RAZVOJ I PRIMJENA KOSIMULACIJSKIH SUSTAVA ZA SINTEZU REGULACIJSKIH STRUKTURA ASINKRONOG STROJA

Varga, Toni

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:685877

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-05-14**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA

Toni Varga

RAZVOJ I PRIMJENA KOSIMULACIJSKIH SUSTAVA ZA SINTEZU REGULACIJSKIH STRUKTURA ASINKRONOG STROJA

Doktorska disertacija

Osijek, 2022.

Ova doktorska disertacija je izrađena u sklopu projekta "Razvoj postupaka kosimulacija programskih alata za primjenu mekog računarstva u elektroenergetici COPESOC", pod vodstvom izv. prof. dr. sc. Marinka Barukčića i oznakom natječaja "UIP-05-2017-8572" na:

Zavodu za elektrostrojarstvo,
Fakulteta elektrotehnike, računarstva i informacijskih tehnologija Osijek,
Sveučilišta J.J. Strossmayera Osijek.

Mentor: Izv. prof. dr.sc. Marinko Barukčić, izvanredni profesor

Disertacija ima 120 stranica

Disertacija broj: 88

Povjerenstvo za ocjenu teme doktorske disertacije:

Prof. dr. sc. Željko Hederić - predsjednik povjerenstva, FERIT Osijek

Izv. prof. dr. sc. Emmanuel Karlo Nyarko, član, FERIT Osijek

Prof. dr. sc. Neven Bulić - vanjski član, Tehnički fakultet Rijeka

Povjerenstvo za obranu doktorske disertacije:

Prof. dr. sc. Željko Hederić - predsjednik povjerenstva, FERIT Osijek

Izv. prof. dr. sc. Emmanuel Karlo Nyarko, član, FERIT Osijek

Prof. dr. sc. Neven Bulić - vanjski član, Tehnički fakultet Rijeka

Datum obrane doktorske disertacije: 22. srpanj 2022.

Želim se zahvaliti mojem mentoru Marinku Barukčiću, koji me je svojim savjetima vodio kroz doktorski studij i svojim djelima osigurao nesmetan i siguran put do obrane ove disertacije.

Veliko hvala mojem kolegi Tinu Benšiću, kojem niti u jednom trenutku nije bilo teško pomoći i dati savjet za rješavanje bilo kojeg problema za vrijeme istraživanja. Puno smo toga napravili skupa.

Posebno hvala mojoj djevojci Maji Lesjak, koja je iza kulisa sa mnom proživljavala sve teške, frustrirajuće i stresne trenutke za vrijeme studija. Tvoja potpora mi je pomogla da ostanem staložen i prijeđem preko svih poteškoća koje su se našle na putu.

Hvala mojoj obitelji, prijateljima i kolegama koji su bili moralna podrška i odvlačili mi pažnju u trenutcima kada mi je trebao odmor i kada je trebalo razbistriti glavu.

Sadržaj

1. Uvod **1**

2. Matematički model elektromotornog pogona s asinkronim strojem **6**

2.1. Matematički model asinkronog stroja **6**

2.1.1. Koordinatni sustavi modela asinkronog stroja 9

2.1.2. Modeliranje asinkronog stroja u dvoosnom koordinatnom sustavu 11

2.2. Matematički model dvorazinskog frekvencijskog pretvarača . **14**

2.3. Modulacija prostornog vektora napona **16**

3. Razvoj x-IL sustava za validaciju algoritama upravljanja asinkronim strojem **21**

3.1. Stvarno-vremenski simulator **22**

3.2. Jedinica sa analognim i digitalnim ulazima i izlazima (I/O jedinica) **24**

3.3. Energetski dio sustava **25**

3.3.1. Filteri 28

3.4. Energetsko sučelje **30**

3.5. Mjerna oprema **31**

3.6. Kompletan sustav za validaciju algoritama upravljanja asinkronim strojem **32**

3.6.1. Postolje sa električnim strojevima 35

3.7. Skalarna regulacija asinkronog stroja **37**

3.7.1. MIL simulacija skalarne regulacije na kosimulacijskom razvojnom sustavu 38

3.7.2. RCP implementacija skalarne regulacije na kosimulacijskom razvojnom sustavu i usporedba sa MIL simulacijom 40

4. Razvoj prediktivnog upravljanja bez težinskih faktora za regulaciju brzine vrtnje asinkronog stroja 43
4.1. Uvod u poglavlje 43
4.2. Klasične regulacijske strukture za precizno upravljanje asinkronim strojevima 45
4.2.1. Regulacija rotorskog toka. 46
4.2.2. Direktno upravljanje momentom 48
4.3. Napredne regulacijske strukture za precizno upravljanje asinkronim strojevima 51
4.3.1. Izvod izraza za predikciju struje asinkronog stroja 51
4.3.2. Konačno prediktivno upravljanje momentom *(Finite control set predictive torque control)* 54
4.3.3. Konačno prediktivno upravljanje strujom *(Finite control set predictive current control)*. 55
4.4. Kontinuirano prediktivno upravljanje strujom asinkronog stroja bez težinskih faktora 57
4.4.1. Vanjska regulacijska petlja 58
4.4.2. Osmotritelj rotorskog toka i brzine vrtnje 59
4.4.3. Analiza stabilnosti sustava 60
4.4.4. Analiza upravljivosti sustava 62
4.4.5. Rezultati simulacije 63
5. Primjena kosimulacijskog pristupa u svrhu optimiranja neizrazitog regulatora brzine vrtnje asinkronog stroja 70
5.1. Uvod u poglavlje 70
5.2. Postupak izrade neizrazitog regulatora brzine vrtnje asinkronog stroja 74
5.2.1. Ulaz i izlaz neizrazitog regulatora 75
5.2.2. Ulazne funkcije pripadnosti 76
5.2.3. Neizrazito zaključivanje 77
5.2.4. Defuzifikacija 78
5.3. Optimizacija neizrazitog regulatora 79
5.3.1. Funkcija cilja 80

5.3.2. Varijable odluke 83
5.3.3. MIDACO optimizator 83
5.4. Rezultati optimizacije. 84
5.5. Performanse pogona 89
5.6. Usporedba predložene metode sa drugim metodama iz kategorije prediktivnog upravljanja 91
6. Zaključak. 94
LITERATURA 98
Tumač oznaka. 113
Sažetak 116
Abstract 118
Biografija 120

1. UVOD

Električni strojevi se koriste u svim granama industrije te u mnogim uređajima, od jednostavnih kućanskih aparata do masivnih generatora visokih snaga. Većina pretvorene svjetske energije dolazi iz pogona u kojima su uključeni upravo električni strojevi [1]. Mnoštvo elektromotornih pogona koristi asinkroni stroj kao radni stroj, zbog njegove visoke robusnosti, pouzdanosti te korisnosti [2]. Kako bi elektromotorni pogon postigao što veću korisnost, podliježe se tehnikama optimizacije, kako dizajna stroja, tako i regulacijskih tehnika. Zbog visoke integriranosti elektromotornih pogona u svjetsku industriju, dovoljan je veoma mali postotak poboljšanja, kako bi se postigao značajan efekt na makro razini.

Suvremeni razvoj različitih programskih paketa za proračun i simuliranje elektromehaničkih i elektromagnetskih prijelaznih pojava pomoću metode konačnih elemenata, kao što su Ansys Maxwell, Comsol i Open Modelica, omogućava inženjerima relativno lak pristup dizajnu strojeva. Programski paketi za simulaciju električnih i temperaturnih prijelaznih pojava komponenata energetske elektronike, kao što su PSim ili PLECS, osnovni su dio razvoja pogona i veoma su bitni u procesu proizvodnje, dok programski paketi za proračune sustava diferencijalnih jednadžbi, kao što je Matlab/Simulink, omogućavaju brz razvoj različitih regulacijskih struktura.

Svi ovi programski paketi koriste se neovisno jedni o drugima u različitim fazama dizajna pogona, međutim simulacija uklapanja MOSFET-a u PLECS-u, ne daje uvid u elektromagnetske prilike geometrije stroja koje se mogu simulirati u Ansys-u. Kako bi se dobila jedinstvena simulacija cijelog pogona, ulažu se napori u razvoj kosimulacijskih sustava. Ovi sustavi sjedinjenjem pojedinih programskih ili fizičkih paketa rade kao jedna veća funkcionalna cjelina.

Ovakav pristup modeliranju daje uvid u sve fizikalne prilike simuliranog sustava prije kretanja u proizvodnju, čime se štedi vrijeme i novac uložen za prototipiranje, što dokazuje i mnoštvo znanstvenih radova objavljenih na ovu temu. U razvoju elektroenergetskih sustava, kosimulacijski pristup se najčešće koristi za hibridnu analizu prijelazne stabilnosti i analizu

elektromagnetskih prijelaznih pojava, kao što je prikazano u [3]. U radovima [4, 5], kosimulacijski pristup se koristi za razvoj sustava za detekciju i analizu kvarova u mikromrežama. Autori rada [6] koriste kosimulaciju programskih paketa Matlab/Simulink i OpenDSS za modeliranje prijenosnog i distribucijskog sustava. Analiza interkonekcije mreže izmjeničnog i istosmjernog napona predstavljena je u [7], gdje autori razvijaju metodu proračuna prijelaznih stanja pojedinih sustava. Kosimulacija elektroenergetskog sustava razvijenog u Matlab/Simulink-u sa NS3 komunikacijskim programom, prikazana je u [8], gdje autori razvijaju mehanizam zaštite sustava za sinkronizirano mjerenje fazora od virtualnih napada. U [9], autori razvijaju kosimulaciju između stvarno-vremenskog sustava i programskog paketa GridLAB-D u svrhu analize utjecaja kućanstava s fotonaponskom elektranom na elektroenergetski sustav. Pregled platformi i programskih paketa za kosimulacije ovisno o vrsti analize može se naći u [10].

Što se tiče kosimulacija razvijenih u području elektromotornih pogona, u radovima se najčešće ističe pristup modeliranja gdje se električni stroj modelira u jednom od programskih paketa za elektromagnetske proračune metodom konačnih elemenata, dok se sustav upravljanja i energetska elektronika modelira u nekom drugom programskom paketu. Ovdje se mogu izdvojiti radovi kao što su [11, 12, 13, 14], gdje autori modeliraju sinkroni stroj s permanentnim magnetima u programskim paketima kao što su MagNet, Flux, ModelSim te Ansys Maxwell, dok regulacijske metode implementiraju u Matlab/Simulinku te Portunusu. U [15], autori modeliraju asinkroni stroj u Ansys Maxwell programskom paketu, a za razvoj upravljačke strukture koriste Matlab/Simulink. Sličan pristup imaju autori u [16, 17], gdje koriste različite programske pakete za razvoj upravljanja reluktantnog stroja s permanentnim magnetima.

Kosimulacije je moguće provoditi na sustavima kao što su osobna ili super računala, što u većini slučajeva znači da će vrijeme simulacije modeliranog sustava varirati u ovisnosti o performansama računala i o veličini modela. Ovakve simulacije su korisne za analize izvedivosti projekata, analize stabilnosti te promatranje prijelaznih pojava. Razvoj stvarno-vremenskih simulatora omogućava da se simulacije izvršavaju u fiksnim vremenskim uzorcima gdje vremenska jedinica simulacije odgovara vremenskoj jedinici stvarnosti. Na ovaj način, simulacije je moguće izvršavati u stvarnom vremenu, a uz pomoć jedinice analognih i digitalnih ulaza i izlaza, simulirane odzive je moguće povezati s vanjskim uređajima. Rad [18] daje detaljan pregled vrsta stvarno-vremenskih simulatora gdje ih dijele prema arhitekturi i vrsti proce-

sora. Osim toga, navode različite vrste simulacija koje ovakvi sustavi omogućavaju, a to su prema engleskoj terminologiji:

1. *Model In the Loop* – MIL: početni dio razvoja gdje se kompletan sustav, regulacija i zaštita sustava modelira unutar stvarno-vremenskog simulatora.

2. *Software In the Loop* – SIL: dio razvoja u kojem se programski kod regulatora ili zaštitnog releja napisan za mikrokontroler ili digitalni procesor signala, izvršava u okruženju stvarno-vremenskog simulatora.

3. *Processor In the Loop* – PIL: dio razvoja u kojem se programski kod regulatora ili zaštitnog releja prevodi i izvršava na mikrokontroleru ili digitalnom procesoru signala koji će se koristiti u stvarnom pogonu. U ovom dijelu razvoja, programski se kod ugađa i podešava za specifičnosti platforme za koju je preveden.

4. *Controller Hardware in The Loop* – CHIL: dio razvoja gdje se gotov regulator ili zaštitni relej testira na način da se regulirani uređaj ili kvar simulira na stvarno-vremenskom simulatoru. Regulator u ovom slučaju šalje upravljačke impulse direktno na digitalne ulaze simulatora, a zaštitni relej prima signale struje i napona na svoje analogne ulaze, direktno s analognih izlaza simulatora.

5. *Power Hardware In the Loop* – PHIL: vrsta simulacije gdje se dio sustava simulira na stvarno-vremenskom simulatoru, a dio sustava se pomoću energetskog pojačala visoke snage, simulira izvan stvarno-vremenskog simulatora. Na ovaj način pojačalo može zamijeniti bilo koji uređaj ili sustav što daje priliku inženjerima da testiraju algoritme regulacije i zaštitne releje prije nego što ih implementiraju u stvarni sustav.

6. *Rapid Control Prototyping* – RCP: kao što samo ime govori, ovakve vrste simulacije se koriste za brz razvoj i testiranje različitih upravljačkih algoritama elektromotora. Ovdje se upravljački algoritmi implementiraju na stvarno-vremenski simulator, a motori su posredstvom energetske elektronike upravljani ovim algoritmima.

Autori u [19] daju pregled različitih uporaba stvarno-vremenskih simulatora, kako u akademiji tako i u industriji. U [20], autori navode različite arhitekture procesora na kojima se mogu izvršavati stvarno-vremenske simulacije, dok u [21], autori navode različite vrste komercijalno dostupnih stvarno-vremenskih simulatora. U [22], autori razvijaju vlastiti stvarno-vremenski simulator pomoću mikorkontrolera, gdje demonstriraju mogućnost

razvoja upravljačkih algoritama za elektromotorni pogon i sustave pohrane energije. U radovima kao što su [23] i [24] predstavljeni su pregledi metoda kojima se modeliraju komponente energetske elektronike te različite vrste algoritama za proračun elektromagnetskih prijelaznih pojava u elektroenergetskim sustavima prilagođenih za implementaciju i izvršavanje na stvarno-vremenskim simulatorima. U [25], autori razvijaju vlastiti stvarno-vremenski simulator pomoću FPGA čipa te ga koriste za simuliranje komponenata energetske elektronike. U radovima [26, 27], autori predstavljaju pristup redukcije matrice stanja kod modela modularnog matričnog frekvencijskog pretvarača za izvršavanje na stvarno-vremenskom simulatoru. Testiranje različitih sustava zaštite i upravljanje baterijskim spremnicima u pametnim i mikromrežama, prezentirano je u [28, 29, 30]. Simulacije elektromotornih pogona na stvarno-vremenskim simulatorima prikazane su u radovima kao što su [31], gdje se simuliraju mehanička naprezanja osovine stroja u stvarnom vremenu, [32], gdje autori vrše ispitivanje pretvarača, a stroj simuliraju na stvarno-vremenskom simulatoru te [33], gdje autori izvršavaju PHIL simulaciju pomoću energetskog pojačala koji simulira sinkroni stroj, a komercijalni pretvarač upravlja istim. Zbog diskretne prirode stvarno-vremenskih simulatora, mogu se javljati problemi sa sinkronizacijom vanjskih sustava koji su povezani sa simulatorom. Radovi [34, 35] navode ove probleme te prednosti i nedostatke pojedinih rješenja.

Koncepti simuliranja sustava na stvarno-vremenskim simulatorima su danas veoma često primijenjeni u industriji, počevši od simulacije kompletnog sustava do testiranja pojedinih uređaja pomoću energetskih pojačala. Prvi razlog tome je velika ušteda novca u procesu prototipiranja, gdje se simulacijama lako izbjegne uništavanje pojedinih komponenti sustava. Drugi je razlog ušteda vremena u završnim fazama proizvodnje jer se većina grešaka i problema riješila u početnim fazama putem simulacija.

U ovoj disertaciji predstavljen je razvoj kosimulacijskog sustava za prototipiranje i optimizaciju upravljačkih algoritama asinkronog stroja pomoću stvarno-vremenskog simulatora. S obzirom da se kroz cijelu disertaciju protežu simulacije asinkronog stroja spojenog na frekvencijski pretvarač, u prvom poglavlju bit će predstavljeni matematički modeli asinkronog stroja i frekvencijskog pretvarača te modulacijska tehnika korištena za moduliranje upravljačkog napona koji se primjenjuje na asinkroni stroj.

U drugom poglavlju predstavljen je detaljan pregled uređaja i komponenti koje su korištene za realizaciju kosimulacijskog sustava. Sustav je potom iskorišten za MIL simulaciju ska-

larne regulacije asinkronog stroja, a nakon analize odziva u simulaciji, upravljački algoritam je pomoću RCP pristupa testiran na stvarnom pogonu. Na kraju poglavlja prikazana je usporedba stvarnih i simuliranih odziva brzine vrtnje i struje asinkronog stroja.

U trećem poglavlju prikazane su metode za vektorsko upravljanje asinkronim strojevima. Predstavljene su konvencionalne metode koje se implementiraju u suvremene frekvencijske pretvarače te napredne metode koje spadaju u kategoriju prediktivnih metoda na temelju modela. Metoda prediktivnog upravljanja strujom asinkronog stroja detaljno je opisana, a također je predstavljeno i poboljšanje ove metode.

U četvrtom poglavlju predstavljeno je dodatno poboljšanje metode prediktivnog upravljanja strujom asinkronog stroja. Za ovo poboljšanje korišteni su principi računalne inteligencije, konkretno neizrazita logika. Principi neizrazite logike korišteni su za sintezu regulatora brzine vrtnje asinkronog stroja. Parametri regulatora su optimirani metaheurističkim optimizatorom u kosimulaciji sa stvarno-vremenskim simulatorom, kako bi se dobili što bolji odzivi momenta i brzine vrtnje asinkronog stroja.

2. MATEMATIČKI MODEL ELEKTROMOTORNOG POGONA S ASINKRONIM STROJEM

S obzirom da se ova disertacija bavi razvojem upravljačkih algoritama za pogone sa asinkronim strojevima, u ovom poglavlju prikazani su izvodi matematičkih modela asinkronog stroja i frekvencijskog pretvarača. Modulacijska tehnika kojom se upravljački napon modulira i realizira na stezaljkama asinkronog stroja također je objašnjena. Jednadžbe izvedene u ovom poglavlju koristit će se u svim narednim poglavljima.

2.1. Matematički model asinkronog stroja

Rotirajući električni strojevi pojavili su se krajem 19. stoljeća, no prvi matematički modeli istih pojavili su se tek nešto manje od pola stoljeća kasnije i to u svrhu modeliranja sinkronih strojeva. André Eugène Blondel postavio je temelje modeliranja sinkronih strojeva 1913. godine u [36]. Doherty i Nickle 1926. godine u [37], predstavljaju proširenje Blondelovog rada te postavljaju temelje modeliranja za primjenu u analizama i rješavanja praktičnih problema. Robert Henry Park u radovima [38] i [39] dodatno generalizira i pojednostavljuje postavljenu teoriju te ovime otvara vrata za matematičko modeliranje koje se može primijeniti i na asinkrone strojeve. Neke od knjiga u kojima je teorija asinkronih strojeva sistematično prikazana su [40], [41] i [42]. Na temelju teorije iznesene u ovim knjigama, prikazan je model asinkronog stroja u ovoj disertaciji.

Pri modeliranju asinkronih strojeva, donosi se nekoliko pretpostavki kako bi se pojednostavilo matematičko modeliranje, a to su:

- asinkroni stroj je trofazni, dvopolni i klizno-kolutni,
- stator se sastoji od 3 namota međusobno razmaknutih za 120° i namoti su spojeni u zvijezdu,

- rotor se sastoji od 3 namota međusobno razmaknutih za 120° i namoti su kratko spojeni,
- statorski i rotorski namoti stroja imaju sinusoidalnu distribuciju po obodu,
- veza između struja i tokova stroja je linearna,
- *skin* efekt i vrtložne struje su zanemarene.

Poštivajući ove pretpostavke, moguće je nacrtati nadomjesnu shemu prema kojoj se vrši matematičko modeliranje asinkronog stroja. Ova shema prikazana je na slici 2.1. Slova "s" i "r" u indeksima oznaka varijabli i parametara, označavaju pripadnost istih statoru, odnosno rotoru stroja. Isto vrijedi i za jednadžbe kojima je model opisan.

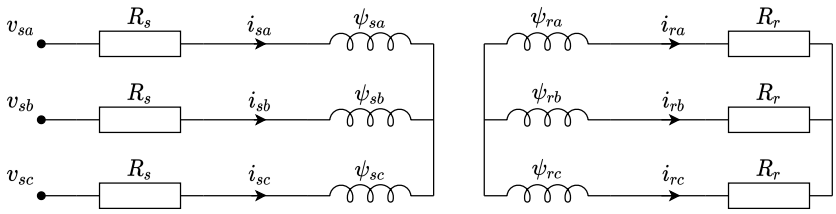

Slika 2.1: *Nadomjesna shema asinkronog stroja.*

Statorska i rotorska jednadžba stroja prikazane su izrazom (2-1), gdje vektor $\boldsymbol{v}_{s,abc} = \begin{bmatrix} v_{sa} & v_{sb} & v_{sc} \end{bmatrix}^T$ predstavlja napon stroja, vektori $\boldsymbol{i}_{s,abc} = \begin{bmatrix} i_{sa} & i_{sb} & i_{sc} \end{bmatrix}^T$ i $\boldsymbol{i}_{r,abc} = \begin{bmatrix} i_{ra} & i_{rb} & i_{rc} \end{bmatrix}^T$ predstavlju vektore statorske i rotorske struje stroja, a vektori $\boldsymbol{\psi}_{s,abc} = \begin{bmatrix} \psi_{sa} & \psi_{sb} & \psi_{sc} \end{bmatrix}^T$ i $\boldsymbol{\psi}_{r,abc} = \begin{bmatrix} \psi_{ra} & \psi_{rb} & \psi_{rc} \end{bmatrix}^T$ predstavljaju ulančane statorske i rotorske tokove stroja. R_s i R_r označavaju otpore namota faza statora i rotora.

$$\begin{aligned} \boldsymbol{v}_{s,abc} &= R_s \boldsymbol{i}_{s,abc} + \frac{\mathrm{d}}{\mathrm{d}t} \boldsymbol{\psi}_{s,abc} \\ 0 &= R_r \boldsymbol{i}_{r,abc} + \frac{\mathrm{d}}{\mathrm{d}t} \boldsymbol{\psi}_{r,abc} \end{aligned} \tag{2-1}$$

Veza tokova i struja stroja definira se jednadžbom (2-2), gdje $\boldsymbol{L}_s$ i $\boldsymbol{L}_r$ označava matrice samoinduktiviteta faza statora i rotora, a $\boldsymbol{L}_m$ označava matricu međuinduktiviteta.

$$\begin{bmatrix} \boldsymbol{\psi}_{s,abc} \\ \boldsymbol{\psi}_{r,abc} \end{bmatrix} = \begin{bmatrix} \boldsymbol{L}_{s,abc} & \boldsymbol{L}_{m,abc} \\ \boldsymbol{L}_{m,abc} & \boldsymbol{L}_{r,abc} \end{bmatrix} \begin{bmatrix} \boldsymbol{i}_{s,abc} \\ \boldsymbol{i}_{r,abc} \end{bmatrix} \tag{2-2}$$

Matrice induktiviteta $\boldsymbol{L}_s$, $\boldsymbol{L}_r$ i $\boldsymbol{L}_m$ su 3x3 matrice, čiji su elementi detaljno prikazani u [40]. Elementi matrice međuinduktiviteta nisu konstantni, već njihov iznos ovisi o položaju

rotora stroja, što će biti bitno pri izvođenju izraza za elektromagnetski moment. Jednadžba (2-3) prikazuje izraz za moment rotirajućeg sustava dobivenog pomoću energije W_{el} koja se prenosi s električnog izvora. Pomak ρ je u kontekstu modeliranja asinkronog stroja stvarni pomak osovine rotora.

$$T_e = \frac{\partial W_{el}(\boldsymbol{i}, \rho)}{\partial \rho} \tag{2-3}$$

Izraz za energiju W_{el} prikazan je jednadžbom (2-4):

$$W_{el} = \frac{1}{2}\boldsymbol{i}_{s,abc}^T \boldsymbol{L}_s \boldsymbol{i}_{s,abc} + \boldsymbol{i}_{s,abc}^T \boldsymbol{L}_m \boldsymbol{i}_{r,abc} + \frac{1}{2}\boldsymbol{i}_{r,abc}^T \boldsymbol{L}_r \boldsymbol{i}_{r,abc} \tag{2-4}$$

Ako se izraz iz jednadžbe (2-4) supstituira u (2-3) te uzme u obzir da samo međuinduktivitet stroja ovisi o položaju rotora, dobiva se konačan izraz za moment asinkronog stroja:

$$T_e = \boldsymbol{i}_{s,abc}^T \frac{\partial}{\partial \rho} \boldsymbol{L}_m \boldsymbol{i}_{r,abc} \tag{2-5}$$

Konačni trofazni model stroja prikazan je jednadžbom (2-6). Ovakav model se još naziva i model asinkronog stroja u troosnom koordinatnom sustavu. Zadnja jednadžba u izrazu je jednadžba gibanja, gdje J predstavlja inerciju pogona, ω_r predstavlja brzinu rotora u radijanima, a T_l predstavlja moment tereta.

$$\begin{gathered}
\boldsymbol{v}_{s,abc} = R_s \boldsymbol{i}_{s,abc} + \frac{\mathrm{d}}{\mathrm{d}t}\boldsymbol{\psi}_{s,abc} \\
0 = R_r \boldsymbol{i}_{r,abc} + \frac{\mathrm{d}}{\mathrm{d}t}\boldsymbol{\psi}_{r,abc} \\
\begin{bmatrix} \boldsymbol{\psi}_{s,abc} \\ \boldsymbol{\psi}_{r,abc} \end{bmatrix} = \begin{bmatrix} \boldsymbol{L}_{s,abc} & \boldsymbol{L}_{m,abc} \\ \boldsymbol{L}_{m,abc} & \boldsymbol{L}_{r,abc} \end{bmatrix} \begin{bmatrix} \boldsymbol{i}_{s,abc} \\ \boldsymbol{i}_{r,abc} \end{bmatrix} \\
T_e = \boldsymbol{i}_{s,abc}^T \frac{\partial}{\partial \rho} \boldsymbol{L}_m \boldsymbol{i}_{r,abc} \\
J\frac{\mathrm{d}}{\mathrm{d}t}\omega_r = T_e - T_l
\end{gathered} \tag{2-6}$$

Ovako izveden model teško se implementira i analizira zbog promjenjivih elemenata matrice međuinduktiviteta. Zbog toga se uvodi transformacija varijabli koja ove elemente čini

konstantnima. Transformacija također utječe i na ostale električne veličine, pa tako struje, naponi i tokovi stroja postaju neovisni o vremenu. Radi se o transformaciji modela iz troosnog u dvoosni koordinatni sustav koja je pobliže prikazana u sljedećem potpoglavlju.

2.1.1. Koordinatni sustavi modela asinkronog stroja

Slika 2.2 prikazuje troosni mirujući koordinatni sustav čije su osi međusobno razmaknute 120° i označene slovima a, b i c te ortonomirani dvoosni koordinatni sustav čije su osi označene slovima d i q.

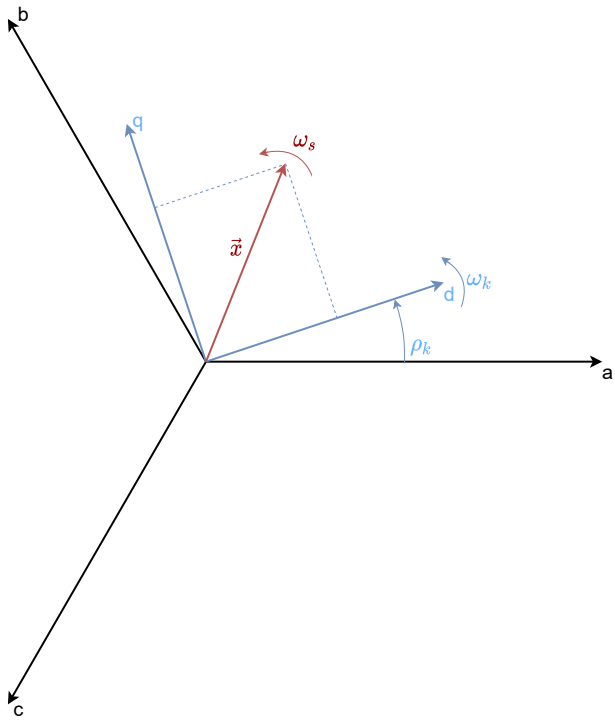

Slika 2.2: *Troosni i dvoosni koordinatni sustavi.*

Vektor $\boldsymbol{x} = \begin{bmatrix} x_a & x_b & x_c \end{bmatrix}^T$ označen crvenom bojom definiran je jednadžbom (2-7), gdje su $\vec{a}$, $\vec{b}$ i $\vec{c}$ jedinični vektori koji čine bazu troosnog koordinatnog sustava. Ovaj vektor rotira brzinom ω_s, a u kontekstu modeliranja asinkronih strojeva, još se naziva i prostorni vektor određene električne veličine.

$$\vec{x} = x_a\vec{a} + x_b\vec{b} + x_c\vec{c} \tag{2-7}$$

Iz slike je vidljivo da se isti ovaj vektor može prikazati pomoću jediničnih vektora $\vec{d}$ i $\vec{q}$ koji čine bazu ortonomiranog dq sustava. Jednadžba (2-8) Prikazuje ovaj zapis.

$$\vec{x} = x_d\vec{d} + x_q\vec{q} \tag{2-8}$$

Ortonomirani koordinatni sustav dq nije nužno mirujući, već rotira proizvoljnom brzinom ω_k, a kut ρ_k označava trenutni položaj dq sustava u odnosu na a-os troosnog mirujućeg sustava. Bez pretjeranog ulaženja u trigonometrijski izvod, jednadžba (2-9), prikazuje transformaciju prostornog vektora iz troosnog mirujućeg koordinatnog sustava u proizvoljno rotirajući dvoosni koordinatni sustav, gdje je $\boldsymbol{C}_{dq}$ matrica transformacije iz abc u dq koordinatni sustav, a konstanta od 2/3 koja se pojavljuje, služi za skaliranje modula rezultantnog vektora kako bi njegov iznos bio jednak iznosu vršne vrijednosti promatrane električne veličine.

$$\begin{gathered}
\begin{bmatrix} x_d \\ x_q \end{bmatrix} = \boldsymbol{C}_{dq} \begin{bmatrix} x_a \\ x_b \\ x_c \end{bmatrix} \\
\boldsymbol{C}_{dq} = \frac{2}{3} \begin{bmatrix} cos(\rho_k) & cos(\rho_k - \frac{2\pi}{3}) & cos(\rho_k + \frac{2\pi}{3}) \\ -sin(\rho_k) & -sin(\rho_k - \frac{2\pi}{3}) & -sin(\rho_k + \frac{2\pi}{3}) \end{bmatrix} \\
\rho_k = \int_0^\infty \omega_k \, dt + \rho_{k0}
\end{gathered} \tag{2-9}$$

Za transformaciju prostornog vektora iz dq u abc koordinatni sustav primjenjuje se matrica $\boldsymbol{C}_{dq}^{-1}$, a postupak je prikazan izrazom (2-10).

$$\begin{gathered}
\begin{bmatrix} x_a \\ x_b \\ x_c \end{bmatrix} = \boldsymbol{C}_{dq}^{-1} \begin{bmatrix} x_d \\ x_q \end{bmatrix} \\
\boldsymbol{C}_{dq}^{-1} = \begin{bmatrix} cos(\rho_k) & -sin(\rho_k) \\ cos(\rho_k - \frac{2\pi}{3}) & -sin(\rho_k - \frac{2\pi}{3}) \\ cos(\rho_k + \frac{2\pi}{3}) & -sin(\rho_k + \frac{2\pi}{3}) \end{bmatrix}
\end{gathered} \tag{2-10}$$

Najčešće korišteni koordinatni sustavi u području istraživanja električnih strojeva

U teoriji električnih strojeva, dva su koordinatna sustava koja se najčešće koriste za modeliranje, analizu i sintezu metoda upravljanja, a to su: sinkrono rotirajući dq sustav i mirujući $\alpha\beta$ sustav. Oba sustava su dvoosna ortonomirana sustava izvedena iz ranije definiranog

proizvoljno rotirajućeg dq sustava.

Sinkrono rotirajući dq sustav tvori se na način da brzina rotacije ω_k proizvoljno rotirajućeg dq sustava, u svakom trenutku bude jednaka brzini ω_s rotirajućeg vektora $\boldsymbol{x}$. Time se postiže da komponente prostornog vektora $\boldsymbol{x}$ u dq sustavu postaju konstantne, vremenski nepromjenjive. Matrica transformacije prostornog vektora iz troosnog abc sustava u sinkrono rotirajući dq sustav jednaka je matrici $\boldsymbol{C}_{dq}$, uz uvjet da je $\rho_k = \rho_s = \int_0^\infty \omega_s \, dt + \rho_{k0}$. Ovakva transformacija još se naziva i Parkova transformacija.

Mirujući $\alpha\beta$ sustav tvori se na način da se brzina rotacije ω_k proizvoljno rotirajućeg dq sustava i početna vrijednost kuta ρ_{k0} iz jednadžbe (2-9) postave na vrijednost nula. Matrice transformacije $\boldsymbol{C}_{\alpha\beta}$ i $\boldsymbol{C}_{\alpha\beta}^{-1}$ kojima se prostorni vektor $\boldsymbol{x}$ transformira iz abc u $\alpha\beta$ sustav i obrnuto, prikazane su izrazom (2-11). Ova transformacija još se naziva i Clarke transformacija.

$$\begin{aligned} \boldsymbol{C}_{\alpha\beta} &= \frac{2}{3}\begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \\ \boldsymbol{C}_{\alpha\beta}^{-1} &= \begin{bmatrix} 1 & 0 \\ -\frac{1}{2} & \frac{\sqrt{3}}{2} \\ -\frac{1}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \end{aligned} \tag{2-11}$$

Direktna transformacija između dvoosnih dq i $\alpha\beta$ sustava je također moguća te je prikazana izrazom (2-12):

$$\begin{aligned} \begin{bmatrix} x_d \\ x_q \end{bmatrix} &= \begin{bmatrix} cos(\rho_k) & sin(\rho_k) \\ -sin(\rho_k) & cos(\rho_k) \end{bmatrix} \begin{bmatrix} x_\alpha \\ x_\beta \end{bmatrix} \\ \begin{bmatrix} x_\alpha \\ x_\beta \end{bmatrix} &= \begin{bmatrix} cos(\rho_k) & -sin(\rho_k) \\ sin(\rho_k) & cos(\rho_k) \end{bmatrix} \begin{bmatrix} x_d \\ x_q \end{bmatrix} \end{aligned} \tag{2-12}$$

Sada kada su definirane sve transformacije koje se koriste u području istraživanja električnih strojeva, moguće je transformirati model stroja definiran izrazima (2-6) iz troosnog u dvoosni koordinatni sustav.

2.1.2. Modeliranje asinkronog stroja u dvoosnom koordinatnom sustavu

Dvoosni koordinatni sustav u kojem je stroj modeliran je sinkrono rotirajući dq sustav. Bitno je napomenuti da pri modeliranju stroja razlikujemo dva dq sustava: statorski i rotorski.

Naime, brzina rotacije dq sustava se uvijek promatra sa stajališta mirujućeg troosnog sustava. Tako statorski dq sustav rotira frekvencijom ulaznog prostornog vektora napona, odnosno sinkronom frekvencijom, jer je troosni sustav uistinu stacionaran. Rotacija rotorskog dq sustava promatra se sa stajališta troosnog rotorskog sustava koji se rotira brzinom osovine stroja, što znači da prostorni vektor u rotorskom dq sustavu rotira frekvencijom klizanja. Matrica transformacije statorskog dq sustava $\boldsymbol{C}_{sdq}$ predstavljena je izrazom (2-13), dok je matrica transformacije rotorskog dq sustava $\boldsymbol{C}_{rdq}$ zadana izrazom (2-14), gdje je ω_s sinkrona frekvencija, a ω_r frekvencija osovine rotora.

$$\begin{gathered}\boldsymbol{C}_{sdq} = \begin{bmatrix} cos(\rho_s) & cos(\rho_s - \frac{2\pi}{3}) & cos(\rho_s + \frac{2\pi}{3}) \\ -sin(\rho_s) & -sin(\rho_s - \frac{2\pi}{3}) & -sin(\rho_s + \frac{2\pi}{3}) \end{bmatrix} \\ \rho_s = \int_0^\infty \omega_s \, dt + \rho_{s0}\end{gathered} \tag{2-13}$$

$$\begin{gathered}\boldsymbol{C}_{rdq} = \begin{bmatrix} cos(\rho_r) & cos(\rho_r - \frac{2\pi}{3}) & cos(\rho_r + \frac{2\pi}{3}) \\ -sin(\rho_r) & -sin(\rho_r - \frac{2\pi}{3}) & -sin(\rho_r + \frac{2\pi}{3}) \end{bmatrix} \\ \rho_r = \int_0^\infty (\omega_s - \omega_r) \, dt + \rho_{r0}\end{gathered} \tag{2-14}$$

Polazište za izradu modela su statorska i rotorska jednadžba predstavljene izrazom (2-1). Transformiranjem varijabli troosnog sustava u varijable dvoosnog sustava pomoću matrica u izrazima (2-13) i (2-14), dobiva se izraz (2-15):

$$\begin{gathered}\boldsymbol{C}_{sdq}^{-1}\boldsymbol{v}_{s,dq} = R_s\boldsymbol{C}_{sdq}^{-1}\boldsymbol{i}_{s,dq} + \frac{\mathrm{d}\boldsymbol{C}_{sdq}^{-1}\boldsymbol{\psi}_{s,dq}}{\mathrm{d}t} \\ 0 = R_r\boldsymbol{C}_{rdq}^{-1}\boldsymbol{i}_{r,dq} + \frac{\mathrm{d}\boldsymbol{C}_{rdq}^{-1}\boldsymbol{\psi}_{r,dq}}{\mathrm{d}t}\end{gathered} \tag{2-15}$$

Množenjem statorske i rotorske jednadžbe s $\boldsymbol{C}_{sdq}$ i $\boldsymbol{C}_{rdq}$ dobiva se sljedeći izraz:

$$\begin{gathered}\boldsymbol{v}_{s,dq} = R_s\boldsymbol{i}_{s,dq} + \boldsymbol{C}_{sdq}\frac{\mathrm{d}\boldsymbol{C}_{sdq}^{-1}}{\mathrm{d}t}\boldsymbol{\psi}_{s,dq} + \frac{\mathrm{d}}{\mathrm{d}t}\boldsymbol{\psi}_{s,dq} \\ 0 = R_r\boldsymbol{i}_{r,dq} + \boldsymbol{C}_{rdq}\frac{\mathrm{d}\boldsymbol{C}_{rdq}^{-1}}{\mathrm{d}t}\boldsymbol{\psi}_{r,dq} + \frac{\mathrm{d}}{\mathrm{d}t}\boldsymbol{\psi}_{r,dq}\end{gathered} \tag{2-16}$$

Nakon deriviranja i množenja inversa matrica transformacije u izrazu (2-16), dobivaju se konačne statorske i rotorske jednadžbe stroja u dq sustavu prikazane izrazom (2-17).

$$
\begin{aligned}
\boldsymbol{v}_{s,dq} &= R_s \boldsymbol{i}_{s,dq} + \omega_s \boldsymbol{J}_{rot} \boldsymbol{\psi}_{s,dq} + \frac{\mathrm{d}}{\mathrm{d}t} \boldsymbol{\psi}_{s,dq} \\
0 &= R_r \boldsymbol{i}_{r,dq} + (\omega_s - \omega_r) \boldsymbol{J}_{rot} \boldsymbol{\psi}_{r,dq} + \frac{\mathrm{d}}{\mathrm{d}t} \boldsymbol{\psi}_{r,dq} \\
\boldsymbol{J}_{rot} &= \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}
\end{aligned}
\tag{2-17}
$$

Veza između tokova i struja, također se mora transformirati u dq sustav. Transformiranjem veličina u jednadžbi (2-2), dobiva se sljedeći izraz:

$$
\begin{bmatrix} \boldsymbol{\psi}_{s,dq} \\ \boldsymbol{\psi}_{r,dq} \end{bmatrix} = \begin{bmatrix} \boldsymbol{C}_{sdq} \boldsymbol{L}_{s,abc} \boldsymbol{C}_{sdq}^{-1} & \boldsymbol{C}_{sdq} \boldsymbol{L}_{m,abc} \boldsymbol{C}_{rdq}^{-1} \\ \boldsymbol{C}_{rdq} \boldsymbol{L}_{m,abc} \boldsymbol{C}_{sdq}^{-1} & \boldsymbol{C}_{rdq} \boldsymbol{L}_{r,abc} \boldsymbol{C}_{rdq}^{-1} \end{bmatrix} \begin{bmatrix} \boldsymbol{i}_{s,dq} \\ \boldsymbol{i}_{r,dq} \end{bmatrix}
\tag{2-18}
$$

Množenjem elemenata matrice induktiviteta, vrši se transformacija statorskih, rotorskih i međuinduktiviteta stroja, nakon čega oni više ne ovise o položaju rotora, već postaju konstantni, vremenski nepromjenjivi elementi. Ovo je glavni doprinos modeliranja stroja u dvoosnom ortonomiranom sustavu jer omogućuje jednostavno modeliranje i daljnju analizu. Izraz (2-19) prikazuje transformirane matrice induktiviteta stroja.

$$
\begin{aligned}
\boldsymbol{L}_s &= \boldsymbol{C}_{sdq} \boldsymbol{L}_{s,abc} \boldsymbol{C}_{sdq}^{-1} = \begin{bmatrix} L_s & 0 \\ 0 & L_s \end{bmatrix} \\
\boldsymbol{L}_r &= \boldsymbol{C}_{rdq} \boldsymbol{L}_{r,abc} \boldsymbol{C}_{rdq}^{-1} = \begin{bmatrix} L_r & 0 \\ 0 & L_r \end{bmatrix} \\
\boldsymbol{L}_m &= \boldsymbol{C}_{sdq} \boldsymbol{L}_{m,abc} \boldsymbol{C}_{rdq}^{-1} = \boldsymbol{C}_{rdq} \boldsymbol{L}_{m,abc} \boldsymbol{C}_{sdq}^{-1} = \begin{bmatrix} L_m & 0 \\ 0 & L_m \end{bmatrix}
\end{aligned}
\tag{2-19}
$$

Naposljetku, potrebno je transformirati veličine koje se pojavljuju u momentnoj jednadžbi stroja. Polazeći od izraza (2-5) te koristeći dq transformaciju, dobiva se sljedeći izraz:

$$
T_e = (\boldsymbol{C}_{sdq}^{-1} \boldsymbol{i}_{s,dq})^T \frac{\partial}{\partial \rho} \boldsymbol{L}_m \boldsymbol{C}_{rdq}^{-1} \boldsymbol{i}_{r,dq}
\tag{2-20}
$$

Zahvaljujući transformaciji, tokovi su neovisni o položaju i mogu se tretirati kao konstanta u prethodnom izrazu, a deriviranjem i množenjem matrice transformacije, dobiva se izraz za

elektromagnetski moment stroja u dq sustavu:

$$T_e = \frac{3}{2}\boldsymbol{i}_{s,dq}^T \boldsymbol{J}_{rot} \boldsymbol{L}_m \boldsymbol{i}_{r,dq} \tag{2-21}$$

Svođenjem izraza (2-21) na statorske veličine, dobiva se konačan izraz za elektromagnetski moment asinkronog stroja:

$$T_e = \frac{3}{2}\boldsymbol{i}_{s,dq}^T \boldsymbol{J}_{rot} \boldsymbol{\psi}_{s,dq} \tag{2-22}$$

Bitno je napomenuti da se do sada podrazumijevalo da je modelirani stroj dvopolni. Za model višepolnog stroja, potrebno je izmijeniti određene dijelove jednadžbi, pa tako izrazi (2-23) predstavljaju konačan model stroja u dq sustavu, prikladan za modeliranje strojeva s više od jednog para polova, gdje je p broj pari polova:

$$\begin{gathered}
\boldsymbol{v}_{s,dq} = R_s \boldsymbol{i}_{s,dq} + \omega_s \boldsymbol{J}_{rot} \boldsymbol{\psi}_{s,dq} + \frac{\mathrm{d}}{\mathrm{d}t}\boldsymbol{\psi}_{s,dq} \\
0 = R_r \boldsymbol{i}_{r,dq} + (\omega_s - p\omega_r)\boldsymbol{J}_{rot} \boldsymbol{\psi}_{r,dq} + \frac{\mathrm{d}}{\mathrm{d}t}\boldsymbol{\psi}_{r,dq} \\
\begin{bmatrix} \boldsymbol{\psi}_{s,dq} \\ \boldsymbol{\psi}_{r,dq} \end{bmatrix} = \begin{bmatrix} \boldsymbol{L}_s & \boldsymbol{L}_m \\ \boldsymbol{L}_m & \boldsymbol{L}_r \end{bmatrix} \begin{bmatrix} \boldsymbol{i}_{s,dq} \\ \boldsymbol{i}_{r,dq} \end{bmatrix} \\
T_e = \frac{3p}{2}\boldsymbol{i}_{s,dq}^T \boldsymbol{J}_{rot} \boldsymbol{\psi}_{s,dq} \\
J\frac{\mathrm{d}}{\mathrm{d}t}\omega_r = T_e - T_l
\end{gathered} \tag{2-23}$$

2.2. Matematički model dvorazinskog frekvencijskog pretvarača

Bez razvoja energetske elektronike, teško je zamisliti suvremenu industriju, pa čak i najjednostavniji elektromotorni pogon. Različiti elementi energetske elektronike omogućavaju veliki broj topologija frekvencijskih pretvarača koji se mogu koristiti za napajanje asinkronih strojeva. Ovdje se frekvencijski pretvarači dijele na pretvarače koji na izlazu mogu davati referentni napon ili referentnu struju. Realizacija frekvencijskih pretvarača može se ostvariti pomoću različitih elemenata kao što su tiristori (MCT, IGCT) te razne vrste tranzistora (IGBT, MOSFET). Prema topologiji, pretvarači se mogu dijeliti na ciklo-pretvarače, ma-

trične pretvarače te mosne pretvarače. Literatura kao što je [43], [44] i [40] detaljno opisuje ove topologije.

U ovoj disertaciji koristi se topologija mosnog frekvencijskog pretvarača. Ovisno o broj grana, odnosno mostova na izlazu pretvarača, moguće je postići modulirani napon izlaza s većim brojem naponskih razina. Što je veći broj naponskih razina, to je bolja rezolucija moduliranog napona i manji utjecaj viših harmonika. Frekvencijski pretvarač koji se koristi u ovoj disertaciji ima 3 grane na izlaznoj strani te se naziva dvorazinski trofazni frekvencijski pretvarač.

Slika 2.3 prikazuje nadomjesnu shemu spoja ovog pretvarača i asinkronog stroja s adekvatno označenim faznim naponima stroja.

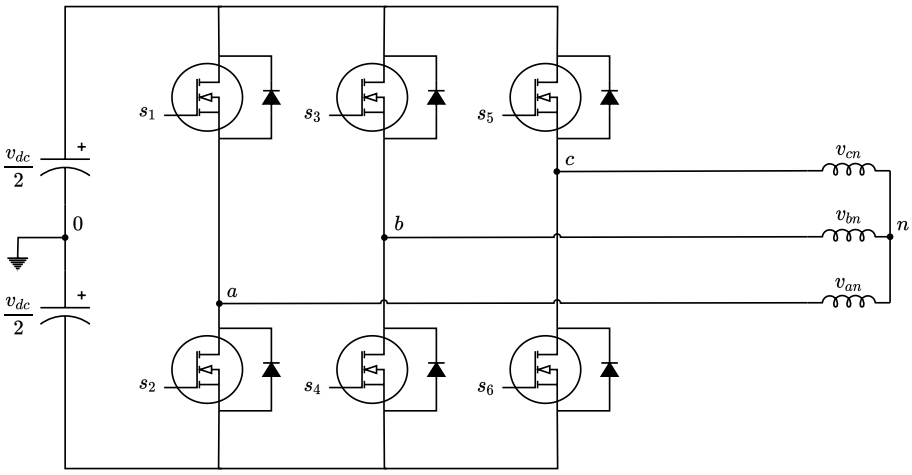

Slika 2.3: *Nadomjesna shema spoja frekvencijskog pretvarača i asinkronog stroja.*

Poštivajući Kirchofove zakone napona, izraz (2-24) prikazuje jednadžbe naponskih petlji koje se mogu opisati na slici 2.3.

$$\begin{aligned} v_{a0} - v_{an} - v_{n0} &= 0 \\ v_{b0} - v_{bn} - v_{n0} &= 0 \\ v_{c0} - v_{cn} - v_{n0} &= 0 \end{aligned} \tag{2-24}$$

Zbrajanjem ove tri jednadžbe te uzimajući u obzir da je asinkroni stroj simetrično trošilo u kojem je napon zvjezdišta jednak nuli, odnosno $v_{an} + v_{bn} + v_{cn} = 0$, dobiva se sljedeći izraz:

$$\begin{aligned} 3v_{n0} &= v_{a0} + v_{b0} + v_{c0} \\ v_{n0} &= \frac{1}{3}(v_{a0} + v_{b0} + v_{c0}) \end{aligned} \tag{2-25}$$

Supstitucijom napona v_{n0} iz izraza (2-25) u izraz (2-24), mogu se izvesti rješenja za fazne

napona ainskronog stroja upravljanog s frekvencijskim pretvaračem te matrično prikazati sljedećim izrazom:

$$\begin{bmatrix} v_{an} \\ v_{bn} \\ v_{cn} \end{bmatrix} = \begin{bmatrix} \frac{2}{3} & -\frac{1}{3} & -\frac{1}{3} \\ -\frac{1}{3} & \frac{2}{3} & -\frac{1}{3} \\ -\frac{1}{3} & -\frac{1}{3} & \frac{2}{3} \end{bmatrix} \begin{bmatrix} v_{a0} \\ v_{b0} \\ v_{c0} \end{bmatrix} \tag{2-26}$$

Iznosi napona v_{a0}, v_{b0} i v_{c0} ovise o iznosu napona istosmjernog međukruga te o trenutnom stanju uklapanja ventila $s_1 - s_6$. Izraz (2-27) prikazuje ovu ovisnost, dok izraz (2-28) prikazuje rezultantne fazne napone stroja u $\alpha\beta$ sustavu, što je pogodnije za daljnje modeliranje i analizu. Oznaka v_{dc} predstavlja napon istosmjernog međukruga, a vektor $\boldsymbol{s} = \begin{bmatrix} s_1 & s_3 & s_5 \end{bmatrix}^T$ predstavlja sklopno stanje frekvencijskog pretvarača.

$$\begin{bmatrix} v_{an} \\ v_{bn} \\ v_{cn} \end{bmatrix} = v_{dc} \begin{bmatrix} \frac{2}{3} & -\frac{1}{3} & -\frac{1}{3} \\ -\frac{1}{3} & \frac{2}{3} & -\frac{1}{3} \\ -\frac{1}{3} & -\frac{1}{3} & \frac{2}{3} \end{bmatrix} \begin{bmatrix} s_1 \\ s_3 \\ s_5 \end{bmatrix} \tag{2-27}$$

$$\begin{bmatrix} v_{\alpha} \\ v_{\beta} \end{bmatrix} = v_{dc} \begin{bmatrix} \frac{2}{3} & -\frac{1}{3} & -\frac{1}{3} \\ 0 & \frac{\sqrt{3}}{3} & -\frac{\sqrt{3}}{3} \end{bmatrix} \begin{bmatrix} s_1 \\ s_3 \\ s_5 \end{bmatrix} \tag{2-28}$$

Izraz (2-28) predstavlja model frekvencijskog pretvarača gdje se u ovisnosti o sklopnim stanjima vektora $\boldsymbol{s}$ dobiva 8 mogućih prostornih vektora napona asinkronog stroja. Ovi vektori, prikazani su plavom bojom na slici 2.4. U sljedećem potpoglavlju objašnjena je modulacijska tehnika koja generira impulse za uklapanje ventila frekvencijskog pretvarača te pomoću raspoloživih prostornih vektora realizira referentni prostorni vektor napona.

2.3. Modulacija prostornog vektora napona

Usporedno s razvojem frekvencijskih pretvarača, razvijale su se i tehnike modulacije kojima se referentna vrijednost napona realizira na izlaznim stezaljkama pretvarača. Danas postoji velik broj tehnika kao što su sinusna, histerezna, sigma-delta modulacija te razne varijacije čija se objašnjenja mogu pronaći u [43]. U ovoj disertaciji koristi se modulacija prostornog vektora napona koja će detaljno biti prezentirana. Modulacija prostornog vektora napona

ima određena svojstva koja ju čine superiornom nad ostalim modulacijskim tehnikama, a to su:

- konstantna frekvencija uklapanja,
- samo jedna grana pretvarača sudjeluje u uklapanju u svakom prijelaznom trenutku,
- ne generiraju se harmonici nižeg frekvencijskog spektra,
- metoda je formirana na način da prima upravljački napon u $\alpha\beta$ sustavu.

Slika 2.4 prikazuje prostorne vektore napona koje je moguće ostvariti s frekvencijskim pretvaračem modeliranim pomoću izraza (2-28). Na slici se mogu primijetiti 6 sekstanata u kojima se referentni prostorni vektor napona može nalaziti. Prostorni vektor $\vec{V}_{ref} = \begin{bmatrix} V_{\alpha,ref} & V_{\beta,ref} \end{bmatrix}^T$ je vektor kojeg je potrebno modulirati. Različitim vremenima uklapanja pojedinog ventila moguće je realizirati ovaj prostorni vektor ovisno o sekstantu u kojemu se on nalazi. U sljedećem tekstu je prikazan postupak za računanje vremena uklapanja ventila za prvi sekstant, a analogno tome moguće je izvesti vremena vođenja za svih šest sekstanata.

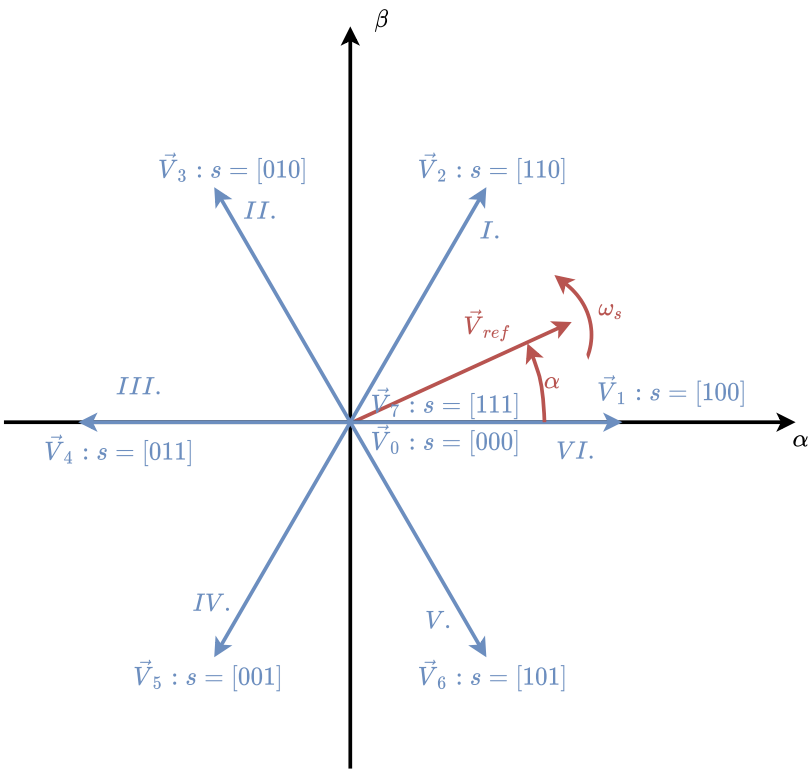

Slika 2.4: *Prostorni vektori realizirani pomoću frekvencijskog pretvarača.*

Kako bi se prostorni vektor realizirao, potrebno je u jednom vremenskom periodu T_s, realizirati vektore $\vec{V}_1'$, $\vec{V}_2'$ te $\vec{V}_0'$ kao što je prikazano na slici 2.5, a matematički zapis prikazan je izrazima (2-29).

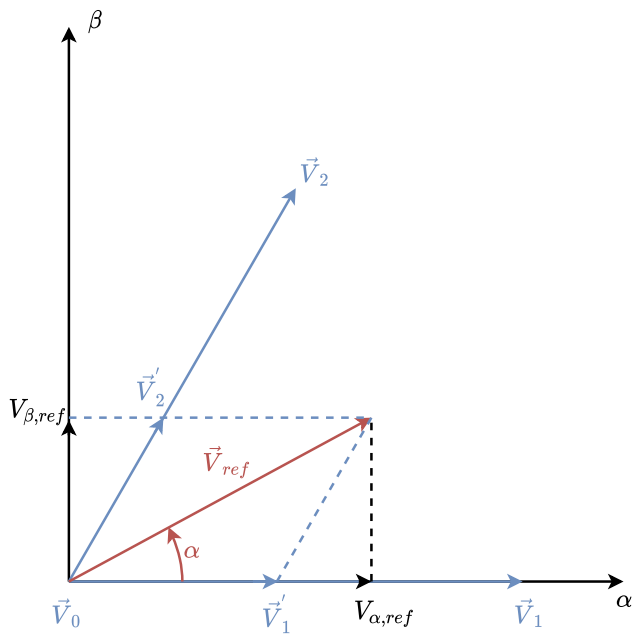

Slika 2.5: *Modulirani prostorni vektor u prvom sekstantu.*

$$\begin{aligned}
\vec{V}_{ref} &= \vec{V}_1' + \vec{V}_2' + \vec{V}_0' \\
\vec{V}_1' &= \frac{T_1}{T_s}\vec{V}_1 \\
\vec{V}_2' &= \frac{T_2}{T_s}\vec{V}_2 \\
\vec{V}_0' &= \frac{T_0}{T_s}\vec{V}_0 \\
T_s\vec{V}_{ref} &= T_1\vec{V}_1 + T_2\vec{V}_2 + T_0\vec{V}_0
\end{aligned} \tag{2-29}$$

Rastavljajući prostorne vektore na komponente, krajnja jednadžba u izrazu (2-29), može se zapisati kao što je prikazano u izrazu (2-30), gdje $V_{ref} = |\vec{V}_{ref}|$ predstavlja modul referentnog prostornog vektora.

$$\begin{aligned}
\begin{bmatrix} V_{\alpha,ref} \\ V_{\beta,ref} \end{bmatrix} = T_s V_{ref} \begin{bmatrix} cos(\alpha) \\ sin(\alpha) \end{bmatrix} = T_1 \frac{2}{3} v_{dc} \begin{bmatrix} 1 \\ 0 \end{bmatrix} + T_2 \frac{2}{3} v_{dc} \begin{bmatrix} cos(\frac{\pi}{3}) \\ sin(\frac{\pi}{3}) \end{bmatrix} \\
V_{ref} = |\vec{V}_{ref}|
\end{aligned} \tag{2-30}$$

Izraz $\frac{2}{3}v_{dc}$ u jednadžbi (2-30) se pojavljuje zato od 6 prostornih vektora sa slike 2.4

ima amplitudu od 2/3 iznosa napona istosmjernog međukruga. Raspisujući izraz (2-30) po komponentama dobivaju se sljedeće jednadžbe:

$$T_s V_{ref} cos(\alpha) = T_1 \frac{2}{3} v_{dc} + T_2 \frac{1}{3} v_{dc} \tag{2-31}$$

$$T_s V_{ref} sin(\alpha) = T_2 \frac{\sqrt{3}}{3} v_{dc} \tag{2-32}$$

Koristeći se supstitucijama i trigonometrijskim identitetima, iz jednadžbi (2-31) i (2-32), mogu se izraziti vremena vođenja T_1 i T_2:

$$T_1 = T_s \sqrt{3} \frac{V_{ref}}{v_{dc}} sin(\frac{\pi}{3} - \alpha) \tag{2-33}$$

$$T_2 = T_s \sqrt{3} \frac{V_{ref}}{v_{dc}} sin(\alpha) \tag{2-34}$$

Vrijeme T_0 se na posljetku računa na način: $T_0 = T_s - T_1 - T_2$.

Izraz (2-35) prikazuje jednadžbe za proračun vremena vođenja ovisno o sekstantu u kojem se modulirani prostorni vektor nalazi, gdje $n \in [1, 6]$ predstavlja trenutni mogući sekstant.

$$\begin{aligned} T_1 &= T_s \sqrt{3} \frac{V_{ref}}{v_{dc}} sin(\frac{n}{3}\pi - \alpha) \\ T_2 &= T_s \sqrt{3} \frac{V_{ref}}{v_{dc}} sin(\alpha - \frac{n-1}{3}\pi) \end{aligned} \tag{2-35}$$

Slika 2.6 prikazuje uzorak uklapanja ventila za realizaciju prostornog vektora u prvom sekstantu, koristeći metodu modulacije prostornog vektora. Može se primijetiti simetričan uzorak uklapanja te pojava gdje samo jedna grana pretvarača sudjeluje u promjeni između dva prostorna vektora.

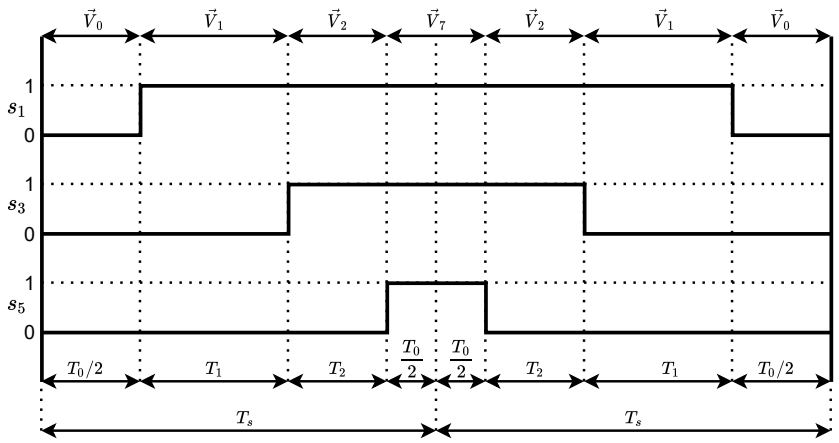

Slika 2.6: *Uzorak uklapanja ventila za realizaciju prostornog vektora u prvom sekstantu.*

3. RAZVOJ X-IL SUSTAVA ZA VALIDACIJU ALGORITAMA UPRAVLJANJA ASINKRONIM STROJEM

U ovom poglavlju prikazan je postupak izrade sustava za razvoj i validaciju upravljačkih algoritama asinkronog stroja. Ovaj sustav su izradili članovi projektnog tima "COPSEOC" pod vodstvom izv. prof. dr. sc. Marinka Barukčića u prvim fazama projekta. Nakon što je sustav izrađen, može se započeti s izvršavanjem simulacija pogona pomoću modela definiranih u prošlom poglavlju te implementacijom različitih algoritama upravljanja. Jedna od temeljnih metoda za regulaciju asinkronih strojeva je skalarna regulacija i upravo ova metoda je prva implementirana i testirana na ovom sustavu. Rezultati simulacije te stvarni odzivi elektromotornog pogona koji je reguliran ovom metodom su prikazani na kraju poglavlja. Razvijeni sustav za validaciju algoritama upravljanja asinkronim strojem sastoji se od nekoliko glavnih dijelova:

1. stvarno-vremenski simulator na kojem se izvršava upravljački algoritam, a po potrebi i simulacija cijelog elektromotornog pogona,

2. jedinica s analognim i digitalnim ulazima i izlazima (u daljnjem tekstu I/O jedinica) za prosljeđivanje signala između vanjskih uređaja i stvarno-vremenskog simulatora,

3. elementi energetske elektronike na koje se priključuje asinkroni stroj u svrhu upravljanja brzine vrtnje. Bitno je napomenuti da je ovaj sustav modularan te da je moguće stvoriti različite topologije energetskih pretvarača koji se ne moraju nužno koristiti u svrhe upravljanja strojevima,

4. energetsko sučelje za prosljeđivanje signala između I/O jedinice i elemenata energetske elektronike,

5. mjerni uređaji,

6. filteri.

Danas je na tržištu dostupno mnoštvo stvarno-vremenskih simulatora. Neki od njih su Speedgoat, dSpace, Plexim RT-Box, NI Compact Rio, TyphoonHIL, Imperix Boombox te Opal-RT. Više o ovim sustavima i programskim paketima pomoću kojih se s njima komunicira može se naći u [21]. Za izradu ove doktorske disertacije korišten je Opal-RT, a u daljnjem tekstu navedeni su svi detalji simulatora i konačnog sustava za prototipiranje algoritama upravljanja.

3.1. Stvarno-vremenski simulator

Kao što je ranije rečeno, u svrhu izrade ove disertacije korišten je Opal-RT stvarno-vremenski simulator, pod nazivom OP-5031, prikazan na slici 3.1.

(a) *Prednja strana Opal-RT stvarno-vremenskog simulatora.*

(b) *Stražnja strana Opal-RT stvarno-vremenskog simulatora.*

Slika 3.1: *Prednja i stražnja strana Opal-RT stvarno-vremenskog simulatora.*

Prema podjeli u [18], ovakav simulator pripada u kategoriju tipa B, jer se algoritmi izvršavaju na procesoru široke primjene. Procesor korišten za izvršavanje simulacija na ovom stvarno-vremenskom simulatoru je Intel Xeon E5, koji se uistinu može koristiti i za druge svrhe kao što je procesiranje zahtjeva na serverima ili za ubrzanje renderiranja videa visoke rezolucije.

U svrhe stvarno-vremenskih simulacija moguće je aktivirati do 32 jezgre za izvršavanje proračuna. Minimalni vremenski korak pri izvršavanju stvarno-vremenskih simulacija elektroenergetskih sustava u fazorskoj domeni je 1 ms. Za potrebe stvarno-vremenskih proračuna odziva dinamičkih sustava kao što su elektromotorni pogoni, najmanji mogući vremenski korak je 10 µs. Jedna jezgra simulatora rezervirana je za izvršavanje naredbi Red Hat Linux operativnog sustava koji održava servise potrebne za komunikaciju simulatora sa osobnim računalom.

Komunikacija sa osobnim računalom izvodi se pomoću *ethernet* veze i programskog paketa RT-Lab. *Ethernet* priključak označen je brojem 1 na slici 3.1b. Za provođenje simulacije u kojoj nije potrebna razmjena signala između simulatora i vanjskih uređaja (MIL), I/O jedinicu nije potrebno priključiti na simulator, međutim ukoliko to nije slučaj, I/O jedinica se spaja sa simulatorom pomoću posebnog priključka označenim brojem 2 na slici 3.1b. Osnovne operacije za provođenje simulacije pomoću Opal-RT stvarno-vremenskog simulatora su sljedeće:

- izrada modela sustava u Matlab/Simulink programskom paketu na osobnom računalu,
- generiranje, prevođenje i prebacivanje C/C++ programskog koda na stvarno-vremenski simulator. Za ovaj korak se u potpunosti brine programski paket RT-Lab,
- izvršavanje modela na stvarno-vremenskom simulatoru.

Odzivi simuliranog sustava šalju se putem *ethernet* veze na osobno računalo, a za vizualizaciju istih mogu se koristiti gotovi mehanizmi prikaza grafova u Simulinku ili LabView programskom paketu. RT-Lab osim ovih mogućnosti omogućava i pristup te uređivanje varijabli modela, snimanje odziva te generiranje datoteka sa snimljenim vrijednostima signala te razne druge mogućnosti koje se mogu pronaći u dokumentaciji sustava.

Sve ove mogućnosti dostupne su i izvan RT-Laba putem različitih API-a (*Application Programming Interface*) koje Opal-RT podržava. API je dostupan za Python, Java, C i LabView programske jezike, što omogućava automatizaciju kod različitih vrsta testiranja te ono što je za ovu doktorsku disertaciju najbitnije, mogućnost kosimulacije između simulatora i ostalih uređaja i programskih paketa..

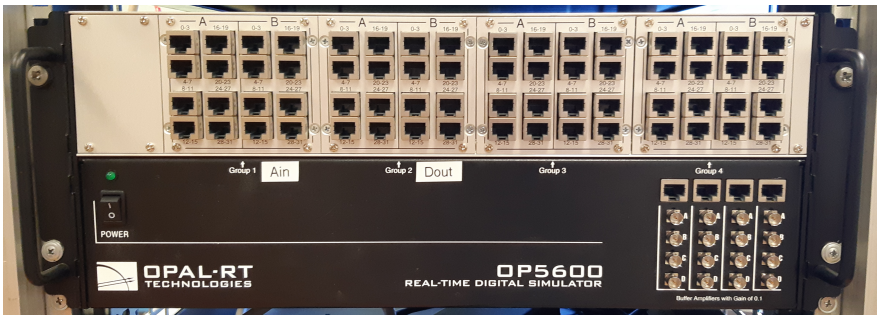

(a) *Prednja strana I/O jedinice.*

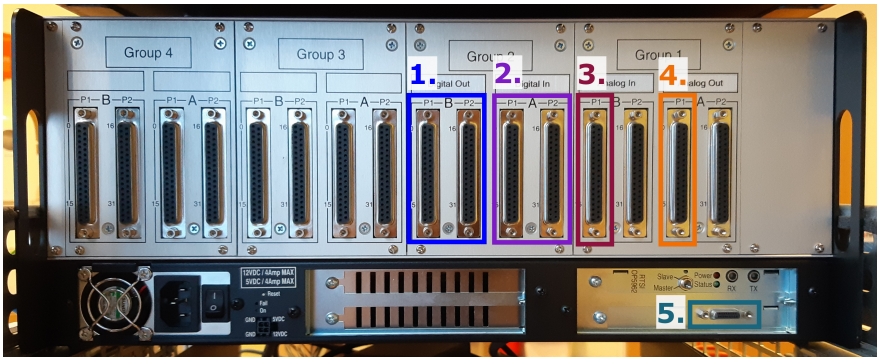

(b) *Stražnja strana I/O jedinice.*

Slika 3.2: *Prednja i stražnja strana I/O jedinice.*

3.2. Jedinica s analognim i digitalnim ulazima i izlazima (I/O jedinica)

Slika 3.2 prikazuje prednju i stražnju stranu I/O jedinice stvarno-vremenskog simulatora pod nazivom OP5600. Ovu jedinicu je također izradila tvrtka Opal. Slika 3.2b prikazuje stražnju stranu I/O jedinice, na kojoj su pojedini ulazni i izlazni signali dostupni putem DB-37 priključaka. Brojevima su označeni sljedeći elementi i to:

1. 32 digitalna izlaza: moguća naponska razina izlaznih signala ima raspon od 5-30 V te brzinu uzorkovanja od 40 MS/s,

2. 32 digitalna ulaza: moguća naponska razina ulaznih signala ima raspon od 5-100 V te brzinu uzorkovanja od 10 MS/s,

3. 16 analognih ulaza: moguća naponska razina ulaznih signala ima raspon od ±24 V, rezoluciju pretvorbe od 16 bita te brzinu uzorkovanja od 500 kS/s,

4. 16 analognih izlaza: moguća naponska razina izlaznih signala ima raspon od ±16 V, rezoluciju pretvorbe od 16 bita te brzinu uzorkovanja od 1 MS/s,

5. priključak za komunikaciju sa stvarno-vremenskim simulatorom.

Svi analogni i digitalni signali se prosljeđuju te su dostupni i na prednjoj strani I/O jedinice prikazanoj na slici 3.2a, putem RJ45 odnosno BNC priključaka. Na ovaj način omogućeno je promatranje signala putem osciloskopa ili nekih drugih uređaja, ukoliko stražnjoj strani I/O jedinice nije moguće pristupiti.

Svi ulazi i izlazi realizirani su putem FPGA čipova unutar I/O jedinice. Osim za svrhe prosljeđivanja ulaznih signala simulatoru i slanja izlaznih signala iz simulatora, ovi FPGA čipovi mogu se koristiti za izvršavanje stvarno-vremenskih simulacija komponenata energetske elektronike, gdje zahtjevi za vremenskim koracima simulacije premašuju mogućnosti procesora.

3.3. Energetski dio sustava

Sustav energetske elektronike koji se koristi za validaciju algoritama upravljanja asinkronim strojem u ovoj doktorskoj disertaciji, proizvela je tvrtka Imperix. Ovaj sustav je modularne izvedbe, a na jednom modulu nalazi jedna grana klasičnog frekvencijskog pretvarača. Ovime se omogućava realizacija različitih topologija frekvencijskih pretvarača koji se mogu koristiti u različite svrhe, a ne samo za upravljanje asinkronim strojevima. Principijelna shema modula se nalazi na slici 3.3, dok slika 3.4 prikazuje sami energetski modul.

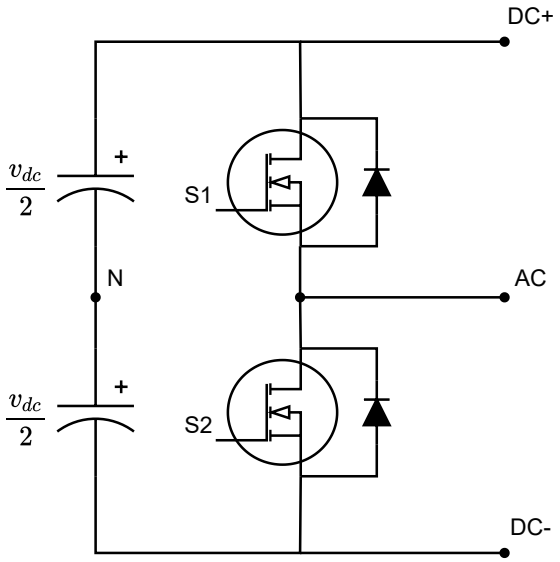

Slika 3.3: *Principijelna shema energetskog modula.*

Glavni dio modula je takozvani polumost, izveden pomoću dva Silicij-Karbid MOSFET

tranzistora. Ovi tranzistori imaju mogućnost uklapanja frekvencijom do 200 kHz, a nazivna vrijednost struje koju mogu provesti je 24 A te 36 A kratkotrajno.

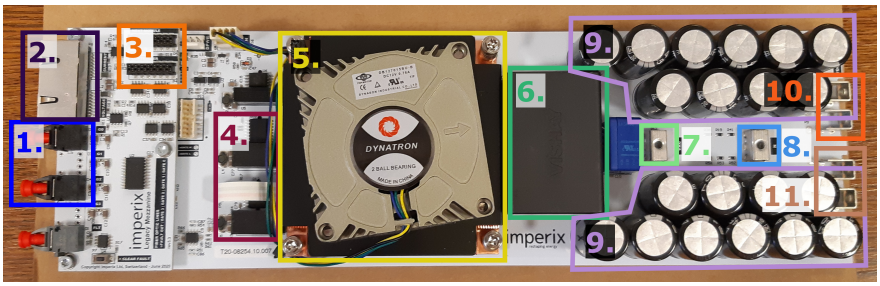

(a) *Gornja strana energetskog modula.*

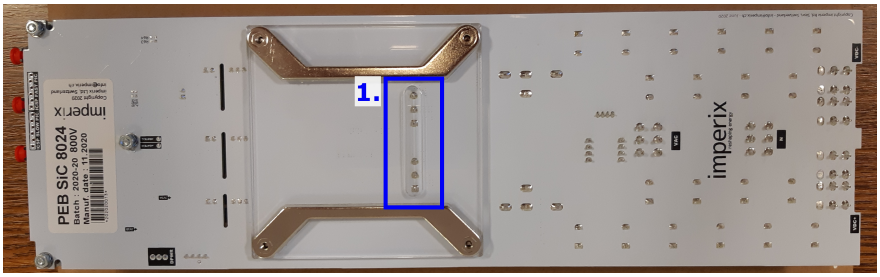

(b) *Donja strana energetskog modula.*

Slika 3.4: *Gornja i donja strana Imperix energetskog modula.*

Slika 3.4a prikazuje gornju stranu energetskog modula gdje su bitni dijelovi označeni brojevima:

1. Ulaz optičkog signala za upravljanje zasunom MOSFET tranzistora,
2. izlazni priključci za slanje mjerenih signala u energetsko sučelje (moduli imaju mogućnost mjerenja struje MOSFET-a i napona na ugrađenim kondenzatorima),
3. priključci za komunikaciju s drugim modulima,
4. mikrokontroleri za regulaciju napona zasuna MOSFET tranzistora,
5. hladnjak i ventilator MOSFET tranzistora,
6. CPLD za implementaciju različitih zaštitnih i logičkih funkcija modula,
7. priključak za izlaz/ulaz grane polumosta (točka "AC" na shemi 3.3),
8. priključak za neutralnu točku polumosta (točka "N" na shemi 3.3),
9. kondenzatori koji u određenim topologijama služe kao istosmjerni međukrug frekvencijskog pretvarača. Ukupan kapacitet kondenzatora jednog modula je 260 µF,

10. priključak pozitivne strane kondenzatora,

11. priključak negativne strane kondenzatora.

Slika 3.4b prikazuje donju stranu energetskog modula gdje su brojem 1 označeni kontakti MOSFET tranzistora. Slika 3.5 prikazuje 3 energetska modula smještena u kućište te spojena na način da čine kompletan izmjenjivački dio dvorazinskog mosnog frekvencijskog pretvarača. U jedno kućište stane ukupno 6 modula te je moguće realizirati i ispravljački dio pretvarača, no ispravljački dio nije potreban jer se sustav ne napaja iz energetske mreže, već iz laboratorijskog izvora istosmjernog napona, prikazanog na slici 3.6. Ovaj laboratorijski izvor proizvela je tvrtka ET System, a izvor na izlazu može davati napon od 0-1000 V te struju do 10 A.

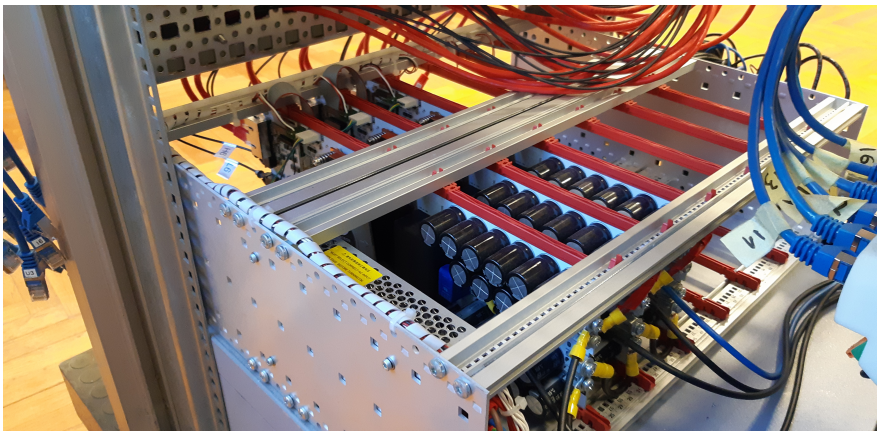

Slika 3.5: *Izvedba pretvarača pomoću energetskih modula.*

Slika 3.6: *Laboratorijski izvor za napajanje energetskog pretvarača.*

Predložena izvedba je pogodna za istraživačke svrhe jer ovakvi laboratorijski izvori imaju ugrađene limitatore struje koji su korisni u slučaju kratkih spojeva ili preopterećenja sustava. Ukoliko je potrebno sustav napajati iz energetske mreže ili transformatora, tada je potrebno

sastaviti i ispravljački dio pretvarača te izraditi sklop za punjenje istosmjernog međukruga. Principijelna shema ovog sklopa prikazana je na slici 3.7, a realizacija sklopa prikazana je na slici 3.8. Sklop se sastoji od otpornika kroz koje inicijalno teče struja punjenja te paralelno spojenog sklopnika koji se zatvara nakon što se istosmjerni međukrug napuni te time premošćuje otpornike u strujnom krugu.

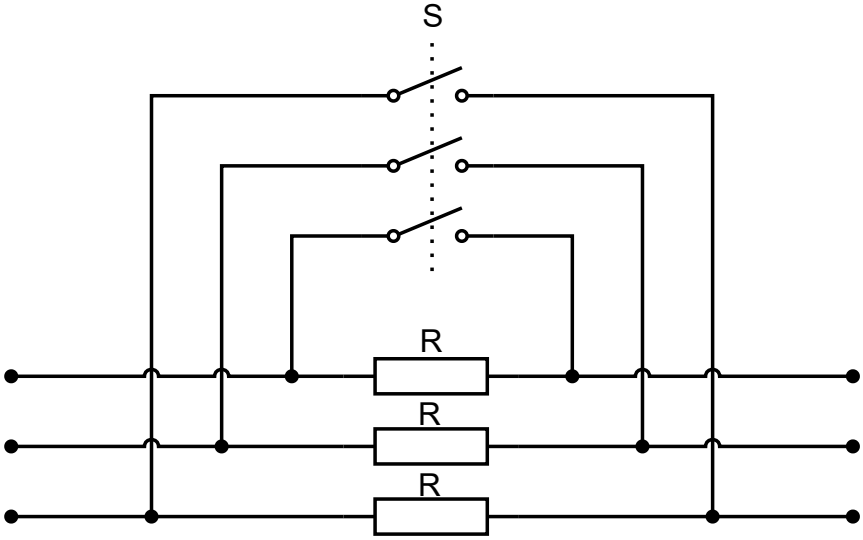

Slika 3.7: *Principijelna shema sklopa za punjenje istosmjernog međukruga.*

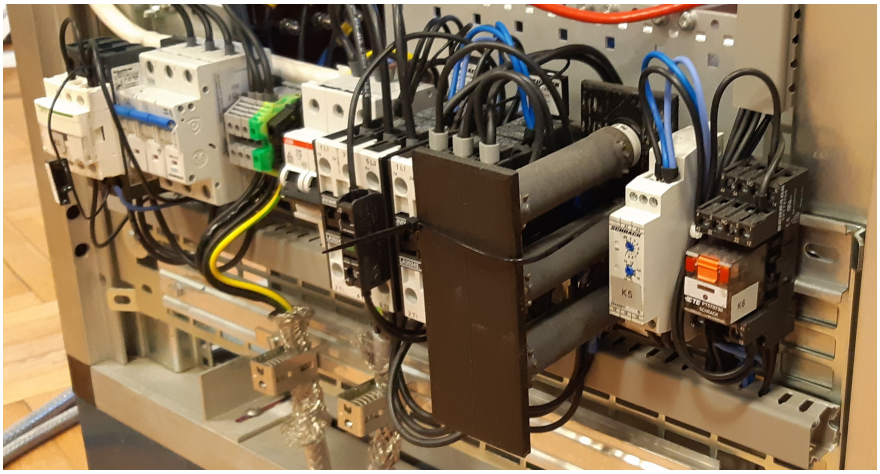

Slika 3.8: *Realizacija sklopa za punjenje istosmjernog međukruga.*

3.3.1. Filteri

Bitan dio energetskog dijela sustava su filteri koji se mogu priključiti u strujni krug za ispitivanje upravljačkih algoritama asinkronog stroja. Ovdje se radi o dvije vrste filtera: filteri elektromagnetskih smetnji te filtera za ublažavanje kratkoročnih prijelaznih pojava struja ili napona uzrokovanih brzim uklapanjem MOSFET tranzistora. Slika 3.9 prikazuje

prednju i stražnju stranu jedinice u kojoj se nalaze ovi filteri, a na slici 3.9b pravokutnicima su označene stezaljke pojedinih filtera i to:

- 1-1. i 2-1. ulazne i izlazne stezaljke filtera za ublažavanje kratkoročnih prijelaznih pojava (2 filtera),
- 1-2. i 2-2. ulazne i izlazne stezaljke filtera elektromagnetskih smetnji (2 filtera).

Principijelna shema jedinice s filterima prikazana je na slici 3.10.

(a) *Prednja strana jedinice s filterima.*

(b) *Stražnja strana jedinice s filterima.*

Slika 3.9: *Prednja i stražnja strana Imperix jedinice s filterima.*

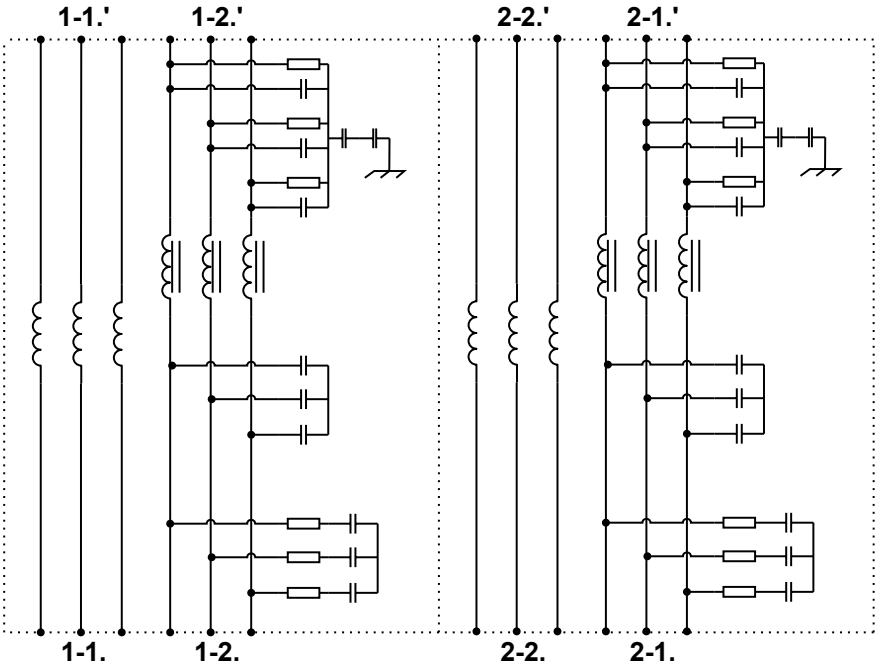

Slika 3.10: *Principijelna shema jedinice s filterima.*

3.4. Energetsko sučelje

S obzirom da I/O jedinica stvarno-vremenskog simulatora na svojim digitalnim izlazima generira naponske impulse, a energetski moduli s MOSFET tranzistorima zahtjevaju optički upravljački signal, potrebno je sučelje koje će naponske impulse pretvarati u optičke signale. Ovo sučelje se naziva energetsko sučelje. Razvila ga je tvrtka Imperix i prikazano je na slici 3.11.

(a) *Prednja strana energetskog sučelja.*

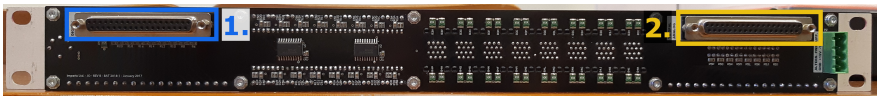

(b) *Stražnja strana energetskog sučelja.*

Slika 3.11: *Prednja i stražnja strana Imperix energetskog sučelja.*

Na slici 3.11a prikazana je prednja strana energetskog sučelja na kojoj su bitni dijelovi označeni brojevima i to:

1. kontakti analognih ulaza sučelja koji signale prosljeđuje u I/O kutiju. Ovo su testni kontakti i služe za pristup sondama osciloskopa ili drugih mjernih uređaja,

2. RJ45 ulazni priključci za analogne signale mjernih sondi, služe za pristup sondama osciloskopa ili drugih mjernih uređaja,

3. optički izlazi čiji se signali optičkim kablom prenose na energetske module,

4. kontakti digitalnih ulaza sučelja koji prima signale iz I/O jedinice. Ovo su također testni kontakti.

Na slici 3.11b prikazana je stražnja strana energetskog sučelja na kojoj su bitni dijelovi označeni brojevima i to:

1. DB-37 priključak kojim se digitalni izlazi s I/O jedinice prosljeđuju na energetsko sučelje,

2. DB-37 priključak kojim se analogni ulazi s energetskog sučelja prosljeđuju na I/O kutiju.

3.5. Mjerna oprema

Za mjerenje struja i napona sustava, koriste se diferencijalne mjerne sonde koje je razvila tvrtka Imperix. Strujna sonda ima rezoluciju od 99 mV/A i može mjeriti struju od ±50 A. Naponska sonda ima rezoluciju od 2,46 mV/V i može mjeriti napon od ±800 V. Mjerenja sa sondi se prenose na energetsko sučelje pomoću *ethernet* kabla. Sonde su ugrađene u postolje sa svim ostalim elementima sustava. Slika 3.12 prikazuje smještaj strujnih sondi, a slika 3.13 prikazuje smještaj naponskih sondi u postolju.

Slika 3.12: *Smještaj strujnih sondi u postolju.*

Slika 3.13: *Smještaj naponskih sondi u postolju.*

Mjerenje struje je dostupno i s energetskog modula prikazanog na slici 3.4. Osim mjerenja struje, ovaj modul omogućava i mjerenje napona na kondenzatorima, koji kod topologije frekvencijskog pretvarača predstavljaju istosmjerni međukrug.

3.6. Kompletan sustav za validaciju algoritama upravljanja asinkronim strojem

Sve prethodno navedene komponente ugrađene su u postolje i kao cjelina predstavljaju kompletan sustav za razvoj i validaciju algoritama upravljanja asinkronim strojem. Bitno je naglasiti da ovaj laboratorijski postav nije komercijalan, već je ručno izrađen od strane članova projektnog tima "COPESOC". Slika 3.14 prikazuje prednju i stražnju stranu sustava, gdje su bitni dijelovi i uređaji označeni brojevima:

1. Opal-RT stvarno-vremenski simulator,
2. Opal I/O jedinica,
3. energetsko sučelje,
4. komandna ploča,
5. kućište s energetskim modulima,
6. jedinica s filterima,
7. naponske mjerne sonde (strujne mjerne sonde se nalaze iza ploče s priključcima pod brojem 8 i nisu vidljive na slici),

8. ploča s priključcima za energetske module i mjerne sonde.

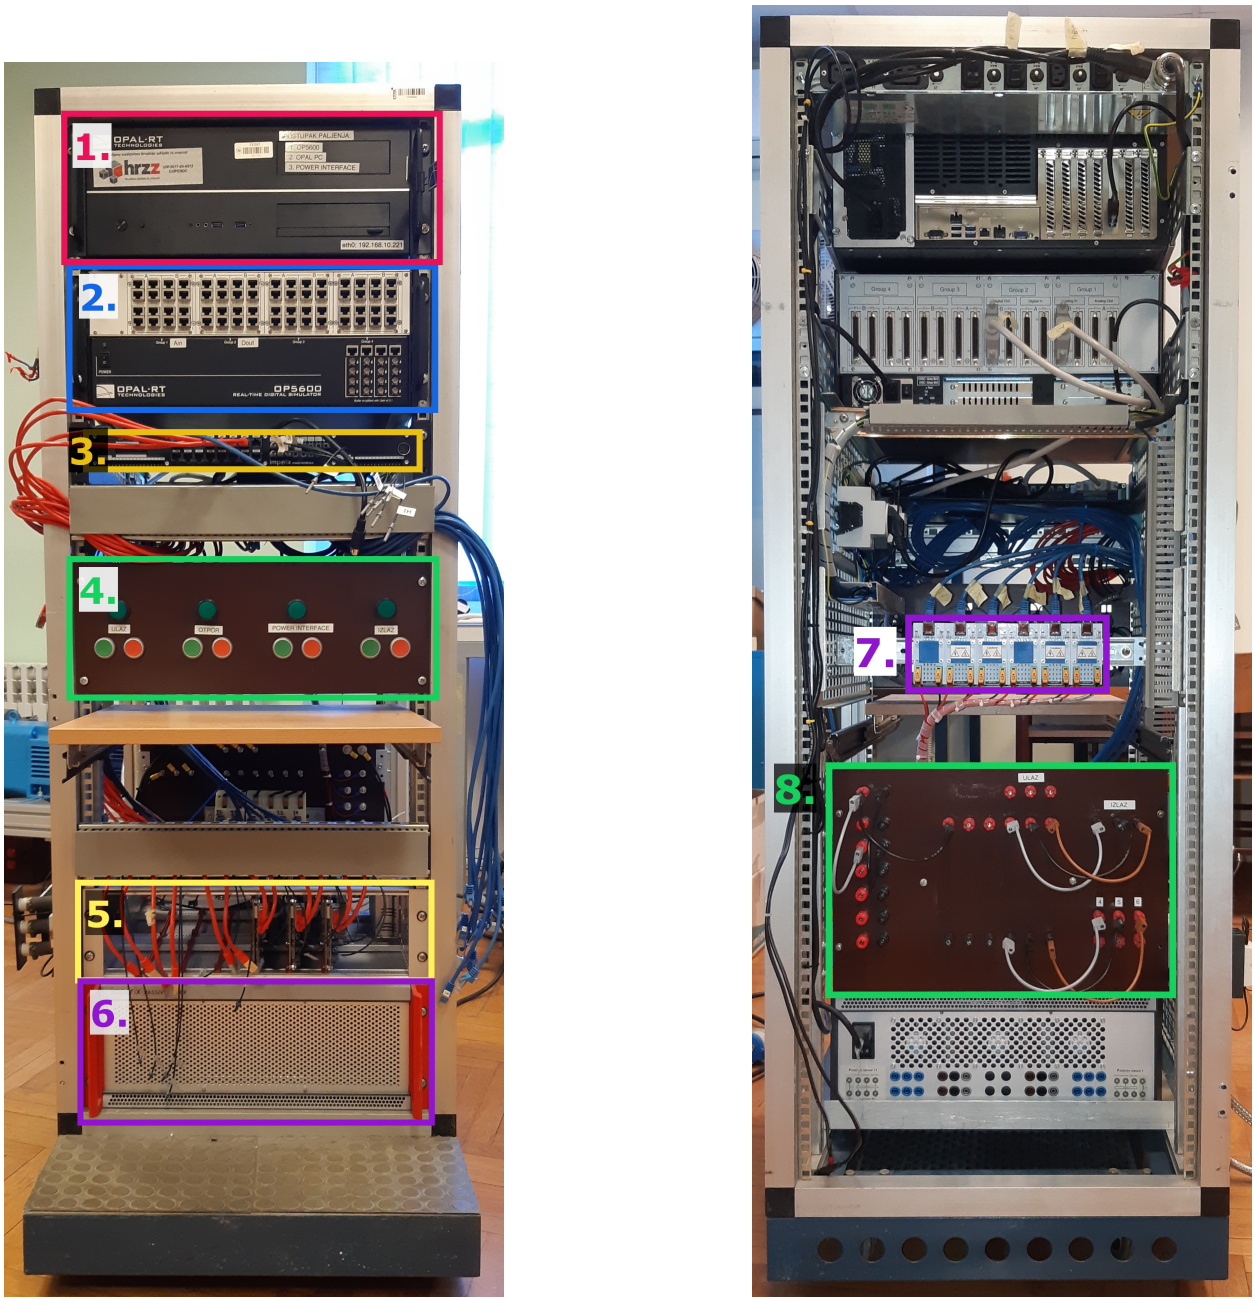

(a) *Prednja strana sustava.* **(b)** *Stražnja strana sustava.*

Slika 3.14: *Prednja i stražnja strana sustava za razvoj i validaciju upravljačkih algoritama asinkronog stroja.*

Uvećani prikaz komandne ploče predstavlja slika 3.15. Pomoću tipkala, moguće je:

- upravljati ulaznim sklopnikom kojim se dovodi napajanje ispravljačkom dijelu frekvencijskog pretvarača (ova funkcionalnost je potrebna ukoliko se energetski dio sustava napaja iz energetske mreže),

- upravljati izlaznim sklopnikom kojim se dovodi napajanje asinkronom stroju iz energetskog pretvarača,
- upravljati sklopnikom preko kojeg se vrši napajanje energetskog sučelja,
- upravljati sklopnikom koji premoštava otpornike za ograničavanje struje punjenja istosmjernog međukruga te ih na taj način po potrebi ubacivati i izbacivati iz strujnog kruga.

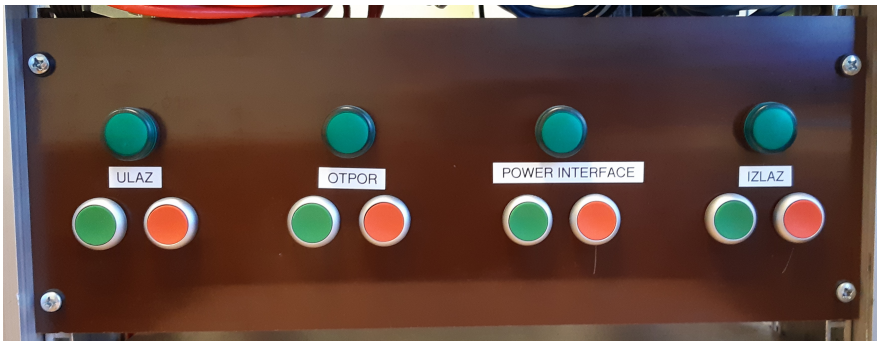

Slika 3.15: *Komandna ploča.*

Slika 3.16 predstavlja uvećan prikaz ploče s priključcima za energetske module i mjerne sonde. Osim ovih priključaka, izvedeni su i priključci za napajanje istosmjernog međukruga te priključci ulaznog i izlaznog sklopnika.

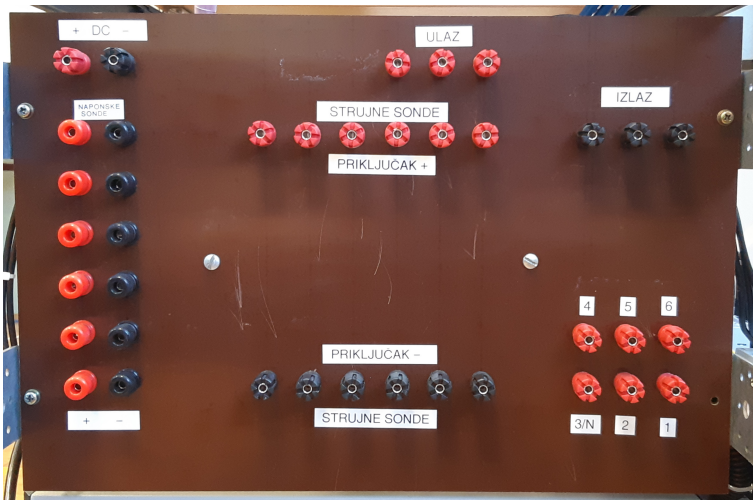

Slika 3.16: *Ploča s priključcima.*

Sklopnici kojima se upravlja pomoću tipkala sa slike 3.15 nalaze se na lijevoj strani postolja. Slika 3.17 pobliže prikazuje sklop za upravljanje, gdje su osim sklopnika, vidljivi i releji te redne stezaljke na koje se priključuje asinkroni stroj.

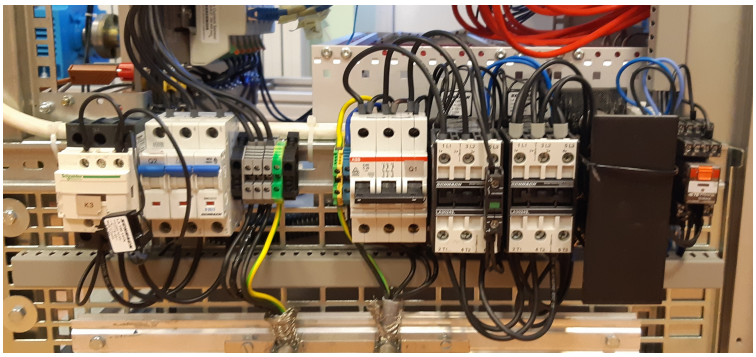

Slika 3.17: *Sklop za upravljanje različitim dijelovima sustava.*

3.6.1. Postolje s električnim strojevima

Slika 3.18 prikazuje postolje s reguliranim asinkronim strojem na desnoj strani i istosmjernim strojem na lijevoj strani. Postolje je ručno izrađeno od aluminijskih profila, a u izradi je osim članova projektnog tima "COPESOC" sudjelovao i jedan od laboranata zavoda za elektrostrojarstvo, Goran Kurtović, kojemu se posebno zahvaljujem.

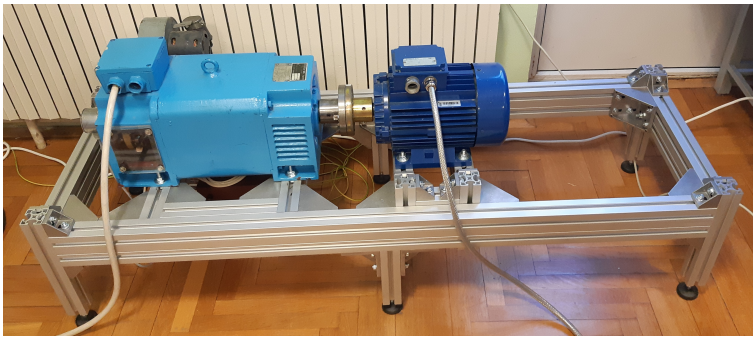

Slika 3.18: *Postolje sa asinkronim strojem i istosmjernim motorom.*

Regulacijom momenta istosmjernog stroja realizira se opterećenje osovine asinkronog stroja, a regulacija se izvršava pomoću komercijalnog pretvarača Siemens Simoreg, prikazanim na slici 3.19. Podatci strojeva su prikazani u tablici 3.1.

Tablica 3.1: *Podatci asinkronog i istosmjernog stroja*

Asinkroni stroj		Istosmjerni stroj	
Proizvođač	Končar	Proizvođač	Siemens
Napon Δ/⅄	220/380 V	Armatura	
Struja Δ/⅄	9,2/5,3 A	Napon	460 V
Snaga	2200 W	Struja	13 A
Brzina vrtnje	1400 min^{-1}	Uzbuda	
Frekvencija	50 Hz	Napon	180 V
Faktor snage	0,8	Struja	1,2 A
		Snaga	4950 W
		Brzina vrtnje	2250 min^{-1}

Slika 3.19: *Pretvarač Siemens Simoreg za upravljanje momentom istosmjernog motora.*

3.7. Skalarna regulacija asinkronog stroja

Nakon što je kosimulacijski razvojni sustav izrađen, može se početi s implementacijom i analizom različitih upravljačkih algoritama asinkronog stroja. Prvi implementirani algoritam je skalarna regulacija asinkronog stroja koja će ukratko biti prezentirana u ovom potpoglavlju.

Slika 3.20 prikazuje momentne karakteristike asinkronog stroja T_{e1} i T_{e2} pri određenoj vrijednosti napona V i sinkronih frekvencija f te momentnu karakteristiku proizvoljnog konstantnog tereta T_l. Vidljivo je da brzina vrtnje asinkronog n_1 stroja ovisi o točki sjecišta ovih karakteristika.

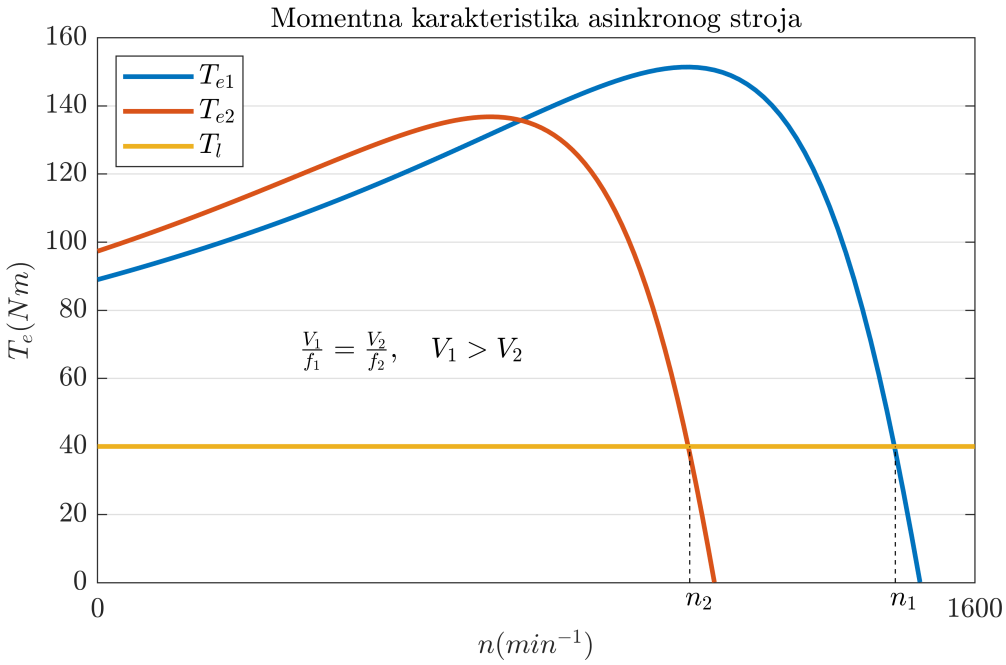

Slika 3.20: *Momentna karakteristika asinkronog stroja.*

Promjenom sinkrone frekvencije, moguće je modificirati momentnu karakteristiku stroja, a posljedično i brzinu rotora stroja pri određenom teretu. Ukoliko se izvršava samo promjena frekvencije uz konstantni napon, doći će do zasićenja toka u zračnom rasporu stroja, što uzrokuje visoke struje i deformira okretno magnetsko polje, kao što je objašnjeno u [43]. Kako bi se ovaj efekt izbjegao, osim frekvencije, mijenja se i efektivna vrijednost napona na kojeg se stroj priključuje. Momentna karakteristika asinkronog stroja T_{e1} je nazivna karakteristika, a karakteristika T_{e2}, dobivena je uz smanjeni napon V_2 i smanjenu sinkronu frekvenciju f_2 te je očito da se kao posljedica ove promjene smanjila i brzina vrtnje stroja. Izvod i izraz za proračun momentne karakteristike asinkronog stroja može se pronaći u [45].

Najstarija i najjednostavnija metoda upravljanja koja se koristi u ove svrhe je upravo

V/f regulacija, odnosno skalarna regulacija brzine vrtnje. Ovom metodom se omjer napona i frekvencije izvora drži konstantnim do nazivne vrijednosti brzine vrtnje, a iznad nazivne vrijednosti, samo se sinkrona frekvencija povećava, dok efektivna vrijednost napona ostaje konstantna. Metoda je detaljno je objašnjena u knjigama kao što su [43] i [41]. Frekvencijski pretvarač koji služi za realizaciju izvora promjenjive frekvencije i napona prikazan je na slici 3.5.

3.7.1. MIL simulacija skalarne regulacije na kosimulacijskom razvojnom sustavu

Skalarna regulacija implementirana je u programskom paketu Matlab/Simulink. Slika 3.21 prikazuje implementaciju algoritma upravljanja, modulatora, frekvencijskog pretvarača i asinkronog stroja. Matematički modeli ovih elemenata definirani su u prethodnom poglavlju. Osim navedenih elemenata, u modelu je prisutan i generator referentnih vrijednosti brzine vrtnje i momenta tereta.

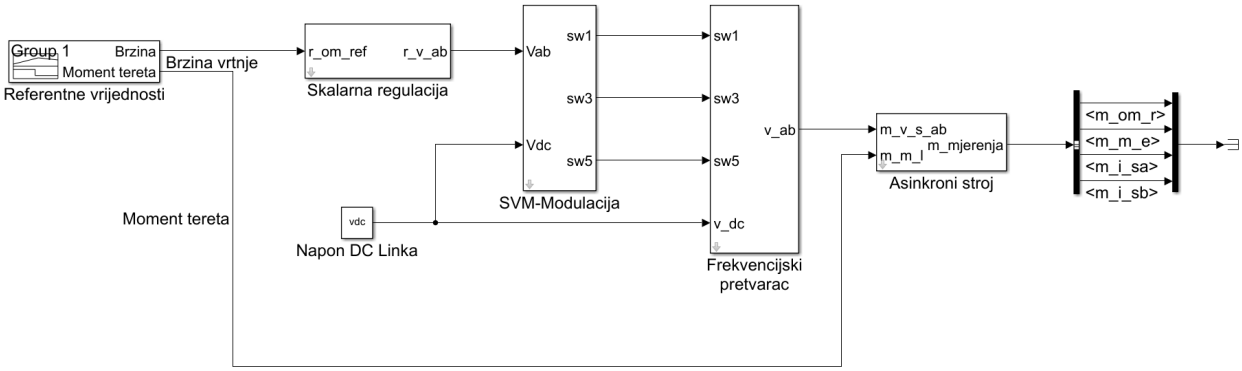

Slika 3.21: *Implementacija skalarno upravljanog asinkronog stroja u Simulinku.*

Kako bi se dinamički model asinkronog stroja mogao realizirati, osim podataka s natpisne pločice, potrebni su i podatci parametara modela stroja prikazanih u tablici 3.2. Ovi parametri mogu se dobiti postupkom identifikacije parametara, međutim s obzirom da se u ovoj disertaciji takav algoritam nije implementirao, za identifikaciju parametara korišten je komercijalni frekvencijski pretvarač Siemens G120. Osim parametara modela stroja, navedeni su i parametri vezani za model frekvencijskog pretvarača te izvršavanje simulacije.

Tablica 3.2: *Parametri MIL simulacije elektromotornog pogona*

Parametar		Vrijednost
Otpor statora	R_s (Ω)	1.515
Otpor rotora	R_r (Ω)	0.815
Induktivitet statora	L_s (H)	0.3693
Induktivitet rotora	L_r (H)	0.3703
Međuinduktivitet	L_m (H)	0.3508
Broj pari polova	p	2
Moment inercije	J (kgm^2)	0.056
Napon istosmjernog međukruga	v_{DC} (V)	535
Frekvencija uklapanja ventila pretvarača	f_{sw} (kHz)	10
Vremenski korak	T_s (µs)	100
Solver		Runge-Kutta

Ovako parametriran Simulink model, korišten je za MIL simulaciju zaleta asinkronog stroja u praznom hodu na Opal-RT stvarno-vremenskom simulatoru. Pogon je pokrenut na način da amplituda i frekvencija napona na kojeg je stroj priključen linearno raste od nule do nazivnih vrijednosti u periodu od 9 sekundi, kao što je prikazano na slici 3.22.

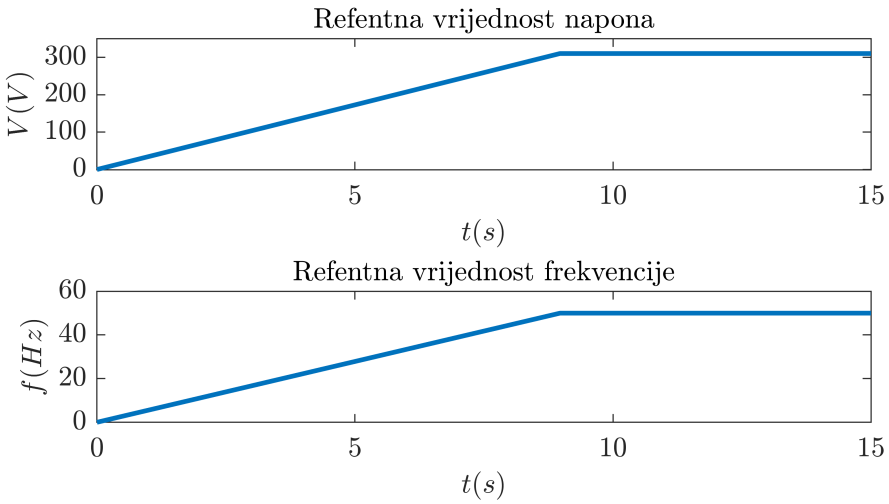

Slika 3.22: *Referentne vrijednosti sinkrone frekvencije i napona asinkronog stroja.*

Slika 3.23 prikazuje odziv brzine vrtnje ovako pokrenutog stroja. Može se zaključiti da

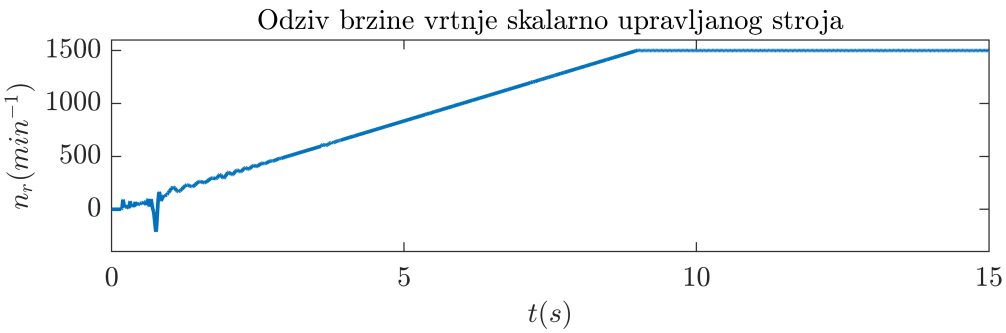

Slika 3.23: *Odziv brzine vrtnje simuliranog pogona.*

brzina rotora stroja prati referentnu vrijednost sinkrone frekvencije te da MIL simulacija može služiti kao vjerni prikaz mehaničkih veličina pogona. Opterećenje jezgre simulatora za vrijeme MIL simulacije iznosilo je 13,42 %.

3.7.2. RCP implementacija skalarne regulacije na kosimulacijskom razvojnom sustavu i usporedba s MIL simulacijom

Za implementaciju algoritma u RCP režimu, na stvarno-vremenski simulator je potrebno implementirati samo algoritam skalarne regulacije te algoritam modulacije prostornog vektora napona. Referentni napon kojeg algoritam generira, realizira se na stezaljkama asinkronog stroja prikazanog na slici 3.18 putem frekvencijskog pretvarača prikazanog na slici 3.5.

Slika 3.24 prikazuje stvarni i simulirani odziv brzine vrtnje za vrijeme zaleta elektromotornog pogona upravljanog skalarnom regulacijom.

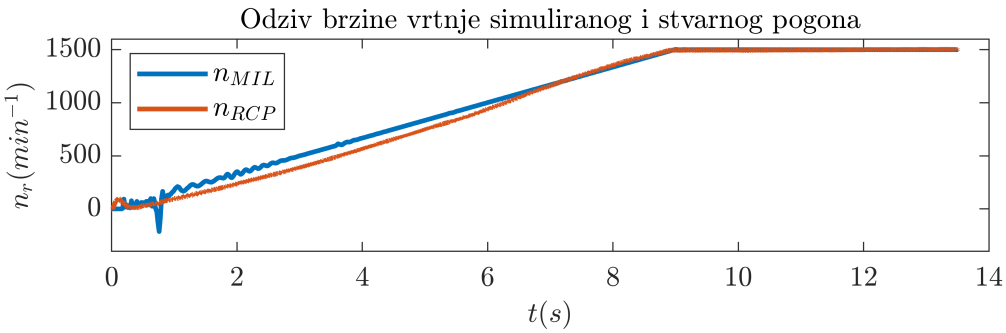

Slika 3.24: *Usporedba brzine vrtnje simuliranog (MIL) i stvarnog (RCP) pogona za vrijeme zaleta.*

Prije interpretacije rezultata bitno je napomenuti kako je odziv brzine vrtnje dobiven s tahogeneratora istosmjernog stroja, preko naponske mjerne sonde prikazane na slici 3.13. Odziv dobiven sa sonde je filtriran te je samo krajnji rezultat prikazan na slici. Zbog filtriranja nema savršenog poklapanja simuliranog i stvarnog odziva brzine vrtnje za vrijeme

zaleta, no u ustaljenom stanju se vidi savršeno poklapanje.

Slika 3.25 prikazuje simulirani i stvarni odziv fazne struje u praznom hodu po završetku zaleta asinkronog stroja. Odziv mjerene fazne struje je također filtriran te se vidi skoro savršeno poklapanje sa simuliranim odzivom.

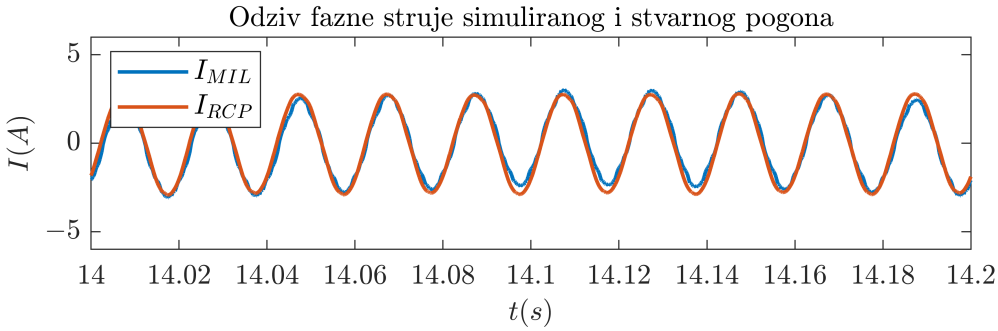

Slika 3.25: *Usporedba fazne struje simuliranog (MIL) i stvarnog (RCP) pogona u praznom hodu.*

Slika 3.26 prikazuje simulirani i stvarni odziv fazne struje pogona pod različitim opterećenjima i to od 7 i 9,1 N m pri različitim sinkronim brzinama. Odzivi mjerenih faznih struja su filtrirani te se vidi skoro savršeno poklapanje sa simuliranim odzivom.

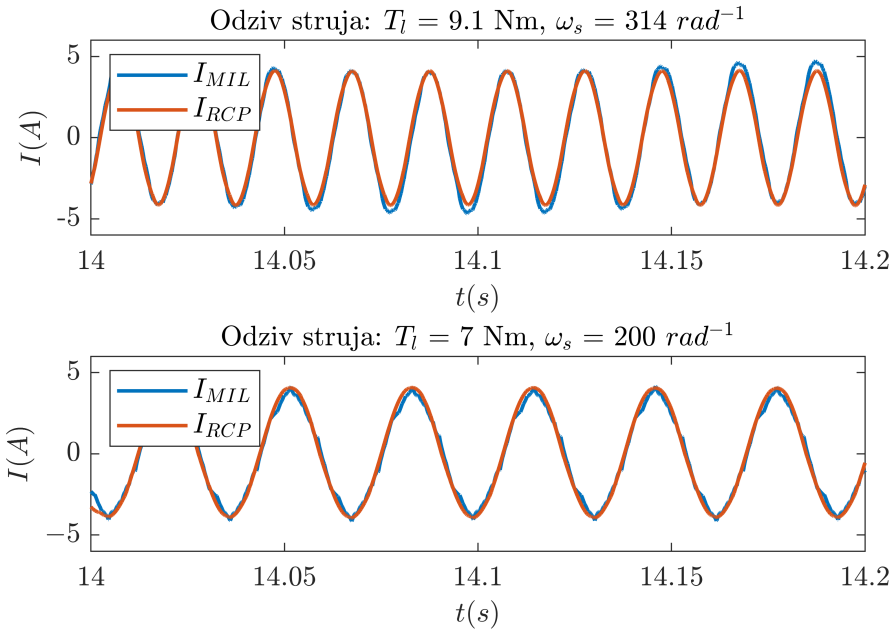

Slika 3.26: *Usporedba fazne struje simuliranog (MIL) i stvarnog (RCP) pogona pod opterećenjem.*

Tablica 3.3 prikazuje podatke vezane za odziv brzine vrtnje simuliranog i stvarnog pogona. Vidi se da je kod odziva brzine vrtnje prisutno određeno odstupanje koje može biti

pripisano odstupanjima u parametrima modela.

Tablica 3.3: *Vrijednost brzine vrtnje pri različitim opterećenjima i sinkronim brzinama*

T_l (N m)	ω_s (rad^{-1})	$n_{r,MIL}$ (min^{-1})	$n_{r,RCP}$ (min^{-1})	Odstupanje (%)
7	200	940,67	916,49	2,64
0	314	1499,9	1499,9	0
9.1	314	1484,07	1449,9	1,82

4. RAZVOJ PREDIKTIVNOG UPRAVLJANJA BEZ TEŽINSKIH FAKTORA ZA REGULACIJU BRZINE VRTNJE ASINKRONOG STROJA

4.1. Uvod u poglavlje

U prethodnom poglavlju prikazana je najjednostavnija i najstarija metoda upravljanja brzinom vrtnje asinkronog stroja. Ova metoda nema dovoljno dobro vladanje u dinamičkim uvjetima i zbog toga se ne koristi za zahtjevnije primjene kod kojih je potrebna visoka preciznost upravljanja. Metode koje su revolucionarizirale područje upravljanja asinkronim strojevima su regulacija rotorskog toka (*Field Oriented Control*-FOC), koju su razvili Hasse i Blaschke sedamdesetih godina i predstavili u svojim doktorskim disertacijama [46, 47] i direktno upravljanje momentom (*Direct Torque Control*-DTC) koju su razvili Takahashi i Noguchi [48]. Ove dvije metode upravljanja klasificiraju se kao metode vektorske regulacije te su temelj područja upravljanja asinkronim strojevima. Vektorsko upravljanje se, za razliku od skalarnog , dokazalo adekvatnim za primjene s visokim zahtjevima vezanim za dinamičke odzive, pa se tako krajem 20. stoljeća asinkroni strojevi sve više počinju koristiti u elektromotornim pogonima, a mnoštvo autora počinje istraživati i razvijati nove metode upravljanja asinkronih strojeva. Jedan od smjerova istraživanja je prediktivno upravljanje na temelju modela ili skraćeno, prediktivno upravljanje. Sedamdesetih godina, prediktivno upravljanje koristilo se za regulaciju sporih kemijskih procesa zbog velikih računalnih zahtjeva algoritama. Danas, uz razvoj digitalnih procesora signala, ove metode se mogu implementirati za brze procese.

Prediktivno upravljanje može se podijeliti na dvije skupine: s konačnim skupom referenci (*Finite Control Set*) i s kontinuiranim skupom referenci (*Continuous Control Set*). U nastavku teksta će se u ovom kontekstu koristiti termini konačno i kontinuirano prediktivno upravljanje. Autori Vazquez et al. prikazali su pregled korištenja prediktivnog upravljanja

u [49], gdje su klasificirali različite konačne i kontinuirane metode. Proširena klasifikacija prediktivnih metoda može se naći u [50]. Konačno i kontinuirano prediktivno upravljanje različitih tipova energetskih pretvarača prikazano je u [51, 52], što dokazuje da se ovakve metode uspješno mogu implementirati za brze procese. Upravljanje frekvencijskim pretvaračima zbog samog principa rada pretvarača, spada u kategoriju upravljanja konačnim skupom referenci, što znači da se metode konačnog prediktivnog upravljanja savršeno mogu implementirati za upravljanje elektromotornih pogona. Zahvaljujući različitim modulacijskim tehnikama, frekvencijski pretvarač lako preslikava i kontinuirane upravljačke signale te se na taj način omogućava i korištenje kontinuiranog prediktivnog upravljanja.

U području upravljanja asinkronih strojeva, poznate su dvije glavne metode prediktivnog upravljanja: prediktivno upravljanje momentom (PUM) i prediktivno upravljanje strujom (PUS). U zadnjih nekoliko godina objavljeno je mnoštvo bitnih radova koji uspoređuju ove metode s klasičnim metodama upravljanja. Autori Wang et al. u [53] uspoređuju upravljanje rotorskim tokom, direktno upravljanje momentom, prediktivno upravljanje strujom te prediktivno upravljanje momentom asinkronog stroja, dok autori Kennel et al. rade usporedbu upravljanja rotorskim tokom, direktnog upravljanja momentom te prediktivnog upravljanja momentom u [54]. Dostupno je još radova koji uspoređuju klasične s modernim metodama upravljanja kao što su [55, 56, 57]. Mnoštvo radova je objavljeno gdje su prezentirana unaprijeđenja postojećih prediktivnih metoda. Autori Englert et al. razvili su metodu za optimalno podešavanje referentne vrijednosti za prediktivno upravljanje momentom u [58]. Poznato je da kod klasične metode prediktivnog upravljanja momentom postoje težinski faktori koji služe za skaliranje pogreške momenta i toka u funkciji cilja. Autori radova [59, 60] unaprijedili su klasičnu metodu tako što su eliminirali težinske faktore. Kako bi se smanjilo podrhtavanje momenta, autori radova [61, 62, 63], optimirali su vremena vođenja pojedinih ventila pretvarača. U [64], autori koriste Kalman filter za procjenu struje i toka te iste koriste za prediktivno upravljanje momentom, dok u [65], autori poboljšavaju rad metode pomoću algoritma za procjenu stanja za dulji prediktivni horizont.

Mnoštvo radova je objavljeno gdje autori unaprjeđuju metode prediktivnog upravljanja strujom asinkronog motora. U [66], autori koriste univerzalni proporcionalni integralni osmotritelj kako bi poboljšali odzive sustava za vrijeme dinamičkog terećenja, a u [67] ga koriste kako bi poboljšali osjetljivost na promjenu parametara. U [68] autori prilagođavaju model za predikciju kojeg koriste za pretvarač s niskom frekvencijom uklapanja kako bi se

smanjili gubitci. Kako bi se omogućio rad pogona bez senzora za mjerenje brzine vrtnje, autori Wang et al. koriste osmotritelj brzine vrtnje visokog pojačanja u [69] i Luneberger-ov osmotritelj u [70]. Sve navedene metode spadaju u kategoriju konačnog prediktivnog upravljanja što rezultira promjenjivom frekvencijom uklapanja pretvarača i povećava rizik od pojave rezonancije i podrhtavanja momenta.

Broj radova koji se bave kontinuiranim prediktivnim upravljanjem struje je veoma nizak. Klasifikacija kontinuiranih metoda dana je u preglednom radu [71]. U [72, 73], razvijena je kontinuirana prediktivna metoda upravljanja strujom gdje je korišten LQR regulator, a u funkciji cilja koja se koristi u ovoj metodi pojavljuje se matrica težinskih faktora. Autori Ahmed et al. u [74, 75] predstavljaju način za izračun matrice težinskih faktora kako bi ograničili referentni napon asinkronog stroja, a u [76], autori razvijaju kontinuiranu prediktivnu metodu za upravljanje momentom gdje koriste matricu težinskih faktora za osiguranje stabilnosti sustava.

U ovom poglavlju, predstavljena je metoda kontinuiranog prediktivnog upravljanja strujom asinkronog stroja bez potrebe za računanjem matrice težinskih faktora. Osim u disertaciji, metoda je predstavljena i u znanstvenom članku [77], gdje je validirana kroz međunarodnu recenziju. Spomenute klasične metode ukratko su objašnjene na početku poglavlja, a potom su prikazane i konačne prediktivne metode upravljanja asinkronim strojem. Potom je prikazan izvod kontinuirane prediktivne metode upravljanja strujom asinkronog stroja te su izvršene analize upravljivosti i stabilnosti. Osmotritelj koji se koristi za procjenu brzine vrtnje i rotorskog toka je također prikazan, a na posljetku su prikazani i rezultati simulacije. MIL simulacije elektromotornih pogona upravljanih različitim metodama su izvršene na stvarno-vremenskom simulatoru te je prikazano opterećenje jezgre za pojedinu metodu.

4.2. Klasične regulacijske strukture za precizno upravljanje asinkronim strojevima

Kao što je rečeno u uvodu, metode koje su revolucionarizirale područje upravljanja asinkronim strojevima su regulacija rotorskog toka te direktno upravljanje momentom. U ovom potpoglavlju su ukratko opisane ove dvije metode te su istaknuti prednosti i nedostatci svake od njih.

4.2.1. Regulacija rotorskog toka

Regulacija rotorskog toka je metoda kod koje se za generiranje referentnih veličina primjenjuju tehnike automatskog upravljanja linearnih sustava. Krajnji signal upravljačkog napona je kontinuiran te je potrebna modulacijska tehnika kako bi ga frekvencijski pretvarač primijenio na stroj. Slika 4.1 prikazuje dijagram upravljanja asinkronog stroja ovom tehnikom. Bitno je napomenuti da se regulacija izvršava u sinkrono rotirajućem dq sustavu koji rotira jednakom brzinom kao i prostorni vektor rotorskog toka asinkronog stroja. Odavde i dolazi naziv "Regulacija rotorskog toka".

Na dijagramu se mogu primijetiti vanjska regulacijska petlja brzine vrtnje te unutarnja regulacijska petlja struje q-osi. Ove dvije petlje čine regulaciju po q-osi, a regulirana struja se može poistovjetiti sa strujom armature istosmjernog stroja. U d-osi prisutna je samo regulacijska petlja struje magnetiziranja, jer se referentna vrijednost rotorskog toka najčešće drži konstantnom za vrijeme rada pogona. Struja d-osi se može poistovjetiti sa strujom uzbude istosmjernog stroja.

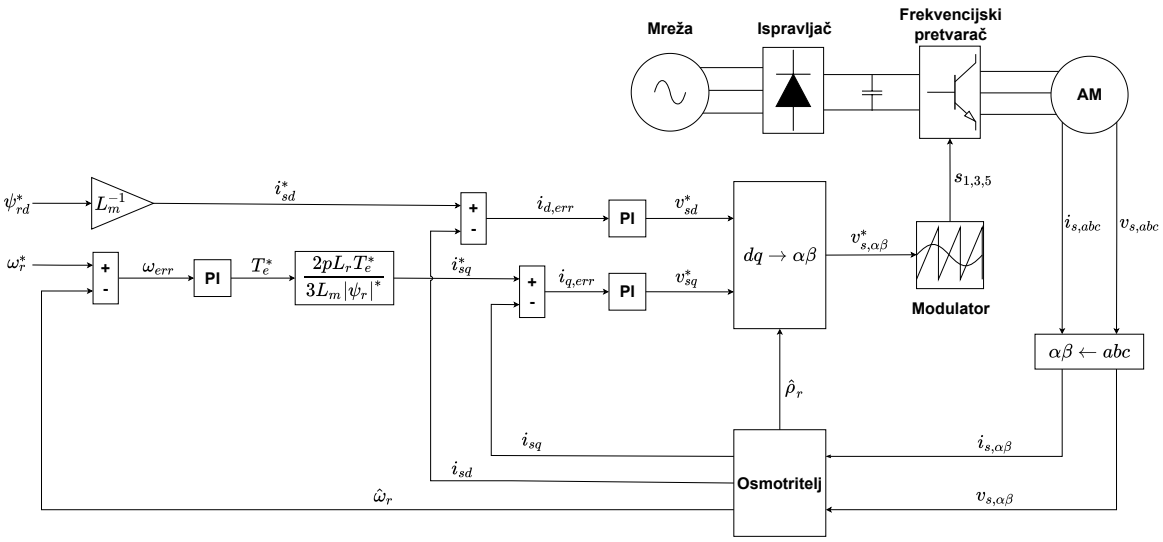

Slika 4.1: *Dijagram regulacije prostornog vektora rotorskog toka.*

Kako bi se kod ove upravljačke metode mogle iskoristiti tehnike upravljanja linearnih sustava, potrebno je pretpostaviti da regulacijski dq sustav, osim što rotira sinkrono s prostornim vektorom rotorskog toka stroja, također ima svoju d-os poravnatu s ovim prostornim vektorom. Time se postiže da je sav rotorski tok sadržan u d-osi, a q komponenta prostornog vektora rotorskog toka iznosi nula, odnosno: $\psi_{rd} = |\boldsymbol{\psi}_r|$, $\psi_{rq} = 0$. Ako se ove dvije veličine supstituiraju u model asinkronog stroja u dq sustavu danim izrazom (2-23) te ako se uzme

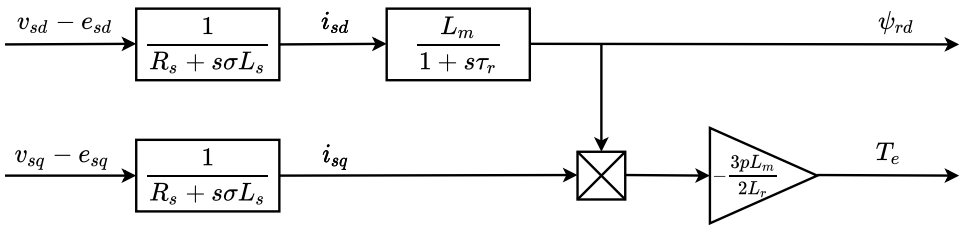

Slika 4.2: *Asinkroni stroj modeliran PT1 prijenosnim funkcijama.*

u obzir da se vrijednost rotorskog toka ne mijenja u vremenu ($|\dot{\boldsymbol{\psi}}_{rd}| = 0$), asinkroni stroj se može prikazati pomoću nekoliko PT1 prijenosnih funkcija, na temelju kojih se mogu računati optimalni parametri PI regulatora. Ovaj izvod je dobro prikazan u literaturi kao što je [42], a krajnji model prikazan je na slici 4.2, gdje $\tau_r = L_r/R_r$ predstavlja rotorsku vremensku konstantu, $\sigma = 1 - \frac{L_m^2}{L_s L_r}$ predstavlja faktor rasipanja, s predstavlja Laplaceov operator, a naponi e_{sd} i e_{sq} predstavljaju napone sprege između d i q osi regulacijskog kruga.

U dijagramu na slici 4.1 se vidi da je za uspješnu implementaciju ove metode potreban osmotritelj koji procjenjuje brzinu vrtnje (ukoliko nema senzora brzine vrtnje) te kut rotorskog toka ρ_r, koji služi za transformaciju regulacijskog dq sustava u $\alpha\beta$ sustav. Osim ove transformacije, potrebna je implementacija modulacijske tehnike koja realizira signal referentnog napona na frekvencijskom pretvaraču. Zbog spomenute transformacije i modulacije napona, ova metoda spada u računalno zahtjevne metode, no uz današnje mogućnosti mikrokontrolera i digitalnih procesora signala, ovo ne predstavlja problem kod implementacije. Osim toga, zahvaljujući modulacijskoj tehnici, frekvencija uklapanja ventila pretvarača je konstantna, što je uvijek poželjno jer se na taj način izbjegavaju pojave rezonancije. Osim izbjegavanja rezonancije, podrhtavanje momenta je također manje izraženo ako se koristi konstantna frekvencija uklapanja.

Slika 4.3 prikazuje implementaciju ove metode u Simulinku. Opterećenje jezgre OpalRT stvarno-vremenskog simulatora za vrijeme izvršavanje MIL simulacije elektromotornog pogona upravljanog ovom metodom iznosi 19,57 %.

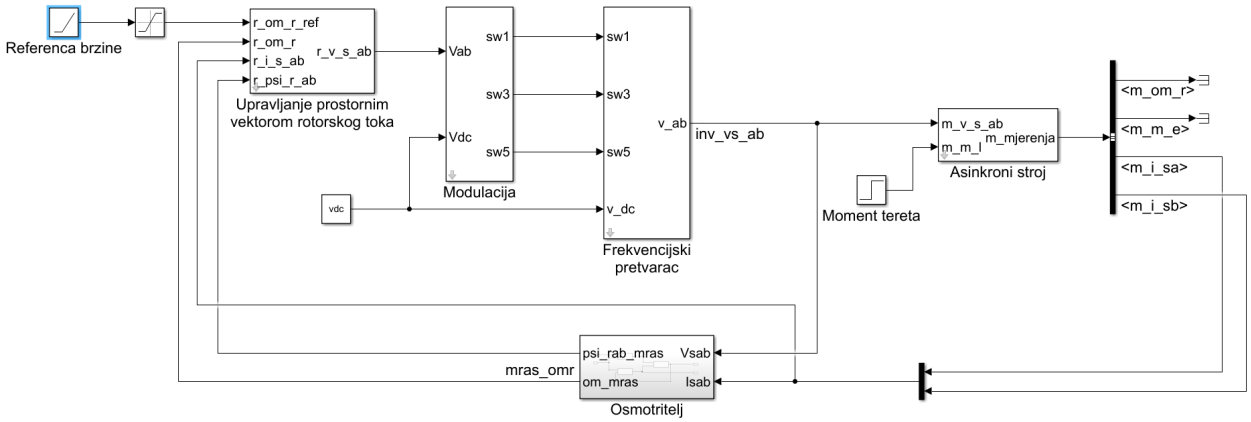

Slika 4.3: *Implementacija regulacije prostornim vektorom rotorskog toka u Simulinku.*

4.2.2. Direktno upravljanje momentom

Direktno upravljanje momentom je metoda predstavljena desetak godina nakon metode upravljanja prostornim vektorom rotorskog toka. Kod nje se u svrhu regulacije momenta i statorskog toka primjenjuju histerezni regulatori. Na temelju razlike između referentnih i procijenjenih veličina koja ulazi u histerezni regulator definira se potreba za povećanjem ili smanjenjem momenta odnosno statorskog toka. Slika 4.4 prikazuje dijagram direktnog upravljanja momentom, a knjige koje najbolje opisuju ovu metodu su [43] i [42].

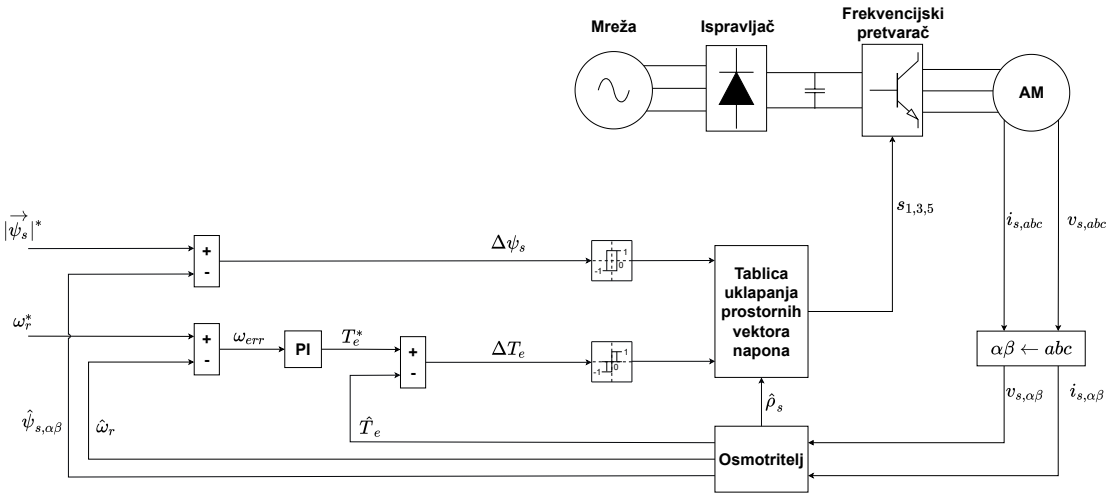

Slika 4.4: *Dijagram direktnog upravljanja momentom.*

Kod ove metode, definira se 6 sektora u kojima se prostorni vektor statorskog toka može nalaziti. Ovi sektori su prikazani na slici 4.5.

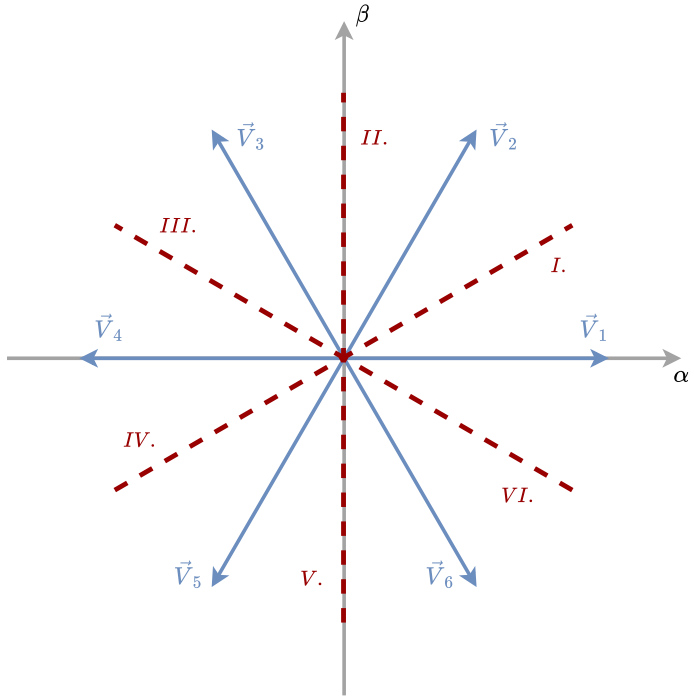

Slika 4.5: *Raspored sektora kod metode direktnog upravljanja momentom.*

Različitim uklapanjem naponskih vektora, moguće je utjecati na statorski tok stroja, a samim time i na elektromagnetski moment. Slika 4.6 prikazuje prostorni vektor statorskog toka stroja s mogućim doprinosima tokova generiranih različitim naponskim vektorima, a tablica 4.1 prikazuje utjecaj prostornih vektora napona na statorski tok i moment stroja.

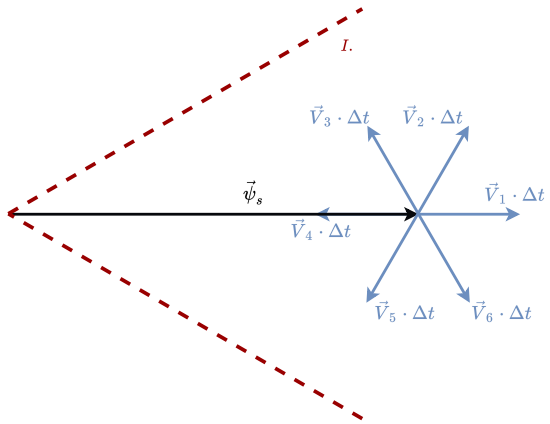

Slika 4.6: *Tvorba prostornog vektora toka u prvom sektoru.*

Tablica 4.1: *Utjecaj prostornog vektora napona na prostorni vektor statorskog toka u prvom sektoru*

$\vec{V}_s \cdot \Delta t$	T_e	$\lvert\vec{\psi}_s\rvert$
$\vec{V}_2 \cdot \Delta t$	Povećanje	Povećanje
$\vec{V}_3 \cdot \Delta t$	Povećanje	Smanjenje
$\vec{V}_5 \cdot \Delta t$	Smanjenje	Smanjenje
$\vec{V}_6 \cdot \Delta t$	Smanjenje	Povećanje

Tablica 4.2 prikazuje koji se prostorni vektor napona mora primijeniti na temelju sektora statorskog toka te izlaza histereznog regulatora.

Tablica 4.2: *Tablica uklapanja prostornih vektora napona kod direktnog upravljanja momentom*

		Sektor					
ΔT_e	$\Delta\psi_s$	$I.$	$II.$	$III.$	$IV.$	$V.$	$VI.$
1	1	$\vec{V}_2$	$\vec{V}_3$	$\vec{V}_4$	$\vec{V}_5$	$\vec{V}_6$	$\vec{V}_1$
0	1	$\vec{V}_7$	$\vec{V}_0$	$\vec{V}_7$	$\vec{V}_0$	$\vec{V}_7$	$\vec{V}_0$
-1	1	$\vec{V}_6$	$\vec{V}_1$	$\vec{V}_2$	$\vec{V}_3$	$\vec{V}_4$	$\vec{V}_5$
1	-1	$\vec{V}_3$	$\vec{V}_4$	$\vec{V}_5$	$\vec{V}_6$	$\vec{V}_1$	$\vec{V}_2$
0	-1	$\vec{V}_0$	$\vec{V}_7$	$\vec{V}_0$	$\vec{V}_7$	$\vec{V}_0$	$\vec{V}_7$
-1	-1	$\vec{V}_5$	$\vec{V}_6$	$\vec{V}_1$	$\vec{V}_2$	$\vec{V}_3$	$\vec{V}_4$

Kao što se vidi iz dijagrama regulacije na slici 4.4, ova metoda koristi osmotritelj koji procjenjuje moment i statorski tok, no za razliku od metode upravljanja rotorskog toka, nema potrebe za sinkrono rotirajućim dq sustavom regulacijskog kruga. Osim toga, nema potrebe niti za modulacijom napona jer se u svakom koraku uzorkovanja primjenjuje prostorni vektor napona koji je u tom trenutku potreban da vrijednosti momenta i statorskog toka ostanu unutar histereznih pojasa. Ova metoda je manje računalno zahtjevna i jednostavnija za implementaciju od prethodne, što je osamdesetih bio napredak jer je za implementaciju bio dovoljan procesor slabije računalne moći. Danas je ova metoda inferiornija jer su procesori visokih performansi lako dostupni, a regulacijske tehnike s boljim karakteristikama jednostavne su za implementaciju. Nedostatak modulacije napona može predstavljati problem jer frekvencija uklapanja ventila pretvarača nije konstantna što može dovesti do pojave rezo-

nancije i podrhtavanja momenta. Unatoč tome, ova metoda upravljanja je i dalje dostupna u komercijalnim frekvencijskim pretvaračima kao što je *ABB*.

Slika 4.7 prikazuje implementaciju direktnog upravljanja momentom u Simulinku, a MIL simulacija elektromotornog pogona upravljanog ovom metodom koja se izvršava na Opal-RT stvarno-vremenskom simulatoru zauzima 9,21 % jezgre simulatora.

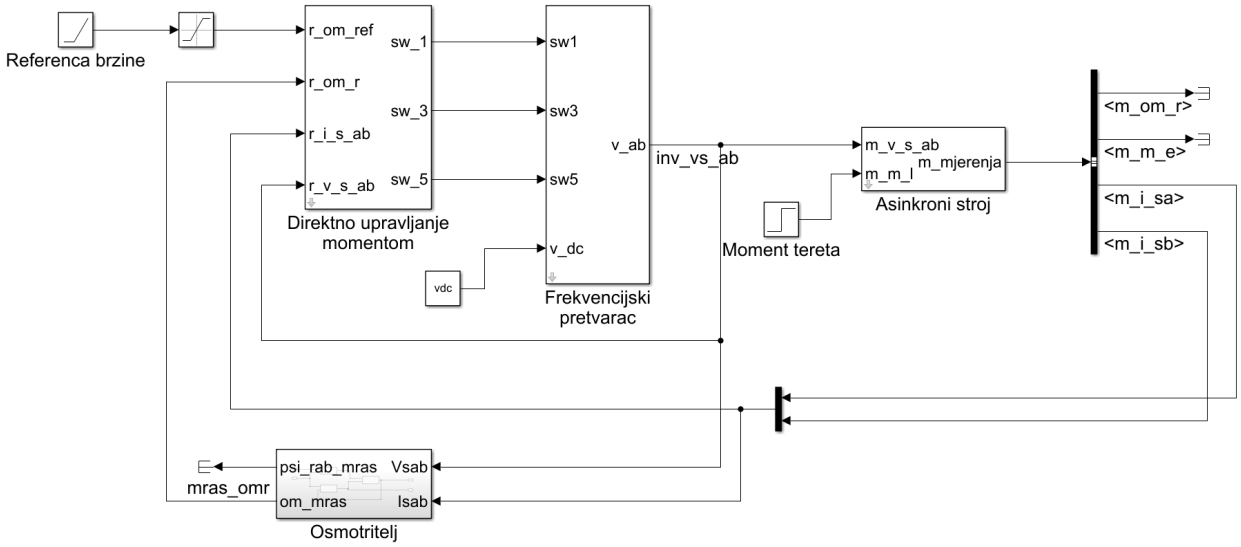

Slika 4.7: *Implementacija direktnog upravljanja momentom u Simulinku.*

4.3. Napredne regulacijske strukture za precizno upravljanje asinkronim strojevima

U uvodu poglavlja predstavljen je pregled literature vezan za metode prediktivnog upravljanja asinkronim strojevima. Kratki matematički izvodi za svaku metodu prikazani su u [53]. U ovom potpoglavlju prikazan je detaljan izvod za konačno prediktivno upravljanje momentom (K-PUM) i strujom (K-PUS) asinkronog stroja. Predikcija struje koristi se u obje metode, a koristi se i u unaprijeđenju postojeće metode kojom se ova disertacija bavi, stoga će njen izvod biti predstavljen prvi, prije opisivanja pojedine metode.

4.3.1. Izvod izraza za predikciju struje asinkronog stroja

Matematički model stroja koji se koristi u svrhu predikcije struje u metodi prediktivnog upravljanja je model u stacionarnom $\alpha\beta$ sustavu. Ovaj model tvori se na način da se sinkrona brzina ω_s u izrazima (2-23) postavi na vrijednost nula, a krajnji rezultat prikazan je izrazima (4-1)-(4-4):

$$\boldsymbol{v}_{s,\alpha\beta} = R_s \boldsymbol{i}_{s,\alpha\beta} + \frac{\mathrm{d}}{\mathrm{d}t}\boldsymbol{\psi}_{s,\alpha\beta} \tag{4-1}$$

$$0 = R_r \boldsymbol{i}_{r,\alpha\beta} - \boldsymbol{J}_{rot} p \omega_r \boldsymbol{\psi}_{r,\alpha\beta} + \frac{\mathrm{d}}{\mathrm{d}t}\boldsymbol{\psi}_{r,\alpha\beta} \tag{4-2}$$

$$J\frac{\mathrm{d}}{\mathrm{d}t}\omega_r = T_e - T_l \tag{4-3}$$

$$T_e = \frac{3}{2}p(\psi_{s\alpha} i_{s\beta} - \psi_{s\beta} i_{s\alpha}) \tag{4-4}$$

Statorski i rotorski tokovi stroja prikazani su izrazima (4-5) i (4-6), a parametri i električne veličine modela opisani su u 2. poglavlju, stoga se ovdje neće ponavljati.

$$\boldsymbol{\psi}_{s,\alpha\beta} = L_s \boldsymbol{i}_{s,\alpha\beta} + L_m \boldsymbol{i}_{r,\alpha\beta} \tag{4-5}$$

$$\boldsymbol{\psi}_{r,\alpha\beta} = L_r \boldsymbol{i}_{r,\alpha\beta} + L_m \boldsymbol{i}_{s,\alpha\beta} \tag{4-6}$$

Ako se iz jednadžbe (4-6) izrazi rotorska struja i supstituira u jednadžbu (4-2), može se izvesti jednadžba (4-7) koja opisuje dinamiku rotorskog toka:

$$\frac{\mathrm{d}}{\mathrm{d}t}\boldsymbol{\psi}_{r,\alpha\beta} = \frac{L_m}{\tau_r}\boldsymbol{i}_{s,\alpha\beta} - (\frac{1}{\tau_r}\boldsymbol{I} - \boldsymbol{J}_{rot} p \omega_r)\boldsymbol{\psi}_{r,\alpha\beta} \tag{4-7}$$

gdje $\tau_r = L_r/R_r$ predstavlja rotorsku vremensku konstantu, a $\boldsymbol{I}$ je matrica identiteta. Nadalje, ako se u jednadžbi (4-1) supstituiraju tokovi izrazima iz jednadžbi (4-5) i (4-6), a derivacija toka se zamjeni s jednadžbom iz izraza (4-7), dobiva se sljedeća jednadžba koja opisuje statorsku struju asinkronog stroja:

$$\frac{\mathrm{d}}{\mathrm{d}t}\boldsymbol{i}_{s,\alpha\beta} = -\frac{R_s + \frac{L_m^2}{L_r \tau_r}}{\sigma L_s}\boldsymbol{i}_{s,\alpha\beta} + \frac{L_m}{\sigma L_s L_r}(\frac{1}{\tau_r}\boldsymbol{I} - \boldsymbol{J}_{rot} p \omega_r)\boldsymbol{\psi}_{r,\alpha\beta} + \frac{1}{\sigma L_s}\boldsymbol{v}_{s,\alpha\beta} \tag{4-8}$$

gdje $\sigma = 1 - \frac{L_m^2}{L_s L_r}$ opisuje faktor rasipanja. Kada se jednadžbe (4-7) i (4-8) prikažu u obliku prostora stanja, mogu se definirati sljedeći izrazi:

$$\dot{\boldsymbol{x}} = \boldsymbol{A}(\omega_r)\boldsymbol{x} + \boldsymbol{B}\boldsymbol{u} \tag{4-9}$$

Gdje je $\boldsymbol{x}$ vektor stanja, $\boldsymbol{A}(\omega_r)$ je matrica stanja ovisna o brzini vrtnje, $\boldsymbol{B}$ ulazna matrica, a $\boldsymbol{u}$ ulazni vektor, definirani jednadžbama u izrazu (4-10).

$$\boldsymbol{x} = \begin{bmatrix} i_{s\alpha} \\ i_{s\beta} \\ \psi_{r\alpha} \\ \psi_{r\beta} \end{bmatrix} \quad \boldsymbol{u} = \begin{bmatrix} v_{s\alpha} \\ v_{s\beta} \end{bmatrix}$$
$$\boldsymbol{A}(\omega_r) = \begin{bmatrix} -\frac{R_s+\frac{L_m^2}{L_r\tau_r}}{\sigma L_s} & 0 & \frac{L_m}{\sigma L_s L_r \tau_r} & \frac{L_m p\omega_r}{\sigma L_s L_r} \\ 0 & -\frac{R_s+\frac{L_m^2}{L_r\tau_r}}{\sigma L_s} & -\frac{L_m p\omega_r}{\sigma L_s L_r} & \frac{L_m}{\sigma L_s L_r \tau_r} \\ \frac{L_m}{\tau_r} & 0 & -\frac{1}{\tau_r} & -p\omega_r \\ 0 & \frac{L_m}{\tau_r} & p\omega_r & -\frac{1}{\tau_r} \end{bmatrix} \quad \boldsymbol{B} = \begin{bmatrix} \frac{1}{\sigma L_s} & 0 \\ 0 & \frac{1}{\sigma L_s} \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \tag{4-10}$$

Kako bi se prediktivna metoda upravljanja strujom ili momentom asinkronog stroja mogla implementirati, model asinkronog stroja je potrebno diskretizirati. Jednadžba (4-11) prikazuje unaprijednu Eulerovu diskretizaciju pomoću koje je moguće, na temelju trenutnih vrijednosti varijabli stanja, izračunati vrijednosti varijabli stanja u idućem trenutku uzorkovanja. S obzirom da se radi izvod za predikciju α i β komponenti struje asinkronog stroja, računske operacije će biti izvršene samo na prva dva reda matrice stanja i ulazne matrice.

Nakon diskretizacije s vremenom uzorkovanja T_s, izvedena je jednadžba (4-12) koja će se koristiti za daljnje razvijanje algoritma za prediktivno upravljanje asinkronim strojem.

$$\begin{gathered} \boldsymbol{x}[k+1] = \boldsymbol{A}_d(\omega_r)\boldsymbol{x}[k] + \boldsymbol{B}_d\boldsymbol{u}[k] \\ \boldsymbol{A}_d(\omega_r) = \boldsymbol{I} + T_s\boldsymbol{A}(\omega_r) \quad \boldsymbol{B}_d = T_s\boldsymbol{B} \end{gathered} \tag{4-11}$$

$$\begin{bmatrix} i_{s\alpha}[k+1] \\ i_{s\beta}[k+1] \end{bmatrix} = \begin{bmatrix} 1-\frac{(R_s+\frac{L_m^2}{L_r\tau_r})T_s}{\sigma L_s} & 0 & \frac{L_m T_s}{\sigma L_s L_r \tau_r} & \frac{L_m p\omega_r T_s}{\sigma L_s L_r} \\ 0 & 1-\frac{(R_s+\frac{L_m^2}{L_r\tau_r})T_s}{\sigma L_s} & -\frac{L_m p\omega_r T_s}{\sigma L_s L_r} & \frac{L_m T_s}{\sigma L_s L_r \tau_r} \end{bmatrix} \begin{bmatrix} i_{s\alpha}[k] \\ i_{s\beta}[k] \\ \psi_{r\alpha}[k] \\ \psi_{r\beta}[k] \end{bmatrix} + \begin{bmatrix} \frac{T_s}{\sigma L_s} & 0 \\ 0 & \frac{T_s}{\sigma L_s} \end{bmatrix} \begin{bmatrix} v_{s\alpha}[k] \\ v_{s\beta}[k] \end{bmatrix} \tag{4-12}$$

4.3.2. Konačno prediktivno upravljanje momentom *(Finite control set predictive torque control)*

Osnovna literatura za bolje razumijevanje metode konačnog prediktivnog upravljanja momentom asinkronog stroja koja se preporučuje je [78]. Kod ove metode potrebne su predikcije statorskog toka i momenta koje se koriste u funkciji cilja za računanje optimalnog naponskog vektora koji se u danom trenutku mora primijeniti na stroj. Funkcija cilja koja se koristi prikazana je izrazom 4-13, gdje vrijednosti sa zvjezdicom u eksponentu predstavljaju referentne vrijednosti električne veličine, a h je broj krajnjeg koraka za koji se računa buduća vrijednost veličine i još se naziva prediktivni horizont.

$$G[\boldsymbol{v}_i] = \sum_{j=0}^{h} (|T_e^* - T_e[k+j]| + w \cdot |\|\boldsymbol{\psi}_{s,\alpha\beta}^*\| - \|\boldsymbol{\psi}_{s,\alpha\beta}[k+j]\||), \;\; i \in \{0, 1, ..., 7\} \tag{4-13}$$

Pomoću funkcija cilja vrši se odabir optimalnog prostornog vektora napona $\boldsymbol{v}_i$ kojeg pretvarač realizira na stezaljkama statora stroja. Jednadžbe za predikciju momenta i statorskog toka prikazane su izrazima (4-14) i (4-15). Jednadžba za predikciju statorske struje $\boldsymbol{i}_{s,\alpha\beta}[k+1]$ prikazana je izrazom (4-12).

$$T_e[k+1] = \frac{3p}{2} \boldsymbol{i}_{s,\alpha\beta}^T[k+1] \boldsymbol{J}_{rot} \boldsymbol{\psi}_{s,\alpha\beta}[k+1] \tag{4-14}$$

$$\boldsymbol{\psi}_{s,\alpha\beta}[k+1] = \boldsymbol{\psi}_{s,\alpha\beta}[k] + T_s(\boldsymbol{v}_{s,\alpha\beta}[k] - R_s \boldsymbol{i}_{s,\alpha\beta}[k]) \tag{4-15}$$

Slika 4.8 prikazuje dijagram prediktivnog upravljanja momentom asinkronog stroja, a za uspješnu implementaciju, potreban je osmotritelj rotorskog i statorskog toka. Modulacijska tehnika nije potrebna jer se u svakom trenutku uzorkovanja računa optimalan prostorni vektor napona kojeg pretvarač primjenjuje na stroj te se zbog toga ova metoda naziva konačno prediktivno upravljanje momentom asinkronog stroja (K-PUM).

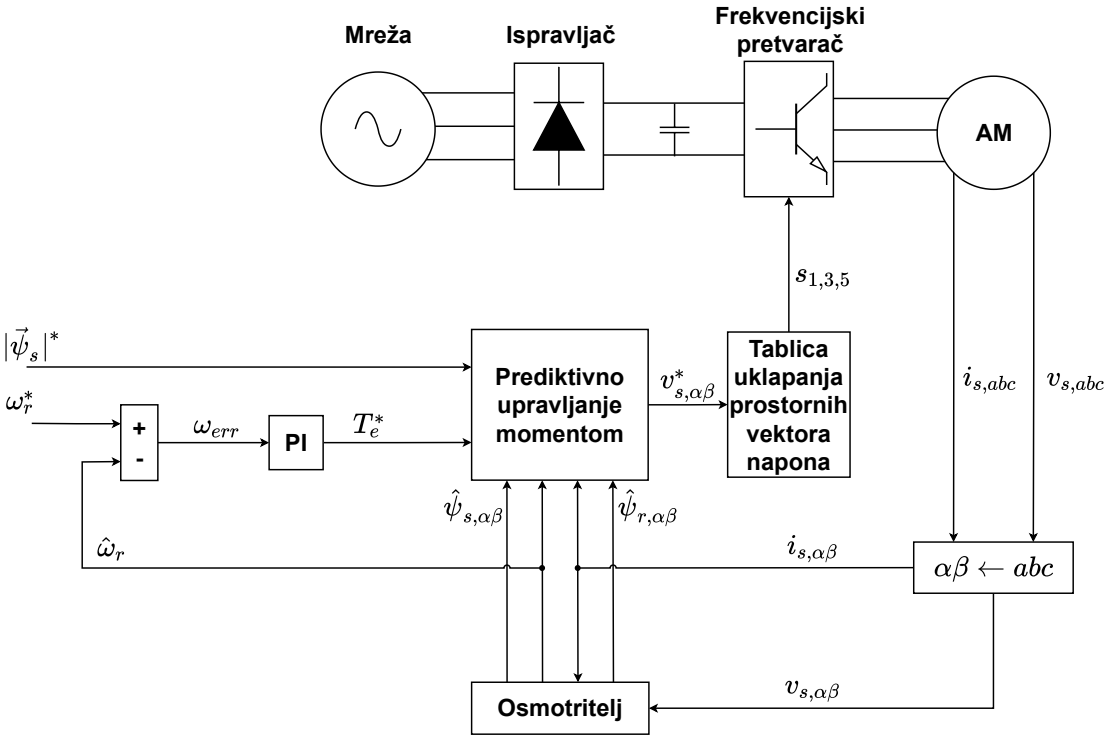

Slika 4.8: *Dijagram konačnog prediktivnog upravljanja momentom.*

Slika 4.9 prikazuje implementaciju konačnog prediktivnog upravljanja momentom u Simulinku. MIL simulacija elektromotornog pogona upravljanog ovom metodom zauzima 8,9 % jezgre na Opal-RT stvarno-vremenskom simulatoru.

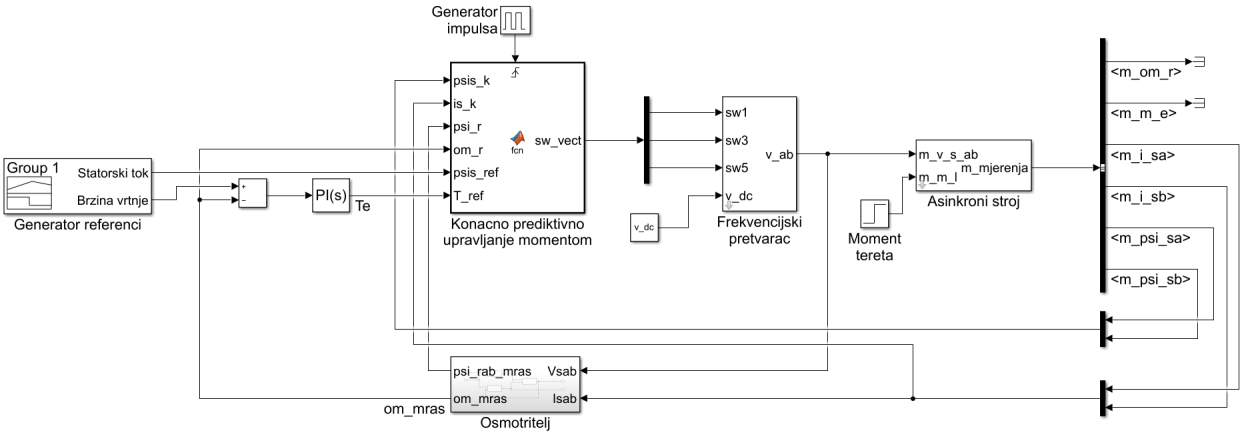

Slika 4.9: *Implementacija konačnog prediktivnog upravljanja momentom u Simulinku.*

4.3.3. Konačno prediktivno upravljanje strujom *(Finite control set predictive current control)*

Preporučena literatura za bolje razumijevanje metode prediktivnog upravljanja strujom asinkronog stroja su radovi [79] i [56]. U ovoj metodi također se koristi funkcija cilja pomoću koje

se računa optimalan prostorni vektor napona kojeg pretvarač primjenjuje na stroj. Funkcija cilja koja se koristi u ovoj metodi prikazana je jednadžbom (4-16). Kao i u prethodnoj metodi, veličine sa zvjezdicom u eksponentu predstavljaju referentne vrijednosti. Kao što se vidi iz izraza (4-16), kod prediktivnog upravljanja strujom se u funkciji cilja računaju pogreške predikcija α i β komponenti statorskih struja, za svaki mogući prostorni vektor napona $\boldsymbol{v}_i$. Također je prisutan i prediktivni horizont h koji se može proizvoljno odabrati.

$$G[\boldsymbol{v}_i] = \sum_{j=0}^{h} (|i^*_{s\alpha} - i_{s\alpha}[k+j]| + |i^*_{s\beta} - i_{s\beta}[k+j]|), \;\; i \in \{0, 1, ..., 7\} \tag{4-16}$$

Vrijednosti predikcija strujnih komponenti koje se koriste u izračunu vrijednosti funkcije cilja prikazane su izrazom (4-12), a slika 4.10 prikazuje dijagram prediktivnog upravljanja strujom asinkronog stroja. Za razliku od prethodne tehnike, osmotritelj je potreban samo za rotorski tok. Osim rotorskog toka, osmotritelj generira i kut $\hat{\rho}_k$ koji se koristi u $dq \rightarrow \alpha\beta$ transformaciji struja. Kod ove metode se usvajaju principi iz metode upravljanja prostornog vektora rotorskog toka, pa se tako referentne vrijednosti struja generiraju u dq sustavu, a s obzirom da se predikcije vrše u $\alpha\beta$ sustavu, potrebna je ova transformacija. Pomoću funkcije cilja (4-16) se računa optimalan prostorni vektor napona u svakom trenutku uzorkovanja kao i u prethodnoj metodi, tako da modulacijska tehnika također nije potrebna.

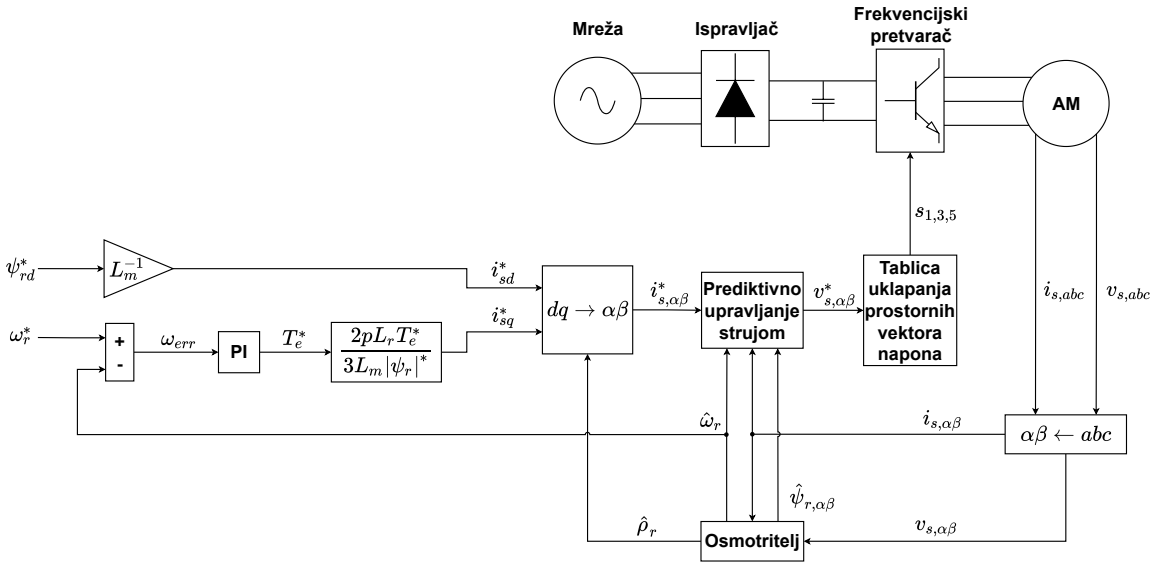

Slika 4.10: *Dijagram konačnog prediktivnog upravljanja strujom.*

Slika 4.11 prikazuje implementaciju konačnog prediktivnog upravljanja strujom u Simulinku. MIL simulacija elektromotornog pogona upravljanog ovom metodom zauzima 10,63 % jezgre na Opal-RT stvarno-vremenskom simulatoru.

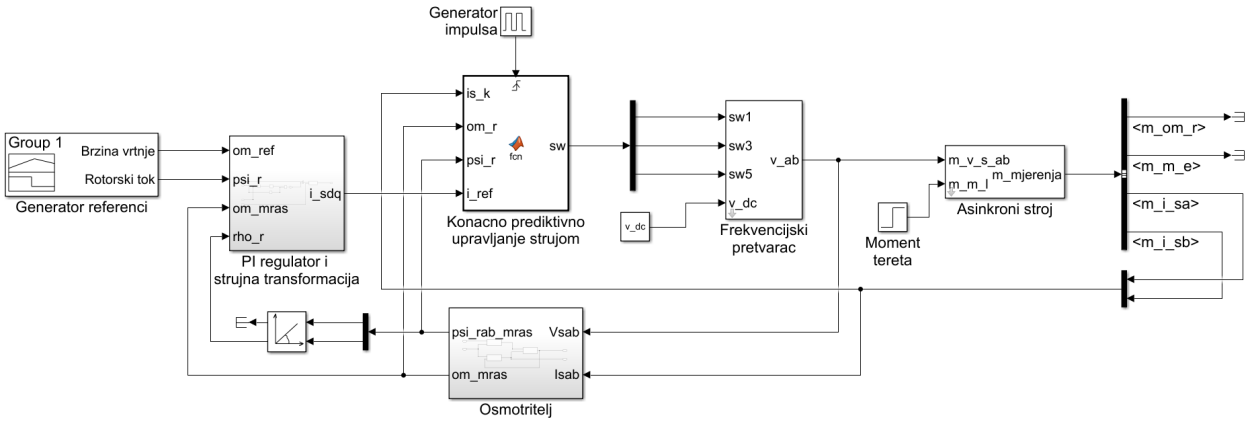

Slika 4.11: *Implementacija konačnog prediktivnog upravljanja strujom u Simulinku.*

Metoda konačnog prediktivnog upravljanja strujom asinkronog stroja, temelj je jednog od doprinosa ove doktorske disertacije. Koristeći se tehnikama objašnjenim u sljedećem potpoglavlju, ova prediktivna metoda prilagođava se da generira kontinuirani signal referentnog napona, čime prelazi iz konačne u kontinuiranu prediktivnu metodu upravljanja strujom. Osim što je metoda prilagođena da generira kontinuirani signal referentnog napona, za ovu prilagodbu nema potrebe za računanjem težinskih faktora u funkciji cilja kako bi sustav ostao stabilan, što je glavni doprinos ovog postupka.

4.4. Kontinuirano prediktivno upravljanje strujom asinkronog stroja bez težinskih faktora

Kako bi se zakon kontinuiranog upravljanja mogao izvesti, potrebno je definirati dvije funkcije cilja, prikazane jednadžbom (4-17), gdje svaka predstavlja kvadrat pogreške predikcije α i β komponenti statorskih struja.

$$\boldsymbol{G} = \begin{bmatrix} G_\alpha \\ G_\beta \end{bmatrix} = \begin{bmatrix} (i_\alpha^*[k] - i_\alpha[k+1])^2 \\ (i_\beta^*[k] - i_\beta[k+1])^2 \end{bmatrix} \tag{4-17}$$

Supstitucijom strujnih predikcija u (4-17) sa izrazom iz (4-12) te rješavanjem jednadžbe (4-18), moguće je dobiti izraz za izračun optimalnih komponenti statorskog napona koji minimiziraju funkciju cilja, a samim time vode statorsku struju asinkronog stroja prema referentnoj vrijednosti.

$$\frac{\partial \boldsymbol{G}}{\partial \boldsymbol{v}_{s,\alpha\beta}} = 0 \tag{4-18}$$

Gotov izraz za optimalan napon prikazan je jednadžbom (4-19):

$$\boldsymbol{v}^*_{s,\alpha\beta}[k+1] = \boldsymbol{K}_d(\omega_r)\boldsymbol{x}[k] + \boldsymbol{E}_d\boldsymbol{i}^*_{s,\alpha\beta}[k]$$

$$\boldsymbol{K}_d(\omega_r) = \begin{bmatrix} R_s + \frac{L_m^2}{L_r\tau_r} - \frac{\sigma L_s}{T_s} & 0 & -\frac{L_m}{L_r\tau_r} & -\frac{L_m p\omega_r}{L_r} \\ 0 & R_s + \frac{L_m^2}{L_r\tau_r} - \frac{\sigma L_s}{T_s} & \frac{L_m p\omega_r}{L_r} & -\frac{L_m}{L_r\tau_r} \end{bmatrix} \tag{4-19}$$

$$\boldsymbol{E}_d = \begin{bmatrix} \frac{\sigma L_s}{T_s} & 0 \\ 0 & \frac{\sigma L_s}{T_s} \end{bmatrix}, \quad \boldsymbol{v}^*_{s,\alpha\beta}[k] = \begin{bmatrix} v^*_{s\alpha}[k] \\ v^*_{s\beta}[k] \end{bmatrix}, \quad \boldsymbol{i}^*_{s,\alpha\beta}[k] = \begin{bmatrix} i^*_{s\alpha}[k] \\ i^*_{s\beta}[k] \end{bmatrix}$$

Signal napona $\boldsymbol{v}^*_{s,\alpha\beta}$ kojeg algoritam generira je sada kontinuiran, za razliku od metode gdje se u svakom vremenskom koraku računa jedan od 8 mogućih prostornih vektora napona pretvarača. To znači da će modulacijskom tehnikom ovaj signal biti realiziran na statoru asinkronog stroja, a frekvencija uklapanja ventila bit će konstantna što pogoduje odzivu momenta i uklanja mogućnost pojave rezonancije. Kao što se može primijetiti, u ovom postupku nije bilo potrebe za izračunavanjem matrica težinskih faktora u funkciji cilja, kao što je to slučaj u radovima [72, 73] ili [74, 75]. U sljedećem potpoglavlju će biti prikazana procedura za računanje referentnih vrijednosti strujnih komponenti.

4.4.1. Vanjska regulacijska petlja

Za generiranje referentnih vrijednosti α i β komponenti statorske struje, mogu se primijeniti procedure iz klasičnih metoda upravljanja asinkronim strojevima gdje se koristi rotirajući dq sustav. Pomoću referentne vrijednosti rotorskog toka, moguće je izračunati referentnu vrijednost d-komponente struje, a referentna vrijednost q-komponente struje može se izračunati iz referentne vrijednosti momenta, kao što je prikazano izrazima (4-20). Da bi se ove vrijednosti transformirale iz dq u $\alpha\beta$ sustav, koristi se transformacija prikazana jednadžbom (2-12).

$$i^*_{sd} = \frac{|\boldsymbol{\psi}_r|^*}{L_m} \qquad i^*_{sq} = \frac{2pL_rT^*_e}{3L_m|\boldsymbol{\psi}_r|^*} \tag{4-20}$$

Referentni tok može biti promjenjiv i imati različite vrijednosti ovisno o režimu rada pogona, međutim u ovoj disertaciji je izabran konstantan referentni rotorski tok. Vrijednost referentnog rotorskog toka se obično uzima kao nazivna vrijednost toka, a računa se pomoću jednadžbe (4-21), gdje v_n predstavlja nazivni fazni napon stroja, a ω_s nazivnu sinkronu frekvenciju.

$$|\boldsymbol{\psi}_r|^* = \frac{\sqrt{2}v_n}{\omega_s} \tag{4-21}$$

Referentna vrijednost momenta dobiva se iz regulacijske petlje brzine vrtnje koristeći klasični PI regulator kako je prikazano u jednadžbi (4-22), gdje s predstavlja Laplaceov operator, $K_{P\omega}$ i $K_{I\omega}$ predstavljaju pojačanja regulatora, a $\hat{\omega}_r$ predstavlja procijenjenu vrijednost brzine vrtnje rotora.

$$T_e^* = (\omega_r - \hat{\omega}_r)(K_{P\omega} - \frac{K_{I\omega}}{s}) \tag{4-22}$$

4.4.2. Osmotritelj rotorskog toka i brzine vrtnje

Osmotritelj je bitan dio regulacijske strukture asinkronog stroja. U predloženoj regulacijskoj strukturi, koristit će se klasični *MRAS*-(*Model Reference Adaptive System*) osmotritelj koji je detaljno opisan u [43]. Referentni model opisan je izrazom (4-23), a adaptivni model izrazom (4-24), gdje kapa opisuje procijenjene vrijednosti, a $K_{P_{mras}}$ i $K_{I_{mras}}$ predstavljaju proizvoljna pojačanja osmotritelja.

$$\begin{aligned} \frac{\mathrm{d}}{\mathrm{d}t}\boldsymbol{\psi}_{s,\alpha\beta} &= \boldsymbol{v}_{s,\alpha\beta} - R_s\boldsymbol{i}_{s,\alpha\beta} \\ \boldsymbol{\psi}_{r,\alpha\beta} &= \frac{L_r}{L_m}(\boldsymbol{\psi}_{s,\alpha\beta} - \sigma L_s\boldsymbol{i}_{s,\alpha\beta}) \end{aligned} \tag{4-23}$$

$$\begin{aligned} \frac{\mathrm{d}}{\mathrm{d}t}\hat{\boldsymbol{\psi}}_{r,\alpha\beta} &= \begin{bmatrix} -\frac{1}{\tau_r} & -\hat{\omega}_r \\ \hat{\omega}_r & -\frac{1}{\tau_r} \end{bmatrix}\hat{\boldsymbol{\psi}}_{r,\alpha\beta} + \frac{L_m}{\tau_r}\boldsymbol{i}_{s,\alpha\beta} \\ \zeta &= \hat{\psi}_{r\alpha}\psi_{r\beta} - \hat{\psi}_{r\beta}\psi_{r\alpha} \\ \hat{\omega}_r &= \zeta(K_{P_{mras}} + \frac{K_{I_{mras}}}{s}) \end{aligned} \tag{4-24}$$

Regulacijska struktura je sada potpuna, a blok dijagram predložene metode prikazan je na slici 4.12. Može se primijetiti da su metode konačnog i kontinuiranog prediktivnog upravljanja strujom, strukturno slične. Razlika je u tome što kontinuirana metoda ima drugačiji algoritam predviđanja optimalnog napona koji zahtjeva modulaciju.

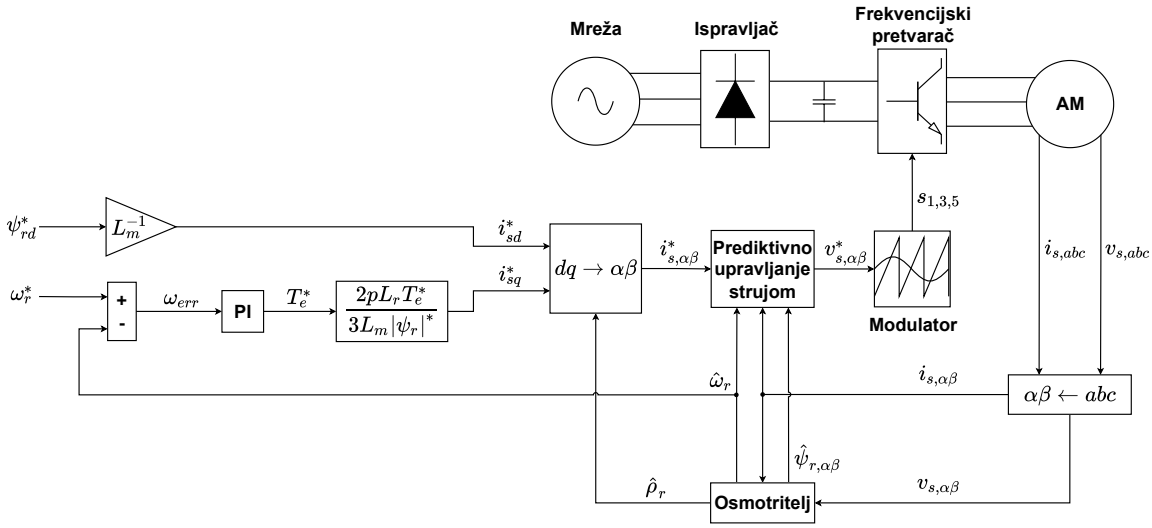

Slika 4.12: *Dijagram kontinuiranog prediktivnog upravljanja asinkronog stroja.*

4.4.3. Analiza stabilnosti sustava

Kako bi se dokazala stabilnost predložene regulacijske strukture, potrebno je analizirati prijenosnu funkciju ili svojstvene vrijednosti matrice stanja zatvorenog sustava. Izvedeni zakon upravljanja predstavljen izrazom (4-19) može se supstituirati u izraz za predikciju struje (4-12) te se na taj način može dobiti model zatvorenog sustava prikazanog izrazom (4-25).

$$\begin{aligned} \boldsymbol{x}[k+1] &= \boldsymbol{A'}(\omega_r)\boldsymbol{x}[k] + \boldsymbol{B}_d\boldsymbol{E}_d\boldsymbol{i}^*_{\alpha\beta}[k] \\ \boldsymbol{A'}(\omega_r) &= \boldsymbol{A}_d(\omega_r) + \boldsymbol{B}_d\boldsymbol{K}_d(\omega_r) \end{aligned} \tag{4-25}$$

Može se primijetiti da izvedeni sustav podsjeća na metodu upravljanja povratnom vezom stanja, gdje $\boldsymbol{K}_d(\omega_r)$ može biti promatran kao matrica pojačanja povratne veze. Ako se u tom slučaju izraz $\boldsymbol{A'}(\omega_r)$ dokaže stabilnim, odnosno, ako se sve svojstvene vrijednosti matrice $\boldsymbol{A'}(\omega_r)$ nalaze unutar jedinične kružnice, sustav je moguće smatrati stabilnim. U slučaju ovog sustava, matrica $\boldsymbol{A'}(\omega_r)$ i matrica pojačanja povratne veze $\boldsymbol{K}_d(\omega_r)$ ovise o trenutnim vrijednostima brzine vrtnje ω_r, zbog čega analitički izraz za računanje svojstvenih vrijednosti matrice postaje praktički nemoguć za izvođenje. Zbog toga je odrađeno numeričko rješavanje polova sustava za raspon svih mogućih brzina vrtnje koji su kasnije i grafički prikazani. Bitno je napomenuti da u velikoj količini radova kao što su [72, 73], analiza stabilnosti nije odrađena. Slika 4.13 prikazuje diskretne polove sustava za raspon brzine vrtnje od

$-157\,\mathrm{rad\,s^{-1}} \leqslant \omega_r \leqslant 157\,\mathrm{rad\,s^{-1}}, \omega_r \in \mathbb{Z}$. Vidi se da polovi ostaju unutar jedinične kružnice za cijeli raspon brzine vrtnje, što dokazuje da je sustav stabilan.

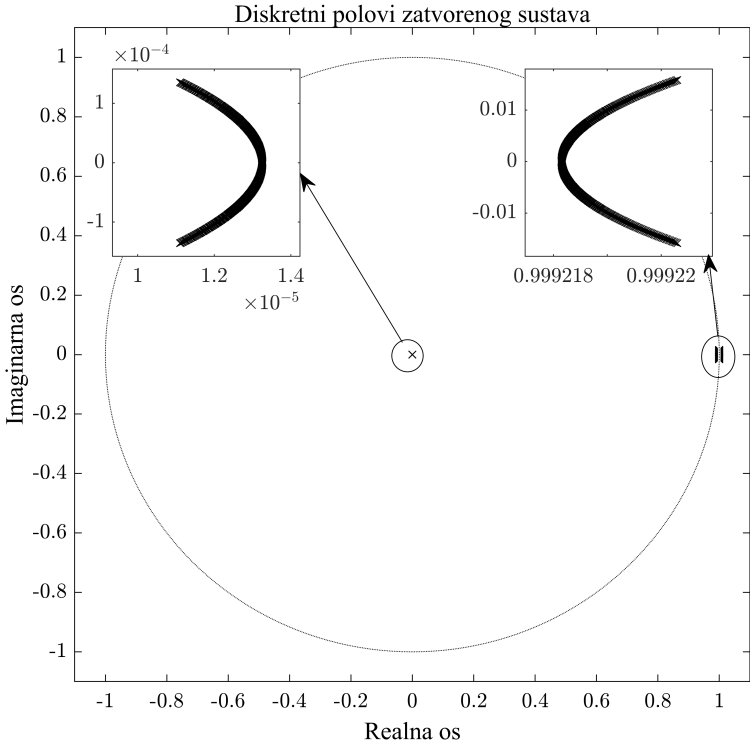

Slika 4.13: *Diskretni polovi zatvorenog sustava za puni raspon vrijednosti brzine vrtnje.*

Parametri asinkronog stroja za koji je izvršena analiza prikazani su u tablici 4.3 i dovoljni su za reproduciranje rezultata sa slike 4.13.

Tablica 4.3: *Parametri reguliranog asinkronog stroja*

Parametar		**Vrijednost**
Otpor statora	R_s (Ω)	1.1507
Otpor rotora	R_r (Ω)	1.0107
Induktivitet statora	L_s (H)	0.1315
Induktivitet rotora	L_r (H)	0.1315
Međuinduktivitet	L_m (H)	0.126
Broj pari polova	p	2
Moment inercije	J (kgm^2)	0.129

4.4.4. Analiza upravljivosti sustava

Kod metoda upravljanja stanjem pomoću povratne veze, upravljivost je nužno svojstvo koje je potrebno zadovoljiti kako bi metoda funkcionirala. S obzirom da se predložena metoda može promatrati na ovaj način, potrebno je odraditi analizu upravljivosti. Analiza se izvršava tako što se formira matrica upravljivosti ($\boldsymbol{Co}$) prikazana jednadžbom (4-26) te se potom računa njen rang. Kao i kod analize stabilnosti postupak će biti odrađen za raspone brzine vrtnje: $-157\,\mathrm{rad\,s^{-1}} \leqslant \omega_r \leqslant 157\,\mathrm{rad\,s^{-1}}, \omega_r \in \mathbb{Z}$.

$$\boldsymbol{Co} = \begin{bmatrix} \boldsymbol{B} & \boldsymbol{A}(\omega_r)\boldsymbol{B} & \boldsymbol{A}^2(\omega_r)\boldsymbol{B} & \dots & \boldsymbol{A}^{n-1}(\omega_r)\boldsymbol{B} \end{bmatrix} \tag{4-26}$$

Matrica za cijeli raspon brzine vrtnje mora biti punog ranga kako bi se moglo dokazati da je sustav upravljiv. Za bolji vizualni prikaz ovog dokaza, prikladno je izračunati gramian upravljivosti i iscrtati njegove svojstvene vrijednosti. Slika 4.14 prikazuje svojstvene vrijednosti gramiana za pun raspon brzine vrtnje. S obzirom da su realni dijelovi svih svojstvenih vrijednosti pozitivni, možemo zaključiti da su matrice gramiana pozitivno definitne, što dokazuje da je sustav upravljiv. Za više informacija o matrici gramiana preporuča se [80].

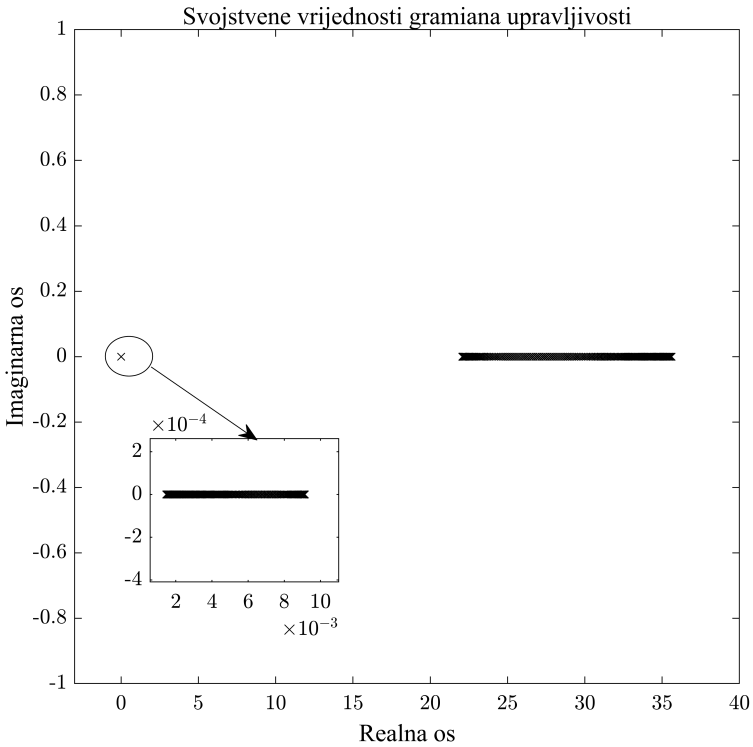

Slika 4.14: *Svojstvene vrijednosti gramiana upravljivosti za raspon vrijednosti brzine vrtnje rotora.*

Tablica 4.4: *Parametri regulacijskog kruga i simulacije*

Parametar		Vrijednost
MRAS proporcionalno pojačanje	$K_{P_{mras}}$	1000
MRAS integralno pojačanje	$K_{I_{mras}}$	10000
Proporcionalno pojačanje regulatora brzine	$K_{P\omega}$	10
Integralno pojačanje regulatora brzine	$K_{I\omega}$	100
Vremenski korak simulacije	T_{sim} (s)	10^{-5}
Napon istosmjernog međukruga	v_{DC} (V)	565
Frekvencija uklapanja ventila pretvarača	f_{sw} (kHz)	10
Vremenski korak	T_s (s)	10^{-5}
Solver		Runge-Kutta

4.4.5. Rezultati simulacije

Slika 4.15 prikazuje implementaciju kontinuiranog prediktivnog upravljanja strujom u Simulinku. Kako bi rezultati simulacije bili što realističniji, pretvarač i modulator bit će uključeni u simulaciju. Model frekvencijskog pretvarača prikazan je jednadžbom (2-28) u 2. poglavlju. Modulacijska tehnika korištena u predloženoj metodi je modulacija prostornog vektora napona, također prikazana u 2. poglavlju. MIL simulacija ovog pogona zauzima 18,44 % jezgre na Opal-RT stvarno-vremenskom simulatoru. Svi parametri simulacije navedeni su u tablici 4.4.

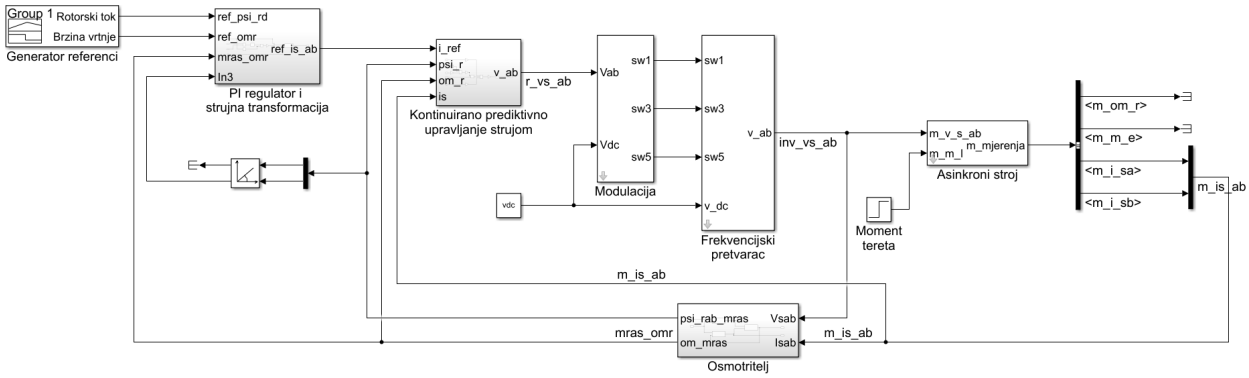

Slika 4.15: *Implementacija kontinuiranog prediktivnog upravljanja strujom u Simulinku.*

Referentne vrijednosti koje su korištene kao ulaz regulator su sljedeće:

- rotorski tok: linearna funkcija koja raste od 0-0.8 H tijekom prve sekunde simulacije, a potom postaje konstanta,
- brzina rotora: linearna funkcija koja raste od 0-1433 min^{-1}, od prve do četvrte sekunde simulacije, a potom postaje konstanta,
- Moment tereta: nazivni moment tereta od 27 N m priključen je na motor u petoj sekundi simulacije te ostao konstantan do kraja simulacije.

Sve navedene veličine grafički su prikazane na slici 4.16.

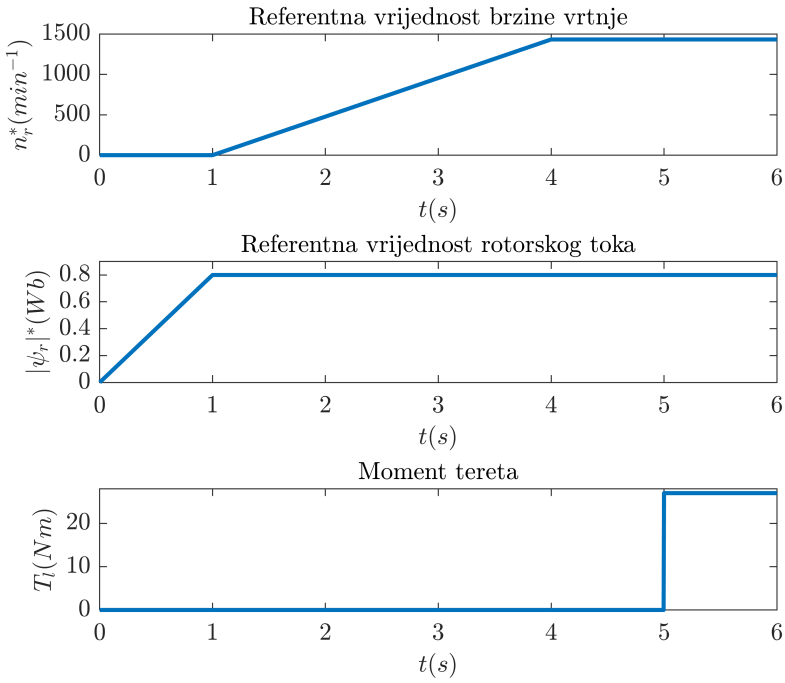

Slika 4.16: *Vrijednosti referentnih veličina i profil momenta tereta.*

Slika 4.17 pokazuje performanse regulatora u smislu praćenja referentne vrijednosti brzine vrtnje. Vidi se da je pogreška praćenja brzine vrtnje u ustaljenom stanju jednaka nuli isto kao i pogreška procijenjene brzine vrtnje. U prijelaznim stanjima, može se vidjeti da pogreška brzo konvergira prema nuli.

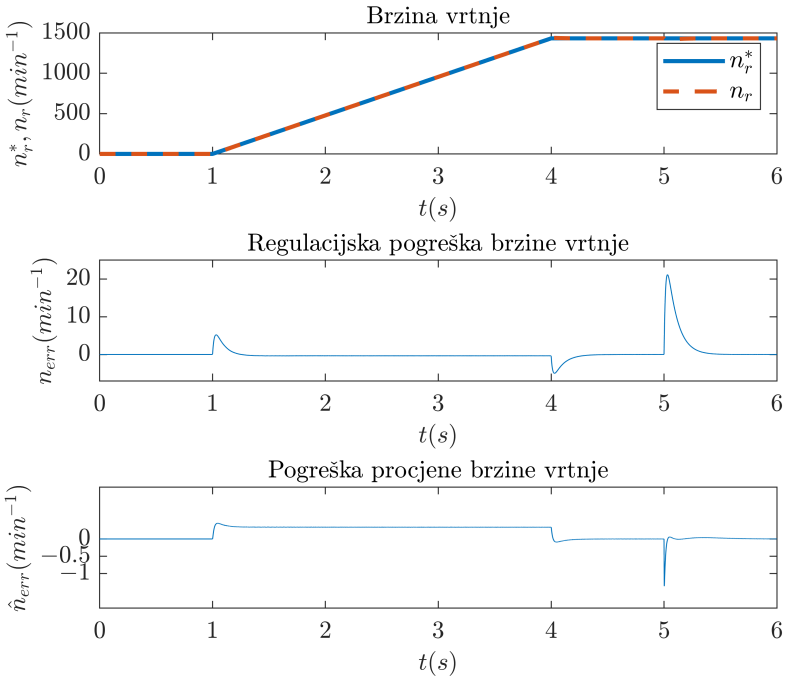

Slika 4.17: *Performanse regulacije i procjene brzine vrtnje*

Slike 4.18 i 4.19 pokazuju procijenjene i stvarne vrijednosti d i q komponenti rotorskog toka te pogreške procjena.

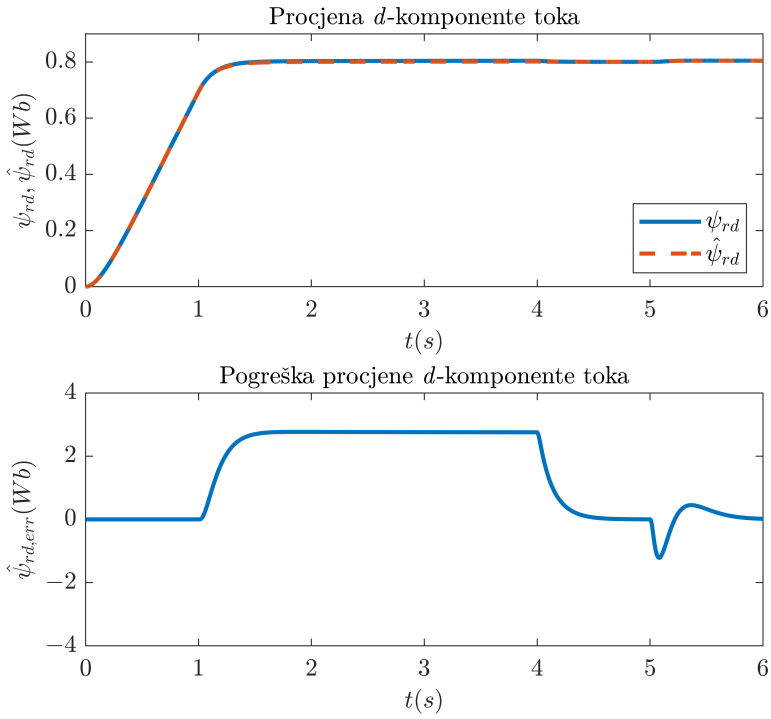

Slika 4.18: *Performanse procjene d-komponente rotorskog toka.*

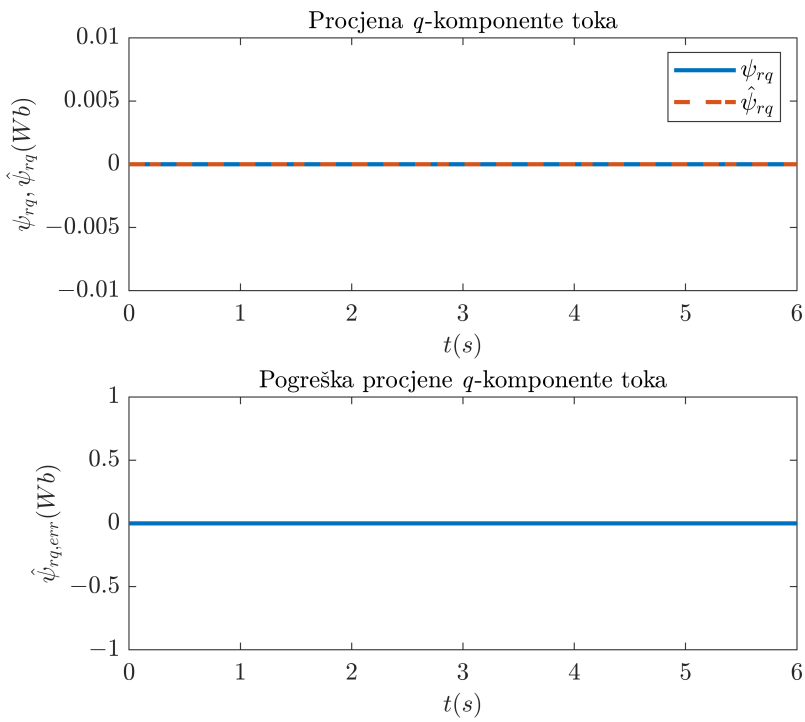

Slika 4.19: *Performanse procjene q-komponente rotorskog toka*

Komponente rotorskog toka su preračunate iz $\alpha\beta$ u dq sustav radi bolje vizualizacije. Može se vidjeti da je procjena d-komponente rotorskog toka za vrijeme prijelaznih pojava sklonija pogreškama nego procjena q komponente, no u ustaljenom stanju, pogreška brzo konvergira ka nuli. Maksimalna vrijednost pogreške d-komponente toka je tek oko 0,4% ukupne vrijednosti toka. Pogreška procjene q-komponente rotorskog toka nije naglašena, kao što se može vidjeti iz slike 4.19.

Slika 4.20 pokazuje referentni moment te izračunati elektromagnetski moment stroja. Može se vidjeti da vrijednost generiranog elektromagnetskog momenta prati referentnu vrijednost momenta, no podrhtavanje momenta je očigledno. Podrhtavanje momenta je neizbježno zbog moduliranog napona kojeg daje frekvencijski pretvarač, no modulacija prostornog vektora uvelike ublažuje ovu pojavu te smanjuje harmonijski sadržaj naspram drugih tehnika modulacije.

Harmonijski sadržaj je vidljiv i u statorskim strujama. Slika 4.21 prikazuje trofazne struje za vrijeme zaleta, a slika 4.22 prikazuje uvećani dio struje jedne faze gdje je harmonijski sadržaj najbolje vidljiv. Kao što je ranije spomenuto, ovakav odziv je neizbježan i može se samo ublažiti ali ne i potpuno izbjeći.

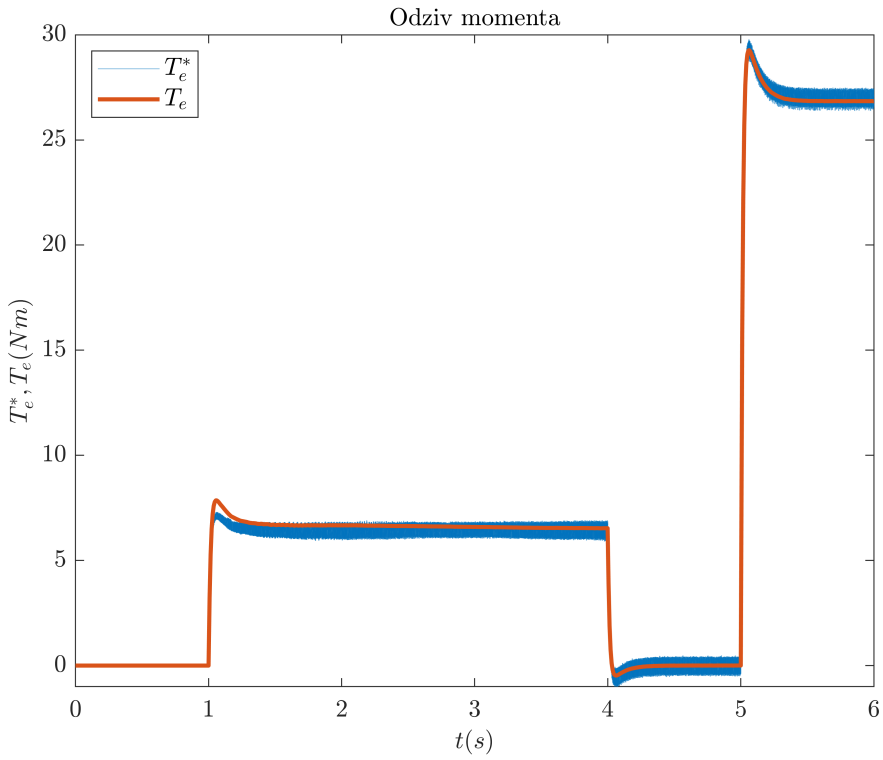

Slika 4.20: *Referentna i generirana vrijednost elektromagnetskog momenta.*

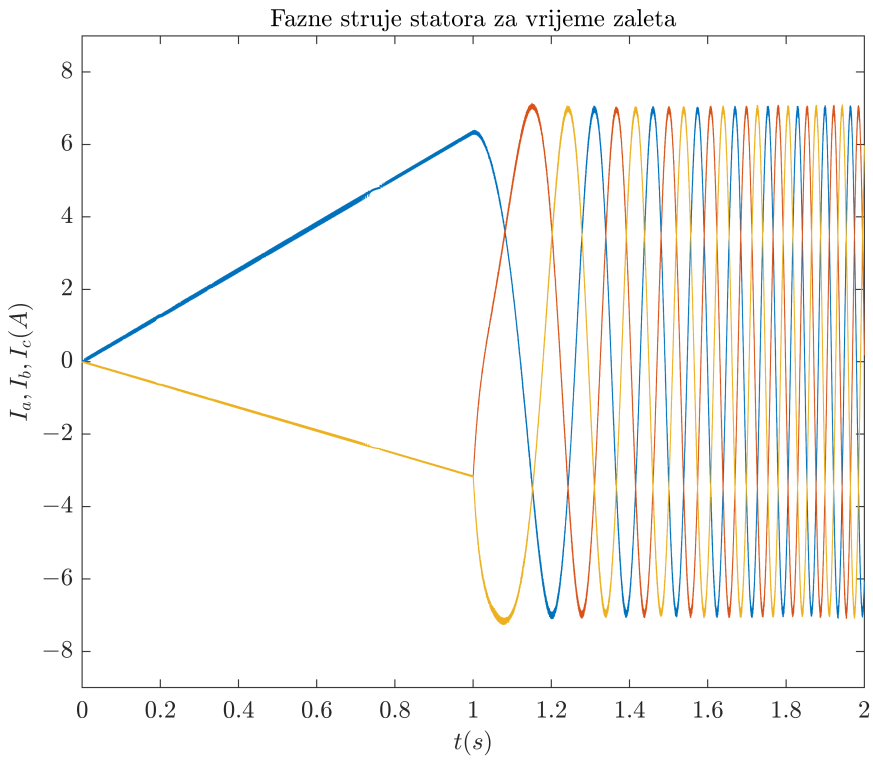

Slika 4.21: *Fazne struje statora asinkronog stroja za vrijeme zaleta.*

Metoda konačnog prediktivnog upravljanja struje je srodna predloženoj metodi. S obzirom da se u predloženoj metodi koristi modulacija napona s fiksnom frekvencijom uklapanja pre-

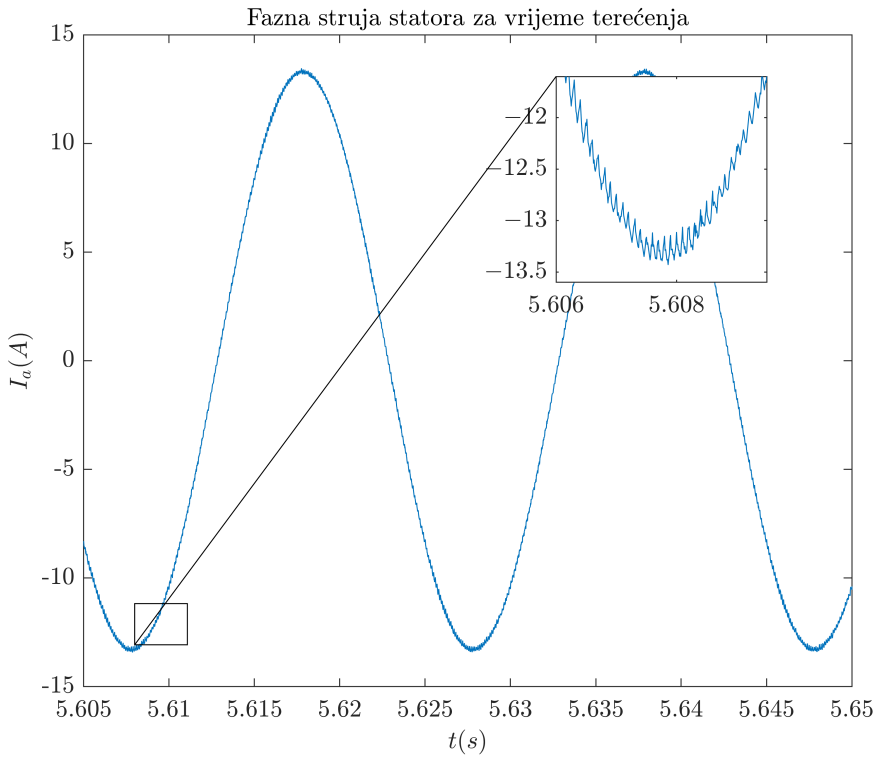

Slika 4.22: *Fazna struja statora asinkronog stroja za vrijeme terećenja.*

tvarača, trebalo bi se vidjeti poboljšanje u spektru momenta. Slika 4.23 prikazuje harmonijski sadržaj momenta na osovini motora za konačnu i kontinuiranu metodu regulacije.

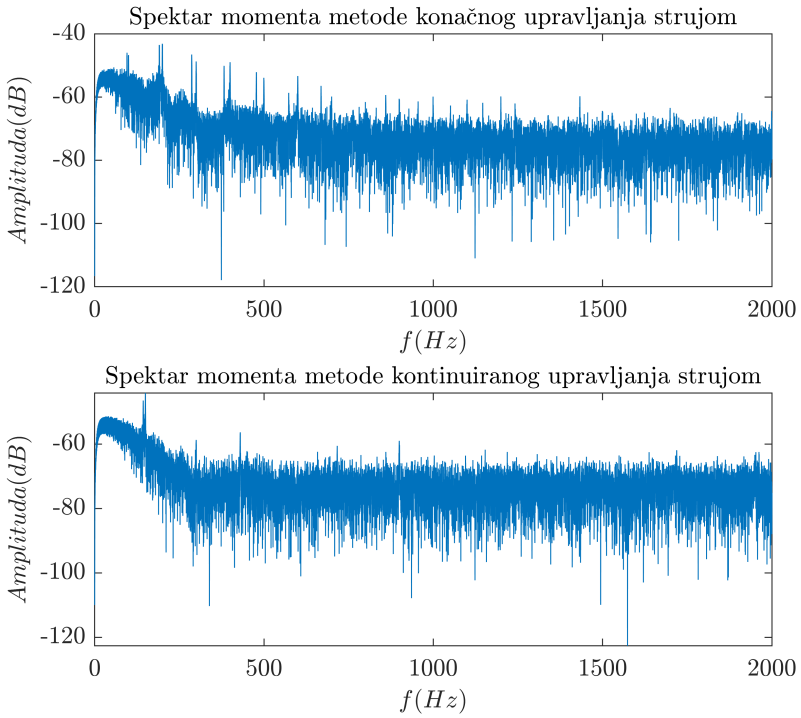

Slika 4.23: *Fourierova analiza elektromagnetskog momenta za kontinuiranu i konačnu prediktivnu metodu upravljanja strujom.*

Spektar je dobiven na način da je istosmjerna komponenta momenta filtrirana pomoću nisko propusnog filtra, a Fourierova analiza je potom primijenjena na izmjeničnu komponentu. Može se vidjeti da metoda konačne prediktivne regulacije struje ima mnogo viši harmonijski sadržaj, za razliku od metode kontinuirane regulacije. Kako bi se utjecaj viših harmonika bolje vidio, izvršena je Fourierova analiza elektromagnetskog momenta stroja pri terećenju. Slika 4.24 prikazuje harmonijski spektar momenta. Vidljivo je da se kod metode konačnog prediktivnog upravljanja strujom pojavljuju viši harmonici na svakih 100 Hz, dok ove pojave nema kod metode kontinuiranog prediktivnog upravljanja strujom.

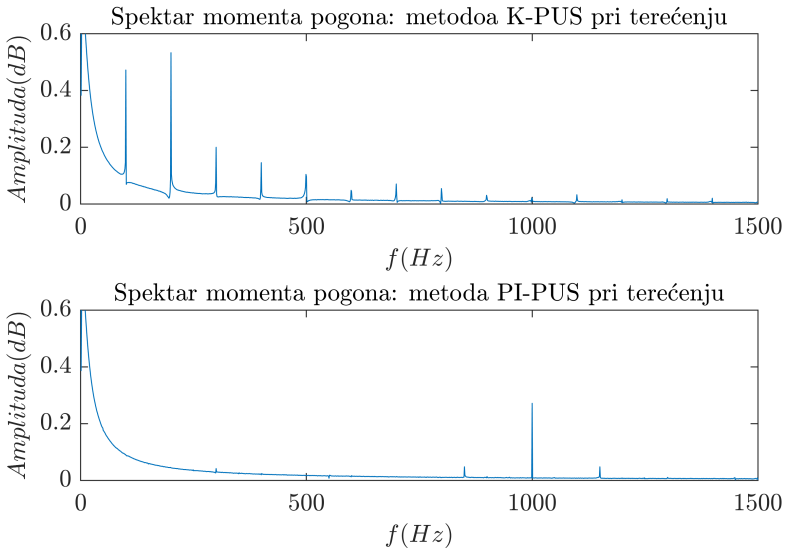

Slika 4.24: *Fourierova analiza elektromagnetskog momenta za kontinuiranu i konačnu prediktivnu metodu upravljanja strujom za vrijeme terećenja.*

Iz slika 4.23 i 4.24 je jasno da metoda kontinuirane regulacije ima mnogo manji utjecaj na osovinu stroja u vidu podrhtavanja momenta i generiranja nepoželjnih vibracija.

5. PRIMJENA KOSIMULACIJSKOG PRISTUPA U SVRHU OPTIMIRANJA NEIZRAZITOG REGULATORA BRZINE VRTNJE ASINKRONOG STROJA

5.1. Uvod u poglavlje

Metode upravljanja prostornim vektorom magnetskog toka te direktnog upravljanja momentom, predstavljene u prethodnom poglavlju, prve su i osnovne razvijene metode vektorskog upravljanja. Unatoč tome, smatraju se modernim metodama i implementirane su u mnoštvo frekvencijskih pretvarača koji se koriste u gotovo svim elektromotornim pogonima gdje se zahtjeva velika preciznost upravljanja. Ove metode naravno imaju svoje nedostatke, pa je tako u [81], pokazano kako metoda upravljanja prostornim vektorom magnetskog toka pati od osjetljivosti na promjenu parametara. U [82], autori su prikazali da metoda direktnog upravljanja momentom ima problema kod vođenja pri malim brzinama vrtnje što se manifestira kroz podrhtavanje momenta i toka. Za pogone visokih performansi, koji zahtijevaju brze dinamičke odzive i dobro vladanje pri smetnjama, ovi problemi se moraju riješiti ili se moraju razviti nove metode kod kojih ovih problema nema. Jedan od pristupa rješavanju problema je implementiranje koncepata računalne inteligencije, kao što je neizrazita logika, u postojeće konvencionalne regulacijske strukture.

Koncept neizrazite logike utemeljio je Lofti A. Zadeh u [83], 1965. godine, potaknut činjenicom da se određene veličine u različitim sustavima često ne mogu apsolutno grupirati. Na primjer, temperatura se može grupirati u kategorije *hladno* ili *toplo*, međutim, granica koja razdvaja ove dvije skupine je često subjektivna te ovisi o kontekstu ili sustavu u kojemu se pojavljuje. Može se reći da ova granica nije *izražena* i odavde pojam "neizrazito" u imenu "neizrazita logika". Kako bi se ovaj problem riješio, Zadeh predlaže koncept neiz-

razitih skupova u kojima je svakom elementu dodijeljena vrijednost pripadnosti tom skupu. Pripadnost može imati vrijednost iz intervala $[0, 1]$. Sada je temperaturu iz spomenutog primjera moguće grupirati u kategorije na način da u isto vrijeme pripada u oba skupa, ali s različitim vrijednostima pripadnosti.

Može se reći da je problem kojeg princip neizrazite logike rješava taj da postoji nesigurnost pri klasificiranju veličina određenih sustava, a alat kojim se ovaj problem rješava je funkcija pripadnosti veličine određenim klasama, odnosno neizrazitim skupovima. Pomoću ovog principa izrađuju se sustavi neizrazitog zaključivanja koji ulazne veličine klasificiraju pomoću funkcija pripadnosti te računaju vrijednost izlazne veličine. Ovakvi sustavi se zovu neizraziti sustavi tipa 1, a osnovna literatura koja daje matematičku podlogu vezanu za neizrazite skupove i njihova svojstva je [84]. Knjige kao što su [85, 86, 87] prikazuju primjene neizrazitih sustava tipa 1 u različitim sustavima upravljanja.

Daljnjim istraživanjem znanstvenici su shvatili da je moguće postojanje nesigurnosti pri tvorbi samih funkcija pripadnosti. Ovaj problem je riješen takozvanim neizrazitim sustavom tipa 2, gdje se funkciji pripadnosti uvodi devijacija pomoću koje se moguća pogreška uključuje u postupak neizrazitog odlučivanja. Knjige kao što su [88, 89, 90, 91] preporučuju se za bolje razumijevanje neizrazitih sustava tipa 2 te prikazuju njihovu primjenu u sustavima upravljanja.

Slika 5.1 prikazuje postupak obrade ulazne veličine u neizrazitom sustavu zaključivanja. Ovaj proces se sastoji od *fuzifikacije* koja realnoj ulaznoj vrijednosti dodjeljuje pripadnost definiranim neizrazitim skupovima pomoću ulaznih funkcija pripadnosti. Potom se pomoću tablice neizrazitih pravila vrši neizrazito zaključivanje, a na kraju se pomoću *defuzifikacije* neizrazita vrijednost izlazne veličine transformira u realnu vrijednost.

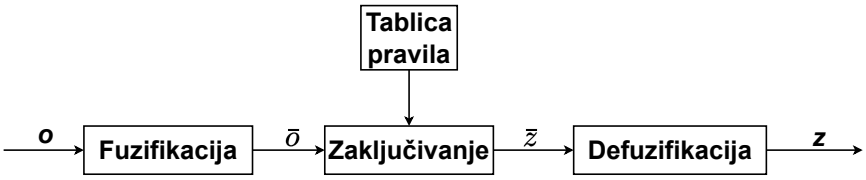

Slika 5.1: *Struktura sustava neizrazitog zaključivanja.*

Neizraziti sustavi tipa 1 i tipa 2, računalno su zahtjevni zbog procesa *defuzifikacije* pomoću kojeg se računa izlazna vrijednost sustava. Naime, osim ulaznih funkcija pripadnosti, prisutne su i izlazne funkcije pripadnosti, a proces *defuzifikacije* zahtjeva računanje presjeka ili unije površina ispod krivulja ovih funkcija. Ovi proračuni mogu biti iznimno

zahtjevni, posebno ako je broj neizrazitih skupova velik. U kontekstu regulacije, ovakvi sustavi se još nazivaju Mamdani sustavi prema autoru rada [92], gdje je ovakav sustav prvi put primijenjen za regulaciju pritiska u parnom kotlu.

Deset godina nakon što je Mamdanijev sustav prvi put spomenut, autori T. Takagi i M. Sugeno, u [93], predstavljaju sustav neizrazite logike kod kojeg izlazne funkcije pripadnosti nisu potrebne u procesu *defuzifikacije*, što uvelike smanjuje računalno opterećenje i zahtjeve kod implementacije. *Defuzifikacija* se u ovim sustavima najčešće vrši pomoću polinoma prvog stupnja, a sustavi se primjereno zovu Takagi-Sugeno sustavi.

Kako se u ovoj disertaciji neizraziti sustavi koriste u kontekstu upravljanja elektromotornih pogona, u nastavku poglavlja će se za ove sustave još koristiti termin "neizraziti regulatori". Pregledni rad [94] prikazuje rastući trend pristupa implementacije neizrazitih sustava u klasične strukture upravljanja elektromotornim pogonima, a u daljnjem tekstu prikazan je pregled novije literature koji dokazuje interes znanstvenika za implementacijom neizrazitih regulatora za vođenje pogona.

Neizrazita logika u većini slučajeva zahtjeva visoku računalnu moć, stoga u [95], autori istražuju neizrazite regulatore s niskim računalnim zahtjevima. U [96], autori implementiraju neizraziti regulator u metodu direktnog upravljanja momentom kako bi smanjili harmonijski sadržaj momenta u pogonu visokih performansi. Autori u radu [97], istražuju neizraziti regulator za vođenje pogona u režimima rada niske brzine vrtnje. U [98], autori istražuju računalne zahtjeve neizrazitog regulatora u ovisnosti o veličini tablice pravila. U [99, 100], autori istražuju neizraziti regulator tipa 2 kako bi poboljšali vladanje pogona upravljanih s petero-razinskim i tro-razinskim pretvaračem. Autori radova [101, 102] koriste neizraziti regulator kako bi poboljšali direktno upravljanje momentom asinkronog stroja te stroja s dvostrukim statorom. Autori rada [103] poboljšavaju metodu vektorskog upravljanja magnetskim poljem asinkronog stroja implementacijom neizrazitog regulatora s automatskim podešavanjem proporcionalnog pojačanja. Tir et al. koriste neizraziti regulator kako bi poboljšali upravljanje prostornog vektora magnetskog toka u pogonu s jednim motorom u [104] i u višemotornom pogonu u [105]. Bessaad et al. koriste neizraziti sustav u [106] razvoju korekcijskog regulatora u višemotornom pogonu napajanom iz jednog frekvencijskog pretvarača. Autori u [107] razvijaju algoritam pretrage za podešavanje neizrazitog regulatora asinkronog stroja. Za poboljšanje korisnosti, autori radova [108, 109], koriste neizrazitu logiku u algoritmu pretrage minimalnih gubitaka asinkronog stroja i samouzbuđenog ge-

neratora. U [110], autori koriste neizrazitu logiku za razvoj ekspertnog sustava za analizu kvarova asinkronog stroja. Autori rada [111] koriste neizraziti regulator za odabir optimalnog vektora napona petero-faznog asinkronog stroja kako bi smanjili podrhtavanje momenta. Autori rada [112] koriste neizrazitu logiku kao mehanizam odluke za odabir težinskog faktora kod metode prediktivne regulacije momentom asinkronog stroja. U radu [113], autori koriste izlaze 2 neizrazita regulatora kao ulazne varijable u algoritam linearizacije povratnom vezom kako poboljšali vladanje pogona. Saghafinia et al. koriste neizraziti regulator u [114] kao regulator brzine vrtnje u metodi regulacije klizanjem. U radu [115], autori razvijaju neizraziti regulator kojim minimiziraju ulaznu snagu asinkronog stroja, a maksimiziraju njegove performanse. U radu [116], Youb et al. razvijaju neizraziti PI regulator s automatskim podešavanjem proporcionalnog i integralnog pojačanja za asinkroni stroj s dvostrukim statorom.

Postoji mnoštvo radova u kojima se neizrazita logika koristi u svrhe procjene parametara. Autori rada [117] koriste principe neizrazite logike za izradu osmotritelja na temelju Takagi-Sugeno modela asinkronog stroja. U [118], Jabbour et al. koriste neizrazitu logiku za procjenu parametara za vrijeme rada pogona. U radu [119], autori koriste neizraziti regulator tipa 1 i tipa 2 kod osmotritelja brzine vrtnje i toka asinkronog stroja. Autori rada [120] razvijaju Luenbergerov osmotritelj koristeći neizraziti sustav čiji su izlazi procijenjene vrijednosti varijabli stanja. U starijem radu [121], autori optimiraju neizraziti sustav u svrhe procjene rotorske vremenske konstante. U [122], Shkula et al. koristi neizraziti sustav za procjenu brzine vrtnje i toka asinkronog stroja upravljanog metodom direktnog upravljanja momentom.

Neizrazita logika se koristi i u regulaciji snage i frekvencije, kao što se može vidjeti u radu [123], gdje autori koriste neizrazitu logiku za podešavanje proporcionalnog, integralnog i derivabilnog pojačanja regulatora dvostruko napajanog asinkronog stroja. U [124], autori koriste principe neizrazite logike kako bi poboljšali metodu direktnog upravljanja momentom dvostruko napajanog asinkronog stroja, dok se u [125] neizraziti regulator koristi za upravljanje radnom snagom. U [126], Dewangan et al. koriste neizraziti regulator umjesto klasičnog PI regulatora kako bi poboljšali performanse samouzbuđenog asinkronog stroja pogonjenog vjetrom za vrijeme kvara i promjenjivih prilika puhanja vjetra. Autori Pantea et al. u [127] razvijaju neizraziti regulator za šestero-fazni asinkroni stroj koji u stanjima kvara pokazuje bolje vladanje od klasičnog regulatora.

U ovom poglavlju disertacije opisana je procedura za optimizaciju parametara neizrazitog regulatora brzine vrtnje asinkronog stroja u kosimulaciji s Opal-RT stvarno-vremenskim simulatorom. Što se tiče optimizacije parametara neizrazitog regulatora, izdvojeni su sljedeći radovi koji su na tragu onoga što je u disertaciji napravljeno. U radu [128], George et al. koriste optimizacijsku proceduru kako bi dobili optimalne parametre neizrazitog regulatora za upravljanje električnim vozilom. Autori rada [129] koriste pristup optimizacije parametara neizrazitog regulatora kako bi uspješno regulirali frekvenciju velikog elektroenergetskog sustava s većim brojem elektrana. Oba prethodno navedena rada istražuju nekoliko kriterija po kojima se izvršava izračun vrijednosti funkcije cilja. U [125] autori koriste kriterij integriranja kvadratne pogreške s vremenom za izračun vrijednosti funkcije cilja i algoritam roja čestica kao optimizator regulatora snage dvostruko napajanog asinkronog stroja. Autori rada [130] optimiraju neizraziti regulator brzine vrtnje asinkronog stroja, gdje koriste prosječnu regulacijsku pogrešku brzine vrtnje kao kriterij za optimiranje parametara ulaznih i izlaznih funkcija pripadnosti.

U nastavku poglavlja detaljno je prikazana struktura neizrazitog regulatora brzine vrtnje čiji se parametri optimiraju pomoću kosimulacije sa stvarno-vremenskim simulatorom Opal-RT. Osim u disertaciji, metoda je predstavljena i u znanstvenom članku [131], gdje se optimizacija izvršava na osobnom računalu te je validirana kroz međunarodnu recenziju. Za implementaciju regulatora je korišten Takagi-Sugeno neizraziti sustav, a u poglavlju su opisane ulazne i izlazne veličine regulatora, tablica pravila te postupak optimizacije parametara regulatora. Metoda upravljanja u koju je optimirani regulator implementiran je kontinuirano prediktivno upravljanje strujom asinkronog stroja, prezentirano u 4. poglavlju. Odzivi pogona su uspoređeni s odzivima dobivenim srodnim prediktivnim metodama te su uočena određena poboljšanja.

5.2. Postupak izrade neizrazitog regulatora brzine vrtnje asinkronog stroja

Slika 5.2 prikazuje dijagram regulacije asinkronog stroja kontinuiranom metodom prediktivnog upravljanja struje, s neizrazitim regulatorom brzine vrtnje. Može se primijetiti da je dijagram vrlo sličan dijagramu sa slike 4.12 gdje se referenca momenta generira pomoću PI regulatora brzine vrtnje. U ovom poglavlju, PI regulator je zamijenjen s neizrazitim regula-

torom (NR), čije je parametre potrebno optimirati. U nastavku teksta će se za predloženu metodu iz 4. poglavlja koristiti kratica "PI-PUS", a za metodu s neizrazitim regulatorom brzine vrtnje će se koristiti kratica "N-PUS".

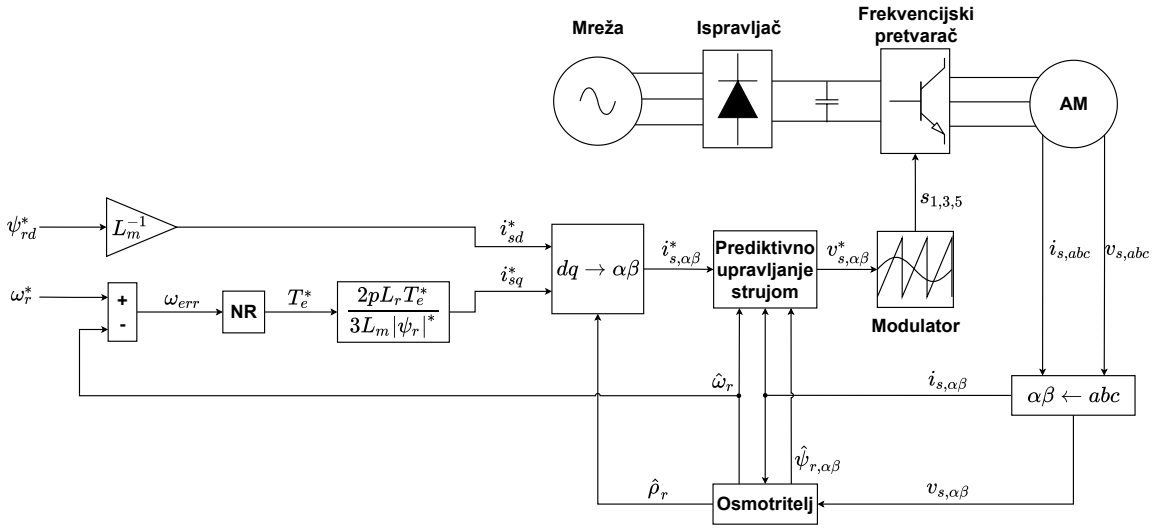

Slika 5.2: *Dijagram neizrazitog prediktivnog upravljanja asinkronog stroja.*

5.2.1. Ulaz i izlaz neizrazitog regulatora

Izabrane ulazne varijable neizrazitog regulatora su regulacijska pogreška brzine vrtnje ω_{err} i njena derivacija $\dot{\omega}_{err}$, a izlazna varijabla je neizrazita regulacijska pogreška f_{err}. Bitni vektori i skupovi koji se koriste u procesu su: realni ulazni vektor $\boldsymbol{o}$, ulazni vektor lingvističkih varijabli $\bar{\boldsymbol{o}}$ i skup ulaznih lingvističkih vrijednosti $\bar{O}_i$, gdje index i predstavlja redni broj ulazne varijable. Što se tiče izlaza, $\boldsymbol{z}$ predstavlja realni izlazni vektor, $\bar{\boldsymbol{z}}$ predstavlja izlazni vektor lingvističkih varijabli, a $\bar{Z}$ predstavlja skup izlaznih lingvističkih vrijednosti. Svi navedeni vektori i skupovi su definirani na sljedeći način:

- $\boldsymbol{o} = \begin{bmatrix} \omega_{err} & \dot{\omega}_{err} \end{bmatrix}$,
- $\bar{\boldsymbol{o}} = [$*"Regulacijska pogreška brzine" "Derivacija regulacijske pogreške brzine*$]$,
- $\bar{O}_1 = \bar{O}_2 = \{$*"Negativno Veliko", "Negativno Malo", "Nula", "Pozitivno Malo", "Pozitivno Veliko"*$\}$,
- $\boldsymbol{z} = \begin{bmatrix} f_{err} \end{bmatrix}$,
- $\bar{\boldsymbol{z}} = [$*"Neizrazita regulacijska pogreška"*$]$,
- $\bar{Z} = \{$*"Negativno", "Nula", "Pozitivno"*$\}$.

5.2.2. Ulazne funkcije pripadnosti

Funkcije pripadnosti su definirane za i-tu ulaznu lingvističku varijablu $\bar{o}_i$ i za k-tu moguću lingvističku vrijednost $\bar{O}^k$. Njihova struktura ovisi o promatranoj lingvističkoj varijabli i njenoj lingvističkoj vrijednosti. Jednadžbe (5-1)-(5-3) predstavljaju izraze funkcija pripadnosti za sve moguće kombinacije indeksa i i potencije k. Funkcije su jedinične linearne po odsječcima i definiraju se pomoću 2 parametra: a_{ik} i b_{ik}. Slika 5.3 grafički prikazuje funkcije pripadnosti i njihove parametre.

$$\mu_{\bar{O}_i^k}(o_i) = max\left[\left(1 - \left|\frac{a_{ik} - o_i}{b_{ik}}\right|\right), 0\right], \quad i \in \{1,2\}, \quad k \in \{2,3,4\} \tag{5-1}$$

$$\mu_{\bar{O}_i^k}(o_i) = \begin{cases} 1, & o_i < a_{ik} \\ 0, & o_i > b_{ik} \\ \frac{a_{ik}-o_i}{b_{ik}-a_{ik}} + 1, & a_{ik} \leq o_i \leq b_{ik} \end{cases} \quad i \in \{1,2\}, \quad k = 1 \tag{5-2}$$

$$\mu_{\bar{O}_i^k}(o_i) = \begin{cases} 0, & o_i < a_{ik} \\ 1, & o_i > b_{ik} \\ \frac{o_i-a_{ik}}{b_{ik}-a_{ik}}, & a_{ik} \leq o_i \leq b_{ik} \end{cases} \quad i \in \{1,2\}, \quad k = 5 \tag{5-3}$$

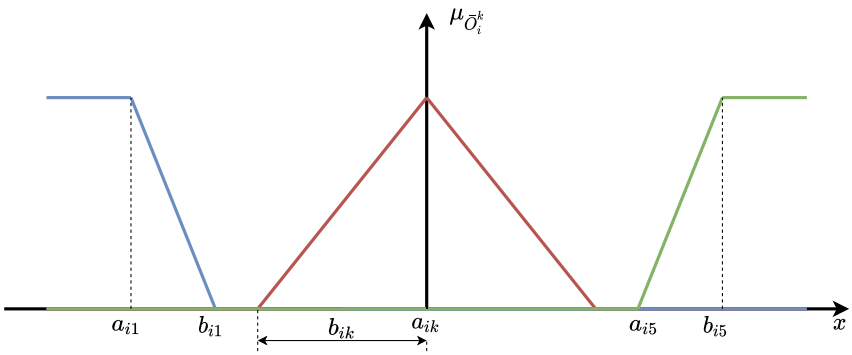

Slika 5.3: *Prikaz funkcija pripadnosti i njihovih parametara.*

Zahvaljujući tome što se funkcije pripadnosti definiraju pomoću samo 2 parametra, olakšana je njihova implementacija, a ova činjenica može se iskoristiti i u optimizaciji neizrazitog regulatora, što će biti objašnjeno u narednom tekstu. Idući korak je generiranje izlaza regulatora koristeći neizrazito zaključivanje i proces defuzifikacije.

5.2.3. Neizrazito zaključivanje

Kod neizrazitog zaključivanja potrebno je konstruirati tablicu neizrazitih pravila, a u području regulacije, najčešće se prate zadane konvencije prikazane u tablici 1 u [98] ili tablici 2 u [128], gdje je broj ulaznih i izlaznih lingvističkih vrijednosti u skupovima $\bar{O}_i$ i $\bar{Z}$ jednak. Kod predložene metode ova praksa se neće primijeniti zato što ulazni skup lingvističkih vrijednosti sadrži 5 elemenata, a izlazni 3. Skupovi su definirani na ovaj način kako bi se smanjio broj varijabli odluke u optimizacijskoj proceduri te ubrzao proces izračuna. Tablica 5.1 je tablica neizrazitih pravila koji se koriste za proces neizrazitog zaključivanja u predloženoj metodi. Lingvističke vrijednosti su predstavljene skraćenicama: N-Negativno, P-Pozitivno, N^0-Nula, V^--Negativno Veliko, M^--Negativno Malo, M^+-Pozitivno Malo i V^+-Pozitivno Veliko. Pravila se čitaju na sljedeći način: „Ako je regulacijska pogreška brzine negativno velika i njena derivacija negativno velika, onda je neizrazita pogreška negativna“ itd.

Tablica 5.1: *Tablica neizrazitih pravila.*

$\bar{o}_2^m$ \ $\bar{o}_1^n$	V^-	M^-	N^0	M^+	V^+
V^-	N	N	N	N	N^0
M^-	N	N	N	N^0	P
N^0	N	N	N^0	P	P
M^+	N	N^0	P	P	P
V^+	N^0	P	P	P	P

$\bar{Z}_{nm}, \quad n, m \in [1, 5]$

Koristeći tablicu 5.1, moguće je konstruirati matricu težinskih faktora pravila $\boldsymbol{W}$, prikazanu jednadžbom (5-4) te izračunati njene elemente koristeći jednadžbu (5-5). Ova matrica koristi se za računanje izlazne vrijednosti u procesu defuzifikacije.

$$\boldsymbol{W} = \begin{bmatrix} w_{11} & \dots & w_{1m} \\ \vdots & \ddots & \vdots \\ w_{n1} & \dots & w_{nm} \end{bmatrix} \tag{5-4}$$

$$w_{nm} = min(\mu_{\bar{O}_1^n}(o_1), \mu_{\bar{O}_2^m}(o_2)), \quad n, m \in [1, 5] \tag{5-5}$$

5.2.4. Defuzifikacija

Defuzifikacija je posljednji korak pri dobivanju izlazne vrijednosti neizrazitog regulatora. U predloženoj metodi koristi se Takagi-Sugeno pristup jer ga je jednostavno implementirati za razliku od Mamdani pristupa, a nije računalno zahtjevan. Implementira se na način da se formira matrica razine pravila $\boldsymbol{H}$ prikazana jednadžbom (5-6). Elementi matrice $\boldsymbol{H}$ računaju se pomoću jednadžbe (5-7). Ova jednadžba je formirana za svaki element u matrici $\boldsymbol{H}$ i njeni koeficijenti ovise o izlaznoj lingvističkoj vrijednosti $\bar{Z}_{nm}$ koja je definirana tablicom 5.1.

$$\boldsymbol{H} = \begin{bmatrix} h_{11} & \dots & h_{1m} \\ \vdots & \ddots & \vdots \\ h_{n1} & \dots & h_{nm} \end{bmatrix} \tag{5-6}$$

$$\begin{gathered} h_{nm} = c_{nm}o_1 + d_{nm}o_2 + e_{nm} \\ c_{nm} = \begin{cases} c_N, & \bar{Z}_{nm} = N \\ c_{N^0}, & \bar{Z}_{nm} = N^0 \\ c_P, & \bar{Z}_{nm} = P \end{cases} \quad d_{nm} = \begin{cases} d_N, & \bar{Z}_{nm} = N \\ d_{N^0}, & \bar{Z}_{nm} = N^0 \\ d_P, & \bar{Z}_{nm} = P \end{cases} \quad e_{nm} = \begin{cases} e_N, & \bar{Z}_{nm} = N \\ e_{N^0}, & \bar{Z}_{nm} = N^0 \\ e_P, & \bar{Z}_{nm} = P \end{cases} \\ n, m \in [1, 5] \end{gathered} \tag{5-7}$$

Izlaz z neizrazitog regulatora računa se pomoću matrica $\boldsymbol{W}$ i $\boldsymbol{H}$ kako je prikazano jednadžbom (5-8).

$$z = \frac{\sum_{i=n}^{5} \sum_{m=1}^{5} w_{nm} h_{nm}}{\sum_{i=n}^{5} \sum_{m=1}^{5} w_{nm}} \tag{5-8}$$

Konačna topologija neizrazitog regulatora prikazana je na slici 5.4. Može se primijetiti da postoje još 4 dodatna parametra: B_e i B_{ce} koje služe kao bazne vrijednosti za skaliranje ulaznih vrijednosti regulatora, s obzirom da su ulazne funkcije pripadnosti jedinične i linearne po odsječcima. K_{Pf} i K_{If} su proporcionalna i integralna pojačanja koja djeluju na izlaznu neizrazitu regulacijsku pogrešku koja je zapravo izlaz regulatora.

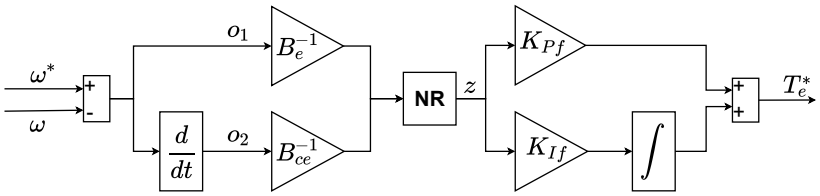

Slika 5.4: *Topologija neizrazitog regulatora.*

Iz slike 5.2, može se vidjeti da neizraziti regulator služi kao regulator brzine koji generira referentnu vrijednost momenta, a implicitno generira i vrijednost β komponente struje statora putem skaliranja i transformacije koordinatnog sustava, kao što se vidi iz dijagrama regulacije na slici 5.2. Uzimajući u obzir ulazne funkcije pripadnosti, izlazne funkcije i bazne vrijednosti te pojačanja regulatora, postoji 33 parametra, prikazanih vektorom $\boldsymbol{\theta}$ u izrazu (5-9), koje je potrebno ugoditi kako bi se pogonom moglo ispravno upravljati. Vektor $\boldsymbol{\theta}$ se još naziva i vektor varijabli odluke koji s koristi u optimizaciji neizrazitog regulatora, čiji je proces objašnjen u narednom potpoglavlju.

$$\begin{aligned}\boldsymbol{\theta} &= [a_{11} \dots a_{ik},\ b_{11} \dots b_{ik},\ c_N,\ c_{N^0},\ c_P,\ d_N,\ d_{N^0},\ d_P,\ e_N,\ e_{N^0},\ e_P,\ B_e,\ B_{ce},\ K_{Pf},\ K_{If}] \\ &= [\theta_1,\ \theta_2,\ \dots,\ \theta_{33}], \quad k \in [1,5],\ i \in \{1,2\}\end{aligned} \tag{5-9}$$

5.3. Optimizacija neizrazitog regulatora

U predloženoj metodi, neizraziti regulator služi kao regulator brzine vrtnje koji generira referencu momenta za prediktivno upravljanje strujom asinkronog stroja. Moment se treba pravovremeno mijenjati kako bi se smanjila regulacijska pogreška brzine vrtnje te kako bi nadvišenje momenta bilo minimalno da se osovina rotora što manje napreže. Da bi se ovi zahtjevi postigli, potrebno je izračunati optimalne parametre neizrazitog regulatora. Neizraziti regulator je definiran velikim brojem parametara te da bi se našla njihova optimalna kombinacija, pristupa se optimizacijskoj proceduri. Parametri koje optimizacijska procedura generira, ovise o kriteriju korištenom za izračun vrijednosti funkcije cilja, a iz istraživanja je vidljivo da različiti kriteriji optimizacije uvelike utječu na odzive asinkronog stroja. Cilj je naći ispravan kriterij za izračun vrijednosti funkcije cilja pomoću kojeg se generiraju optimalne vrijednosti parametara koji daju najbolje performanse pogona.

Optimizacija se vrši u kosimulaciji s Opal-RT stvarno-vremenskim simulatorom, a slika

5.5 prikazuje detalje kosimulacije: optimizator je implementiran u Matlab okruženju te generira vektor varijabli odluke, odnosno parametara regulatora $\boldsymbol{\theta}^j$. Simulacija pogona, koja se izvršava na Opal-RT stvarno-vremenskom simulatoru, prima ove parametre i računa vrijednost funkcije cilja $f(\boldsymbol{\theta}^j)$ iz odziva brzine vrtnje i momenta stroja. Ova vrijednost se šalje nazad u optimizator koji generira novi vektor varijabli odluke. Ovaj proces se ponavlja dok se ne zadovolji kriterij koji stopira optimizaciju. Komunikacija između simulatora i optimizatora je realizirana pomoću Opal API-ja implementiranog u Python programskom jeziku.

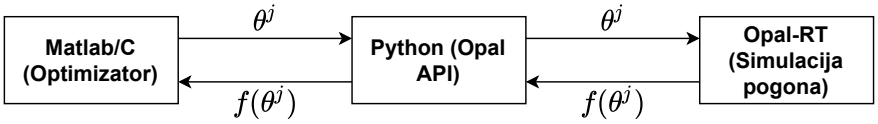

Slika 5.5: *Kosimulacija: MIDACO $\longleftrightarrow$ Matlab/Simulink.*

Detalji o funkciji cilja, varijablama odluke i samom optimizatoru su navedeni u nastavku teksta

5.3.1. Funkcija cilja

Kako bi se parametri neizrazitog regulatora optimirali, istraženo je nekoliko kriterija za izračun vrijednosti funkcija cilja, a onaj kriterij koji je davao najbolje rezultate (minimalna regulacijska pogreška brzine vrtnje i najmanje nadvišenje momenta), pobliže je analiziran. Kriteriji su sljedeći: Integrirana apsolutna pogreška (f_{IAE}), integrirana kvadratna pogreška (f_{ISE}), integrirana apsolutna pogreška s vremenom (f_{ITAE}) te integrirana kvadratna pogreška s vremenom (f_{ITSE}). Ovi kriteriji prikazani su jednadžbom (5-10), gdje $\boldsymbol{\theta}$ predstavlja vektor varijabli odluke.

$$\begin{aligned}
f_{IAE} &= f_1(\omega_{err}(\boldsymbol{\theta})) = \int_0^\infty |\omega_{err}(\boldsymbol{\theta})|\, dt \\
f_{ISE} &= f_2(\omega_{err}(\boldsymbol{\theta})) = \int_0^\infty \omega_{err}^2(\boldsymbol{\theta})\, dt \\
f_{ITAE} &= f_3(\omega_{err}(\boldsymbol{\theta})) = \int_0^\infty |\omega_{err}(\boldsymbol{\theta})|\, t\, dt \\
f_{ITSE} &= f_4(\omega_{err}(\boldsymbol{\theta})) = \int_0^\infty \omega_{err}^2(\boldsymbol{\theta})\, t\, dt
\end{aligned} \tag{5-10}$$

$\omega_{err}(\boldsymbol{\theta})$ predstavlja regulacijsku pogrešku brzine vrtnje dobivenu izrazom (5-11). Svi odzivi su dobiveni putem simulacije elektromotornog pogona koja se izvršava na Opal-RT

stvarno-vremenskom simulatoru. Bitno je napomenuti da se u implementiranom modelu pogona korištenom za optimizaciju, model pretvarača i modulatora izbacio, kako bi se optimizacijska procedura što više ubrzala. Osim toga simulacija nije izvršavana u stvarnom vremenu već u najbržem mogućem načinu rada. Parametri simulacije i asinkronog stroja korišteni u optimizaciji su prikazani u tablici 5.2.

$$\omega_{err}(\boldsymbol{\theta}) = \omega_r^* - \omega_r(\boldsymbol{\theta}) \tag{5-11}$$

Dinamika simuliranog pogona prikazana je na slici 5.6. Na slici se može vidjeti da je referentna brzina vrtnje linearna funkcija koja raste od 0 do 1433 min^{-1} u vremenu od dvije sekunde, počevši od 0.2 sekunde simulacije. Nazivni moment tereta od 27 Nm opterećuje osovinu u trećoj sekundi simulacije i ostaje konstantan do kraja simulacije. Prikazan je i profil elektromagnetskog momenta stroja potrebnog za savladavanje dinamike, izračunatog na temelju referentne brzine vrtnje i momenta tereta koristeći jednadžbu (5-12).

Tablica 5.2: *Parametri asinkronog stroja i simulacije.*

Parametar		**Vrijednost**
Otpor statora	R_s (Ω)	1.1507
Otpor rotora	R_r (Ω)	1.0107
Induktivitet statora	L_s (H)	0.1315
Induktivitet rotora	L_r (H)	0.1315
Međuinduktivitet	L_m (H)	0.126
Broj pari polova	p	2
Moment inercije	J (kgm^2)	0.129
Vremenski korak simulacije	T_s (s)	10^{-5}

$$T_e = J\frac{\mathrm{d}}{\mathrm{d}t}\omega_r^* + T_l \tag{5-12}$$

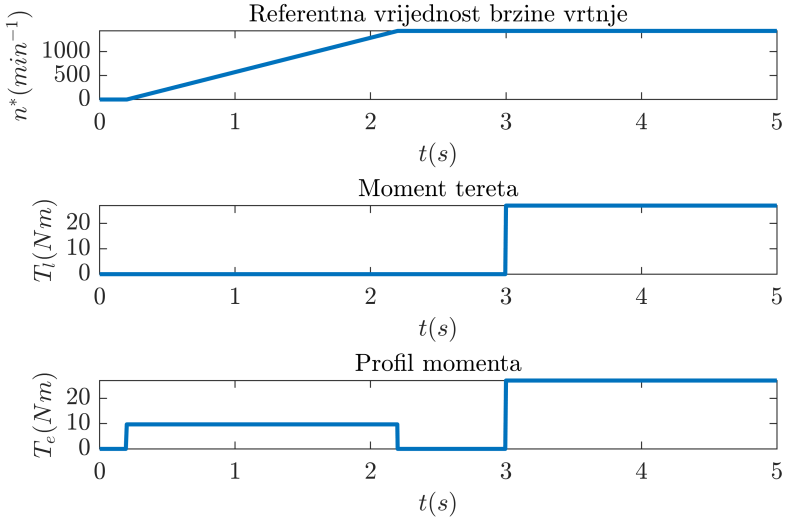

Slika 5.6: *Dinamika pogona*

Ako se profil potrebnog elektromagnetskog momenta detaljno promotri, može se zaključiti da se pojava nadvišenja momenta može očekivati u trenutku početka zaleta (*OS1*), kraja zaleta (*OS2*) te u trenutku terećenja (*OS3*). Ukupno nadvišenje računa se prema jednadžbi (5-13) i koristi se za formiranje još jednog skupa kriterija za izračun vrijednosti funkcije cilja, prikazanog jednadžbama u izrazu (5-14), gdje w predstavlja težinski faktor.

$$f_{OS} = |OS1| + |OS2| + |OS3| \tag{5-13}$$

$$\begin{aligned} f_{IAE+OS} &= f_5(\omega_{err}(\boldsymbol{\theta})) = f_1(\omega_{err}(\boldsymbol{\theta})) + w \cdot f_{OS} \\ f_{ISE+OS} &= f_6(\omega_{err}(\boldsymbol{\theta})) = f_2(\omega_{err}(\boldsymbol{\theta})) + w \cdot f_{OS} \\ f_{ITAE+OS} &= f_7(\omega_{err}(\boldsymbol{\theta})) = f_3(\omega_{err}(\boldsymbol{\theta})) + w \cdot f_{OS} \\ f_{ITSE+OS} &= f_8(\omega_{err}(\boldsymbol{\theta})) = f_4(\omega_{err}(\boldsymbol{\theta})) + w \cdot f_{OS} \end{aligned} \tag{5-14}$$

Jednadžba (5-15) predstavlja optimalan vektor varijabli odluke $\boldsymbol{\theta}_i^{opt}$, koji je dobiven minimizacijom funkcija cilja pomoću ranije predstavljenih kriterija, gdje S predstavlja granice prostora pretrage, a indeks i predstavlja redni broj kriterija koji se koristi u optimizacijskom postupku. U narednom tekstu, objašnjen je postupak izbora varijabli odluke i njihove granice.

$$\boldsymbol{\theta}_i^{opt} = \underset{\boldsymbol{\theta} \in S \subset \mathbb{R}}{argmin}[f_i(\omega_{err}(\boldsymbol{\theta}))], \quad i \in [1, 8]$$
$$S \in [\boldsymbol{\theta}^{min}, \boldsymbol{\theta}^{max}] \tag{5-15}$$

5.3.2. Varijable odluke

Parametri neizrazitog regulatora (parametri funkcija pripadnosti, izlaznih funkcija, baznih vrijednosti i pojačanja) čine vektor varijabli odluke, kao što je prikazano u jednadžbi (5-9). Određena pojednostavljenja se mogu donijeti na temelju kojih je moguće smanjiti broj elemenata vektora varijabli odluke: regulator mora imati jednaku apsolutnu vrijednost odziva za negativne i pozitivne ulazne vrijednosti. To znači da nije potrebno definirati sve funkcije pripadnosti, već samo one koje pripadaju pozitivnom dijelu lingvističkih vrijednosti, a suprotne vrijednosti parametara se mogu koristiti za negativne lingvističke vrijednosti. Ovime se broj parametara vezanih za funkcije pripadnosti reducira s 20 na 10. Isto vrijedi i za izlazne funkcije. Koeficijenti c_{N^0}, d_{N^0} i e_{N^0} iz jednadžbe (5-7) se mogu postaviti na vrijednost 0, a samo koeficijenti vezani za pozitivne lingvističke varijable ulaze u vektor varijabli odluke. Ovime se broj parametara vezanih za izlazne funkcije smanji s 9 na 3. Ovim zaključivanjem se ukupan broj elemenata u vektoru varijabli odluke smanjio s 33 na 17. Tablica 5.3 prikazuje limite prostora pretrage za svaki element.

Tablica 5.3: *Prostor pretrage optimizacije.*

Parametar	**Vrijednost** ($\boldsymbol{\theta}^{min}$)	**Vrijednost** ($\boldsymbol{\theta}^{max}$)
a_{ik}, b_{ik}	0	1
c_P, d_P,e_P	0	100
B_e, B_{ce}	0.000001	10000
K_{Pf}	0	10000
K_{If}	0	100000

5.3.3. MIDACO optimizator

Za optimizaciju neizrazitog regulatora koristi se MIDACO (*Mixed Integer Distributed Ant Colony Optimization*) optimizator, koji je temeljen na jednom od mnogih metaheurističkih metoda za traženje globalnog optimuma. Optimizator je prvi puta korišten u svrhe optimizacije putanje svemirske letjelice od Zemlje prema Jupiteru [132]. Izabran je jer se lako

koristi i dobro radi s velikim brojem varijabli odluke, a s obzirom da je implementiran u Matlab programskom okruženju, lako se koristi za potrebe kosimulacije s drugim sustavima. Optimizator nudi mnogo opcija, međutim jedine nužne opcije su vektor vrijednosti varijabli odluke za početak pretrage te ograničenja vrijednosti istih.

5.4. Rezultati optimizacije

U ovom potpoglavlju predstavljeni su rezultati optimizacije dobiveni različitim kriterijima za izračun vrijednosti funkcije cilja. Istražen je veći broj kriterija jer je poznato da optimalne vrijednosti parametara regulatora mogu varirati u ovisnosti o kriteriju koji je korišten za optimizaciju. Ovisno o parametrima regulatora, mijenjaju se i dinamički odzivi sustava te je cilj ocijeniti najbolji odziv i na temelju njega zaključiti koji kriterij je najadekvatniji za optimizaciju. U nastavku su predstavljeni kriteriji iz jednadžbi (5-10), (5-13) i (5-14). Slika 5.7 prikazuje odzive momenta i regulacijske pogreške brzine vrtnje koji su dobiveni kriterijima iz jednadžbe (5-10). Može se zaključiti da dinamika sustava skoro pa ni nema utjecaj na regulacijsku pogrešku brzine vrtnje, s obzirom da maksimalna pogreška iznosi samo 0.2 min^{-1} i ima brzo vrijeme ustaljenja. Promatrajući odziv momenta vidi se da postoji neprihvatljivo nadvišenje od 20 Nm. Razlog tome je taj što je kriterij za optimizaciju bila samo regulacijska pogreška brzine vrtnje. Kako bi se ova pogreška minimizirala, visoko regulacijsko djelovanje je potrebno svaki put kada bi brzina divergirala od referentne vrijednosti. S obzirom da kriterij ne sadrži nikakav član koji bi djelovao na smanjenje momenta, parametri dobiveni optimizacijom dopuštaju ovakvo djelovanje. Kako bi se ovaj problem riješio, upotrijebljena je višeciljna, konkretno dvociljna optimizacija. Ova vrsta optimizacije je specifična po tome što nema jedinstvenog optimalnog rješenja, već se uvodi termin "Pareto pročelje" iz kojeg se može odabrati jedno od mnogih mogućih rješenja optimizacije. Prva funkcija cilja je izabrana kao f_{ISE} iz jednadžbe (5-10), a druga ukupno nadvišenje iz jednadžbe (5-13). Slika 5.8 prikazuje rezultate ove optimizacije u obliku pareto pročelja, gdje x-os predstavlja vrijednost funkcije f_{ISE}, a y-os predstavlja ukupno nadvišenje.

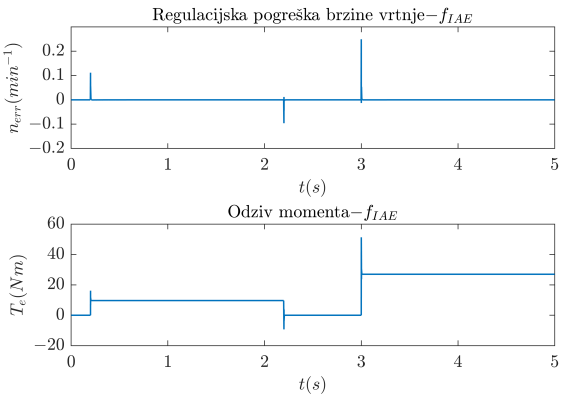

(a) *Odzivi regulacijske pogreške brzine i momenta za f_{IAE} kriterij.*

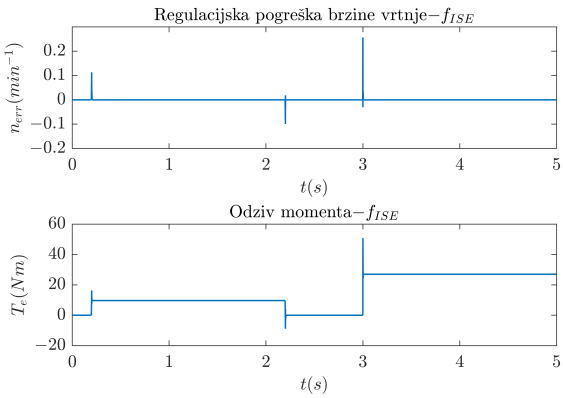

(b) *Odzivi regulacijske pogreške brzine i momenta za f_{ISE} kriterij.*

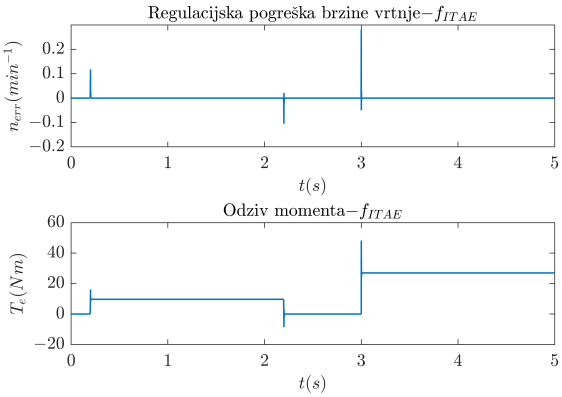

(c) *Odzivi regulacijske pogreške brzine i momenta za f_{ITAE} kriterij.*

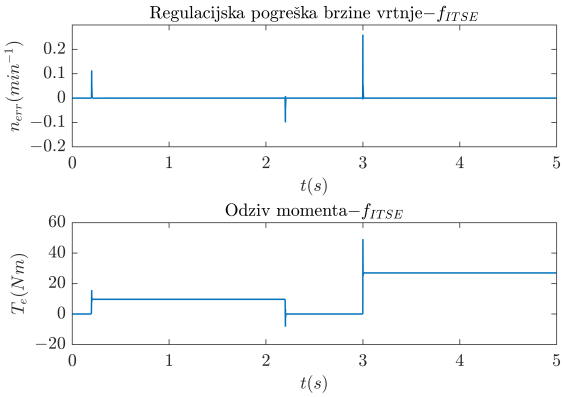

(d) *Odzivi regulacijske pogreške brzine i momenta za f_{ITSE} kriterij.*

Slika 5.7: *Odzivi regulacijske pogreške brzine vrtnje i momenta generiranih različitim kriterijima: (**a**) Integrirana apsolutna greška. (**b**) Integrirana kvadratna greška. (**c**) Integrirana apsolutna greška s vremenom. (**d**) Integrirana kvadratna greška s vremenom.*

Rezultat je spektar rješenja predstavljen kružićima na grafu, koji se mogu izabrati ovisno o tome kakvo je vladanje pogona poželjno. Zeleni šesterokut na slici je područje na pareto pročelju u kojemu je optimizator pronašao rješenje, a slika 5.9 predstavlja odziv sustava dobivenih s optimalnim parametrima iz čega je vidljivo da se nadvišenje momenta znatno smanjilo.

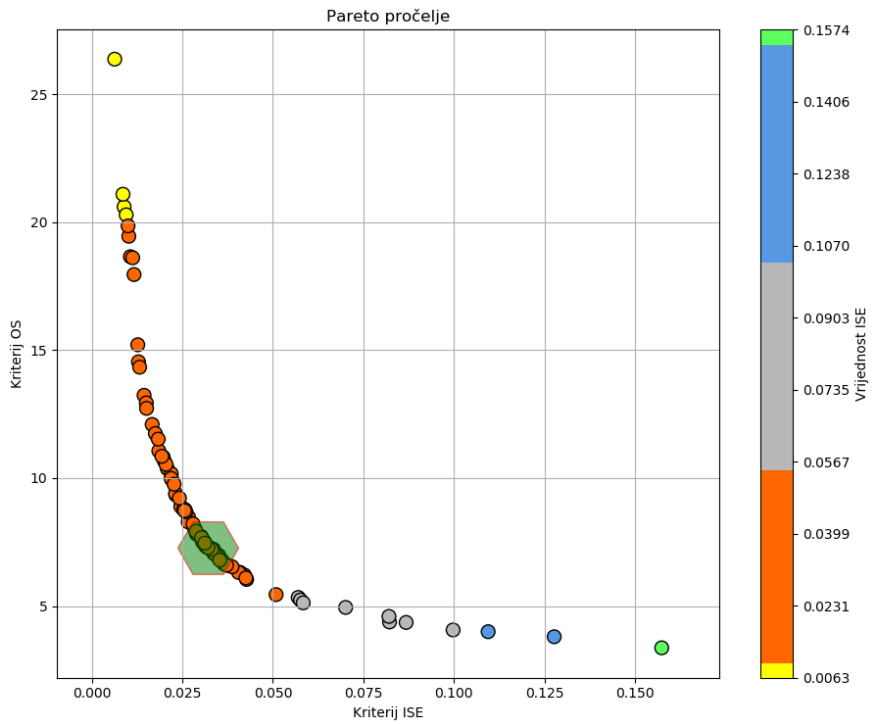

Slika 5.8: *Pareto pročelje višeciljne optimizacije.*

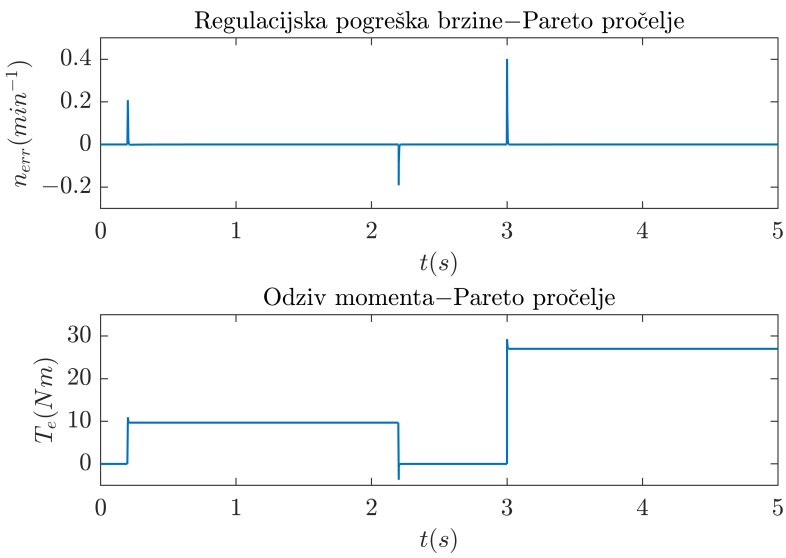

Slika 5.9: *Odzivi sustava koristeći rješenje iz pareto pročelja.*

Kako bi se dobilo jedinstveno rješenje koje generira još bolje odzive, istraženi su kriteriji iz jednadžbe (5-14). Slika 5.10 prikazuje odzive momenta i regulacijske pogreške brzine vrtnje dobivenim pomoću kriterija iz jednadžbe (5-14), gdje je iznos težinskog faktora w jednak 10. Može se vidjeti da je nadvišenje momenta potpuno reducirano, a odziv regulacijske pogreške brzine vrtnje je i dalje prihvatljiv.

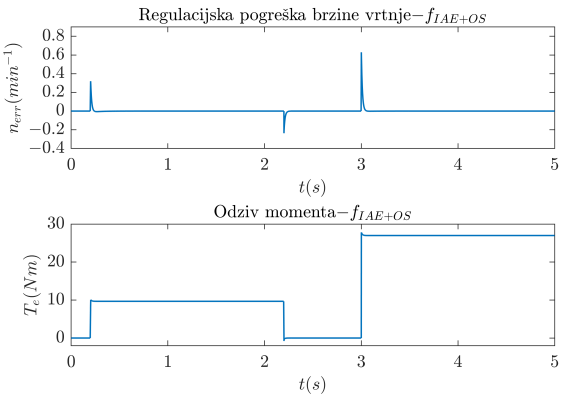

(a) *Odzivi regulacijske pogreške brzine i momenta za f_{IAE+OS} kriterij.*

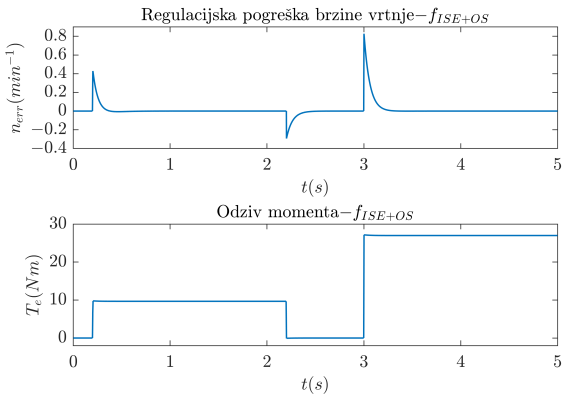

(b) *Odzivi regulacijske pogreške brzine i momenta za f_{ISE+OS} kriterij.*

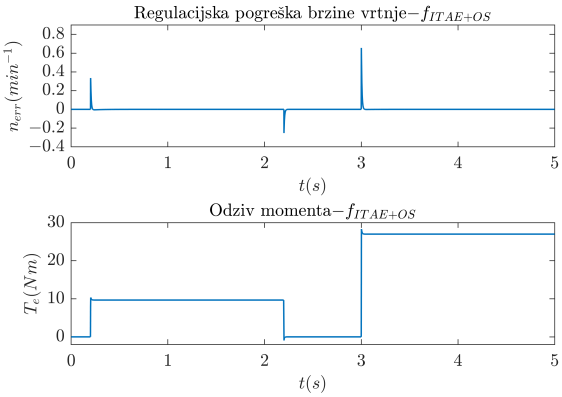

(c) *Odzivi regulacijske pogreške brzine i momenta za $f_{ITAE+OS}$ kriterij.*

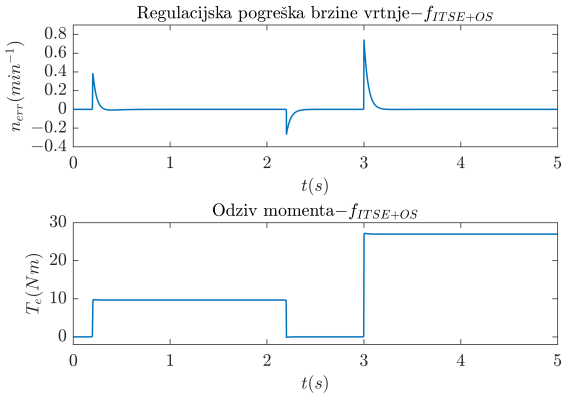

(d) *Odzivi regulacijske pogreške brzine i momenta za $f_{ITSE+OS}$ kriterij.*

Slika 5.10: *Odzivi regulacijske pogreške brzine vrtnje i momenta generiranih različitim kriterijima s penalizacijom nadvišenja: (**a**) Integrirana apsolutna greška s nadvišenjem. (**b**) Integrirana kvadratna greška s nadvišenjem. (**c**) Integrirana apsolutna greška s vremenom i nadvišenjem. (**d**) Integrirana kvadratna greška s vremenom s nadvišenjem.*

Ukupno je odrađeno 9 optimizacijskih procedura s 9 različitih kriterija izračuna vrijednosti funkcije cilja. Tablica 5.4 numerički prikazuje sve bitne vrijednosti za vrednovanje ovih kriterija.

Tablica 5.4: *Rezultati optimizacija.*

Optimizacijska procedura	Kriterij u funkciji cilja	$T_{e,max}$ (Nm)	$n_{err,max}$ (min^{-1})
1	f_{IAE}	24.34	0.25
2	f_{ISE}	23.80	0.26
3	f_{ITAE}	21.28	0.28
4	f_{ITSE}	22.23	0.26
5 (višeciljno)	$f_1 = f_{ISE},\ f_2 = f_{OS}$	2.28	0.40
6	f_{IAE+OS}	0.84	0.63
7	f_{ISE+OS}	0.20	0.83
8	$f_{ITAE+OS}$	1.34	0.66
9	$f_{ITSE+OS}$	0.24	0.75

Može se zaključiti da jednociljne optimizacije dobivene kriterijima iz izraza (5-14) polučuju najbolje rezultate jer imaju minimalno nadvišenje momenta, a brzina vrtnje je i dalje zadržana ispod 1 min^{-1}. Kriterij koji će dalje biti analiziran odabran je prema tablici 5.5, koja prikazuje vrijednosti funkcije cilja na kraju optimizacije za svaki od ovih kriterija.

Tablica 5.5: *Vrijednosti funkcija cilja za različite kriterije.*

Optimizacijska procedura	Vrijednost funkcije cilja
f_{IAE+OS}	34.73
f_{ISE+OS}	7.43
$f_{ITAE+OS}$	48.33
$f_{ITSE+OS}$	11.09

Iz tablice se vidi da kriterij f_{ISE+OS} daje malo najbolji rezultat, stoga je on daljnje analiziran. Slika 5.11 daje prikaz optimiranih funkcija pripadnosti, a tablica 5.6 prikazuje optimalne bazne vrijednosti, pojačanja i parametre izlaznih funkcija.

Tablica 5.6: *Optimalne vrijednosti pojačanja i koeficijenata izlaznih funkcija.*

Parametar	Vrijednost
B_e	6049.6
B_{ce}	3212.6
K_{Pf}	6076.7
K_{If}	98680.5
c_P	77.5
d_P	51.66
e_P	94.78

Bitno je napomenuti da koeficijenti c_N, d_N i e_N imaju suprotne vrijednosti od njihovih pozitivnih pandana.

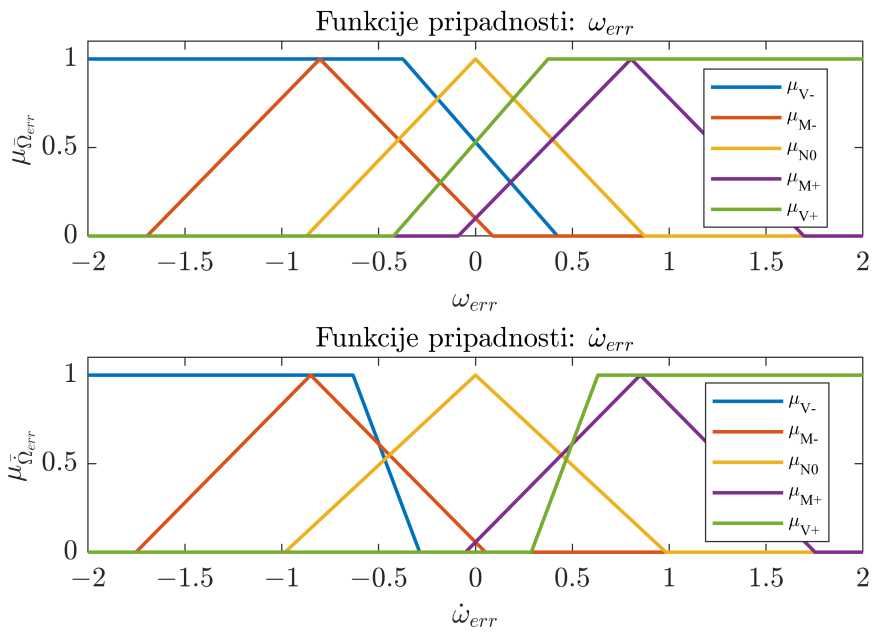

Slika 5.11: *Ulazne funkcije pripadnosti dobivene optimizacijom.*

5.5. Performanse pogona

U ovom potpoglavlju prikazani su rezultati simulacije pogona s uključenim modelima pretvarača i modulatora. Parametri regulatora su optimalni parametri dobiveni pomoću f_{ISE+OS} kriterija. Slika 5.12 prikazuje implementaciju simulacije pogona u Simulinku, a opterećenje jezgre stvarno-vremenskog simulatora za izvršavanje ove simulacije iznosi 23,61 %.

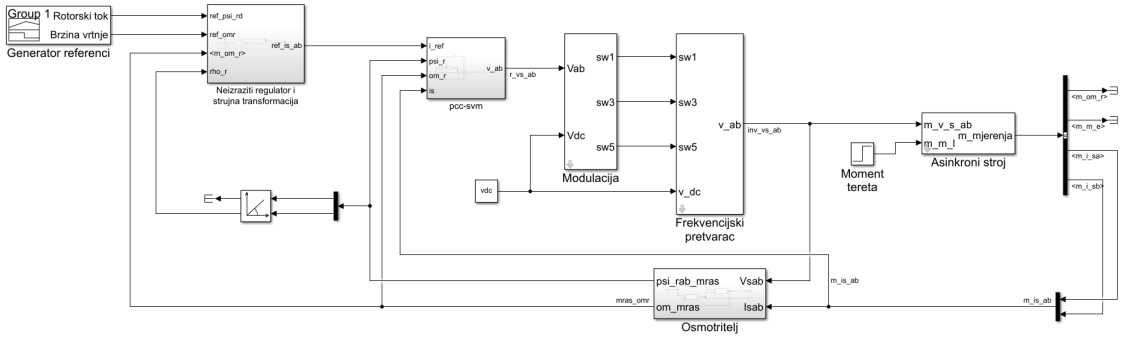

Slika 5.12: *Implementacija simulacije pogona u Simulinku.*

Iz slike 5.13a može se vidjeti da optimirani regulator generira malu regulacijsku pogrešku brzine vrtnje od samo 2 min^{-1}, ali i dalje ima visoko nadvišenje momenta u trenutku terećenja sustava. Ovaj problem se lako može riješiti smanjenjem proporcionalnog i integralnog pojačanja regulatora. Slika 5.13b prikazuje odzive sustava s reduciranim pojačanjima, u ovom slučaju $K_{Pf} = 500$ i $K_{If} = 4000$. Može se vidjeti kako je nadvišenje momenta jako smanjeno, s malim negativnim utjecajem na brzinu vrtnje, ali i dalje veoma dobrim vladanjem od samo 10 min^{-1} maksimalne regulacijske pogreške. U sljedećem poglavlju izvršit će se usporedba predložene metode s nekoliko drugih metoda temeljene na prediktivnom upravljanju.

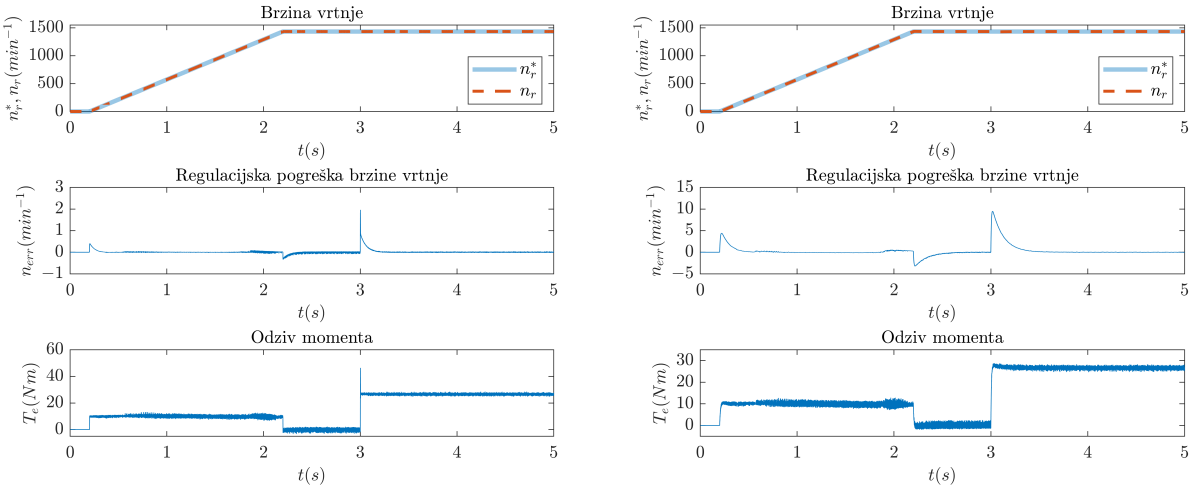

(a) *Odzivi sustava s originalnim optimalnim parametrima.*

(b) *Odzivi sustava s reduciranim K_{Pf} and K_{If} parametrima.*

Slika 5.13: *Odzivi sustava: (**a**) S orignialnim optimalnim parametrima. (**b**) S reduciranim K_{Pf} i K_{If} Parametrima.*

5.6. Usporedba predložene metode s drugim metodama iz kategorije prediktivnog upravljanja

Slika 5.14 prikazuje usporedbu predložene metode s metodom predstavljenom u 4. poglavlju. Na slici 5.14a se može vidjeti da se odziv brzine vrtnje veoma poboljšao i da ima puno manju vrijednost maksimalne regulacijske pogreške i slično vrijeme ustaljenja. Odzivi momenta su filtrirani kako bi se nadvišenja bolje vidjela i kao što se može vidjeti, predložena metoda upravljanja daje manje nadvišenje od klasične metode. Razlog poboljšanja je taj što neizraziti regulator reagira na regulacijsku pogrešku brzine vrtnje i na njenu derivaciju. Na derivaciju regulacijske pogreške brzine vrtnje se može gledati kao na procjenu momenta tereta, što povećava regulacijsko djelovanje u trenutcima kada se moment tereta mijenja. Metoda PI-PUS koristi PI regulator koji djeluje samo na regulacijsku pogrešku brzine vrtnje i nema ovu prednost. Slika 5.14b prikazuje nefiltrirani elektromagnetski moment obje metode i može se zaključiti da je podrhtavanje momenta unutar sličnih granica.

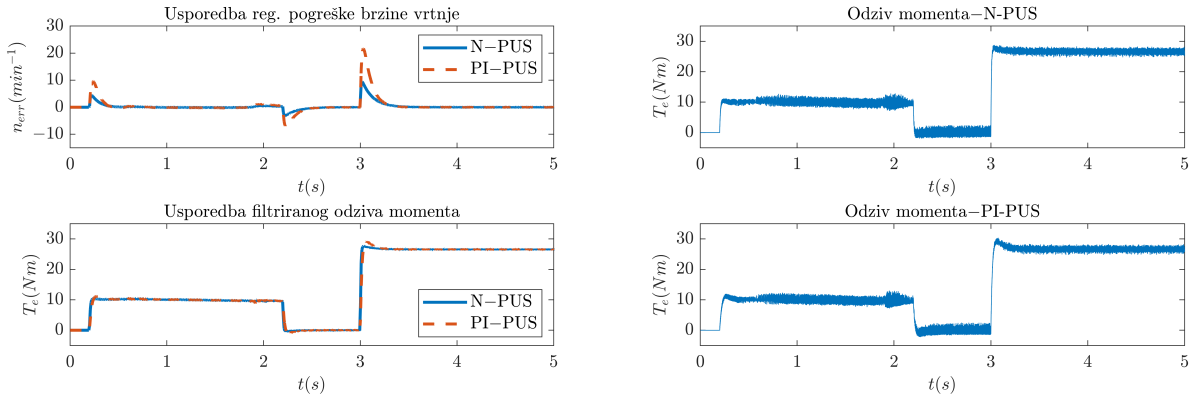

(a) *Usporedba regulacijske pogreške brzine vrtnje i filtriranog odziva momenta.*

(b) *Usporedba nefiltriranih odziva momenta.*

Slika 5.14: *Usporedba odziva sustava između predložene metode i kontinuirane prediktivne metode upravljanja strujom: (**a**) Regulacijska pogreška brzine vrtnje i filtrirani odziv momenta. (**b**) Nefiltrirani odziv momenta.*

Kako bi se poboljšanje metode dodatno potvrdilo, još dvije usporedbe su izvršene. Slika 5.15 prikazuje usporedbu odziva regulacijske pogreške brzine vrtnje i filtriranog momenta predložene metode s konačnim prediktivnim metodama upravljanja, dok slika 5.16 prikazuje usporedbu nefiltriranih odziva momenta predložene metode s konačnim prediktivnim metodama upravljanja. Prema slici 5.15 vidljivo je da predložena metoda generira manje nadvišenja u momentu i ima bolje vladanje što se tiče praćenja reference brzine vrtnje, naspram

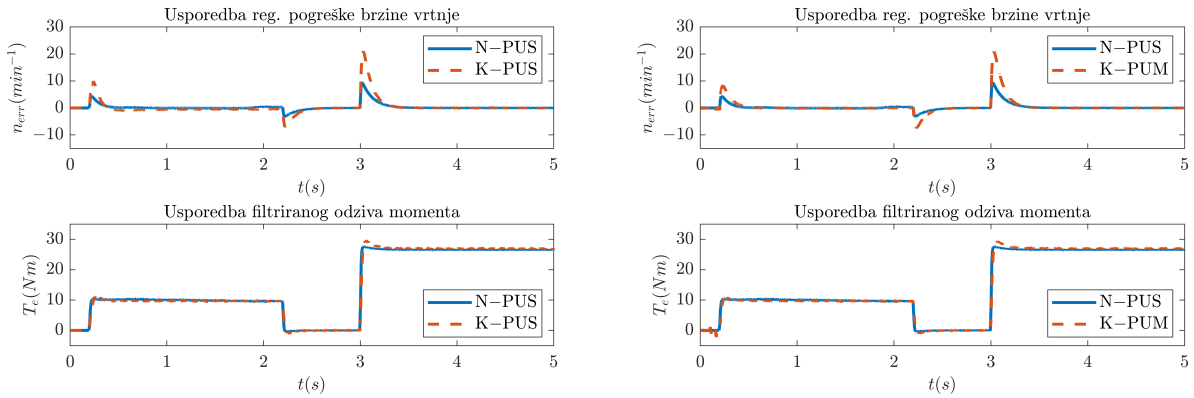

(a) *Regulacijska pogreška brzine vrtnje i filtriranog odziva momenta predložene i konačne PUS metode.*

(b) *Regulacijska pogreška brzine vrtnje i filtriranog odziva momenta predložene i konačne PUM metode.*

Slika 5.15: *Usporedba regulacijska pogrešaka brzine vrtnje i filtriranog odziva momenta prediktivnih metoda upravljanja: (**a**) Predložena metoda i metoda konačnog prediktivnog upravljanja strujom. (**b**) Predložena metoda i metoda konačnog prediktivnog upravljanja momentom.*

konačnih prediktivnih metoda upravljanja.

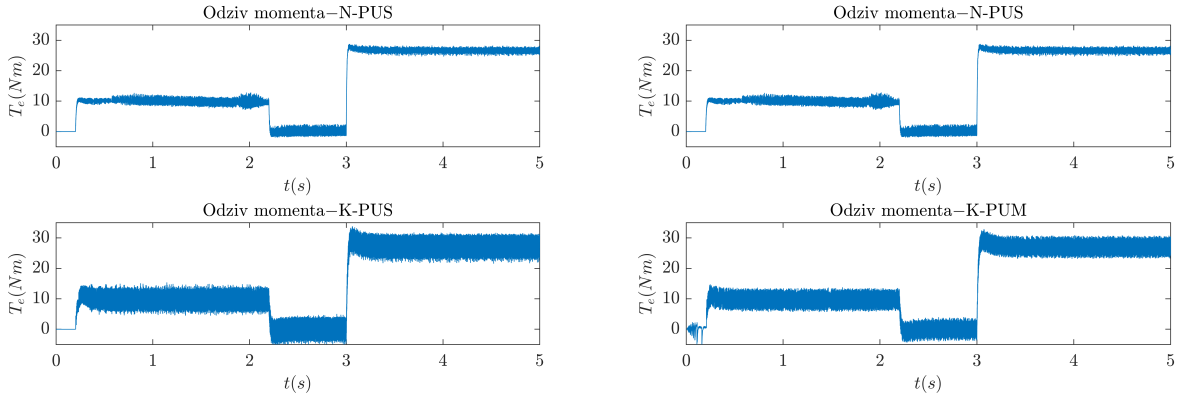

(a) *Nefiltrirani odziv momenta predložene i konačne PUS metode.*

(b) *Nefiltrirani odziv momenta predložene i konačne PUM metode.*

Slika 5.16: *Usporedba nefiltriranog odziva momenta prediktivnih metoda upravljanja: (**a**) Predložena metoda i metoda konačnog prediktivnog upravljanja strujom. (**b**) Predložena metoda i metoda konačnog prediktivnog upravljanja momentom.*

Slika 5.16 prikazuje nefiltrirane odzive elektromagnetskog momenta prediktivnih metoda upravljanja i može se zaključiti da konačne prediktivne metode upravljanja generiraju veće podrhtavanje momenta nego predložena metoda, što znači da predložena metoda ima manji negativni utjecaj na osovinu rotora stroja i po tome je superiornija. Numeričke vrijednosti za evaluaciju metoda su prikazane u tablici 5.7.

Tablica 5.7: *Usporedba predložene metode s drugim prediktivnim metodama.*

	N-PUS	**PI-PUS**	**K-PUS**	**K-PUM**
$\boldsymbol{n_{err,max}}$ **(min^{-1})**	9.48	21.68	21.05	20.88
$\boldsymbol{T_{e,max}}$ **(Nm)**	0.63	2.16	2.72	2.45

Tablica 5.8 prikazuje vrijeme potrebno za optimizaciju neizrazitog regulatora na osobnom računalu i stvarno-vremenskom simulatoru za različite vrijednosti vremenskog koraka simulacije. Računalo koje je poslužilo za usporedbu ima Intel(R) Core(TM) i3-7100 procesor s četiri jezgre, s taktom od 3,9 GHz te 8 GB RAM-a. Pri većim vremenskim koracima osobno računalo i stvarno-vremenski simulator imaju otprilike jednake performanse, no pri nižim vremenskim koracima vidi se da stvarno-vremenski simulator brže izvršava optimizaciju.

Tablica 5.8: *Vrijeme optimizacije na različitim procesorima.*

Vremenski korak	**Broj iteracija**	**Osobno računalo**	**Opal-RT**
$T_s = 100$ µs	600	$t \approx 31$ min	$t \approx 29$ min
$T_s = 10$ µs	5	$t \approx 28$ s	$t \approx 14$ s
	20	$t \approx 81$ s	$t \approx 58$ s

6. ZAKLJUČAK

Motivacija za izradu ove doktorske disertacije je primjena kosimulacijskog pristupa za unaprijeđenje algoritama upravljanja brzinom vrtnje asinkronog stroja. Naglasak je postavljen na tehnike optimizacije te primjenu tehnika iz područja mekog računarstva.

U uvodu disertacije prikazan je pregled literature vezan za područje kojim se disertacija bavi, a to je primjena kosimulacijskih sustava i stvarno-vremenskih simulatora u različitim granama elektrotehnike. Iz priložene literature vidi se da su ovakvi sustavi aktualni i da se koriste u različite svrhe kako u industriji tako i u akademiji. Prikazana je podjela različitih vrsta simulacija koje se mogu izvršavati na stvarno-vremenskim simulatorima, ovisno o tome kakvi uređaji sudjeluju u simulaciji. Za izradu disertacije korištene su takozvane MIL *(Model In the Loop)* simulacije i RCP *(Rapid Control Prototyping)* implementacija algoritma upravljanja.

S obzirom da se disertacija bavi simulacijama elektromotornih pogona sa asinkronim strojevima, u drugom poglavlju prikazani su svi bitni matematički modeli uređaja koji su uključeni u spomenute simulacije. Najbitniji je asinkroni stroj za kojeg je prikazan model u stacionarnom troosnom koordinatnom sustavu te transformacije pomoću kojih se model transformira u stacionarni $\alpha\beta$ ili sinkrono rotirajući dq dvoosni koordinatni sustav. Model u dvoosnom koordinatnom sustavu uvelike olakšava modeliranje i analizu stroja. Osim matematičkog modela asinkronog stroja, prikazan je izvod za matematički model frekvencijskog pretvarača, a da bi isti mogao dobivati upravljačke impulse, prikazana je i tehnika modulacije prostornog vektora koja se koristi u disertaciji.

Treće poglavlje prikazuje dijelove kosimulacijskog sustava za sintezu regulacijskih struktura asinkronog stroja od kojih je najbitniji stvarno-vremenski simulator Opal-RT. Također je objašnjena metoda skalarne regulacije brzine vrtnje asinkronog stroja jer je MIL simulacija elektromotornog pogona reguliranog ovom metodom prva izvršena pomoću kosimulacijskog sustava. Prikazani su odzivi brzine vrtnje za vrijeme zaleta asinkronog stroja te odzivi fazne struje pri terećenju stroja dobiveni MIL simulacijom, gdje se vidi kako se mehaničke i elek-

trične prilike mogu simulirati pomoću ovog sustava. Potom je izvršena RCP implementacija skalarne regulacije asinkronog stroja te su snimljeni odzivi struje i brzine vrtnje za različite sinkrone brzine i opterećenje stroja. Usporedbom simuliranih i stvarnih odziva može se zaključiti da simulirani sustav vjerno prikazuje električne prilike stroja, dok je kod mehaničkih veličina prisutno određeno odstupanje koje može biti pripisano odstupanjima u parametrima modela. Ovime je ostvaren prvi definirani doprinos doktorske disertacije.

Četvrto poglavlje daje uvid u različite konvencionalne i napredne tehnike upravljanja brzinom vrtnje asinkronog stroja. Od naprednih tehnika izdvojena je metoda konačnog prediktivnog upravljanja strujom asinkronog stroja jer su istraživanjem uočena određena poboljšanja koja se mogu izvršiti kako bi se metoda unaprijedila. Prvo poboljšanje je prilagodba funkcije cilja koja se koristi za generiranje optimalnog upravljačkog napona pomoću koje metoda prelazi iz klase konačnih u klasu kontinuiranih metoda te se na taj način poboljšava harmonijski spektar struje i elektromagnetskog momenta stroja što smanjuje vibracije i podrhtavanje osovine. Ovo poboljšanje je vidljivo iz analize harmonijskog spektra momenta stroja upravljanog pomoću razvijene kontinuirane prediktivne metode i konačne prediktivne metode upravljanja strujom. Razlog manjeg podrhtavanja momenta pri regulaciji stroja predloženom metodom je taj što je generirani signal upravljačkog napona kontinuiran i na stezaljke stroja se realizira pomoću modulacijske tehnike koja uklapa ventilima frekvencijskog pretvarača konstantnom frekvencijom. Glavni doprinos ovog poglavlja je dokaz stabilnosti sustava gdje je pokazano da izračun matrice težinskih faktora pri definiranju funkcije cilja nije potreban, već se mogu postaviti jedinični težinski faktori. Analiza stabilnosti je izvršena izračunom svojstvenih vrijednosti diskretizirane matrice stanja zatvorenog sustava za cijeli raspon brzine vrtnje asinkronog stroja. S obzirom da se svojstvene vrijednosti za cijeli raspon brzine vrtnje nalaze unutar jedinične kružnice u kompleksnoj ravnini, može se zaključiti da je sustav stabilan. Osim analize stabilnosti, izvršena je i analiza upravljivosti gdje su prikazane svojstvene vrijednosti gramiana upravljivosti koje se nalaze u pozitivnoj poluravnini kompleksne ravnine, što dokazuje da je sustav upravljiv.

Peto poglavlje prikazuje primjenu neizrazite logike za unaprjeđenje algoritma upravljanja brzinom vrtnje asinkronog stroja predstavljene u četvrtom poglavlju. Prikazani su različiti sustavi neizrazitog zaključivanja koji nalaze primjenu u području regulacije elektromotornih pogona u kontekstu neizrazitih regulatora. U disertaciji je korišten Takagi-Sugeno neizraziti regulator umjesto PI regulatora brzine vrtnje te je prikazana njegova struktura i implemen-

tacija. Također je prikazana i problematika ugađanja neizrazitog regulatora zbog prevelikog broja parametara koji nemaju fizikalno značenje te se vidi kako je za optimalan rad sustava potrebna optimizacija ovih parametara. Optimizacija je izvršena pomoću kosimulacijskog sustava gdje se metaheuristički optimizacijski algoritam izvršavao na osobnom računalu, a simulacija pogona s neizrazitim regulatorom se izvršavala na stvarno-vremenskom simulatoru. Istraženo je nekoliko kriterija za izračunavanje vrijednosti funkcije cilja optimizacijskog algoritma, a onaj kriterij koji je polučio najmanju vrijednost detaljno je analiziran. Ispostavilo se da kriterij koji računa ukupno kvadratno odstupanje pogreške brzine vrtnje i kažnjava nadvišenje elektromagnetskog momenta, generira najbolje parametre neizrazitog regulatora brzine vrtnje asinkronog stroja. Ovako ugođen regulator daje najbolje odzive momenta i brzine vrtnje gdje su nadvišenja momenta minimalna, kao i regulacijska pogreška brzine vrtnje. Odzivi elektromotornog pogona upravljanim s optimiranim neizrazitim regulatorom uspoređeni su s pogonom upravljanim srodnim regulacijskim tehnikama, što potvrđuje da je predložena metoda superiornija. Razlog tome je taj što neizraziti regulator djeluje na regulacijsku pogrešku brzine vrtnje te na njenu derivaciju koja se može protumačiti kao pogreška momenta. Klasični PI regulator korišten u srodnim metodama djeluje samo na regulacijsku pogrešku brzine vrtnje te nema ovu prednost. Pokazano je kako se razvijeni kosimulacijski sustav može uspješno koristiti u svrhe optimizacije regulacijske strukture za upravljanje brzinom vrtnje asinkronog stroja te se time potvrđuje i treći doprinos ove disertacije. Vrijeme potrebno za optimizaciju neizrazitog regulatora iznosilo je oko 29 minuta.

Sve regulacijske tehnike koje su predstavljene u disertaciji su također implementirane na stvarno-vremenski simulator te je izvršena MIL simulacija elektromotornog pogona upravljanog svakom od njih. Tablica 6.1 prikazuje opterećenost jezgre stvarno-vremenskog simulatora pri izvršavanju pojedinih MIL simulacija. Svaka MIL simulacija ima vremenski korak od 10 µs. Vidi se da sve tehnike kod kojih je potrebna modulacija napona i dodatna dq transformacija imaju mnogo veće opterećenje na jezgru stvarno-vremenskog simulatora. Kontinuirano prediktivno upravljanje strujom ima malo manje opterećenje na jezgru od klasične metode upravljanja rotorskim tokom dok zadnja predložena metoda najviše opterećuje jezgru. Razlog tome je neizraziti regulator kod kojeg se izvršava mnogo više matematičkih operacija nego kod ostalih tehnika. Iako ova tehnika najviše opterećuje jezgru, pokazala se superiornijom nad ostalima, stoga su ovi zahtjevi opravdani.

Tablica 6.1: *Opterećenost jezgre stvarno-vremenskog simulatora za različite regulacijske tehnike.*

Regulacijska tehnika	**Opterećenost jezgre (%)**
Skalarna regulacija	13,42
Direktno upravljanje momentom	9,21
Upravljanje rotorskim tokom	19,57
Konačno prediktivno upravljanje momentom	8,9
Konačno prediktivno upravljanje strujom	10,63
Kontinuirano prediktivno upravljanje strujom	18,44
Neizrazito prediktivno upravljanje strujom	23,61

LITERATURA

[1] Aldo Boglietti, Ayman M. El-Refaie, Oliver Drubel, Avoki M. Omekanda, Nicola Bianchi, Emmanuel B. Agamloh, Mircea Popescu, Antonino Di Gerlando, and James Borg Bartolo. Electrical machine topologies: Hottest topics in the electrical machine research community. *IEEE Industrial Electronics Magazine*, 8(2):18–30, jun 2014.

[2] Rajendra Mistry, William R. Finley, Emam Hashish, and Scott Kreitzer. Rotating machines: The pros and cons of monitoring devices. *IEEE Industry Applications Magazine*, 24(6):44–55, nov 2018.

[3] Dewu Shu, Ziqiang Ouyang, and Zheng Yan. Multirate and mixed solver based cosimulation of combined transient stability, shifted-frequency phasor, and electromagnetic models: A practical lcc hvdc simulation study. *IEEE Transactions on Industrial Electronics*, 68(6):4954–4965, jun 2021.

[4] Luca Barbierato, Abouzar Estebsari, Lorenzo Bottaccioli, Enrico Macii, and Edoardo Patti. A distributed multimodel cosimulation platform to assess general purpose services in smart grids. *IEEE Transactions on Industry Applications*, 56(5):5613–5624, sep 2020.

[5] Bo Zhang, Wanting Deng, Ling Ruan, Tao Wang, Jiangtao Quan, Quanliang Cao, Yaqing Teng, Weihua Wang, Yang Yuan, and Liang Li. Field–circuit cosimulation of 500-kV transformers in AC/DC hybrid power grid. *IEEE Transactions on Applied Superconductivity*, 26(4):1–5, jun 2016.

[6] Gayathri Krishnamoorthy and Anamika Dubey. Transmission–distribution cosimulation: Analytical methods for iterative coupling. *IEEE Systems Journal*, 14(2):2633–2642, jun 2020.

[7] Dewu Shu, Huiwen Yang, and Guanghui He. A harmonic phasor domain cosimulation method and new insight for harmonic analysis of large-scale VSC-MMC based AC/DC grids. *IEEE Transactions on Power Electronics*, 36(4):3909–3924, apr 2021.

[8] Danial Jafarigiv, Keyhan Sheshyekani, Houshang Karimi, and Jean Mahseredjian. A scalable FMI-compatible cosimulation platform for synchrophasor network studies. *IEEE Transactions on Industrial Informatics*, 17(1):270–279, jan 2021.

[9] Bryan Palmintier, Blake Lundstrom, Sudipta Chakraborty, Tess Williams, Kevin Schneider, and David Chassin. A power hardware-in-the-loop platform with remote distribution circuit cosimulation. *IEEE Transactions on Industrial Electronics*, 62(4):2236–2245, apr 2015.

[10] Weilin Li, Mohsen Ferdowsi, Marija Stevic, Antonello Monti, and Ferdinanda Ponci. Cosimulation for smart grid communications. *IEEE Transactions on Industrial Informatics*, 10(4):2374–2384, nov 2014.

[11] G. Scelba, G. De Donato, F. Giulii Capponi, A. Consoli, and O. Honorati. A co-simulation platform for evaluation of sensorless control techniques for IPMSMs. In *The XIX International Conference on Electrical Machines - ICEM 2010*. IEEE, sep 2010.

[12] L. Di Leonardo, F. Parasiliti, M. Tursini, and M. Villani. Transient analysis of PM synchronous motor drives by finite element model co-simulation. In *IECON 2013 - 39th Annual Conference of the IEEE Industrial Electronics Society*. IEEE, nov 2013.

[13] Ying-Shieh Kung and Nguyen Trung Hieu. Simulink/modelsim co-simulation of EKF-based sensorless PMSM drives. In *2013 IEEE 10th International Conference on Power Electronics and Drive Systems (PEDS)*. IEEE, apr 2013.

[14] Marco Tursini, Marco Villani, Alessio Di Tullio, Giuseppe Fabri, and Francesco Parasiliti Collazzo. Nonlinear model suitable for the offline cosimulation of fault-tolerant PM motors drives. *IEEE Transactions on Industry Applications*, 53(4):3719–3729, jul 2017.

[15] Bing Hang, Qunjing Wang, Fang Xie, and Lei Shi. Co-simulation of field oriented control in induction motor drive system. In *2016 IEEE 11th Conference on Industrial Electronics and Applications (ICIEA)*. IEEE, jun 2016.

[16] Xiaoyong Zhu, Ming Cheng, Wenxiang Zhao, Chunhua Liu, and K. T. Chau. A transient cosimulation approach to performance analysis of hybrid excited doubly salient machine considering indirect field-circuit coupling. *IEEE Transactions on Magnetics*, 43(6):2558–2560, jun 2007.

[17] Wenxiang Zhao, Ming Cheng, Xiaoyong Zhu, Wei Hua, and Xiangxin Kong. Analysis of fault-tolerant performance of a doubly salient permanent-magnet motor drive using transient cosimulation method. *IEEE Transactions on Industrial Electronics*, 55(4):1739–1748, apr 2008.

[18] M. D. Omar Faruque, Thomas Strasser, Georg Lauss, Vahid Jalili-Marandi, Paul Forsyth, Christian Dufour, Venkata Dinavahi, Antonello Monti, Panos Kotsampopoulos, Juan A. Martinez, Kai Strunz, Maryam Saeedifard, Xiaoyu Wang, David Shearer, and Mario Paolone. Real-time simulation technologies for power systems design, testing, and analysis. *IEEE Power and Energy Technology Systems Journal*, 2(2):63–73, jun 2015.

[19] Xavier Guillaud, M. Omar Faruque, Alexandre Teninge, Ali Hasan Hariri, Luigi Vanfretti, Mario Paolone, Venkata Dinavahi, Pinaki Mitra, Georg Lauss, Christian Dufour, Paul Forsyth, Anurag K. Srivastava, Kai Strunz, Thomas Strasser, and Ali Davoudi. Applications of real-time simulation technologies in power and energy systems. *IEEE Power and Energy Technology Systems Journal*, 2(3):103–115, sep 2015.

[20] Sameer Mojlish, Nuh Erdogan, David Levine, and Ali Davoudi. Review of hardware platforms for real-time simulation of electric machines. *IEEE Transactions on Transportation Electrification*, 3(1):130–146, mar 2017.

[21] Jae Suk Lee and Gilsu Choi. Modeling and hardware-in-the-loop system realization of electric machine drives — a review. *CES Transactions on Electrical Machines and Systems*, 5(3):194–201, sep 2021.

[22] Qing-Chang Zhong, Yeqin Wang, Yiting Dong, Beibei Ren, and Mohammad Amin. Go real: Power electronics from simulations to experiments in hours: Versatile experimen-

tal tool for next generation engineers. *IEEE Power Electronics Magazine*, 7(3):52–61, sep 2020.

[23] Hao Bai, Chen Liu, Elena Breaz, Kamal Al-Haddad, and Fei Gao. A review on the device-level real-time simulation of power electronic converters: Motivations for improving performance. *IEEE Industrial Electronics Magazine*, 15(1):12–27, mar 2021.

[24] Sunil Subedi, Manisha Rauniyar, Saima Ishaq, Timothy M. Hansen, Reinaldo Tonkoski, Mariko Shirazi, Richard Wies, and Phylicia Cicilio. Review of methods to accelerate electromagnetic transient simulation of power systems. *IEEE Access*, 9:89714–89731, 2021.

[25] Aung Myaing and Venkata Dinavahi. FPGA-based real-time emulation of power electronic systems with detailed representation of device characteristics. *IEEE Transactions on Industrial Electronics*, 58(1):358–368, jan 2011.

[26] Philippe Bontemps, Stefan Milovanovic, and Drazen Dujic. Distributed real-time model of the m3c for HIL systems using small-scale simulators. *IEEE Open Journal of Power Electronics*, 2:603–613, 2021.

[27] Stefan Milovanovic, Ignacio Polanco, Milan Utvic, and Drazen Dujic. Flexible and efficient MMC digital twin realized with small-scale real-time simulators. *IEEE Power Electronics Magazine*, 8(2):24–33, jun 2021.

[28] Lulu Guo, Jinan Zhang, Jin Ye, Stephen James Coshatt, and Wenzhan Song. Data-driven cyber-attack detection for PV farms via time-frequency domain features. *IEEE Transactions on Smart Grid*, 13(2):1582–1597, mar 2022.

[29] Aushiq Ali Memon and Kimmo Kauhaniemi. Real-time hardware-in-the-loop testing of IEC 61850 GOOSE-based logically selective adaptive protection of AC microgrid. *IEEE Access*, 9:154612–154639, 2021.

[30] Lorenzo Bottaccioli, Abouzar Estebsari, Enrico Pons, Ettore Bompard, Enrico Macii, Edoardo Patti, and Andrea Acquaviva. A flexible distributed infrastructure for real-time cosimulations in smart grids. *IEEE Transactions on Industrial Informatics*, 13(6):3265–3274, dec 2017.

[31] Kenichiro Saito and Hirofumi Akagi. A real-time real-power emulator for a medium-voltage high-speed electrical drive: Discussion on mechanical vibrations. *IEEE Transactions on Industry Applications*, 57(2):1482–1494, mar 2021.

[32] R. Champagne, L.-A. Dessaint, H. Fortin-Blanchette, and G. Sybille. Analysis and validation of a real-time AC drive simulator. *IEEE Transactions on Power Electronics*, 19(2):336–345, mar 2004.

[33] M. Steurer, C.S. Edrington, M. Sloderbeck, Wei Ren, and J. Langston. A megawatt-scale power hardware-in-the-loop simulation setup for motor drives. *IEEE Transactions on Industrial Electronics*, 57(4):1254–1260, apr 2010.

[34] Fei Li, Yichao Wang, Fan Wu, Yao Huang, Yang Liu, Xing Zhang, and Mingyao Ma. Review of real-time simulation of power electronics. *Journal of Modern Power Systems and Clean Energy*, 8(4):796–808, 2020.

[35] Andrea Benigni, Thomas Strasser, Giovanni De Carne, Marco Liserre, Marco Cupelli, and Antonello Monti. Real-time simulation-based testing of modern energy systems: A review and discussion. *IEEE Industrial Electronics Magazine*, 14(2):28–39, jun 2020.

[36] A. Blondel, C.O. Mailloux, and C.A. Adams. *Synchronous Motors and Converters: Theory and Methods of Calculation and Testing.* McGraw-Hill Book Company, 1913.

[37] R. E. Doherty and C. A. Nickle. Synchronous machines i-an extension of blondel's two-reaction theory. *Transactions of the American Institute of Electrical Engineers*, XLV:912–947, jan 1926.

[38] R. H. Park. Two-reaction theory of synchronous machines generalized method of analysis-part i. *Transactions of the American Institute of Electrical Engineers*, 48(3):716–727, jul 1929.

[39] R. H. Park. Two-reaction theory of synchronous machines-II. *Transactions of the American Institute of Electrical Engineers*, 52(2):352–354, jun 1933.

[40] Paul Krause. *Analysis of electric machinery and drive systems.* Wiley, Hoboken, New Jersey, 2013.

[41] R Krishnan. *Electric motor drives : modeling, analysis, and control.* Prentice Hall, Upper Saddle River, N.J, 2001.

[42] Ned Mohan Mohan. *Advanced Electric Drives.* John Wiley & Sons, August 2014.

[43] Bimal K. Bose. *Modern Power Electronics and AC Drives.* PRENTICE HALL, October 2001.

[44] T. A. Lipo D. W. Novotny. *Vector Control and Dynamics of AC Drives.* OXFORD UNIV PR, September 1996.

[45] Stephen J. Chapman. *Electric machinery fundamentals.* McGraw-Hill, 2012.

[46] Karl Hasse. *Zur Dynamik drehzahlgeregelter Antriebe mit stromrichtergespeisten Asynchron-Kurzschlusslaaeufermaschinen.* PhD thesis, Technische Hochschule Darmstadt, 1969.

[47] F. Blaschke. *Das Verfahren der Feldorientierung zur Regelung der Drehfeldmaschine.* PhD thesis, Eindhoven University of Technology, 1973.

[48] Isao Takahashi and Toshihiko Noguchi. A new quick-response and high-efficiency control strategy of an induction motor. *IEEE Transactions on Industry Applications*, IA-22(5):820–827, sep 1986.

[49] Sergio Vazquez, Jose Rodriguez, Marco Rivera, Leopoldo G. Franquelo, and Margarita Norambuena. Model predictive control for power converters and drives: Advances and trends. *IEEE Transactions on Industrial Electronics*, 64(2):935–947, feb 2017.

[50] P. Cortes, M.P. Kazmierkowski, R.M. Kennel, D.E. Quevedo, and J. Rodriguez. Predictive control in power electronics and drives. *IEEE Transactions on Industrial Electronics*, 55(12):4312–4324, dec 2008.

[51] S. Kouro, P. Cortes, R. Vargas, U. Ammann, and J. Rodriguez. Model predictive control—a simple and powerful method to control power converters. *IEEE Transactions on Industrial Electronics*, 56(6):1826–1838, jun 2009.

[52] Jose Rodriguez, Marian P. Kazmierkowski, Jose R. Espinoza, Pericle Zanchetta, Haitham Abu-Rub, Hector A. Young, and Christian A. Rojas. State of the art of finite

control set model predictive control in power electronics. *IEEE Transactions on Industrial Informatics*, 9(2):1003–1016, may 2013.

[53] Fengxiang Wang, Zhenbin Zhang, Xuezhu Mei, José Rodríguez, and Ralph Kennel. Advanced control strategies of induction machine: Field oriented control, direct torque control and model predictive control. *Energies*, 11(1):120, jan 2018.

[54] R. Kennel, J. Rodriguez, J. Espinoza, and M. Trincado. High performance speed control methods for electrical machines: An assessment. In *2010 IEEE International Conference on Industrial Technology*. IEEE, mar 2010.

[55] José Rodriguez, Ralph M. Kennel, José R. Espinoza, Mauricio Trincado, César A. Silva, and Christian A. Rojas. High-performance control strategies for electrical drives: An experimental assessment. *IEEE Transactions on Industrial Electronics*, 59(2):812–820, feb 2012.

[56] Fengxiang Wang, Shihua Li, Xuezhu Mei, Wei Xie, Jose Rodriguez, and Ralph M. Kennel. Model-based predictive direct control strategies for electrical drives: An experimental evaluation of PTC and PCC methods. *IEEE Transactions on Industrial Informatics*, 11(3):671–681, jun 2015.

[57] Fengxiang Wang, Zhe Chen, Peter Stolze, Ralph Kennel, Mauricio Trincado, and Jose Rodriguez. A comprehensive study of direct torque control (DTC) and predictive torque control (PTC) for high performance electrical drives. *EPE Journal*, 25(1):12–21, mar 2015.

[58] Tobias Englert and Knut Graichen. Nonlinear model predictive torque control and setpoint computation of induction machines for high performance applications. *Control Engineering Practice*, 99:104415, jun 2020.

[59] Christian A. Rojas, Jose Rodriguez, Felipe Villarroel, José R. Espinoza, César A. Silva, and Mauricio Trincado. Predictive torque and flux control without weighting factors. *IEEE Transactions on Industrial Electronics*, 60(2):681–690, feb 2013.

[60] Fengxiang Wang, Haotian Xie, Qing Chen, S. Alireza Davari, Jose Rodriguez, and Ralph Kennel. Parallel predictive torque control for induction machines without weighting factors. *IEEE Transactions on Power Electronics*, 35(2):1779–1788, feb 2020.

[61] M. Nemec, D. Nedeljkovic, and V. Ambrozic. Predictive torque control of induction machines using immediate flux control. *IEEE Transactions on Industrial Electronics*, 54(4):2009–2017, aug 2007.

[62] Abdelsalam A. Ahmed, Byung Kwon Koh, Hyo Sung Park, Kyo-Beum Lee, and Young Il Lee. Finite-control set model predictive control method for torque control of induction motors using a state tracking cost index. *IEEE Transactions on Industrial Electronics*, 64(3):1916–1928, mar 2017.

[63] Yongchang Zhang, Bo Xia, and Haitao Yang. Model predictive torque control of induction motor drives with reduced torque ripple. *IET Electric Power Applications*, 9(9):595–604, nov 2015.

[64] Mohand Ouhrouche, Rachid Errouissi, Andrzej M. Trzynadlowski, Kambiz Tehrani, and A Benzaioua. A novel predictive direct torque controller for induction motor drives. *IEEE Transactions on Industrial Electronics*, pages 1–1, 2016.

[65] Fengxiang Wang, Zhenbin Zhang, Ralph Kennel, and José Rodríguez. Model predictive torque control with an extended prediction horizon for electrical drive systems. *International Journal of Control*, 88(7):1379–1388, aug 2014.

[66] Junxiao Wang and Fengxiang Wang. Robust sensorless FCS-PCC control for inverter-based induction machine systems with high-order disturbance compensation. *Journal of Power Electronics*, 20(5):1222–1231, jun 2020.

[67] Junxiao Wang, Fengxiang Wang, Gaolin Wang, Shihua Li, and Li Yu. Generalized proportional integral observer-based robust finite control set predictive current control for induction motor systems with time-varying disturbances. *IEEE Transactions on Industrial Informatics*, pages 1–1, 2018.

[68] Tan Wang, Yihua Hu, Zuyu Wu, and Kai Ni. Low-switching-loss finite control set model predictive current control for IMs considering rotor-related inductance mismatch. *IEEE Access*, 8:108928–108941, 2020.

[69] Fengxiang Wang, Junxiao Wang, Ralph M. Kennel, and Jose Rodriguez. Fast speed control of AC machines without the proportional-integral controller: Using an extended

high-gain state observer. *IEEE Transactions on Power Electronics*, 34(9):9006–9015, sep 2019.

[70] Fengxiang Wang, Zhenbin Zhang, Junxiao Wang, and José Rodríguez. Sensorless model-based PCC for induction machine. *IET Electric Power Applications*, 11(5):885–892, may 2017.

[71] Mohammad Hossein Vafaie. Approach for classifying continuous control set-predictive controllers applied in AC motor drives. *IET Power Electronics*, 13(8):1500–1513, jun 2020.

[72] Oliver Wallscheid and Etienne Florian Bouna Ngoumtsa. Investigation of disturbance observers for model predictive current control in electric drives. *IEEE Transactions on Power Electronics*, 35(12):13563–13572, dec 2020.

[73] Karol Wróbel, Piotr Serkies, and Krzysztof Szabat. Model predictive base direct speed control of induction motor drive—continuous and finite set approaches. *Energies*, 13(5):1193, mar 2020.

[74] Abdelsalam A. Ahmed, Byung Kwon Koh, and Young Il Lee. A comparison of finite control set and continuous control set model predictive control schemes for speed control of induction motors. *IEEE Transactions on Industrial Informatics*, 14(4):1334–1346, apr 2018.

[75] Abdelsalam A. Ahmed, Byung Kwon Koh, and Young Il Lee. Continuous control set-model predictive control for torque control of induction motors in a wide speed range. *Electric Power Components and Systems*, 46(19-20):2142–2158, dec 2018.

[76] Abdelsalam A. Ahmed, Byung Kwon Koh, and Young Il Lee. Torque control of induction motors with minimal ripples based on continuous control set-MPC in a wide speed range. In *2017 IEEE Vehicle Power and Propulsion Conference (VPPC)*. IEEE, dec 2017.

[77] Toni Varga, Tin Benšić, Vedrana Jerković Štil, and Marinko Barukčić. Continuous control set predictive current control for induction machine. *Applied Sciences*, 11(13):6230, jul 2021.

[78] Pablo Correa, Mario Pacas, and Jos Rodriguez. Predictive torque control for inverter-fed induction machines. *IEEE Transactions on Industrial Electronics*, 54(2):1073–1079, apr 2007.

[79] Jos Rodriguez, Jorge Pontt, Csar A. Silva, Pablo Correa, Pablo Lezana, Patricio Cortes, and Ulrich Ammann. Predictive current control of a voltage source inverter. *IEEE Transactions on Industrial Electronics*, 54(1):495–503, feb 2007.

[80] Afanas. *Mathematical Theory of Control Systems Design.* Springer Netherlands, Dordrecht, 1996.

[81] Saad Khadar, Haitham Abu-Rub, and Abdellah Kouzou. Sensorless field-oriented control for open-end winding five-phase induction motor with parameters estimation. *IEEE Open Journal of the Industrial Electronics Society*, 2:266–279, 2021.

[82] Hanbing Dan, Peng Zeng, Wenjing Xiong, Meng Wen, Mei Su, and Marco Rivera. Model predictive control-based direct torque control for matrix converter-fed induction motor with reduced torque ripple. *CES Transactions on Electrical Machines and Systems*, 5(2):90–99, jun 2021.

[83] L.A. Zadeh. Fuzzy sets. *Information and Control*, 8(3):338–353, jun 1965.

[84] James J. Buckley and Esfandiar Eslami. *An Introduction to Fuzzy Logic and Fuzzy Sets (Advances in Soft Computing).* Physica-Verlag Heidelberg, 2002.

[85] Guanrong. Chen and Trung Tat Pham. *Introduction to Fuzzy Sets, Fuzzy Logic, and Fuzzy Control Systems.* CRC, 2000.

[86] Jairo Espinosa, Joos Vandewalle, and Vincent Wertz. *Fuzzy Logic, Identification and Predictive Control (Advances in Industrial Control).* Springer, 2004.

[87] Marios M. Polycarpou Jay A. Farrell. *Adaptive Approximation Based Control: Unifying Neural, Fuzzy and Traditional Adaptive Approximation Approaches.* WILEY, March 2006.

[88] Rómulo Antão, Alexandre Mota, Rui Martins, and José Tenreiro Machado. *Type-2 Fuzzy Logic : Uncertain Systems' Modeling and Control.* Springer.

[89] Oscar Castillo. *Type2 Fuzzy Logic In Intelligent Control Applications.* Springer, 2011.

[90] Oscar Castillo and Luis T. Aguilar. *Type-2 Fuzzy Logic in Control of Nonsmooth Systems : Theoretical Concepts and Applications*. Springer.

[91] Jerry Mendel, Hani Hagras, William W. Melek, Woei-Wan Tan, and Hao Ying. *Introduction to Type-2 Fuzzy Logic Control*. Wiley & Sons, Limited, John, 2014.

[92] E.H. Mamdani and S. Assilian. An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7(1):1–13, jan 1975.

[93] Tomohiro Takagi and Michio Sugeno. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-15(1):116–132, jan 1985.

[94] Shuai Zhao, Frede Blaabjerg, and Huai Wang. An overview of artificial intelligence applications for power electronics. *IEEE Transactions on Power Electronics*, 36(4):4633–4658, apr 2021.

[95] Qazwan A. Tarbosh, Omer Aydogdu, Nabil Farah, Md Hairul Nizam Talib, Adeeb Salh, Nihat Cankaya, Fuad Alhaj Omar, and Akif Durdu. Review and investigation of simplified rules fuzzy logic speed controller of high performance induction motor drives. *IEEE Access*, 8:49377–49394, 2020.

[96] Alberto Berzoy, Johnny Rengifo, and Osama Mohammed. Fuzzy predictive dtc of induction machines with reduced torque ripple and high-performance operation. *IEEE Transactions on Power Electronics*, 33(3):2580–2587, March 2018.

[97] Mohamed S. Zaky and Mohamed K. Metwaly. A performance investigation of a four-switch three-phase inverter-fed im drives at low speeds using fuzzy logic and pi controllers. *IEEE Transactions on Power Electronics*, 32(5):3741–3753, May 2017.

[98] Nabil Farah, Md. Hairul Nizam Talib, Zulkifilie Ibrahim, Qazwan Abdullah, Omer Aydogdu, Maaspaliza Azri, Jurifa Binti Mat Lazi, and Zainuddin Mat Isa. Investigation of the computational burden effects of self-tuning fuzzy logic speed controller of induction motor drives with different rules sizes. *IEEE Access*, 9:155443–155456, 2021.

[99] Venkataramana Naik N. and Sajjan Pal Singh. A novel interval type-2 fuzzy-based direct torque control of induction motor drive using five-level diode-clamped inverter. *IEEE Transactions on Industrial Electronics*, 68(1):149–159, Jan 2021.

[100] Venkataramana Naik N, Aurobinda Panda, and S. P. Singh. A three-level fuzzy-2 dtc of induction motor drive using svpwm. *IEEE Transactions on Industrial Electronics*, 63(3):1467–1479, March 2016.

[101] H. Sudheer, S. F. Kodad, and B. Sarvesh. Improved fuzzy logic based dtc of induction machine for wide range of speed control using ai based controllers. *JOURNAL OF ELECTRICAL SYSTEMS*, 12(2):301–314, JUN 2016.

[102] Flah Aymen, Naoui Mohamed, Saad Chayma, C. H. Rami Reddy, Mosleh M. Alharthi, and Sherif S. M. Ghoneim. An improved direct torque control topology of a double stator machine using the fuzzy logic controller. *IEEE Access*, 9:126400–126413, 2021.

[103] Nabil Farah, Md. Hairul Nizam Talib, Nor Shahida Mohd Shah, Qazwan Abdullah, Zulkifilie Ibrahim, Jurifa Binti Mat Lazi, and Auzani Jidin. A novel self-tuning fuzzy logic controller based induction motor drive system: An experimental approach. *IEEE Access*, 7:68172–68184, 2019.

[104] Zoheir Tir, Youcef Soufi, Mohammad Naser Hashemnia, Om P. Malik, and Khoudir Marouani. Fuzzy logic field oriented control of double star induction motor drive. *ELECTRICAL ENGINEERING*, 99(2):495–503, JUN 2017.

[105] Zoheir Tir, Om P. Malik, and Ali M. Eltamaly. Fuzzy logic based speed control of indirect field oriented controlled double star induction motors connected in parallel to a single six-phase inverter supply. *ELECTRIC POWER SYSTEMS RESEARCH*, 134:126–133, MAY 2016.

[106] Taieb Bessaad, Rachid Taleb, Fayçal Chabni, and Atif Iqbal. Fuzzy adaptive control of a multimachine system with single inverter supply. *International Transactions on Electrical Energy Systems*, 29(10), jun 2019.

[107] Mahammad A. Hannan, Jamal A. Ali, Azah Mohamed, Ungku Anisa Ungku Amirulddin, Nadia Mei Lin Tan, and Mohammad Nasir Uddin. Quantum-behaved lightning search algorithm to improve indirect field-oriented fuzzy-PI control for IM drive. *IEEE Transactions on Industry Applications*, 54(4):3793–3805, jul 2018.

[108] D. de Almeida Souza, W.C.P. de Aragao Filho, and G.C.D. Sousa. Adaptive fuzzy controller for efficiency optimization of induction motors. *IEEE Transactions on Industrial Electronics*, 54(4):2157–2164, aug 2007.

[109] Mateo Basic and Dinko Vukadinovic. Online efficiency optimization of a vector controlled self-excited induction generator. *IEEE Transactions on Energy Conversion*, 31(1):373–380, mar 2016.

[110] N. Mayadevi, V. P. Mini, R. Hari Kumar, and Shruti Prins. Fuzzy-based intelligent algorithm for diagnosis of drive faults in induction motor drive system. *Arabian Journal for Science and Engineering*, 45(3):1385–1395, may 2019.

[111] Abderrahmane BERKANI. Fuzzy direct torque control for induction motor sensorless drive powered by five level inverter with reduction rule base. *PRZEGL D ELEKTROTECHNICZNY*, 1(7):68–73, jul 2019.

[112] Christian A. Rojas, Jose R. Rodriguez, Samir Kouro, and Felipe Villarroel. Multi-objective fuzzy-decision-making predictive torque control for an induction motor drive. *IEEE Transactions on Power Electronics*, 32(8):6245–6260, Aug 2017.

[113] Abdelkarim Ammar. Performance improvement of direct torque control for induction motor drive via fuzzy logic-feedback linearization. *COMPEL - The international journal for computation and mathematics in electrical and electronic engineering*, 38(2):672–692, mar 2019.

[114] Ali Saghafinia, Hew Wooi Ping, Mohammad Nasir Uddin, and Khalaf Salloum Gaeid. Adaptive fuzzy sliding-mode control into chattering-free im drive. *IEEE Transactions on Industry Applications*, 51(1):692–701, 2015.

[115] Constantin Volosencu. Reducing energy consumption and increasing the performances of AC motor drives using fuzzy PI speed controllers. *Energies*, 14(8):2083, apr 2021.

[116] L. YOUB, S. BELKACEM, F. NACERI, M. CERNAT, and L. G. PESQUER. Design of an adaptive fuzzy control system for dual star induction motor drives. *Advances in Electrical and Computer Engineering*, 18(3):37–44, 2018.

[117] M. Bahloul, L. Chrifi-Alaoui, S. Drid, M. Souissi, and M. Chabaane. Robust sensorless vector control of an induction machine using multiobjective adaptive fuzzy luenberger observer. *ISA TRANSACTIONS*, 74:144–154, MAR 2018.

[118] Nikolaos Jabbour and Christos Mademlis. Online parameters estimation and autotuning of a discrete-time model predictive speed controller for induction motor drives. *IEEE Transactions on Power Electronics*, 34(2):1548–1559, feb 2019.

[119] Tejavathu Ramesh, Anup Kumar Panda, and S. Shiva Kumar. Type-2 fuzzy logic control based mras speed estimator for speed sensorless direct torque and flux control of an induction motor drive. *ISA TRANSACTIONS*, 57:262–275, JUL 2015.

[120] Zakaria Boulghasoul, Zineb Kandoussi, Abdelhadi Elbacha, and Abdelouahed Tajer. Fuzzy improvement on luenberger observer based induction motor parameters estimation for high performances sensorless drive. *Journal of Electrical Engineering and Technology*, 15(5):2179–2197, aug 2020.

[121] E. Bim. Fuzzy optimization for rotor constant identification of an indirect foc induction motor drive. *IEEE Transactions on Industrial Electronics*, 48(6):1293–1295, 2001.

[122] Saurabh Shukla and Bhim Singh. Adaptive speed estimation with fuzzy logic control for PV-grid interactive induction motor drive-based water pumping. *IET Power Electronics*, 12(6):1554–1562, mar 2019.

[123] Trong-Thang Nguyen, Duc-Minh Nguyen, and Quang-Vi Ngo. The power-sharing system of DFIG-based shaft generator connected to a grid of the ship. *IEEE Access*, 9:109785–109792, 2021.

[124] Najib El Ouanjli, Saad Motahhir, Aziz Derouich, Abdelaziz El Ghzizal, Ali Chebabhi, and Mohammed Taoussi. Improved dtc strategy of doubly fed induction motor using fuzzy logic controller. *ENERGY REPORTS*, 5:271–279, NOV 2019.

[125] Alireza Ashouri-Zadeh, Mohammadreza Toulabi, Shahab Bahrami, and Ali Mohammad Ranjbar. Modification of DFIG's active power control loop for speed control enhancement and inertial frequency response. *IEEE Transactions on Sustainable Energy*, 8(4):1772–1782, oct 2017.

[126] Sanjay Dewangan, Giribabu Dyanamina, and Navin Kumar. Performance improvement of wind-driven self-excited induction generator using fuzzy logic controller. *International Transactions on Electrical Energy Systems*, 29(8), jun 2019.

[127] Alin Pantea, Omar Bouyahia, Alaaeddine Abdallah, Amine Yazidi, and Franck Betin. Fault tolerant fuzzy logic control of a 6-phase induction generator for wind turbine energy production. *Electric Power Components and Systems*, 49(8):756–766, may 2021.

[128] Mary Ann George, Dattaguru V. Kamat, and Ciji Pearl Kurian. Electronically tunable ACO based fuzzy FOPID controller for effective speed control of electric vehicle. *IEEE Access*, 9:73392–73412, 2021.

[129] Gonggui Chen, Zhijun Li, Zhizhong Zhang, and Shuaiyong Li. An improved ACO algorithm optimized fuzzy PID controller for load frequency control in multi area interconnected power systems. *IEEE Access*, 8:6429–6447, 2020.

[130] Jamal Abd Ali, M. A. Hannan, Azah Mohamed, and Maher G. M. Abdolrasol. Fuzzy logic speed controller optimization approach for induction motor drive using backtracking search algorithm. *MEASUREMENT*, 78:49–62, JAN 2016.

[131] Toni Varga, Tin Benšić, Marinko Barukčić, and Vedrana Jerković Štil. Optimization of fuzzy controller for predictive current control of induction machine. *Electronics*, 11(10):1553, may 2022.

[132] Martin Schlueter, Sven O. Erb, Matthias Gerdts, Stephen Kemble, and Jan-J. Rückmann. MIDACO on MINLP space applications. *Advances in Space Research*, 51(7):1116–1131, apr 2013.

TUMAČ OZNAKA

	Osnovne matematičke notacije
x	Skalarna veličina
$\boldsymbol{x}$, $\vec{x}$	Vektorska veličina
$\boldsymbol{X}$	Matrična veličina
$\hat{x}$	Procijenjena veličina
$x(t)$	Vremenski kontinuirana veličina
$x[k]$	Vremenski diskretna veličina
$\frac{\mathrm{d}}{\mathrm{d}t}x$, $\dot{x}$	Vremenska derivacija od x
$\lvert \cdot \rvert$	Modul vektora ili kompleksnog broja
$\lvert\lvert \cdot \rvert\rvert$	Norma vektora
$f(\cdot)$	Skalarna funkcija
	Fizikalne veličine modela asinkronog stroja
$\boldsymbol{v}$	Napon
$\boldsymbol{i}$	Struja
$\boldsymbol{\psi}$	Ulančani magnetski tok
T_e,T_l	Elektromagnetski moment motora, moment tereta
ω_r	Brzina vrtnje osovine asinkronog stroja
ω_s	Sinkrona brzina
ρ	Kut prostornog vektora određene fizikalne veličine
	Parametri modela asinkronog stroja
R_s	Otpor statora
R_r	Otpor rotora
L_s,L_r	Statorski i rotorski induktiviteti
L_m	Međuinduktivitet
τ_r	Rotorska vremenska konstanta

σ	Koeficijent rasipanja
J	Moment inercije asinkronog stroja
p	Broj pari polova
Notacije vezane za transformacije koordinatnih sustava	
$\boldsymbol{C}_{dq}$	Matrica transformacije iz abc u dq sustav
ρ_k	Kut korišten pri transformaciji iz abc u dq sustav
$\boldsymbol{C}_{\alpha\beta}$	Matrica transformacije iz abc u $\alpha\beta$ sustav
$\boldsymbol{C}_{sdq}$	Matrica Parkove transformacije statorskih veličina asinkronog stroja
$\boldsymbol{C}_{rdq}$	Matrica Parkove transformacije rotorskih veličina asinkronog stroja
Indeksacija modela asinkronog stroja	
s	Statorske veličine
r	Rotorske veličine
abc	Veličina u mirujućem abc koordinatnom sustavu
dq	Veličina u rotirajućem dq koordinatnom sustavu
$\alpha\beta$	Veličina u mirujućem $\alpha\beta$ koordinatnom sustavu
Notacije vezane za prediktivno upravljanje asinkronim strojem	
x^*	Referentna veličina x
x_{err}	Regulacijsko odstupanje veličine x
$\hat{x}_{err}$	Pogreška procjene veličine x
$\boldsymbol{A}$,$\boldsymbol{B}$,$\boldsymbol{C}$,$\boldsymbol{D}$	Matrice linearnog modela u prostoru stanja
d -indeks	Diskretizirana matrica sustava
$\boldsymbol{x}$, $\boldsymbol{u}$	Vektor varijabli stanja i ulaza sustava
T_s	Vrijeme uzorkovanja
K_p, K_i	Proporcionalno i integralno pojačanje PI regulatora
$mras$ - indeks	Pojačanja regulatora osmotritelja
ω - indeks	Pojačanja regulatora brzine
f - indeks	Pojačanja neizrazitog regulatora
Notacije vezane za optimizaciju neizrazitog regulatora brzine vrtnje asinkronog stroja	
$\boldsymbol{o}$	Vektor realnih ulaznih veličina neizrazitog regulatora
$\bar{\boldsymbol{o}}$	Vektor ulaznih lingvističkih varijabli
$\bar{O}_i$	Skup ulaznih lingvističkih vrijednosti
$\boldsymbol{z}$	Vektor realnih izlaznih veličina neizrazitog regulatora

$\bar{\boldsymbol{z}}$	Vektor izlaznih lingvističkih varijabli
$\bar{Z}$	Skup izlaznih lingvističkih vrijednosti
$\mu_{\bar{O}_i^k}(o_i)$	ulazne funkcije pripadnosti
$\boldsymbol{W}$	Matrica težinskih faktora neizrazitih pravila
$\boldsymbol{H}$	Matrica razine neizrazitih pravila
$\boldsymbol{\theta}$	Varijable odluke optimizacije

SAŽETAK

Razvoj i primjena kosimulacijskih sustava za sintezu regulacijskih struktura asinkronog stroja

Cilj ove doktorske disertacije je izraditi te osposobiti sustav za simuliranje i prototipiranje uređaja iz područja elektroenergetike ili elektrostrojarstva te na njemu implementirati modele elektromotornog pogona s različitim algoritmima upravljanja asinkronog stroja. Sustav također mora biti omogućen za rad u kosimulaciji s različitim programskim okruženjima i alatima iz područja mekog računarstva. Sustav je realiziran pomoću stvarno-vremenskog simulatora te je iskorišten za prototipiranje frekvencijskog pretvarača za napajanje asinkronog stroja. Predstavljena je napredna metoda za regulaciju brzine vrtnje asinkronim strojem, a u kosimulaciji s meta-heurističkim optimizatorom, sustav je iskorišten za optimiranje parametara neizrazitog regulatora brzine vrtnje asinkronog stroja.

U prvom poglavlju, predstavljeni su matematički modeli svih elemenata elektromotornog pogona koji su bitni za uspješno simuliranje dinamike elektromotornih pogona pomoću stvarno-vremenskog simulatora.

U drugom poglavlju, prikazani su dijelovi sustava za simuliranje i prototipiranje upravljačkih algoritama elektromotornih pogona. Glavni dijelovi ovog sustava su stvarno-vremenski simulator s proširenjem za digitalne i analogne ulaze i izlaze te energetski dio koji se sastoji od filtera energetskih modula za izradu frekvencijskog pretvarača. Pomoću sustava je izvršena simulacija elektromotornog pogona sa skalarno upravljanim asinkronim strojem te stvarna skalarna regulacija asinkronog stroja. Simulirani i stvarni odzivi su potom uspoređeni.

U trećem poglavlju, predstavljeni su konvencionalne i napredne metode upravljanja brzinom vrtnje asinkronog stroja. Od naprednih metoda izdvojeno je prediktivno upravljanje strujom i momentom asinkronog stroja na temelju modela. Prediktivno upravljanje strujom asinkronog stroja je pobliže analizirano te prilagođeno za rad s konstantnom frekvencijom uklapanja frekvencijskog pretvarača. Glavni doprinos pri razvoju ove tehnike upravljanja je

dokaz stabilnosti klasičnom metodom analiziranja svojstvenih vrijednosti i činjenica da nema potrebe za računanjem težinskih faktora koji inače osiguravaju stabilnost sustava. Razvijena metoda je uspoređena sa srodnom metodom upravljanja te je vidljivo poboljšanje u spektru elektromagnetskog momenta asinkronog stroja.

U četvrtom poglavlju izvršena su dodatna poboljšanja metode prediktivnog upravljanja strujom, gdje je PI regulator brzine vrtnje zamijenjen s neizrazitim regulatorom. Parametri neizrazitog regulatora su optimirani pomoću meta-heurističkog optimizatora. Optimizacija je izvršena kosimulacijskim pristupom na način da stvarno-vremenski simulator izvršava simulaciju elektromotornog pogona s neizrazitim regulatorom, a optimizator prima rezultate na temelju kojih generira optimalne parametre. Odzivi elektromotornog pogona upravljanog s optimiranim neizrazitim regulatorom su uspoređeni s odzivima dobivenim srodnim metodama te je vidljivo poboljšanje odziva momenta i brzine vrtnje.

ABSTRACT

Development and Application of a Cosimulation System for Induction Machine Control Structures Synthesis

The goal of this PhD thesis is to develop a system for simulation and prototyping of devices from the fields of electrical or electromechanical engineering and use it for implementation of electric drive models that utilize different structures for induction machine control. The system should also allow for cosimulation with different software environments and tools from the field of soft computing. This system is realized using the real-time simulator and it is used for induction machine frequency converter prototyping. Advanced method for induction machine speed control is presented. System is also used for optimization of induction machine fuzzy speed controller utilizing meta-heuristic optimizer through cosimulation process.

First chapter presents mathematical models of all electric drive elements that are relevant for successful dynamical simulation using the real-time simulator.

Chapter two presents parts of the rapid control prototyping system used for electric drives. Main parts of this system are real-time simulator with the extension for digital and analog inputs and outputs, and power part that consists of passive filters and energy modules for frequency converter realization. Using the system, a model in the loop simulation of scalar controlled electric drive is executed and then scalar control is tested on the real machine. Simulated and real responses are then compared.

The third chapter presents conventional and advanced induction machine control methods with the emphasis on model predictive control methods, specifically model predictive torque, and model predictive current control. Model predictive current control is closely analyzed and adapted for operation with constant modulation frequency. Main contribution regarding this algorithm is proof of stability using the classic eigenvalue analysis, which makes weighing factor matrix that is usually used to ensure stability obsolete. Proposed method

is compared with another method from the family of model predictive control methods and the improvement in electromagnetic torque spectrum is clearly visible.

Chapter four represents additional improvements of induction machine predictive current control where speed PI controller gets replaced with fuzzy speed controller. Parameters of the fuzzy speed controller are optimized using meta-heuristic optimizer. Optimization is executed through cosimulation where real-time simulator executes electric drive simulation, and optimizer receives the results based on which it generates new set of parameters. Induction machine responses controlled by fuzzy controller are compared with the responses obtained by several different methods which shows improvement in electric drive speed and torque responses.

BIOGRAFIJA

Toni Varga rođen je 24.11.1992. godine u Osijeku. Po završetku osnovne škole Frana Krsto Frankopana, upisuje Elektrotehničku i prometnu školu Osijek, smjer "Elektrotehničar". Nakon završetka srednje škole upisuje Elektrotehnički Fakultet Osijek te za vrijeme studija aktivno sudjeluje u radu različitih volonterskih društava te radi kao demonstrator u laboratoriju za energetsku elektroniku.

Fakultet završava 2017. godine kada se zapošljava u informatičkoj tvrtki Adcon, gdje radi kao tester programskih rješenja u telekomunikacijskim sustavima. Godine 2018. zapošljava se u tvrtki Capital Hook, gdje radi kao razvojni inženjer na ugradbenim sustavima.

Iste godine zapošljava se na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Osijek kao asistent na projektu "Razvoj postupaka kosimulacija programskih alata za primjenu mekog računarstva u elektroenergetici COPESOC", pod vodstvom izv.prof.dr.sc. Marinka Barukčića. Za vrijeme trajanja poslijediplomskog studija, 2021. godine, dobiva nagradu za uspješnost u studiranju. Tokom rada na fakultetu objavio je sveukupno 19 radova, od kojih je 6 radova indeksirano u WoS CC bazi te drži laboratorijske vježbe iz Osnova elektrotehnike u prvom semestru preddiplomskog i Elektromotornih pogona u šestom semestru stručnog studija.