaju u četiri kategorije, a to su mikro, mali, srednji i veliki poduzetnici. Pokazatelji na temelju kojih se poduzetnici razvrstavaju su:

- iznos ukupne aktive
- iznos prihoda i
- prosječan broj radnika tijekom poslovne godine.

Mikro poduzetnici oni su koji ne prelaze granične pokazatelje u dva od sljedeća tri uvjeta:

- ukupna aktiva od 2.600.000 kuna
- prihod od 5.200.000 kuna
- prosječan broj radnika tijekom poslovne godine – 10 radnika.

Mali poduzetnici oni su koji nisu mikro poduzetnici i ne prelaze granične pokazatelje u dva od sljedeća tri uvjeta:

- ukupna aktiva od 30.000.000 kuna
- prihod od 60.000.000 kuna
- prosječan broj radnika tijekom poslovne godine – 50 radnika.

Srednji poduzetnici oni su koji nisu ni mikro, ni mali poduzetnici i ne prelaze granične pokazatelje u dva od sljedeća tri uvjeta:

- ukupna aktiva od 150.000.000 kuna
- prihod od 300.000.000 kuna
- prosječan broj radnika tijekom poslovne godine – 250 radnika.

Veliki poduzetnici oni su koji prelaze granične pokazatelje u najmanje dva od tri sljedeća uvjeta:

- ukupna aktiva veća od 150.000.000 kuna
- prihod veći od 300.000.000 kuna
- prosječan broj radnika tijekom poslovne godine veći od 250 radnika.

U ovome su istraživanju kontaktirane tri kategorije poduzeća. No najveći broj utvrđenih vitkih poduzeća spada u kategoriju srednjih i velikih poduzeća (vidi Sliku 51). Kako bi se dobio uvid u zastupljenost poduzeća prema broju zaposlenih, potrebno je pogledati najnovije podatke Državnog zavoda za statistiku (DZS) Republike Hrvatske u vrijeme provođenja ankete o vitkim alatima. Struktura poduzeća prema broju zaposlenih prikazana je u Tablici 24.

Slika 51. *Struktura anketiranih vitkih poduzeća prema veličini*

Tablica 24. *Broj vitkih poduzeća prema veličini*

	Broj poduzeća				
IZVOR PODATAKA	Mikro (1 – 9)	Mala (10 – 49)	Srednja (50 – 249)	Velika (250 i više)	Ukupno
DZS 31.12.2017.	135002	11683	3152	564	150401
Vitka poduzeća prema istraživanju	0	12	27	24	63
Utvrđeno istraživanjem %	0,000 %	0,103 %	0,857 %	4,255 %	0,042 %

Važno je napomenuti da 60000 hrvatskih mikro poduzeća nema niti jednog zaposlenika te su u istraživanju takve tvrtke bile u potpunosti izostavljene. Već je ranije rečeno da je u ovome istraživanju kontaktirano nešto više od 300 poduzeća te su kriteriji za pronalazak potencijalnih vitkih poduzeća bili postavljeni na način da utvrđivanje bude što brže i relevantnije. Takav kriterij otkrivanja vitkih poduzeća osigurao je brzinu, no moguće je da su neka mala poduzeća koja se koriste vitkom filozofijom izostavljena. Anketiranje mikro i malih poduzeća nije bilo u primarnom fokusu jer su mnoge studije pokazale da takve tvrtke imaju malu financijsku snagu te su ograničene u pogledu uvođenja određenih vitkih alata. Ovo istraživanje temeljilo se na pronalasku modela za uvođenje vitkih alata pa je bilo bitno utvrditi koje su tvrtke u mogućnosti implementirati financijski zahtjevne vitke alate.

Vitka proizvodnja nastala je u industriji koja proizvodi gotove fizičke proizvode te se s vremenom raširila u ostale industrijske grane u kojima se proizvod ne proizvodi ili nije fizički opipljiv. Budući da se gospodarstvo svake države dijeli u četiri osnovna sektora, na Slici 52. i 53. može se vidjeti da najveći broj hrvatskih vitkih poduzeća dolazi upravo iz sekundarnog sektora koji se veže uz proizvodnju gotovih proizvoda.

Slika 52. *Sektor djelatnosti vitkih poduzeća*

Slika 53. *Sektor djelatnosti vitkih poduzeća*

4.2.2. Klasifikacija vitkih poduzeća prema djelatnosti

Prema važećoj Nacionalnoj klasifikaciji djelatnosti (NKD) RH iz 2007. godine sljedeća su područja djelatnosti:

A. Poljoprivreda, šumarstvo i ribarstvo
B. Rudarstvo i vađenje
C. Prerađivačka industrija
D. Opskrba električnom energijom, plinom, parom i klimatizacija
E. Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša
F. Građevinarstvo
G. Trgovina na veliko i na malo; popravak motornih vozila i motocikala
H. Prijevoz i skladištenje
I. Djelatnosti pružanja smještaja te pripreme i usluživanja hrane
J. Informacije i komunikacije
K. Financijske djelatnosti i djelatnosti osiguranja
L. Poslovanje nekretninama
M. Stručne, znanstvene i tehničke djelatnosti
N. Administrativne i pomoćne uslužne djelatnosti
O. Javna uprava i obrana; obvezno socijalno osiguranje
P. Obrazovanje
Q. Djelatnosti zdravstvene zaštite i socijalne skrbi
R. Umjetnost, zabava i rekreacija
S. Ostale uslužne djelatnosti
T. Djelatnosti kućanstva kao poslodavca; djelatnosti kućanstava koja proizvode različitu robu i obavljaju različite usluge za vlastite potrebe
U. Djelatnosti izvan teritorijalnih organizacija i tijela.

Sve navedene djelatnosti sastoje se od odjeljka, skupine i razreda te je za analizu vitkih poduzeća u obzir uzet samo odjeljak djelatnosti jer je uzorak vitkih poduzeća premal da bi se sagledavalo dalje od odjeljka. Prema provedenom istraživanju na području RH vitki koncept najprisutniji je u prerađivačkoj industriji (vidi Sliku 54). Vitki koncept svoje je početke u razvijenom svijetu napravio upravo u prerađivačkoj industriji pa je bilo očekivano da hrvatska prerađivačka industrija bude pionir i najveći korisnik vitke proizvodnje.

Slika 54. *Područja djelatnosti vitkih poduzeća*

Prerađivačka industrija ima značajno mjesto u svakom gospodarstvu pa je konkurencija u ovoj industriji golema. Poslovni subjekti ove industrije međusobno se natječu za potrošače te su u stalnoj potrazi da zadovolje tržišne potrebe i želje te u krajnosti stvore što veći profit. Upravo je profit pokretač tržišne ekonomije pa poduzeća traže sva dozvoljena i nedozvoljena sredstva za stvaranje profita. Vitka filozofija dokazano je sredstvo za optimalno upravljanje poslovanjem, a neka hrvatska poduzeća prepoznala su ovaj model kao priliku za povećanje profita pomoću raznih načela i alata. Prerađivačka industrija vrlo je širok pojam, a pod nju spada proizvodnja hrane i pića, automobila i zrakoplova, kemijskih proizvoda, metala, naftnih prerađevina, odjeće, računala i dr. U zapadnom svijetu vitki koncept prvo se pojavio u automobilskoj industriji te se iz te industrije proširio na druge grane gospodarstva. Budući da Hrvatska nema automobilsku industriju, bilo je očekivano da pionir vitke filozofije u prerađivačkoj industriji bude djelatnost usko vezana uz ili slična automobilskoj industriji. Tako je sa Slike 55. vidljivo da je industrija proizvodnje gotovih metalnih proizvoda vodeći korisnik vitkog koncepta. Najčešće dokumentirane i opisane vitke prakse odnose se na prerađivačku industriju pa je očekivano da industrija koja ima najbolje dokumentirane vitke prakse bude inicijalni korisnik ove filozofije. Isto tako, ne treba zanemariti činjenicu da je većina hrvatske vitke literature, ako se to tako može nazvati, vezana uz prerađivačku industriju. Jednostavnije rečeno, ostalim industrijama teško je vidjeti snagu vitke proizvodnje ako nema dokumentiranih praksi o vitkoj proizvodnji u njihovoj djelatnosti.

Slika 55. *Odjeljak djelatnosti hrvatskih vitkih poduzeća*

4.2.3. Duljina primjene vitke proizvodnje u RH

Vitka proizvodnja je koncept poslovanja koji se u RH koristi unazad pet godina te mnogobrojna mala poduzeća još uvijek nisu došla u doticaj s ovom filozofijom. Pojedina poduzeća u RH primjenjuju vitku proizvodnju već više od pet godina, no sa Slike 56. i 57. vidljivo je da vitka filozofija uzima sve više i više maha.

Slika 56. *Koliko se dugo vitki koncept primjenjuje u pojedinim hrvatskim poduzećima*

Poduzeća koja su, takoreći, starosjedioci u primjeni vitke filozofije većinom su tržišni lideri ili su visoko usmjereni na inozemna tržišta. Najveće zanimanje za vitku proizvodnju pokazala je prerađivačka industrija pa su poduzeća koja primjenjuju vitku filozofiju više od pet godina manje-više iz te industrije. Na Slici 57. jasno se vidi da postoji pojačano zanimanje za vitkim konceptom posljednjih godina. Sve veći broj poslovnih subjekata prepoznaje snagu vitkog koncepta te pokušava integrirati vitke principe i alate u svoje poslovanje. Možda je najveći problem, koji koči još veći prodor vitkog koncepta na hrvatsko tržište, povezan s malim brojem vitke literature na hrvatskom jeziku. Vrlo je teško shvatiti vitku filozofiju i krenuti na vitko putovanje bez znanja o vitkoj implementaciji. Srednje velika i velika poduzeća najveći su korisnici vitke proizvodnje, što je logično, jer imaju širok kadar visokoobrazovnog osoblja koji može premostiti nedostatak vitke literature na hrvatskom jeziku. Takva poduzeća ne samo da imaju kadar, već i kapital koji će pratiti vitko obrazovanje i implementaciju. Gotovo 98 % hrvatskog gospodarstva čine mikro i mala poduzeća, no takva poduzeća ne kreću na vitko

putovanje. Vitka proizvodnja vjerojatno će imati još veći odjek u RH ako njezine prednosti u budućnosti budu dokumentirane i pravilno predstavljene malom poduzetništvu. Jednostavno rečeno, bez znanja o vitkom konceptu nema ni vitkih poduzeća.

Slika 57. *Rast primjene vitke filozofije u hrvatskim poduzećima*

4.2.4. Motivi za uvođenje vitke proizvodnje u RH

Implementacija vitke proizvodnje mukotrpan je posao koji zahtijeva drastične kulturološke promjene, a okidači za kretanje na vitko putovanje su razni. Kako bi se saznali glavni okidači za kretanje na vitko putovanje u hrvatskim poduzećima, ispitanicima su ponuđeni odgovori o njihovim motivima za primjenu vitkog koncepta. Budući da je slično istraživanje provedeno u poduzećima u Velikoj Britaniji, mogući odgovori preuzeti su iz tog istraživanja te su ispitanici mogli zaokružiti više odgovora. Navedeno istraživanje iz kojeg su precrtani odgovori ono je Bhasina S. objavljeno 2012. godine pod nazivom „An appropriate change strategy for lean success“ u prestižnom međunarodnom časopisu „Management Decision“.

Najveći motiv za kretanje na vitko putovanje kod hrvatskih poduzeća općenito je bila želja da se poveća učinkovitost, što je vidljivo na Slici 58. Kada govorimo o učinkovitosti, ona je u ovom istraživanju bila precizirana povećanjem učinkovitosti, produktivnosti i profita. Ostali važni

razlozi za kretanje na vitko putovanje predstavljanje su vitkog koncepta od strane skupine ljudi unutar poduzeća, viđeni rezultati u drugim poduzećima i želja za povećanjem timskog duha i motivacije.

Slika 58. *Glavni motivi za primjenu vitkog koncepta u hrvatskim poduzećima*

4.2.5. Vrste restrukturiranja koje se provode vitkom proizvodnjom u RH

Tržište je nepredvidivo, dinamično i potrebe se mijenjaju iz dana u dan. Postoje različiti poslovni modeli za hvatanje ukorak s tržištem. Jedan od takvih poslovnih modela je i vitka proizvodnja. Kada poduzeće pokušava promijeniti svoj poslovni model, tada sa sigurnošću možemo reći da ulazi u fazu restrukturiranja.

Restrukturiranje je proces čiji je cilj povećanje tržišne vrijednosti tvrtke na način da se implementiraju aktivnosti koje će poboljšati cjelokupno poslovanje. Ono što se često miješa s pojmom restrukturiranja je reprogramiranje, stoga je potrebno razjasniti osnovnu razliku između tih dvaju pojmova. Restrukturiranje se čini dobrovoljno na poticaj same organizacije, dok je reprogramiranje manje dobrovoljno i najčešće se odvija na poticaj kreditora. Restrukturiranje se općenito prepoznaje kroz značajne promjene u upravi, financijama, poslovnim procesima, kapacitetima, organizacijskoj strukturi itd.

Općenito govoreći, postoje tri vrste restrukturiranja:

1. FINANCIJSKO – za poduzeća koja imaju problem s likvidnošću i ispunjavanjem obveza
2. OPERATIVNO – za poduzeća koja imaju problem s učinkovitošću
3. STRATEŠKO – za poduzeće koja imaju problem s rastom i osvajanjem tržišta.

U posljednjih deset godina hrvatsko tržište bilo je prilično turbulentno te su mnogi tržišni lideri ušli u predstečajne nagodbe uslijed nemogućnosti plaćanja dospjelih obveza. Većina tih tvrtki nakon dokapitalizacije tražila je određeni poslovni model kojim će restrukturirati svoje poslovanje. Neke od takvih tvrtki primijenile su vitki koncept za optimizaciju svog poslovanja pa je bilo logično dokumentirati organizacijska razmišljanja prilikom uvođenja vitke filozofije. Anketirana vitka poduzeća mogla su zaokružiti više odgovora te su rezultati prilično zanimljivi. Tako većina hrvatskih vitkih poduzeća primjenom vitkog koncepta pokušava napraviti operativno ili još, uz operativno, radi i strateško restrukturiranje.

Slika 59. *Vrste restrukturiranja za koje se koristi vitki koncept u RH*

4.2.6. Ciljevi prilikom uvođenja vitke proizvodnje u RH

Svako poduzeće ima vlastite kratkoročne i dugoročne ciljeve prilikom reorganizacije poslovanja. Kako bi se otkrile želje i ciljevi poduzeća koja su krenula na vitko putovanje, u jednom od anketnih pitanja ispitanici su prikazali svoje ciljeve. Budući da je slično istraživanje provedeno u poduzećima u Velikoj Britaniji, mogući su odgovori preuzeti iz tog istraživanja te su ispitanici mogli zaokružiti više odgovora. Navedeno istraživanje iz kojeg su precrtani odgovori ono je

Bhasina S. objavljeno 2012. godine pod nazivom „An appropriate change strategy for lean success“ u prestižnom međunarodnom časopisu „Management Decision“.

Prema ispitanicima hrvatska vitka poduzeća većinom žele povećati učinak, profitabilnost, produktivnost, eliminirati gubitke i poboljšati učinkovitost zaposlenika. Ovaj dio ankete vrlo je važan jer on zorno pokazuje misaoni sklop organizacije.

Slika 60. *Ciljevi koji se žele postići uvođenjem vitke filozofije*

4.2.7. Gubitci u hrvatskim poduzećima prije uvođenja vitke proizvodnje

Implementacija novog poslovnog modela može i ne mora biti uspješna. Prilikom uvođenja vitkog koncepta svaka bi organizacija trebala dokumentirati svoje trenutno stanje te bi trebale biti istaknute najslabije točke poslovanja. Tek kada su istaknute najslabije točke, menadžment može pristupiti rješavanju problema.

Vitka proizvodnja kao poslovni model može djelovati u jednom ili više smjerova te je važno odrediti prioritete kako bi očekivanja bila ostvarena. Jedan od najvažnijih smjerova djelovanja vitkog koncepta je eliminacija gubitaka. Budući da se gubitci u vitkoj proizvodnji najčešće razvrstavaju u osam skupina te je svaku skupinu moguće detaljnije precizirati u podskupinama, ovo istraživanje fokusiralo se upravo na dokumentiranje i eliminaciju gubitaka implementacijom vitkih alata. Tablica 25. predstavlja osam vitkih gubitaka i vrste gubitaka koje su povezane s tom kategorijom gubitka. Iz Tablice 25. moguće je vidjeti da većina vitkih poduzeća smatra da ima problem s nedovoljnom iskorištenosti zaposlenika, škartom, nepotrebnim zalihama i prekomjernim transportom. Podaci dobiveni iz 63 poduzeća općenito ukazuju na to da su gubitci u hrvatskim poduzećima prije primjene vitke proizvodnje bili srednji ili mali, a veliki gubitci prisutni su u relativno malom broju slučajeva.

Ovaj dio istraživanja prvotno je zamišljen na način da se dokumentira stanje u poduzećima prije primjene vitkog koncepta te da se u kasnijim koracima napravi analiza postignutih poboljšanja prema svim kategorijama i potkategorijama gubitaka. Podaci o gubitcima bili su kvantificirani skalom od 0 – 3 na sljedeći način:

- 0 – nema gubitaka
- 1 – mali gubitci
- 2 – srednji gubitci
- 3 – veliki gubitci.

Svi gubitci bili su brojčano kvantificirani te su se kasnije obrađivali prema kategoriji gubitka. Budući da su gubitke ocjenjivali ispitanici, potrebno je naglasiti da je takvo dokumentiranje subjektivno i podložno individualnim stajalištima. Svi su ispitanici dolazili iz vrhovnog ili srednjeg menadžmenta, čime se nastojala postići što veća objektivnost podataka.

Tablica 25. *Vrste i veličine gubitaka u poduzećima prije uvođenja vitke proizvodnje*

Rang	Vrsta gubitka	Opis gubitka	Nema gubitaka	Mali gubitci	Srednji gubitci	Veliki gubitci
7	Prekomjerna proizvodnja	Stvaranje proizvoda ili usluga koje se ne mogu plasirati na tržište	43 %	37 %	19 %	2 %
		Izvođenje operacija koje nisu nužne	2 %	56 %	33 %	10 %
		Prekomjerna administracija	8 %	35 %	37 %	21 %
		Loša procjena zahtjeva tržišta	19 %	46 %	30 %	5 %
		Proizvodnja „za svaki slučaj“	32 %	30 %	27 %	11 %
4	Prekomjeran transport	Nepotrebno kretanje materijala između operacija ili skladišta	16 %	35 %	40 %	10 %
		Neučinkovit prijenos informacija	3 %	30 %	52 %	14 %
		Neuspješna komunikacija: nepouzdanost ili gubitak podataka	8 %	41 %	37 %	14 %
5	Čekanje	Vrijeme čekanja između operacija	5 %	41 %	37 %	17 %
		Loše planiranje proizvodnje i procesa	8 %	32 %	44 %	16 %
		Čekanje na odobrenje ili potpis	25 %	44 %	16 %	14 %
		Nepravovremena isporuka dobavljača	11 %	33 %	38 %	17 %
8	Prekomjerna obrada	Nepouzdana ili kriva tehnološka oprema	37 %	38 %	21 %	5 %
		Loša konstrukcija proizvoda koja zahtijeva puno koraka obrade	35 %	27 %	32 %	6 %
3	Nepotrebne zalihe	Velike zalihe na skladištima – „zamrznuti kapital“	17 %	27 %	37 %	19 %
		Velike količine nepotrebnih podataka u arhivi	8 %	35 %	38 %	19 %
6	Nepotrebni pokreti	Loš raspored strojeva koji rezultira nepotrebnim kretanjem radnika	22 %	44 %	21 %	13 %
		Kretanje ljudi kako bi došli do informacija	13 %	49 %	27 %	11 %
		Loša ergonomija radnog mjesta	14 %	48 %	24 %	14 %
2	Škart	Prekid toka proizvodnje radi loših ili nepotpunih informacija	14 %	33 %	41 %	11 %
		Vrijeme otklanjanja pogrešaka	10 %	27 %	37 %	27 %
1	Nedovoljna iskorištenost potencijala zaposlenika	Nedovoljno korištenje potencijala zaposlenika	5 %	41 %	32 %	22 %
		Slabo prepoznavanje sposobnih zaposlenika	5 %	46 %	33 %	16 %
		Nedovoljno uključenje radnika u procese poboljšanja	2 %	38 %	40 %	21 %

4.2.8. Implementacija vitkih alata u hrvatskim poduzećima

Prilikom uvođenja vitke proizvodnje svako poduzeće prije ili kasnije dođe do vitkih alata. Kao što je već rečeno danas postoji preko sto vitkih alata pa je odabir pravog vitkog alata zbunjujuć i težak zadatak. Cijela vitka priča lijepo je zapakiran poslovni model, ali operativno provođenje vitke proizvodnje zna biti zamršen proces. Svaka implementacija LP-a podrazumijeva uvođenje određenih vitkih alata, stoga vitki alati igraju bitnu ulogu kod brzine, uspješnosti i održivosti vitke implementacije. Budući da je srž ovog istraživanja bila pronaći najpogodniji implementacijski put uvođenja vitkih alata, neizbježno je bilo vidjeti koji su vitki alati najzastupljeniji u hrvatskim poduzećima. Stoga iz Tablice 26. vidimo da se neki vitki alati koriste češće kod vitkog poslovanja, što jasno ukazuje na činjenicu da takvi alati nailaze na plodno tlo u hrvatskim poduzećima.

Tablica 26. *Vitki alati koji su prisutni u hrvatskim poduzećima*

Rang	Vitki alat	Zastupljenost
1	**Standardizacija rada**	61,9 %
2	**5S** (uređenje prostora)	58,7 %
3	***Kaizen*** (kontinuirano poboljšanje)	58,7 %
4	**Ključni indikatori učinkovitosti**	55,6 %
5	**VSM** (mapiranje toka vrijednosti)	47,6 %
6	**Analiza uskih grla**	46,0 %
7	**Pametni ciljev**i (konkretni, mjerljivi, dostižni…)	44,4 %
8	**Vizualna tvornica**	39,7 %
9	**JIT** (proizvodnja bez zaliha)	36,5 %
10	***Muda*** (uklanjanje gubitaka)	33,3 %
11	**SMED** (brza izmjena alata)	33,3 %
12	**TPM** (cjelovito produktivno održavanje)	33,3 %
13	**Kontinuirani tok** (proizvodnja bez zastoja)	31,7 %
14	***Hoshin kanri*** (politika razvoja)	31,7 %
15	**Analiza glavnog uzroka**	30,2 %
16	***Jidoka*** (djelomična automatizacija)	28,6 %
17	***Gemba*** (problemi se moraju vidjeti iz „prve ruke“)	25,4 %
18	***Kanban*** (metoda za regulaciju robe i zaliha)	23,8 %
19	**Taktno vrijeme** (usklađenje proizvodnje i zahtjeva kupaca)	22,2 %
20	**OEE** (cjelokupna učinkovitost opreme)	20,6 %
21	**PDCA** (metoda planiraj – učini – provjeri – djeluj)	20,6 %
22	***Poka-yoke*** (sustav za detekciju grešaka)	19,0 %
23	***Andon*** (vizualni sustav pogona)	12,7 %
24	***Heijunka*** (niveliranje proizvodnje)	9,5 %
25	**Šest velikih gubitaka** (kategorizacija gubitaka)	7,9 %

Budući da je učestalost pojave vitkih alta u poduzećima tek jedan spektar vitke implementacije, važno je bilo istraživanjem obuhvatiti i druge aspekte vitkih alata. Znatan broj poduzeća implementira određeni vitki alat ili praksu te ta praksa ne ispuni prvotna očekivanja. Korijen takvog problema može biti različit, od toga da je za određeni problem ili gubitak primijenjen krivi alat, do toga da je znanje ili vještina uvođenja vitkog alata nezadovoljavajuća i pogrešna. Kako bi se dobio uvid u učinak 25 temeljnih vitkih alata, ispitanike se nakon pitanja o vitkim alatima koji se koriste pitalo je li taj alat doveo do bilo kakvog poboljšanja. Tako se iz Slike 61. vidi da su neki vitki alati u većem broju slučajeva doveli do poboljšanja, ali su isto tako neki alati u određenim situacijama bili loš implementacijski izbor.

Slika 61. *Pozitivan utjecaj vitkih alata*

Jednostavno je vidljivo i neizbježno iz Slike 61. da poduzeća nekada vitke alate uvode nasumično, što jasno ukazuje na činjenicu da je potrebno stvoriti model najpogodnijih vitkih alata za određene organizacijske gubitke. Pogrešno određeni problemi dovode do lošeg odabira kompleta vitkih alata pa je poželjno da poduzeće prije implementacije vitke filozofije prepoznaje svoje prioritete te se u skladu s time postavljaju kratkoročni i dugoročni ciljevi. Misija, vizija, politika razvoja i slične dogme ne smiju biti krute odredbe koje zaposlenici ne razumiju i ne primjenjuju u svakodnevnom poslovanju. Menadžment u dogovoru sa svim zaposlenicima mora utvrditi probleme i saslušati sva mišljenja u vezi pronalaženja mogućeg rješenja. Krivo određeni problemi dovode do loše primjene vitkih alata.

Postoji velik broj vitkih alata, a općenito govoreći, veći broj održivih implementiranih vitkih alata znači vitkije poslovanje. Neki su alati financijski i vremenski zahtjevniji, a neki moraju ispunjavati određene preduvjete kako bi alat bio uspješno i održivo uveden. Često je za uvođenje određenog vitkog alata nužno imati već uveden komplet određenih vitkih alata kako bi novi alat bio uveden s optimalnim rezultatom. Kako bi se dobio uvid u implementacijski okvir uvođenja vitkih alata, ispitanici u ovom istraživanju zamoljeni su da ispune svojevrstan Ganttov dijagram uvođenja vitkih alata. Budući da različita poduzeća imaju različite financijske i kadrovske resurse, uvođenje određenog alata u jednom poduzeću može trajati kraće, dok u drugom može trajati dulje. Ispitanicima je bila ponuđena tablica s 25 vitkih alata i 15 koraka implementacije, u kojoj su za svaki korak davali informacije o vitkim alatima koje su primijenili u tom koraku. Ovo se istraživanje nije bavilo vremenskim trajanjem uvođenja vitkih alata, već samo redoslijedom uvođenja jer implementacijsko razdoblje alata ovisi o različitim čimbenicima. Tako se iz Tablice 27. vidi da je učestalost pojave određenih alata veća u određenim implementacijskim koracima pa je za naslutiti da se takve prakse trebaju dokumentirati i analizirati.

Većina organizacija uvođenje vitke proizvodnje provodi u nekoliko implementacijskih koraka, gdje je svaki korak obilježen pokušajem uvođenja jednog ili više vitkih alata. Ono što svakako treba naglasiti to je da sigurno postoje i neki drugi alati koje su hrvatska poduzeća primijenila tijekom vitke transformacije, no ti alati nisu dokumentirani u ovom istraživanju. Obuhvaćeni alati ovim istraživanjem predstavljaju okosnicu vitke proizvodnje, no pojava drugih alata tijekom vitke implementacije nije neizostavna.

Tablica 27. ne prikazuje samo učestalost pojave određenih vitkih praksi u pojedinim transformacijskim etapama, već ona daje cjelokupan uvid u složenost vitke filozofije. Ono što je kristalno jasno iz Tablice 27. to je da ne postoji jedinstveno rješenje ili optimalni redoslijed uvođenja vitkih alata za sve organizacije. Međutim, u Tablici 27. daljnjom je analizom moguće pronaći implementacijske prakse koje su kvalitetne i koje vode bržem napretku. Kao što se niti jedan vitki alat ne može jednoznačno promatrati kao štura procedura, tako se niti jedan implementacijski okvir ne može doslovno precrtavati s jednog poslovnog subjekta na drugi. Kako bi organizacija što bezbolnije provela vitku filozofiju, potrebno je imati kadar koji dubinski razumije i poznaje sve aspekte organizacijskog poslovanja te bi taj kadar trebao biti sposoban adaptirati vitke alate za potrebe navedenog poduzeća. Ako se vitki alati šturo precrtavaju iz

drugih organizacija, poboljšanja će biti kratkog vijeka i održivost samog koncepta bit će upitna. Tablica 27. nije implementacijska „kuharica“ vitke proizvodnje, već je to dokumentirano razmišljanje vitkih poduzeća. Upravo to dokumentirano razmišljanje trebalo bi budućim vitkim praktičarima olakšati pri redoslijedu odabira vitkih alata da ostvare ciljeve koji su pred njih postavljeni.

Većina novijih istraživanja o implementaciji vitke proizvodnje poziva se upravo na postojanje implementacijskog okvira tijekom kretanja na vitko putovanje. Isto tako, većina novijih istraživanja poziva se na to da implementacija vitke proizvodnje mora biti izvedena u obliku projektnog pristupa. Vitki praktičari pritom se stvorenog implementacijskog okvira ne smiju držati kao „pijan plota“, već je potrebno stalno preispitivati smjer kretanja i analizirati povratne informacije.

Tablica 27. *Redoslijed uvođenja vitkih alata prema ispitanicima*

Vitki alat	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
5S (uređenje prostora)	49 %	22 %	19 %	8 %	0 %	3 %	0 %	0 %	0 %	0 %	0 %	0 %	0 %	0 %	0 %
Andon (vizualni sustav pogona)	0 %	13 %	25 %	25 %	13 %	13 %	0 %	0 %	0 %	0 %	13 %	0 %	0 %	0 %	0 %
Analiza uskih grla	7 %	34 %	14 %	14 %	24 %	7 %	0 %	0 %	0 %	0 %	0 %	0 %	0 %	0 %	0 %
Kontinuirani tok (proizvodnja bez zastoja)	5 %	25 %	0 %	15 %	15 %	15 %	5 %	5 %	5 %	5 %	5 %	0 %	0 %	0 %	0 %
VSM (mapiranje toka vrijednosti)	23 %	27 %	27 %	3 %	7 %	3 %	7 %	0 %	3 %	0 %	0 %	0 %	0 %	0 %	0 %
Heijunka (niveliranje proizvodnje)	0 %	0 %	17 %	0 %	33 %	17 %	0 %	0 %	33 %	0 %	0 %	0 %	0 %	0 %	0 %
Hoshin kanri (politika razvoja)	15 %	5 %	15 %	15 %	25 %	0 %	10 %	10 %	0 %	0 %	0 %	0 %	0 %	5 %	0 %
Jidoka (parcijalna automatizacija)	11 %	33 %	11 %	11 %	17 %	0 %	6 %	6 %	0 %	0 %	0 %	0 %	0 %	6 %	0 %
JIT (pravovremena proizvodnja)	9 %	0 %	17 %	22 %	4 %	4 %	17 %	4 %	9 %	4 %	4 %	4 %	0 %	0 %	0 %
Kaizen (kontinuirano poboljšanje)	41 %	24 %	11 %	19 %	0 %	0 %	3 %	0 %	0 %	3 %	0 %	0 %	0 %	0 %	0 %
Kanban (metoda za regulaciju robe i zaliha)	27 %	7 %	20 %	0 %	13 %	13 %	7 %	7 %	0 %	0 %	7 %	0 %	0 %	0 %	0 %
Ključni indikatori učinkovitosti	14 %	20 %	26 %	11 %	6 %	9 %	3 %	3 %	3 %	3 %	0 %	3 %	0 %	0 %	0 %
Muda (uklanjanje gubitaka)	24 %	33 %	14 %	10 %	0 %	5 %	0 %	5 %	0 %	5 %	0 %	0 %	5 %	0 %	0 %
OEE (cjelokupna učinkovitost opreme)	8 %	15 %	31 %	0 %	8 %	15 %	8 %	0 %	8 %	0 %	0 %	0 %	8 %	0 %	0 %
PDCA (metoda planiraj – učini – provjeri – djeluj)	8 %	25 %	17 %	25 %	17 %	0 %	0 %	8 %	0 %	0 %	0 %	0 %	0 %	0 %	0 %
Poka-yoke (sustav za detekciju grešaka)	0 %	17 %	25 %	17 %	8 %	8 %	0 %	0 %	8 %	8 %	0 %	8 %	0 %	0 %	0 %
Analiza glavnog uzroka	16 %	0 %	11 %	16 %	16 %	16 %	11 %	5 %	0 %	0 %	11 %	0 %	0 %	0 %	0 %
SMED (brza izmjena alata)	0 %	5 %	19 %	19 %	19 %	10 %	5 %	10 %	0 %	0 %	0 %	10 %	0 %	5 %	0 %
Vizualna tvornica	4 %	16 %	28 %	4 %	20 %	20 %	4 %	0 %	0 %	0 %	0 %	4 %	0 %	0 %	0 %
Pametni ciljevi (konkretni, mjerljivi, dostižni…)	25 %	11 %	18 %	14 %	18 %	11 %	4 %	0 %	0 %	0 %	0 %	0 %	0 %	0 %	0 %
Standardizacija rada	23 %	21 %	8 %	15 %	10 %	5 %	8 %	5 %	0 %	0 %	3 %	0 %	3 %	0 %	0 %
Taktno vrijeme (usklađenje proizvodnje i zahtjeva kupaca)	14 %	7 %	0 %	29 %	0 %	7 %	14 %	7 %	0 %	7 %	0 %	0 %	7 %	7 %	0 %
TPM (cjelovito produktivno održavanje)	0 %	0 %	0 %	24 %	14 %	14 %	24 %	14 %	5 %	0 %	0 %	0 %	0 %	0 %	5 %
Gemba (problemi se moraju vidjeti iz „prve ruke“)	19 %	19 %	25 %	6 %	13 %	19 %	0 %	0 %	0 %	0 %	0 %	0 %	0 %	0 %	0 %
Šest velikih gubitaka (kategorizacija gubitaka)	0 %	20 %	0 %	20 %	0 %	20 %	20 %	0 %	20 %	0 %	0 %	0 %	0 %	0 %	0 %

4.2.9. Poboljšanja u hrvatskim poduzećima nakon uvođenja vitke proizvodnje

Postoji brojna literatura o dokumentiranim poboljšanjima putem vitke proizvodnje. Neka od tih poboljšanja jasno su dokumentirana i analizirana, no neka poboljšanja uslijed uvođenja vitkog koncepta nisu vidljiva na prvu ruku. Budući da je za mišljenje o nastalim poboljšanjima uslijed uvođenja vitkog koncepta najpraktičnije pitati poduzeća i vitke praktičare, samo anketno istraživanje provedeno je na način da se dobije povratna veza o nastalim poboljšanjima od vitkih poduzeća. Tako je u završnom dijelu ankete ispitanicima ponuđena tablica s vrstom gubitaka i kategorijama poboljšanja. Ovaj dio ankete zamišljen je kao povratna veza o smanjenju gubitaka koji su bili dokumentirani prije početka uvođenja vitkog koncepta.

Tablica 28. predstavlja poboljšanja u 63 vitka poduzeća obuhvaćena ovom anketom. Ovaj dio istraživanja prvotno je zamišljen na način da se dokumentira stanje u poduzećima nakon primjene vitkog koncepta te da se u kasnijim koracima provede analiza s dokumentiranim gubitcima u Tablici 25. Podaci o poboljšanjima bili su kvantificirani skalom 0 – 3 na sljedeći način:

- 0 – nema poboljšanja
- 1 – mala poboljšanja
- 2 – srednja poboljšanja
- 3 – velika poboljšanja.

Sva su poboljšanja bila brojčano kvantificirana te su kasnije obrađena prema vrsti gubitaka. Budući da su poboljšanja ocjenjivali ispitanici, potrebno je naglasiti da je takvo dokumentiranje subjektivno i podložno individualnim stajalištima. Svi ispitanici dolazili su iz vrhovnog ili srednjeg menadžmenta, čime se nastojala postići što veća objektivnost podataka.

Općenito govoreći, vitka poduzeća u RH napravila su najveći korak u smanjenju ili eliminaciji gubitaka koji su povezani s nedovoljnom iskorištenosti potencijala zaposlenika, škartom, prekomjernim transportom i čekanjima. Vidljivo je da su poboljšanja općenito manjeg ili srednjeg opsega, što jasno ukazuje na to da vitki koncept nije poslovni model koji nudi skokovit i nekontroliran zaokret načina poslovanja. Vitka proizvodnja temelji se na malim postupnim svakodnevnim poboljšanjima, a ne na skokovitim i neodrživim hirovima.

Tablica 28. *Vrste i veličine poboljšanja nakon uvođenja vitke proizvodnje*

Rang	**Vrsta gubitka**	**Opis poboljšanja**	Nema poboljšanja	Mala poboljšanja	Srednja poboljšanja	Velika poboljšanja
6	Prekomjerna proizvodnja	Stvaranje proizvoda ili usluga koji se mogu bolje plasirati na tržištu	40 %	48 %	10 %	3 %
		Bolje izvođenje operacija	16 %	57 %	19 %	8 %
		Smanjenje administracije	19 %	52 %	21 %	8 %
		Bolja procjena zahtjeva tržišta	29 %	48 %	17 %	6 %
		Proizvodnja s manjim zalihama	22 %	51 %	21 %	6 %
3	Prekomjeran transport	Bolje kretanje materijala između operacija ili skladišta	22 %	29 %	41 %	8 %
		Bolji prijenos informacija	6 %	46 %	37 %	11 %
		Bolja komunikacija: pouzdanost podataka	6 %	44 %	38 %	11 %
4	Čekanje	Smanjenje vremena čekanja između operacija	11 %	48 %	27 %	14 %
		Bolje planiranje proizvodnje i procesa	8 %	43 %	32 %	17 %
		Smanjenje čekanja na odobrenje ili potpis	40 %	35 %	19 %	6 %
		Bolja i brža isporuka dobavljača	44 %	37 %	13 %	6 %
8	Prekomjerna obrada	Pouzdanost ili bolji odabir tehnološke opreme	49 %	38 %	10 %	3 %
		Bolja konstrukcija proizvoda koja ne zahtjeva puno obrade	54 %	29 %	11 %	6 %
7	Nepotrebne zalihe	Smanjenje zaliha na skladištima – „zamrznuti kapital“	33 %	46 %	11 %	10 %
		Smanjenje količine nepotrebnih podataka u arhivi	25 %	54 %	14 %	6 %
5	Nepotrebni pokreti	Bolji raspored strojeva koji rezultira boljim kretanjem radnika	38 %	38 %	19 %	5 %
		Kraće kretanje ljudi kako bi došli do informacija	17 %	51 %	25 %	6 %
		Bolja ergonomija radnog mjesta	30 %	37 %	30 %	3 %
2	Škart	Poboljšanje toka proizvodnje	13 %	40 %	35 %	13 %
		Skraćenje vremena otklanjanja pogrešaka	11 %	38 %	33 %	17 %
1	Nedovoljna iskorištenost potencijala zaposlenika	Bolje korištenje potencijala zaposlenika	10 %	43 %	37 %	11 %
		Bolje prepoznavanje sposobnih zaposlenika	6 %	48 %	33 %	13 %
		Uključenje radnika u procese poboljšanja	6 %	38 %	33 %	22 %

4.3. Analiza rezultata

Provedeno istraživanje rezultirao je uzorkom od 63 poduzeća te je cijela statistička analiza odrađena u SPSS-u. IBM SPSS jedan od je najpoznatijih statističkih programa kojim se mogu analizirati i obrađivati iznimno složeni podaci. Ovaj statistički program nudi velik izbor statističkih testova te isto tako „uvoz“ podataka iz Excela, što je vrlo bitno jer su svi podaci vezani uz anketu pripremljeni upravo u Excelu.

4.3.1. Povezanost vremenske duljine primjene vitke proizvodnje s ukupnim napretkom

Budući da je ispitni uzorak od 63 hrvatska poduzeća pokazao da neka poduzeća vitku proizvodnju primjenjuju kraće, a neka dulje, logično je bilo ispitati jesu li poduzeća koja dulje primjenjuju vitku proizvodnju dulje napravila veći napredak u pogledu eliminacije gubitka. Rezultati su sljedeći: duljina primjene vitke proizvodnje kvalitativna je varijabla, dok je ukupan napredak brojčana varijabla. Potrebno je naglasiti da je ukupan napredak brojčana varijabla koja je izražena kao srednja vrijednost ili aritmetička sredina ukupnog napretka u pogledu eliminacije svih osam vrsta gubitaka. Jednostavnije rečeno, ukupan napredak za svaki uzorak predstavlja srednju vrijednost napretka koja može iznositi 0-3, gdje veći broj znači veći napredak u pogledu eliminacije osam vrsta gubitaka.

Slika 62. *Boxplot grafikon duljine primjene vitke proizvodnje i napretka u eliminaciji gubitaka*

Boxplot grafikon sa Slike 62. je pokazao da je napredak u pogledu eliminacije gubitka veći ako poduzeća dulje primjenjuju vitku proizvodnju. Međutim, općenito gledajući, napredak u pogledu eliminacije gubitaka mali je ili srednje velik, što ukazuje na činjenicu da vitka proizvodnja ne daje brza i radikalna poboljšanja.

4.3.2. Povezanost vremenske duljine primjene vitke proizvodnje s napretkom u određenoj kategoriji gubitka

Kako bi se mogli donositi bilo kakvi zaključci vezani uz duljinu primjene vitke proizvodnje i veličinu napretka, potrebno je bilo provesti detaljniju analizu. Budući da je test frekvencija pokazano da vrlo mali broj poduzeća vitku proizvodnju koristi tri godine (N = 6), četiri godine (N = 5) i pet godina (N = 6), bilo je potrebno grupirati kvalitativne varijable kako bi svaka kvalitativna varijabla imala uzorak veći od 10 poduzeća. Tako su poduzeća koja koriste vitku proizvodnju manje od dvije godine grupirana u jednu kvalitativnu varijablu (N = 31), poduzeća koja koriste vitku proizvodnju 3 – 5 godina u drugu kvalitativnu varijablu (N = 17), a poduzeća koja koriste vitku proizvodju više od pet godina u treću kvalitativnu varijablu (N = 15).

Isto tako, srednja vrijednost ukupnog napretka nije bila primjerena za statističku obradu jer se ona sastoji od 8 kategorija i 24 pripadajuće potkategorije gubitka. Stoga je bilo jedino pogodno promatrati duljinu primjene vitke proizvodnje sa svakom kategorijom gubitka pojedinačno.

Budući da su ovdje uspoređivane tri kvalitativne varijable s jednom numeričkom varijablom, provođen je ANOVA test (parametrijska metoda) ili Kruskal-Wallisov test (neparametrijska metoda). Ako je raspodjela podataka bila normalna, tada je provođen ANOVA test, dok je u obrnutom slučaju provođen Kruskal-Wallisov test. Rezultati statističke analize se nalaze u Tablici 29.

Tablica 29. *Statistička značajnost između duljine primjene vitke proizvodnje i smanjenja određene kategorije gubitka*

Kategorija gubitka	Statistička značajnost između duljine primjene vitke proizvodnje i smanjenja određene kategorije gubitka		
	< 2 god. – 3 – 5 god. p (Sig.)	< 2 god. – > 5 god. p (Sig.)	3 – 5 god. – > 5 god. p (Sig.)
Prekomjerna proizvodnja	**0,001**	**0,001**	0,999
Prekomjeran transport	0,184	**0,000**	0,106
Čekanje	**0,015**	**0,007**	0,203
Prekomjerna obrada	0,125	**0,005**	0,162
Prekomjerne zalihe	0,702	**0,002**	**0,013**
Nepotrebni pokreti	**0,044**	**0,001**	0,116
Škart	0,800	**0,009**	**0,025**
Nedovoljna iskorištenost potencijala zaposlenika	0,158	0,061	0,392

Zaključci su slijedeći:

1) <u>Duljina primjene vitke proizvodnje i smanjenje prekomjerne proizvodnje</u>
(vidi prilog 7.1.)
   - Postoji statistički značajna razlika u pogledu smanjenja prekomjerne proizvodnje između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina
   - Postoji statistički značajna razlika u pogledu smanjenja prekomjerne proizvodnje između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju dulje od 5 godina
   - NE postoji statistički značajna razlika u pogledu smanjenja prekomjerne proizvodnje između poduzeća koja koriste vitku proizvodnju 3 – 5 godina i poduzeća koja koriste vitku proizvodnju dulje od 5 godina.
2) <u>Duljina primjene vitke proizvodnje i smanjenje prekomjernog transporta</u>
(vidi prilog 7.2.)
   - NE postoji statistički značajna razlika u pogledu smanjenja prekomjernog transporta između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina

- Postoji statistički značajna razlika u pogledu smanjenja prekomjernog transporta između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju dulje od 5 godina
- NE postoji statistički značajna razlika u pogledu smanjenja prekomjernog transporta između poduzeća koja koriste vitku proizvodnju 3 – 5 godina i poduzeća koja koriste vitku proizvodnju dulje od 5 godina.

3) Duljina primjene vitke proizvodnje i smanjenje čekanja
(vidi prilog 7.3.)
- Postoji statistički značajna razlika u pogledu smanjenja čekanja između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina
- Postoji statistički značajna razlika u pogledu smanjenja čekanja između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju dulje od 5 godina
- NE postoji statistički značajna razlika u pogledu smanjenja čekanja između poduzeća koja koriste vitku proizvodnju između 3 – 5 godina i poduzeća koja koriste vitku proizvodnju dulje od 5 godina.

4) Duljina primjene vitke proizvodnje i smanjenje prekomjerne obrade
(vidi prilog 7.4.)
- NE postoji statistički značajna razlika u pogledu smanjenja prekomjerne obrade između poduzeća koja koriste vitkuproizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina
- Postoji statistički značajna razlika u pogledu smanjenja prekomjerne obrade između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju više od pet godina
- NE postoji statistički značajna razlika u pogledu smanjenja prekomjerne obrade između poduzeća koja koriste vitku proizvodnju 3 – 5 godina i poduzeća koja koriste vitku proizvodnju više od pet godina.

5) Duljina primjene vitke proizvodnje i smanjenje nepotrebnih zaliha
(vidi prilog 7.5.)
- NE postoji statistički značajna razlika u pogledu smanjenja nepotrebnih zaliha između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina
- Postoji statistički značajna razlika u pogledu smanjenja nepotrebnih zaliha između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju dulje od pet godina
- Postoji statistički značajna razlika u pogledu smanjenja nepotrebnih zaliha između poduzeća koja koriste vitku proizvodnju 3 – 5 godina i poduzeća koja koriste vitku proizvodnju dulje od pet godina.

6) Duljina primjene vitke proizvodnje i smanjenje nepotrebnih pokreta
(vidi prilog 7.6.)
- Postoji statistički značajna razlika u pogledu smanjenja nepotrebnih pokreta između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina
- Postoji statistički značajna razlika u pogledu smanjenja nepotrebnih pokreta između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju dulje od pet godina
- NE postoji statistički značajna razlika u pogledu smanjenja nepotrebnih pokreta između poduzeća koja koriste vitku proizvodnju 3 – 5 godina i poduzeća koja koriste vitku proizvodnju dulje od pet godina.

7) Duljina primjene vitke proizvodnje i smanjenje škarta
(vidi prilog 7.7.)
- NE postoji statistički značajna razlika u pogledu smanjenja škarta između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina
- Postoji statistički značajna razlika u pogledu smanjenja škarta između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju dulje od pet godina
- Postoji statistički značajna razlika u pogledu smanjenja škarta između poduzeća koja koriste vitku proizvodnju 3 – 5 godina i poduzeća koja koriste vitku proizvodnju dulje od pet godina.

8) Duljina primjene vitke proizvodnje i smanjenje nedovoljne iskorištenosti zaposlenika
(vidi prilog 7.8.)
- NE postoji statistički značajna razlika između skupina

4.3.3. Vitki alati koji su najpogodniji za smanjenje određenog gubitka

Glavni motiv ovog istraživanja bio pronaći vitke alate koji su najpogodniji za eliminaciju gubitaka, analiza je provedena na način da se gledalo utječe li primjena određenog vitkog alata na smanjenje određenog gubitka.

Nezavisna varijabla sastojala se od dvije skupine. Skupina koja nije primjenjivala određeni vitki alat obilježena je s 0, dok je skupina koja je primjenjivala određeni vitki alat obilježena s 1. Analiza je provedena nezavisnim studentovim t-testom, no ondje gdje nisu bili ostvareni preduvjeti za taj test, koristio se Mann-Whitneyev test (vidi priloge 9 - 33).

Preduvjeti za korištenje nezavisnog studentovog t-testa su sljedeći [243]:

1) Podaci za zavisnu varijablu moraju biti kontinuirani (mjereni na intervalnim ili omjernim skalama).
2) Nezavisna varijabla mora biti kvalitativna i sastojati se od minimalno dvije skupine.
3) Nezavisnost opažanja (različiti ispitanici u svakoj skupini).
4) Nema značajnih ekstremnih vrijednosti. Vrijednosti koje značajno odstupaju od srednjih vrijednosti, iznad 3 i više standardnih devijacija.
5) Zavisna varijabla mora biti približno normalno distribuirana. Normalna distribucija mora biti zastupljena u svim skupinama nezavisne varijable.
6) Homogenost varijance.

Preduvjeti za korištenje Mann-Whitneyevog testa su sljedeći [244]:

1) Podaci za zavisnu varijablu moraju biti kontinuirani (mjereni na intervalnim ili omjernim skalama).
2) Nezavisna varijabla mora biti kvalitativna.
3) Nezavisnost opažanja (različiti ispitanici u svakoj skupini).

Analiza u SPSS-u rezultirala je saznanjima da neki vitki alati bolje smanjuju određene kategorije gubitaka. Tako je TPM jedini vitki alat koji je dobar za bolji napredak smanjenja svih kategorija gubitaka, dok su se vitki alati poput *hoshin kanrija*, JIT-a, PDCA, standardizacije rada i *gembe* pokazali kao alati koji ne rade bitnu razliku kod napretka u smanjenju gubitaka. To ne znači da ti alati ne smanjuju ili ne eliminiraju neke kategorije gubitaka, već da njihov doprinos u smanjenju gubitaka nije statistički značajan.

Nadalje, analizom je utvrđeno da postoji 14 vitkih alata koji utječu na smanjenje nekoliko kategorija gubitaka te 6 vitkiha alata koji utječu na smanjenje samo jedne kategorije gubitka, vidi Tablicu 30.

Tablica 30. *Vitki alati i smanjenje gubitaka*

Vitki alati	Suma kategorija gubitaka koje ovaj alat bolje smanjuje ili eliminira
TPM (cjelovito produktivno održavanje)	8
Poka-yoke (izbjegavanje greške)	7
SMED (brza izmjena alata)	6
5S (uređenje prostora)	5
Andon (vizualni sustav pogona)	5
Kontinuirani tok (proizvodnja bez zastoja)	5
Taktno vrijeme (usklađenje proizvodnje i zahtjeva kupaca)	5
Heijunka (niveliranje proizvodnje)	4
Jidoka (parcijalna automatizacija)	4
Kaizen (kontinuirano poboljšanje)	3
OEE (cjelokupna učinkovitost opreme)	3
Ključni indikatori učinkovitosti	2
Vizualna tvornica	2
Šest velikih gubitaka (kategorizacija gubitaka)	2
Analiza uskih grla	1
VSM (mapiranje toka vrijednosti)	1
Kanban (metoda za regulaciju robe i zaliha)	1
Muda (uklanjanje gubitaka)	1
Analiza glavnog uzroka	1
Pametni ciljevi	1
Hoshin kanri (politika razvoja)	0
JIT (pravovremena proizvodnja)	0
PDCA (metoda planiraj – učini – provjeri – djeluj)	0
Standardizacija rada	0
Gemba (problemi se moraju vidjeti iz „prve ruke“)	0

Općenito govoreći, statistička analiza je pokazala da se svakoj kategoriji gubitka mora pristupati individualno, to jest različiti alati se trebaju primjenjivati pri smanjenju različitih kategorija gubitaka. Pritom postoje vitki alati koji smanjuju nekoliko vrsta gubitaka kao što su TPM, *poka-yoke*, SMED, 5S, *andon*, kontinuirani tok, taktno vrijeme, *heijunka*, *jidoka*, *kaizen*, OEE, ključni indikatori učinkovitosti, vizualna tvornica i šest velikih gubitaka te alati koji smanjuju samo jednu vrstu gubitka kao što su analiza uskih grla, VSM, *kanban*, *muda*, analiza glavnog uzroka i pametni ciljevi. Statistička značajnost vitkih alata pri redukciji određenih vrsta gubitaka vidljiva je iz Tablice 31. dok su poboljšanja uslijed primjene određenih vitkih alata kvantificirana u Tablici 32.

Tablica 31. Statistička značajnost između poduzeća koja primjenjuju i ne primjenjuju određeni vitki alat u smanjenju određenog gubitka

	Prekomjerna proizvodnja	Prekomjeran transport	Čekanje	Prekomjerna obrada	Nepotrebne zalihe	Nepotrebni pokreti	Škart	Nedovoljna iskorištenost potencijala zaposlenika
	p (Sig.)							
5S (uređenje prostora)	0,039	0,020	0,001	0,283	0,050	0,041	0,881	0,074
Andon (vizualni sustav pogona)	0,013	0,038	0,003	0,034	0,316	0,002	0,507	0,657
Analiza uskih grla	0,781	0,867	0,119	0,267	0,545	0,034	0,223	0,107
Kontinuirani tok (proizvodnja bez zastoja)	0,046	0,018	0,005	0,287	0,681	0,001	0,024	0,269
VSM (mapiranje toka vrijednosti)	0,622	0,134	0,065	0,210	0,915	0,200	0,090	0,030
Heijunka (niveliranje proizvodnje)	0,013	0,013	0,017	0,437	0,809	0,043	0,294	0,108
Hoshin kanri (politika razvoja)	0,073	0,640	0,864	0,090	0,599	0,665	0,786	0,477
Jidoka (parcijalna automatizacija)	0,016	0,024	0,019	0,001	0,499	0,066	0,150	0,322
JIT (pravovremena proizvodnja)	0,140	0,230	0,481	0,448	0,076	0,268	0,730	0,838
Kaizen (kontinuirano poboljšanje)	0,308	0,107	0,119	0,702	0,415	0,002	0,019	0,018
Kanban (metoda za regulaciju robe i zaliha)	0,308	0,056	0,069	0,269	0,020	0,452	0,416	0,753
Ključni indikatori učinkovitosti	0,125	0,316	0,029	0,126	0,549	0,005	0,345	0,081
Muda (uklanjanje gubitaka)	0,138	0,465	0,033	0,994	0,588	0,161	1,000	0,313
OEE (cjelokupna učinkovitost opreme)	0,221	0,002	0,162	0,192	0,001	0,038	0,151	0,183
PDCA (metoda planiraj – učini – provjeri – djeluj)	0,726	0,132	0,240	0,561	0,813	0,260	0,460	0,695
Poka-yoke (izbjegavanje greške)	0,013	0,001	0,009	0,001	0,072	0,002	0,000	0,024
Analiza glavnog uzroka	0,437	0,660	0,044	0,399	0,914	0,930	0,577	0,878
SMED (brza izmjena alata)	0,001	0,004	0,004	0,008	0,395	0,001	0,040	0,051
Vizualna tvornica	0,037	0,163	0,163	0,104	0,586	0,029	0,267	0,467
Pametni ciljevi	0,042	0,479	0,329	0,169	0,658	0,669	0,667	0,121
Standardizacija rada	0,127	0,820	0,085	0,307	0,994	0,212	0,094	0,234
Taktno vrijeme (usklađenje proizvodnje i zahtjeva kupaca)	0,152	0,003	0,000	0,137	0,029	0,035	0,008	0,102
TPM (cjelovito produktivno održavanje)	0,000	0,019	0,002	0,001	0,016	0,002	0,010	0,000
Gemba (problemi se moraju vidjeti iz "prve ruke")	0,095	0,631	0,327	0,323	0,541	0,090	0,573	0,777
Šest velikih gubitaka (kategorizacija gubitaka)	0,030	0,297	0,264	0,134	0,026	0,396	0,265	0,419

Tablica 32. Statistički značajna razlika srednjih vrijednosti napretka u smanjenju gubitka između poduzeća koja su koristila i koja nisu koristila određeni vitki alat

Prekomjerna proizvodnja	Prekomjeran transport	Čekanje	Prekomjerna obrada	Nepotrebne zalihe	Nepotrebni pokreti	Škart	Nedovoljna iskorištenost potencijala zaposlenika
TPM 0,7095 (1,5238)	***Poka-yoke*** 0,7908 (2,1111)	**Taktno vrijeme** 0,8342 (1,8393)	***Poka-yoke*** 0,9069 (1,4167)	**OEE** 0,6400 (1,5000)	***Andon*** 0,6970 (1,6667)	***Poka-yoke*** 0,8971 (2,2500)	**TPM** 0,7540 (2,0794)
Šest velikih gubitaka 0,5966 (1,6000)	**OEE** **0**,6667 (2,0000)	***Heijunka*** 0,7566 (1,8750)	**TPM** 0,6905 (1**,**1429)	**Šest velikih gubitaka** 0, 5517 (1,5000)	***Poka-yoke*** 0,6830 (1,6111)	**Taktno vrijeme** 0,6581 (2,0357)	***Poka-yoke*** 0,5915 (2,0556)
Heijunka 0,5333 (1,5333)	***Heijunka*** 0,6462 (2,0556)	***Andon*** 0,7483 (1,8438)	***Jidoka*** 0,6000 (1,1111)	**TPM** 0,5119 (1,3333)	**SMED** 0,6508 **(**1,4921)	**TPM** 0,5358 (1,8810)	***Kaizen*** 0,4363 (1,7568)
SMED 0,5095 (1,3905)	**Taktno vrijeme** 0,6191 (1,9524)	***Poka-yoke*** 0,7356 (1,6458)	***Andon*** 0,5784 (1,1875)	***Kanban*** 0,4479 (1,3333)	**TPM** 0,5556 (1,4286)	**Kontinuirani tok** 0,4779 (1,8500)	**VSM** 0,3202 (1,7444)
Poka-yoke 0,4931 (1,4500)	***Andon*** 0,5583 (1,9583)	**TPM** 0,5714 (1,5714)	**SMED** 0,5476 (1,0476)	**Taktno vrijeme** 0,4234 (1,3214)	***Heijunka*** 0,5502 (1,5556)	***Kaizen*** 0,4662 (1,7162)	
Andon 0,4573 (1,4500)	**SMED** 0,5317 (1,8254)	**5S** 0,5535 (1,4189)		**5S** 0,3794 (1,1486)	**Kontinuirani tok** 0,5496 (1,4333)	**SMED** 0,4285 (1,8095)	
5S 0,3484 (1,1946)	**5S** 0,4962 (1,6757)	**SMED** 0,5178 (1,5357)			***Kaizen*** 0,5357 (1,2793)		
Vizualna tvornica 0,3137 (1,2400)	**Kontinuirani tok** 0,4334 (1,7667)	**Kontinuirani tok** 0,5084 (1,5375)			**Ključni indikatori učinkovitosti** 0,4691 **(**1,2667)		
Jidoka 0,2867 (1,2556)	***Jidoka*** 0,4297 (1,7778)	**Analiza glavnog uzroka** 0,4432 (1,5000)			**Taktno vrijeme** 0,4456 (1,4048)		
Pametni ciljevi 0,2686 (1,2000)	**TPM** 0,4127 (1,7460)	***Jidoka*** 0,4333 (1,5000)			**Vizualizacija proizvodnje** 0,3898 **(**1,2933)		
Kontinuirani tok 0,2479 (1,2200)		***Muda*** 0,3750 (1,4405)			**5S** 0,3829 **(**1,2162)		
		Ključni indikatori učinkovitosti 0,3589 (1,3500)			**OEE** 0,3790 (1,3590)		
					Analiza glavnog uzroka 0,2968 (1,2184)		

Zaključno valja reći kako 80% temeljnih vitkih alata statistički značajno utječu na redukciju gubitaka. Pritom postoje vitki alati koji sami reduciraju gubitke koji su prikazani u slijedećem poglavlju te postoje vitki alati koji samo u paru ili sprezi više alata pridonose smanjenju gubitaka. Sve u svemu u Tablici 33. se nalaze najpogodniji vitki alati za smanjenje gubitaka.

Tablica 33. Vitki alati koji su najpogodniji za smanjenje gubitaka

Vitki alat	Suma gubitaka koje ovaj alat smanjuje
TPM	8
Poka-yoke	7
Andon	5
5S	5
Kontinuirani tok	5
Taktno vrijeme	5
SMED	5
Heijunka	4
Jidoka	4
OEE	3
Kaizen	3
Šest velikih gubitaka	2
Vizualna tvornica	2
Analiza glavnog uzroka	2
Ključni indikatori učinkovitosti	2
Analiza uskih grla	1
SMED	1
Pametni ciljevi	1
Muda	1
Kanban	1
VSM	1

4.3.4. Vitki alati koji najbolje smanjuju određene gubitke

U prethodnom poglavlju statističkom su analizom otkriveni vitki alati koji statistički značajno pridonose boljem smanjenju određenih gubitaka. Međutim, nije utvrđeno koji su od tih alata najbolji za smanjenje određenog gubitka. Kao najbolja metoda za otkrivanje snažnih vitkih alata u pogledu smanjenje određenih gubitaka odabrana je stupnjevita multivarijatna linearna regresija (engl. *stepwise multiple linear regression*).

Cilj je regresijske analize saznati koliko se varijance može objasniti u zavisnoj varijabli koju nazivamo kriterij na temelju određenog kompleta nezavisnih varijabli koje nazivamo prediktori te kakav udio u prognozi rezultata u kriteriju ima svaki od prediktora. Stupnjeviti modeli u konačnoj jednadžbi zadržavaju samo one prediktore koji značajno doprinose predviđanju kriterija. Preciznije rečeno, stupnjevitom linearnom regresijom selektirani su prediktori (vitki alati) važni za prognozu kriterija (napredak u smanjeju određenog gubitka). Krajnji model sadržava samo prediktore koji značajno doprinose predviđanju kriterijske varijable.

Preduvjeti za korištenje multivarijatne linearne regresije su sljedeći [245]:

1) Podaci za zavisnu varijablu moraju biti kontinuirani (mjereni na intervalnim ili omjernim skalama).
2) Nezavisne varijable mogu biti kontinuirane ili kvalitativne.
3) Nezavisnost opažanja (različiti ispitanici u svakoj skupini).
4) Mora postojati linearna veza između zavisne varijable i svake nezavisne varijable.
5) Podaci moraju pokazivati homoskedastičnost (varijanca ostaje konstanta za sve vrijednosti varijable).
6) Podaci ne smiju pokazivati multikolinearnost (dvije ili više nezavisnih varijabli u jakoj su korelaciji).
7) Nema značajnih ekstremnih vrijednosti.
8) Provjeriti da se rezidualne greške normalno distribuiraju.

Provedeno istraživanje u RH rezultiralo je uzorkom od 63 poduzeća te su u poglavlju 4.3.3. definirani vitki alati koji statistički značajno pridonose smanjenju određenog gubitka. Međutim, analiza koja je provedena u navedneom poglavlju radila se na način da se uspoređuju poduzeća koja primjenjuju određeni vitki alat i koja ne primjenjuju određeni vitki alat te se promatra veličina smanjenja određenog gubitka. Takva je analiza dobra, no ona ima jednu manu koja se svodi na to da ponekad neki vitki alat koji nije obuhvaćen studentovim t-testom ili Mann-Whitneyevim testom radi statistički značajnu razliku u korist poduzeća koja koriste promatrani alat te tako pozitivno utječe na smanjenje određenog gubitka. Stoga je za detekciju najboljih vitkih alata izabran multivarijatni stupnjeviti linearni regresijski model kako bi se precizno detektirali alati koji rade statistički značajnu pozitivnu razliku u smanjenju određenog gubitka. Upravo je ta analiza u prilozima 34 do 41 precizno filtrirala najbolje vitke alate za smanjenje određenog gubitka.

Postavljenim modelom i analizom dobiveni su slijedeći rezultati. U prvu skupinu najboljih vitkih alata spadaju TPM, *poka-yoke*, *kaizen*, 5S i *kanban* jer oni pozitivno utječu na smanjenje nekoliko gubitaka, vidi Tablicu 34. U drugu skupinu najboljih vitkih alata spadaju šest velikih gubitaka, *heijunka*, taktno vrijeme, *andon*, OEE, SMED i ključni indikatori učinkovitosti jer oni statistički značajno bolje smanjuju samo jednu određenu vrstu gubitka. Općenito govoreći, ovo je istraživanje pokazalo da 12 vitkih alata statistički značajno bolje smanjuje gubitke od početno promatranih 25 te su u Tablci 34. definirani najbolji setovi vitkih alata koji smanjuju određene gubitke. Definiranjem najboljih setova vitkih alata postavljen je i model za pravilan redoslijed uvođenja vitkih alata budući da sada poduzeća mogu vidjeti koji vitki alati najbolje smanjuju njihove gubitke.

Tablica 34. *Vitki alati koji najbolje smanjuju gubitke*

Vitki alat	Suma gubitaka koje ovaj alat smanjuje	Prosječni napredak koji se postiže ovim alatom (skala 0 – 3)
TPM	5	0,5264
Poka-yoke	3	0,775
Kaizen	3	0,422
5S	2	0,475
Kanban	2	0,447
Šest velikih gubitaka	1	0,546
Heijunka	1	0,599
Taktno vrijeme	1	0,712
Andon	1	0,638
OEE	1	0,572
SMED	1	0,521
Ključni indikatori učinkovitosti	1	0,329

Tablica 35. *Vitki alati koji najbolje smanjuju određene gubitke*

	Prekomjerna proizvodnja	Prekomjeran transport	Čekanje	Prekomjerna obrada	Nepotrebne zalihe	Nepotrebni pokreti	Škart	Nedovoljna iskorištenost potencijala zaposlenika
R	0,628	0,681	0,742	0,546	0,590	0,582	0,585	0,521
R^2	0,394	0,464	0,550	0,298	0,348	0,339	0,342	0,271
p	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
	TPM	***Poka-yoke***	**Taktno vrijeme**	***Poka-yoke***	**OEE**	**SMED**	***Poka-yoke***	**TPM**
B (β)	0,697 (0,564)	0,740 (0,410)	0,712 (0,435)	0,653 (0,356)	0,572 (0,352)	0,521 (0,353)	0,932 (0,470)	0,711 (0,441)
	Šest velikih gubitaka	**5S**	***Andon***	**TPM**	***Kanban***	***Kaizen***	***Kaizen***	***Kaizen***
B (β)	0,546 (0,254)	0,557 (0,387)	0,638 (0,312)	0,410 (0,269)	0,545 (0,353)	0,392 (0,277)	0,516 (0,326)	0,359 (0,232)
		Heijunka	**5S**		**TPM**	**Ključni indikatori učinkovitosti**		
B (β)		0,599 (0,248)	0,394 (0,285)		0,446 (0,320)	0,329 (0,235)		
		Kanban	**TPM**					
B (β)		0,350 (0,210)	0,368 (0,255)					

5. ZAKLJUČAK

Tržište se zadnjih stotinu godina vrlo brzo mijenjalo. Mnoga poduzeća koja su bila lideri na početku prošlog stoljeća danas više ne postoje ili nemaju značajnu tržišnu ulogu. Globalizacijom su mnoga poduzeća dobila priliku konkurirati na tržištima o kojima su mogla samo sanjati. Rezultat toga je da su bolji, snažniji i okretniji postali tržišni lideri, dok su ostali postali dio povijesti.

Postoje različiti poslovni modeli koji mogu dovesti organizaciju u stanje bolje profitabilnosti, konkurentnosti, fleksibilnosti ili tržišne prihvaćenosti. Vitka proizvodnja jedan je od takvih poslovnih modela. Međutim, provođenje vitke filozofije prožeto je velikim nepoznanicama i potrebno je pravo umijeće kako bi se ostvarili željeni ciljevi. Vitka filozofija temelji se na kulturi eliminacije gubitaka te je takvu kulturu vrlo zahtjevno pretočiti u poslovne procese i aktivnosti. Ljudi ne vole promjene i one se neće dogoditi same od sebe. Stoga menadžment prilikom uvođenja vitke filozofije mora jasno definirati operativni radni okvir, aktivnosti i ciljeve. Radni okvir djelovanja u vitkoj se filozofiji definira kroz vitke alate.

Prema Taiichiju Ohnou postoji osam vrsta gubitaka: prekomjerna proizvodnja, prekomjeran transport, čekanje, prekomjerna obrada, nepotrebne zalihe, nepotrebni pokreti, škart i nedovoljna iskorištenost potencijala zaposlenika. Svaka organizacija u manjoj ili većoj mjeri stvara određene gubitke te je cilj menadžmenta takve gubitke prepoznati i smanjiti. Menadžment se pri vitkom restrukturiranju poduzeća uvijek koristi opipljivim praksama, odnosno vitkim alatima kako bi definirao smjer i opseg djelovanja ljudi. Međutim, postoji mnoštvo vitkih alata i svaki alat ima svoje mane i prednosti u pogledu eliminacije određene kategorije gubitka. Pregledom literature ustanovljeno je da postoji dvadeset pet temeljnih vitkih alata koji se najčešće koriste pri vitkom restrukturiranju poduzeća te je ustanovljeno da su neki alati pogodniji za uporabu kod smanjenja određene kategorije gubitka. Općenito, na temelju istraživanja o vitkoj proizvodnji provedenog u RH možemo zaključiti sljedeće:

I. **Vitku filozofiju najčešće uvode** poduzeća koja pripadaju sekundarnom (65 %) i tercijarnom sektoru (25 %). Preciznije rečeno, radi se o sljedećim područjima djelatnosti: prerađivačka industrija (67 %), trgovina na veliko i malo (13 %), građevinarstvo (6 %), informacije i komunikacije (3 %), financijske djelatnosti i djelatnosti osiguranja (3 %) te stručne, znanstvene i tehničke djelatnosti (3 %).
II. **Prema odjeljku djelatnosti vitku proizvodnju najčešće uvode** poduzeća koja se bave sljedećim djelatnostima: proizvodnja gotovih metalnih proizvoda, osim strojeva i opreme (25 %), trgovina na veliko; osim trgovina motornim vozilima i motociklima (8 %), proizvodnja prehrambenih proizvoda (6 %), proizvodnja električne opreme (6 %), proizvodnja računala te elektroničkih i optičkih proizvoda (5 %) i gradnja građevina niskogradnje (5 %).

III. **Glavni okidači za primjenu vitke filozofije** su sljedeći (mogućnost više odgovora): povećanje učinkovitosti; učinak, produktivnost i profit (73 %), skupina ljudi iz poduzeća predstavila je snagu vitke filozofije (40 %), vidjeli smo rezultate vitke filozofije u drugim poduzećima (38 %), želja za povećanjem timskog duha i motivacije (32 %), upoznali smo se s vitkom filozofijom preko konzultanata i na stručnim skupovima (19 %), zbog pritiska konkurencije (14 %) i zbog pritiska kupaca (8 %).

IV. **Vrste restrukturiranja koje se provode vitkom filozofijom** (mogućnost više odgovora): operativno (57 %), operativno i strateško (22 %), financijsko, operativno i strateško (8 %), financijsko i operativno (6 %) i samo strateško (6 %).

V. **Ciljevi poduzeća prilikom vitkog restrukturiranja** (mogućnost više odgovora): povećati efikasnost (89 %), povećati profitabilnost (70 %), povećati produktivnost (67 %), eliminirati gubitke (67 %), smanjiti troškove proizvodnje (65 %), poboljšati učinkovitost zaposlenika (46 %), postići manje zaliha; sirovina, poluproizvoda i proizvoda (41 %), poboljšati tržišni udio (41 %), postići bolju isporuku proizvoda i usluga (40 %), povećati konkurentnost (37 %), poboljšati timski rad (35 %), smanjiti zastoje i prekide (27 %), poboljšati usluge korisnicima (24 %) i poboljšati upravljanje opskrbnim lancem (16 %).

VI. **Učestalost korištenja vitkih alata** je sljedeća: standardizacija rada (62 %), 5S (59 %), *kaizen* (59 %), ključni indikatori učinkovitosti (56 %), VSM (48 %), analiza uskih grla (46 %), pametni ciljevi (44 %), vizualna tvornica (40 %), JIT (36 %), *muda* (33 %), SMED (33 %), TPM (33 %), kontinuirani tok (32 %), *hoshin-kanri* (32 %), analiza glavnog uzroka (30 %), *jidoka* (29 %), *gemba* (25 %), *kanban* (24 %), taktno vrijeme (22 %), OEE (21 %), PDCA (21 %), *poka-yoke* (19 %), *andon* (13 %), *heijunka* (10 %) i šest velikih gubitaka (8 %).

VII. **Vitki alati koji imaju pozitivan utjecaj na poduzeće iz perspektive menadžmenta**: standardizacija rada (95 %), *kaizen* (95 %), *muda* (95 %), kontinuirani tok (95 %), *hoshin-kanri* (95 %), *jidoka* (94 %), analiza uskih grla (93 %), pametni ciljevi (93 %), vizualna tvornica (92 %), 5S (89 %), analiza glavnog uzroka (89 %), *gemba* (88 %), *andon* (88 %), ključni indikatori učinkovitosti (86 %), SMED (86 %), *heijunka* (83 %), TPM (81 %), VSM (80 %), šest velikih gubitaka (80 %), OEE (77 %), PDCA (75 %), JIT (74 %), taktno vrijeme (71 %), *kanban* (67 %) i *poka-yoke* (67 %).

VIII. **Primjenom vitke proizvodnje poduzeće kontinuirano smanjuje svoje gubitke**. Ovaj tip restrukturiranja oslanja se na mala, ali kontinuirana poboljšanja u kojima nema brzih, radikalnih i ishitrenih poteza.

IX. **Pregledom literature definirani su međuodnosi između vitkih alata** kako slijedi:

   i. Prilikom uvođenja 5S-a često se implementiraju, ili su već implementirani, sljedeći vitki alati: VSM, JIT, *kanban*, SMED, vizualna tvornica i standardizacija rada.

   ii. Prilikom uvođenja *andona* često se implementiraju, ili su već implementirani, sljedeći vitki alati: *poka-yoke* i vizualizacija proizvodnje.

iii. Prilikom uvođenja analize uskih grla često se implementiraju, ili su već implementirani, sljedeći vitki alati: OEE.

iv. Prilikom uvođenja kontinuiranog toka često se implementiraju, ili su već implementirani, sljedeći vitki alati: VSM, *heijunka*, JIT, SMED, taktno vrijeme i *gemba*.

v. Prilikom uvođenja VSM-a često se implementiraju, ili su već implementirani, sljedeći vitki alati: 5S, kontinuirani tok, *jidoka*, JIT, *kaizen*, standardizacija rada, taktno vrijeme i TPM.

vi. Prilikom uvođenja *heijunke* često se implementiraju, ili su već implementirani, sljedeći vitki alati: kontinuirani tok, JIT, *kaizen*, *kanban*, SMED, vizualna tvornica i taktno vrijeme.

vii. Prilikom uvođenja *hoshin kanrija* često se implementiraju, ili su već implementirani, sljedeći vitki alati: *kaizen*, PDCA, vizualna tvornica i pametni ciljevi.

viii. Prilikom uvođenja *jidoke* često se implementiraju, ili su već implementirani, sljedeći vitki alati: VSM, JIT i *poka-yoke*.

ix. Prilikom uvođenja JIT-a često se implementiraju, ili su već implementirani, sljedeći vitki alati: 5S, kontinuirani tok, VSM, *heijunka*, *jidoka*, *kanban*, *muda*, *poka-yoke*, SMED, taktno vrijeme i TPM.

x. Prilikom uvođenja *kaizena* često se implementiraju, ili su već implementirani, sljedeći vitki alati: VSM, *heijunka*, *hoshin kanri*, ključni indikatori učinkovitosti, PDCA, pametni ciljevi, standardizacija rada i TPM.

xi. Prilikom uvođenja *kanbana* često se implementiraju, ili su već implementirani, sljedeći vitki alati: 5S, *heijunka*, JIT, standardizacija rada i taktno vrijeme.

xii. Prilikom uvođenja ključnih indikatora učinkovitosti često se implementiraju, ili su već implementirani, sljedeći vitki alati: *kaizen*, PDCA, SMED, pametni ciljevi i standardizacija rada.

xiii. Prilikom uvođenja *mude* često se implementiraju, ili su već implementirani, sljedeći vitki alati: JIT, pametni ciljevi i standardizacija rada.

xiv. Prilikom uvođenja OEE-a često se implementiraju, ili su već implementirani, sljedeći vitki alati: analiza uskih grla, SMED, TPM i šest velikih gubitaka.

xv. Prilikom uvođenja PDCA često se implementiraju, ili su već implementirani, sljedeći vitki alati: *hoshin kanri*, *kaizen*, ključni indikatori učinkovitosti, standardizacija rada i TPM.

xvi. Prilikom uvođenja *poka-yoke* često se implementiraju, ili su već implementirani, sljedeći vitki alati: *andon*, *jidoka*, JIT, SMED, standardizacija rada i TPM.

xvii. Prilikom uvođenja analize uzroka često se implementiraju, ili su već implementirani, sljedeći vitki alati: SMED i TPM.

xviii. Prilikom uvođenja SMED-a često se implementiraju, ili su već implementirani, sljedeći vitki alati: 5S, kontinuirani tok, *heijunka*, JIT, ključni indikatori učinkovitosti, OEE, *poka-yoke*, analiza glavnog uzroka, standardizacija rada, taktno vrijeme, TPM i *gemba*.

xix. Prilikom uvođenja vizualne tvornice često se implementiraju, ili su već implementirani, sljedeći vitki alati: 5S, *andon*, *heijunka*, *hoshin kanri* i standardizacija rada.

xx. Prilikom uvođenja pametnih ciljeva često se implementiraju, ili su već implementirani, sljedeći vitki alati: *hoshin kanri*, *kaizen*, ključni indikatori učinkovitosti i *muda*.

xxi. Prilikom uvođenja standardizacije rada često se implementiraju, ili su već implementirani, sljedeći vitki alati: 5S, VSM, *kaizen*, *kanban*, *ključni indikatori učinkovitosti*, *muda*, PDCA, *poka-yoke*, SMED, vizualna tvornica, taktno vrijeme i šest velikih gubitaka.

xxii. Prilikom uvođenja taktnog vremena često se implementiraju, ili su već implementirani, sljedeći vitki alati: kontinuirani tok, VSM, *heijunka*, JIT, *kanban*, SMED i standardizacija rada.

xxiii. Prilikom uvođenja TPM-a često se implementiraju, ili su već implementirani, sljedeći vitki alati: VSM, JIT, *kaizen*, OEE, PDCA, *poka-yoke*, analiza glavnog uzroka, SMED, standardizacija rada i šest velikih gubitaka.

xxiv. Prilikom uvođenja *gembe* često se implementiraju, ili su već implementirani, sljedeći vitki alati: analiza uskih grla, kontinuirani tok i SMED.

xxv. Prilikom uvođenja šest velikih gubitaka često se implementiraju, ili su već implementirani, sljedeći vitki alati: OEE, standardizacija rada i TPM.

X. **Primjenom Studentovog t-testa ili Mann-Whitneyevog testa definirani su vitki alati koji pridonose smanjenju određenih kategorija gubitaka** kako slijedi:

i. Vitki alati koji smanjuju prekomjernu proizvodnju su: TPM, šest velikih gubitaka, *heijunka*, SMED, *poka-yoke*, *andon*, 5S, vizualna tvornica, *jidoka*, pametni ciljevi i kontinuirani tok.

ii. Vitki alati koji smanjuju prekomjeran transport su: *poka-yoke*, OEE, *heijunka*, taktno vrijeme, *andon*, SMED, 5S, kontinuirani tok, *jidoka* i TPM.

iii. Vitki alati koji smanjuju čekanje su: taktno vrijeme, *heijunka*, *andon*, *poka-yoke*, TPM, 5S, SMED, kontinuirani tok, analiza glavnog uzroka, *jidoka*, *muda* i ključni indikatori učinkovitosti.

iv. Vitki alati koji smanjuju prekomjernu obradu su: *poka-yoke*, TPM, *jidoka*, *andon* i SMED.

v. Vitki alati koji smanjuju nepotrebne zalihe su: OEE, šest velikih gubitaka, TPM, *kanban*, taktno vrijeme i 5S.

vi. Vitki alati koji smanjuju nepotrebne pokrete su: *andon*, *poka-yoke*, SMED, TPM, *heijunka*, kontinuirani tok, *kaizen*, ključni indikatori učinkovitosti, taktno vrijeme, vizualna tvornica, 5S, OEE i analiza glavnog uzroka.

vii. Vitki alati koji smanjuju škart su: *poka-yoke*, taktno vrijeme, TPM, kontinuirani tok, *kaizen* i SMED.

viii. Vitki alati koji smanjuju nedovoljnu iskorištenost potencijala zaposlenika su: TPM, *poka-yoke*, *kaizen* i VSM.

XI. **Primjenom stupnjevite mulitvarijatne linearne regresije definirani su kompleti vitkih alata koji najbolje smanjuju određene kategorije gubitaka** kako slijedi:

i. Prekomjerna proizvodnja trebala bi se smanjiti primjenom sljedećih vitkih alata: TPM i šest velikih gubitaka.

ii. Prekomjeran transport trebao bi se smanjiti primjenom sljedećih vitkih alata: *poka-yoke*, 5S, *heijunka* i *kanban*.

iii. Čekanje bi se trebalo smanjiti primjenom sljedećih vitkih alata: taktno vrijeme, *andon*, 5S i TPM.

iv. Prekomjerna obrada trebala bi se smanjiti primjenom sljedećih vitkih alata: *poka-yoke* i TPM.

v. Nepotrebne zalihe trebale bi se smanjiti primjenom sljedećih vitkih alata: OEE, *kanban* i TPM.

vi. Nepotrebni pokreti trebali bi se smanjiti primjenom sljedećih vitkih alata: SMED, *kaizen* i ključni indikatori učinkovitosti.

vii. Škart bi se trebao smanjiti primjenom sljedećih vitkih alata: *poka-yoke* i *kaizen*.

viii. Nedovoljna iskorištenost potencijala zaposlenika trebala bi se smanjit primjenom sljedećih vitkih alata: TPM i *kaizen*.

XII. **Vitki alati koji smanjujuju nekoliko kategorija gubitaka** su: TPM (5/8), *poka-yoke* (3/8), *kaizen* (3/8), 5S (2/8) i *kanban* (2/8). Budući da ovi alati reduciraju nekoliko kategorija gubitaka, poželjno ih je prilikom uvođenja vitke filozofije implementirati što prije kako bi napredak bio bolji, brži i održiviji.

XIII. **Vitki alati koji smanjuju samo jednu kategoriju gubitka** su: šest velikih gubitaka, *heijunka*, taktno vrijeme, *andon*, OEE, SMED i ključni indikatori učinkovitosti.

5.1. Potvrda hipoteze istraživanja

Doktorski rad temelji se na hipotezi da je proces implementacije vitke proizvodnje pri restrukturiranju poduzeća učinkovit samo ako postoji pravilan izbor i redoslijed uvođenja pojedinih alata vitkog menadžmenta. Zaključak o potvrdi hipoteze predstavljen je sljedećim istraživačkim pitanjima.

1. Na koji bi se način vitka filozofija trebala implementirati kako bi restrukturiranje bilo učinkovito?

Pregledom literature u poglavlju 2 i 3 dokazano je da menadžment mora imati znanje, sposobnost i iskustvo o vitkoj proizvodnji kako bi restrukturiranje bilo uspješno. Uz navedeno, vrhovni menadžment mora biti sveprisutan, karizmatičan i aktivno se uključiti u integraciju novih vitkih alata. Većina znanstvenih autora zagovara uvođenje vitke filozofije u obliku projektnog zadatka sa sustavno razrađenim planom i ključnim vremenskim točkama. U poglavlju 3 kroz pregled literature prikazano je da moraju postojati preduvjeti za uvođenje određenih vitkih

alata, što znači da redoslijed uvođenja istih mora biti prilagođen organizacijskom stanju i potrebama. Ako se alati implementiraju nasumično, poboljšanja će biti kratkoročna i neodrživa. To znači da organizacija mora nedvojbeno prepoznati i kvantificirati svoje gubitke kako bi mogla odrediti svoje prioritete i stupanj djelovanja.

2. Kojim bi se redoslijedom vitki alati trebali uvoditi nakon što poduzeće prepozna gubitke?

U poglavlju 4 dokumentirane su sve faze vitkog restrukturiranja. Rezultati istraživanja pokazali su da svako poduzeće ima drugačije vrste gubitaka pa tehnike eliminacije istih moraju biti sustavno prilagođene potrebama organizacije. Shodno tome, uvođenje vitkih alata treba se provoditi na sljedeća dva načina:

(1) Ako poduzeće želi smanjiti jednu točno određenu kategoriju gubitka, tada se moraju implementirati oni vitki alati koji značajno utječu na taj gubitak. Takvi kompleti vitkih alata prikazani su u Tablici 32, dok su najbolji dani u Tablici 35.
(2) Ako poduzeće želi smanjiti nekoliko kategorija gubitaka, tada se moraju implementirati oni vitki alati koji smanjuju nekoliko vrsta gubitaka. Takvi alati prikazani su u Tablici 33, dok su najbolji prikazani u Tablici 34.

Kompleti vitkih alata koji su utvrđeni u poglavlju 4.3.4. najbolji su vitki alati za smanjenje gubitaka pa svako učinkovito restrukturiranje podrazumijeva njihovo uvođenje. Razvijeni modeli kreirani su za proces restrukturiranja poduzeća, ali isti mogu biti primjenjivi i u fazi konkurentnog i stabilnog poslovanja.

5.2. Ostvareni znanstveni doprinos

Ovaj doktorski rad dao je nekoliko značajnih znanstvenih doprinosa. Prije svega, u želji proširenja literature o vitkim alatima na hrvatskom jeziku, u ovom su radu opisani svi značajni temeljeni vitki alati pa bi njihovo buduće uvođenje trebalo biti jednostavnije, brže i uspješnije. Pregledom knjiga i znanstvenih radova o vitkoj proizvodnji definirane su smjernice i preduvjeti za uvođenje pojedinih vitkih alata. S druge strane, provedeno istraživanje nad hrvatskim vitkim poduzećima rezultiralo je dokumentiranjem svih bitnih čimbenika pri operativnom provođenju vitkog menadžmenta. Tako su definirani motivi, ciljevi i vrste restrukturiranja koje se provode vitkom filozofijom, izmjereni su i kvantificirani gubitci, izmjerena je učestalost korištenja pojedinih alata, definirana je učestalost korištenja određenih vitkih alata u pojedinim fazama restrukturiranja te su na kraju izmjerena i kvantificirana poboljšanja koja se mogu očekivati uvođenjem vitke filozofije. Zaključno, potrebno je istaknuti da su najvažniji doprinosi sljedeći:

I. Definirani su najpogodniji temeljni vitki alati prilikom restrukturiranja poduzeća temeljem provedenog Studentovog t-testa ili Mann-Whitneyevog testa. Ti su testovi poslužili kao grubi filter čime su definirani široki kompleti vitkih alata koji se mogu koristiti za smanjenje određenih gubitaka.

II. Definirani su najbolji temeljni vitki alati za proces restrukturiranja poduzeća temeljem provedene multivarijatne linearne regresije. Taj je statistički test poslužio kao fini filter koji je istaknuo samo najbolje vitke alate za smanjenje gubitaka. Uvođenje tih vitkih alata treba biti popraćeno velikom pažnjom jer oni najbolje smanjuju gubitke.
III. Definiran je model pravilnog redoslijeda uvođenja vitkih alata pri restrukturiranju poduzeća. Dobiveni su modeli pojednostavili izbor vitkih alata te je proces implementacije vitke proizvodnje stavljen u stabilan i održiv okvir.

5.3. Ograničenja provedenog istraživanja

Provedeno istraživanje imalo je nekoliko ograničenja:

I. Pregledom literature definirani su preduvjeti za uvođenje pojedinih vitkih alata. Međutim, pregled literature temeljio se na znanstvenim časopisima i nekoliko značajnih knjiga. Opsežniji pregled literature trebao bi uključiti doktorske radove i članke manjeg značaja iz predmetnog područja.
II. Intervjuirane osobe pripadale su srednjem i vrhovnom menadžmentu te su bile uključene u proces restrukturiranja. Međutim, kvantifikacija gubitaka prije i poslije uvođenja vitke filozofije stvar je subjektivnog osjećaja i individualnog sustava vrijednosti.
III. Ovo je istraživanje obuhvatilo 25 temeljnih vitkih alata. Međutim, postoji više od stotinu drugih vitkih alata koji su možda značajni kod smanjenja gubitaka, a nisu bili obuhvaćeni ovom studijom.
IV. Neka anketirana poduzeća u trenutku istraživanja imala su veću „vitku zrelost“ pa su stoga bolje smanjila svoje gubitke. S druge strane, neka poduzeća vrlo kratko primjenjuju vitku filozofiju i njihov trenutni mali napredak možda ne predstavlja najbolje krajnji rezultat.
V. Dobiveni model izbora vitkih alata nije primjenjiv za sve makroekonomske okvire jer su svi ispitanici bili samo iz RH.
VI. Veličina i raznolikost uzorka premala je da bi se donosili globalni zaključci o vitkim alatima.

5.4. Smjernice za daljnja istraživanja

Buduća istraživanja trebala bi se fokusirati na primjenu vitkih alata u industriji 4.0. Pametna poduzeća bilježe i analiziraju velike količine podataka. Međutim, takva obrada podataka traje danima, tjednima, katkada i mjesecima što predstavlja gubitak. Bilo bi korisno otkriti koji vitki alati pridonose boljoj i održivoj digitalizaciji te na koji se način načela vitke filozofije mogu integrirati u industriju 4.0.

LITERATURA

[1] Womack PJ, Jones TD. Lean Thinking: Banish Waste and Create Wealth in Your Corporation. New York: Free Press. 1st edition. 2003., p. 26-27.

[2] Dombrowski U, Mielke T. Lean Leadership - Fundamental Principles and their Application. Forty Sixth CIRP Conference on Manufacturing Systems. Elsevier. Procedia CIRP 7. 2013;569-574, Available from: http://www.sciencedirect.com/science/article/pii/S221282711300303X.

[3] Belekoukias I, Garza-Reyes JA, Kumar V. The impact of lean methods and tools on the operational performance of manufacturing organisations. International Journal of Production Research. Taylor & Francis. 2014;52(18):5346-5366. Available from: http://dx.doi.org/10.1080/00207543.2014.903348.

[4a] Womack PJ, Jones TD, Roos D. The Machine that Changed the World. New York. Macmillan Publishing Company. Massachusetts Institute of Technology. 1990., p. 225.

[4b] Womack PJ, Jones TD, Roos D. The Machine That Changed The World, New York, Macmillan Publishing Company, Massachusetts Institute of Technology, (1990), pp. 276

[5] Dombrowski U. Zahn, T. Mielke, T. Roadmap for the Implementation of Lean Production Systems, 5th Americas International Conference on Production Research. 2010.

[6] Holtskog H. Continuous Improvement Beyond the Lean Understanding. Procedia CIRP. Elsevier. 2013;7:575–5799, Available from: http://www.sciencedirect.com/science/article/pii/S2212827113003041

[7] Sundar R, Balaji NA, Satheesh Kumar MR. A Review on Lean Manufacturing Implementation Techniques. Procedia Engineering. Elsevier. 2014;97:1875-1885. Available from: http://www.sciencedirect.com/science/article/pii/S1877705814034092

[8] Bozdogan K, Milauskas R, Mize J, Nightingale D, Taneja A, Tonaszuck D. Transition to a Lean Enterprise: A Guide for Leaders. Massachusetts Institute of Technology. 2000);3:11-25.

[9] https://www.leanproduction.com/top-25-lean-tools.html [Accesed 20.01.2016.]

[10] Krishna Jasti VN, Kodali R. Development of a framework for lean production system: An integrative approach. Procedia Institute of Mechanical Engineering. Part B: Sage Journals. Journal of Engineering Manufacture. 2016;230(1):136-156. Available from: http://journals.sagepub.com/doi/pdf/10.1177/0954405415596141.

[11] Carreira B. Lean Manufacturing That Works: Powerful Tools for Dramatically Reducing Waste and Maximizing Profits. New York. American Management Association books. Printing number: 109876. 2005., p. 2-3.

[12] Hines P, Taylor D. Going Lean - A Guide to Implementation. Cardiff (UK), Cardiff Business School. Lean Enterprise Research Centre, First Publish. 2000., p. 9-10.

[13] Wahab ANA, Mukhtar M, Sulaiman R. A Conceptual Model of Lean Manufacturing Dimensions. Procedia Technology. Elsevier. 2013;11:1292-1298. Available from: http://www.sciencedirect.com/science/article/pii/S2212017313004817.

[14] El-Namrouty AK, AbuShaaban SM. Seven Wastes Elimination Targeted by Lean Manufacturing Case Study "Gaza Strip Manufacturing Firms''. International Journal of Economics, Finance and Management Sciences. 2013;1(2):68-80. Available from: http://article.sciencepublishinggroup.com/pdf/10.11648.j.ijefm.20130102.12.pdf

[15] https://www.processexcellencenetwork.com/business-transformation/articles/the-8-deadly-lean-wastes-downtime [Accessed 21.10.2017.]

[16a] Liker KJ, Meier D. The Toyota Way Field book: A Practical Guide For Implementing Toyota's 4Ps. USA. McGraw Hill. 2006., p. 220-221. Available from: https://navysigma.files.wordpress.com/2012/07/book-lss-toyota-way.pdf

[16b] Liker KJ, Meier D. The Toyota Way Field book: A Practical Guide For Implementing Toyota's 4Ps. USA. McGraw Hill. 2006., p. 8-14. Available from: https://navysigma.files.wordpress.com/2012/07/book-lss-toyota-way.pdf

[16c] Liker KJ, Meier D. The Toyota Way Field book: A Practical Guide For Implementing Toyota's 4Ps. USA. McGraw Hill. 2006., p. 80-81. Available from: https://navysigma.files.wordpress.com/2012/07/book-lss-toyota-way.pdf

[16d] Liker KJ, Meier D. The Toyota Way Field book: A Practical Guide For Implementing Toyota's 4Ps. USA. McGraw Hill. 2006., p. 177-187. Available from: https://navysigma.files.wordpress.com/2012/07/book-lss-toyota-way.pdf

[16e] Liker KJ, Meier D. The Toyota Way Field book: A Practical Guide For Implementing Toyota's 4Ps. USA. McGraw Hill. 2006., p. 37. Available from: https://navysigma.files.wordpress.com/2012/07/book-lss-toyota-way.pdf

[17] Sikavica P, Bahtijarević-Šiber F, Vokić Pološki N. Temelji menadžmenta, Zagreb, Sveučilište u Zagrebu, Školska knjiga. 2008., p. 515-516

[18] Sugimori Y, Kusunoki K, Cho F. & Uchikawa S. Toyota production system and Kanban system Materialzation of just-in-time and respect-for-human system. International journal of production research. 1977;15(6):553-564. Available from: https://doi.org/10.1080/00207547708943149.

[19] Pegels CC, The Toyota Production System - Lessons for American Management. International Journal of Operations & Production Management. 1984;4(1):3-11. Available from: http://www.emeraldinsight.com/doi/pdfplus/10.1108/eb054703

[20] Benton, WC. Push and Pull Production Systems. Wiley Encyclopedia of Operations Research and Management Science. USA. John Wiley & Sons, Inc. 2011. Available from: https://doi.org/10.1002/9780470400531.eorms0690.

[21] Smalley A. Creating Level Pull - A lean production - system improvement guide for production - control, operations, and engineering professionals. Cambridge. MA. USA. The Lean Enterprise Institute. 2009., p. 107-108.

[22] Schonberger RJ. Applications of Single-Card and Dual-Card Kanban. Interfaces. Providence. 1983;13(4):56-67, Available from: https://doi.org/10.1287/inte.13.4.56

[23] Powell D, Strandhagen OJ, Tommelein I, Ballard G, Rossi M. A New Set of Principles for Pursuing the Lean Ideal in Engineer-to-order Manufacturers. Proceedings of the 47th CIRP Conference on Manufacturing Systems. Elsevier. 2014;17:571-576. Available from: http://www.sciencedirect.com/science/article/pii/S2212827114004144

[24] Kešetović A. Filozofija vitke proizvodnje – koncept, ki prinaša poslovne uspehe, Koper, Zbornik 9. Festivala raziskovanja ekonomije in managementa, Fakulteta za management Koper, (2012), pp. 227-233, Available from: http://www.fm-kp.si/zalozba/ISBN/978-961-266-135-9/prispevki/025.pdf

[25] Marodin AG, Saurin AT, Implementing lean production systems: research areas and opportunities for future studies. International Journal of Production Research. 2013;51(22):6663-6680. Available from: http://dx.doi.org/10.1080/00207543.2013.826831.

[26] Bhasin S. An appropriate change strategy for lean success. Journal of Manufacturing Technology Management. Emerald. 2012;17(4):439-58. Available from: https://doi.org/10.1108/00251741211216223.

[27] Yadav OP, Nepal BP, Rahaman MM, Lal V. Lean Implementation and Organizational Transformation: A Literature Review. Engineering Management Journal. Taylor & Francis. 2017;29(1):2-16. Available from: http://dx.doi.org/10.1080/10429247.2016.1263914.

[28] Scherrer-Rathje M, Boyle TA, Deflorin P. Lean, take two! Reflections from the second attempt at lean implementation. Business Horizons. 2009;52(1):79-88. Available from: http://www.sciencedirect.com/science/article/pii/S0007681308001304.

[29] Pakdil F, Leonard KM. Implementing and sustaining lean processes: the dilemma of societal culture effects. International Journal of Production Research. Taylor & Francis. 2017;55(3):700-717. Available from: http://dx.doi.org/10.1080/00207543.2016.1200761.

[30] Chiarini A. Sustainable manufacturing-greening processes using specific Lean Production tools: an empirical observation from European motorcycle component manufacturers. Journal of Cleaner Production. Elsevier. 2014;85:226-233. Available from: https://doi.org/10.1016/j.jclepro.2014.07.080.

[31] Pavnaskar SJ, Gershenson JK, Jambekar AB. Classification scheme for lean manufacturing tools. International Journal of Production Research. Taylor & Francis. 2003;41(13):3075-3090. Available from: https://doi.org/10.1080/0020754021000049817.

[32] Mourtzis D. Papathanasiou P. Fotia S. Lean Rules Identification and Classification for Manufacturing Industry. Procedia 26th CIRP Design Conference. Elsevier. 2016;50:198-203. Available from: http://www.sciencedirect.com/science/article/pii/S2212827116302840.

[33] https://www.mckinsey.com/business-functions/operations/our-insights/from-lean-to-lasting-making-operational-improvements-stick 02.12.2017.

[34] Netland TH. Exploring the phenomenon of company-specific production systems: One-best-way or own-best-way?. International Journal of Production Research. 2013;51(4):1084-1097. Available from: https://doi.org/10.1080/00207543.2012.676686.

[35] Rose AMN, Deros BM, Rahman MNAb & Nordin N. Lean manufacturing best practices in SMEs. Proceedings of the 2011 International Conference on Industrial Engineering and Operations Management. Kuala Lumpur. Malaysia. 2011:22-24. Available from: https://www.researchgate.net/publication/304346422_Lean_manufacturing_best_practices_in_SMEs.

[36] Jackson, AJ. Lean Manufacturing Initiatives: Are Small & Medium Enterprises Missing Out?. 2011. Available at SSRN: https://ssrn.com/abstract=2424588 or http://dx.doi.org/10.2139/ssrn.2424588.

[37] Begay SM, Swamynathan R, Sekkizhar J. Current Trends on Lean Management - A review, International Journal of Lean Thinking. 2013;4(2):14-21. Available from: http://thinkinglean.com/img/files/PAPER2_V4_I2.pdf.

[38] https://www.vorne.com/about-us/xl-customers.htm [Accessed 17.12.2017.]

[39] Srilalitha S. 'Ringi System' The Decision Making Process in Japanese Management Systems: An Overview. International Journal of Management and Humanities. 2015;1(7):10-11. ISSN: 2394-0913, Available at SSRN: https://ssrn.com/abstract=2597083.

[40] Feld MW. Lean Manufacturing Tools techniques and How to Use Them. CRC Press-Taylor & Francis Group, the Educational Society for Resource Management. 2000:85-87.

[41] https://www.fsb.unizg.hr/atlantis/upload/newsboard/20_09_2011__14682_Osnove_menadzmenta-LEAN.pdf [Accessed 20.12.2017.]

[42] Kobayashi K, Fisher R & Gapp R. Business improvement strategy or useful tool? Analysis of the application of the 5S concept in Japan, the UK and the US. Total Quality Management & Business Excellence. 2008;19(3):245-262, DOI: 10.1080/14783360701600[[4.

[43] Harea CV, Marian L, Moica S & Al-Akel K. Case study concerning 5S method impact in an automotive company. 11th International Conference Interdisciplinarity in Engineering, INTER-ENG 2017, 5-6 October,Tirgu-Mures, Romania. Procedia Manufacturing 2018;22:900-905. Available from: https://doi.org/10.1016/j.promfg.2018.03.127.

[44] Gupta S. & Kumar Jain S. The 5S and kaizen concept for overall improvement of the organisation: a case study. International Journal of Lean Six Sigma. 2015;6(1):73-88. Available from: https://doi.org/10.1108/IJLSS-08-2013-0047.

[45] https://www.leanvlog.com/lean-factory/ [Accessed 13.06.2020.]

[46] Mrugalska B. & Wyrwicka M.K. Towards Lean Production in Industry 4.0. 7th International Conference on Engineering, Project, and Production Management. Procedia Engineering 2018;182:466-473. Available from: https://doi.org/10.1016/j.proeng.2017.03.135.

[47] Monden Y. Toyota Production System: An Integrated Approach to Just-In-Time. Institute of Industrila Engineers. Chapmann & Hall. 1994.

[48] Biller S, Li J, Marin S.P, Meerkov S.M. & Zhang L. Bottlenecks in Production Lines with Rework: A System Approach. Proceedings of the 17th World Congress, The International Federation of Automatic Control, Seoul, Korea. IFAC Proceedings. 2008;41(2):14888-14893. Available from: https://doi.org/10.3182/20080706-5-KR-1001.02520.

[49] Roser C, Lorentzen K. & Deuse J. Reliable Shop Floor Bottleneck Detection for Flow Lines through Process and Inventory Observations. Robust Manufacturing Conference. Procedia CIRP. 2016;19:63-68. Available from: https://doi.org/10.1016/j.procir.2014.05.020.

[50] Subramaniyan M, Skoogh A, Salomonsson H, Bangalore P. & Bokrantz J. A data-driven algorithm to predict throughput bottlenecks in a production system based on active periods of the machines. Computers & Industrial Engineering. 2018;6(1):225-246. Available from: https://doi.org/10.1016/j.cie.2018.04.024.

[51] https://nofluffjuststuff.com/magazine/2016/08/optimizing_the_software_supply_chain [Accessed 13.06.2020]

[52] Leporis M. & Králová Z. Approach To Production Line Bottleneck Analysis. International Conference in Cybernetics and Informatics, Vyšna Boca, Slovak Republic, 10.02-13.02.2010. Available from: https://pdfs.semanticscholar.org/d974/dc2de44956c0cffe4a20721c79c2047c9650.pdf

[53] Zidane YJT, Johansen A, Andersen B. & Hoseini E. Time-thieves and bottlenecks in the Norwegian construction projects. 8th Nordic Conference on Construction Economics and Organization. Procedia Economics and Finance. 2015;21:486-493. Available from: https://doi.org/10.1016/S2212-5671(15)00203-8.

[54] http://www.engineersgallery.com/types-of-plant-layouts/ [Accessed 13.06.2020.]

[55] https://ebpmgroup.com/event/demo-executive-sur-le-gestion-des-processus-daffaires/one-piece-flow-assemblymag/ [Accessed 13.06.2020]

[56] https://www.allaboutlean.com/line-layout-i-s-u-l-lines/ [Accessed 13.06.2020]

[57] Li S.G. & Rong Y.L. The reliable design of one-piece flow production system using fuzzy ant colony optimization. Computers & Operations Research. 2009;36(5):1656-1663. Available from: https://doi.org/10.1016/j.cor.2008.03.010.

[58] Puchkova A, Romancer J.L. & McFarlane D. Balancing Push and Pull Strategies within the Production System. IFAAC –PapersOnLine. 2016;49(2):66-71. Available from: https://doi.org/10.1016/j.ifacol.2016.03.012.

[59] Norzaimi Che Ani M. The Effectiveness and impacts of one piece flow manufacturing technique into manufacturing industries. 3rd International Conference on Engineering and ICT (ICEI2012), Melaka, Malaysia. 04-06.04.2012.

[60] https://www.slideshare.net/InstitutLeanFrance/the-quest-of-onepieceflow-in-it-by-pierre-masai-toyota-motor-europe [Accessed 23.05.2018.]

[61] Suarez-Barraza M.F, Ramis-Pujol J. & Estrada-Robles M. Applying Gemba-Kaizen in a multinational food company: a process innovation framework. International Journal of Quality and Service Sciences. 2012;4(1):27-50. Available from: https://doi.org/10.1108/17566691211219715.

[62] Bremer M. Walk the line: The effective way to do a gemba walk. Quality Progess. March 2016;48(3):18-22.

[63] https://excelenciaempauta.com.br/liderando-a-mao-de-obra-no-chao-de-fabrica-via-excelencia-operacional/ [Accessed 13.06.2020.]

[64] Rewers P, Hamrol A, Żywicki K, Božek M. & Kulus W. Production Leveling as an Effective Method for Production Flow Control – Experience of Polish Enterprises. 7th International Conference on Engineering, Project, and Production Management. Procedia Engineering. 2017;182:619-626. Available from: https://doi.org/10.1016/j.proeng.2017.03.167.

[65] Cheng T.C.E. & Podolsky S. Just-In-Time manufacturing: An introduction. 2nd edition. London: McGraw-Hill; 1996.

[66] Hüttmeir A, Treville S, Ackere A, Monnier L. & Prenninger J. Trading off between heijunka and just-in-sequence. International Journal of Production Economics. 2009;118(2):501-507. Available from: https://doi.org/10.1016/j.ijpe.2008.12.014.

[67] Lippolt C.R. & Furmans K. (2008) Sizing of Heijunka-controlled Production Systems with Unreliable Production Processes. In: Koch T. (eds) Lean Business Systems and Beyond.

IFIP – The International Federation for Information Processing. 2008;257:11-19. Available from: https://doi.org/10.1007/978-0-387-77249-3_2.

[68] https://slideplayer.com/slide/3897783/ [Accessed 13.06.2020]

[69] https://www.sites.google.com/site/blueheronjournal/paging-dr-lean-paging-dr-lean/paging-dr-lean-for-manufacturing-solutions?tmpl=%2Fsystem%2Fapp%2Ftemplates%2Fprint%2F&showPrintDialog=1 [Accessed 13.06.2020.]

[70] Grimaud F, Dolgui A. & Korytkowski P. Exponential Smoothing for Multi-Product Lot-Sizing With Heijunka and Varying Demand. Management and Production Engineering Review. 2014;5(2):20-26. Available from: https://doi.org/10.2478/mper-2014-0013.

[71] Harris I. and Disney S.M. Levelling product mix in a Heijunka Board with shortest path algorithms. Pre-prints of the 18th International Working Seminar of Production Economics, Innsbruck, Austria, February 24th–28th, 2014;4:75-87.

[72] Cwiklicki M. TQM methods applied in the hoshin kanri management system. 6th International Scientific Conference May 13–14, 2010, Vilnius, Lithuania.

[73] Hutchins David. Hoshin Kanri: The strategic approach to continuous improvement. AI &Society. Gower, Taylor &Francis Group. 2010.

[74] https://www.pinterest.com/pin/374432156497652296/ [Accessed 13.06.2020]

[75] Witcher B.J, Chau V.S. & Harding P. Dynamic capabilities: top executive audits and hoshin kanri at Nissan South Africa. International Journal of Operations & Production Management. 2008;28(6):540-561. Available from: https://doi.org/10.1108/01443570810875359.

[76] Silveira W.G, Lima E.P, Costa S.E.G. & Deschamps F. Guidelines for Hoshin Kanri implementation: development and discussion. Production Planning & Control. 2017;28(10):843-859. Available from: https://doi.org/10.1080/09537287.2017.1325020.

[77] Nicholas J. Hoshin kanri and critical success factors in quality management and lean production. Total Quality Management & Business Excellence. 2014;27(3-4):250-264. Available from: https://doi.org/10.1080/14783363.2014.976938.

[78] Chiarini A, Baccarani C. & Mascherpa V. Lean production, Toyota Production System and Kaizen philosophy: A conceptual analysis from the perspective of Zen Buddhism. The TQM Journal. 2018. Available from: https://doi.org/10.1108/TQM-12-2017-0178.

[79] https://www.latestquality.com/jidoka-lean-manufacturing/ [Accessed 13.06.2020]

[80] Yang C.C. and Yang K.J. An Integrated Model of the Toyota Production System with Total Quality Management and People Factors. Human Factors and Ergonomics in

Manufacturing & Service Industries. 2012;23(5):450-461. Available from: https://doi.org/10.1002/hfm.20335.

[81] Fujimoto Takahiro. Why do Japanese Companies Automate Assembly operatinos? Discussion Paper for the Berlin Workshoop on Assembly Automation. 1992:1-18. Available from: http://www.cirje.e.u-tokyo.ac.jp/research/dp/92/f15/dp.pdf.

[82] Boakye-Adjei K, Thamma R. and Kirby E.D. Autonomation: The Future of Manufacturing. IJISET - International Journal of Innovative Science, Engineering & Technology. 2015;2(10):214-219. Available from: http://ijiset.com/vol2/v2s10/IJISET_V2_I10_30.pdf.

[83] Kannan V.R. & Tan K.C. Just in time, total qualitymanagement, and supplychain management: understanding their linkages and impact on business performance. Omega. 2005;33(2):153-162. Available from: https://doi.org/10.1016/j.omega.2004.03.012.

[84] Handfield Robert. Distinguishing Features of Just-in-Time Systems in the Make-to-Order/Assemble-to-Order Environment. Decision Sciences. 1993;24(3):581-602. Available from: https://doi.org/10.1111/j.1540-5915.1993.tb01294.x.

[85] Inman R.A. & Mehra S. Financial Justification of JIT Implementation", International Journal of Operations & Production Management. 1993;13(4):32-39, Available from: https://doi.org/10.1108/01443579310027734.

[86] Ward P, Zhou H. Impact of Information Technology Integration and Lean/Just-In-Time Practices on Lead-Time Performance. Decision Sciences. 2006;37(2):177-203. Available from: https://doi.org/10.1111/j.1540-5915.2006.00121.x.

[87] Sánchez A.M. & Pérez M.P. Lean indicators and manufacturing strategies. International Journal of Operations & Production Management. 2001;21(11):1433-1452. Available from: https://doi.org/10.1108/01443570110407436.

[88] Bortolotti T, Danese P. & Romano P. Assessing the impact of just-in-time on operational performance at varying degrees of repetitiveness. International Journal of Production Research. 2013;51(4):1117-1130. Available from: https://doi.org/10.1080/00207543.2012.678403.

[89] Golhar D.Y. & Stamm C.L. The just-in-time philosophy: A literature review. International Journal of Production Research. 1991; 29(4):657-676. Available from: https://doi.org/10.1080/00207549108930094.

[90] Hopp W.J. & Spearman M.L. To Pull or Not to Pull: What Is the Question?. Manufacturing & Service Operations Management. 2004;6(2):133-148. Available from: http://dx.doi.org/10.1287/msom.1030.0028.

[91] Inman, R. R. Inventory is the flower of all evil. Production Inventory Management Journal. 1993;34(4):41-45.

[92] https://slideplayer.com/slide/12891903/ [Accessed 13.06.2020.]

[93] Brunet A.P. & New S. Kaizen in Japan: an empirical study. International Journal of Operations & Production Management. 2003;23(12):1426-1446. Available from: https://doi.org/10.1108/01443570310506704.

[94] Farris J.A, Van Aken E.M, Doolen T.L. and Worley J. Critical success factors for human resource outcomes in Kaizen events: An empirical study. International Journal of Production Economics. 2009;117(1):42-65. Available from: https://doi.org/10.1016/j.ijpe.2008.08.051.

[95] https://clubtechnical.com/kaizen [Accessed 13.06.2020.]

[96] Aoki Katsuki. Transferring Japanese kaizen activities to overseas plants in China. International Journal of Operations & Production Management. 2008;28(6):518-539. Available from: https://doi.org/10.1108/01443570810875340.

[97] https://www.lean.org/workshops/WorkshopDescription.cfm?WorkshopId=83 [Accessed 13.06.2020]

[98] Bessant J, Caffyn S. & Gallagher M. An evolutionary model of continuous improvement behaviour. Technovation. 2001;21(2):67-77. Available from: https://doi.org/10.1016/S0166-4972(00)00023-7.

[99] García J.L, Rivera D.G. & Iniesta A.A. Critical success factors for Kaizen implementation in manufacturing industries in Mexico. The International Journal of Advanced Manufacturing Technology. 2013;68(1-4):537-545. Available from: https://doi.org/10.1007/s00170-013-4750-2.

[100] Wittenberg G. Kaizen - The many ways of getting better. Assembly Automation. 1994;14(4):12-17. Available from: https://doi.org/10.1108/EUM0000000004213.

[101] Montabon Frank. Using kaizen events for back office processes: the recruitment of frontline supervisor co-ops. Total Quality Management & Business Excellence. 2005;16(10):1139-1147. Available from: https://doi.org/10.1080/14783360500235876.

[102] García J.L. and Maldonado A.A. Human critical success factors for kaizen and its impacts in industrial performance. The International Journal of Advanced Manufacturing Technology. 2017;70(9-12):2187-2198. Available from: https://doi.org/10.1007/s00170-013-5445-4.

[103] https://www.pinterest.se/pin/490188740690795529/ [Accessed 13.06.2020]

[104] Junior M.L. & Filho M.G. Variations of the kanban system: Literature review and classification. International Journal of Production Economics. 2010;125(1):13-21. Available from: https://doi.org/10.1016/j.ijpe.2010.01.009.

[105] Akturk M.S. & Erhun F. An overview of design and operational issues of kanban systems. International Journal of Production Research. 1999;37(17):3859-3881. Available from: http://dx.doi.org/10.1080/002075499189808.

[106] Huang C.C. & Kusiak A. Overview of Kanban systems. International Journal of Computer Integrated Manufacturing. 1996;9(3)169-189. Available from: http://dx.doi.org/10.1080/095119296131643.

[107] Karmarkar U.S. & Kekre S. Batching Policy in Kanban systems. Journal of Manufacturing Systems. 1989;8(4):317-328. Available from: https://doi.org/10.1016/0278-6125(89)90009-5.

[108] Thürer M. Land M.J. Stevenson M. & Fredendall L.D. Card-based delivery date promising in high-variety manufacturing with order release control. Interantional Journal of Production Economics. 2016;172:19-30. Available from: https://doi.org/10.1016/j.ijpe.2015.11.003.

[109] https://www.mpug.com/articles/introduction-to-kanban-kanban-system-and-kanban-development/ [Accessed 28.6.2018.]

[110] Miwa K. & Nomura J. Module-based modeling and analysis of just-in-time production adopting dual-card kanban system and Mizusumashi worker. Winter Simulation Conference (WSC) December 03-06, 2017. Available from: http://dx.doi.org/10.1109/WSC.2017.8248088.

[111] Mukhopadhyay S.K. & Shanker S. Kanban implementation at a tyre manufacturing plant: a case study. Production Planning & Control: The Management of Operations. 2005;16(5):488-499. Available from: http://dx.doi.org/10.1080/09537280500121778.

[112] https://www.weigang.de/en/world-topics/methods/kanban/kanban-application-example [Accessed 13.06.2020]

[113] Ishaq Bhatti M. Awan H.M. & Razaq Z. The key performance indicators (KPIs) and their impact on overall organizational performance. Quality & Quantity. 2014;48(6):3127-3143. Available from: https://doi.org/10.1007/s11135-013-9945-y.

[114] Keeble J.J. Topiol S. & Berkeley S. Using Indicators to Measure Sustainability Performance at a Corporate and Project Level. Journal of Business Ethics. 2003;44(2-3):149-158. Available from: https://doi.org/10.1023/A:1023343614973.

[115] Sanderson D. List of Top 20 Financial KPI: Examples of the Most Popular Key Performance Indicators Defined by Categories". The KPI Examples Review, 2016.

[116] https://www.assemblymag.com/articles/94316-magnetic-whiteboard-system-for-performance-tracking?v=preview [Accessed 12.06.2020.]

[117] Kang N., Zhao C., Li J. & Horst J.A. A Hierarchical structure of key performance indicators for operation management and continuous improvement in production systems. International Journal of Production Research. 2016;54(21):6333-6350. Available from: https://doi.org/10.1080/00207543.2015.1136082.

[118] Shahin A. & Mahbod M.A. Prioritization of key performance indicators: An integration of analytical hierarchy process and goal setting. International Journal of Productivity and Performance Management. 2007;56(3):226-240. Available from: https://doi.org/10.1108/17410400710731437.

[119] Lewis M.A. Lean production and sustainable competitive advantage. International Journal of Operations & Production Management. 2000;20(8):959-978. Available from: https://doi.org/10.1108/01443570010332971.

[120] Suárez-Barraza M.F., Dahlgaard-Park S.M., Rodríguez-González F.G. & Durán-Arechiga C. In search of "Muda" through the TKJ diagram. International Journal of Quality and Service Sciences. 2016;8(3):377-394. Available from: https://doi.org/10.1108/IJQSS-04-2016-0028.

[121] Szwejczewski M. & Jones M. Lean Improvement: Eliminating Waste and Inventory. In: Learning From World-Class Manufacturers. Palgrave Macmillan; 2013., p. 47-65. Available from: https://doi.org/10.1057/9781137292308_3.

[122] Lewis P. & Cooke G. Developing a lean measurement system to enhance process improvement. International Journal of Metrology and Quality Engineering. 2013;4(3):145151. Available from: https://doi.org/10.1051/ijmqe/2013058.

[123] Vinodh S, Arvind K.R. & Somanaathan M. Tools and techniques for enabling sustainability through lean initiatives. Clean Technologies and Environmental Policy. 2011;13(3):469-479. Available from: https://doi.org/10.1007/s10098-010-0329-x.

[124] Radnor Z., Walley P., Stephens A. & Bucci G. Evaluation of the lean approach to business management and its use in the public sector: Scottish Executive Edinburgh. 2006, p. 78. Available from: http://www.gov.scot/resource/doc/129627/0030899.pdf.

[125] Rawabdeh I.A. A model for the assessment of waste in job shop environments. International Journal of Operations & Production Management. 2005;25(8):800-822. Available from: https://doi.org/10.1108/01443570510608619.

[126] Zammori F, Braglia M. & Frosolini M. Stochastic overall equipment effectiveness. International Journal of Production Research. 2015;49(21):6469-6490. Available from: https://doi.org/10.1080/00207543.2010.519358.

[127] Koch Arno. Discover the Hidden Machine: OEE for the Production Team : the Complete OEE User Guide. Fullfact, 2007.

[128] Gibbons P.M. & Burgess S.C. Introducing OEE as a measure of lean Six Sigma capability. International Journal of Lean Six Sigma. 2010;1(2):134-156. Available from: https://doi.org/10.1108/20401461011049511.

[129] Benjamin S.J, Murugaiah U. & Marathamuthu M.S. The use of SMED to eliminate small stops in a manufacturing firm. Journal of Manufacturing Technology Management. 2013;24(5):792-807. Available from: https://doi.org/10.1108/17410381311328016.

[130] Zammori F. Fuzzy Overall Equipment Effectiveness (FOEE): capturing performance fluctuations through LR Fuzzy numbers. Production Planning & Control: The Management of Operations. 2015;26(6):451-466. Available from: https://doi.org/10.1080/09537287.2014.920545.

[131] Zuashkiani A, Rahmandad H. & Jardine A.K.S. Mapping the dynamics of overall equipment effectiveness to enhance asset management practices. Journal of Quality in Maintenance Engineering. 2011;17(1):74-92. Available from: https://doi.org/10.1108/13552511111116268.

[132] Jonsson P. & Lesshammar M. Evaluation and improvement of manufacturing performance measurement systems - the role of OEE. International Journal of Operations & Production Management. 1999;19(1):55-78. Available from: https://doi.org/10.1108/01443579910244223.

[133] Hedman R, Subramaniyan M. & Almström P. Analysis of Critical Factors for Automatic Measurement of OEE. Procedia CIRP. 2016;57:128-133. Available from: https://doi.org/10.1016/j.procir.2016.11.023.

[134] https://www.ibm.com/blogs/insights-on-business/electronics/hey-bud-want-free-manufacturing-line-part-2/ [Accesed 23.07.2018.]

[135] Hasrulnizzam Wan Mahmood W, Abdullah I. & Hafidz Fazli MdFauadi M. Translating OEE Measure into Manufacturing Sustainability. Applied Mechanics and Materials. 2015;761:555-559. Available from: https://10.4028/www.scientific.net/AMM.761.555

[136] Ratnagiri P. Gnanavelbabu A. Identification of High Impact Lean Production Tools in Automobile Industries using Weighted Average Method. Procedia Engineering. 2014;97:2072-2080. Available from: https://doi.org/10.1016/j.proeng.2014.12.450.

[137] Clark D.M, Silvester K. & Knowles S. Lean management systems: creating a culture of continuous quality improvement. Journal of Clinical Pathology. 2013;66:638-643. Available from: https://10.1136/jclinpath-2013-201553.

[138] Cagliano R, Caniato F, Corso M. & Spina G. Collaborative improvement in the extended manufacturing enterprise: lessons from an action research process. Production Planning & Control. 2005;16(4):345-355. Available from: https://doi.org/10.1080/09537280500063251.

[139] Meiling J.H, Sandberg M. & Johnsson H. A study of a plan-do-check-act methodused in less industrialized activities: two cases from industrialized housebuilding. Construction Management and Economics. 2014;32(1-2):109-125. Available from: https://doi.org/10.1080/01446193.2013.812227.

[140] https://conceptdraw.com/a1739c4/preview [Accessed 01.06.2020.]

[141] Lodgaard E, Gamme I. & Aasland K.E. Success Factors for PDCA as Continuous Improvement Method in Product Development. In: Emmanouilidis C, Taisch M, Kiritsis D. editors. Advances in Production Management Systems. Competitive Manufacturing for Innovative Products and Services. APMS 2012. IFIP Advances in Information and Communication Technology. 2013;397:645652. Available from: https://doi.org/10.1007/978-3-642-40352-1_81.

[142] Schmidt M.T, Elezi F, Tommelein I.D. & Lindemann U. Towards Recursive Plan-Do-Check-Act Cycles for Continuous Improvement. IEEE International Conference on Industrial Engineering and Engineering Management. 2014:1486-1490. Available from: https://10.1109/IEEM.2014.7058886.

[143] Chiarini A. Japanese total quality control, TQM, Deming's system of profound knowledge, BPR, Lean and Six Sigma: Comparison and discussion. International Journal of Lean Six Sigma, 2011;2(4):332-355, Available from: https://doi.org/10.1108/20401461111189425.

[144] Watson G.H. & DeYong C.F. Design for Six Sigma: caveat emptor. International Journal of Lean Six Sigma. 2010;1(1):66-84. Available from: https://doi.org/10.1108/20401461011033176.

[145] Matsuo M. & Nakahara J. The effects of the PDCA cycle and OJT on workplace learning. The International Journal of Human Resource Management. 2013;24(1):195-207. Available from: https://doi.org/10.1080/09585192.2012.674961.

[146] Meng-Meng R, Ling N, Wei X. & Shu-Hai F. The Application of PDCA Cycle Management in Project Management. International Conference on Computer Science and Applications (CSA). Wuhan, China, 20.11.-22.11.2015. Available from: http://10.1109/CSA.2015.84.

[147] Larina L.N. Practical Application of Total Quality Management System to Education of International Students. Procedia - Social and Behavioral Sciences. 2015;215:9-13. Available from: https://doi.org/10.1016/j.sbspro.2015.11.566.

[148] Khoury L. & Amin A. What Hospitalists Need to Know About Quality Improvement. Current Emergency and Hospital Medicine Reports. 2017;5(3):109-113. Available from: https://doi.org/10.1007/s40138-017-0139-0.

[149] Chase R.B. & Stewart D.M. Make your service fail-safe. Sloan Management Review. 1994;35(3):35-44. Available from: https://sloanreview.mit.edu/article/make-your-service-failsafe/.

[150] Erlandson R.F. & Sant D. Poka-Yoke Process Controller: Designed for Individuals with Cognitive Impairments. Assistive Technology: The Official Journal of RESNA. 1998;10(2):102-112. Available from: http://dx.doi.org/10.1080/10400435.1998.10131968.

[151] Stewart D.M. & Grout J.R. The Human Side of Mistake-Proofing. Production and Operations Management. 2001;10(4):440-459. Available from: https://doi.org/10.1111/j.1937-5956.2001.tb00086.x.

[152] Tsou J.C. & Chen W.J. The impact of preventive activities on the economics of production systems: Modeling and application. Applied Mathematical Modelling. 2008;32(6):1056-1065. Available from: https://doi.org/10.1016/j.apm.2007.03.005.

[153] Vinod M, Devadasan S.R, Sunil D.T. & Thilak V.M.M. Six Sigma through Poka-Yoke: a navigation through literature arena. The International Journal of Advanced Manufacturing Technology. 2015;81(1-4):315-327. Available from: https://doi.org/10.1007/s00170-015-7217-9.

[154] Desai D.A, Kotadiya P, Makwana N. & Patel S. Curbing variations in packaging process through Six Sigma way in a large-scale food-processing industry. Journal of Industrial Engineering International. 2015;11(1):119-129. Available from: https://doi.org/10.1007/s40092-014-0082-6.

[155] Garza-Reyes J.A, Kumar V, Chaikittisilp S. & Tan K.H. The effect of lean methods and tools on the environmental performance of manufacturing organisations. International Journal of Production Economics. 2018;200:170-180. Available from: https://doi.org/10.1016/j.ijpe.2018.03.030.

[156] Teeravaraprug J, Kitiwanwong K. & Saetong N. Relationship model and supporting activities of JIT, TQM and TPM. Songklanakarin Journal of Science and Technology. 2011;33(1):101-106. Available from: http://rdo.psu.ac.th/sjstweb/journal/33-1/0125-3395-33-1-101-106.pdf.

[157] MÍkva M, Prajová V, Yakimovich B, Korshunov A. & Tyurin I. Standardization – One of the Tools of Continuous Improvement. Procedia Engineering. 2016;149:329-332. Available from: https://doi.org/10.1016/j.proeng.2016.06.674.

[158] Shimbun N.K. Poka-Yoke: Improving Product Quality by Preventing Defects. Portland: Productivity Press; 1988.

[159] Latino R.J. & Latino K.C. Root Cause Analysis: Improving Performance for Bottom-Line Results. 3rd edition. Boca Raton: CRC Press, Taylor & Francis Group; 2006.

[160] Andersen B. & Fagerhaug T. Root Cause Analysis: Simplified Tools and Techniques. 2nd Edition. Milwaukee: American Society for Quality (ASQ), Quality Press; 2006.

[161] Schriefer J. & Leonard M.S. Patient safety and quality improvement: an overview of QI. Pediatrics in Review. 2012;33(8):353-359. Available from: htttps://doi.org/10.1542/pir.33-8-353.

[162] Al-Tahat M.D. & Jalham I.S. A structural equation model and a statistical investigation of lean-based quality and productivity improvement. Journal of Intelligent Manufacturing. 2015;26(3):571-583. Available from: https://doi.org/10.1007/s10845-013-0816-0.

[163] Singh B.J. & Khanduja D. SMED: for quick changeovers in foundry SMEs. International Journal of Productivity and Performance Management. 2009;59(1):98-116. Available from: https://doi.org/10.1108/17410401011006130.

[164] Braglia M, Frosolini M. & Gallo M. SMED enhanced with 5-Whys Analysis to improve set-upreduction programs: the SWAN approach. The International Journal of Advanced Manufacturing Technology. 2017;90(5-8):1845-1855. Available from: https://doi.org/10.1007/s00170-016-9477-4.

[165] Mahto D. & Kumar A. Application of root cause analysis in improvement of product quality and productivity. Journal of Industrial Engineering and Management. 2008;1(2):16-53. Available from: http://dx.doi.org/10.3926/jiem..v1n2.p16-53.

[166] Garg P. & Garg A. An empirical study on critical failure factors for enterprise resource planning implementation in Indian retail sector. Business Process Management Journal. 2013;19(3):496-514. Available from: https://doi.org/10.1108/14637151311319923.

[167] Serrat O. The Five Whys Technique. Knowledge Solutions. 2017;307-310. Available from: https://doi.org/10.1007/978-981-10-0983-9_32.

[168] Sharma R.K, Kumar D. & Kumar P. Modeling and analysing system failure behaviour using RCA, FMEA and NHPPP models. International Journal of Quality & Reliability Management. 2007;24(5):525-546. Available from: https://doi.org/10.1108/02656710710748385.

[169] McIntosh R.I, Culley S.J, Mileham A.R. & Owen G.W. A critical evaluation of Shingo's 'SMED' (Single Minute Exchange of Die) methodology. International Journal of Production Research. 2000;38(11):2377-2395. Available from: http://dx.doi.org/10.1080/00207540050031823.

[170] Cakmacki M. Process improvement: performance analysis of the setup time reduction-SMED in the automobile industry. The International Journal of Advanced Manufacturing Technology. 2009;41(1-2):168-179. Available from: https://doi.org/10.1007/s00170-008-1434-4.

[171] Almomani M.A, Aladeemy M, Abdelhakim A. & Mumani A. A proposed approach for setup time reduction through integrating conventional SMED method with multiple criteria

decision-making techniques. Computers & Industrial Engineering. 2013;66(2):461-469. Available from: https://doi.org/10.1016/j.cie.2013.07.011.

[172] Moreira A.C. & Pais G.C.S. Single Minute Exchange of Die: A Case Study Implementation. Journal of Technology Management & Innovation. 2011;6(1):129-146. Available from: http://dx.doi.org/10.4067/S0718-27242011000100011.

[173] Coimbra E.A. Total Flow Management: Achieving Excellence with Kaizen and Lean Supply Chains. Kaizen Institute. 2009.

[174] Gest G, Culley S.J, McIntosh R.I, Mileham A.R. & Owen, G.W. Review of fast tool change systems. Computer Integrated Manufacturing Systems. 1995;8(3):205-210. Available from: https://doi.org/10.1016/0951-5240(95)00011-H.

[175] Morales Méndez J.D, & Silva Rodríguez. The International Journal of Advanced Manufacturing Technology. 2016:84(9-12):1907-1916. Available from: https://doi.org/10.1007/s00170-015-7845-0.

[176] Sabadka D, Molnar V. & Fedorko G. The use of lean manufacturing techniques - SMED analysis to optimization of the production process. Advances in Science and Technology Research Journal. 2017;11(3):187-195. Available from: https://doi.org/10.12913/22998624/76067.

[177] Cakmacki M. & Kemal Karasu M. Set-up time reduction process and integrated predetermined time system MTM-UAS: A study of application in a large size company of automobile industry. The International Journal of Advanced Manufacturing Technology. 2007;33(3-4):334-344. Available from: https://doi.org/10.1007/s00170-006-0466-x.

[178] Dal B, Tugwell P.& Greatbanks R. Overall equipment effectiveness as a measure of operational improvement – A practical analysis. International Journal of Operations & Production Management. 2000;20(12):1488-1502. Available from: https://doi.org/10.1108/01443570010355750.

[179] Nakajima S. Introduction to TPM: Total Productive Maintenance. Massachusetts: Productivity Press; 1988.

[180] Badiger A.S, Gandhinathan R. & Gaitonde V.N. A methodology to enhance equipment performance using the OEE measure. European Journal of Industrial Engineering. 2008;2(3):356-376. Available from: https://doi.org/10.1504/EJIE.2008.017690.

[181] Wudhikarn R. Improving overall equipment cost loss adding cost of quality. International Journal of Production Research. 2012;50(12):3434-3449. Available from: https://doi.org/10.1080/00207543.2011.587841.

[182] Ahuja I.P.S. & Khamba J.S. Total productive maintenance: literature review and directions. International Journal of Quality & Reliability Management. 2008;25(7):709-756. Available from: https://doi.org/10.1108/02656710810890890.

[183] Brown C.B, Collins T.R. & McCombs E.L. Transformation From Batch to Lean Manufacturing: The Performance Issues. Engineering Management Journal. 2006;18(2):3-14. Available from: https://doi.org/10.1080/10429247.2006.11431689.

[184] Smith R. and Hawkins B. Lean Maintenance: Reduce Costs, Improve Quality, and Increase Market Share. Massachusetts; Elsevier Butterworth-Heinemann: 2004. p. 56-57.

[185] Yemm G. Leading Your Team: How to set goals, measure performance and reward talent. Harlow; Pearson, Financial Times: 2012.

[186] Kaganski S, Majak J. & Karjust K. Fuzzy AHP as a tool for prioritization of key performance indicators. Procedia CIRP. 2018;72:1227-1232. Available from: https://doi.org/10.1016/j.procir.2018.03.097.

[187] McDermott L, Waite B. & Brawley N. Putting together a world-class team. Training & Development. 1999;53(1):47-51.

[188] Doran G.T. There's a S.M.A.R.T. way to write managements' goals and objectives. Management Review. 1981;70:35-36.

[189] Locke E. A. & Latham G. P. Building a Practically Useful Theory of Goal Setting and Task Motivation. American Psychologist. 2002;57(9):705-717.

[190] Madison P. The Importance of Setting SMART Goals. Available from: http://www.hydratemarketing.com/blog/the-importance-of-setting-smart-goals [cited 2018 Sep 19]

[191] Lander E. & Liker J.K. The Toyota Production System and art: making highly customized and creative products the Toyota way. International Journal of Production Research. 2007;45(16): 3681-3698. Available from: http://dx.doi.org/10.1080/00207540701223519.

[192] https://www.slideshare.net/oeconsulting/standard-work-by-operational-excellence-consulting [Accessed 20.09.2018.]

[193] Johansson P.E.C, Lezama T, Malmsköld L, Sjögren B. & Ahlström L.M. Current State of Standardized Work in Automotive Industry in Sweden. Procedia CIRP. 2013;7:151-156. Available from: https://doi.org/10.1016/j.procir.2013.05.026.

[194] Whitmore T. Standardized work. Manufacturing Engineering. 2008;140(5):171-179.

[195] Benders J. & van Hootegem G. Teams and their context: moving the team discussion beyond existing dichotomies. Journal of Management Studies. 1999;36(5):609-628. Available from: https://doi.org/10.1111/1467-6486.00151.

[196] Gilson L.L, Mathieu J.E, Shalley C.E. & Ruddy T.M. Creativity and Standardization: Complementary or Conflicting Drivers of Team Effectiveness?. The Academy of Management Journal. 2005;48(3):521-531. Available from: https://www.jstor.org/stable/20159673.

[197] MÍkva M, Prajová V, Yakimovich B, Korshunov A. & Tyurin I. Standardization - one of the tools of continuous improvement. Procedia Engineering. 2016;149:329-332. Available from: https://doi.org/10.1016/j.proeng.2016.06.674.

[198] Hall R.W. "Lean" and the Toyota Production System. Target. 2004;20(3):22-27. Available from: http://www.ame.org/sites/default/files/target_articles/04-20-3-Lean_and_TPS.pdf

[199] Fin J.C, Vidor G, Cecconello I. & Machado V.D. Improvement based on standardized work: an implementation case study. Brazilian Journal of Operations & Production Management. 2017;14(3):388-395. Availae from: https://doi.org/10.14488/BJOPM.2017.v14.n3.a12.

[200] Yu H, Al-Hussein M, Al-Jibouri S.& Telyas A. Case Study Lean Transformation in a Modular Building Company: A Case for Implementation. Journal of Management in Engineering. 2013;29(1):103-111. Available from: https://doi.org/10.1061/(ASCE)ME.1943-5479.0000115.

[201] Ayabakan M. & Eken Ö. Creating 5S climate at the shopfloor. In: Kocaoglu D.F, Anderson T.R, Daim T.U, Kozanoglu D.C, Niwa K. & Perman. G, editor. Portland International Conference on Management of Engineering & Technology (PICMET) 2014; Kanazawa, Japan, 27.07.-31.07.2014.

[202] Vilkas M, Koreckaja I, Katiliūtė E. & Bagdonienė D. Adoption of Lean Production: Preliminary Evidence from Lithuania. Procedia - Social and Behavioral Sciences. 2015;213(1):884-889. Available from: https://doi.org/10.1016/j.sbspro.2015.11.500.

[203] Pattanaik L.N. & Sharma B.P. Implementing lean manufacturing with cellular layout: a case study. International Journal of Advanced Manufacturing Technology. 2009;42(7-8):772-779. Available from: https://doi.org/10.1007/s00170-008-1629-8.

[204] Seth D. & Gupta V. Application of value stream mapping for lean operations and cycle time reduction: an Indian case study. Production Planning & Control. 2005;16(1):44:59. Available from: https://doi.org/10.1080/09537280512331325281.

[205] Simons D. & Zokaei K. Application of lean paradigm in red meat processing. British Food Journal. 2005;107(4-5):192-211. Available from: https://doi.org/10.1108/00070700510589495.

[206] https://tulip.co/blog/lean-manufacturing/bringing-lean-to-the-21st-century-with-manufacturing-apps/ [Accessed 12.06.2020]

[207] Deif A.M. Dynamic analysis of a lean cell under uncertainty. International Journal of Production Research. 2012;50(4):1127-1139. Available from: https://doi.org/10.1080/00207543.2011.556154.

[208] Bockhorst J.A.C. & Slomp J. Lean Production Control at a High-Variety, Low-Volume Parts Manufacturer. Interfaces. 2010;40(4):303-312. Available from: http://dx.doi.org/10.1287/inte.1100.0503.

[209] Ali R.M. & Deif A.M. Dynamic Lean Assessment for Takt Time Implementation. Procedia CIRP. 2014;17:577-581. Available from: https://doi.org/10.1016/j.procir.2014.01.128.

[210] Abdelhadi A. Investigating emergency room service quality using lean manufacturing. International Journal of Health Care Quality Assurance. 2015;28(5):510-519. Available from: https://doi.org/10.1108/IJHCQA-01-2015-0006.

[211] Pujo P, El Khabous I. & Ounnar F. Experimental assessment of the productivity improvement when using U-shaped production cells with variable takt time. International Journal of Six Sigma. 2015;6(1):17-38. Available from: https://doi.org/10.1108/IJLSS-07-2013-0038.

[212] Reynolds K.T. Cellular manufacturing & the concept of total quality. Computers & Industrial Engineering. 1998;35(1-2):89-92. Available from: https://doi.org/10.1016/S0360-8352(98)00027-8.

[213] Carleton S.A. & Six Sigma Academy. The Lean Six Sigma Tools Memory Jogger: The Concise Reference Guide for LLS Success. Goal/QPC;2016. Available from: https://memoryjoggerlibrary.com/book/lean-six-sigma-tools/onePieceFlow.

[214] Mobley R.K. An Introduction to Predictive Maintenance. New York: Van Nostrand Reinhold; 1990.

[215] Robinson C.J. and Ginder A.P. Implementing TPM: The North American Experience. Portland: Productivity Press; 1995.

[216] Chaneski W.S. Total productive maintenance – an effective technique. Modern Machine Shop. 2002;75(2):46-48.

[212] Jostes R.S. & Helms M.M. Total Productive Maintenance and Its Link to Total Quality Management. Work Study. 1994;43:18-20. Available from: https://doi.org/10.1108/EUM0000000004012.

[218] Jain A, Bhatti R. & Singh H. Total productive maintenance (TPM) implementation practice: A literature review and directions. International Journal of Lean Six Sigma. 2014;5(3):293-323. Available from: https://doi.org/10.1108/IJLSS-06-2013-0032.

[219] Noon M, Jenkins S. & Martinez Lucio M. Fads, Techniques and Control: The Competing Agendas of TPM and TECEX at the Royal Mail (UK). Journal of Management Studies. 2000;37(4):499-520. Available from: https://doi.org/10.1111/1467-6486.00191.

[220] McKone K.E, Schroeder R.G. & Cua K.O. The impact of total productive maintenance practices on manufacturing performance. Journal of Operations Management. 2001;19(1):39-58. Available from: https://doi.org/10.1016/S0272-6963(00)00030-9.

[221] Brah S.A & Chong W.K. Relationship between total productive maintenance and performance. International Journal of Production Research. 2004;42(12):2383-2401. Available from: https://doi.org/10.1080/00207540410001661418.

[222] Pinjala S.K, Pintelon L. & Vereecke A. An empirical investigation on the relationship between business and maintenance strategies. International Journal of Production Economics. 2006;104(1):214-229. Available from: https://doi.org/10.1016/j.ijpe.2004.12.024.

[223] Ahuja I.P.S. & Khamba. J.S. Total productive maintenance: literature review and directions. International Journal of Quality & Reliability Management. 2008;25(7):709-756. Available from: https://doi.org/10.1108/02656710810890890.

[224] Quality Assurance Solutions. Total Productive Maintenance (TPM): Maximizing Equipment Effectiveness for Operational Excellence. Available from: https://www.quality-assurance-solutions.com/Total-Productive-Maintenance.html. [cited 2018 Oct 09]

[225] https://leanmanufacturing.online/tag/tpm-training-course/ [Accessed 11.06.2020.]

[226] Charantimath P.M. Total Quality Management. India. Pearson. 2011. p. 436.

[227] Rother M. & Shook J. Learning to See: Value Stream Mapping to Add Value and Eliminate Muda. Brookline, MA: The Lean Enterprise Institute: 1999.

[228] Andreadis E, Garza-Reyes J. & Kumar V. Towards a conceptual framework for value stream mapping (VSM) implementation: an investigation of managerial factors. International Journal of Production and Research. 2017;55(23):7073-7095. Available from: https://doi.org/10.1080/00207543.2017.1347302.

[229] Karen Martin Associates. Lean Webinar Series: Value Stream Mapping in Office & Service Environments. 2009. Available from: https://pt.slideshare.net/KarenMartinGroup/value-stream-mapping-in-office-service-setttings/27-Value_Stream_Mapping_ProcessProducts_good. [Accesed 15.10.2018.]

[230] Shou W, Wang J, Wu P, Wang X. & Chong H.Y. A cross-sector review on the use of value stream mapping. International Journal of Production Research. 2017;55(13):3906-3928. Available from: https://doi.org/10.1080/00207543.2017.1311031.

[231] Lugert A, Batz A. & Winkler H. Empirical assessment of the future adequacy of value stream mapping in manufacturing industries. Journal of Manufacturing Technology Management. 2018;29(5):886-906. Available from: https://doi.org/10.1108/JMTM-11-2017-0236.

[232] Vinodh S, Arvind K.R. & Somanaathan M. Application of value streammapping in an Indian camshaftmanufacturing organisation. Journal of Manufacturing Technology Management. 2010;21(7):888-900. Available from: https://doi.org/10.1108/17410381011077973.

[233] https://www.xeridia.co.uk/blog/how-use-value-stream-mapping-devops-environment 12.06.2020. [Accessed 12.06.2020.]

[234] Sullivan W.G, McDonald T.N. & Van Aken E.M. Equipment replacement decisions and lean manufacturing. Robotics and Computer Integrated Manufacturing. 2002;18(3-4):255-265. Available from: https://doi.org/10.1016/S0736-5845(02)00016-9.

[235] Ranky P.G. Eighteen "monozukuri-focused" assembly line design and visual factory management principles with DENSO industrial examples. Assembly Automation. 2007;27(1):12-16. Available from: https://doi.org/10.1108/01445150710724649.

[236] Bilalis N, Scroubelos G, Antoniadis A, Emiris D. & Koulouriotis D. Visual factory: basic principles and the‘zoning’approach. International Journal of Production Research. 2002;40(15):3575-3588. Available from: https://doi.org/10.1080/00207540210140031.

[237] Greif M. The Visual Factory: Building Participation Through Shared Information. Portland: Productivity Press; 1991.

[238] Parry G.C. & Turner C.E. Application of lean visual process management tools. Production Planning & Control: The Management of Operations. 2006;17(1):77-86. Available from: http://dx.doi.org/10.1080/09537280500414991.

[239] Anjoran R. Lean Visual Management Boards in Factories: Keep It Simple. 2017. Available from: https://www.cmc-consultants.com/blog/lean-visual-management-boards-in-factories-keep-it-simple [Accessed 18.10.2018.]

[240] Wright I. Is There a Technological Solution to the Manufacturing Skills Gap. 2017. Available from: https://www.engineering.com/AdvancedManufacturing/ArticleID/15442/Is-There-a-Technological-Solution-to-the-Manufacturing-Skills-Gap.aspx [cited 2018 Oct 18]

[241] https://statistics.laerd.com/spss-tutorials/one-way-anova-using-spss-statistics.php [Accessed 10.12.2018.]

[242] https://statistics.laerd.com/spss-tutorials/kruskal-wallis-h-test-using-spss-statistics.php [Accessed 10.12.2018.]

[243] https://statistics.laerd.com/spss-tutorials/independent-t-test-using-spss-statistics.php [Accessed 10.12.2018.]

[244] https://statistics.laerd.com/spss-tutorials/mann-whitney-u-test-using-spss-statistics.php [Accessed 10.12.2018.]

[245] https://statistics.laerd.com/spss-tutorials/lmultiple-regression-using-spss-statistics.php [Accessed 10.12.2018.]

PRILOZI

PRILOG 1: duljina primjene vitke proizvodnje i smanjenje prekomjerne proizvodnje

PRILOG 2: duljina primjene vitke proizvodnje i smanjenje prekomjernog transporta

PRILOG 3: duljina primjene vitke proizvodnje i smanjenje čekanja

PRILOG 4: duljina primjene vitke proizvodnje i smanjenje prekomjerne obrade

PRILOG 5: duljina primjene vitke proizvodnje i smanjenje nepotrebnih zaliha

PRILOG 6: duljina primjene vitke proizvodnje i smanjenje nepotrebnih pokreta

PRILOG 7: duljina primjene vitke proizvodnje i smanjenje škarta

PRILOG 8: duljina primjene vitke proizvodnje i smanjenje nedovoljne iskorištenosti potencijala zaposlenika

PRILOG 9: 5S i eliminacija gubitaka

PRILOG 10: *andon* i eliminacija gubitaka

PRILOG 11: analiza uskih grla i eliminacija gubitaka

PRILOG 12: kontinuirani tok i eliminacija gubitaka

PRILOG 13: VSM i eliminacija gubitaka

PRILOG 14: *heijunka* i eliminacija gubitaka

PRILOG 15: *hoshin kanri* i eliminacija gubitaka

PRILOG 16: *jidoka* i eliminacija gubitaka

PRILOG 17: JIT i eliminacija gubitaka

PRILOG 18: *kaizen* i eliminacija gubitaka

PRILOG 19: *kanban* i eliminacija gubitaka

PRILOG 20: ključni indikatori učinkovitosti i eliminacija gubitaka

PRILOG 21: *muda* i eliminacija gubitaka

PRILOG 22: OEE i eliminacija gubitaka

PRILOG 23: PDCA i eliminacija gubitaka

PRILOG 24: *poka-yoke* i eliminacija gubitaka

PRILOG 25: analiza glavnog uzroka i eliminacija gubitaka

PRILOG 26: SMED i eliminacija gubitaka

PRILOG 27: vizualna tvornica i eliminacija gubitaka

PRILOG 28: pametni ciljevi i eliminacija gubitaka

PRILOG 29: standardizacija rada i eliminacija gubitaka

PRILOG 30: taktno vrijeme i eliminacija gubitaka

PRILOG 31: TPM i eliminacija gubitaka

PRILOG 32: *gemba* i eliminacija gubitaka

PRILOG 33: Šest velikih gubitaka i eliminacija gubitaka

PRILOG 34: vitki alati koji najbolje smanjuju prekomjernu proizvodnju

PRILOG 35: vitki alati koji najbolje smanjuju prekomjeran transport

PRILOG 36: vitki alati koji najbolje smanjuju čekanje

PRILOG 37: vitki alati koji najbolje smanjuju prekomjernu obradu

PRILOG 38: vitki alati koji najbolje smanjuju nepotrebne zalihe

PRILOG 39: vitki alati koji najbolje smanjuju nepotrebne pokrete

PRILOG 40: vitki alati koji najbolje smanjuju škart

PRILOG 41: vitki alati koji najbolje smanjuju nedovoljnu iskorištenost potencijala zaposlenika

PRILOG 1: duljina primjene vitke proizvodnje i smanjenje prekomjerne proizvodnje

Descriptive Statistics

Means

Case Processing Summary

	Cases					
	Included		Excluded		Total	
	N	Percent	N	Percent	N	Percent
NapredakPrekomjernaProizvodnja * KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano	63	100.0%	0	0.0%	63	100.0%

Slika 63. *Uzorak u SPSS-u*

Report

NapredakPrekomjernaProizvodnja KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Mean	N	Std. Deviation	Minimum	Maximum	Range	Median
do 2 godine	.7484	31	.40977	.00	1.60	1.60	.8000
3 do 5 godina	1.3412	17	.57777	.60	2.40	1.80	1.4000
više od 5 godina	1.3467	15	.62091	.60	3.00	2.40	1.2000
Total	1.0508	63	.58692	.00	3.00	3.00	1.0000

Slika 64. *Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u*

- Srednja vrijednost napretka u pogledu smanjenja prekomjerne proizvodnje povećava se s duljinom primjene vitke proizvodnje

Explore

Case Processing Summary

		Cases					
	KolikoDugoPrimjenjujete	Valid		Missing		Total	
	VitkuProizvodnjuGrupirano	N	Percent	N	Percent	N	Percent
NapredakPrekomjerna Proizvodnja	do 2 godine	31	100.0%	0	0.0%	31	100.0%
	3 do 5 godina	17	100.0%	0	0.0%	17	100.0%
	više od 5 godina	15	100.0%	0	0.0%	15	100.0%

Slika 65. *Grupiranje u SPSS-u*

Descriptives

	KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano			Statistic	Std. Error
Napredak Prekomjerna Proizvodnja	do 2 godine	Mean		.7484	.07360
		95% Confidence Interval for Mean	Lower Bound	.5981	
			Upper Bound	.8987	
		5% Trimmed Mean		.7427	
		Median		.8000	
		Variance		.168	
		Std. Deviation		.40977	
		Minimum		.00	
		Maximum		1.60	
		Range		1.60	
		Interquartile Range		.60	
		Skewness		.323	.421
		Kurtosis		-.519	.821
	3 do 5 godina	Mean		1.3412	.14013
		95% Confidence Interval for Mean	Lower Bound	1.0441	
			Upper Bound	1.6382	
		5% Trimmed Mean		1.3235	
		Median		1.4000	
		Variance		.334	
		Std. Deviation		.57777	
		Minimum		.60	
		Maximum		2.40	
		Range		1.80	
		Interquartile Range		.80	
		Skewness		.474	.550
		Kurtosis		-.562	1.063
	više od 5 godina	Mean		1.3467	.16032
		95% Confidence Interval for Mean	Lower Bound	1.0028	
			Upper Bound	1.6905	
		5% Trimmed Mean		1.2963	
		Median		1.2000	
		Variance		.386	
		Std. Deviation		.62091	
		Minimum		.60	
		Maximum		3.00	
		Range		2.40	
		Interquartile Range		.80	
		Skewness		1.444	.580
		Kurtosis		2.606	1.121

Slika 66. *Mjerenje svih važnih statističkih parametara u SPSS-u*

Tests of Normality

	KolikoDugoPrimjenjujeteVitku Proizvodnju	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
NapredakPrekomjerna Proizvodnja	do 2 godine	.127	31	.200*	.951	31	.161
	3 do 5 godina	.134	17	.200*	.933	17	.240
	više od 5 godina	.208	15	.079	.876	15	.041

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

Slika 67. *Test normalne razdiobe podataka u SPSS-u*

- Shapiro-Wilkov test distribucije podataka primjereniji je za manje uzorke (N < 50), dok se Kolmogorov-Smirnovljev test distribucije koristi za veće uzorke (N > 50). Ako je p (Sig.) > 0,05, tada je distribucija podataka normalna.
- Kolmogorov-Smirnovljevim testom utvrđeno je da je p > 0,05, tj. imamo normalnu razdiobu podataka kod sve tri kvalitativne varijable (skupine).

Slika 68. *Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju prekomjerne proizvodnje (SPSS)*

Slika 69. *Boxplot graf duljine primjene vitke proizvodnje i napretka u smanjenju prekomjerne proizvodnje*

Oneway ANOVA (jednofaktorska ANOVA)

Test of Homogeneity of Variances

NapredakPrekomjernaProizvodnja

Levene Statistic	df1	df2	Sig.
1.363	2	60	.264

Slika 70. *Test homogenosti varijanci u SPSS-u*

- Varijance su jednake jer je $p > 0,05$, što znači da se *one way* ANOVA test može provesti.

Preduvjeti za korištenje *one way* ANOVA testa su sljedeći [226]:

1) Podaci za zavisnu varijablu moraju biti kontinuirani (mjereni na intervalnim ili omjernim skalama).
2) Nezavisna varijabla mora biti kvalitativna.
3) Nezavisnost opažanja (različiti ispitanici u svakoj skupini).
4) Nema značajnih ekstremnih vrijednosti. Vrijednosti koje značajno odstupaju od srednjih vrijednosti, iznad 3 i više standardnih devijacija.

5) Zavisna varijabla mora biti približno normalno distribuirana. Normalna distribucija mora biti zastupljena u svim skupinama nezavisne varijable.
6) Homogenost varijance.

Budući da su svi preduvjeti za *one way* ANOVA test bili ispunjeni, postavili smo hipoteze i proveli analizu.
Nulta hipoteza H_0 – nema statistički značajne razlike između skupina.
Alternativna hipoteza H_1 – postoji statistički značajna razlika između skupina.

ANOVA

NapredakPrekomjernaProizvodnja

	Sum of Squares	Df	Mean Square	F	Sig.
Between Groups	5.582	2	2.791	10.614	.000
Within Groups	15.776	60	.263		
Total	21.357	62			

***Slika 71**. ANOVA test u SPSS-u*

- Utvrđeno je da postoji statistički značajna razlika između skupina jer je $p < 0,05$, no ne zna se između kojih skupina, odbačena je nulta hipoteza i prihvaćena H_1.
- Proveden je *post hoc* test (Tukey) u SPSS-u kako bi se saznalo između kojih skupina postoji statistički značajna razlika.

Multiple Comparisons

Dependent Variable: NapredakPrekomjernaProizvodnja

Tukey HSD

(I) KolikoDugo PrimjenjujeteVitkuProizvodnjuGrupirano	(J) KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval Lower Bound	95% Confidence Interval Upper Bound
do 2 godine	3 do 5 godina	-.59279*	.15475	.001	-.9647	-.2209
	više od 5 godina	-.59828*	.16128	.001	-.9859	-.2107
3 do 5 godina	do 2 godine	.59279*	.15475	.001	.2209	.9647
	više od 5 godina	-.00549	.18165	.999	-.4420	.4310
više od 5 godina	do 2 godine	.59828*	.16128	.001	.2107	.9859
	3 do 5 godina	.00549	.18165	.999	-.4310	.4420

*. The mean difference is significant at the 0.05 level.

***Slika 72.** Turkey HSD test u SPSS-u*

- Ako je $p < 0,05$, znači da postoji statistički značajna razlika između tih skupina.

- Postoji statistički značajna razlika u pogledu smanjenja prekomjerne proizvodnje između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina.
- Postoji statistički značajna razlika u pogledu smanjenja prekomjerne proizvodnje između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju dulje od 5 godina.
- NE postoji statistički značajna razlika u pogledu smanjenja prekomjerne proizvodnje između poduzeća koja koriste vitku proizvodnju 3 – 5 godina i poduzeća koja koriste vitku proizvodnju dulje od 5 godina.

Homogeneous Subsets

NapredakPrekomjernaProizvodnja

Tukey HSD[a,b]

KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	N	Subset for alpha = 0.05	
		1	2
do 2 godine	31	.7484	
3 do 5 godina	17		1.3412
više od 5 godina	15		1.3467
Sig.		1.000	.999

Means for groups in homogeneous subsets are displayed.

a. Uses Harmonic Mean Sample Size = 19.018.

b. The group sizes are unequal. The harmonic mean of the group sizes is used. Type I error levels are not guaranteed.

Slika 73.*Turkey HSD test u SPSS-u*

PRILOG 2: duljina primjene vitke proizvodnje i smanjenje prekomjernog transporta

Descriptive Statistics

Means

Case Processing Summary

	Cases					
	Included		Excluded		Total	
	N	Percent	N	Percent	N	Percent
NapredakPrekomjeranTransport * KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano	63	100.0%	0	0.0%	63	100.0%

Slika 74. *Uzorak u SPSS-u*

Report

NapredakPrekomjeranTransport KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Mean	N	Std. Deviation	Minimum	Maximum	Range	Median
do 2 godine	1.1828	31	.64313	.00	3.00	3.00	1.0000
3 do 5 godina	1.5294	17	.68778	.33	2.67	2.33	1.3333
više od 5 godina	2.0000	15	.59094	.67	3.00	2.33	2.0000
Total	1.4709	63	.71501	.00	3.00	3.00	1.3333

Slika 75. *Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u*

- Srednja vrijednost napretka u pogledu smanjenja prekomjernog transporta povećava se s duljinom primjene vitke proizvodnje.

Explore

Case Processing Summary

		Cases					
	KolikoDugoPrimjenjujete	Valid		Missing		Total	
	VitkuProizvodnjuGrupirano	N	Percent	N	Percent	N	Percent
NapredakPrekomjeran Transport	do 2 godine	31	100.0%	0	0.0%	31	100.0%
	3 do 5 godina	17	100.0%	0	0.0%	17	100.0%
	više od 5 godina	15	100.0%	0	0.0%	15	100.0%

Slika 76. *Grupiranje u SPSS-u*

Descriptives

	KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano			Statistic	Std. Error
Napredak Prekomjeran Transport	do 2 godine	Mean		1.1828	.11551
		95% Confidence Interval for Mean	Lower Bound	.9469	
			Upper Bound	1.4187	
		5% Trimmed Mean		1.1476	
		Median		1.0000	
		Variance		.414	
		Std. Deviation		.64313	
		Minimum		.00	
		Maximum		3.00	
		Range		3.00	
		Interquartile Range		.33	
		Skewness		.904	.421
		Kurtosis		1.568	.821
	3 do 5 godina	Mean		1.5294	.16681
		95% Confidence Interval for Mean	Lower Bound	1.1758	
			Upper Bound	1.8830	
		5% Trimmed Mean		1.5327	
		Median		1.3333	
		Variance		.473	
		Std. Deviation		.68778	
		Minimum		.33	
		Maximum		2.67	
		Range		2.33	
		Interquartile Range		1.00	
		Skewness		.196	.550
		Kurtosis		-.857	1.063
	više od 5 godina	Mean		2.0000	.15258
		95% Confidence Interval for Mean	Lower Bound	1.6728	
			Upper Bound	2.3272	
		5% Trimmed Mean		2.0185	
		Median		2.0000	
		Variance		.349	
		Std. Deviation		.59094	
		Minimum		.67	
		Maximum		3.00	
		Range		2.33	
		Interquartile Range		.67	
		Skewness		-.266	.580
		Kurtosis		1.126	1.121

Slika 77. *Mjerenje svih važnih statističkih parametara u SPSS-u*

Tests of Normality

	KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
NapredakPrekomjeran Transport	do 2 godine	.193	31	.005	.919	31	.022
	3 do 5 godina	.200	17	.068	.937	17	.285
	više od 5 godina	.167	15	.200*	.932	15	.293

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

Slika 78. *Test normalne razdiobe podataka u SPSS-u*

- Kolmogorov-Smirnovljev test pokazao je da je $p > 0,05$, tj. imamo normalnu razdiobu podataka kod sve tri kvalitativne varijable (skupine).

NapredakPrekomjeranTransport

Slika 79. *Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju prekomjernog transporta (SPSS)*

Slika 80. *Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju prekomjernog transporta*

Oneway ANOVA (jednofaktorska ANOVA)

Test of Homogeneity of Variances

NapredakPrekomjeranTransport

Levene Statistic	df1	df2	Sig.
.857	2	60	.430

Slika 81. *Test homogenosti varijanci u SPSS-u*

- Varijance su jednake jer je $p > 0,05$, što znači da se *one way* ANOVA test može provesti.

Preduvjeti za korištenje *one way* ANOVA testa su sljedeći [241]:

1) Podaci za zavisnu varijablu moraju biti kontinuirani (mjereni na intervalnim ili omjernim skalama).
2) Nezavisna varijabla mora biti kvalitativna.
3) Nezavisnost opažanja (različiti ispitanici u svakoj skupini).

4) Nema značajnih ekstremnih vrijednosti. Vrijednosti koje značajno odstupaju od srednjih vrijednosti, iznad 3 i više standardnih devijacija.
5) Zavisna varijabla mora biti približno normalno distribuirana. Normalna distribucija mora biti zastupljena u svim skupinama nezavisne varijable.
6) Homogenost varijance.

Budući da su svi preduvjeti za *one way* ANOVA test ispunjeni, postavljene su hipoteze i provedena je analiza.
Nulta hipoteza H_0 – nema statistički značajne razlike između skupina.
Alternativna hipoteza H_1 – postoji statistički značajna razlika između skupina.

ANOVA

NapredakPrekomjeranTransport

	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	6.831	2	3.415	8.241	.001
Within Groups	24.866	60	.414		
Total	31.697	62			

***Slika 82**. ANOVA test u SPSS-u*

- Utvrđeno je da postoji statistički značajna razlika između skupina jer je $p < 0,05$, no ne zna se između kojih skupina, odbačena je nulta hipoteza i prihvaćena H_1.
- Proveden je *post hoc* test (Tukey) u SPSS-u kako bi se saznalo između kojih skupina postoji statistički značajna razlika.

Multiple Comparisons

Dependent Variable: NapredakPrekomjeranTransport

Tukey HSD

(I) KolikoDugoPrimjenjujete VitkuProizvodnju Grupirano	(J) KolikoDugoPrimjenjujete VitkuProizvodnju Grupirano	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval Lower Bound	95% Confidence Interval Upper Bound
do 2 godine	3 do 5 godina	-.34662	.19429	.184	-.8135	.1203
	više od 5 godina	-.81720*	.20248	.000	-1.3038	-.3306
3 do 5 godina	do 2 godine	.34662	.19429	.184	-.1203	.8135
	više od 5 godina	-.47059	.22805	.106	-1.0186	.0775
više od 5 godina	do 2 godine	.81720*	.20248	.000	.3306	1.3038
	3 do 5 godina	.47059	.22805	.106	-.0775	1.0186

*. The mean difference is significant at the 0.05 level.

***Slika 83.** Turkey HSD test u SPSS-u*

- Ako je $p < 0,05$, to znači da postoji statistički značajna razlika između tih skupina.
- NE postoji statistički značajna razlika u pogledu smanjenja prekomjernog transporta između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina.
- Postoji statistički značajna razlika u pogledu smanjenja prekomjernog transporta između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju dulje od 5 godina.
- NE postoji statistički značajna razlika u pogledu smanjenja prekomjernog transporta između poduzeća koja koriste vitku proizvodnju 3 – 5 godina i poduzeća koja koriste vitku proizvodnju dulje od 5 godina.

Homogeneous Subsets

NapredakPrekomjeranTransport

Tukey HSD[a,b]

KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	N	Subset for alpha = 0.05 1	2
do 2 godine	31	1.1828	
3 do 5 godina	17	1.5294	1.5294
više od 5 godina	15		2.0000
Sig.		.229	.070

Means for groups in homogeneous subsets are displayed.

a. Uses Harmonic Mean Sample Size = 19.018.

b. The group sizes are unequal. The harmonic mean of the group sizes is used. Type I error levels are not guaranteed.

Slika 84. *Turkey HSD test u SPSS-u*

PRILOG 3: duljina primjene vitke proizvodnje i smanjenje čekanja

Descriptive Statistics

Means

Case Processing Summary

	Cases					
	Included		Excluded		Total	
	N	Percent	N	Percent	N	Percent
NapredakČekanje * KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	63	100.0%	0	0.0%	63	100.0%

Slika 85. *Uzorak u SPSS-u*

Report

NapredakČekanje KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Mean	N	Std. Deviation	Median	Minimum	Maximum	Range
do 2 godine	.9032	31	.47731	.7500	.00	1.75	1.75
3 do 5 godina	1.2794	17	.49119	1.5000	.50	2.00	1.50
više od 5 godina	1.6833	15	.93287	1.7500	.25	3.00	2.75
Total	1.1905	63	.68644	1.0000	.00	3.00	3.00

Slika 86. *Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u*

- Srednja vrijednost napretka u pogledu smanjenja prekomjernog transporta povećava se s duljinom primjene vitke proizvodnje.

Explore

Case Processing Summary

		Cases					
	KolikoDugoPrimjenjujeteVitku	Valid		Missing		Total	
	Proizvodnju	N	Percent	N	Percent	N	Percent
NapredakČekanje	do 2 godine	31	100.0%	0	0.0%	31	100.0%
	3 do 5 godina	17	100.0%	0	0.0%	17	100.0%
	više od 5 godina	15	100.0%	0	0.0%	15	100.0%

Slika 87. *Grupiranje u SPSS-u*

Descriptives

	KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano			Statistic	Std. Error
Napredak Čekanje	do 2 godine	Mean		.9032	.08573
		95% Confidence Interval for Mean	Lower Bound	.7281	
			Upper Bound	1.0783	
		5% Trimmed Mean		.9064	
		Median		.7500	
		Variance		.228	
		Std. Deviation		.47731	
		Minimum		.00	
		Maximum		1.75	
		Range		1.75	
		Interquartile Range		1.00	
		Skewness		.106	.421
		Kurtosis		-1.195	.821
	3 do 5 godina	Mean		1.2794	.11913
		95% Confidence Interval for Mean	Lower Bound	1.0269	
			Upper Bound	1.5320	
		5% Trimmed Mean		1.2827	
		Median		1.5000	
		Variance		.241	
		Std. Deviation		.49119	
		Minimum		.50	
		Maximum		2.00	
		Range		1.50	
		Interquartile Range		.88	
		Skewness		-.465	.550
		Kurtosis		-1.040	1.063
	više od 5 godina	Mean		1.6833	.24086
		95% Confidence Interval for Mean	Lower Bound	1.1667	
			Upper Bound	2.1999	
		5% Trimmed Mean		1.6898	
		Median		1.7500	
		Variance		.870	
		Std. Deviation		.93287	
		Minimum		.25	
		Maximum		3.00	
		Range		2.75	
		Interquartile Range		1.50	
		Skewness		-.168	.580
		Kurtosis		-1.382	1.121

Slika 88. *Mjerenje svih važnih statističkih parametara u SPSS-u*

Tests of Normality

	KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
NapredakČekanje	do 2 godine	.188	31	.007	.918	31	.021
	3 do 5 godina	.203	17	.062	.903	17	.077
	više od 5 godina	.168	15	.200*	.926	15	.236

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

Slika 89. *Test normalne razdiobe podataka u SPSS-u*

- Kolmogorov-Smirnovljev test pokazao je da je $p > 0,05$, tj. postoji normalna razdioba podataka kod sve tri kvalitativne varijable (skupine).

NapredakČekanje

Slika 90. *Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju čekanja (SPSS)*

Slika 91. *Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju čekanja*

Oneway ANOVA (jednofaktorska ANOVA)

Test of Homogeneity of Variances

NapredakČekanje

Levene Statistic	df1	df2	Sig.
10.576	2	60	.000

Slika 92. *Test homogenosti varijanci u SPSS-u*

- Varijance NISU jednake jer je $p < 0,05$, što znači da se NE može provoditi *one way* ANOVA te se mora provesti Kruskal-Wallisov test.

Preduvjeti za korištenje Kruskal-Wallisovog testa su sljedeći [242]:

1) Podaci za zavisnu varijablu moraju biti kontinuirani (mjereni na intervalnim ili omjernim skalama).
2) Nezavisna varijabla mora biti kvalitativna.
3) Nezavisnost opažanja (različiti ispitanici u svakoj skupini).

Budući da su svi preduvjeti za Kruskal-Wallisov test ispunjeni, postavljene su hipoteze i provedena je analiza.
Nulta hipoteza H_0 – nema statistički značajne razlike između skupina.
Alternativna hipoteza H_1 – postoji statistički značajna razlika između skupina.

NPar Tests

Descriptive Statistics

	N	Mean	Std. Deviation	Minimum	Maximum
NapredakČekanje	63	1.1905	.68644	.00	3.00
KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	63	1.7460	.82243	1.00	3.00

Slika 93. *Kruskal-Wallisov test u SPSS-u*

Kruskal-Wallis Test

Ranks

	KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	N	Mean Rank
NapredakČekanje	do 2 godine	31	24.76
	3 do 5 godina	17	36.56
	više od 5 godina	15	41.80
	Total	63	

Slika 94. *Kruskal-Wallisov test u SPSS-u*

Test Statistics[a,b]

	NapredakČekanje
Chi-Square	10.376
df	2
Asymp. Sig.	.006

a. Kruskal Wallis Test

b. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 95. *Kruskal-Wallisov test u SPSS-u*

- Postoji statistički značajna razlika između skupina jer je $p < 0,05$, no još se uvijek ne zna između kojih grupa, odbačena je nultu hipoteza i prihvaćena H_1.

Hypothesis Test Summary

	Null Hypothesis	Test	Sig.	Decision
1	The distribution of NapredakČekanje is the same across categories of KolikoDugoPrimjenjujete LEANMetologijuGrupirano.	Independent-Samples Kruskal-Wallis Test	.006	Reject the null hypothesis.

Asymptotic significances are displayed. The significance level is .05.

Slika 96. *Odbacivanje nulte hipoteze u SPSS-u*

Kako bi se saznalo između kojih skupina postoji statistički značajna razlika, proveden je Mann-Whitneyev test između različitih skupina s kojim se radi usporedba dvije skupine neovisnih podataka.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakČekanje	do 2 godine	31	20.92	648.50
	3 do 5 godina	17	31.03	527.50
	Total	48		

Slika 97. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakČekanje
Mann-Whitney U	152.500
Wilcoxon W	648.500
Z	-2.433
Asymp. Sig. (2-tailed)	.015

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 98. *Mann-Whitneyev test*

- Ako je $p < 0{,}05$, to znači da postoji statistički značajna razlika između tih skupina.
- Postoji statistički značajna razlika u pogledu smanjenja čekanja između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakČekanje	do 2 godine	31	19.84	615.00
	više od 5 godina	15	31.07	466.00
	Total	46		

Slika 99. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakČekanje
Mann-Whitney U	119.000
Wilcoxon W	615.000
Z	-2.684
Asymp. Sig. (2-tailed)	.007

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 100. *Mann-Whitneyev test*

- Postoji statistički značajna razlika u pogledu smanjenja čekanja između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju dulje od 5 godina.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakČekanje	3 do 5 godina	17	14.53	247.00
	više od 5 godina	15	18.73	281.00
	Total	32		

Slika 101. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakČekanje
Mann-Whitney U	94.000
Wilcoxon W	247.000
Z	-1.273
Asymp. Sig. (2-tailed)	.203
Exact Sig. [2*(1-tailed Sig.)]	.216[b]

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

b. Not corrected for ties.

Slika 102. *Mann-Whitneyev test*

- NE postoji statistički značajna razlika u pogledu smanjenja čekanja između poduzeća koja koriste vitku proizvodnju između 3 – 5 godina i poduzeća koja koriste vitku proizvodnju dulje od 5 godina.

PRILOG 4: duljina primjene vitke proizvodnje i smanjenje prekomjerne obrade

Descriptive Statistics

Means

Case Processing Summary

	Cases					
	Included		Excluded		Total	
	N	Percent	N	Percent	N	Percent
NapredakPrekomjernaObrada * KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	63	100.0%	0	0.0%	63	100.0%

Slika 103. *Uzorak SPSS-u*

Report

NapredakPrekomjernaObrada KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Mean	N	Std. Deviation	Median	Minimum	Maximum	Range
do 2 godine	.4355	31	.57361	.0000	.00	1.50	1.50
3 do 5 godina	.7059	17	.63882	.5000	.00	1.50	1.50
više od 5 godina	1.1667	15	.87966	1.0000	.00	3.00	3.00
Total	.6825	63	.72569	.5000	.00	3.00	3.00

Slika 104. *Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u*

- Srednja vrijednost napretka u pogledu smanjenja prekomjerne obrade povećava se s duljinom primjene vitke proizvodnje.

Explore

Case Processing Summary

		Cases					
	KolikoDugoPrimjenjujeteVitku	Valid		Missing		Total	
	ProizvodnjuGrupirano	N	Percent	N	Percent	N	Percent
Napredak Prekomjerna Obrada	do 2 godine	31	100.0%	0	0.0%	31	100.0%
	3 do 5 godina	17	100.0%	0	0.0%	17	100.0%
	više od 5 godina	15	100.0%	0	0.0%	15	100.0%

Slika 105. *Grupiranje u SPSS-u.*

Descriptives

	KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano			Statistic	Std. Error
Napredak Prekomjerna Obrada	do 2 godine	Mean		.4355	.10302
		95% Confidence Interval for Mean	Lower Bound	.2251	
			Upper Bound	.6459	
		5% Trimmed Mean		.4005	
		Median		.0000	
		Variance		.329	
		Std. Deviation		.57361	
		Minimum		.00	
		Maximum		1.50	
		Range		1.50	
		Interquartile Range		1.00	
		Skewness		.834	.421
		Kurtosis		-.920	.821
	3 do 5 godina	Mean		.7059	.15494
		95% Confidence Interval for Mean	Lower Bound	.3774	
			Upper Bound	1.0343	
		5% Trimmed Mean		.7010	
		Median		.5000	
		Variance		.408	
		Std. Deviation		.63882	
		Minimum		.00	
		Maximum		1.50	
		Range		1.50	
		Interquartile Range		1.50	
		Skewness		.121	.550
		Kurtosis		-1.740	1.063
	više od 5 godina	Mean		1.1667	.22713
		95% Confidence Interval for Mean	Lower Bound	.6795	
			Upper Bound	1.6538	
		5% Trimmed Mean		1.1296	
		Median		1.0000	
		Variance		.774	
		Std. Deviation		.87966	
		Minimum		.00	
		Maximum		3.00	
		Range		3.00	
		Interquartile Range		1.00	
		Skewness		.501	.580
		Kurtosis		.036	1.121

Slika 106. *Mjerenje svih važnih statističkih parametara u SPSS-u*

Tests of Normality

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
NapredakPrekomjerna Obrada	do 2 godine	.357	31	.000	.726	31	.000
	3 do 5 godina	.218	17	.030	.816	17	.003
	više od 5 godina	.175	15	.200*	.927	15	.250

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

Slika 107. *Test normalne razdiobe podataka u SPSS-u*

- Kolmogorov-Smirnovljev test pokazao je da je $p < 0,05$ kod dvije skupine te nemamo normalnu razdiobu podataka, što znači da se mora provesti Kruskal-Wallisov test.

NapredakPrekomjernaObrada

Slika 108. *Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju prekomjerne obrade (SPSS)*

Slika 109. *Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju prekomjerne obrade*

Preduvjeti za korištenje Kruskal-Wallisovog testa su sljedeći [242]:

1) Podaci za zavisnu varijablu moraju biti kontinuirani (mjereni na intervalnim ili omjernim skalama).
2) Nezavisna varijabla mora biti kvalitativna.
3) Nezavisnost opažanja (različiti ispitanici u svakoj skupini).

Budući da su svi preduvjeti za Kruskall-Wallisov test bili ispunjeni, postavljene su hipoteze i provedena je analiza.

Nulta hipoteza H_0 – nema statistički značajne razlike između skupina.

Alternativna hipoteza H_1 – postoji statistički značajna razlika između skupina.

NPar Tests

Descriptive Statistics

	N	Mean	Std. Deviation	Minimum	Maximum
NapredakPrekomjerna Obrada	63	.6825	.72569	.00	3.00
KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	63	1.7460	.82243	1.00	3.00

Slika 110. *Kruskal-Wallisov test u SPSS-u*

Kruskal-Wallis Test

Ranks

	KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	N	Mean Rank
NapredakPrekomjerna Obrada	do 2 godine	31	26.19
	3 do 5 godina	17	33.76
	više od 5 godina	15	42.00
	Total	63	

Slika 111. *Kruskal-Wallisov test u SPSS-u*

Test Statistics[a,b]

	NapredakPrekomjernaObrada
Chi-Square	8.570
df	2
Asymp. Sig.	.014

a. Kruskal Wallis Test

b. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 112. *Kruskal-Wallisov test u SPSS-u*

- Postoji statistički značajna razlika između skupina jer je $p < 0,05$, no još uvijek se ne zna između kojih skupina, odbačena je nulta hipotezu i prihvaćena H_1.

Hypothesis Test Summary

	Null Hypothesis	Test	Sig.	Decision
1	The distribution of NapredakPrekomjernaObrada is the same across categories of KolikoDugoPrimjenjujete LEANMetologijuGrupirano.	Independent-Samples Kruskal-Wallis Test	.014	Reject the null hypothesis.

Asymptotic significances are displayed. The significance level is .05.

Slika 113. *Odbacivanje nulte hipoteze u SPSS-u*

Kako bi se saznalo između kojih skupina postoji statistički značajna razlika, proveden je Mann-Whitneyev test između različitih skupina s kojim se radi usporedba dvije skupine neovisnih podataka.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakPrekomjerna Obrada	do 2 godine	31	22.37	693.50
	3 do 5 godina	17	28.38	482.50
	Total	48		

Slika 114. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakPrekomjerna Obrada
Mann-Whitney U	197.500
Wilcoxon W	693.500
Z	-1.534
Asymp. Sig. (2-tailed)	.125

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 115. *Mann-Whitneyev test*

- Ako je $p < 0,05$, to znači da postoji statistički značajna razlika između tih skupina.
- NE postoji statistički značajna razlika u pogledu smanjenja prekomjerne obrade između poduzeća koja koriste vitkuproizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakPrekomjerna Obrada	do 2 godine	31	19.82	614.50
	više od 5 godina	15	31.10	466.50
	Total	46		

Slika 116. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakPrekomjernaObrada
Mann-Whitney U	118.500
Wilcoxon W	614.500
Z	-2.836
Asymp. Sig. (2-tailed)	.005

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 117. *Mann-Whitneyev test*

- Postoji statistički značajna razlika u pogledu smanjenja prekomjerne obrade između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju više od pet godina.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakPrekomjerna Obrada	3 do 5 godina	17	14.38	244.50
	više od 5 godina	15	18.90	283.50
	Total	32		

Slika 118. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakPrekomjernaObrada
Mann-Whitney U	91.500
Wilcoxon W	244.500
Z	-1.398
Asymp. Sig. (2-tailed)	.162
Exact Sig. [2*(1-tailed Sig.)]	.176[b]

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

b. Not corrected for ties.

Slika 119. *Mann-Whitneyev test*

- NE postoji statistički značajna razlika u pogledu smanjenja prekomjerne obrade između poduzeća koja koriste vitku proizvodnju 3 – 5 godina i poduzeća koja koriste vitku proizvodnju više od pet godina.

PRILOG 5: duljina primjene vitke proizvodnje i smanjenje nepotrebnih zaliha

Descriptive Statistics

Means

Case Processing Summary

	Cases					
	Included		Excluded		Total	
	N	Percent	N	Percent	N	Percent
NapredakNepotrebneZalihe * KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano	63	100.0%	0	0.0%	63	100.0%

Slika 120. *Uzorak u SPSS-u*

Report

NapredakNepotrebneZalihe KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Mean	N	Std. Deviation	Median	Minimum	Maximum	Range
do 2 godine	.8065	31	.58705	1.0000	.00	2.50	2.50
3 do 5 godina	.8824	17	.54571	.5000	.00	2.00	2.00
više od 5 godina	1.5000	15	.70711	1.5000	.50	3.00	2.50
Total	.9921	63	.66291	1.0000	.00	3.00	3.00

Slika 121. *Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u*

- Srednja vrijednost napretka u pogledu smanjenja nepotrebnih zaliha povećava se s duljinom primjene vitke proizvodnje.

Explore

Case Processing Summary

	KolikoDugoPrimjenjujeteVitku	Cases					
		Valid		Missing		Total	
	ProizvodnjuGrupirano	N	Percent	N	Percent	N	Percent
NapredakNepotrebne Zalihe	do 2 godine	31	100.0%	0	0.0%	31	100.0%
	3 do 5 godina	17	100.0%	0	0.0%	17	100.0%
	više od 5 godina	15	100.0%	0	0.0%	15	100.0%

Slika 122. *Grupiranje u SPSS-u*

Descriptives

	KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano			Statistic	Std. Error
Napredak NepotrebneZalihe	do 2 godine	Mean		.8065	.10544
		95% Confidence Interval for Mean	Lower Bound	.5911	
			Upper Bound	1.0218	
		5% Trimmed Mean		.7670	
		Median		1.0000	
		Variance		.345	
		Std. Deviation		.58705	
		Minimum		.00	
		Maximum		2.50	
		Range		2.50	
		Interquartile Range		.50	
		Skewness		.701	.421
		Kurtosis		1.248	.821
	3 do 5 godina	Mean		.8824	.13235
		95% Confidence Interval for Mean	Lower Bound	.6018	
			Upper Bound	1.1629	
		5% Trimmed Mean		.8693	
		Median		.5000	
		Variance		.298	
		Std. Deviation		.54571	
		Minimum		.00	
		Maximum		2.00	
		Range		2.00	
		Interquartile Range		1.00	
		Skewness		.527	.550
		Kurtosis		-.658	1.063
	više od 5 godina	Mean		1.5000	.18257
		95% Confidence Interval for Mean	Lower Bound	1.1084	
			Upper Bound	1.8916	
		5% Trimmed Mean		1.4722	
		Median		1.5000	
		Variance		.500	
		Std. Deviation		.70711	
		Minimum		.50	
		Maximum		3.00	
		Range		2.50	
		Interquartile Range		1.00	
		Skewness		.525	.580
		Kurtosis		-.033	1.121

Slika 123. *Mjerenje svih važnih statističkih parametara u SPSS-u*

Tests of Normality

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
NapredakNepotrebne Zalihe	do 2 godine	.242	31	.000	.873	31	.002
	3 do 5 godina	.288	17	.001	.870	17	.022
	više od 5 godina	.167	15	.200*	.940	15	.387

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

Slika 124. *Test normalne razdiobe podataka u SPSS-u*

- Kolmogorov-Smirnovljev test pokazao je da je $p < 0,05$ kod dvije skupine te nemamo normalno razdiobu podataka, što znači da se mora provesti Kruskal-Wallisov test.

NapredakNepotrebneZalihe

Slika 125. *Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju nepotrebnih zaliha (SPSS)*

Slika 126. *Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju nepotrebnih zaliha*

Preduvjeti za korištenje Kruskal-Wallisovog testa su sljedeći [242]:

1) Podaci za zavisnu varijablu moraju biti kontinuirani (mjereni na intervalnim ili omjernim skalama).
2) Nezavisna varijabla mora biti kvalitativna.
3) Nezavisnost opažanja (različiti ispitanici u svakoj skupini).

Budući da su svi preduvjeti za Kruskal-Wallisov test bili ispunjeni, postavljene su hipoteze i provedena je analiza.

Nulta hipoteza H_0 – nema statistički značajne razlike između skupina.

Alternativna hipoteza H_1 – postoji statistički značajna razlika između skupina.

NPar Tests

Descriptive Statistics

	N	Mean	Std. Deviation	Minimum	Maximum
NapredakNepotrebneZalihe	63	.9921	.66291	.00	3.00
KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	63	1.7460	.82243	1.00	3.00

Slika 127. *Kruskal-Wallisov test u SPSS-u*

Kruskal-Wallis Test

Ranks

	KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	N	Mean Rank
NapredakNepotrebneZalihe	do 2 godine	31	27.31
	3 do 5 godina	17	29.24
	više od 5 godina	15	44.83
	Total	63	

Slika 128. *Kruskal-Wallisov test u SPSS-u*

Test Statistics[a,b]

	NapredakNepotrebneZalihe
Chi-Square	10.421
df	2
Asymp. Sig.	.005

a. Kruskal Wallis Test

b. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 129. *Kruskal-Wallisov test u SPSS-u*

- Postoji statistički značajna razlika između skupina jer je $p < 0,05$, no još se uvijek ne zna između kojih skupina, odbačena je nulta hipoteza i prihvaćena H_1.

Hypothesis Test Summary

	Null Hypothesis	Test	Sig.	Decision
1	The distribution of NapredakNepotrebneZalihe is the same across categories of KolikoDugoPrimjenjujete LEANMetologijuGrupirano.	Independent-Samples Kruskal-Wallis Test	.005	Reject the null hypothesis.

Asymptotic significances are displayed. The significance level is .05.

Slika 130. *Odbacivanje nulte hipoteze u SPSS-u*

Kako bi se saznalo između kojih skupina postoji statistički značajna razlika, proveden je Mann-Whitneyev test između različitih skupina s kojim se radi usporedba dvije skupine neovisnih podataka.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakNepotrebneZalihe	do 2 godine	31	23.95	742.50
	3 do 5 godina	17	25.50	433.50
	Total	48		

Slika 131. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakNepotrebneZalihe
Mann-Whitney U	246.500
Wilcoxon W	742.500
Z	-.382
Asymp. Sig. (2-tailed)	.702

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 132. *Mann-Whitneyev test*

- Ako je $p < 0,05$, to znači da postoji statistički značajna razlika između tih skupina.
- NE postoji statistički značajna razlika u pogledu smanjenja nepotrebnih zaliha između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakNepotrebneZalihe	do 2 godine	31	19.35	600.00
	više od 5 godina	15	32.07	481.00
	Total	46		

Slika 133. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakNepotrebneZalihe
Mann-Whitney U	104.000
Wilcoxon W	600.000
Z	-3.126
Asymp. Sig. (2-tailed)	.002

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 134. *Mann-Whitneyev test*

- Postoji statistički značajna razlika u pogledu smanjenja nepotrebnih zaliha između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju dulje od pet godina.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakNepotrebneZalihe	3 do 5 godina	17	12.74	216.50
	više od 5 godina	15	20.77	311.50
	Total	32		

Slika 135. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakNepotrebneZalihe
Mann-Whitney U	63.500
Wilcoxon W	216.500
Z	-2.490
Asymp. Sig. (2-tailed)	.013
Exact Sig. [2*(1-tailed Sig.)]	.014[b]

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

b. Not corrected for ties.

Slika 136. *Mann-Whitneyev test*

- Postoji statistički značajna razlika u pogledu smanjenja nepotrebnih zaliha između poduzeća koja koriste vitku proizvodnju 3 – 5 godina i poduzeća koja koriste vitku proizvodnju dulje od pet godina.

PRILOG 6: duljina primjene vitke proizvodnje i smanjenje nepotrebnih pokreta

Descriptive Statistics

Means

Case Processing Summary

	Cases					
	Included		Excluded		Total	
	N	Percent	N	Percent	N	Percent
NapredakNepotrebniPokreti * KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	63	100.0%	0	0.0%	63	100.0%

Slika 137. *Uzorak u SPSS-u*

Report

NapredakNepotrebniPokreti KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Mean	N	Std. Deviation	Median	Minimum	Maximum	Range
do 2 godine	.7957	31	.70279	.6667	.00	2.67	2.67
3 do 5 godina	1.1373	17	.54082	1.3333	.00	2.00	2.00
više od 5 godina	1.5111	15	.64077	1.3333	.33	3.00	2.67
Total	1.0582	63	.70212	1.0000	.00	3.00	3.00

Slika 138. *Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u*

- Srednja vrijednost napretka u pogledu smanjenja prekomjernih pokreta povećava se s duljinom primjene vitke proizvodnje

Explore

Case Processing Summary

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Cases					
		Valid		Missing		Total	
		N	Percent	N	Percent	N	Percent
NapredakNepotrebni Pokreti	do 2 godine	31	100.0%	0	0.0%	31	100.0%
	3 do 5 godina	17	100.0%	0	0.0%	17	100.0%
	više od 5 godina	15	100.0%	0	0.0%	15	100.0%

Slika 139. *Grupiranje u SPSS-u*

Descriptives

	KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano			Statistic	Std. Error
Napredak Nepotrebni Pokreti	do 2 godine	Mean		.7957	.12622
		95% Confidence Interval for Mean	Lower Bound	.5379	
			Upper Bound	1.0535	
		5% Trimmed Mean		.7491	
		Median		.6667	
		Variance		.494	
		Std. Deviation		.70279	
		Minimum		.00	
		Maximum		2.67	
		Range		2.67	
		Interquartile Range		1.00	
		Skewness		.819	.421
		Kurtosis		.376	.821
	3 do 5 godina	Mean		1.1373	.13117
		95% Confidence Interval for Mean	Lower Bound	.8592	
			Upper Bound	1.4153	
		5% Trimmed Mean		1.1525	
		Median		1.3333	
		Variance		.292	
		Std. Deviation		.54082	
		Minimum		.00	
		Maximum		2.00	
		Range		2.00	
		Interquartile Range		1.00	
		Skewness		-.468	.550
		Kurtosis		-.343	1.063
	više od 5 godina	Mean		1.5111	.16545
		95% Confidence Interval for Mean	Lower Bound	1.1563	
			Upper Bound	1.8660	
		5% Trimmed Mean		1.4938	
		Median		1.3333	
		Variance		.411	
		Std. Deviation		.64077	
		Minimum		.33	
		Maximum		3.00	
		Range		2.67	
		Interquartile Range		1.00	
		Skewness		.498	.580
		Kurtosis		1.018	1.121

Slika 140. *Mjerenje svih važnih statističkih parametara u SPSS-u*

Tests of Normality

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
NapredakNepotrebni Pokreti	do 2 godine	.160	31	.042	.897	31	.006
	3 do 5 godina	.171	17	.200*	.950	17	.453
	više od 5 godina	.156	15	.200*	.937	15	.343

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

Slika 141. *Test normalne razdiobe podataka u SPSS-u*

- Kolmogorov-Smirnovljev test pokazao je da je $p < 0,05$ kod jedne skupine te nemamo normalno razdiobu podataka, što znači da se mora provesti Kruskal-Wallisov test.

NapredakNepotrebniPokreti

Slika 142. *Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju nepotrebnih pokreta (SPSS)*

Slika 143. *Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju nepotrebnih pokreta*

Preduvjeti za korištenje Kruskal-Wallisovog testa su sljedeći [242]:

1) Podaci za zavisnu varijablu moraju biti kontinuirani (mjereni na intervalnim ili omjernim skalama).
2) Nezavisna varijabla mora biti kvalitativna.
3) Nezavisnost opažanja (različiti ispitanici u svakoj skupini).

Budući da su ispunjeni svi preduvjeti za Kruskal-Wallisov test, postavljene su hipoteze i provedena je analiza.

Nulta hipoteza H_0 – nema statistički značajne razlike između skupina.

Alternativna hipoteza H_1 – postoji statistički značajna razlika između skupina.

NPar Tests

Descriptive Statistics

	N	Mean	Std. Deviation	Minimum	Maximum
NapredakNepotrebniPokreti	63	1.0582	.70212	.00	3.00
KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	63	1.7460	.82243	1.00	3.00

Slika 144. *Kruskal-Wallisov test u SPSS-u*

Kruskal-Wallis Test

Ranks

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	N	Mean Rank
NapredakNepotrebniPokreti	do 2 godine	31	24.69
	3 do 5 godina	17	35.00
	više od 5 godina	15	43.70
	Total	63	

Slika 145. *Kruskal-Wallisov test u SPSS-u*

Test Statistics[a,b]

	NapredakNepotrebniPokreti
Chi-Square	11.774
df	2
Asymp. Sig.	.003

a. Kruskal Wallis Test

b. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 146. *Kruskal-Wallisov test u SPSS-u*

- Postoji statistički značajna razlika između skupina jer je $p < 0,05$, no još uvijek se ne zna između kojih skupina, odbačena je nulta hipoteza i prihvaćena H_1.

Hypothesis Test Summary

	Null Hypothesis	Test	Sig.	Decision
1	The distribution of NapredakNepotrebniPokreti is the same across categories of KolikoDugoPrimjenjujete LEANMetologijuGrupirano.	Independent-Samples Kruskal-Wallis Test	.003	Reject the null hypothesis.

Asymptotic significances are displayed. The significance level is .05.

Slika 147. *Odbacivanje nulte hipoteze u SPSS-u*

Kako bi se saznalo između kojih skupina postoji statistički značajna razlika proveden je Mann-Whitneyev test između različitih skupina s kojim se radi usporedba dvije skupine neovisnih podataka.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakNepotrebniPokreti	do 2 godine	31	21.53	667.50
	3 do 5 godina	17	29.91	508.50
	Total	48		

Slika 148. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakNepotrebniPokreti
Mann-Whitney U	171.500
Wilcoxon W	667.500
Z	-2.010
Asymp. Sig. (2-tailed)	.044

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 149. *Mann-Whitneyev test*

- Ako je $p < 0,05$, to znači da postoji statistički značajna razlika između tih skupina.
- Postoji statistički značajna razlika u pogledu smanjenja nepotrebnih pokreta između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakNepotrebniPokreti	do 2 godine	31	19.16	594.00
	više od 5 godina	15	32.47	487.00
	Total	46		

Slika 150. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakNepotrebniPokreti
Mann-Whitney U	98.000
Wilcoxon W	594.000
Z	-3.195
Asymp. Sig. (2-tailed)	.001

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 151. *Mann-Whitneyev test*

- Postoji statistički značajna razlika u pogledu smanjenja nepotrebnih pokreta između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju dulje od pet godina.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakNepotrebniPokreti	3 do 5 godina	17	14.09	239.50
	više od 5 godina	15	19.23	288.50
	Total	32		

Slika 152. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakNepotrebniPokreti
Mann-Whitney U	86.500
Wilcoxon W	239.500
Z	-1.573
Asymp. Sig. (2-tailed)	.116
Exact Sig. [2*(1-tailed Sig.)]	.123[b]

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

b. Not corrected for ties.

Slika 153. *Mann-Whitneyev test*

- NE postoji statistički značajna razlika u pogledu smanjenja nepotrebnih pokreta između poduzeća koja koriste vitku proizvodnju 3 – 5 godina i poduzeća koja koriste vitku proizvodnju dulje od pet godina.

PRILOG 7: duljina primjene vitke proizvodnje i smanjenje škarta

Descriptive Statistics

Means

Case Processing Summary

	Cases					
	Included		Excluded		Total	
	N	Percent	N	Percent	N	Percent
NapredakŠkart * KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	63	100.0%	0	0.0%	63	100.0%

Slika 154.*Uzorak u SPSS-u*

Report

NapredakŠkart KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Mean	N	Std. Deviation	Minimum	Maximum	Range	Median
do 2 godine	1.3710	31	.71842	.00	3.00	3.00	1.5000
3 do 5 godina	1.3824	17	.74013	.00	2.50	2.50	1.5000
više od 5 godina	2.0000	15	.82375	.00	3.00	3.00	2.0000
Total	1.5238	63	.78509	.00	3.00	3.00	1.5000

Slika 155. *Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u*

- Srednja vrijednost napretka u pogledu smanjenja škarta povećava se s duljinom primjene vitke proizvodnje.

Explore

Case Processing Summary

		Cases					
	KolikoDugoPrimjenjujeteVitku	Valid		Missing		Total	
	ProizvodnjuGrupirano	N	Percent	N	Percent	N	Percent
NapredakŠkart	do 2 godine	31	100.0%	0	0.0%	31	100.0%
	3 do 5 godina	17	100.0%	0	0.0%	17	100.0%
	više od 5 godina	15	100.0%	0	0.0%	15	100.0%

Slika 156. *Grupiranje u SPSS-u*

Descriptives

	KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano			Statistic	Std. Error
NapredakŠkart	do 2 godine	Mean		1.3710	.12903
		95% Confidence Interval for Mean	Lower Bound	1.1074	
			Upper Bound	1.6345	
		5% Trimmed Mean		1.3665	
		Median		1.5000	
		Variance		.516	
		Std. Deviation		.71842	
		Minimum		.00	
		Maximum		3.00	
		Range		3.00	
		Interquartile Range		1.00	
		Skewness		.126	.421
		Kurtosis		-.211	.821
	3 do 5 godina	Mean		1.3824	.17951
		95% Confidence Interval for Mean	Lower Bound	1.0018	
			Upper Bound	1.7629	
		5% Trimmed Mean		1.3971	
		Median		1.5000	
		Variance		.548	
		Std. Deviation		.74013	
		Minimum		.00	
		Maximum		2.50	
		Range		2.50	
		Interquartile Range		1.00	
		Skewness		-.459	.550
		Kurtosis		-.157	1.063
	više od 5 godina	Mean		2.0000	.21269
		95% Confidence Interval for Mean	Lower Bound	1.5438	
			Upper Bound	2.4562	
		5% Trimmed Mean		2.0556	
		Median		2.0000	
		Variance		.679	
		Std. Deviation		.82375	
		Minimum		.00	
		Maximum		3.00	
		Range		3.00	
		Interquartile Range		1.00	
		Skewness		-.885	.580
		Kurtosis		1.093	1.121

Slika 157. *Mjerenje svih važnih statističkih parametara u SPSS-u*

Tests of Normality

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
NapredakŠkart	do 2 godine	.181	31	.011	.950	31	.157
	3 do 5 godina	.210	17	.044	.925	17	.182
	više od 5 godina	.167	15	.200*	.915	15	.159

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

Slika 158. *Test normalne razdiobe podataka u SPSS-u*

- Kolmogorov-Smirnovljev test pokazao je da je $p < 0,05$ kod dvije skupine te nemamo normalnu razdiobu podataka, što znači da se mora provesti Kruskal-Wallisov test.

Slika 159. *Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju škarta (SPSS)*

Slika 160. *Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju škarta*

Preduvjeti za korištenje Kruskal-Wallisovog testa su sljedeći [242]:

1) Podaci za zavisnu varijablu moraju biti kontinuirani (mjereni na intervalnim ili omjernim skalama).
2) Nezavisna varijabla mora biti kvalitativna.
3) Nezavisnost opažanja (različiti ispitanici u svakoj skupini).

Budući da su svi preduvjeti za Kruskal-Wallisov test bili ispunjeni, postavljene su hipoteze i provedena je analiza.
Nulta hipoteza H_0 – nema statistički značajne razlike između skupina.
Alternativna hipoteza H_1 – postoji statistički značajna razlika između skupina.

NPar Tests

Descriptive Statistics

	N	Mean	Std. Deviation	Minimum	Maximum
NapredakŠkart	63	1.5238	.78509	.00	3.00
KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	63	1.7460	.82243	1.00	3.00

Slika 161. *Kruskal-Wallisov test u SPSS-u*

Kruskal-Wallis Test

Ranks

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	N	Mean Rank
NapredakŠkart	do 2 godine	31	28.11
	3 do 5 godina	17	29.26
	više od 5 godina	15	43.13
	Total	63	

Slika 162. *Kruskal-Wallisov test u SPSS-u*

Test Statistics[a,b]

	NapredakŠkart
Chi-Square	7.591
df	2
Asymp. Sig.	.022

a. Kruskal Wallis Test

b. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 163. *Kruskal-Wallisov test u SPSS-u*

- Postoji statistički značajna razlika između skupina jer je $p < 0,05$, no još se uvijek ne zna između kojih skupina, odbačena je nulta hipoteza i prihvaćena H_1.

Hypothesis Test Summary

	Null Hypothesis	Test	Sig.	Decision
1	The distribution of NapredakŠkart is the same across categories of KolikoDugoPrimjenjujete LEANMetologijuGrupirano.	Independent-Samples Kruskal-Wallis Test	.022	Reject the null hypothesis.

Asymptotic significances are displayed. The significance level is .05.

Slika 164. *Odbacivanje nulte hipoteze u SPSS-u*

Kako bi se saznalo između kojih skupina postoji statistički značajna razlika, proveden je Mann-Whitneyev test između različitih skupina s kojim se radi usporedba dvije skupine neovisnih podataka.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakŠkart	do 2 godine	31	24.13	748.00
	3 do 5 godina	17	25.18	428.00
	Total	48		

Slika 165. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakŠkart
Mann-Whitney U	252.000
Wilcoxon W	748.000
Z	-.254
Asymp. Sig. (2-tailed)	.800

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 166. *Mann-Whitneyev test*

- Ako je $p < 0,05$, to znači da postoji statistički značajna razlika između tih skupina.
- NE postoji statistički značajna razlika u pogledu smanjenja škarta između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju 3 – 5 godina.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakŠkart	do 2 godine	31	19.98	619.50
	više od 5 godina	15	30.77	461.50
	Total	46		

Slika 167. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakŠkart
Mann-Whitney U	123.500
Wilcoxon W	619.500
Z	-2.603
Asymp. Sig. (2-tailed)	.009

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 168. *Mann-Whitneyev test*

- Postoji statistički značajna razlika u pogledu smanjenja škarta između poduzeća koja koriste vitku proizvodnju manje od dvije godine i poduzeća koja koriste vitku proizvodnju dulje od pet godina.

Mann-Whitney Test

Ranks

	KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	N	Mean Rank	Sum of Ranks
NapredakŠkart	3 do 5 godina	17	13.09	222.50
	više od 5 godina	15	20.37	305.50
	Total	32		

Slika 169. *Mann-Whitneyev test*

Test Statistics[a]

	NapredakŠkart
Mann-Whitney U	69.500
Wilcoxon W	222.500
Z	-2.234
Asymp. Sig. (2-tailed)	.025
Exact Sig. [2*(1-tailed Sig.)]	.027[b]

a. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

b. Not corrected for ties.

Slika 170. *Mann-Whitneyev test*

- Postoji statistički značajna razlika u pogledu smanjenja škarta između poduzeća koja koriste vitku proizvodnju 3 – 5 godina i poduzeća koja koriste vitku proizvodnju dulje od pet godina.

PRILOG 8: duljina primjene vitke proizvodnje i smanjenje nedovoljne iskorištenosti potencijala zaposlenika

Descriptive Statistics

Means

Case Processing Summary

	Cases					
	Included		Excluded		Total	
	N	Percent	N	Percent	N	Percent
NapredakNedovoljnaIskorištenostPotencijalaZaposlenika * KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano	63	100.0%	0	0.0%	63	100.0%

Slika 171. *Uzorak u SPSS-u*

Report

NapredakNedovoljnaIskorištenostPotencijalaZaposlenika

KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	Mean	N	Std. Deviation	Minimum	Maximum	Range	Median
do 2 godine	1.3333	31	.74037	.00	3.00	3.00	1.3333
3 do 5 godina	1.7059	17	.72536	.67	3.00	2.33	2.0000
više od 5 godina	1.9333	15	.73679	1.00	3.00	2.00	2.0000
Total	1.5767	63	.76717	.00	3.00	3.00	1.3333

Slika 172. *Mjerenje srednje vrijednosti, standardne devijacije i medijana u SPSS-u*

- Srednja vrijednost napretka u pogledu smanjenja nedovoljne iskorištenosti potencijala zaposlenika povećava se s duljinom primjene vitke proizvodnje.

Explore

Case Processing Summary

	KolikoDugoPrimjenjujete VitkuProizvodnju Grupirano	Cases					
		Valid		Missing		Total	
		N	Percent	N	Percent	N	Percent
NapredakNedovoljnaIskorištenost PotencijalaZaposlenika	do 2 godine	31	100.0%	0	0.0%	31	100.0%
	3 do 5 godina	17	100.0%	0	0.0%	17	100.0%
	više od 5 godina	15	100.0%	0	0.0%	15	100.0%

Slika 173. *Grupiranje u SPSS-u*

Descriptives

	KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano			Statistic	Std. Error
Napredak Nedovoljna Iskorištenost Potencijala Zaposlenika	do 2 godine	Mean		1.3333	.13297
		95% Confidence Interval for Mean	Lower Bound	1.0618	
			Upper Bound	1.6049	
		5% Trimmed Mean		1.3280	
		Median		1.3333	
		Variance		.548	
		Std. Deviation		.74037	
		Minimum		.00	
		Maximum		3.00	
		Range		3.00	
		Interquartile Range		1.00	
		Skewness		.059	.421
		Kurtosis		-.246	.821
	3 do 5 godina	Mean		1.7059	.17593
		95% Confidence Interval for Mean	Lower Bound	1.3329	
			Upper Bound	2.0788	
		5% Trimmed Mean		1.6917	
		Median		2.0000	
		Variance		.526	
		Std. Deviation		.72536	
		Minimum		.67	
		Maximum		3.00	
		Range		2.33	
		Interquartile Range		1.17	
		Skewness		.366	.550
		Kurtosis		-.893	1.063
	više od 5 godina	Mean		1.9333	.19024
		95% Confidence Interval for Mean	Lower Bound	1.5253	
			Upper Bound	2.3414	
		5% Trimmed Mean		1.9259	
		Median		2.0000	
		Variance		.543	
		Std. Deviation		.73679	
		Minimum		1.00	
		Maximum		3.00	
		Range		2.00	
		Interquartile Range		1.33	
		Skewness		.062	.580
		Kurtosis		-1.122	1.121

Slika 174. *Mjerenje svih važnih statističkih parametara u SPSS-u*

Tests of Normality

	KolikoDugoPrimjenjujete VitkuProizvodnjuGrupirano	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
NapredakNedovoljna IskorištenostPotencijala Zaposlenika	do 2 godine	.165	31	.031	.941	31	.088
	3 do 5 godina	.188	17	.114	.900	17	.069
	više od 5 godina	.203	15	.098	.873	15	.037

a. Lilliefors Significance Correction

Slika 175. *Test normalne razdiobe podataka u SPSS-u*

- Kolmogorov-Smirnovljev test pokazao je da je $p < 0,05$ kod jedne skupine te nemamo normalnu razdiobu podataka, što znači da se mora provesti Kruskal-Wallisov test.

NapredakNedovoljnalskorištenostZaposlenika

Slika 176. *Q-Q plot grafikoni duljine primjene vitke filozofije i napretka u smanjenju nedovoljne iskorištenosti potencijala zaposlenika (SPSS)*

Slika 177. *Boxplot grafikon duljine primjene vitke proizvodnje i napretka u smanjenju nedovoljne iskorištenosti potencijala zaposlenika*

Preduvjeti za korištenje Kruskal-Wallisovog testa su sljedeći [242]:

1) Podaci za zavisnu varijablu moraju biti kontinuirani (mjereni na intervalnim ili omjernim skalama).
2) Nezavisna varijabla mora biti kvalitativna.
3) Nezavisnost opažanja (različiti ispitanici u svakoj skupini).

Budući da su svi preduvjeti za Kruskal-Wallisov test bili ispunjeni, postavljene su hipoteze i provedena je analiza.

Nulta hipoteza H_0 – nema statistički značajne razlike između skupina.

Alternativna hipoteza H_1 – postoji statistički značajna razlika između skupina.

NPar Tests

Descriptive Statistics

	N	Mean	Std. Deviation	Minimum	Maximum
NapredakNedovoljnaIskorištenost PotencijalaZaposlenika	63	1.5767	.76717	.00	3.00
KolikoDugoPrimjenjujeteVitku ProizvodnjuGrupirano	63	1.7460	.82243	1.00	3.00

Slika 178. *Kruskal-Wallisov test u SPSS-u*

Kruskal-Wallis Test

Ranks

	KolikoDugoPrimjenjujeteVitku ProivodnjuGrupirano	N	Mean Rank
NapredakNedovoljna IskorištenostPotencijala Zaposlenika	do 2 godine	31	26.92
	3 do 5 godina	17	34.47
	više od 5 godina	15	39.70
	Total	63	

Slika 179. *Kruskal-Wallisov test u SPSS-u*

Test Statistics[a,b]

	NapredakNedovoljnaIskorištenostPotencijalaZaposlenika
Chi-Square	5.606
df	2
Asymp. Sig.	.061

a. Kruskal Wallis Test

b. Grouping Variable: KolikoDugoPrimjenjujeteVitkuProizvodnjuGrupirano

Slika 180. *Kruskal-Wallisov test u SPSS-u*

- NE postoji statistički značajna razlika između skupina jer je $p > 0,05$ te je prihvaćena hipoteza H_0.

Hypothesis Test Summary

	Null Hypothesis	Test	Sig.	Decision
1	The distribution of NapredakNedovoljnalskorištenost PotencijalaZaposlenika is the same across categories of KolikoDugoPrimjenjujete LEANMetologijuGrupirano.	Independent-Samples Kruskal-Wallis Test	.061	Retain the null hypothesis.

Asymptotic significances are displayed. The significance level is .05.

Slika 181. *Prihvaćanje nulte hipoteze u SPSS-u*

PRILOG 9: 5S i eliminacija gubitaka

Slika 182. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila 5S te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila 5S postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjerna proizvodnja
- prekomjeran transport
- čekanje
- nepotrebne zalihe
- nepotrebni pokreti.

PRILOG 10: *andon* i eliminacija gubitaka

Slika 183. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila andon te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *andon* postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjerna proizvodnja
- prekomjeran transport
- čekanje
- prekomjerna obrada
- nepotrebni pokreti.

PRILOG 11: analiza uskih grla i eliminacija gubitaka

Slika 184. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila analizu uskih grla te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila analizu uskih grla postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- nepotrebni pokreti.

PRILOG 12: kontinuirani tok i eliminacija gubitaka

Slika 185. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila kontinuirani tok te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila kontinuirani tok postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjerna proizvodnja
- prekomjeran transport
- čekanje
- nepotrebni pokreti
- škart.

PRILOG 13: VSM i eliminacija gubitaka

Slika 186. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila VSM te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila VSM postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- nedovoljna iskorištenost potencijala zaposlenika.

PRILOG 14: *heijunka* i eliminacija gubitaka

Slika 187. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila heijunku te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *heijunku* postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjerna proizvodnja
- prekomjeran transport
- čekanje
- nepotrebni pokreti.

PRILOG 15: *hoshin kanri* i eliminacija gubitaka

Slika 188. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila hoshin kanri te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *hoshin kanri* nisu postigla bolji napredak u pogledu smanjenja gubitaka niti u jednoj kategoriji.

PRILOG 16: *jidoka* i eliminacija gubitaka

Slika 189. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila jidoku te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *jidoku* postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjerna proizvodnja
- prekomjeran transport
- čekanje
- prekomjerna obrada.

PRILOG 17: JIT i eliminacija gubitaka

Slika 190. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila JIT te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila JIT nisu postigla bolji napredak u pogledu smanjenja gubitaka niti u jednoj kategoriji.

PRILOG 18: *kaizen* i eliminacija gubitaka

Slika 191. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila kaizen te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *kaizen* postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- nepotrebni pokreti
- škart
- nedovoljna iskorištenost potencijala zaposlenika.

PRILOG 19: *kanban* i eliminacija gubitaka

Slika 192. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila kanban te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *kanban* postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- nepotrebne zalihe.

PRILOG 20: ključni indikatori učinkovitosti i eliminacija gubitaka

Slika 193. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila ključne indikatore učinkovitosti te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila ključne indikatore učinkovitosti postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- čekanje
- nepotrebni pokreti.

PRILOG 21: *muda* i eliminacija gubitaka

Slika 194. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila sustav muda te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila sustav *muda* postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- čekanje.

PRILOG 22: OEE i eliminacija gubitaka

Slika 195. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila OEE te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila OEE postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjeran transport
- nepotrebne zalihe
- nepotrebni pokreti.

PRILOG 23: PDCA i eliminacija gubitaka

Slika 196. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila PDCA te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila PDCA nisu postigla bolji napredak u pogledu smanjenja gubitaka niti u jednoj kategoriji.

PRILOG 24: *poka-yoke* i eliminacija gubitaka

Slika 197. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila poka-yoke te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *poka-yoke* postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjerna proizvodnja
- prekomjeran transport
- čekanje
- prekomjerna obrada
- nepotrebni pokreti
- škart
- nedovoljna iskorištenost potencijala zaposlenika.

PRILOG 25: analiza glavnog uzroka i eliminacija gubitaka

Slika 198. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila analizu glavnog uzroka te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila analizu glavnog uzroka postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- čekanje.

PRILOG 26: SMED i eliminacija gubitaka

Slika 199. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila SMED te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *SMED* postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjerna proizvodnja
- prekomjeran transport
- čekanje
- prekomjerna obrada
- nepotrebni pokreti
- škart.

PRILOG 27: vizualna tvornica i eliminacija gubitaka

Slika 200. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila vizualnu tvornicu te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila vizualnu tvornicu u proizvodnji postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjerna proizvodnja
- nepotrebni pokreti.

PRILOG 28: pametni ciljevi i eliminacija gubitaka

Slika 201. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila pametne ciljeve te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *pametne ciljeve* u proizvodnji postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjerna proizvodnja.

PRILOG 29: standardizacija rada i eliminacija gubitaka

Slika 202. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila standardizaciju rada te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *standardizaciju rada* nisu postigla bolji napredak u pogledu smanjenja gubitaka niti u jednoj kategoriji.

PRILOG 30: taktno vrijeme i eliminacija gubitaka

Slika 203. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila taktno vrijeme te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *taktno vrijeme* u proizvodnji postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjeran transport
- čekanje
- nepotrebne zalihe
- nepotrebni pokreti
- škart.

PRILOG 31: TPM i eliminacija gubitaka

Slika 204. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila TPM te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *TPM* u proizvodnji postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjerna proizvodnja
- prekomjeran transport
- čekanje
- prekomjerna obrada
- nepotrebne zalihe
- nepotrebni pokreti
- škart
- nedovoljna iskorištenost potencijala zaposlenika.

TPM je jedini alat koji osigurava bolje smanjenje gubitaka u svim kategorijama.

PRILOG 32: *gemba* i eliminacija gubitaka

Slika 205. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila gembu te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *gembu* nisu postigla bolji napredak u pogledu smanjenja gubitaka niti u jednoj kategoriji.

PRILOG 33: Šest velikih gubitaka i eliminacija gubitaka

Slika 206. *Boxplot grafikoni poduzeća koja su koristila i koja nisu koristila logiku šest velikih gubitaka te razlika u napretku kod smanjenja određenog gubitka*

Poduzeća koja su koristila *šest velikih gubitka* u proizvodnji postigla su bolji napredak kod smanjenja sljedećih gubitaka:

- prekomjerna proizvodnja
- nepotrebne zalihe.

PRILOG 34: vitki alati koji najbolje smanjuju prekomjernu proizvodnju

Stepwise Multiple Linear Regression

Variables Entered/Removed[a]

Model	Variables Entered	Variables Removed	Method
1	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
2	Primjenjujem u poduzeću (kategorizacija gubitaka) Šest velikih gubitaka	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).

a. Dependent Variable: NapredakPrekomjernaProizvodnja

Slika 207. *Najbolji prediktori dobiveni SMLR modelom*

- TPM i šest velikih gubitaka alati su koji najviše utječu na napredak u pogledu smanjenja prekomjerne proizvodnje.

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.574[a]	.330	.319	.48434
2	.628[b]	.394	.374	.46438

a. Predictors: (Constant), Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM
b. Predictors: (Constant), Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM, Primjenjujem u poduzeću (kategorizacija gubitaka) Šest velikih gubitaka

Slika 208. *Koeficijenti korelacije i determinacije za odabrane prediktore*

- Koeficijent korelacije (R) za prvi je slučaj 0,574, dok je za drugi slučaj 0,628 što znači da imamo srednje pozitivnu vezu i možemo kvalitetno predvidjeti zavisnu varijablu.
- Koeficijent determinacije (R^2) specifičan je pokazatelj reprezentativnosti regresije te je model reprezentativniji što je koeficijent determinacije bliži jedinici. U našem slučaju R^2 je za prvi slučaj 0,330, dok je za drugi slučaj 0,394. To znači da naša nezavisna varijabla u prvome slučaju predviđa 33 % varijabilnosti naše zavisne varijable. Isto tako, u drugom slučaju naše nezavisne varijable predviđaju 39,4 % varijabilnosti naše zavisne varijable.

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	7.048	1	7.048	30.045	.000[b]
	Residual	14.310	61	.235		
	Total	21.357	62			
2	Regression	8.418	2	4.209	19.519	.000[c]
	Residual	12.939	60	.216		
	Total	21.357	62			

a. Dependent Variable: NapredakPrekomjernaProizvodnja
b. Predictors: (Constant), Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM
c. Predictors: (Constant), Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM, Primjenjujem u poduzeću (kategorizacija gubitaka) Šest velikih gubitaka

Slika 209. *Provjera značajnosti varijabli (prediktora)*

- $p < 0,05$ za oba slučaja, što znači da nezavisne varijable statistički značajno predviđaju zavisnu varijablu.

Coefficients[a]

Model		Unstandardized Coefficients B	Unstandardized Coefficients Std. Error	Standardized Coefficients Beta	t	Sig.
1	(Constant)	.814	.075		10.896	.000
	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.710	.129	.574	5.481	.000
2	(Constant)	.775	.073		10.576	.000
	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.697	.124	.564	5.607	.000
	Primjenjujem u poduzeću (kategorizacija gubitaka) Šest velikih gubitaka	.546	.217	.254	2.521	.014

a. Dependent Variable: NapredakPrekomjernaProizvodnja

Slika 210. *Najbolji modeli za smanjenje prekomjerne proizvodnje*

- Nestandardizirani regresijski koeficijent (B) pokazuje udjele prediktorskih varijabli u objašnjenju varijance kriterija. On pokazuje koliko će se povećati ili promijeniti napredak u smanjenju prekomjerne proizvodnje za jedinični pomak u prediktorskoj varijabli. Jednostavnije rečeno, nestandardizirani regresijski koeficijent pokazuje koliko u prosjeku poduzeća koja koriste određeni vitki alat postižu bolji napredak kod redukcije prekomjerne proizvodnje.

- Standardizirani regresijski koeficijent (beta) govori koji prediktor više pridonosi objašnjenju modela.
- Vitki alati koji najbolje pridonose smanjeju prekomjerne proizvodnje su TPM i šest velikih gubitaka.

PRILOG 35: vitki alati koji najbolje smanjuju prekomjeran transport

Stepwise Multiple Linear Regression

Variables Entered/Removed[a]

Model	Variables Entered	Variables Removed	Method
1	Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
2	Primjenjujem u poduzeću (uređenje prostora) 5S	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
3	Primjenjujem u poduzeću Analiza glavnog uzroka	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
4	Primjenjujem u poduzeću (niveliranje proizvodnje) Heijunka	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
5	Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).

a. Dependent Variable: NapredakPrekomjeranTransport

Slika 211. *Najbolji prediktori dobiveni SMLR modelom*

- *Poka-yoke*, 5S, *heijunka*, analiza glavnog uzroka i *kanban* alati su koji najviše utječu na napredak u pogledu smanjenja prekomjernog transporta.

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.438[a]	.192	.178	.64809
2	.558[b]	.311	.289	.60310
3	.619[c]	.383	.352	.57569
4	.651[d]	.424	.384	.56098
5	.681[e]	.464	.417	.54580

a. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke
b. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (uređenje prostora) 5S
c. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (uređenje prostora) 5S, Primjenjujem u poduzeću Analiza glavnog uzroka
d. Predictors: (Constant), Primjenjujem u poduzeću (sustav za detekciju grešaka) Poka-Yoke, Primjenjujem u poduzeću (uređenje prostora) 5S, Primjenjujem u poduzeću Analiza glavnog uzroka, Primjenjujem u poduzeću (niveliranje proizvodnje) Heijunka
e. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (uređenje prostora) 5S, Primjenjujem u poduzeću Analiza glavnog uzroka, Primjenjujem u poduzeću (niveliranje proizvodnje) Heijunka, Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban

Slika 212. *Koeficijenti korelacije i determinacije za odabrane prediktore*

- Koeficijent korelacije (R) u svim nam slučajevima govori da postoji značajna povezanost između nezavisnih i zavisne varijable.
- Koeficijent determinacije (R^2) za peti slučaj iznosi 0,464. To znači da naše nezavisne varijable u petom slučaju predviđaju 46,4 % varijabilnosti naše zavisne varijable.

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	6.076	1	6.076	14.466	.000[b]
	Residual	25.621	61	.420		
	Total	31.697	62			
2	Regression	9.873	2	4.936	13.571	.000[c]
	Residual	21.824	60	.364		
	Total	31.697	62			
3	Regression	12.143	3	4.048	12.213	.000[d]
	Residual	19.554	59	.331		
	Total	31.697	62			
4	Regression	13.444	4	3.361	10.680	.000[e]
	Residual	18.253	58	.315		
	Total	31.697	62			
5	Regression	14.717	5	2.943	9.881	.000[f]
	Residual	16.980	57	.298		
	Total	31.697	62			

a. Dependent Variable: NapredakPrekomjeranTransport
b. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke
c. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (uređenje prostora) 5S
d. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (uređenje prostora) 5S, Primjenjujem u poduzeću Analiza glavnog uzroka
e. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (uređenje prostora) 5S, Primjenjujem u poduzeću Analiza glavnog uzroka, Primjenjujem u poduzeću (niveliranje proizvodnje) Heijunka
f. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (uređenje prostora) 5S, Primjenjujem u poduzeću Analiza glavnog uzroka, Primjenjujem u poduzeću (niveliranje proizvodnje) Heijunka, Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban

Slika 213. *Provjera značajnosti varijabli (prediktora)*

- $p < 0,05$ za sve slučajeve, što znači da nezavisne varijable statistički značajno predviđaju zavisnu varijablu.
- Vitki alati koji najbolje pridonose smanjeju prekomjernog transporta su *poka-yoke*, 5S, *heijunka* i *kanban*.
- Analiza glavnog uzroka negativno utječe na napredak u pogledu smanjenja prekomjernog transporta.

PRILOG 36: vitki alati koji najbolje smanjuju čekanje

Stepwise Multiple Linear Regression

Variables Entered/Removed[a]

Model	Variables Entered	Variables Removed	Method
1	Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
2	Primjenjujem u poduzeću (vizualni sustav pogona) Andon	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
3	Primjenjujem u poduzeću (uređenje prostora) 5S	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
4	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).

a. Dependent Variable: NapredakČekanje

Slika 214. *Najbolji prediktori dobiveni SMLR modelom*

- Taktno vrijeme, *andon*, 5S i TPM alati su koji najviše utječu na napredak u pogledu smanjenja čekanja.

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.509[a]	.259	.247	.59557
2	.620[b]	.384	.363	.54767
3	.699[c]	.489	.463	.50300
4	.742[d]	.550	.519	.47599

a. Predictors: (Constant), Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme
b. Predictors: (Constant), Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme, Primjenjujem u poduzeću (vizualni sustav pogona) Andon
c. Predictors: (Constant), Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme, Primjenjujem u poduzeću (vizualni sustav pogona) Andon, Primjenjujem u poduzeću (uređenje prostora) 5S
d. Predictors: (Constant), Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme, Primjenjujem u poduzeću (vizualni sustav pogona) Andon, Primjenjujem u poduzeću (uređenje prostora) 5S, Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM

Slika 215. *Koeficijenti korelacije i determinacije za odabrane prediktore*

- Koeficijent korelacije (R) u svim nam slučajevima govori da postoji značajna povezanost između nezavisnih i zavisne varijable.

- Koeficijent determinacije (R^2) za četvrti slučaj iznosi 0,550. To znači da naše nezavisne varijable u četvrtom slučaju predviđaju 55 % varijabilnosti naše zavisne varijable.

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	7.577	1	7.577	21.362	.000[b]
	Residual	21.637	61	.355		
	Total	29.214	62			
2	Regression	11.218	2	5.609	18.700	.000[c]
	Residual	17.997	60	.300		
	Total	29.214	62			
3	Regression	14.287	3	4.762	18.822	.000[d]
	Residual	14.928	59	.253		
	Total	29.214	62			
4	Regression	16.073	4	4.018	17.736	.000[e]
	Residual	13.141	58	.227		
	Total	29.214	62			

a. Dependent Variable: NapredakČekanje
b. Predictors: (Constant), Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme
c. Predictors: (Constant), Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme, Primjenjujem u poduzeću (vizualni sustav pogona) Andon
d. Predictors: (Constant), Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme, Primjenjujem u poduzeću (vizualni sustav pogona) Andon, Primjenjujem u poduzeću (uređenje prostora) 5S
e. Predictors: (Constant), Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme, Primjenjujem u poduzeću (vizualni sustav pogona) Andon, Primjenjujem u poduzeću (uređenje prostora) 5S, Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM

Slika 216. *Provjera značajnosti varijabli (prediktora)*

- $p < 0,05$ za sve slučajeve, što znači da nezavisne varijable statistički značajno predviđaju zavisnu varijablu.

Coefficients[a]

Model		Unstandardized Coefficients B	Unstandardized Coefficients Std. Error	Standardized Coefficients Beta	t	Sig.
1	(Constant)	1.005	.085		11.813	.000
	Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme	.834	.180	.509	4.622	.000
2	(Constant)	.917	.082		11.144	.000
	Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme	.819	.166	.500	4.936	.000
	Primjenjujem u poduzeću (vizualni sustav pogona) Andon	.722	.207	.353	3.484	.001
3	(Constant)	.669	.104		6.454	.000
	Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme	.746	.154	.455	4.845	.000
	Primjenjujem u poduzeću (vizualni sustav pogona) Andon	.705	.190	.345	3.702	.000
	Primjenjujem u poduzeću (uređenje prostora) 5S	.453	.130	.327	3.483	.001
4	(Constant)	.597	.101		5.890	.000
	Primjenjujem u poduzeću (usklađenje proizvodnje i zahtjeva kupaca) Taktno vrijeme	.712	.146	.435	4.870	.000
	Primjenjujem u poduzeću (vizualni sustav pogona) Andon	.638	.182	.312	3.512	.001
	Primjenjujem u poduzeću (uređenje prostora) 5S	.394	.125	.285	3.156	.003
	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.368	.131	.255	2.808	.007

a. Dependent Variable: NapredakČekanje

Slika 217. *Najbolji modeli za smanjenje čekanja*

- Vitki alati koji najbolje pridonose smanjenju čekanja su taktno vrijeme, *andon*, 5S i TPM.

PRILOG 37: vitki alati koji najbolje smanjuju prekomjernu obradu

Stepwise Multiple Linear Regression

Variables Entered/Removed[a]

Model	Variables Entered	Variables Removed	Method
1	Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
2	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).

a. Dependent Variable: NapredakPrekomjernaObrada

Slika 218. *Najbolji prediktori dobiveni SMLR modelom*

- *Poka-yoke* i TPM alati su koji najviše utječu na napredak u pogledu smanjenja prekomjerne obrade.

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.495[a]	.245	.232	.63584
2	.546[b]	.298	.274	.61816

a. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke
b. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM

Slika 219. *Koeficijenti korelacije i determinacije za odabrane prediktore*

- Koeficijent korelacije (R) u svim nam slučajevima govori da postoji značajna povezanost između nezavisnih i zavisne varijable.
- Koeficijent determinacije (R^2) za drugi slučaj iznosi 0,298. To znači da naše nezavisne varijable u drugom slučaju predviđaju 29,8 % varijabilnosti naše zavisne varijable.

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	7.989	1	7.989	19.761	.000[b]
	Residual	24.662	61	.404		
	Total	32.651	62			
2	Regression	9.723	2	4.862	12.723	.000[c]
	Residual	22.927	60	.382		
	Total	32.651	62			

a. Dependent Variable: NapredakPrekomjernaObrada
b. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke
c. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM

Slika 220. *Provjera značajnosti varijabli (prediktora)*

- p < 0,05 za sve slučajeve, što znači da nezavisne varijable statistički značajno predviđaju zavisnu varijablu.

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients		
		B	Std. Error	Beta	t	Sig.
1	(Constant)	.510	.089		5.726	.000
	Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke	.907	.204	.495	4.445	.000
2	(Constant)	.421	.096		4.387	.000
	Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke	.653	.231	.356	2.825	.006
	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.410	.193	.269	2.131	.037

a. Dependent Variable: NapredakPrekomjernaObrada

Slika 221. *Najbolji modeli za smanjenje prekomjerne obrade*

- Vitki alati koji najbolje pridonose smanjenju prekomjerne obrade su *poka-yoke* i TPM.

PRILOG 38: vitki alati koji najbolje smanjuju nepotrebne zalihe

Stepwise Multiple Linear Regression

Variables Entered/Removed[a]

Model	Variables Entered	Variables Removed	Method
1	Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
2	Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
3	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
4	Primjenjujem u poduzeću (parcijalna automatizacija) Jidoka	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).

a. Dependent Variable: NapredakNepotrebneZalihe

Slika 222. *Najbolji prediktori dobiveni SMLR modelom*

- OEE, *kanban*, TPM i *jidoka* alati su koji najviše utječu na napredak u pogledu smanjenja nepotrebnih zaliha.

Model Summary[e]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.394[a]	.155	.141	.61431
2	.471[b]	.222	.196	.59447
3	.529[c]	.280	.243	.57659
4	.590[d]	.348	.303	.55345

a. Predictors: (Constant), Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE
b. Predictors: (Constant), Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE, Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban
c. Predictors: (Constant), Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE, Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban, Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM
d. Predictors: (Constant), Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE, Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban, Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM, Primjenjujem u poduzeću (parcijalna automatizacija) Jidoka
e. Dependent Variable: NapredakNepotrebneZalihe

Slika 223. *Koeficijenti korelacije i determinacije za odabrane prediktore*

- Koeficijent korelacije (R) u svim nam slučajevima govori da postoji značajna povezanost između nezavisnih i zavisne varijable.

- Koeficijent determinacije (R^2) za četvrti slučaj iznosi 0,348. To znači da naše nezavisne varijable u četvrtom slučaju predviđaju 34,8 % varijabilnosti naše zavisne varijable.

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	4.226	1	4.226	11.198	.001[b]
	Residual	23.020	61	.377		
	Total	27.246	62			
2	Regression	6.042	2	3.021	8.549	.001[c]
	Residual	21.204	60	.353		
	Total	27.246	62			
3	Regression	7.631	3	2.544	7.651	.000[d]
	Residual	19.615	59	.332		
	Total	27.246	62			
4	Regression	9.480	4	2.370	7.737	.000[e]
	Residual	17.766	58	.306		
	Total	27.246	62			

a. Dependent Variable: NapredakNepotrebneZalihe
b. Predictors: (Constant), Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE
c. Predictors: (Constant), Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE, Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban
d. Predictors: (Constant), Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE, Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban, Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM
e. Predictors: (Constant), Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE, Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban, Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM, Primjenjujem u poduzeću (parcijalna automatizacija) Jidoka

Slika 224. *Provjera značajnosti varijabli (prediktora)*

- $p < 0,05$ za sve slučajeve, što znači da nezavisne varijable statistički značajno predviđaju zavisnu varijablu.

Coefficients[a]

Model		Unstandardized Coefficients B	Unstandardized Coefficients Std. Error	Standardized Coefficients Beta	t	Sig.
1	(Constant)	.860	.087		9.899	.000
	Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE	.640	.191	.394	3.346	.001
2	(Constant)	.772	.093		8.337	.000
	Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE	.605	.186	.372	3.257	.002
	Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban	.400	.176	.259	2.267	.027
3	(Constant)	.681	.099		6.886	.000
	Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE	.438	.196	.270	2.241	.029
	Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban	.413	.171	.268	2.413	.019
	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.366	.167	.262	2.186	.033
4	(Constant)	.720	.096		7.482	.000
	Primjenjujem u poduzeću (cjelokupna učinkovitost opreme) OEE	.572	.195	.352	2.926	.005
	Primjenjujem u poduzeću (metoda za regulaciju robe i zaliha) Kanban	.545	.173	.353	3.150	.003
	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.446	.164	.320	2.722	.009
	Primjenjujem u poduzeću (parcijalna automatizacija) Jidoka	-.437	.178	-.300	-2.457	.017

a. Dependent Variable: NapredakNepotrebneZalihe

Slika 225. *Najbolji modeli za smanjenje nepotrebnih zaliha*

- Vitki alati koji najbolje pridonose smanjenju nepotrebnih zaliha su OEE, *kanban* i TPM .
- *Jidoka* negatvno utječe na smanjenje nepotrebnih zaliha.

PRILOG 39: vitki alati koji najbolje smanjuju nepotrebne pokrete

Stepwise Multiple Linear Regression

Variables Entered/Removed[a]

Model	Variables Entered	Variables Removed	Method
1	Primjenjujem u poduzeću (brza izmjena alata) SMED	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
2	Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
3	Primjenjujem u poduzeću Ključni indikatori učinkovitosti	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).

a. Dependent Variable: NapredakNepotrebniPokreti

Slika 226. *Najbolji prediktori dobiveni SMLR modelom*

- SMED, *kaizen* i ključni indikatori učinkovitosti alati su koji najviše utječu na napredak u pogledu smanjenja nepotrebnih pokreta.

Model Summary[d]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.440[a]	.194	.181	.63549
2	.535[b]	.286	.262	.60307
3	.582[c]	.339	.305	.58522

a. Predictors: (Constant), Primjenjujem u poduzeću (brza izmjena alata) SMED
b. Predictors: (Constant), Primjenjujem u poduzeću (brza izmjena alata) SMED, Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen
c. Predictors: (Constant), Primjenjujem u poduzeću (brza izmjena alata) SMED, Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen, Primjenjujem u poduzeću Ključni indikatori učinkovitosti
d. Dependent Variable: NapredakNepotrebniPokreti

Slika 227. *Koeficijenti korelacije i determinacije za odabrane prediktore*

- Koeficijent korelacije (R) u svim nam slučajevima govori da postoji značajna povezanost između nezavisnih i zavisne varijable.
- Koeficijent determinacije (R^2) za treći slučaj iznosi 0,339. To znači da naše nezavisne varijable u trećem slučaju predviđaju 33,9 % varijabilnosti naše zavisne varijable.

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	5.929	1	5.929	14.682	.000[b]
	Residual	24.635	61	.404		
	Total	30.564	62			
2	Regression	8.743	2	4.371	12.020	.000[c]
	Residual	21.822	60	.364		
	Total	30.564	62			
3	Regression	10.358	3	3.453	10.081	.000[d]
	Residual	20.207	59	.342		
	Total	30.564	62			

a. Dependent Variable: NapredakNepotrebniPokreti
b. Predictors: (Constant), Primjenjujem u poduzeću (brza izmjena alata) SMED
c. Predictors: (Constant), Primjenjujem u poduzeću (brza izmjena alata) SMED, Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen
d. Predictors: (Constant), Primjenjujem u poduzeću (brza izmjena alata) SMED, Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen, Primjenjujem u poduzeću Ključni indikatori učinkovitosti

Slika 228. *Provjera značajnosti varijabli (prediktora)*

- $p < 0,05$ za sve slučajeve, što znači da nezavisne varijable statistički značajno predviđaju zavisnu varijablu.

Coefficients[a]

Model		Unstandardized Coefficients B	Unstandardized Coefficients Std. Error	Standardized Coefficients Beta	t	Sig.
1	(Constant)	.841	.098		8.579	.000
	Primjenjujem u poduzeću (brza izmjena alata) SMED	.651	.170	.440	3.832	.000
2	(Constant)	.613	.124		4.933	.000
	Primjenjujem u poduzeću (brza izmjena alata) SMED	.568	.164	.384	3.463	.001
	Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen	.437	.157	.309	2.781	.007
3	(Constant)	.471	.137		3.442	.001
	Primjenjujem u poduzeću (brza izmjena alata) SMED	.521	.161	.353	3.248	.002
	Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen	.392	.154	.277	2.550	.013
	Primjenjujem u poduzeću Ključni indikatori učinkovitosti	.329	.152	.235	2.171	.034

a. Dependent Variable: NapredakNepotrebniPokreti

***Slika 229**. Najbolji modeli za smanjenje nepotrebnih pokreta*

- Vitki alati koji najbolje pridonose smanjenju nepotrebnih pokreta su SMED, *kaizen* i ključni indikatori učinkovitosti.

PRILOG 40: vitki alati koji najbolje smanjuju škart

Stepwise Multiple Linear Regression

Variables Entered/Removed[a]

Model	Variables Entered	Variables Removed	Method
1	Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
2	Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
3	Primjenjujem u poduzeću (kategorizacija gubitaka) Šest velikih gubitaka	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).

a. Dependent Variable: NapredakŠkart

Slika 230. *Najbolji prediktori dobiveni SMLR modelom*

- *Poka-yoke, kaizen* i šest velikih gubitaka alati su koji najviše utječu na napredak u pogledu smanjenja škarta.

Model Summary[d]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.452[a]	.205	.192	.70591
2	.522[b]	.272	.248	.68082
3	.585[c]	.342	.309	.65268

a. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke
b. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen
c. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen, Primjenjujem u poduzeću (kategorizacija gubitaka) Šest velikih gubitaka
d. Dependent Variable: NapredakŠkart

Slika 231. *Koeficijenti korelacije i determinacije za odabrane prediktore*

- Koeficijent korelacije (R) u svim nam slučajevima govori da postoji značajna povezanost između nezavisnih i zavisne varijable.
- Koeficijent determinacije (R^2) za treći slučaj iznosi 0,342. To znači da naše nezavisne varijable u trećem slučaju predviđaju 34,2 % varijabilnosti naše zavisne varijable.

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	7.817	1	7.817	15.687	.000[b]
	Residual	30.397	61	.498		
	Total	38.214	62			
2	Regression	10.403	2	5.202	11.222	.000[c]
	Residual	27.811	60	.464		
	Total	38.214	62			
3	Regression	13.081	3	4.360	10.236	.000[d]
	Residual	25.133	59	.426		
	Total	38.214	62			

a. Dependent Variable: NapredakŠkart
b. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke
c. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen
d. Predictors: (Constant), Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke, Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen, Primjenjujem u poduzeću (kategorizacija gubitaka) Šest velikih gubitaka

Slika 232. *Provjera značajnosti varijabli (prediktora)*

- $p < 0,05$ za sve slučajeve, što znači da nezavisne varijable statistički značajno predviđaju zavisnu varijablu.

Coefficients[a]

Model		Unstandardized Coefficients B	Unstandardized Coefficients Std. Error	Standardized Coefficients Beta	t	Sig.
1	(Constant)	1.353	.099		13.687	.000
	Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke	.897	.226	.452	3.961	.000
2	(Constant)	1.118	.138		8.120	.000
	Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke	.857	.219	.432	3.909	.000
	Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen	.413	.175	.261	2.362	.021
3	(Constant)	1.107	.132		8.377	.000
	Primjenjujem u poduzeću (izbjegavanje greške) Poka-Yoke	.932	.212	.470	4.393	.000
	Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen	.516	.172	.326	2.989	.004
	Primjenjujem u poduzeću (kategorizacija gubitaka) Šest velikih gubitaka	-.795	.317	-.276	-2.507	.015

a. Dependent Variable: NapredakŠkart

Slika 233. *Najbolji modeli za smanjenje škarta*

- Vitki alati koji najbolje pridonose smanjenju škarta su *poka-yoke* i *kaizen*.

PRILOG 41: vitki alati koji najbolje smanjuju nedovoljnu iskorištenost potencijala zaposlenika

Stepwise Multiple Linear Regression

Variables Entered/Removed[a]

Model	Variables Entered	Variables Removed	Method
1	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).
2	Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen	.	Stepwise (Criteria: Probability-of-F-to-enter <= .050, Probability-of-F-to-remove >= .100).

a. Dependent Variable: NapredakNedovoljnaIskorištenostPotencijalaZaposlenika

Slika 234. *Najbolji prediktori dobiveni SMLR modelom*

- TPM i *kaizen* alati su koji najviše utječu na napredak u pogledu smanjenja nedovoljne iskorištenosti potencijala zaposlenika.

Model Summary[c]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.467[a]	.218	.205	.68391
2	.521[b]	.271	.247	.66575

a. Predictors: (Constant), Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM
b. Predictors: (Constant), Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM, Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen
c. Dependent Variable: NapredakNedovoljnaIskorištenostPotencijalaZaposlenika

Slika 235. *Koeficijenti korelacije i determinacije za odabrane prediktore*

- Koeficijent korelacije (R) u svim nam slučajevima govori da postoji značajna povezanost između nezavisnih i zavisne varijable.
- Koeficijent determinacije (R^2) za drugi slučaj iznosi 0,271. To znači da naše nezavisne varijable u trećem slučaju predviđaju 27,1 % varijabilnosti naše zavisne varijable.

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	7.959	1	7.959	17.015	.000[b]
	Residual	28.532	61	.468		
	Total	36.490	62			
2	Regression	9.897	2	4.948	11.164	.000[c]
	Residual	26.594	60	.443		
	Total	36.490	62			

a. Dependent Variable: NapredakNedovoljnaIskorištenostPotencijalaZaposlenika
b. Predictors: (Constant), Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM
c. Predictors: (Constant), Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM, Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen

Slika 236. *Provjera značajnosti varijabli (prediktora)*

- $p < 0,05$ za sve slučajeve, što znači da nezavisne varijable statistički značajno predviđaju zavisnu varijablu.

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	1.325	.106		12.559	.000
	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.754	.183	.467	4.125	.000
2	(Constant)	1.129	.139		8.112	.000
	Primjenjujem u poduzeću (cjelovito produktivno održavanje) TPM	.711	.179	.441	3.971	.000
	Primjenjujem u poduzeću (kontinuirano poboljšanje) Kaizen	.359	.171	.232	2.091	.041

a. Dependent Variable: NapredakNedovoljnaIskorištenostPotencijalaZaposlenika

Slika 237. *Najbolji modeli za smanjenje škarta*

- Vitki alati koji najbolje pridonose smanjenju nedovoljne iskorištenosti potencijala zaposlenika su TPM i *kaizen.*

ŽIVOTOPIS

Ivan Lekšić rođen je 29. travnja 1989. godine u Zagrebu. Osnovnu školu i Prvu gimnaziju (opću) završio je u Zagrebu, nakon čega 2009. godine upisuje Fakultet strojarstva i brodogradnje na Sveučilištu u Zagrebu, smjer strojarstvo, usmjerenje industrijsko inženjerstvo i menadžment. Preddiplomski studij završava 2013. godine obranom rada iz područja upravljanja kvalitetom, dok diplomski studij uspješno završava 2014. godine obranom diplomskog rada iz područja vitke proizvodnje.

Odmah po završetku studija, 2014. godine, upisuje doktorat te usporedno počinje raditi u poduzeću Viadukt d.d., u kojem više od tri godine radi na projektima izgradnje mostova i ostale niskogradnje diljem Hrvatske. Nakon stečaja Viadukta d.d. odlazi u Zagrebački električni tramvaj d.o.o., u kojem godinu dana radi na poslovima projektiranja dijelova za tračnička vozila. Početkom 2019. godine prelazi u Končar – Generatore i motore d.d., gdje i danas radi kao voditelj projekata na izgradnji hidroelektrana diljem Europe i jugoistočne Azije.

Autor je nekoliko znanstvenih radova na temu vitkog menadžmenta i upravljanja procesima.

BIOGRAPHY

Ivan Lekšić was born on April 29th, 1989 in Zagreb, Croatia. He completed elementary school and the 1st Grammar School in Zagreb. In 2009, he started studying Industrial Engineering and Management, field of Mechanical Engineering, at the Faculty of Mechanical Engineering and Naval Architecture (FMENA), University of Zagreb. In 2013, he defended his bachelor thesis in Quality Assurance, and in 2014, he earned his master's degree with graduate thesis in Lean Management.

In 2014, he became a Ph.D. student at the FMENA, University of Zagreb, and started a full-time job in Viadukt Inc. He worked there for more than three years on bridge construction and other civil engineering projects across Croatia. After bankruptcy and forced administration in Viadukt, he continued his career in Zagreb Electric Tram Ltd., where he worked as a design engineer for railway vehicles for a year. In 2019, he started to work in Končar – Generators and motors Inc. as Project Manager for hydropower plants in Europe and South East Asia, where he still works.

He is the author of several scientific papers, mostly about Lean and Process Management.