Upravljanje pogonom vjetroelektrana zasnovano na sinkroniziranim mjerenjima

Klarić, Mario

Doctoral thesis / Disertacija

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Electrical Engineering and Computing / Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:168:269736

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**



Repository / Repozitorij:

FER Repository - University of Zagreb Faculty of Electrical Engineering and Computing repozitory







Sveučilište u Zagrebu
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

MARIO KLARIĆ

UPRAVLJANJE POGONOM VJETROELEKTRANA ZASNOVANO NA SINKRONIZIRANIM MJERENJIMA

DOKTORSKI RAD

Mentor: prof. dr.sc. Igor Kuzle

Zagreb, 2019. godina.



University of Zagreb
FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING

MARIO KLARIĆ

CONTROL OF WIND POWER PLANTS OPERATION BASED ON SYNCHRONIZED MEASUREMENTS

DOCTORAL THESIS

Supervisor: prof. dr.sc. Igor Kuzle

Zagreb, year 2019

Doktorski rad izrađen je u Zavodu za visoki napon i energetiku Fakulteta elektrotehnike i računarstva te u tvrtkama Dalekovod d.d. – Zagreb i Dalekovod-Projekt d.o.o. iz Zagreba.

Mentor: prof. dr. sc. Igor Kuzle

Doktorski rad ima: 237 stranica

Doktorski rad br.

ŽIVOTOPIS MENTORA

Prof. dr. sc. Igor Kuzle Igor Kuzle rođen je 1967. godine. Osnovnu i srednju školu završio je u Požegi. Diplomirao je 1991. godine, magistrirao 1997. godine i doktorirao 2002. godine na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu. Nakon diplomiranja zaposlio se 1992. godine na Zavodu za visoki napon i energetiku, Fakulteta elektrotehnike i računarstva Sveučilišta u Zagrebu. Za znanstvenog savjetnika izabran je 2012. godine. Igor Kuzle se bavi istraživanjima iz područja regulacije, dinamike, modeliranja i održavanja elemenata elektroenergetskog sustava te problemima vezanim s uvođenje i organizaciju tržišta električne energije. Iz predmetnih područja objavio je jedan sveučilišni udžbenik (Tržište električne energije, Graphis, Zagreb, 2009.), više internih sveučilišnih skripata te dva srednjoškolska udžbenika. Objavio je više članaka u prestižnim svjetskim časopisima, a ukupno je publicirao više od 200 radova uključujući i radove napravljene za privredne subjekte. Član je uredničkog odbora 12 međunarodnih znanstvenih časopisa od kojih je izvanredni urednik (engl. Associate editor) u 3 časopisa. Sudjelovao je u organizaciji i radu većeg broja međunarodnih konferencija i radionica na kojima je održao više pozvanih predavanja te prezentacija konferencijskih radova. Bio je ili je predsjedavajući konferencija IEEE EUROCON 2013, Zagreb, 01-04.7.2013. i IEEE ENERGYCON 2014 Cavtat, 13.-16.05.2014., a bio je ili je predsjednik lokalnog organizacijskog odbora na konferencijama: European Energy Market 2011, Zagreb, 25.-27.05.2011. i PAC World 2014, Zagreb, 24-26.06.2014. Sudjelovao je na više znanstvenih projekata od kojih su najznačajniji FP7 projekti: - "ACROSS - Centre of Research Excellence for Advanced Cooperative Systems", voditelj grupe Electric Power System Dynamics, Automatization and Control (EPSDAC), 01.10.2011.-31.03.2015. - "DYMASoS – Dynamic Management of Physically Coupled Systems of Systems", istraživač, 01.10.2013.-31.09.2016. - "EYE - Empowering Young Explorers", koordinator za Hrvatsku, 01.11.2013.-01.11.2015. - "Flex-ChEV - Advanced Infrastructures for Electric Vehicle Charging Stations", voditelj i koordinator za Hrvatsku, 01.03.2014.-01.03.2016. Od međunarodnih strukovnih organizacija aktivan je u najvećoj svjetskoj udruzi inženjera elektrotehnike i elektronike sa sjedištem u New Yorku (IEEE). U periodu 2009.-2012. bio je predsjednik Hrvatske sekcije IEEE, od 2011. godine predstavnik je svih IEEE odjela Industrijske primjene za Europu, Afriku i Bliski Istok, a od 2010. godine predstavnik je svih IEEE odjela Elektroenergetike središnju Europu i Skandinaviju. Član je i više domaćih strukovnih organizacija i društava (HRO CIGRÉ, HKIE, HDO). U periodu 2008.-2012 bio član izvršnog odbora Hrvatskog ogranka CIGRÉ i predsjednik Studijskog odbora C2 (Pogon i vođenje elektroenergetskog sustava). Od 2012. član je Stalne koordinacije Hrvatskog operatora prijenosnog sustava d.o.o. za priključenje obnovljivih izvora energije na prijenosni sustav RH kao i član Savjetodavnog stručnog povjerenstva u Ministarstva zaštite okoliša i prirode u postupcima procjene utjecaja vjetroelektrana na okoliš. Bio je voditelj na više od 50 stručnih projekata financiranih od privrede.

MENTHOR'S CURRICULUM VITAE

Prof. dr. sc. Igor Kuzle Igor Kuzle was born in 1967. He finished elementary and high school in Pozega. He graduated in 1991, received his master's degree in 1997 and his doctorate in 2002 at the Faculty of Electrical Engineering and Computing, University of Zagreb. After graduation, he took a job in 1992 at the Department of High Voltage and Power Engineering, Faculty of Electrical Engineering and Computing, University of Zagreb. He was elected Scientific Advisor in 2012. Igor Kuzle is engaged in research in the field of regulation, dynamics, modeling and maintenance of elements of the power system and problems related to the introduction and organization of the electricity market. From the subject areas he published one university book (Electricity Market, Graphis, Zagreb, 2009), several internal university scripts, and two high school textbooks. He has published several articles in prestigious world journals, and has published more than 200 works, including works made for businesses. He is a member of the editorial board of 12 international scientific journals, of which he is associate editor in 3 journals. He participated in the organization of a number of international conferences and workshops, at which he held several invited lectures and presentation of conference papers. He was chair of the IEEE EUROCON 2013 Conference, Zagreb, 01-04.7.2013. and IEEE ENERGYCON 2014 Cavtat, May 13-16, 2014, and was or was chairman of the local organizing committee at conferences: European Energy Market 2011, Zagreb, May 25-27, 2011. and PAC World 2014, Zagreb, June 24-26, 2014. He has participated in several scientific projects, the most significant of which are FP7 projects: - "ACROSS - Center for Research Excellence for Advanced Cooperative Systems", Head of Electric Power System Dynamics, Automation and Control (EPSDAC) Group, 01.10.2011.-31.03.2015. - "DYMASoS - Dynamic Management of Physically Coupled Systems of Systems", Researcher, 01/10/2013 - 09/31/2016. - "EYE - Empowering Young Explorers", Coordinator for Croatia, 01.11.2013.- 01.11.2015. - "Flex-ChEV - Advanced Infrastructures for Electric Vehicle Charging Stations", Head and Coordinator for Croatia, 01.03.2014.-01.03.2016. He is active in the largest electrical engineering and electronics engineers association based in New York (IEEE) from international professional organizations. In the period 2009-2012. he has been the President of the IEEE Croatian Section, since 2011 he has been a representative of all IEEE Departments of Industrial Application for Europe, Africa and the Middle East, and since 2010 he has been a representative of all IEEE Departments of Central Europe and Scandinavia. He is also a member of several domestic professional organizations and societies (HRO CIGRÉ, HKIE, HDO). In the period 2008-2012 he was a member of the executive board of the Croatian branch of CIGRÉ and chairman of the C2 Study Committee (Power System Operation and Maintenance). Since 2012 he is a member of the Permanent Coordination of the Croatian Transmission System Operator d.o.o. for connection of renewable energy sources to the transmission system of the Republic of Croatia, as well as a member of the Advisory Expert Commission of the Ministry of Environment and Nature in the environmental impact assessment procedures of wind farms. He has been the leader on more than 50 professional projects funded by the industry.

Mojoj obitelji

SAŽETAK

Intermitirajuća narav električne energije proizvedene iz vjetroelektrana čini velike probleme prilikom vođenja elektroenergetskog sustava i time ograničava njihovu veću integraciju. Paralelno s tim procesom, proces starenja postojeće infrastrukture također predstavlja dodatne izazove vlasnicima i operaterima infrastrukture zbog potreba za velikim kapitalnim investicijama. Korištenje naprednih i sinkroniziranih mjernih tehnologija nameće se kao jedno od rješenja za veću integraciju vjetroelektrana i obnovljivih izvora u cjelini. U ovom se radu opisuje rješenje vođenja pogona vjetroelektrane korištenjem tehnika rudarenja podataka na skupu sinkroniziranih mjernih podataka iz PMU jedinica i ostalih naprednih mjerenja. Pri tom se postojeća infrastruktura može koristiti kao osnovna platforma u kojoj se sve dodatne instalacije mogu brzo i jednostavno izvršiti modularno i adaptivno. U radu je opisan model upravljanja pogonom vjetroelektrana zasnovan na metodi klasterizacije te klasifikacije pogonskih stanja uporabom klasifikacijskih i regresijskih stabala odlučivanja te uporabom sinkroniziranih podataka generiranih iz mjernih i senzorskih uređaja. Algoritam odlučivanja o režimu pogona vjetroelektrane izrađen je u obliku stabla odlučivanja. Konačni model upravljanja i algoritam odlučivanja verificirani su korištenjem testnog modela te na mjernim podacima iz elektroenergetskog sustava. Pokazane su mogućnosti primjene ovakvih metoda i algoritama kao i proširivost na veće količine električkih i neelektričkih podataka koje će se generirati u elektroenergetskim sustavima.

KLJUČNE RIJEČI

elektroenergetski sustav, vjetroelektrana, sinkronizirana mjerenja, vođenje pogona, rudarenje podataka

THESIS TITLE:

CONTROL OF WIND POWER PLANTS OPERATION BASED ON SYNCHRONIZED MEASUREMENTS

SUMMARY

The intermittent nature of electricity produced from wind power plants poses major problems in the control of the power system and thus limits their bigger integration. Parallel to this process, the aging process of the existing infrastructure also poses additional challenges to infrastructure owners and operators due to the need for large capital investments. The use of advanced and synchronized measurement technologies is one of the solutions for greater integration of wind power and renewable resources as a whole. This thesis describes the solution of wind power plant operation using data mining techniques at a set of synchronized measurement data from PMU units and other advanced measurements. In this, the existing infrastructure can be used as a basic platform in which all additional installations can be done modularly and adaptively quickly and easily. This thesis describes a model of wind power plant control based on the clustering method and the classification of operating conditions by using classification and regression trees and using synchronized data generated from measuring and sensor devices.

An increase in the number of intelligent electronic devices, ie various measuring, monitoring, control and sensing devices installed in the power system, results in a constant increase in the amount of data transmitted and stored in the competent control centers and other hierarchical levels. The amount of data described will be increasing in the future as a further increase in the number of installed subject devices can be expected. This raises the possibility and need to analyze these new types of data not only by classical deterministic models, but also by new non-deterministic mathematical models. One of the key prerequisites for this is data consistency, harmonization and synchronization. Having all the data concentrated would enable efficient data storing and processing enhancing the current information stream with the extraction of right information from the big data surrounding. Key characteristic of such future infrastructure enhancements would need to be adaptivity towards existing power grid infrastructure and modularity to allow system’s components separation and recombination (“adaptidular” infrastructure). The most important benefits of the new infrastructure (Figure 3) following the adaptidular design paradigm can be described as following: • Existing capacities and possibilities of existing infrastructure enhancement and upgrading • Capital expenditures (CAPEX) postponing or abolishing (building of new lines, substations, power infrastructure reconstruction) due to availability of new information in asset management systems, dynamic line rating system, PMU systems etc. •

Maintenance cost cutting through the usage of predictive maintenance enabled through sensor networks and IoT gateways • Additional services provision: numerous additional services such as meteorological data assessment, air quality mapping, telecom services provision through IP/MPLS etc. Having all the data concentrated would enable efficient data storing and processing enhancing the current information stream with the extraction of right information from the big data surrounding. Key characteristic of such future infrastructure enhancements would need to be adaptivity towards existing power grid infrastructure and modularity to allow system's components separation and recombination ("adaptidular" infrastructure). The most important benefits of the new infrastructure following the adaptidular design paradigm can be described as following:

- Existing capacities and possibilities of existing infrastructure enhancement and upgrading
- Capital expenditures (CAPEX) postponing or abolishing (building of new lines, substations, power infrastructure reconstruction) due to availability of new information in asset management systems, dynamic line rating system, PMU systems etc.
- Maintenance cost cutting

This thesis describes one of the possibilities of using such harmonized and synchronized data using a data mining technique for the purpose of operating a wind farm.

In order to investigate the possibility and potential of wind power monitoring and control based on big data surrounding an algorithm for monitoring and incorporating synchrophasor measurement was developed. As described earlier, it has all the characteristics of adaptive and modular applications that can easily be installed and commissioned on the existing infrastructure. It also provides ability for later upgrades and integration into large scale applications.

The power system infrastructure produces huge amounts of data. The nonlinear nature of this data makes the extraction of useful information complicated. Compared to standard mathematical models, data mining techniques are non-deterministic and provide a feasible and valid solution which is not exact but is simple to obtain, concise, practical and easy to understand. This characteristic is especially suitable when processing the big data streams which are inevitably involved. As mentioned earlier, large wind power capacities are being installed and connected to different voltage levels. Every wind turbine, wind measuring masts inside the wind park transformer substations, etc. represent the source of large quantities of data every second. All these data streams can be further expanded with the installation of new data sensors arrays. These large quantities of data can be deemed unnecessary, but with the usage of different big data algorithms a way to monetize this data can be found. The most important data that can and should be used in power system data mining algorithms is the data for

state estimation and future power system state predictions. These data streams can be classified into three main groups:
1. Phasor values measurements;
2. Loads and production measurements;
3. Other influential variables measurements.

Phasor values like voltages and currents together with belonging phasor angles, can be gathered through PMU measurements and can provide valuable insights into system operation. Also, load and generation data with exact time stamp can easily be measured and collected to afterwards be used for different analyses.

Other influential variables of additional data that are not directly connected to power system monitoring and control are also sometimes highly influential. These include meteorological data from various kinds of measurement systems of which most important are wind speeds and wind directions, air temperature, humidity and pressure, solar irradiance measurements. Together with meteorological data, other measurements such as conductor temperatures, overhead line sags, partial discharges, current transmission line capacity obtained by dynamic line rating (DLR) systems etc. can also be collected. All these data series can be used in wind and solar power system monitoring and control as well as for load forecasting applications and power evacuation possibilities. The prerequisite is to have an efficient solution for data transmission and processing.

As described earlier, the huge amounts of data inside power creates the big data surroundings. The non-linear nature of the system makes the definition of new models for extraction of useful information from heaps of gathered data even more demanding. Especially demanding is the usage of data from wind power plants since these stochastic sources produce even bigger amounts of data due to dependable variables which influence the output power. Therefore, good data mining scope thus integrates wide area of variables. This paper defines simplified model which comprises of:

- Wind power plant active and reactive power production (PWind, QWind), at wind power plant point of common coupling (PCC);
- Wind power plant active and reactive power settings (PSettings, QSettings), which are operational decisions for the settings of wind power controller placed at wind power (PCC);
- Total system load measurements (PL), expressed in percentage, as a percentage of nominal load;
- Voltage amplitudes and angles (phasors) measurements (Vi , δi) on selected nodes in the system;
- Line, transformer and generator availability information

Each operating condition (OC) is defined as a mathematical set whose members are the following elements or variables: OCk = {V1, V2, V3, . . . Vi , δ1, δ2, δ3, . . . δi, PL, PWind, QWind, Zth} (1) - with i = 1, 2, 3, . . . n; where n is the number of nodes in power system with measurements of effective

values and voltage angles in the system, and - with k = 1, 2, 3, . . . m; where m—total number of input states over which data mining techniques are analyzed. The abovementioned data can be expanded by defining the finely tuned fractal structures attached to it: • Wind power total can be divided into wind power of single wind turbine or a cluster of turbines; • Total system load can be divided into loads on busbar, consumer, or load area level; • Voltage amplitudes and angles can be enhanced with current amplitudes and angles for each branch as well as Thevenin impedance measurements; • Wind production is defined with wind speed and can further be detailed with wind direction, air temperature and pressure, solar irradiance and air humidity measurements; • Line and transformer availability can further be described through breaker status in line bays and transformer bays or through transformer and line monitoring systems. All this data needs to form large and well-organized databases for further usage in control, planning, asset management and operation and maintenance (O&M) optimization process. Therefore, to take full advantage of the available data efficient algorithms for big data analysis are needed.

The proposed model of wind power plant management consists of a clustering part, which divides the existing metering and simulation data into three data clusters for normal, emergency and critical operating conditions, and then a classification part, thereby assigning previously defined data classes to the new metering data. The first scientific contribution of this paper was defined by the creation of a model of wind power plant control based on synchronized measurements.

In this way, the new metrics can define the transition of the power system from normal to emergency or critical state of the system and define a new so-called. Early Warning Signal (EWS) as a measure of security awareness (SA - Situational Awareness).

The aim of the developed algorithm is to create a new kind of early warning signal (EWS) and recognize the structure of critical transitions for transmission system and wind power operators in the form of a situational awareness (SA) indicator. These signals should be structured to warn the operators that the alarming operating condition could be reached and that preventive or corrective actions should be done (e.g., wind power curtailment or reactive power support increase) and thus move the system to normal operating state, like described in figure below. Created EWS signal as a situational awareness indicator serves as a main triggering signal for operating decisions in wind power settings in order to change operating condition back to EWS value NORMAL. Therefore, EWS could serve as a first line of defense to reduce the risks of total or partial system blackouts and thus reducing the opportunity costs associated with the costs of electric energy not being delivered. Commonly used data mining algorithms identified by the IEEE International Conferences on Data Mining (ICDM) are C4.5, k-Means, Support Vector Machine (SVM), Apriori, PageRank, AdaBoost, Neural Networks, Naive Bayes and Classification and regression trees

(C&RT). These 10 algorithms cover classification, clustering, statistical learning, association analysis, and link mining, which are all among the most important topics in data mining research and development.

The first step in the algorithm is data management and preparation which consists of time synchronization, format unifying, and ordering of historical raw data from actual power system measurements. Additionally, synthetic data which is produced and gathered from various kinds of simulations based on mathematical models is also included in this step.

In this way, mathematically defined power system states are defined as input data in the algorithm. It is important to note that except for the variables defined herein, the input set of system states can be extended to a whole range of additional input signals such as data from various measuring devices for measuring electrical and nonelectric values, meteorological measuring devices, sensors and other devices. The model is therefore adaptive and modular. It is easy to upgrade by simply expanding the operating condition (OC) math data set.

The second step is data clustering, with the aim of defining system states on a given database or set of operating conditions. For the algorithm design described in this paper, the analytics software package Statistica was used. Standard variable definition from statistical theory was used where an independent variable (also called experimental or predictor variable), is being manipulated in an experiment to observe the effect on a dependent variable (also called an outcome variable). Total set of operating conditions in this example to be a representative sample needs to be large enough and cover all possible system states and. K-Means algorithm with Euclidian distances was used for clustering of the initial data set.

The classification part of the model results in a decision tree that contains measurement variables, such as synchronized measurements, and control variables, such as wind power plant active and reactive power. The induced decision tree results in possible operating conditions that belong into normal, emergency and critical operating states clusters. As a final part of the operating mode decision algorithm, a simple optimization procedure is performed by selecting a possible normal operating condition with minimal reactive power production and maximum active power production. By defining the decision tree described above and performing a simple optimization procedure, a decision algorithm for changing the mode of operation of wind power plants was defined based on the characteristic values of the electrical parameters of the system in order to optimize the power system operation, and thus the second scientific contribution of this paper was defined.

Verification of the developed mathematical model based on measurements in a real power system was made using measurements made in the actual operation of the Zadar 6 wind power plant, connected to the 35 kV

distribution network, and the wind power plants Zadar 2 and Zadar 3, connected to the 110 kV transmission network. Verification of the mathematical model confirmed the tested mathematical model and the algorithm developed, and the third scientific contribution of this paper was defined.

The developed and tested model can be considered robust, since any type of parameter measurements identified as essential parameters for the operation of wind farms and the power system as a whole can serve as input to the algorithm. An essential prerequisite is that all metrics are standardized, harmonized and synchronized, which is quite difficult to achieve at this time, especially given the non-harmonization of measurement and communication standards and protocols for these different parameters.

Also, a necessary prerequisite is the existence of a record of operating states in all defined operating areas, ie normal, emergency and critical operating conditions. It is very difficult to obtain records of a state of emergency, and especially critical, operating condition in a real facility. Therefore, records in critical operating condition need to be made most often by simulations or so called synthetic or syntex data.

Continued research in this area primarily involves the production of more simulation records and data in the emergency and critical drive section. This gives a more granular granulation when creating a data cluster. Further upgrades include taking into account additional sets of other types of metrics, such as sensor data, in particular, from a series of sensors that will increasingly be installed in the power system.

Concerning the application of the mathematical model and the algorithm developed, it is currently necessary to define the market in the Croatian Power System with a reactive power regulation service. It is also necessary to systematically define ways of limiting the wind farm's operating power in terms of covering losses of wind farm owners.

KEY WORDS
power system, wind power plant, synchronized measurements, system control, data mining

SADRŽAJ

1. UVOD ... 1
1.1. Liberalizacija elektroenergetskih sektora u europi i svijetu ... 1
1.1.1 Vertikalno integrirani elektroenergetski sustavi ... 1
1.1.2 Horizontalno integrirani elektroenergetski sustavi ... 4
1.1.3 Neovisni proizvođači električne energije ... 5
1.2. Poticanje obnovljivih izvora električne energije ... 5
1.2.1 Proizvodnja energije iz obnovljivih izvora u EU ... 5
1.2.2 Stanje obnovljivih izvora energije u Hrvatskoj ... 6
1.2.3 Zakonska regulativa i buduće projekcije u Hrvatskoj ... 8
1.3. Vjetroelektrane u Europi i svijetu ... 9
1.3.1 Razvoj vjetroelektrana ... 9
1.3.2 Instalirani proizvodni kapaciteti vjetroelektrana ... 11
1.3.3 Buduće smjernice za vjetroelektrane u Europi ... 12
1.4. Pogon vjetroelektrana ... 15
1.4.1 Pretvorba energije vjetra ... 15
1.4.2 Izlazna snaga vjetroelektrane ... 18
1.4.3 Proračun snage vjetra ... 24
1.4.4 Topografski efekt na brzinu vjetra ... 28
1.4.5 Utjecaj turbulencije vjetra na snagu vjetroagregata ... 30
1.4.6 Utjecaj hrapavosti površine na snagu vjetroagregata ... 31
1.4.7 Utjecaj rada u sjeni na snagu vjetroagregata ... 37
1.4.8 Prolazak kroz kvar ... 40
1.5. Integracija vjetroelektrana u elektroenergetski sustav ... 42
1.5.1 Stabilnost elektroenergetskog sustava ... 42
1.5.2 Vođenje pogona EES-a uz integraciju vjetroelektrana ... 46
1.5.3 Problemi regulacije frekvencije i djelatne snage ... 49
1.5.4 Problemi regulacije napona i jalove snage ... 53
1.5.5 Mogućnost pružanja sistemskih usluga vjetroelektrana ... 56
2. NAPREDNE SINKRONIZIRANE MJERNE VELIČINE ... 58
2.1. Osnovna infrastruktura za korištenje naprednih sinkroniziranih mjerenja ... 58
2.1.1 Telekomunikacijska infrastruktura ... 58
2.1.2 Napredna mjerna infrastruktura ... 61
2.1.3 Pohranjivanje i obrada podataka ... 63
2.1.4 Integracija sustava naprednih mreža ... 65
2.2. Sinkrofazorske veličine ... 70
2.2.1 PMU tehnologija ... 70
2.2.2 Korištenje i funkcionalnosti PMU uređaja ... 71
2.2.3 Najbitnije primjene PMU tehnologije ... 73
2.2.4 Digitalne trafostanice ... 75
2.3. Meteorološke veličine ... 78
2.3.1 Mjerni stupovi ... 78
2.3.2 Mjerenja karakteristika vjetra ... 82
2.4. Senzorske veličine ... 86
2.4.1 Mjerenje temperature vodiča ... 86

2.4.2 Mjerenja provjesa nadzemnih vodova 88
2.4.3 Mjerenja naprezanja nadzemnih vodova 91
2.4.4 Dinamička prijenosna moć vodova 94

3. RUDARENJE PODATAKA 97
3.1. Općenito o rudarenju podataka 97
3.1.1 Tehnike rudarenja podataka 97
3.1.2 Aplikacije rudarenja podataka 99
3.1.3 Glavni nedostaci rudarenja podataka 101
3.1.4 Analiza velikih skupova podataka 102
3.2. Osnovne analize i procesi rudarenja podataka 105
3.2.1 Klasterizacija podataka 105
3.2.2 Klasifikacija podataka 108
3.2.3 Detekcija outliera 111
3.2.4 Indukcija stabala odlučivanja 113
3.2.5 Trendovi i istraživanja u rudarenju podataka 118
3.3. Primjene rudarenja podataka u EES-u 120
3.3.1 Najčešće tehnike rudarenja podataka u EES-u 120
3.3.2 Rudarenja podataka u svrhu analize sigurnosti EES-a 123
3.3.3 Rudarenja velikih količina podataka EES-a 125

4. VOĐENJE POGONA VJETROELEKTRANE TEHNIKOM RUDARENJA PODATAKA 127
4.1. Osnovni koncept modela 127
4.1.1 Razmjena i prijenos podataka 127
4.1.2 Obrada ulaznih podataka 129
4.1.3 Izlazni podaci i signali 132
4.1.4 Dijagram toka modela 135
4.2. Podatkovno rudarenje pogonskih stanja 138
4.2.1 Definicija pogonskih stanja 138
4.2.2 Kreiranje pogonskih stanja 139
4.2.3 Opis klasterizacijskog dijela algoritma 141
4.2.4 Opis klasifikacijskog dijela algoritma 142
4.3. Odlučivanje za promjenu režima rada vjetroelektrane 145
4.3.1 Definicija režima rada 145
4.3.2 Opis i obrazloženje donošenja odluka 148
4.3.3 Dodatne mogućnosti i nadopune 150

5. NUMERIČKI PRIMJERI I VALIDACIJA MODELA 151
5.1. IEEE model sa 14 čvorišta 151
5.1.1 Osnovni ulazni podaci 151
5.1.2 Rezultati modela 153
5.1.3 Validacija modela IEEE 14 158
5.2. Model vjetroelektrane Zadar 6 160
5.2.1 Osnovni ulazni podaci 160
5.2.2 Definicija varijabli i pogonskih stanja 163
5.2.3 Rezultati modela 167
5.2.4 Validacija modela VE Zadar 6 mjernim podacima 174
5.3. Model vjetroelektrane Zadar 2 i 3 177
5.3.1 Osnovni ulazni podaci 177

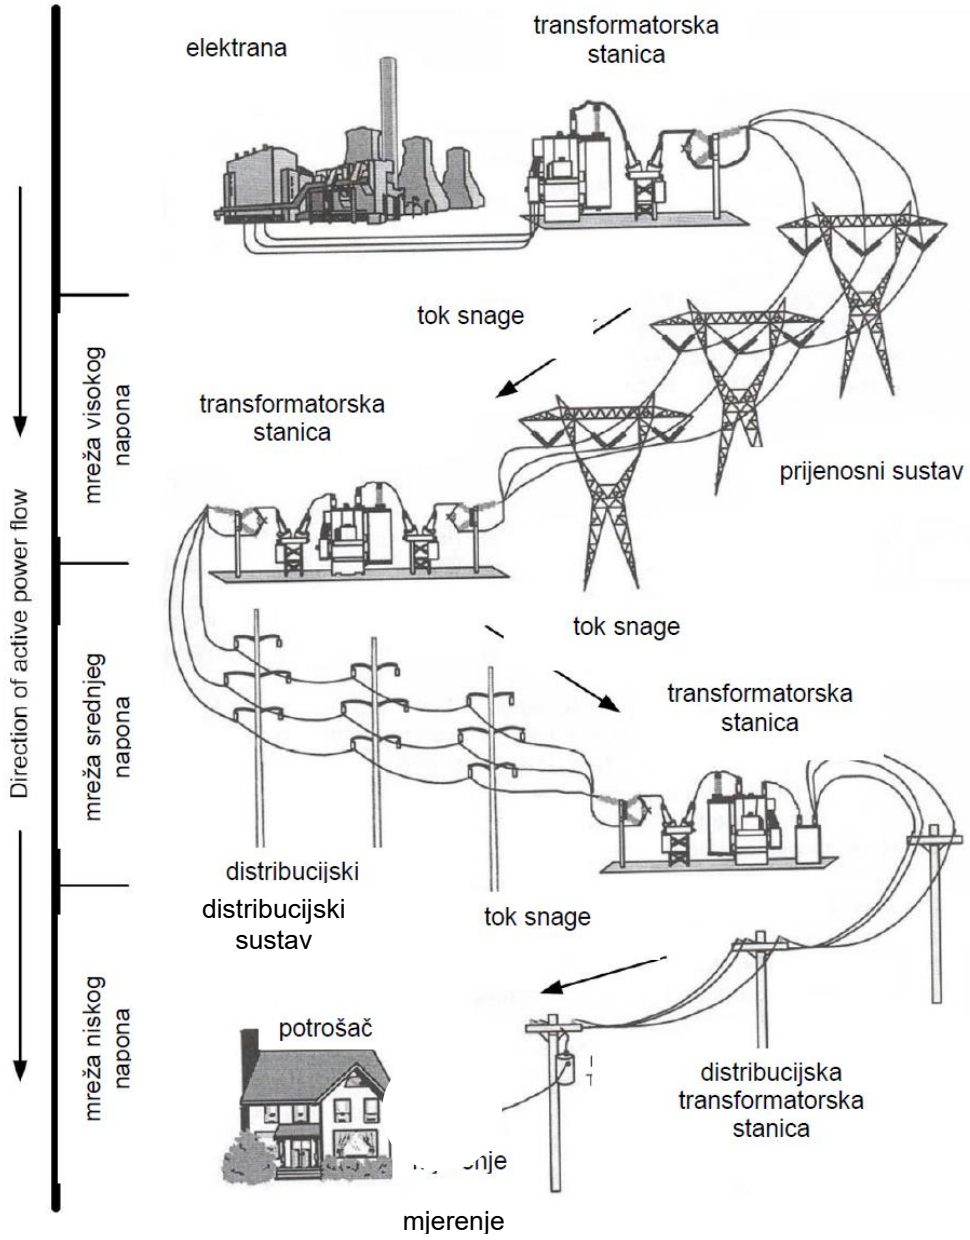
5.3.2 Definicija varijabli 180
5.3.3 Rezultati modela 184
5.3.4 Validacija modela VE Zadar 2 i 3 mjernim podacima 191
6. Zaključak 200
7. POPIS LITERATURE 202
POPIS RADOVA 217
POPIS OZNAKA 209
POPIS SKRAĆENICA 212
PRILOG A – POGONSKA STANJA MODELA IEEE 14 214
PRILOG B – POGONSKA STANJA MODELA VE ZADAR 6 215
PRILOG C – POGONSKA STANJA MODELA VE ZADAR 2i3 216

1. UVOD

1.1. LIBERALIZACIJA ELEKTROENERGETSKIH SEKTORA U EUROPI I SVIJETU

1.1.1 Vertikalno integrirani elektroenergetski sustavi

Elektroenergetski sustavi (EES) u svijetu tradicionalno su bili organizirani u vertikalno strukturiranim poduzećima. Proizvodnja u takvim sustavima odvijala se centralizirano u nekoliko većih proizvodnih jedinica, a jedno poduzeće u državnom vlasništvu upravljalo je proizvodnom, prijenosnom i distribucijskom djelatnošću. Veće proizvodne jedinice unutar takvih sustava uglavnom su bile smještene na udaljenim lokacijama blizu izvora energetskog resursa (ugljenokopa, rijeke, izvora nafte...) ili opskrbnih pravaca te relativno daleko od centara potrošnje. Električna energija prenosi se od istih izvora do zemljopisno disperziranih krajnjih potrošača hijerarhijskom strukturom prijenosne visokonaponske mreže, te distribucijskih srednjenaponskih i niskonaponskih mreža kako je slikovito prikazano na slici 1.1.



Slika 1.1 Vertikalno integrirani elektroenergetski sustavi

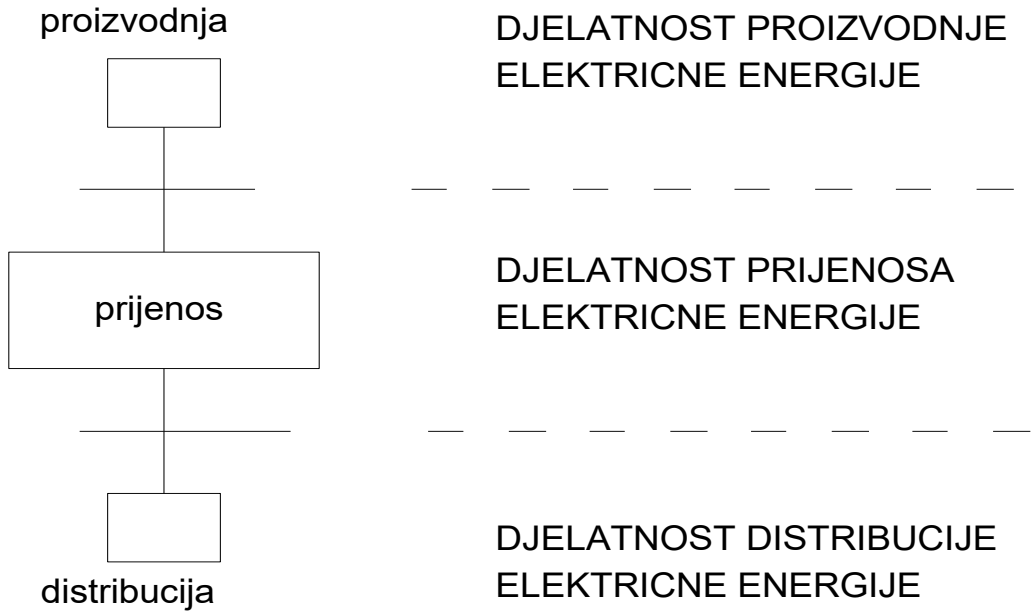
Da bi se osigurala visoka sigurnost i dostupnost opskrbe električnom energijom, prijenosne mreže su uzamčene s ciljem osiguranja alternativnog pravca napajanja u slučaju kvara na jednom od vodova.

Distribucijske mreže uglavnom su bile pasivni sustavi, iako se u posljednje vrijeme sve više proizvodnje priključuje upravo na distribucijsku mrežu koja je najčešće u radijalnom pogonu zbog omogućavanja selektivnosti zaštite.

Proizvodnja električne energije u vertikalnim elektroenergetskim sustavima uglavnom se temeljila na upravljivim izvorima energije kao što su termoelektrane na fosilna goriva ili pribranske hidroelektrane. Povijesno

gledano, rast potrošnje električne energije uzrokovao je izgradnju dodatnih centraliziranih elektrana, novih prijenosnih vodova te proširenje tradicionalnih distribucijskih sustava. Međutim, rješavanje problema prijenosnih kapaciteta izgradnjom novih nadzemnih visokonaponskih vodova postaje iznimno teško zbog troškova same izgradnje, ali i nedostatka prostora za smještaj koridora te otpora javnosti uslijed povećanih razina električnih i magnetskih polja. Ovi problemi kombinirani sa svjetskim trendovima deregulacije i liberalizacije elektroenergetskog sektora, ubrzali su proces otvaranja tržišta električnom energijom te upotrebe distribuirane proizvodnje unutar EES-a.
Liberalizirani elektroenergetski sustavi u kojima je omogućen slobodan pristup mreži pruža veće šanse manjim jedinicama instaliranim neposredno blizu potrošnje, a koje zahtijevaju i manje investicije i kraće vrijeme izgradnje. Koristi od proizvodnje električne energije blizu opterećenja uključuju i iskorištavanje otpadne topline u kogeneraciji za grijanje i hlađenje te napajanje određenih potrošača u slučaju raspada sustava kao i niz ostalih prednosti.

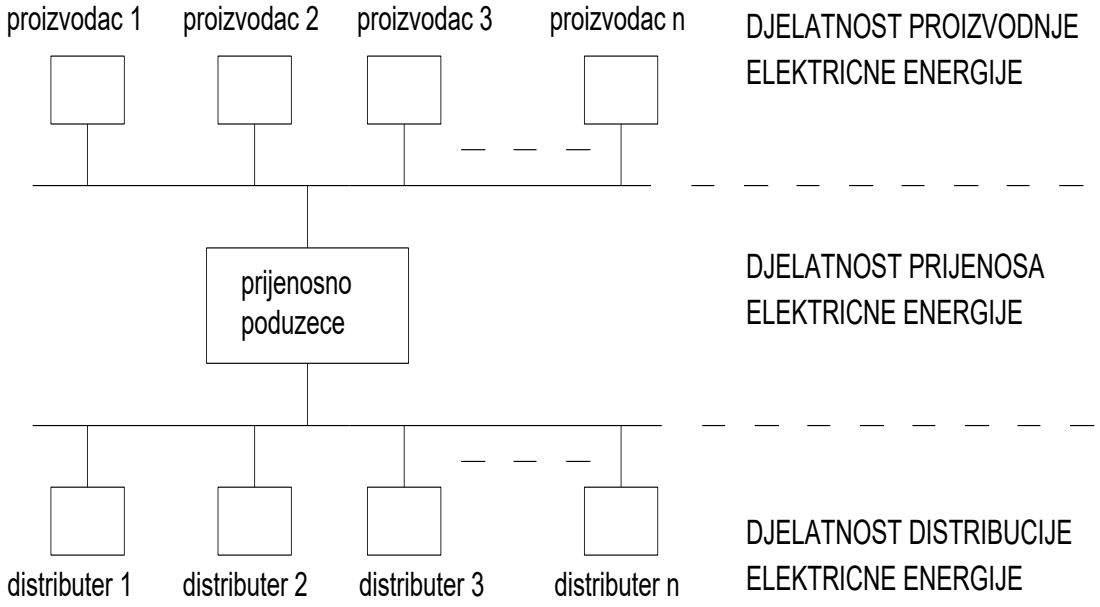
Jedinstvena, vertikalna struktura EES-a, u kojoj nema razdvajanja na proizvodnu, prijenosnu i distribucijsku djelatnost ima velike prednosti kao što su ekonomija razmjera korištenjem velikih centraliziranih proizvodnih jedinica, redukcija potrebnih rezervi proizvodnje, minimizacija troškova električne energije prebacivanjem proizvodnje odnosno dispečingom proizvodnih jedinica, upravljanje dijagramom opterećenja, veća energetska efikasnost korištenjem manjeg broja većih proizvodnih jedinica s manjim pogonskim troškovima, smanjenje rizika itd. Shematski prikaz vertikalno integriranih sustava dat je na sljedećoj slici.



Slika 1.2 Shematski prikaz vertikalno strukturiranih elektroenergetskih sustava

1.1.2 Horizontalno integrirani elektroenergetski sustavi

Usprkos ovim očitim prednostima, konvencionalna proizvodnja električne energije nailazi na velik otpor ponajprije zbog sociooloških i ekoloških karakteristika što se manifestira iznimno visokim tzv. NIMBY (eng. Not In My Back Yard) sindromom. Ta pojava prisutna je i generalno prilikom gradnje elektroenergetskih objekata [L 2]. Također, postojao je određeni zahtjev i pritisak neovisnih proizvođača električne energije za ulazak na tržište. Sve navedeno je posljednjih godina rezultiralo novim politikama i pravcima u elektroenergetici koje su se počele više oslanjati na tzv. nekonvencionalne izvore energije bazirane na distribuiranoj proizvodnji i korištenju obnovljivih izvora energije. Direktivom Europskog Vijeća i Parlamenta 96/92/EC iz 1996. godine definirana su temeljna načela liberalizacije elektroenergetskih sektora u Europi. Istom direktivom određena su zajednička pravila na tržištu električnom energijom unutar Europske Unije. Države članice Europske Unije obvezale su se razdvojiti proizvodnu, prijenosnu i distribucijsku djelatnost te dopustiti slobodan pristup elektroenergetskoj mreži trećoj strani (eng. Third Party Access) te njihovo nastupanje na tržištu električne energije.
Ovom direktivom omogućeno je stvaranje prvih neovisnih poduzeća koja nastupaju na tržištu električne energije te koja se priključuju na elektroenergetsku mrežu. Rezultat je ,,pucanje" vertikalnih veza u elektroprivrednim poduzećima te razdvajanje djelatnosti proizvodnje, prijenosa i distribucije električne energije u posebne neovisne tvrtke (eng. Unbundling) te postupno uvođenje konkurencije u djelatnosti proizvodnje i distribucije.



Slika 1.3 Shematski prikaz horizontalno strukturiranih elektroenergetskih sustava

2003. donesena je nova direktiva 2003/54/EC kojom se ukida postojeća direktiva 96/92/EC te kojom se smanjuju mogućnosti dominacije na tržištu električne energije te jednako tako smanjuju vjerojatnosti predatorskog ponašanja određenih elektroprivrednih poduzeća. Obje direktive doprijenele su razvoju elektroenergetskih sustava te osobito pojavu novih neovisnih proizvođača električne energije.

1.1.3 Neovisni proizvođači električne energije

Neovisni proizvođač električne energije (eng. Independent Power Producer – IPP) je fizička ili pravna osoba koja je neovisna od javne elektroprivrede i koja posjeduje postrojenja za proizvodnju električne energije. Proizvedenu električnu energiju neovisni proizvođač prodaje na tržištu električne energije ili posebno odabranom kupcu preko bilateralnog ugovora.

Prodajom električne energije proizvođači ostvaruju određeni prihod i dobit, a čija veličina ovisi o efikasnosti i ekonomičnosti rada postrojenja za proizvodnju. U početku su neovisni proizvođači energije uglavnom bila postrojenja na prirodni plin koja su svojom cijenom proizvodnje električne energije odnosno ukupnim troškovima proizvodnje, mogla biti konkurentna na tržištima električne energije koja su se postepeno otvarala. Isti proizvođači ostvarivali su svoja prava ugovorom o otkupu električne energije (eng. Power Purchase Agreement – PPA) po određenoj cijeni.

To se međutim nije moglo reći i za proizvođače električne energije koji su koristili obnovljive izvore energije, ponajprije jer su investicijski troškovi takvih elektrana bili iznimno veliki. Stoga su države morale osmisliti inicijative i strategije te ih predočiti u zakonsku regulativu s ciljem poticanja proizvodnje električne energije iz obnovljivih izvora. Takve inicijative najčešće su se sastojale od uvođenja tzv. feed-in tarifa pri čemu je bio zagarantiran otkup cjelokupne proizvedene energije po povlaštenoj cijeni.

1.2. POTICANJE OBNOVLJIVIH IZVORA ELEKTRIČNE ENERGIJE

1.2.1 Proizvodnja energije iz obnovljivih izvora u EU

Ovisnost EU-a o uvozu energenata vrlo je velika i stalno raste. U 1990. godini ona je iznosila 44,6 posto, a 2006. - 53,8 posto. Najveca je uvozna ovisnost o tekucem gorivu (83,7%) zatim o plinu (60,8%) i krutim gorivima (41,4%). Kod uvoza tekuceg goriva dominira uvoz iz Rusije (33,5%) i Norveške (15,8%). Uvoz plina je najveci iz Rusije (42,0%), Norveške (24,2) i Alžira (18,2%), a uvoz ugljena se uglavnom realizira iz šest zemalja (Rusija 25,8%, Južna Afrika 25,0%, Australija 12,8%, Kolumbija 12,3%, Indonezija 9,6% i SAD 8,1%). Kao osnovna poluga u realizaciji glavnih ciljeva zajednicke europske energetske buducnosti postavljeni su obnovljivi izvori

energije pa zadnje projekcije predviđaju 23% električne energije iz obnovljivih izvora do 2021. [L 1]
23. travnja 2009. godine EU parlament i Savjet donijeli su odgovarajucu Direktivu 2009/28/EC koja sadrži niz elemenata bitnih za stvaranje nužne regulative za ispunjenje postavljenih ciljeva proizvodnje električne energije iz obnovljivih izvora energije do 2020. godine. Ta direktiva postavlja obvezujuce nacionalne ciljeve s obzirom na udio obnovljivih izvora u ukupnoj finalnoj potrošnji energije u 2020. godini. Nacionalni ciljevi izracunati su tako da se na postotni udio OI u 2005. godini za svaku državu dodaje jedinstveni porast od 5,5 posto te dodatno povecanje koje ovisi o BDP-u u pojedinoj zemlji. Postavljeni su i međuciljevi za pojedine godine.

1.2.2 Stanje obnovljivih izvora energije u Hrvatskoj

Inicijative kao što su investicije u vjetroelektrane i ostale obnovljive izvore energije u RH su iznimno zanimljive s tehno-ekonomskog aspekta. Razlog tome je iznimno dobar vjetropotencijal, naročito u priobalnom području, ali i potencijal za razvoj ostalih tipova obnovljivih izvora energije. Budući da je energetika jedan od najbitnijih dijelova gospodarstva svake države, Hrvatska bi trebala posvetiti punu pozornost ovim pitanjima.

Prema studiji koja je provedena u sklopu nacionalnog energetskog programa ENWIND i koju je proveo Energetski institut Hrvoje Požar, 1998. je na 29 makrolokacija na otocima, poluotoku Pelješcu i u priobalju procijenjena mogućnost izgradnje 400 MW vjetroelektrana od čega 209 MW na otocima i 163 MW na obali Jadranskog mora. Na tim lokacijama programom ENWIND bila je predviđena moguća godišnja proizvodnja od oko 800 GWh električne energije. Detaljnije analize manjeg broja makrolokacija izvedene su u aranž,anu privatnih tvrtki i na temelju kvalitetnijih podloga i novih spoznaja te uz korištenje suvremenih alata za mikrolociranje Osim spomenutih lokacija definirano je i obrađuje se preko 70 novih lokacija, uglavnom u zaobalju, naročito nakon zakonske zabrane gradnje vjetroelektrana na otocima i 1000 m od obale mora.

Ista zabrana gradnje u tzv. zaštićenom priobalnom pojasu, a sukladno Uredbi o uređenju i zaštiti zaštićenog obalnog područja mora (NN br. 128/2004), izbacila je iz prvog plana mnoge iznimno dobre lokacije koje su bile među najspremnijima za daljnju realizaciju.

U Hrvatskoj su trenutno u pogonu sljedeće vjetroelektrane:

Tablica 1-1 Izgrađene vjetroelektrane u Hrvatskoj (izvor HROTE)

Vjetroelektrana	Instalirana snaga (MW)	Županija
VE Danilo	43.0	Šibensko-kninska
VE Vrataruša	42	Ličko-senjska
VE Kamensko-Voštane	40	Splitsko-dalmatinska
VE ZD2 i ZD 3 (Bruška)	36.8	Zadarska županija
VE Ponikve	34	Dubrovačko-neretvanska
VE Jelinak	30	Splitsko-dalmatinska
VE Trtar-Krtolin	11.2	Šibensko-kninska
VE Crno Brdo	10	Šibensko-kninska
VE Orlice	9.6	Šibensko-kninska
VE Zadar 6 (V.Popina)	9.2	Zadarska
VE Ravne 1	6	Zadarska
VE Pometeno Brdo	17.5	Splitsko-dalmatinska
VE Zadar 4	9	Zadarska
VE Rudine	34.2	Dubrovačko-neretvanska
VE Katuni	39	Splitsko-dalmatinska
VE Lukovac	42	Splitsko-dalmatinska
VE Zelengrad	42	Zadarska
VE Glunča	23	Šibensko-kninska
VE Ogorje	42	Splitsko-dalmatinska
Ukupno	477,5	

Iz pogleda na prethodnu tablicu vidljivo je da se gotovo sve vjetroelektrane nalaze u tri primorske županije odnosno na vrlo maloj geografskoj udaljenosti što uzrokuje veliku korelaciju proizvodnje električne energije iz energije vjetra u Hrvatskom elektroenergetskom sustavu.

1.2.3 Zakonska regulativa i buduće projekcije u Hrvatskoj

Zakonska energetska regulativa koja definira i pravno regulira cijeli elektroenergetski sektor, a samim tim i poticanje korištenja obnovljivih izvora energije relativno je mladog vijeka. 2004. u Hrvatskoj je donesen Zakon o energiji te Zakon o tržištu električne energije i Zakon o regulaciji energetskih djelatnoti. Ovim paketom energetskih zakona bilo je definirano da je korištenje obnovljivih izvora energije od interesa za Republiku Hrvatsku te da će konkretne mjere poticanja obnovljivih izvora energije biti donesene posebnim pripadajućim pravilnicima. Podzakonski akti iz područja obnovljivih izvora energije doneseni su ipak tek tri godine kasnije tj. 2007. godine i to konkretno:

- Tarifni sustav za proizvodnju električne energije iz obnovljivih izvora energije i kogeneracije (NN br. 33/2007),
- Uredba o minimalnom udjelu električne energije proizvedene iz obnovljivih izvora i kogeneracije čija se proizvodnja potiče (NN br. 33/2007),
- Uredba o nkanadama za poticanje proizvodnje električne energije iz obnovljivih izvora energije i kogeneracija (NN br. 33/2007),
- Pravilnik o korištenju obnovljivih izvora energije i kogeneracije (NN 67/2007),
- Pravilnik o stjecanju statusa povlaštenog proizvođača električne energije (67/2007).

Sve vjetroelektrane izgrađene su u skladu s ovim zakonskim paketom.

U ovom trenutku su na snazi bitno izmijenjeni

- Pravilnik o korištenju obnovljivih izvora energije i kogeneracije (NN 88/2012),
- Pravilnik o stjecanju statusa povlaštenog proizvođača električne energije (NN 132/2013, 81/2014, 93/2014, 24/2015, 110/2015),
- Tarifni sustav za proizvodnju električne energije iz obnovljivih izvora energije i kogeneracije (NN 133/2013, 151/2013, 20/2014, 107/2014, 100/2015),
- Uredba o naknadama za poticanje proizvodnje električne energije iz obnovljivih izvora energije i kogeneracije (NN 128/2013),

Prvotnim kompletom zakona proizvođači električne energije iz obnovljivih izvora energije, u koje spadaju i vjetroelektrane, definirani su kao povlašteni proizvođači električne energije te im se jamči povlaštena cijena proizvedene električne energije u periodu 12 godina. Na taj način neovisni proizvođači energije mogu ostvariti povrat svojih investicija u projekt.

Temeljem zakona o tržištu električnom energijom operator prijenosnog sustava i operator distrbucijskog sustava dužni su osigurati nesmetan pristup mreži (eng. third party access) te preuzeti ukupno proizvedenu električnu energiju od povlaštenog proizvođača.

Pravilnikom korištenju obnovljivih izvora energije i kogeneracije definiran je Registar projekata za korištenje obnovljivih izvora energije i kogeneracije te povlaštenih proizvođača. Također, definirani su uvjeti korištenja postrojenja obnovljivih izvora energije te određeni potrebni koraci koje je povlašteni proizvođač dužan učiniti kako bi ishodio prethodno, a potom i konačno odobrenje za gradnju postrojenja. Ovi koraci potrebni su prije ishođenja lokacijske i građevinske dozvole sukladno Zakonu o gradnji. Hrvatska energetska regulatorna agencija (HERA) izdaje rješenje o stjecanju statusa povlaštenog proizvođača prema Pravilniku o stjecanju statusa povlaštenog proizvođača električne energije. Otkup proizvedene električne energije iz postrojenja koja koriste obnovljive izvore energije i kogeneracijskih postrojenja reguliran je preko Hrvatskog regulatora tržišta energije (HROTE).

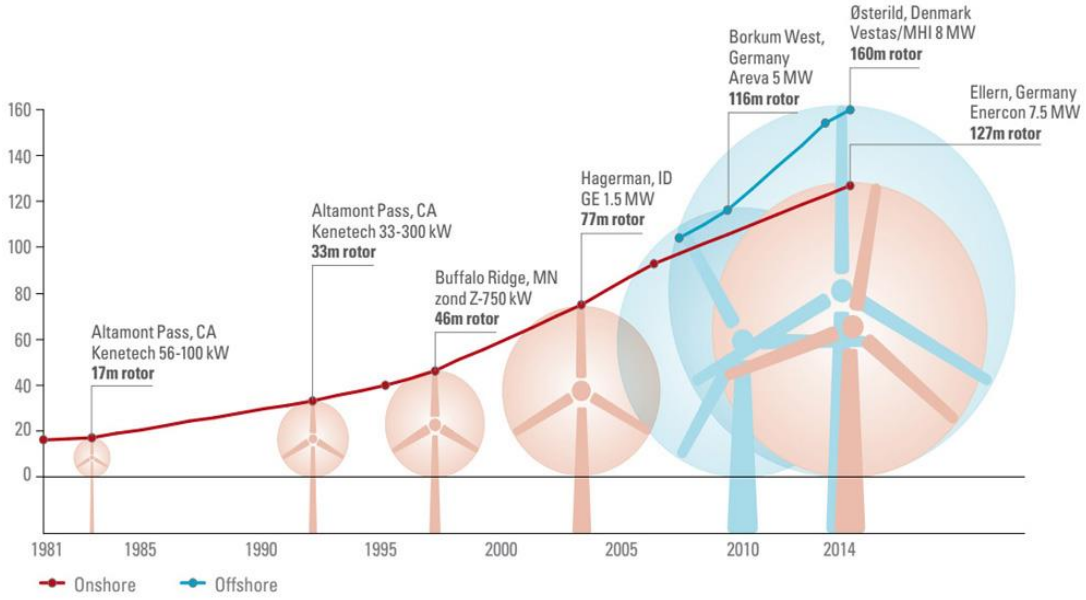
Iako ovi zakoni i pravilnici višenisu na snazi, svi objekti vjetroelektrana izgrađeni su u skladu s tom regulativom.

U ovom trenutku nema novih pravilnika koji bi definirali način poticanja izgradnje vjetroelektrana, ali najvjerojatnije će model poticanja predstavljati tzv. premijski model.

1.3. VJETROELEKTRANE U EUROPI I SVIJETU

1.3.1 Razvoj vjetroelektrana

Energija vjetra koristi se uspješno već stoljećima za podizanje vode, pogon brodova itd. To je vrlo atraktivan i nezagađujući izvor električne energije. Međutim, tek negdje sredinom 80-ih godina ista se značajnije počinje koristiti za opskrbu električnom energijom. Energija vjetra nameće se kao jedan od najisplativijih obnovljivih izvora električne energije. Razvoj vjetroturbina u nekoliko proteklih godina omogućio je izgradnju vjetroelektrana većih instaliranih snaga, a samim tim i proizvodnju veće količine električne energije uz smanjenje cijene za instalaciju i pogon pri proizvodnji iste. Također, osim klasičnih vjetroelektrana na kopnu (eng. onshore), omogućena je i izgradnja vjetroelektrana na moru (eng. offshore).



Slika 1.4 Razvoj veličine i snage vjetroagregata u posljednjih 30 godina (izvor EWEA)

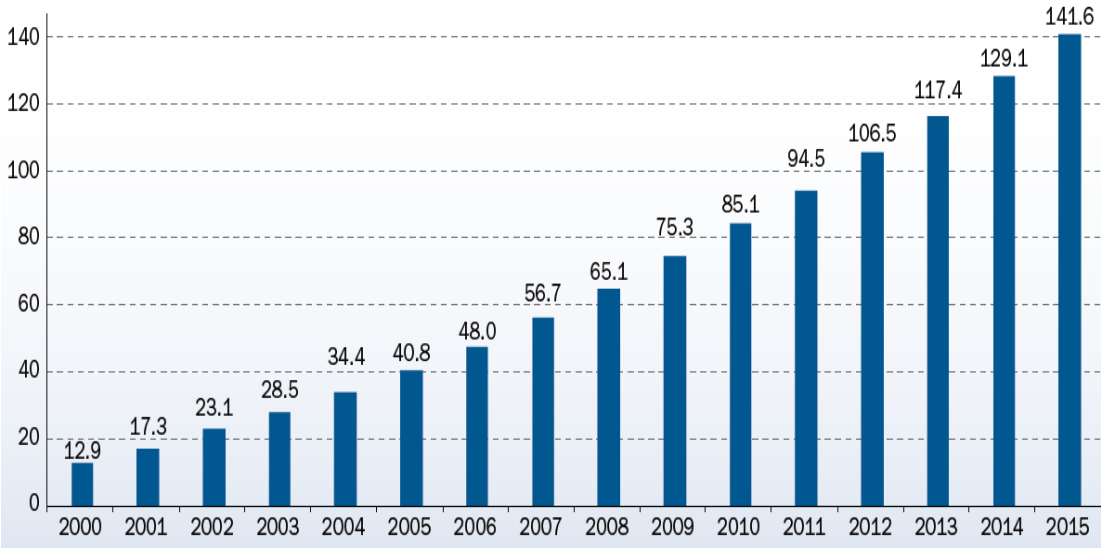
Opće značajke korištenja energije vjetra su obnovljivost, izrazita ekološka podobnost, dostupnost resursa, radna intenzivnost djelatnosti koja otvara nova radna mjesta te procijenjena mogućnost značajnog spuštanja cijene vjetroenergije kroz tehnološka poboljšanja i omasovljavanje upotrebe, potaknula su početkom osamdesetih prve intenzivnije napore za širu implementaciju vjetroenergetike unatoč tada još nekomercijalnom statusu i nekonkurentnim cijenama energije iz vjetra.

Korištenje energije vjetra pomoću vjetroelektrana nove tehnologije počelo je osamdesetih godina u Danskoj i Kaliforniji. Narednih godina razvoju u Europi pridružuju se tehnološki vodeće zemlje: Velija Britanija, Njemačka, Nizozemska i Švedska. Ove zemlje najveći su korisnici, ali i proizvođači vjetroenergetskih postrojenja. Grupi korisnika postupno se pridružuju i mediteranske zemlje, a u SAD-u druge njezine savezne države. Suvremene vjetroelektrane danas posjeduju zemlje Azije među kojima je vodeća Indija, a i Kina i Japan intenzivno provode projekte na programu korištenja vjetroenergije.

U načelu dva su paralelna pristupa provođena u nastojanjima da se omogući komercijalizacija korištenja energije vjetra i formiranje tržišta: financiranje razvoja vjetrotehnologije s jedne strane, što je pomoglo proizvođačima da proizvedu bolje i efikasnije vjetroturbine, te poticajne ekonomsko-tržišne mjere s druge strane, da bi se privukao interes potencijalnih investitora.

1.3.2 Instalirani proizvodni kapaciteti vjetroelektrana

U zadnjih deset godina, ukupni instalirani kapacitet vjetroelektrana u EU porastao je s 40.8 GW iz 2005. godine na 141.6 GW do kraja 2015., sa kumulativnom godišnjom stopom rasta od 9% u zadnjih 15 godina.

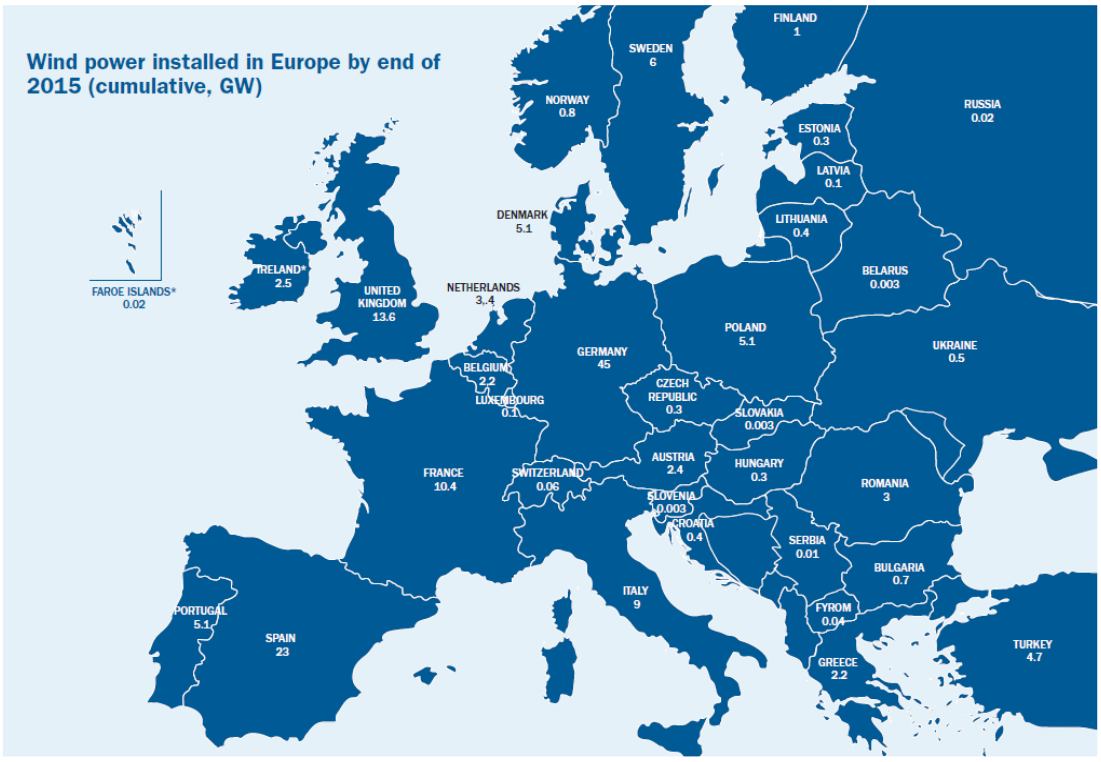


Slika 1.5 Kumulativni instalirani kapacitet proizvodnje električne energije iz energije vjetra u Europi u MW (izvor EWEA)

Osim udjela instaliranih kapaciteta vjetroelektrana, jasniju sliku daje podatak o udjelu u ukupnoj proizvodnji električne energije Ukupna potrošnja električne energije u EU, prema podacima Eurostata u 2015. iznosi 2770 TWh. Ukupna proizvodnja električne energije iz vjetroelektrana u 2015. prema podacima EWEA i Eurostata iznosila je 315 TWh od čega 40.6 TWh iz offshore vjetroelektrana i 274.5 TWh iz onshore vjetroelektrana. Udio električne energije dobiven iz vjetroelektrana na taj način je u 2015. dosegao 11.4%.

U pojedinim zemljama ti su udjeli još i veći, naročito u zemljama i pokrajinama koje snažno podupiru razvoj projekata vjetroelektrana kao što su Danska, njemačka pokrajina Schleswig-Holstein te španjolska pokrajina Navarra.

Na sljedećoj slici prikazani su ukupni instalirani kapaciteti proizvodnje električne energije u vjetroelektranama.



Slika 1.6 Ukupni instalirani kapaciteti proizvodnje vjetroelektrana u 2015. izraženi u MW (izvor EWEA)

1.3.3 Buduće smjernice za vjetroelektrane u Europi

Naznake budućeg razvoja mogu se očitati iz programa “Wind Force 12”, kojeg su izradili EWEA (eng. European Wind Energy Association) i Greenpeace, u kojem stoji da bi se 12% ukupne energije do 2020. godine trebalo proizvoditi iz energije vjetra. Na posljednjih nekoliko susreta skupine G8 zaključeno je da bi se do 2025. 25% energije trebalo proizvoditi obnovljivim izvorima energije, pri čemu energija vjetra ima najveći potencijal daljnjeg rasta i ulaganja. Energija vjetra mogla bi zadovoljiti buduće potrebe za energijom te se troškovi proizvodnje električne energije u vjetroelektranama i dalje smanjuju. Za razliku od nafte, ne postoji organizacija kao što je OPEC koja bi mogla regulirati cijene električne energije proizvedene iz energije vjetra. Također, za razliku od cijena plina, koje su vrlo promjenjive u nekoliko mjeseci, cijene električne energije proizvedene u vjetroelektranama padaju. Ovo je osobito važno s obzirom na posljednja događanja vezana uz isporuku plina iz Rusije i Ukrajine.

Energetika je tradicionalno u svim europskim državama tretirana kao djelatnost od posebnog nacionalnog interesa. Ulaskom u EU zemlje clanice su zadržale dotadašnji način planiranja energetskog razvoja. Energetska politika EU-a je tako postala suma energetskih politika zemalja članica. Suma energetskih politika nikako nije bila i optimalna politika ako se EU promatra kao cjelina.

Godina 2007. može se smatrati prekretnicom. Europski parlament je 14. veljače prihvatio rezoluciju o klimatskim promjenama, a u ožujku se Europski savjet složio s tim da se postave precizni, pravno obvezujuci kljucni ciljevi:

- Do 2020. godine smanjenje emisije staklenickih plinova za barem 20 posto - s povecanjem na 30 posto ako se usvoji medunarodni sporazum ostalih razvijenih zemalja (u smislu znatnog smanjenja emisije staklenickih plinova) te ekonomski naprednijih zemalja u razvoju ciji doprinos bi trebao biti razmjeran njihovim odgovornostima i mogucnostima;
- Obvezujuci udio od 20 posto OI u ukupnoj potrošnji energije u EU u 2020. godini;
- U 2020. godini obvezujuci minimalni udio od 10 posto biogoriva u ukupnoj potrošnji goriva u svim zemljama clanicama na podlozi cost-effectiveness analize uz uvjet da proizvodnja biogoriva bude uskladena s kriterijima održivosti, da biogoriva druge generacije budu komercijalno raspoloživa te da se donesu odgovarajuci propisi o miješanju biogoriva s klasicnim gorivima fosilnog podrijetla.

Na ove obvezujuce ciljeve Europski savjet je dodatno naglasio potrebu povecanja energetske ucinkovitosti u EU tako da se postigne ušteda od 20 posto u usporedbi s prethodnom procjenom potrošnje u 2020. godini napravljenoj u Zelenoj knjizi o energetskoj ucinkovitosti. Svi ovi planovi sumarno se nazivaju strategijom ili planom 20-20-20.

U ovom planu iznimno puno očekuje se od energije biomase i energije sunca. Međutim, energija vjetra bi najviše trebala pridonijeti realizaciji postavljenih ciljeva. Vjetroelektrane se, uz znacajne poticaje, ubrzano grade u mnogim zemljama, iako još uvijek dominiraju Njemacka, Španjolska i Danska, a radi se o tehnologiji koja je provjerena i brzo tehnološki napreduje. Jedinične snage su znatno povecane u posljednjih 10-15 godina, od nekoliko stotina kilovata do nekoliko megavata po jedinici, pa to znatno smanjuje specificne troškove. Osnovni nedostatak vjetroenergije je u potencijalu vjetra koji nije jednoliko rasporeden i daje veliku prednost europskoj atlantskoj obali (od Portugala i Španjolske, preko Irske i Velike Britanije do nordijskih zemalja) u odnosu na unutrašnjost Europe [L 3].

Prema istim planovima, neke zemlje bi trebale izgraditi ogromne dodatne kapacitete: Velika Britanija 61,5 GW, Njemacka 42,7 GW, Poljska 31,7 GW, Nizozemska 20 GW, Belgija 16,3 GW, Španjolska 16 GW, Italija 11,6 GW, Francuska 9,7 GW, itd. Sretna je okolnost da se (s izuzetkom Njemacke i Poljske) radi o zemljama koje barem na nekim svojim dijelovima imaju kvalitetan potencijal vjetra. Ukupno potrebna dodatna snaga vjetroelektrana od 244 GW u 2020. u odnosu na 2005. čini se ipak ogromnim pothvatom koji će biti vrlo teško realizirati s obzirom na niz izazova koje treba riješiti u vrlo kratkom vremenu [L 4].

Tablica 1-2 Postojeće vjetroelektrane i planirana snaga vjetroelektrana do 2020.

	Planirana snaga vjetroelektrana 2020. (GW)	Postojece vjetroelektrane (GW)	Nove vjetroelektrane do 2020. GW
Belgija	16,51	0,01	16,33
Bugarska	1,68	0,03	1,64
Ceška	6,99	0,04	6,87
Danska	4,70	3,13	1,56
Njemacka	63,73	20,62	42,67
Estonija	0,00	0,03	0,00
Irska	5,38	0,49	4,84
Grcka	5,32	0,49	4,78
Španjolska	26,13	9,92	16,05
Francuska	10,52	0,72	9,70
Italija	13,30	1,64	11,55
Cipar	0,00	0,00	0,00
Latvija	0,00	0,03	0,00
Litva	0,00	0,00	0,00
Luksemburg	2,70	0,04	2,63
Madarska	6,56	0,02	6,48
Malta	0,24	0,00	0,24
Nizozemska	21,45	1,22	20,02
Austrija	0,00	0,83	0,00
Poljska	32,17	0,12	31,72
Portugal	0,00	1,06	0,00
Rumunjska	2,89	0,00	2,86
Slovenija	0,00	0,00	0,00
Slovacka	2,56	0,01	2,52
Finska	0,00	0,08	0,00
Švedska	0,00	0,49	0,00
V, Britanija	63,74	1,57	61,53
Ukupno	286,6	42,6	244,0

1.4. POGON VJETROELEKTRANA

1.4.1 Pretvorba energije vjetra

Pravilo o neophodnom postojanju ili dostupnosti izvora energije vrijedi za vjetroagregate kao i za bilo koji drugi energetski objekt. Za pogon vjetroagregata koristi se energija vjetra koje treba biti dovoljno na lokaciji na kojoj se planira instalacija vjetroturbine. Energiju vjetra je teško valorizirati zbog stohastičkog karaktera vjetra. Za izražavanje količine energije vjetra koristi se izraz vjetropotencijal čiji se iznos može pojednostavljeno izraziti pomoću statističkih veličina od kojih je najznačajnija srednja brzina vjetra i ruža vjetrova na promatranoj lokaciji ili u njenoj blizini. Smjer vjetra je bitan zbog ustanovljavanja dominantnog vjetra odnosno količine energije vjetra iz pojedinog smjera što je bitno za postavljanje vjetroagregata u skupinama. Zbog mogućeg međusobnog ometanja prilikom rada (rad u tragu – eng. wake effect), vjetroagregate unutar vjetroelektrane potrebno je postaviti na način da se čim manje međusobno ometaju prilikom rada.

Vjetroelektrana treba biti izložena vjetru odnosno smještena na uzvisinama koje su po svom karakteru udaljene od područja ljudskog boravka i djelovanja. Izdvojene potencijalne lokacije za vjetroelektrane udaljene su od većih naselja, nacionalnih i ostalih parkova, znamenitosti, zračnih luka, turističkih središta.

Pretvorba kinetičke energije vjetra u kinetičku energiju zamašnih masa osovine odvija se pomoću lopatica rotora. Pri tome se rotor i električni generator nalaze na zajedničkoj osovini (između njih može i ne mora postojati odgovarajući prijenosnik). U generatoru dolazi do pretvorbe kinetičke energije vrtnje osovine u električnu energiju.

Jedan ili više vjetroagregata s pripadajućom opremom (generator, prijenosnik, kućište, stup, temelji, regulacija, trafostanica,...) čini vjetroelektranu. Specifična snaga vjetra proporcionalna je trećoj potenciji njegove brzine, a za konstantnu brzinu i površinu okomitu na smjer strujanja iznosi:

$$P_{vj} = \frac{\rho v^3}{2} \qquad \textbf{(1.1)}$$

pri čemu su:

P_{vj} - ukupna specifična snaga vjetra, [W/m^2]

ρ - gustoća zraka, [kg/m^3]

Gustoća zraka definirana je tlakom i temperaturom zraka:

$$\rho = \rho_0 \frac{288 \cdot p_B}{760 \cdot T} \qquad \textbf{(1.2)}$$

ρ_0 - gustoća zraka pri standardnim uvjetima: 288 [K] i 760 [mmHg], što iznosi (1.225 kg/m^3).

p_B - barometarski tlak [mmHg],

T - temperatura zraka [K],

v - brzina vjetra [m/s].

Treba naglasiti kako se prosječna godišnja snaga ne može računati s prosječnom godišnjom brzinom vjetra, jer će rezultat značajno podcijeniti stvarnu prosječnu snagu vjetra. U općem slučaju brzina vjetra nije konstantna pa je prosječna specifična snaga jednaka:

$$P_{vj} = \frac{1}{2T}\int_0^T \rho v^3(t)dt \qquad \textbf{(1.3)}$$

Poznato je kako se najveće vrijednosti brzine vjetra postižu na vrhovima brda, izloženim obalama mora, te na otvorenom moru. Pri tome su za projektiranje bilo kakvog postrojenja za iskorištavanje energije vjetra, osim srednje vrijednosti brzine vjetra, važni i brojni drugi čimbenici koji opisuju vanjske uvjete kao što su parametri Weibullove razdiobe, razdioba učestalosti smjerova (ruža vjetrova), perzistencija vjetra, okomiti gradijent brzine vjetra, gustoća zraka, značajke površine okolnog tla i dr.

Svi ti podaci strogo ovise o točno određenom mjestu pa se mogu odrediti jedino mjerenjem na tom mjestu tijekom duljeg razdoblja, dok opći meteorološki podaci mogu poslužiti tek kao smjernice.

Tlak i temperatura zraka funkcija su nadmorske visine pa se na razini mora (ρ=1.2 kg/m^3) za specifičnu snagu vjetra može približno uzeti:

$$P_{vj(0)} = 0{,}6v^3 \qquad \textbf{(1.4)}$$

Kinetička energija vjetra u struji zraka u vremenu *t* dobiva se množenjem snage s vremenom:

$$E_{k,vj} = \int_0^t P_{vj}(t)dt \qquad \textbf{(1.5)}$$

odnosno, za vremenski interval T_T u kojem se brzina vjetra uzima konstantnom:

$$E_{k,vj} = \frac{1}{2}\rho v^3 T_T \qquad \textbf{(1.6)}$$

pri čemu su:

$E_{k,vj}$ - kinetička energija vjetra po površini, [J/m^2],

t - vrijeme [s],

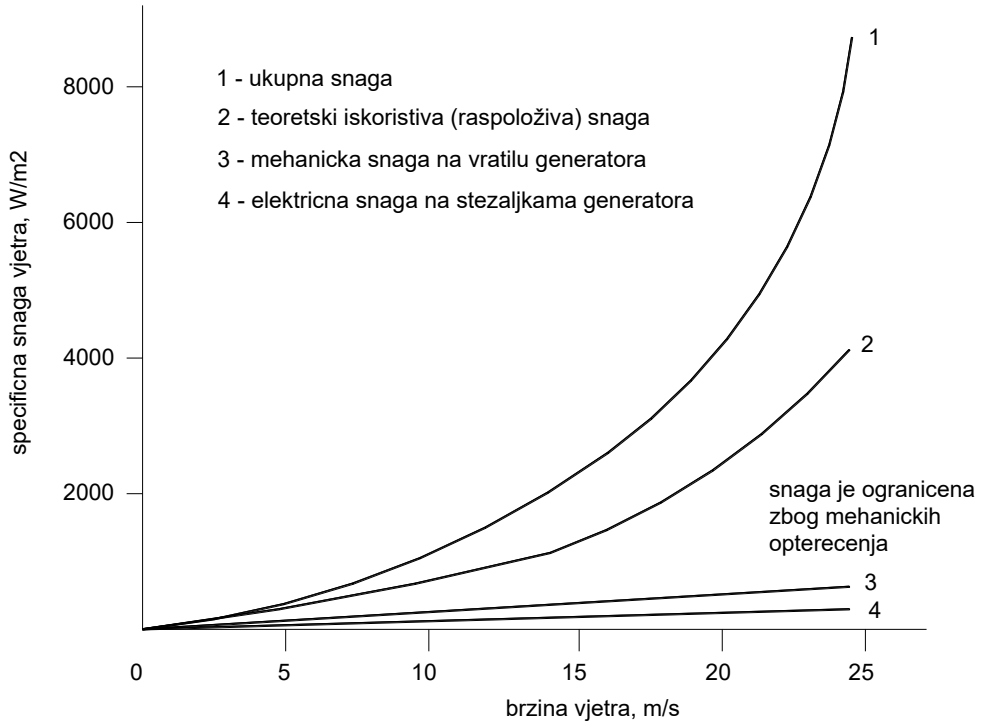
T_T - vremenski interval [s].

Za niz od *n* sukcesivnih intervala (minutnih, 10-minutnih, satnih i sl.) ukupna energija iznosi:

$$E_{k,vj} = \frac{\rho}{2} \sum_{i=1}^{n} v_i^3 T_i \qquad \textbf{(1.7)}$$

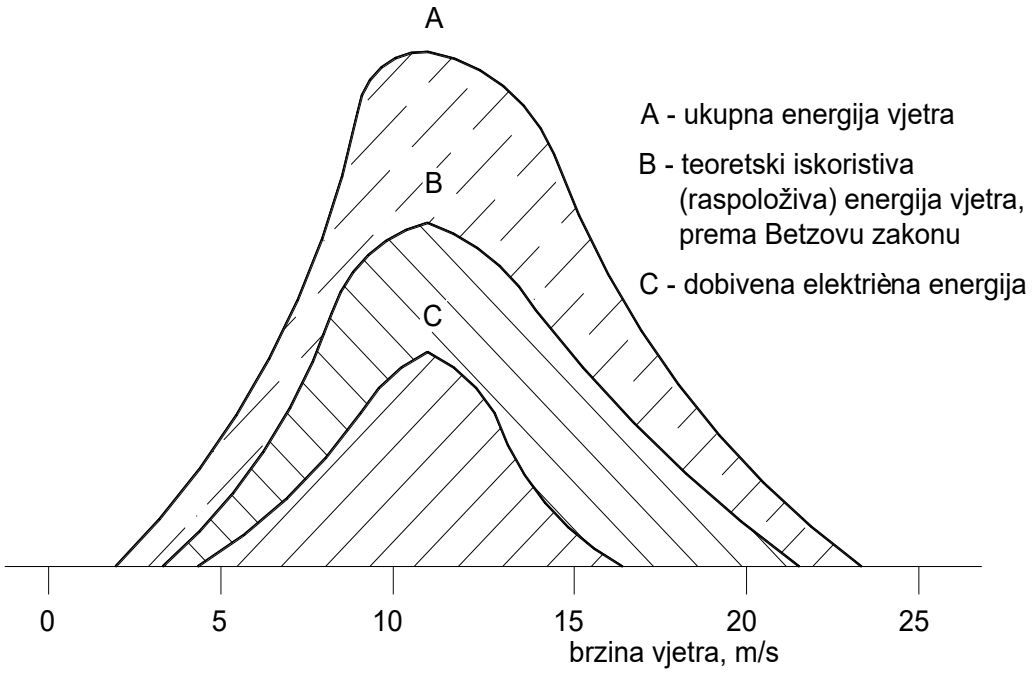
Važno je napomenuti kako pri prostrujavanju zraka kroz lopatice vjetroturbine ne dolazi do promjene njegove temperature, već samo do promjene brzine. To je također slučaj kod vodenih turbina, ali ne i kod plinskih ili parnih turbina.

Odnos ukupne i iskoristive snage vjetroelektrane može se prikazati sljedećim dijagramom.



Slika 1.7 Specifična i raspoloživa (teoretski iskoristiva) snaga vjetra, mehanička snaga na vratilu i električna snaga na stezaljkama generatora

Raspodjela energije vjetra pri pretvorbama na vjetroturbini može se prikazati Weibullovom raspodjelom, odnosno matematičkom krivuljom vjerojatnosti (Slika 1.8).



Slika 1.8 Ukupna i teoretski iskoristiva energija vjetra u Weibullovoj raspodjeli brzine (kvalitativno)

Za procjenu moguće snage vjetra, a time i snage koja se može dobiti pretvorbama u vjetroelektrani, nisu dovoljni samo točni podaci o brzini vjetra, već oni moraju biti reprezentativni, na što utječu visina na kojoj se mjeri, vremenska razlučivost (rezolucija), razdoblje i metode mjerenja te mogućnost primjene rezultata na šire područje.

1.4.2 Izlazna snaga vjetroelektrane

Raspoloživost vjetroagregata određena je udjelom vremena u kojem se može dobivati električna energija u ukupnom vijeku trajanja postrojanja. Raspoloživost suvremenih vjetroturbina kreću se najčešće između 95 i 99%, što znači da je turbina samo 1 do 5% svog vijeka trajanja van pogona (npr. zbog redovitog održavanja, kvara ili havarije), što u usporedbi s drugim postrojenjima za proizvodnju električne energije vrlo mala vrijednost.

Faktor opterećenja (eng. FLH – Full Load Hour) također je važan pokazatelj djelovanja vjetroturbine, a određen je omjerom dobivene električne energije u određenom razdoblju (npr. tjedan, mjesec, godina) i nazivne snage. Faktor opterećenja iznosi:

$$\eta_{god} = \frac{E_{el,god}}{P_n \cdot 8760} \qquad \textbf{(1.8)}$$

pri čemu su:

η_{god} - godišnji faktor opterećenja (FLH)

$E_{el,god}$ - električna energija dobivena u jednoj godini, $[kWh]$

P_n - nazivna snaga, $[kW]$

Godišnji faktori opterećenja iznose do 30% za onshore i do 40% za offshore VE.

Procjena moguće godišnje proizvodnje korisne energije osnovni je korak pri projektiranju bilo kojeg postrojanja za pretvorbu energije. Za vjetroagregat se to provodi interpolacijom podataka o dugoročnoj raspodjeli brzine vjetra i krivulje snage čime se dobiva energija koja se može dobiti pri određenoj brzini vjetra i time ukupna godišnja proizvedena energija.

Postupak za određivanje moguće godišnje proizvodnje električne energije iz vjetroagregata moguće je podjeliti u nekoliko koraka:

1. određivanje satne raspodjele brzine vjetra u godini u odgovarajućem području brzina (npr. od 1 do 2 m/s) množenjem raspodjela događanja brzine vjetra (*p(v)*) s brojem sati godišnje (8760);
2. određivanjem radne karakteristike, odnosno snage vjetroagregata pri brzinama koje odgovaraju srednjim vrijednostima u odgovarajućem području brzina;
3. određivanje dobivene električne energije množenjem vrijednosti satne raspodjele brzine u godini u odgovarajućem području brzina i snage vjetroagregata pri srednjoj brzini vjetra u tom području;
4. određivanje ukupne godišnje energije zbrajanjem svih dobivenih vrijednosti:

$$E_{god} = \sum_{i=1}^{N} H(i) W(i) \qquad \textbf{(1.9)}$$

pri čemu su:

E_{god} - (moguća) ukupna godišnja proizvedena energija (kWh),

$H(i)$ - ukupni broj sati u određenom području brzina (h),

$W(i)$ - izlazna snaga u određenom području brzina (kW),

Pri tome valja reći kako je ukupna proizvodnja vjetroelektrane koja se sastoji od više jedinica (tzv. vjetrofarme ili vjetroparka) manja od zbroja predviđene proizvedene energije u svim jedinicama zasebno. Razlog tome ponajviše treba tražiti u činjenici kako je zbog djelovanja strujanja zraka i turbulencija učinak jedinica koje se nalaze "iza" manji od predviđenog. Ovisno o stvarnim

uvjetima, ukupna snaga niza vjetroagregata manja je od zbroja svih jedinica za 5 do 15%, čemu još valja dodati 1 do 2% gubitaka na transformatorima i internoj kabelskoj mreži između jedinica.
Ipak, najveći dio ukupne kinetičke energije vjetra ne može se iskoristiti, odnosno pretvoriti u kinetičku energiju vrtnje lopatica rotora jer vjetar mora nastaviti strujanje kako bi omogućio nadolazak vjetra iza sebe. Ta se činjenica naziva Betzovim zakonom (iz 1919. godine), a matematički se može izraziti stupnjem aerodinamičke pretvorbe koji je određen kao omjer snage na vratilu vjetroturbine i raspoložive snage u slobodnoj struji vjetra:

$$c_p = \frac{P_t}{P_{vj}} = \frac{P_t}{\frac{1}{2}\rho v^3} \qquad \textbf{(1.10)}$$

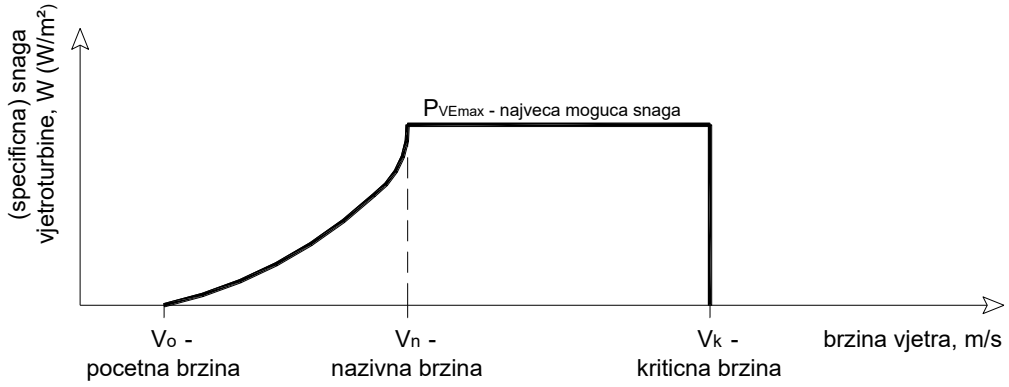
pri čemu su:

c_p - stupanj aerodinamičke pretvorbe, (0.45-0.52 za suvremene vjetroagregate)

P_t - transformirana snaga (W/m^2),

Najveća moguća vrijednost stupnja aerodinamičke pretvorbne naziva se Betzovom granicom ili Betzovim brojem i iznosi $c_{p,\max} = 16/27 = 0.593$. Pri tome je važno napomenuti kako se učinkovitost (stupanj djelovanja) nijednog postrojenja za iskorištenje energije vjetra (vjetroelektrane, vjetrenjače) nikakvim poboljšanjima ne može povećati iznad te vrijednosti, odnosno prema slici Slika 1.9:

$$P_{t,\max} = 0.593 \cdot \frac{\rho v^3}{2} \qquad \textbf{(1.11)}$$

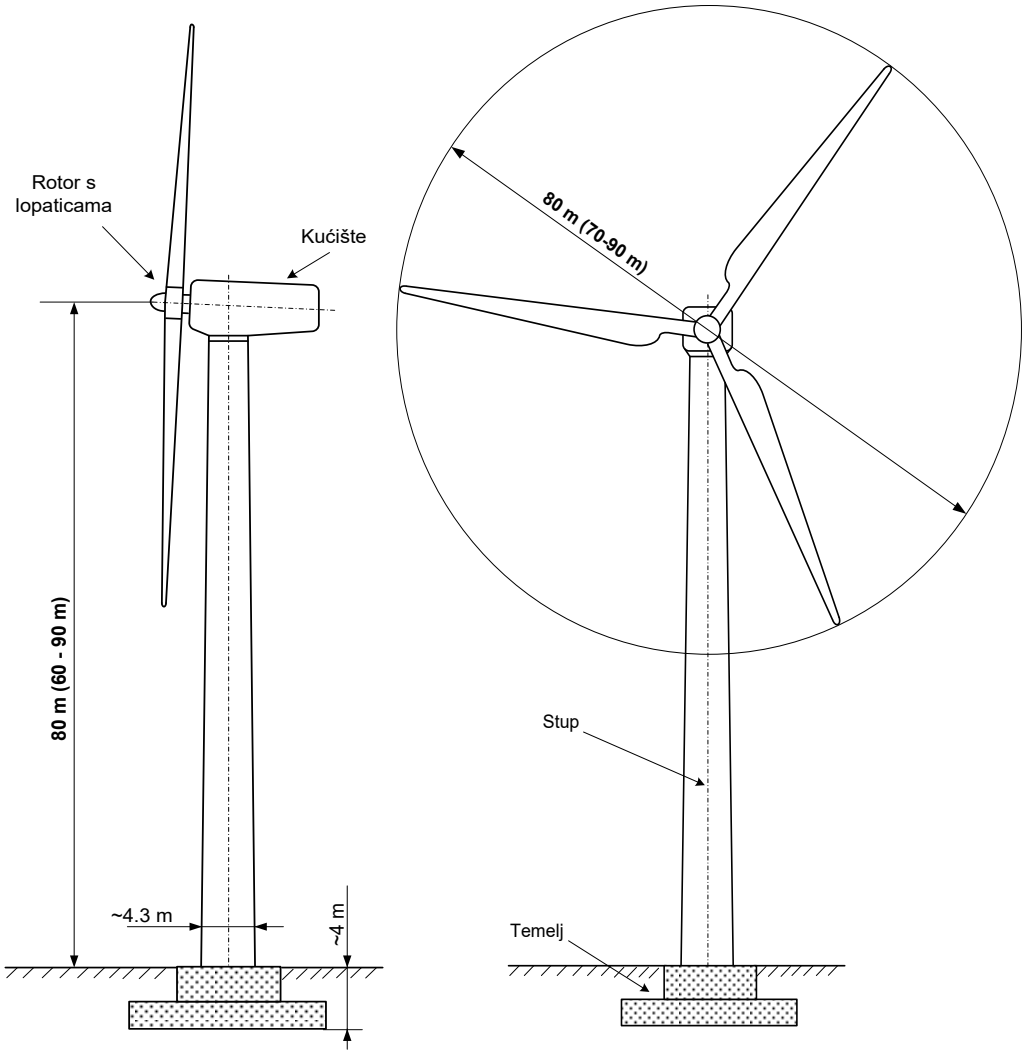


Slika 1.9 Ovisnost snage vjetroagregata o brzini vjetra (kvalitativno)

Uzimajući u obzir i ostale gubitke do kojih dolazi pri procesima pretvorbe energije u vjetroelektrani (kinetička energija vjetra u kinetičku energiju vrtnje lopatica, pa vratila generatora te konačno u električnu energiju) proizlazi kako

se tek nešto manje od 1/2 početne (ukupne) kinetičke energije vjetra pretvara u korisnu električnu.

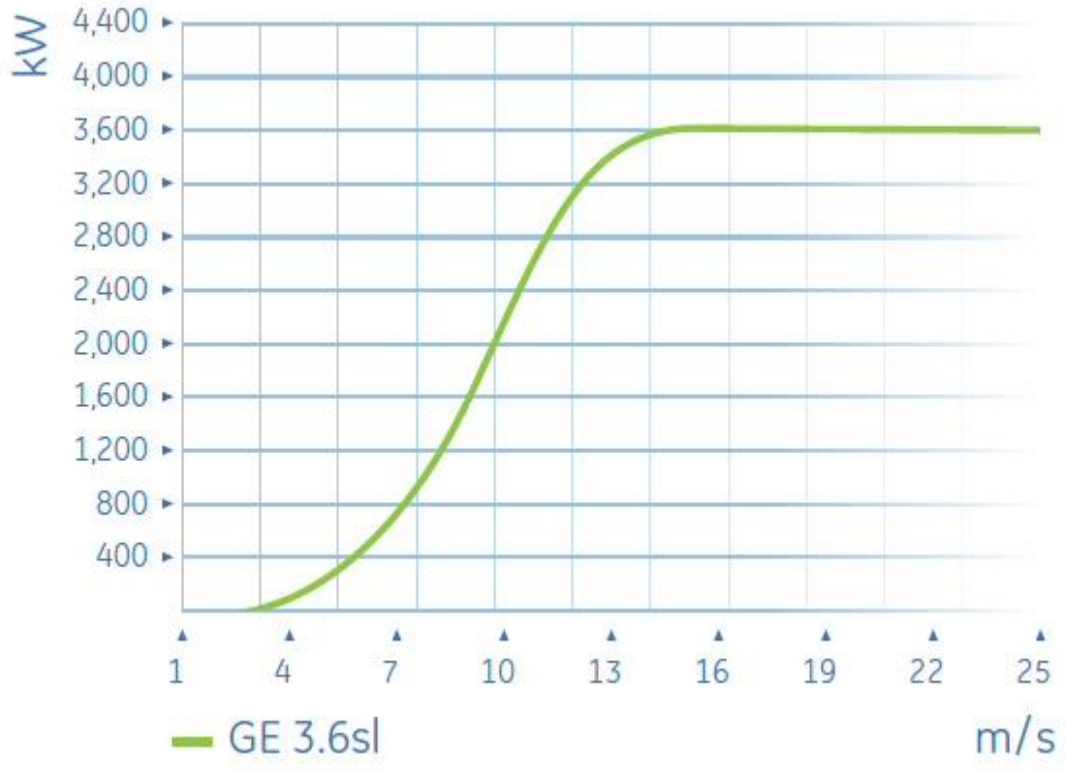
Osnovni dio svakog postrojenja za pretvorbu energije vjetra u druge korisne oblike, električnu energiju ili mehanički rad je vjetroagregat koji se sastoji od rotora, odnosno njegovih lopatica i osovine. Osovina može ili ne mora biti spojena na odgovarajući prijenosnik koji pokreće električni generator (kod vjetroelektrana) ili mehanizam kojim se obavlja koristan rad (kod vjetrenjača). Osovina, prijenosnik, generator i razni regulacijski dijelovi smješteni su u zajedničko kućište koje se postavlja na stup odgovarajuće visine. Kako bi stup izdržao sva opterećenja od udara vjetra i drugih utjecaja kojima je cijeli sustav izložen mora se dobro temeljiti.



Slika 1.10 Prikaz dimenzija vjetroagregata snage reda veličine 2 MW (kvalitativno)

Krivulja snage pokazuje ovisnost neto dobivene električne energije iz vjetroturbine, odnosno vjetroelektrane, o brzini vjetra na visini glavčine. Određuje se iz teoretskih proračuna ili na temelju ispitivanja koja se provode

u skladu s međunarodnim smjernicama (npr. Međunarodne agencije za energiju). Rezultati dobiveni ispitivanjima izražavaju se kao 10-minutne prosječne vrijednosti dobivene (izlazne) električne snage i brzine vjetra na visini glavčine. Svođenjem rezultata na prosječne vrijednosti izbjegavaju se tranzijentni učinci.



Slika 1.11 Krivulja snage vjetroagregata nazivne snage 3.6 MW (kvalitativno) – izvor GE

Učinkovitost (stupanj djelovanja) vjetroagregata određena je omjerom izlazne (dobivene) električne snage i kinetičke energije vjetra koji struji kroz površinu koju opisuju lopatice rotora:

$$\eta_{VT} = \frac{P_{el}}{P_{vj} A} \qquad \textbf{(1.12)}$$

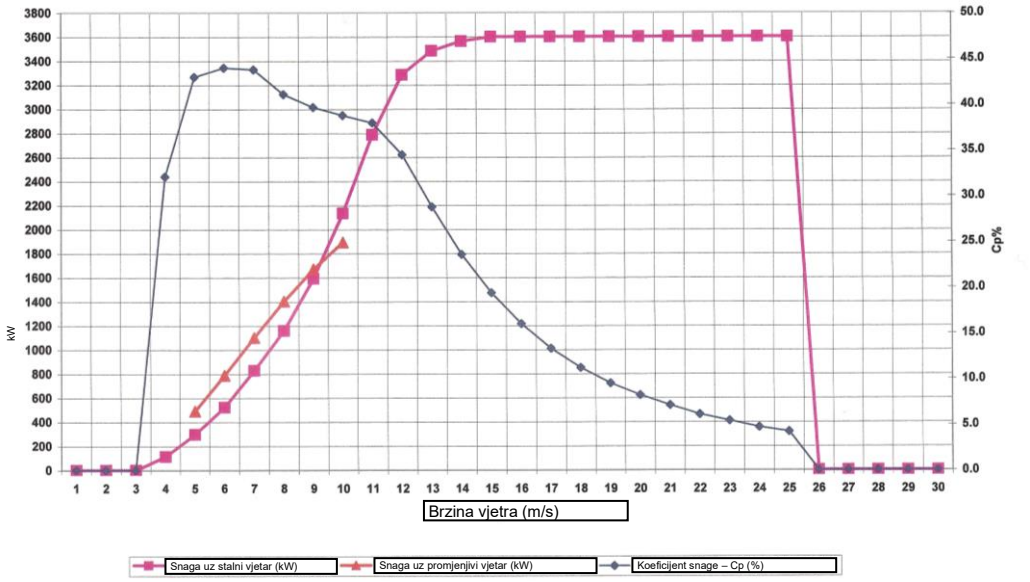
Na krivulji snage ističu se nekoliko osnovnih pogonskih veličina vjetroturbina:

- brzina pokretanja (v_p) (eng. cut-in speed): brzina vjetra kod koje vjetroelektrana počinje proizvoditi električnu energiju i koja je veća od brzine potrebne za okretanje lopatica;

- brzina zaustavljanja (eng. cut-out speed) (v_z): brzina vjetra kod koje treba prekinuti vrtnju rotora zbog smanjivanja opterećenja na turbinu;
- nazivna snaga (P_n): najveća stalno dobivena (izlazna) električna snaga na stezaljkama generatora;
- nazivna brzina (v_n): brzina vjetra kod koje se dobiva nazivna snaga.

Osim krivulje snage, postoji i krivulja potiska vjetroagregata koja prikazuje ovisnost stupnja djelovanja (eng. power coefficient), odnosno pretvorbe energije vjetra u električnu, o brzini vjetra.

Iznos veličine faktora c_p odnosno koeficijenta snage vjetroagregata, regulira se promjenom kuta između vjetra i lopatica rotora, što se obavlja zakretanjem lopatica – *pitch* sustavom.



Slika 1.12 Ovisnost koeficijenta snage vjetroagregata o brzini vjetra (kvalitativno) – izvor Siemens

Koeficijent snage vjetroagregata daje vrijednost koja opisuje koliko efikasno turbina pretvara energiju vjetra u električnu energiju.

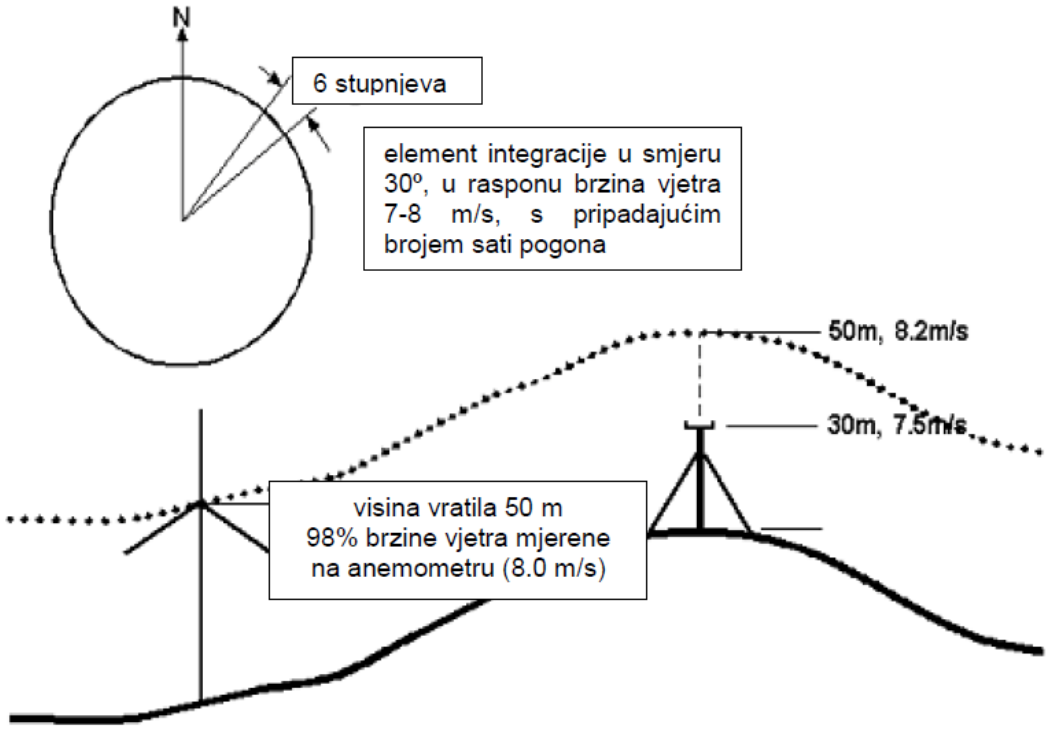
Za vjetroagregate nije bitno da što efikasnije pretvaraju energiju vjetra u električnu energiju. Ono što se traži jest što manji specifični trošak „izvlačenja“ energije iz vjetra narednih 20 godina. Budući da je „gorivo“ za ovakve pogone besplatno i obnovljivo, nema potrebe za očuvanjem i štednjom pogonskog goriva odnosno efikasnošću pretvorbe, kao što je to slučaj kod elektrana na fosilna goriva.

1.4.3 Proračun snage vjetra

Podaci potrebni za proračun proizvodnje vjetroelektrane su sljedeći [L 5]:

- podaci o distribuciji vjetra (ruža vjetrova koja predstavlja vjetrovne prilike u određenoj točki na lokaciji; podaci uključuju profil vjetra i informacije o turbulenciji)
- podaci o vjetroagregatu (snaga i moment sile u ovisnosti o vjetru)
- topografski podaci (prezentacija topografije koja uključuje podatke o visinama terena i hrapavosti površine same lokacije vjetroelektrane i okolice)

Prilikom procesa kalkulacije snage proizvodnje vjetroelektrane, potrebno je obaviti dvostruku integraciju u svim smjerovima te pri svim brzinama vjetra pri kojima je vjetroelektrana u pogonu. Ti podaci definirani su mjerenjima obavljenim na mjernom stupu [L 7] koji se nalazi na samoj lokaciji gradnje vjetroelektrane.



Slika 1.13 Slikoviti prikaz primjera proračuna proizvodnje vjetroagregata na temelju obavljenih mjerenja na bliskoj lokaciji

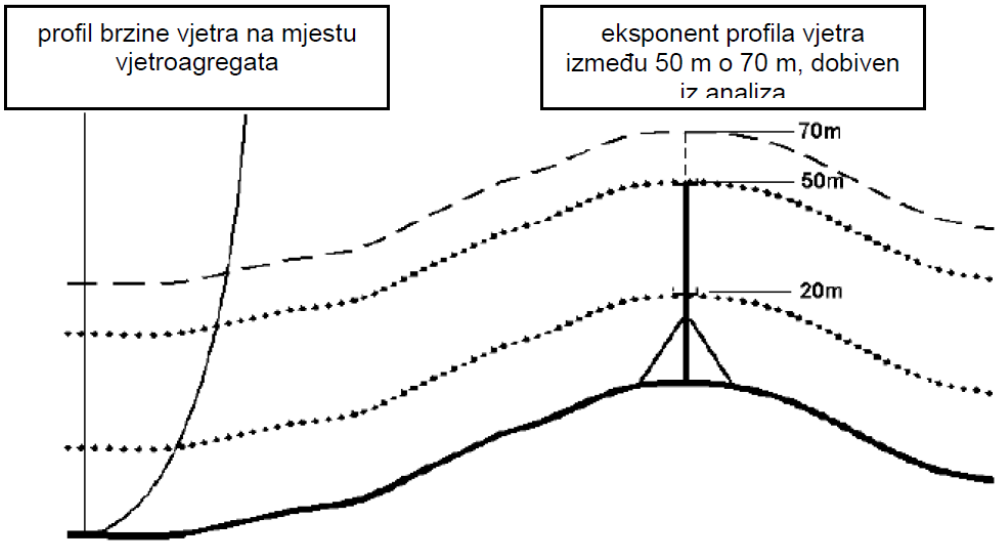
Proces integracije mora uzeti dovoljno mali korak integracije odnosno mali korak izražen u stupnjevima punog kruga tako da su efekti rada u sjeni uzeti u obzir. Prilikom proračuna u ovom radu uzet je korak od 6˚ odnosno 60 koraka integracije u punom krugu.

Procedura proračuna je sljedeća:

- proračun broja sati rada na određenoj brzini vjetra
- proračun brzine vjetra s obzirom na topologiju i podatke o orografiji terena
- proračun deficita uslijed rada u sjeni te utjecaja turbulencije
- proračun snage proizvodnje s obzirom na rezultantnu brzinu vjetra na visini vratila vjetroagregata

Brzinu vjetra s lokacije mjernog stupa potrebno je preračunati na lokacije pojedinih vjetroagregata i to na visinu vratila samog vjetroagregata da bi se dobila snaga proizvodnje na visini vratila vjetroagregata.

Jedan od problema prilikom proračuna snage i energije vjetroelektrana jest taj što su parametri vjetra obično izmjereni na takvim visinama da ti podaci moraju biti ekstrapolirani na visine vratila vjetroagregata. Na sljedećoj slici prikazan je primjer mjerenja parametara vjetra na visinama 20 m i 50 m na mjernom stupu te vjetroagregata visine 70 m.



Slika 1.14 Slikoviti prikaz proračuna profila vjetra na mjestu vjetroagregata na temelju mjerenja na mjernom stupu

Obavljenim mjerenjima obavlja se analiza profila vjetra. Pretpostavljena je eksponencijalna funkcija profila vjetra s visinom, odnosno prema sljedećoj formulaciji:

$$\frac{v_{h2}}{v_{h1}} = \left(\frac{h_2}{h_1}\right)^{\alpha} \qquad \textbf{(1.13)}$$

gdje je

v_{h1} - brzina vjetra na visini h_1
v_{h2} - brzina vjetra na visini h_2
α - eksponent proporcionalnosti brzine vjetra s visinom

Iz obavljenih mjerenja brzine vjetra može se proračunati vrijednost koeficijenta α (eng. wind shear coefficient) koja najbolje odgovara izmjerenim vrijednostima brzina vjetra na odabranim visinama. Na taj način se brzina vjetra u kasnijim analizama ekstrapolira na visine od 70 m, 80 m ili čak 100 m na kojima se nalaze vratila vjetroagregata. Naravno, što su parametri vjetra mjereni na većim visinama to su podaci koji se ekstrapoliraju točniji, a rezultati vjerodostojniji. Osim ovakve procjene temeljem ovog proračuna, potrebno je također uzeti u obzir utjecaj orografije terena te hrapavosti površine.
Ukoliko je vjetroelektrana smještena na otvorenom terenu s jednolikom hrapavosti površine, karakteristike vjetra bit će jednake na cijelom području na kojem je vjetroelektrana smještena. Međutim, tipična lokacija vjetroelektrane nalazi se na brdovitom terenu pa na brzinu vjetra, a samim tim i sangu i energiju vjetroelektrane, utječu varijacije u visini terena te promjene hrapavosti površine. Stoga je, za proračun snage i energije vjetroelektrane, neophodno proračunati varijacije brzine vjetra na cijeloj lokaciji. Ove varijacije ovise o smjeru vjetra te o visini iznad tla.

Koja god metoda da se upotrijebi za proračun topografskih varijacija brzina vjetra, ista mora kao ulazne parametre koristiti poznate mjerne podatke s referentne točke koju predstavlja ili meteorološka stanica ili stup za mjerenje vjetra koji je vlasništvo tvrtke koja želi graditi vjetroelektranu. Što je mjerni stup dalje od same vjetroelektrane, veća je mogućnost pogreške u proračunima snage i energije vjetroelektrane. Ove pogreške nisu samo uzrokovane udaljenošću nego i vjetrovnim prilikama koje se mogu razlikovati na lokaciji vjetroelektrane i na lokaciji mjernog stupa. U tipičnim slučajevima, meteorološke stanice smještene su na niskim nadmorskim visinama s manjim prosječnim brzinama vjetra dok je lokacija vjetroelektrane smještena na brdima odnosno na većim nadmorskim visinama gdje su i veće prosječne brzine vjetra. Stoga je očito da se mjerenjima parametara vjetra na samoj lokaciji ove pogreške mogu bitno reducirati. Kad se brzina i smjer vjetra na lokaciji mjernog stupa kombiniraju s podacima o profilu vjetra može se proračunati brzina vjetra na svim visinama iznad tla za određeni smjer vjetra. Na taj način proračunavaju se parametri vjetra na svim visinama unutar lokacije vjetroelektrane. Dva su dodatna efekta vjetra koja se dodatno pri tom moraju razmotriti. To su efekt visine odnosno orografije terena te efekt hrapavosti površine. Nije potrebno ukalkulirati efekt orografije ukoliko je teren ravan, a jednako tako nije potrebno ukalkulirati efekt hrapavosti površine ukoliko je teren jednolik. Najčešće korišteni modeli strujanja vjetra temelje se na modelu razvijenom od strane Jacksona i Hunta te nešto manje model MS-Micro za proračun efekta orografije te Sempreviva za proračun efekta hrapavosti površine. Oba ova modela temelje se na pojednostavljenjima stvarnih fizikalnih strujanja vjetra. Pri tom se oba efekta proračunavaju

zasebno te zbrajaju kako bi se dobio konačan ukupni efekt na brzinu vjetra, a samim tim i snagu i energiju vjetroelektrane.
Većina podataka vjetroagregata, koji se tiču snage i sile potiska, specificirano je pri standardnim atmosferskim uvjetima (15˚C, na površini mora). Obično je potrebna korekcija podataka o gustoći zraka za pravilan proračun snage i energije koju daje vjetroagregat. Povećanjem nadmorske visine zrak postaje rjeđi te samim tim i snaga i energija opadaju. Također, smanjenjem temperature zraka, povećava se njegova gustoća pa se snaga i energija vjetroagregata povećavaju. Stoga je u proračun snage i energije vjetroelektrane potrebno unijeti veličine koje su relevantne za promjenu gustoće zraka, odnosno temperaturu, tlak zraka te nadmorsku visinu vjetroagregata. Utjecaj vlažnosti zraka je zanemaren.
Formulacije koje opisuju promjene gustoće s promjenama prethodno opisanih veličina su sljedeće:

$$\rho_{sl} = \rho_0 \cdot \frac{T_0}{T_{sl}} \cdot \frac{p_{sl}}{p_0} \qquad \textbf{(1.14)}$$

gdje je
ρ_{sl} – gustoća zraka pri promjenjenoj vrijednosti ovisnih parametara
ρ_0 – gustoća zraka pri standardnim atmosferskim prilikama
T_0 – temperatura zraka pri standardnim atmosferskim prilikama
T_{sl} – temperatura zraka vrijednosti ovisnih parametara
p_0 – tlak zraka pri standardnim atmosferskim prilikama
p_{sl} – tlak zraka vrijednosti ovisnih parametara

Promjena tlaka s nadmorskom visinom data je sljedećom formulacijom:

$$\frac{p}{p_{sl}} = \left(\frac{T}{T_{sl}}\right)^{-5.25588} \qquad \textbf{(1.15)}$$

Iz prethodnih jednadžbi dobije se

$$\frac{\rho}{\rho_{sl}} = \left(\frac{T_{sl}}{T}\right) \cdot \left(\frac{p}{p_{sl}}\right) = \left(\frac{T_{sl}}{T}\right)^{-4.25588} = \left(\frac{T}{T_{sl}}\right)^{4.25588} \qquad \textbf{(1.16)}$$

odnosno

$$\frac{\rho}{\rho_0} = \left(\frac{T_0}{T_{sl}}\right) \cdot \left(\frac{T}{T_{sl}}\right)^{4.25588} = \left(\frac{T_0}{T}\right) \cdot \left(\frac{T}{T_{sl}}\right)^{5.25588} \qquad \textbf{(1.17)}$$

Formule standardnih atmosferskih uvjeta, za nižu atmosferu (0-11 km) daju varijaciju temperature s visinom koja glasi:

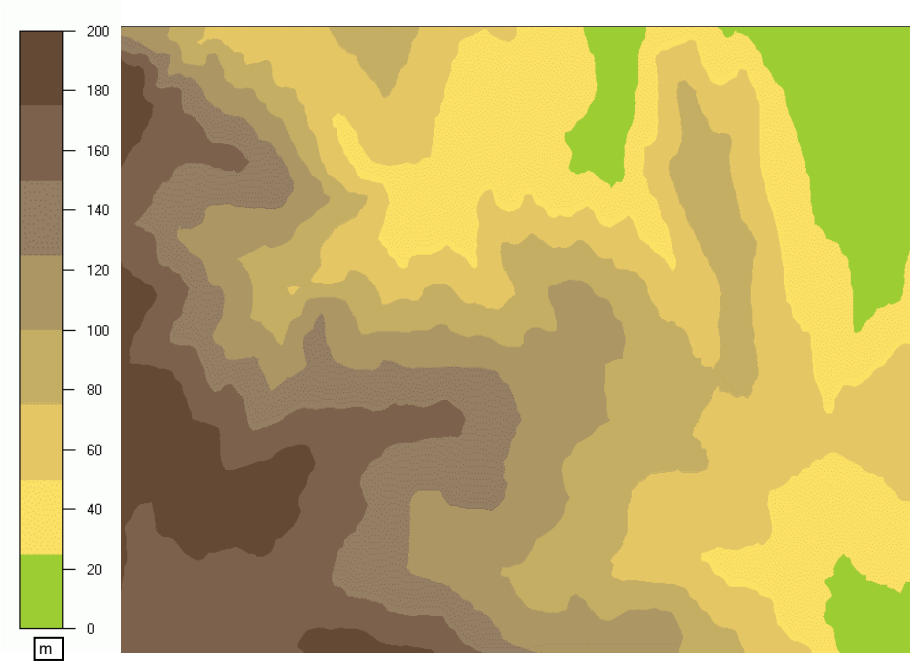
$$T = T_{sl} - 0.0065 \cdot h \qquad \textbf{(1.18)}$$

1.4.4 Topografski efekt na brzinu vjetra

Ako se vjetroelektrana nalazi na otvorenoj lokaciji s jednolikom hrapavosti terena, karakteristike vjetra su jednake na cijeloj lokaciji vjetroelektrane. Međutim, na stvarnim lokacijama, na brzinu vjetra utječe razlika u hrapavosti površine te varijacije u visini terena odnosno orografija terena. Da bi se izračunala snaga proizvodnje pojedinog vjetroagregata, a samim tim i ukupna proizvedena energija, moraju se izračunati varijacije brzine vjetra na cijeloj lokaciji. Bilo koja metoda da se upotrijebi za računanje brzina vjetra na pozicijama vjetroagregata, kao referentna brzina vjetra uzima se podatak dobiven s mjernog mjesta koje se može nalaziti izvan lokacije (kao postojeća meteorološka stanica) ili na samoj lokaciji (kao posebno postavljeni mjerni stup).

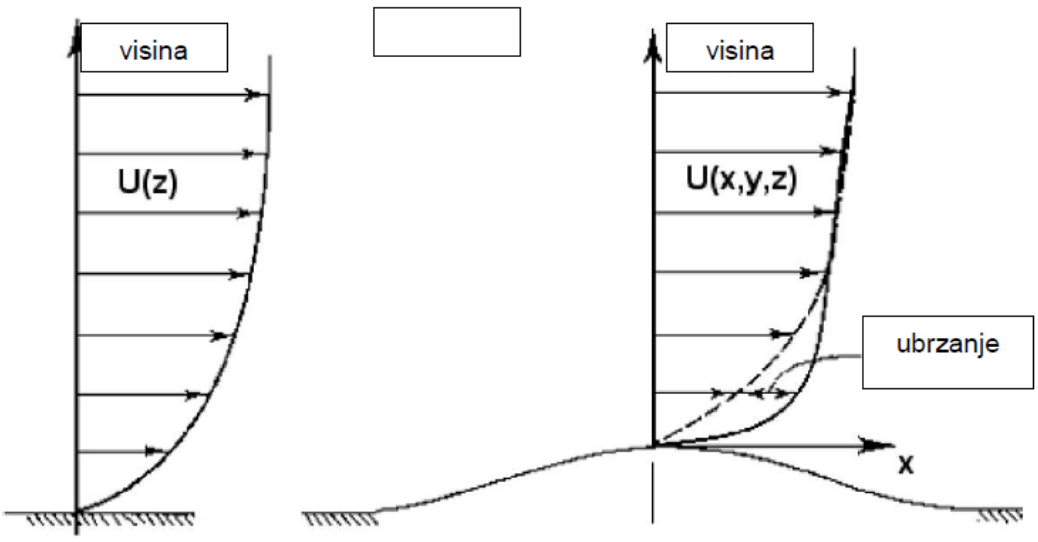
Ukoliko je lokacija koja služi za referentno mjerenje udaljena od lokacije vjetroelektrane, povećava se netočnost procjene brzine vjetra, a samim tim i snage proizvodnje vjetroelektrane. Netočnost procjene vjetra na samoj lokaciji uzrokovana je i činjenicom da su mjerne stanice obično postavljene u zaklonjenim dolinama dok su vjetroelektrane obično izgrađene na vrhovima brda gdje su i brzine vjetra veće. Stoga se mjerenjem atmosferskih prilike na samoj lokaciji vjetroelektrane može uvelike smanjiti netočnost procjene snage proizvodnje. Osim toga, dodatno smanjenje netočnosti procjene brzine vjetra radi se postavljanjem dodatnog mjernog mjesta na lokaciji vjetroelektrane. Tehnika se temelji na uprosječivanju proizvodnje vjetroagregata iz pojedinačnih proračuna. Varijacije brzine vjetra po lokaciji kreiraju se uz ulazne podatke o karakteristikama vjetra, visinama terena te hrapavosti površine na cijeloj lokaciji. Brzina, smjer i turbulencija vjetra variraju ako vjetar puše preko brda te postoji niz modela koji služe za simulaciju toka vjetra. Najuobičajeniji modeli temelje se na jednadžbama idealiziranih rubnih slojeva. Proračuni strujanja vjetra obavljeni su najčešće uporabom programskog koda za kompleksne terene koji mogu predstavljati pojednostavljenu inačicu metode razvijene od strane Jacksona i Hunta.

Varijacije visine i hrapavosti terena utječu na brzine vjetra na području vjetroelektrane i stoga su topografski podaci potrebni za kvalitetan proračun brzina vjetra na cijelom području lokacije, a samim tim i snage proizvodnje. Najjednostavniji primjer predstavlja ravna i jednolika površina kao što je površina mora pa su stoga u zapadnoj Europi iznimno zastupljene tzv. offshore vjetroelektrane.
Visina terena specificirana je podacima u obliku visinskih kontura (izohipsi) u određenom visinskom intervalu (najčešće 10 m). Također, mogu se specificirati u obliku skupa točkastih podataka (eng. grid data) u obliku mreže s određenim intervalom podataka.



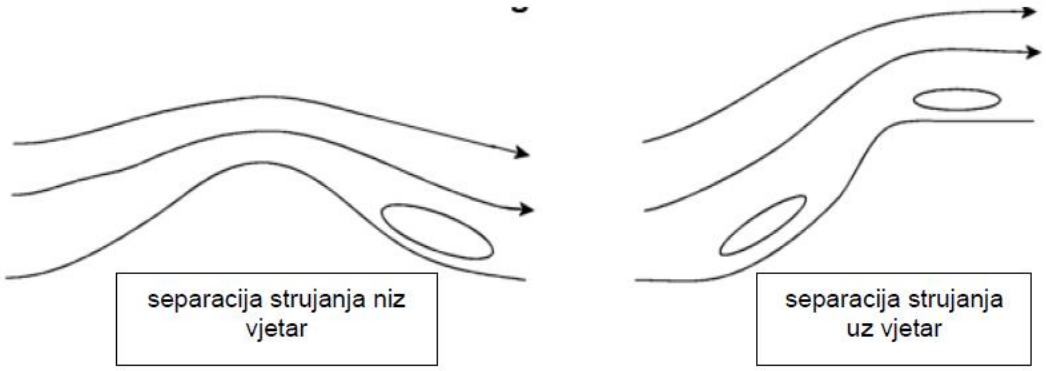
Slika 1.15 Kvalitativni rimjer podataka o orografiji terena na lokaciji vjetroelektrane

Vjetroagregati se obično smještaju na vrhovima brdovitih područja da bi se na taj način iskoristile veće brzine vjetrova koje na tim područjima vladaju. Takav smještaj vjetroagregata ipak predstavlja problem budući da je na tom području otežano predviđanje brzine vjetra. U slučaju glatkog brda doći će do porasta brzine vjetra blizu površine tla na vrhovima brda. Takav porast brzine vjetra uzrokovan oblikom brda prikazan je na sljedećoj slici:



Slika 1.16 Ilustracija porasta brzine vjetra uslijed nailaska na orografsku prepreku

Brzina, smjer i turbulencija vjetra variraju u slučajevima kad vjetar puše preko brda te su razvijeni razni modeli koji simuliraju ove pojave, najčešće temeljeni na jednadžbama idealiziranog rubnog sloja [L 9, L 10]. Pri tom treba biti vrlo oprezan na vrlo strmim (stjenovitim) terenima gdje može doći do vrlo velikih odstupanja uzrokovanih pojavom odvojenih strujanja vjetra tj. većih turbulencija. Separacije strujanja vjetra nastupaju na strminama većim od 1:4 (25%) niz smjer vjetra, te 1:2.5 (40%) uz smjer vjetra kad slobodna struja vjetra preskače ta mjesta



Slika 1.17 Separacija strujanja vjetra i stvaranje turbulencija

Prirodne prepreke i građevine mijenjaju strujanje vjetra. Utjecaj je zamjetan kroz:

- smanjenje brzine vjetra
- povećanje turbulencija
- smanjenje snage vjetra

Ponekad je vrlo teško razabrati da li određene skupine prepreka modelirati kao zasebne prepreke ili hrapavost površine.

1.4.5 Utjecaj turbulencije vjetra na snagu vjetroagregata

Turbulencija je nepravilno vrtložno gibanje koje se pojavljuje pri strujanju zraka kad vjetar struji pored čvrstih predmeta ili kad brzina strujanja prijeđe određenu granicu. Za turbulentno strujanje karakteristično je da pored srednje brzine cijelog strujanja, svaka čestica zraka ima još i dodatnu brzinu koja može biti djelomično u smjeru glavnog strujanja, djelomično okomita na smjer strujanja. Po tome se razlikuje turbulentno od laminarnog strujanja, u kojem nema dodatnih brzina [L 11].

U atmosferi je strujanje zraka (vjetra) uvijek turbulentno; vjetar puše gotovo redovito na mahove i smjer mu se neprestano mijenja. Rezultat turbulentnog gibanja zraka je međusobno djelovanje zračnih slojeva različitih brzina; brži

sloj utječe na sporiji i obrnuto. Ova se pojava često naziva i turbulentno trenje.

Turbulencija vjetra utječe na smanjenje brzine vjetra te smanjenje snage vjetra. Zbog pojednostavljenja, trenutna brzina vjetra može se promatrati kao zbroj kvazi-stacionarne komponente i turbulentne komponente, koja je u biti fluktuacija oko srednje vrijednosti. Brzina vjetra u kvazi-stacionarnom stanju dobivena je uprosječavanjem u određenom vremenskom periodu, najčešće 10-minutnom periodu (10-minutni prosjeci), dok se varijabilnost vjetra karakterizira varijancom brzina vjetra u tom istom periodu. Srednja vrijednost brzine vjetra računa se po sljedećoj formuli:

$$v_{sr} = \sum_{i=1}^{n} v_i \cdot p(v_i) \qquad \textbf{(1.19)}$$

pri čemu je
v_{sr} – srednja brzina vjetra,
v_i – centralna vrijednost (medijan) brzina vjetra i-tog intervala,
$p(v_i)$ – vjerojatnost pojave centralne vrijednosti u i-tom intervalu

Varijanca se računa kao korijen izmjerenih fluktuacija turbulencije dok je drugi korijen varijance standardna devijacija brzine vjetra te ima dimenziju m/s.

Indikacija stalnosti vjetra mjeri se parametrom koji se naziva turbulencija (T) i izračunava se kao omjer srednje standardne devijacije i srednje vrijednosti brzine vjetra, odnosno prema formuli:

$$IT = \frac{\sigma_{vj}}{v_{sr}} \qquad \textbf{(1.20)}$$

pri čemu je
IT – intenzitet turbulencije (bezdimenzionalan)
σ_{vj} – varijanca brzine vjetra (m/s)
v_{sr} – srednja brzina vjetra (m/s)

Intenzitet turbulencije uzrokuje određen deficit brzine vjetra, a samim tim i snage vjetroagregata.

1.4.6 Utjecaj hrapavosti površine na snagu vjetroagregata

Hrapavost površine obično se definira veličinom koja se naziva duljina ili visina hrapavosti (Z_0). Empirijska geometrijska relacija može se upotrijebiti za izražavanje duljine hrapavosti na temelju veličine objekata u krajobrazu

lokacije vjetroelektrane te udaljenosti između njih. Ako postoji *n* objekata visine h_2 i širine *w* (poprečna površina spram pravca vjetra iznosi $w \cdot h_2$), i ako su ravnomjerno raspoređeni po površini *A*, onda se kao procjena može uzeti u obzir sljedeća relacija:

$$Z_0 = \frac{n \cdot w \cdot h_2}{2 \cdot A} \qquad \textbf{(1.21)}$$

Na temelju ovih izračuna definiraju se sljedeće 4 klase hrapavosti površine s opisom i slikom klase:

klasa 0
predstavlja područja s vodom odnosno morem te pješčana područja s duljinom hrapavosti reda 0.0002 do 0.001



Slika 1.18 Primjer područja hrapavosti površine klase 0

klasa 1
predstavlja otvorena područja s vrlo malo prepreka u prostoru te sporadičnom pojavom stabala ili zgrada u okolici. Duljina hrapavosti površine je reda 0.02 do 0.05.



Slika 1.19 Primjer područja hrapavosti površine klase 1

klasa 2
odgovara poljoprivrednim krajobrazima s farmama, gdje su prepreke obično vrlo udaljene (oko 1000 m i više). Duljina hrapavosti površine u tom području je oko 0.07 do 0.15.



Slika 1.20 Primjer područja hrapavosti površine klase 2

klasa 3

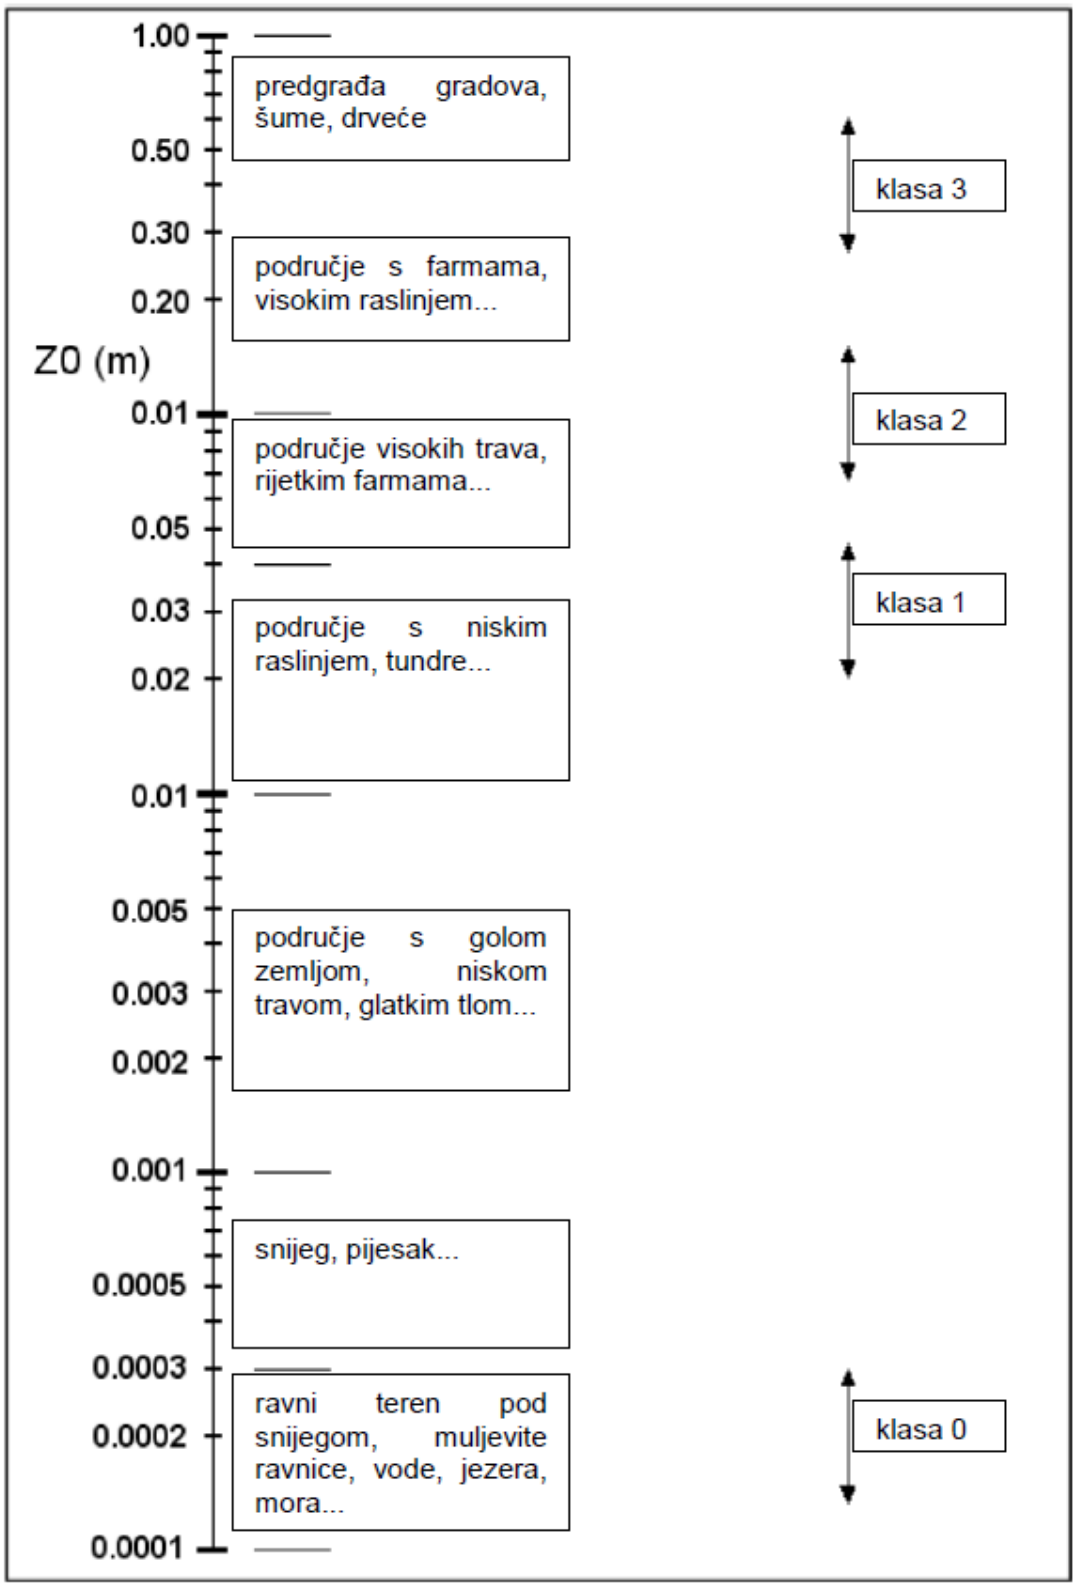
odgovara područjima zatvorenih krajobraza gdje su prepreke gušće raspoređene. Duljine hrapavosti koje odgovaraju tom području su 0.25 do 0.6.



Slika 1.21 Primjer područja hrapavosti površine klase 3

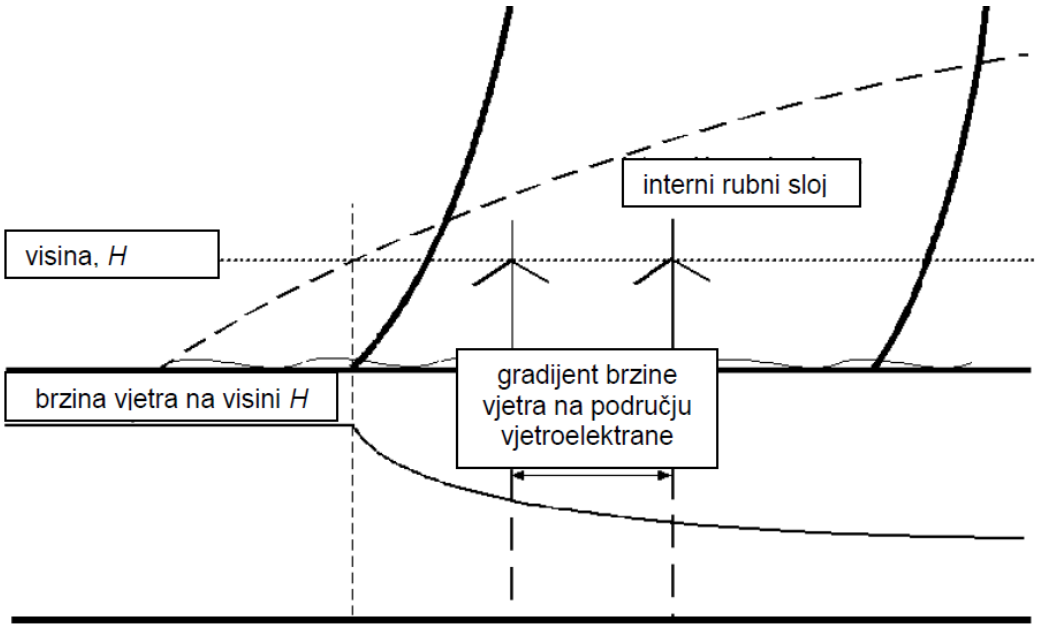
Hrapavost površine može se mjeriti, ali to je vrlo kompliciran postupak koji se još uvijek istražuje. Vrijednost duljine hrapavosti poprima vrijednosti između 0 i 1 što su ujedno krajnje ekestremne vrijednosti. Pri tom vrijednost 0 označava hrapavost površine mora, a vrijednost 1 označava duljinu hrapavosti površine u gradu s visokim neboderima.

Tipične duljine hrapavosti površine mogu se opisati sljedećim dijagramom u logaritamskoj skali:



Slika 1.22 Iznosi duljine hrapavosti za različite terene

Kad se računa efekt hrapavosti površine na brzinu vjetra, potrebno je uzeti u obzir samo promjenu hrapavosti budući da ona utječe na izmjenu oblika profila vjetra. Na sljedećoj slici prikazan je efekt promjene hrapavosti površine iz klase 0 u klasu 1 (prijelaz s morske površine na obalu). Promjena u hrapavosti očituje se u povećanju duljine hrapavosti površine u smjeru niz vjetar. Maksimalna visina na kojoj se osjeti utjecaj hrapavosti površine naziva se interni rubni sloj (eng. IBL – Internal Boundary Layer) te je također prikazana na sljedećoj slici:

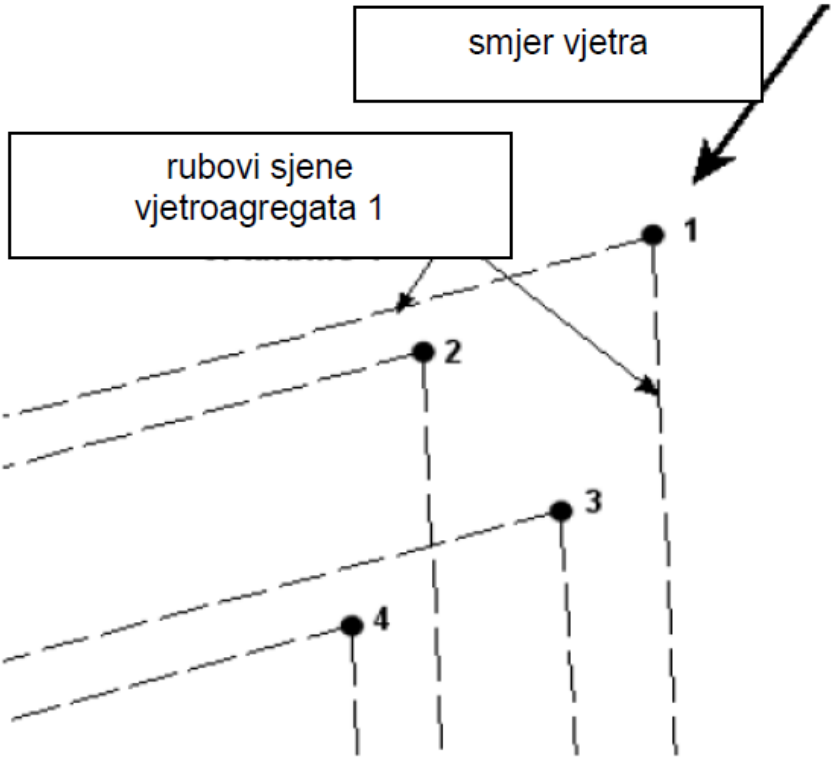


Slika 1.23 Stvaranje internog rubnog sloja na prijelazu između područja s različitom hrapavošću tla

Iznad internog rubnog sloja, brzina vjetra ostaje u svom prvotnom stanju i profil brzina vjetra se ne mijenja. Ukoliko se vjetroagregati nalaze u internom rubnom sloju, proizvodnja vjetroelektrane neće biti ugrožena uslijed hrapavosti površine. U donjem dijelu slike prikazana je tipična raspodjela brzine vjetra na visini *H*, uslijed efekta promjene hrapavosti površine. Sukladno prikazu na slici, nema efekta na vjetroelektranu dok se rotori vjetroagregata nalaze unutar internog rubnog sloja. U području gdje je interni rubni sloj prelazi preko visine vratila vjetroagregata, brzina vjetra opada eksponencijalno. Efekt promjene hrapavosti površine se smanjuje s udaljenošću od prepreka u prostoru koje su uzrokovale promjenu hrapavosti. Također, maksimalna promjena brzine vjetra na lokaciji vjetroelektrane izravno ovisi i o veličini same vjetroelektrane odnosno lokacije na kojoj su postavljeni vjetroagregati .

1.4.7 Utjecaj rada u sjeni na snagu vjetroagregata

Efekt rada u sjeni (eng. wake effect) na pojedini vjetroagregat ovisi o potisku vjetra i efektu turbilencije na samoj mikrolokaciji vjetroagregata. Budući da potisak vjetroa predstavlja sila kojom vjetar djeluje na lopatice vjetroagregata, efekt rada u sjeni manifestira se kao gubitak momenta odnosno brzine vjetra u dijelu područja koji je zasjenjen radom drugog vjetroagregata. Informacije o turbulenciji dobivaju se iz mjerenja karakteristika vjetra. Primjer pogona vjetroagregata u sjeni dat je na sljedećoj slici.



Slika 1.24 Ilustracija efekta rada vjetroagregata u sjeni

Ako se promotri primjer dat na prethodnoj slici, vidljivo je da turbina 1 ne radi u sjeni pogona nijednog vjetroagregata. Vjetroagregati 2 i 3 rade u sjeni pogona vjetroagregata 1. Ukoliko se poznaju karakteristike pogona u sjeni vjetroagregata 1, može se izračunati deficit brzine odnosno potiska u vjetroagregatima 2 i 3. Rezultat je dobivena brzina vjetra na mikrolokacijama vjetroagregata 2 i 3 te samim tim i snaga proizvodnje na istim mjestima. Također, treba imati u vidu i da se zbog rada u sjeni povećava razina turbulencije (eng. added turbulence).
Vjetroagregat 4 radi u sjeni pogona vjetroagregata 1, 2 i 3. Utjecaji rada u sjeni svih vjetroagregata trebaju se izračunati i superponirati sukladno odabranoj metodi zbrajanja utjecaja [L 12, L 13]. Rezultantna brzina vjetra na mjestu vjetroagregata 4 daje snagu proizvodnje vjetroagregata.

Vrlo često se koristi model za izračun utjecaja rada u sjeni prema aksisimetričnoj metodi razvijenoj od strane Ainsleja. Pri tom modelu utjecaj rada u sjeni ovisi o koeficijentu potiska vjetroagregata - *CT* (eng. thrust coefficient) te o itenzitetu turbulencije, odnosno prema istom modelu, smanjenje brzine vjetra uslijed rada u sjeni vjetroagregata može se definirati kao:

$$VD = \frac{0.176 \cdot CT^{0.83}}{IT^{0.63} \cdot X_D{}^{0.77}} \qquad \textbf{(1.22)}$$

gdje je:

- *VD* – smanjenje brzine (eng. velocity deficit)
- C_T – koeficijent potiska
- *IT* – intenzitet turbulencije
- X_D – udaljenost između vjetroagregata izražena u promjerima vjetroagregata

Sila potiska na vjetroagregat, odnosno na lopatice vjetroturbine predstavlja silu koja u smjeru vjetra djeluje na vjetroagregat. To je sila proporcionalna momentu ,,izdvojenom" iz vjetra i stoga kao takav definira deficit brzine pri pogonu u izravnoj sjeni od prethodnog vjetroagregata. Koeficijent potiska je bezdimenzionalna veličina koja predstavlja ekvivalentnu silu potiska (u kN). Preporuča se uporaba podataka datih od strane proizvođača vjetroagregata, a koji se tiču vrijednosti koeficijenata potiska.

Kad je vjetroagregat u sjeni jednog ili više vjetroagregata koji se nalaze na dolaznom pravcu vjetra, razina turbulencije se povećava i veća je od razine turbulencije koja bi bila uzrokovana samo i isključivo prolaskom vjetra preko objekata u okolišu. Ova pojava naziva se dodatna turbulencija (eng. added turbulence) i računa se na kontrolnim točkama zamišljene kružnice rotora uporabom formule koju je razvio Garrad-Hassan. Također, kao opcija računanja iste, mogu poslužiti formulacije date metodom RISO laboratorija te metodom datom u Larsen Cookery Book. Dodatna turbulencija uzima se kao konstantna vrijednost koja se dobila računanjem na cijeloj širini rada u sjeni vjetroagregata. Metoda Garrad-Hassana rezultira većim gubicima rada u sjeni pa stoga kao izlaznu veličinu daje manje iznose proizvedene energije pa je stoga uzeta kao konzervativnija metoda.

U slučajevima kad na rad vjetroagregata utječe nekoliko drugih vjetroagregata zbog kombiniranog rada u sjeni, deficit brzine vjetra mora se superponirati [L 17, L 20]. Dvije se metode nameću za zbrajanje utjecaja rada u sjeni, a to su

- zbroj kvadrata deficita brzine vjetra,
- metoda ravnoteže energije.

Za većinu vjetroelektrana nema velike razlike u primjeni ovih dviju metoda, ali se metoda ravnoteže energije preporuča budući da je dala vrlo dobre rezultate na testnim primjerima [L 22]. Ipak, u slučajevima vjetroelektrana s

malim brojem vjetroagregata koji su na velikoj međusobnoj udaljenosti, metoda zbroja kvadrata deficita brzine vjetra se nameće kao povoljnije rješenje jer su iznosi deficita brzine vjetra manji.

Model utjecaja rada u sjeni razvijen je upotrebom aksi-simetrične metode razvijene od strane Ainsliea. Kako je već ranije napomenuto, veličina utjecaja rada u sjeni ovisi o koeficijentu sile potiska vjetroagregata (C_T), intenzitetu turbulencije uzrokovane terenom (I), te omjeru visine vratila i duljine hrapavosti površine (ZH/Z_o). Ova relacija može se pojednostavljeno prikazati u obliku jednadžbe:

$$IT = \frac{1}{\log\left(\frac{ZH}{Z_0}\right)} \qquad \textbf{(1.23)}$$

Dodatna turbulencija (eng. added turbulence) uslijed rada u sjeni računa se na kontrolnim točkama opisanog kruga lopatica rotora upotrebom formulacije:

$$AT = 1.31 \cdot CT^{0.7} \cdot I^{0.68} \cdot \left(\frac{X}{X_n}\right)^{-0.96} \qquad \textbf{(1.24)}$$

gdje je:
- X - udaljenost u smjeru niz vjetar
- X_n - dužina područja bliskog rada u sjeni (eng. near wake length)

Ukoliko vjetroagregat radi u sjeni nekoliko drugih vjetrogregata, zbrajanje deficita brzine uslijed rada u sjeni u ovom radu izračunato je korištenjem drugog korijena sume kvadrata deficita brzine

$$\left(1 - \frac{Ui}{Uw}\right)^2 = I \cdot \left(1 - \frac{U_{ij}}{U_j}\right)^2 \qquad \textbf{(1.25)}$$

gdje je:
- U_w - brzina vjetra
- U_i - brzina vjetra na i–tom vjetroagregatu
- U_{ij} - brzina vjetra na i-tom vjetroagregatu uslijed rada u sjeni j-tog vjetroagregata

Ostale metodologije podrazumijevaju i upotrebu formulacija koje koriste načelo ravnoteže energije, geometrijske superpozicije te linearne superpozicije.

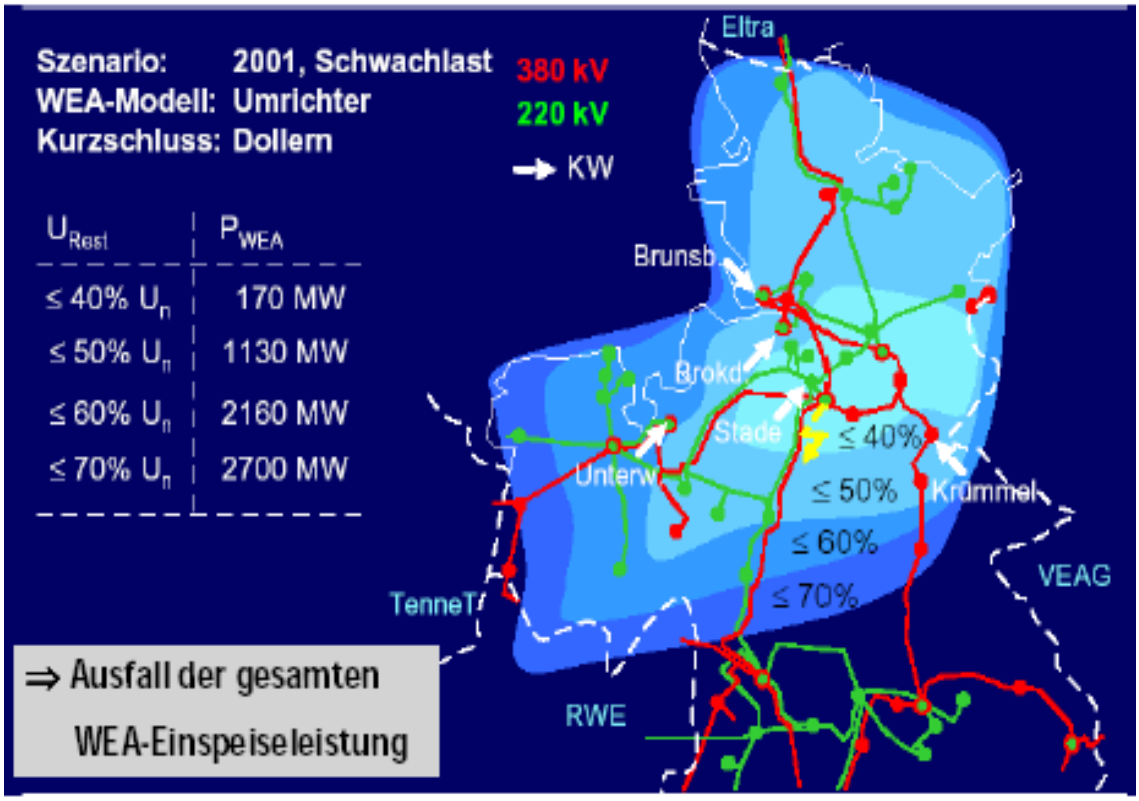
Iz svega prikazanog, vidljivo je da je izlazna snaga vjetroelektrane ovisna o čitavom nizu faktora i parametara koji utječu na istu. Stoga se u posljednjih nekoliko godina razvija čitav niz determinističkih i nedeterminističkih modela za predviđanje izlazne snage vjetroelektrane te pogon vjetroelektrane.

1.4.8 Prolazak kroz kvar

Vjetroelektrana u cjelini, a samim tim i pojedini vjetroagregati, mora biti u stanju ,,izdržati" stanje kvara, odnosno kratkog spoja u mreži te ostati u pogonu bez obzira na snižene napone i povišene struje u mreži.

U trenutku kratkog spoja u elektroenergetskom sustavu u blizini nastanka kratkog spoja dolazi do pojave sniženih napona koja se može manifestirati ispadom pojedinih vjetroelektrana iz pogona uslijed nemogućnosti ostanka u pogonu pri sniženim naponima. To u konačnici može rezultirati gubitkom iznimno velikog dijela proizvodnje djelatne snage te dovesti do većeg smanjenja frekvencije i daljnjih problema i nestabilnosti elektroenergetskog sustava [L 44].

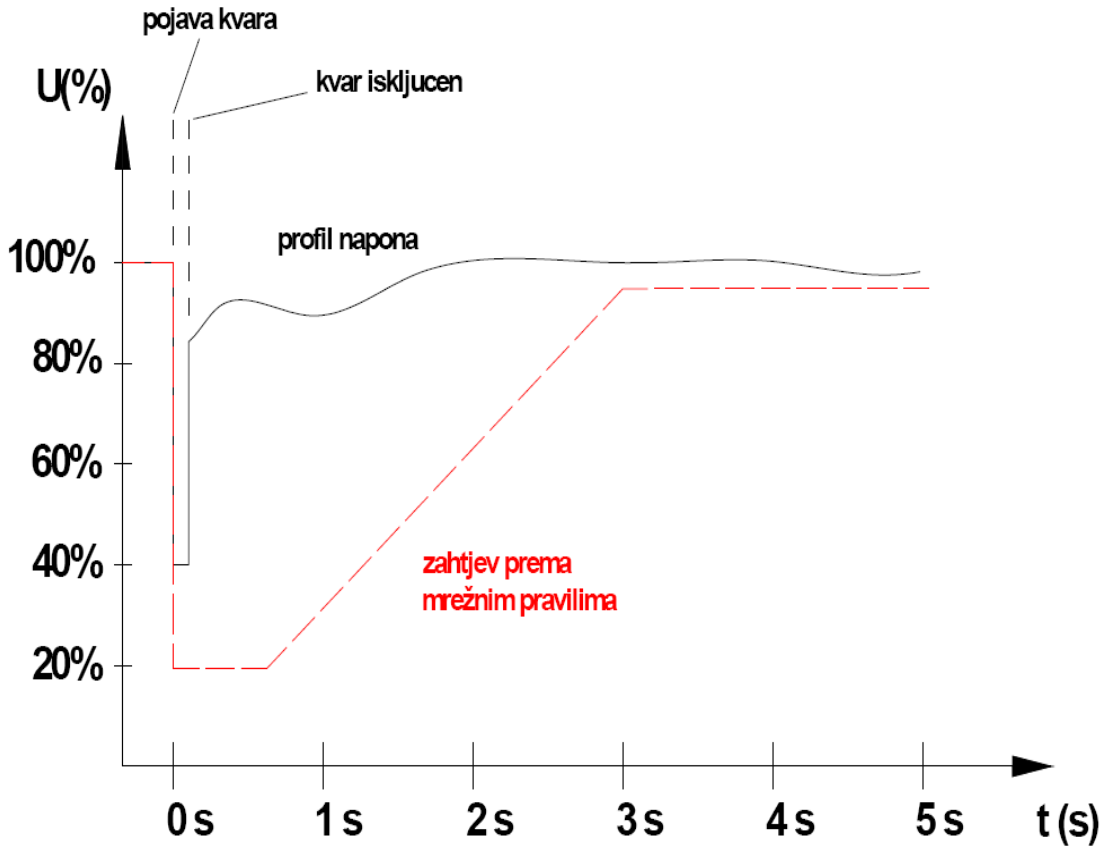
Na sljedećoj slici prikazana je situacija sa sniženim naponima u elektroenergetskom sustavu Operatora EON u Njemačkoj. Vidljivo je da se u zoni napona nižeg od 0.7 p.u. nalazi oko 2700 MW instalirane proizvodnje u vjetroelektranama. Iz toga proizlazi da bi u toj zoni, vjetroagregati osjetljivi na sniženje napona vrlo lako bili isključeni iz pogona što bi rezultiralo dodatnim zahtjevima za aktiviranjem regulacije djelatne snage te po potrebi i isključivanjem dijela opterećenja.



Slika 1.25 Profil napona nakon tropolnog kratkog spoja u elektroenergetskom sustavu operatora EON u Njemačkoj 2001.

Da ne bi došlo do većeg gubitka proizvodnje djelatne snage iz vjetroelektrana, potrebno je da vjetroagregati imaju karakteristike koje im omogućavaju prolazak kroz kvarove pri kojima dolazi do značajnijeg snižavanja napona. Inače će čak i u slučaju udaljenih kvarova doći do odvajanja vjetroagregata s mreže što, osim gubitaka u proizvodnji električne energije, može dovesti i do daljnjih problema s naponom u mreži, a samim tim i nestabilnosti sustava.

Mogućnost prolaska kroz kvarove (eng. LVRT – Low Voltage Ride Through i ZVRT – Zero Voltage Ride Through) iznimno je bitna karakteristika modernih vjetroagregata koja im omogućava dodatno podržavanje elektroenergetskog sustava u kritičnim uvjetima.
Primjer smanjenja napona na priključnom mjestu zajedno sa zahtjevima sukladno Mrežnim pravilima hrvatskog elektroenergetskog sustava prikazani su na sljedećoj slici.

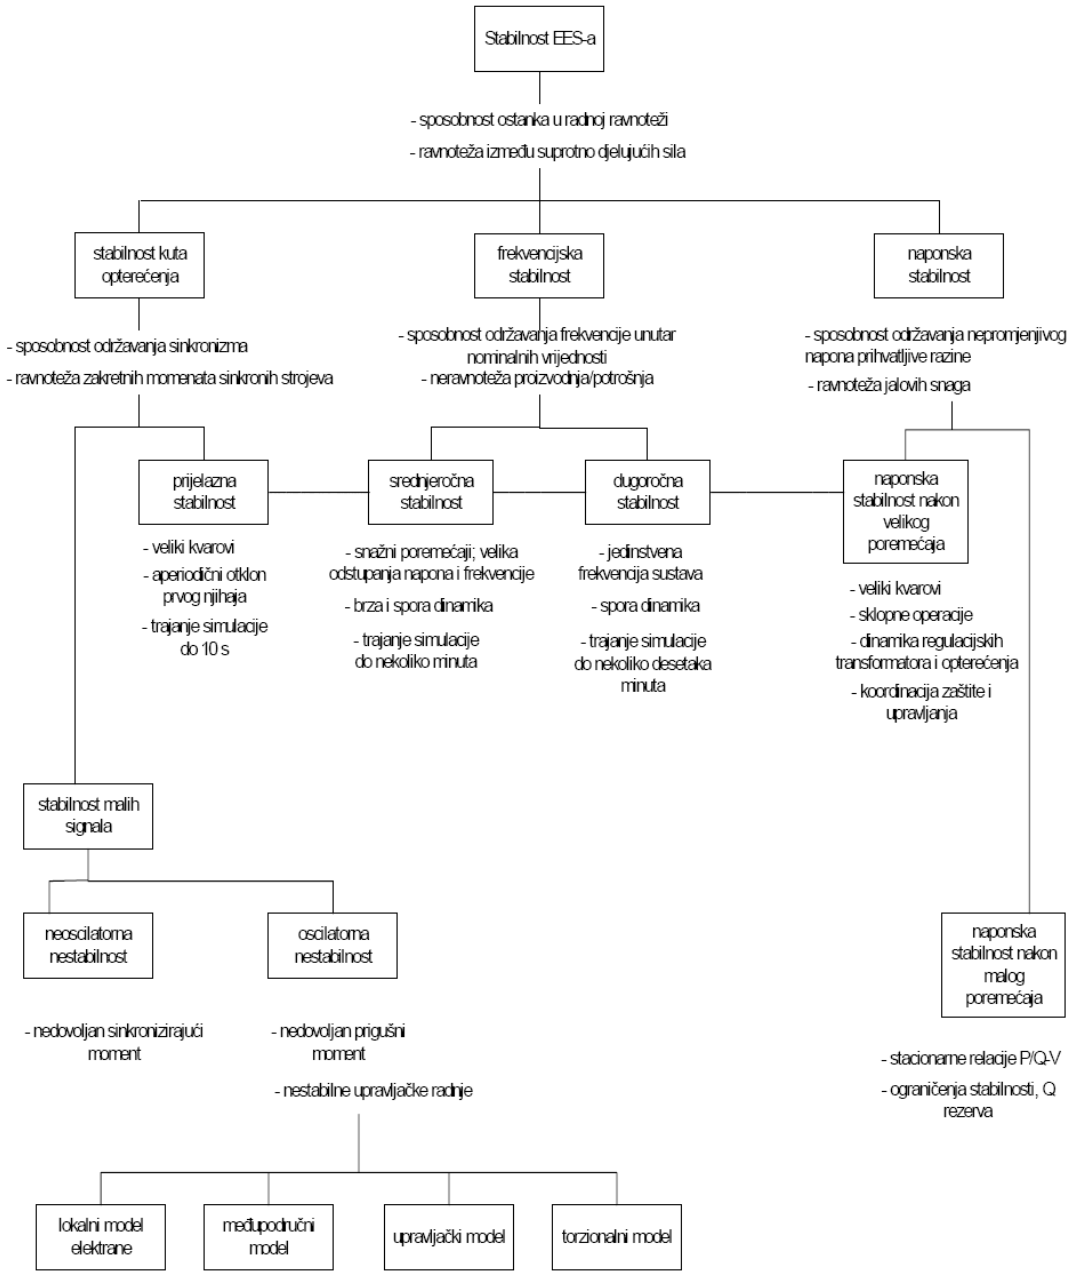


Slika 1.26 Prikaz profila napona pri kvaru u sustavu te zahtjeva za karakteristike vjetroagregata sukladno dodatnim tehničkim uvjetima za priključak i pogon vjetroelektrana na prijenosnoj mreži

1.5. INTEGRACIJA VJETROELEKTRANA U ELEKTROENERGETSKI SUSTAV

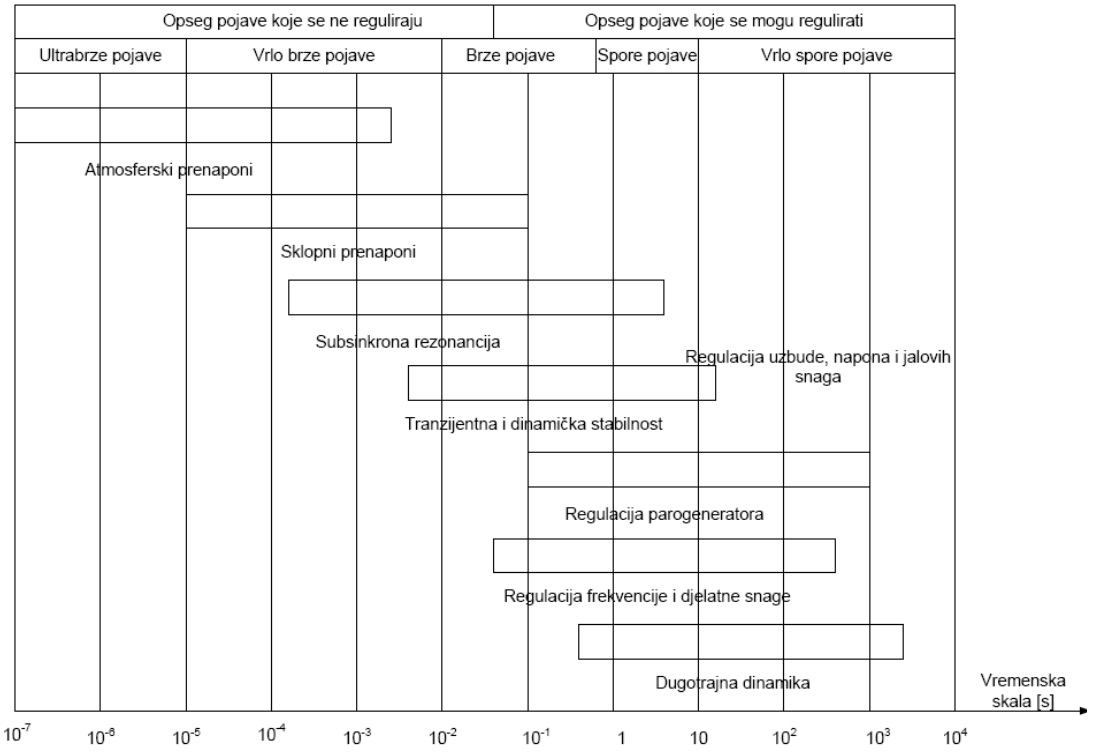
1.5.1 Stabilnost elektroenergetskog sustava

Temeljna definicija stabilnosti EES-a je sposobnost elektroenergetskog sustava koja omogućava njegov ostanak u ravnotežnom pogonskom stanju pri normalnim pogonskim prilikama te povratak u prihvatljivo ravnotežno stanje nakon nekog poremećaja u sustavu. Stabilnost je ravnotežno stanje među suprotnim silama.



Slika 1.27 Pregled problema stabilnosti elektroenergetskog sustava

Nestabilnost unutar EES-a može se manifestirati na puno različitih načina ovisno o konfiguraciji sustava, načinu rada i obliku poremećaja. U slučaju značajnije neravnoteže između proizvodnje i potrošnje, generatori i primarni regulatori turbina bivaju izuzetno važni kao i upravljanje sustavom i posebne zaštite.



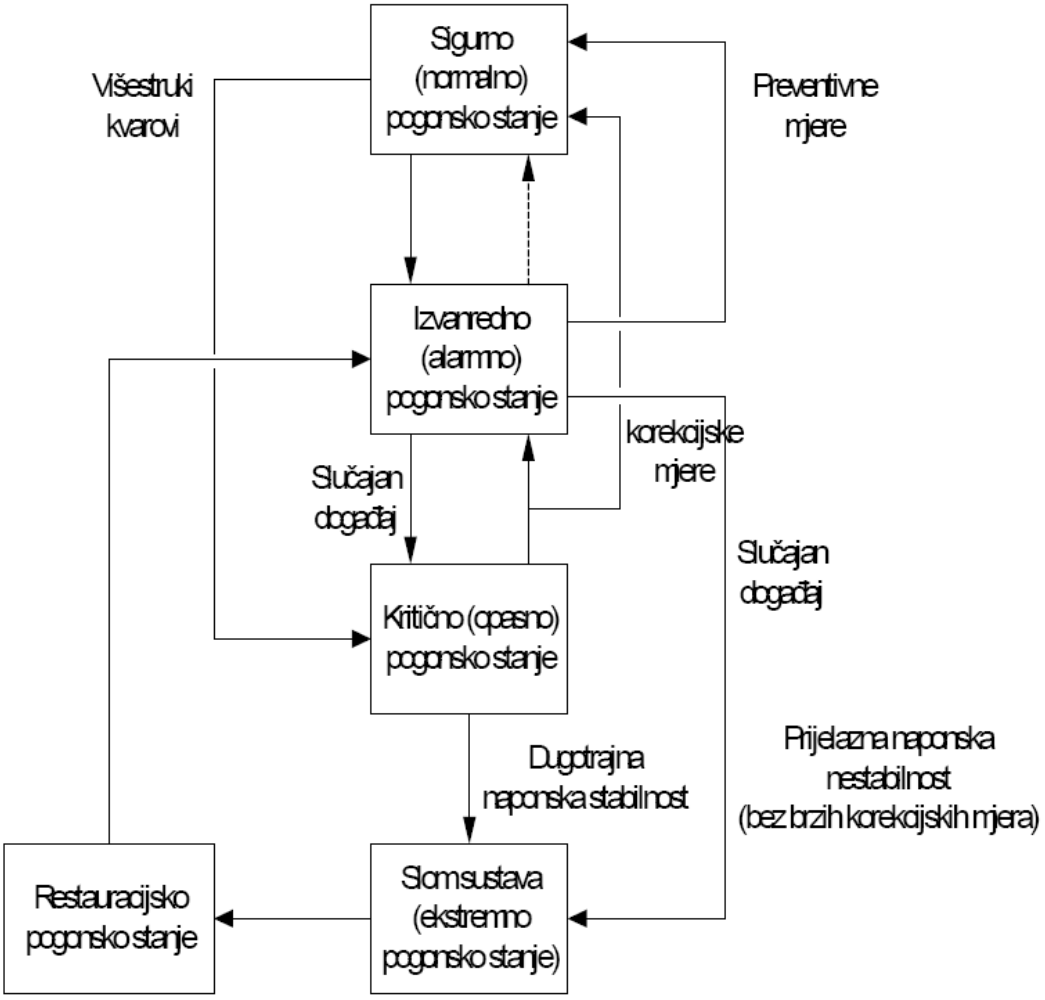
Slika 1.28 Vremenska skala odvijanja različitih pojava u elektroenergetskom sustavu

Frekvencijska stabilnost je sposobnost održavanja frekvencije EES-a unutar nazivnog intervala vrijednosti nakon poremećaja koji može, ali i ne mora, rezultirati razdvajanjem sustava u podsustave. U ovom slučaju poremećaj općenito rezultira neravnotežom proizvodnje i potrošnje i/ili nestabilnom regulacijom frekvencije.

Naponska stabilnost EES-a odražava sposobnost održavanja napona na svim čvorištima u sustavu pri normalnim pogonskim prilikama te nakon što je sustav bio izložen poremećaju. Sustav ulazi u stanje naponske nestabilnosti kad poremećaj uzrokuje progresivno i nekontrolirano opadanje napona na čvorištima u sustavu. Razlozi naponske nestabilnosti u EES-u su jednostavno objašnjivi. Načini na koje dolazi do naponske nestabilnosti u stvarnom EES-u su kompliciran i mogu uključivati međusobni utjecaj velikog broja uređaja i upravljačkih signala čiji su parametri određeni pogonskim stanjem i značajkama EES-a. Naponski slom (ili naponsku nestabilnost) može izazvati ili nedovoljna uzbuda, tj. nedostatak rezerve jalove snage, ili povećanje reaktancije sustava ili rad blizu maksimalnog kapaciteta mreže.

Stabilnost kuta opterećenja ili kutna stabilnost označava sposobnost sinkronih generatora priključenih na EES da ostanu u sinkronizmu s mrežom na koju su priključeni odnosno da održavaju sinkroni pogon pri normalnim pogonskim uvjetima kao i nakon što su bili izloženi nekom poremećaju. Predmetna stabilnost ovisi o sposobnosti svakog generatora u mreži da održava ravnotežno stanje između elektromagnetskog i mehaničkog momenta odnosno da se vrati u ravnotežno stanje nakon nekog poremećaja. Nestabilnost koja može rezultirati iz opisane neravnoteže, pojavljuje se u povećanim njihanjima kuta opterećenja pojedinih generatora što može dovesti do gubitka sinkronizma istih.

Mjere za sprečavanje raspada elektroenergetskog sustava mogu se podijeliti na prevencijske i korekcijske mjere, a sukladno sljedećoj slici.



Slika 1.29 Prevencijske i korekcijske mjere za sprečavanje sloma elektroenergetskog sustava

Prevencijske mjere poduzimaju se predviđanjem značajnih poremećaja i mogu uključivati skupe radnje kao što su preraspoređivanje proizvodnje (eng. rescheduling) u cilju smanjenja uvoza električne energije ili čak iskapčanja različitih potrošača. Neke prevencijske radnje mogu biti iznimno značajne i korisne pri određenim poremećajima, ali ne tako korisne i značajne ili čak i štetne za druge poremećaje. Prevencijske mjere obično su inicirane od strane operatera na temelju programa za procjenu sigurnosti sustava ili na temelju off-line simulacija. Neke efikasne prevencijske mjere su vrlo jednostavne, primjerice, uklapanje paralelne kondenzatorske baterije s ciljem povećanja brze rezerve jalove snage u generatorima.
Iako su prevencijske mjere pouzdanije i robusnije, korekcijske mjere su često efikasnije i ekonomičnije. Korekcijske mjere se primjenjuju (obično automatski) ukoliko se pojavi značajni poremećaj u sustavu. Korekcijske mjere služe za premještanje pogonskog stanja sustava iz hitnog pogonskog stanja u alarmno ili normalno pogonsko stanje odnosno iz alarmnog stanja u normalno pogonsko stanje.
Ovakvom klasifikacijom pogonskih stanja EES-a prevencijske mjere za sprečavanje naponskog sloma pomiču pogonsko stanje iz alarmnog u normalno stanje. Slika 1.29 pokazuje klasifikaciju pogonskih stanja s naznačenim korekcijskim i prevencijskim mjerama. Budući da nema općeprihvaćene jedinstvene klasifikacije stanja u EES-u, naveden je primjer kompromisnog prijedloga s kriterijem potrebnog vremena do korektivne radnje. Tako definirana pogonska stanja su:

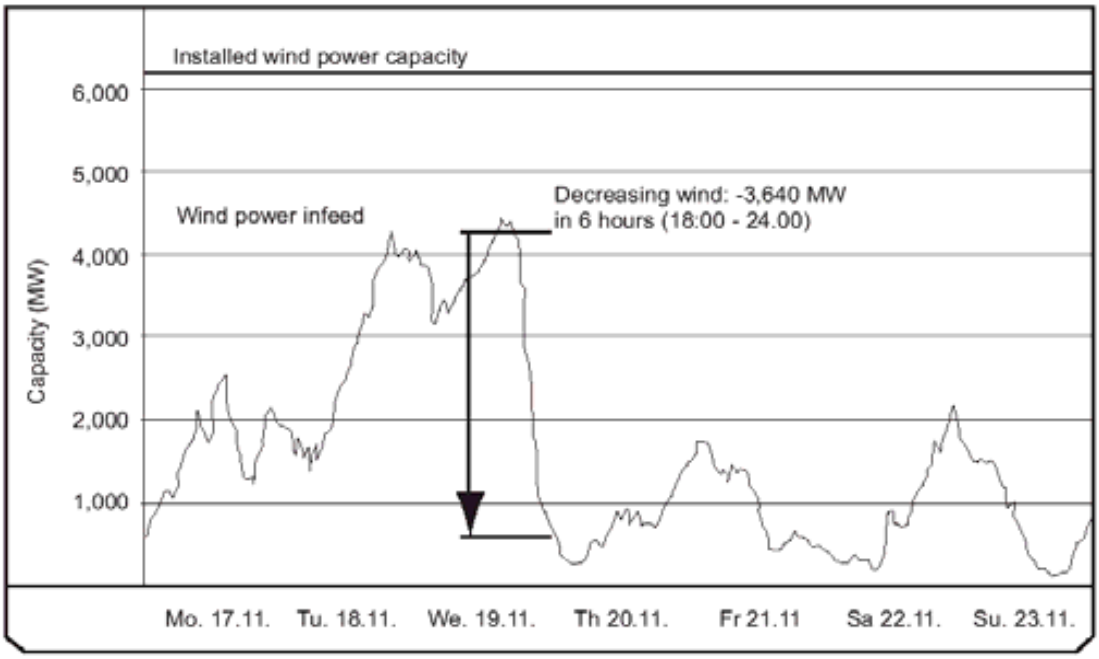
- normalno (sigurno),
- izvanredno (alarmno, eng. alert state),
- kritično (opasno, eng. emergency state),
- krajnje kritično (ekstremno),
- restauracijsko (stanje uspostavljanja).

Pri izvanrednom stanju stanje u sustavu je pogoršano, ali uvjeti pogona još nisu narušeni. Vjerojatnost pogoršanja je velika jer slijedeći ispad (N-1) dovodi do kritičnog stanja. Obično je potrebno 15-30 min za uspostavu razine sigurnosti kao u normalnom pogonu. Potrebno je brzo intervenirati da se abnormalna situacija nastala slučajnim događajem ne razvije u kritičnu.
U kritičnom stanju u sustavu su neprihvatljiva opterećenja, naponi ili frekvencija i potrebno je smjesta poduzeti radnje za saniranje stanja. Prijeđeni su pragovi kritičnih opterećenja (vodova, komponenti), a moduli i kutevi napona, kao i frekvencije, su izvan normalnog intervala. To je obično posljedica iznenadnog kvara u sustavu.
Kritično stanje se dalje može pogoršavati u ekstremno pogonsko stanje koje rezultira kaskadnim ispadima u mreži i raspadanjem sustava.

1.5.2 Vođenje pogona EES-a uz integraciju vjetroelektrana

Iz prethodno navedenih razloga, potrebno je redovito pratiti opterećenje elektroenergetskog sustava u cilju održavanja napona na čvorištima te regulacije frekvencije i djelatne snage sustava, a samim tim i omogućavanja stabilnosti elektroenergetskog sustava u cjelini. To je osobito teško u uvjetima povećane integracije vjetroelektrana koje se ne mogu ubaciti u dijagrame opterećenja i koje često ne sudjeluju u regulaciji napona i jalove snage. Proizvodnja vjetroelektrana modelira se kao dio opterećenja te utječe na smanjenje ukupnog opterećenja sustava. Samim tim unosi se dodatna stohastička varijabla u predviđanje opterećenja koje samo po sebi spada u iste takve varijable [L 45].

Uzevši u obzir ovisnost snage vjetroelektrane o brzini vjetra i gustoći zraka predstavljenom u prethodnim poglavljima, može se, uslijed stohastičke naravi brzine vjetra, temperature i tlaka zraka, očitati i varijabilnost izlazne snage vjetroelektrane. Sve veći udjel vjetroelektrana u elektroenergetskim sustavima u svijetu stvara sve veće probleme vezane uz regulaciju elektroenergetskog sustava. Najveći problemi vezani su uz stohastičku narav vjetra kao izvora energije odnosno intermitirajuću vrstu proizvodnje električne energije.



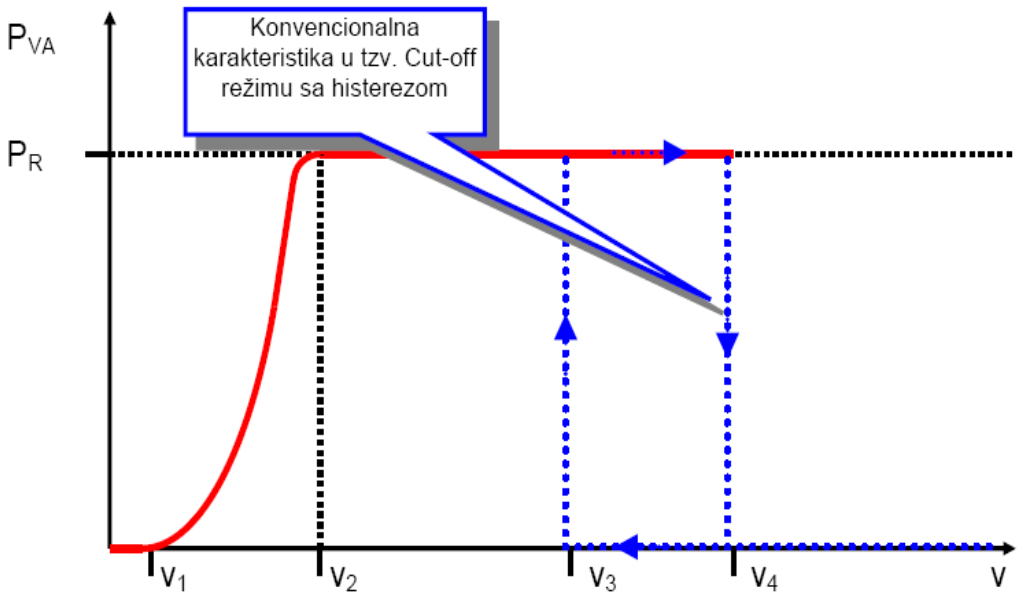
Slika 1.30 Fluktuacija snage ukupne proizvodnje svih vjetroelektrana u prijenosnom sustavu mreže operatora E.ON Netz u Njemačkoj 2007.

Na slici Slika 1.30 prikazana je fluktuacija ukupne snage proizvodnje svih vjetroelektrana u prijenosnoj mreži E.ON Netz Operatora prijenosnog sustava

u Njemačkoj na kojoj je vidljivo i smanjenje snage proizvodnje za 3640 MW u vremenu od 6 sati. Takav propad u proizvodnji djelatne snage dogodio se nekoliko puta te je doveo do znatnih poteškoća u regulaciji frekvencije i djelatne snage što je, uz još određene probleme u prijenosnoj mreži, nekoliko puta u konačnici rezultiralo i djelomičnim raspadom sustava.

Jedan od razloga ovakvog naglog propada ukupne snage proizvodnje vjetroelektrana u sustavu krije se u karakteristici proizvodnje vjetroelektrane odnosno u krivulji snage vjetroelektrane.

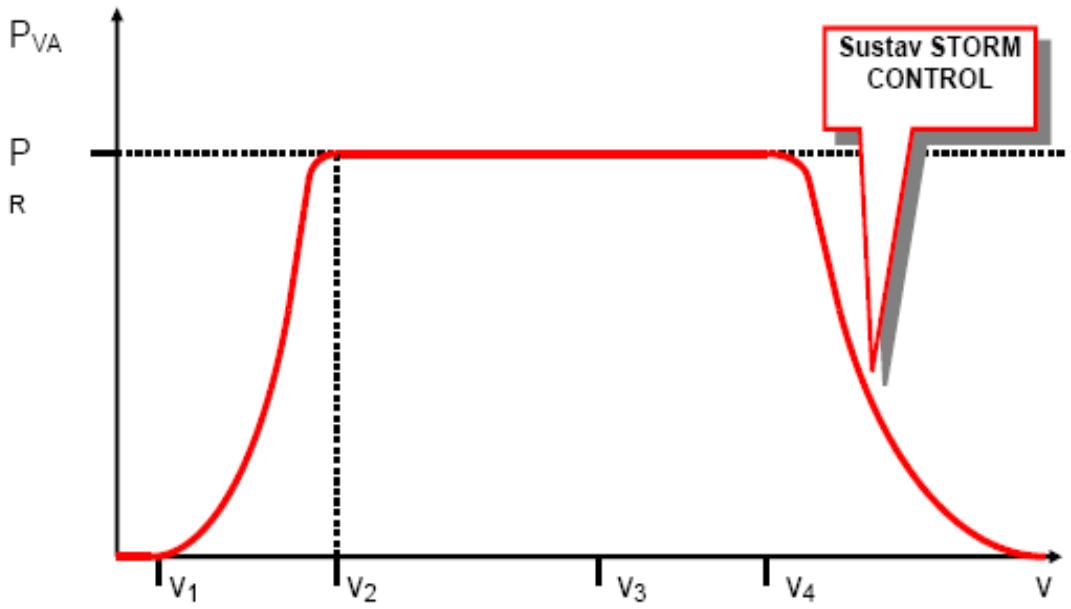
Klasične krivulje snage vjetroaregata imaju karakteristiku prema kojoj pri određenoj brzini vjetra v1 (eng. cut-in speed) vjetroagregati počinju s radom. Pri brzini v2 vjetroagregati dolaze na nazivnu snagu proizvodnje, a pri brzini v4 (eng. cut-off speed) vjetroagregat se koči i isključuje s mreže. Brzina pri kojoj se vjetroagregat isključuje s mreže iznosi oko 25 m/s. Dakle, u slučaju povišenja brzine vjetra iznad 25 m/s snaga vjetroagregata pada na nulu. Ponovno uključenje vjetroagregata pri smanjenju brzine ne događa se pri padu brzine vjetra na 25 m/s već vjetroagregati posjeduju određenu histerezu te se ponovno uključivanje u pogon odvija pri padu brzine vjetra ispod brzine v3, koja za većinu agregata iznosi oko 22-23 m/s. Ista karakteristika opisana je na sljedećem dijagramu.



Slika 1.31 Klasična karakteristika krivulje snage vjetroagregata

Moderni vjetroagregati posjeduju sustav kontrole izlazne snage kod kritičnih brzine vjetra koji se često naziva Storm Control. Naime, vrlo često se brzine vjetra kreću u rasponu 25 m/s – 30 m/s pri prolasku veće olujne fronte kroz polje vjetroagregata. U tom slučaju potrebno je izbjeći isključenje

vjetroagregata uslijed povišenja brzine vjetra iznad 25 m/s. To se postiže tzv. sustavom HWRT (eng. High Wind Ride Through) koji se još i naziva STORM CONTROL kod nekih proizvođača i to na način da vjetroagregat ostaje u pogonu, ali sa smanjenom snagom proizvodnje. Ipak, čak i u takvom režimu rada, gdje se brzine vjetra kreću oko 30 m/s, vjetroagregat daje određenu snagu u mrežu sukladno sljedećoj krivulji snage.



Slika 1.32 Krivulja snage vjetroagregata s ugrađenim sustavom HWRT tj. Storm Control

Iz prikazanog dijagrama, vidljivo je da vjetroagregat nastavlja pogon i u slučaju pojave vjetrova brzina većih od 25 m/s, doduše sa smanjenom snagom. Kao rezultat takve karakteristike, vjetroagregat ostaje u pogonu svo vrijeme trajanja jačih strujanja vjetra čime se povećava proizvodnja same vjetroelektrane. Jednako tako, na ovaj način ne dolazi do naglog isključenja vjetroelektrane i gubitka veće snage proizvodnje, čime se postiže velik doprinos stabilnosti sustava jer nema potrebe naglog angažmana većih snaga regulacijskih elektrana u sustavu.
Vjetroagregat se ne pokreće iz položaja mirovanja ili praznog hoda u slučaju brzine vjetra veće od 31 m/s. Ukoliko je zabilježena prosječna brzina vjetra veća od 31 m/s ili udar vjetra veći od 34 m/s, upravljački sustav zaustavlja vjetroagregat. Turbina se također zaustavlja ukoliko je dostignut maksimalno dopušten kut zakreta lopatice rotora ili ako je anemometar zaleđen. U svim spomenutim slučajevima vjetroagregat prelazi u pogon u praznom hodu. Komponente vjetroagregata (lopatice rotora, gondola, stup i temelji) konstruirani su da izdrže i veće brzine vjetra. Turbina se automatski ponovno pokreće kada brzina vjetra padne ispod 31m/s (cut-out speed) u periodu od 10 minuta.

Kada brzina vjetra premaši 28 m/s upravljački sustav za velike brzine vjetra ne zaustavlja trenutno turbinu, već kontinuirano smanjuje snagu zakretanjem lopatica rotora (slika 2-13). Izlazna snaga se smanjuje na 0 MW pri prosječnoj brzini vjetra od 34 m/s. Ovakva metoda zaustavljanja pri jakim vjetrovima poboljšava ponašanje VE u sustavu i povećava prosječnu izlaznu snagu.
Osim toga, uslijed ostanka u pogonu vjetroagregati su u stanju proizvoditi kako djelatnu tako i jalovu snagu potrebnu za regulaciju napona i jalove snage. Proizvodnja jalove snage opisana je pogonskim dijagramom vjetroagregata.

1.5.3 Problemi regulacije frekvencije i djelatne snage

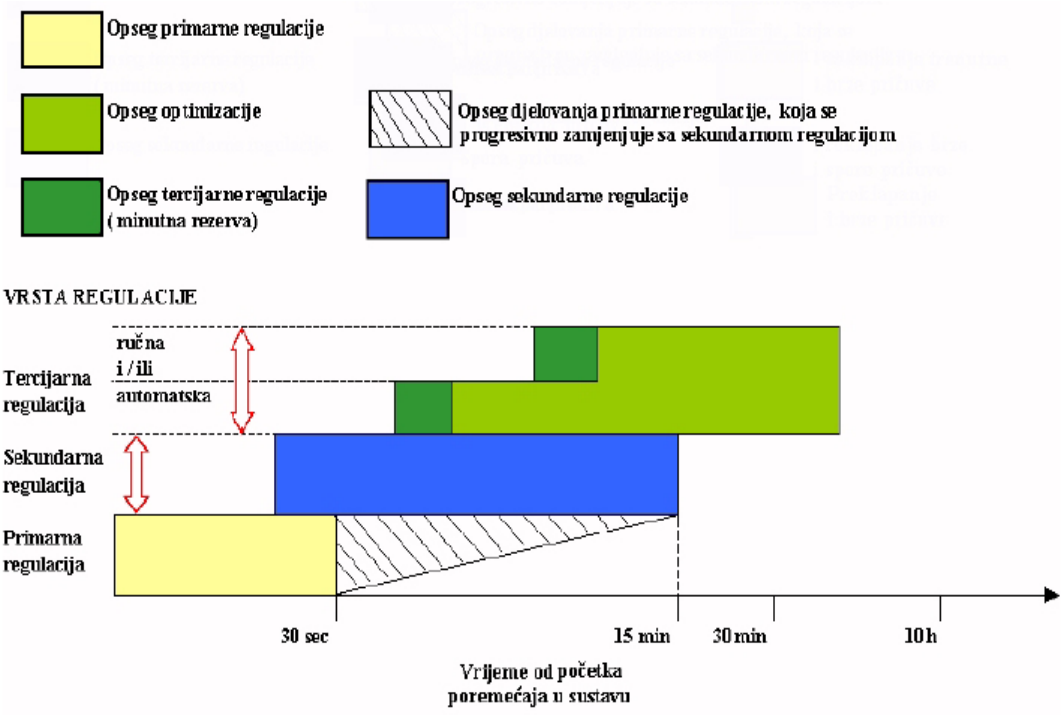
Prethodno opisane pojave prilikom značajnije integracije vjetroelektrana u sustav mogu stvoriti znatne probleme u regulaciji frekvencije i djelatne snage u sustavu.

Stalno održavanje konstantne frekvencije nužno je za normalan pogon elektroenergetskog sustava zbog
- točnosti preraspodjele opterećenja na određene agregate,
- dimenzioniranja potrošača na točno određenu frekvenciju.

U određenim prijelaznim pogonskim stanjima nije niti moguće održavati frekvenciju konstantnom, a uostalom nije toliko niti potrebno u istim posebnim situacijama.
U sustavu UCTE dozvoljeno odstupanje iznosi $\pm$1‰ odnosno $\pm$50 mHz. To znači da je normalan frekvencijski opseg u intervalu vrijednosti:

49.95 – 50.05 Hz.

Prema UCTE definiraju se vrste regulacije sukladno vremenskom odzivu, a sukladno sljedećem dijagramu:

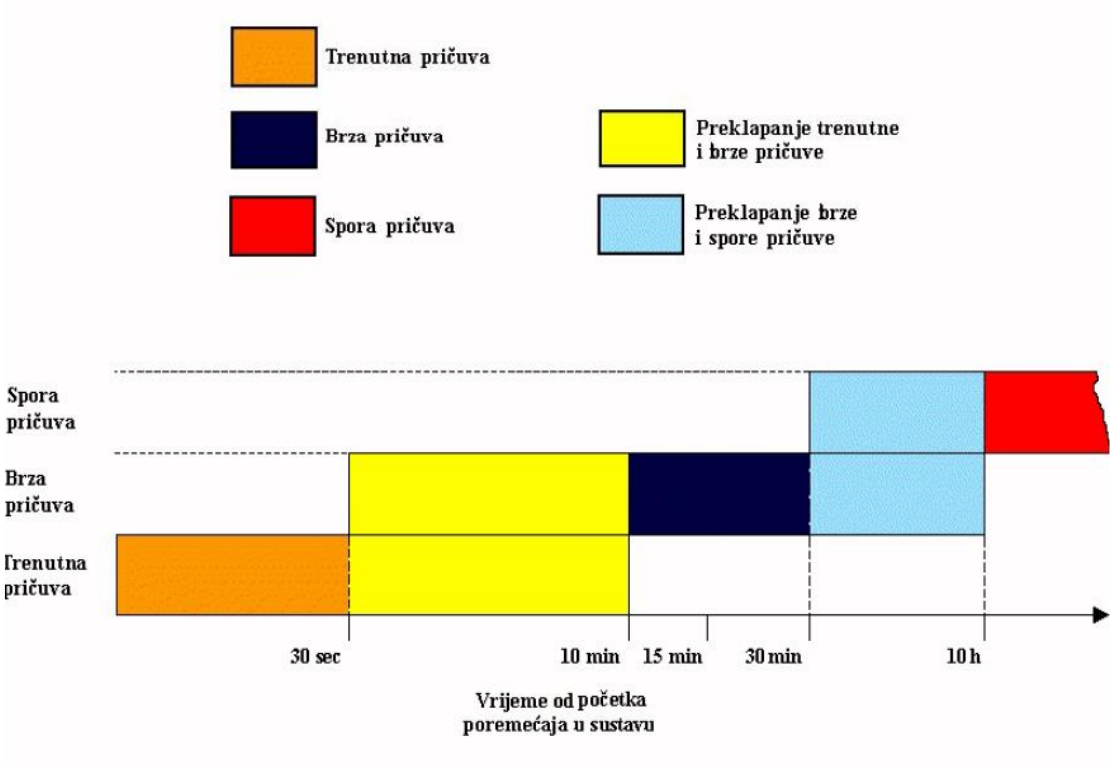


Slika 1.33 Vrste regulacije prema UCTE (izvor FER-ZVNE)

Primarna regulacija frekvencije obuhvaća djelovanje turbinskih regulatora brzine vrtnje, koji djeluju na promjenu snage turbine kada frekvencija odstupa od nazivne vrijednosti u sinkrono povezanoj mreži kao cjelini.

Sekundarna regulacija mora djelovati 30 sekundi nakon pojave odstupanja između proizvodnje i potrošnje (ispravljanje trenutne regulacijske greške) tj. kada je završeno djelovanje primarne regulacije, čak i u najtežim uvjetima koji su pretpostavljeni za referentni poremećaj. Povratak frekvencije i snage razmjene na zadane vrijednosti pod djelovanjem sekundarne regulacije mora završiti nakon 15 minuta.

Tercijarna regulacija podrazumijeva podešenje parametara sekundarne regulacije za osiguranje dovoljne zahtijevane sekundarne regulacijske pričuve u dovoljnoj količini i u pravom trenutku te gospodarski optimalne raspodjele sekundarne regulacijske snage na proizvodne jedinice koje sudjeluju u sekundarnoj regulaciji.
Na sljedećoj slici prikazan je međusobni odnos i podjela pričuve prema UCTE-u.



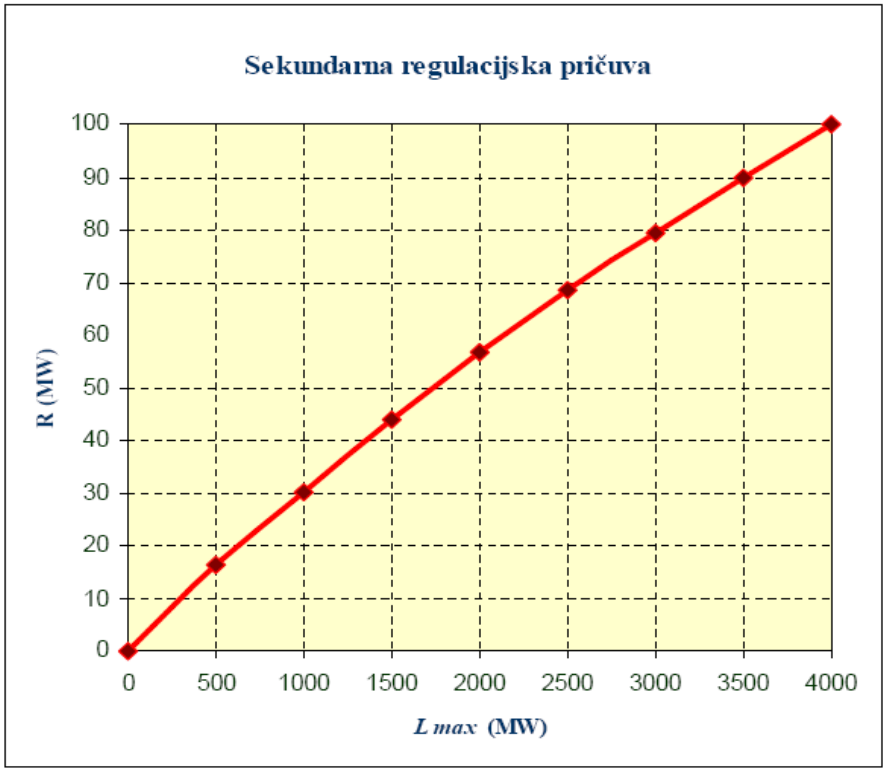
Slika 1.34 Podjela pričuve prema UCTE (izvor FER-ZVNE)

Zahtijevana sekundarna regulacijska pričuva *RP* (pozitivni dio sekundarnog regulacijskog opsega) prema preporukama UCTE-a odnosno ENTSO-E iznosi:

$$RP = \sqrt{a \cdot L_{\max} + b^2} - b \qquad \textbf{(1.26)}$$

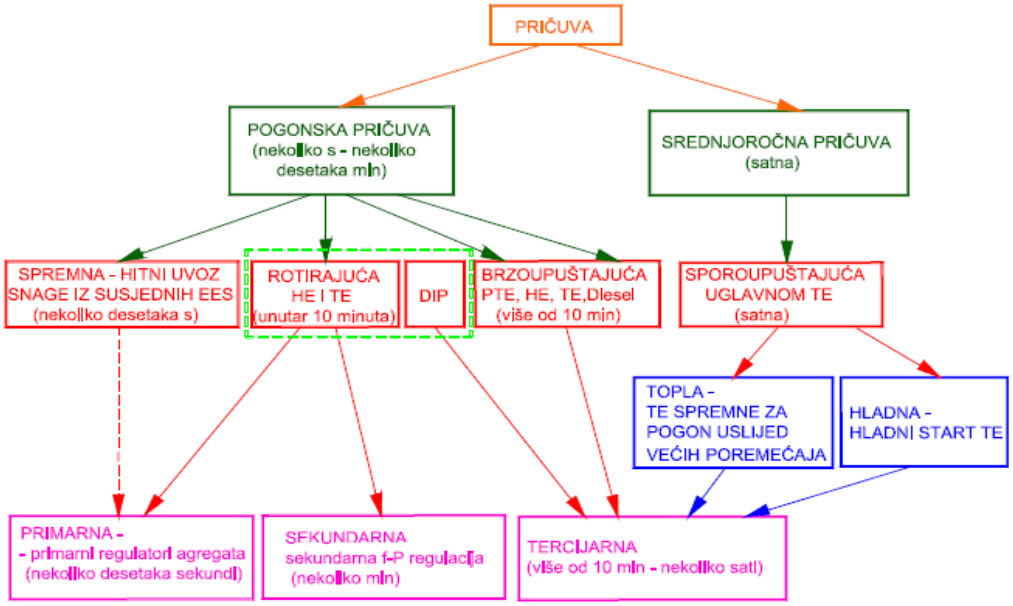
gdje je:
RP - zahtijevana vrijednost sekundarne regulacijske rezerve (MW)
L_{max} - očekivana maks. snaga potrošnje regulacijskog područja (MW)
a=10 i *b*=150- iskustveni koeficijenti

Grafički prikaz prethodne jednadžbe dat je na sljedećoj slici:



Slika 1.35 Sekundarna regulacijska pričuva (izvor FER-ZVNE)

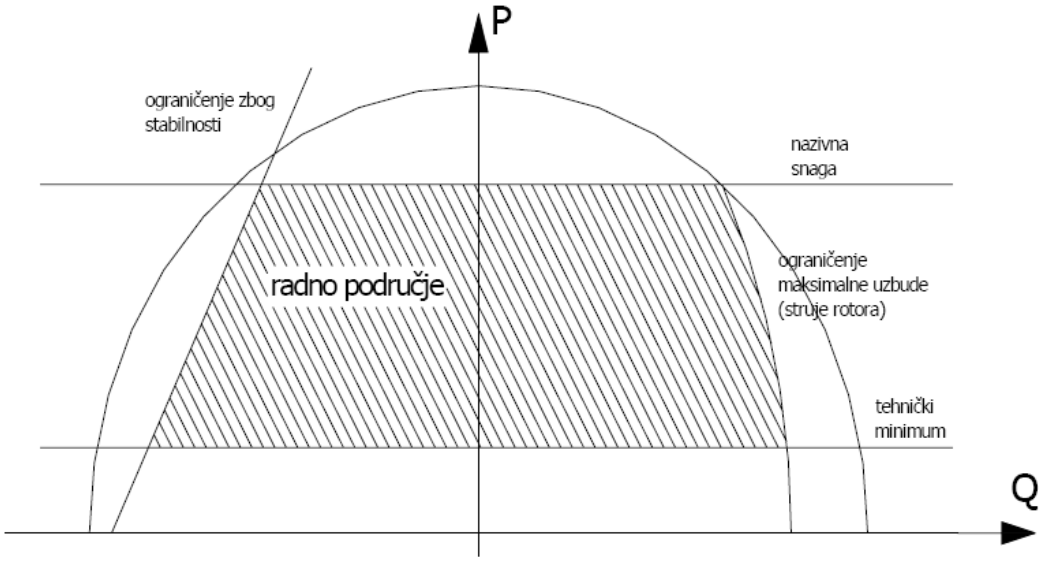
Detaljna podjela pričuve u elektroenergetskom sustavu data je na sljedećoj slici



Slika 1.36 Detaljna podjela pričuve u elektroenergetskom sustavu (izvor FER-ZVNE)

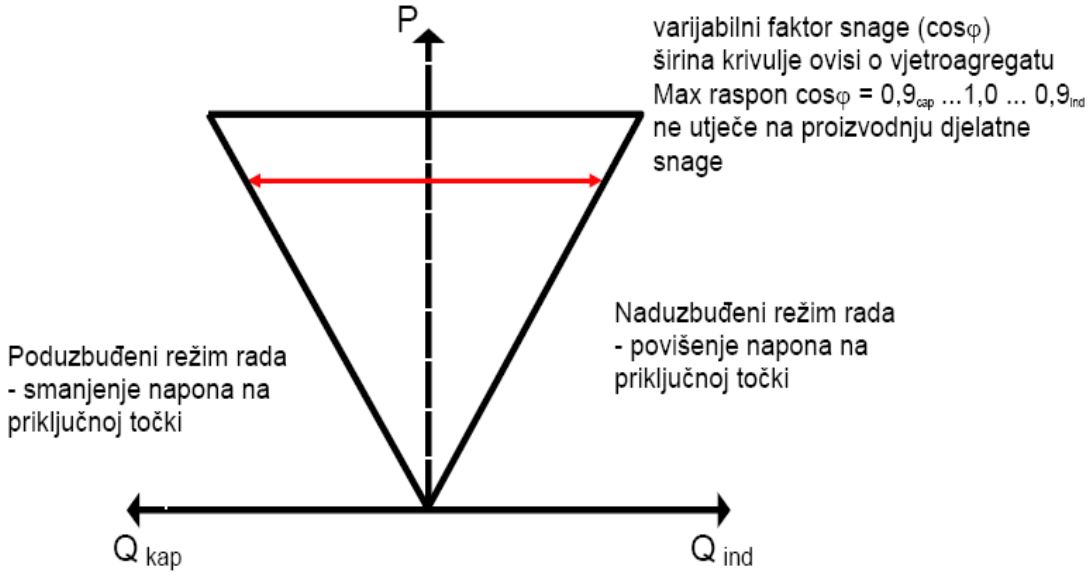
1.5.4 Problemi regulacije napona i jalove snage

U stvarnom pogonu generatori pa tako i vjetroagregati nemaju neograničenu proizvodnju jalove snage. Ona je ograničena maksimalnom uzbudom odnosno zagrijavanjem rotora u induktivnom režimu rada, kao i ograničenjima zbog stabilnosti pogona u kapacitivnom režimu rada.



Slika 1.37 Pojednostavljeni pogonski dijagram generatora (kvalitativno)

Pogonski dijagram vjetroagregegata u općenitom slučaju prikazan je na sljedećoj slici:

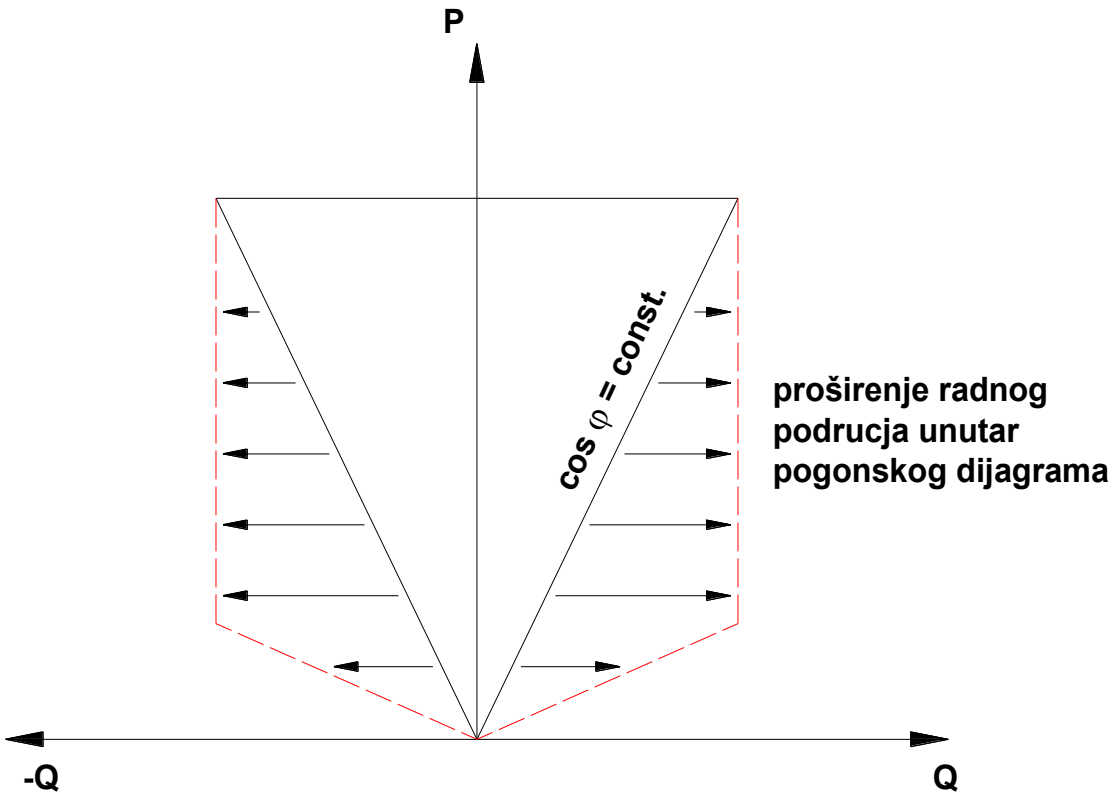


Slika 1.38 Pojednostavljeni pogonski dijagram vjetroagregata izvedenog standardnim asinkronim generatorom (kvalitativno)

Mogućnosti regulacije napona i jalove snage iznimno su bitne za održavanje stabilnosti napona u mreži. Naročito se to odnosi na kritične situacije u sustavu odnosno na pojavu kvarova u sustavu kad je iznimno bitno da agregati ostanu priključeni na sustav te proizvode potrebnu djelatnu snagu za regulaciju djelatne snage odnosno sprečavanje propada frekvencije.
Osim regulacije frekvencije i djelatne snage, iznimno je bitna sposobnost regulacije napona i jalove snage u istim takvim kritičnim režimima rada.

Iz prethodnog dijagrama je vidljivo da trokutasta karakteristika dijagrama snage opisuje konstantni omjer djelatne i jalove snage odnosno konstantni faktor snage. Na taj način ista trokutasta karakteristika opisuje područje širine maksimalnog raspona od cos φ = -0.9 do 0.9. Također, pri manjoj proizvodnji djelatne snage, odnosno pri manjim brzinama vjetra, postoji smanjena mogućnost proizvodnje jalove snage. To stvara opasnosti prilikom pojave manjih brzina vjetra ukoliko se u sustavu pojavljuju sniženi naponi uslijed kojih bi moglo doći do problema te u ekstremnim slučajevima i do sloma napona.

Da bi se spriječili problemi, do kojih može doći uslijed smanjene mogućnosti proizvodnje jalove snage pri manjim brzinama vjetra, moderni vjetroagregati izrađuju se sa dijagramom snage kao na sljedećoj slici:



Slika 1.39 Pogonski dijagram vjetroagregata s proširenim mogućnostima proizvodnje jalove snage pri manjim brzinama vjetra – kvalitativno (izvor General Electric)

Mogućnosti proizvodnje jalove snage pri manjim iznosima djelatne snage ograničene su zbog smanjenih mogućnosti hlađenja samog generatora unutar vjetroagregata.
Osim navedenih mogućnosti, moderni vjetroagregati posjeduju i mogućnosti proizvodnje jalove snage čak i u slučajevima kad nema uopće proizvodnje djelatne snage odnosno kad uopće nema vjetra. To se postiže instaliranjem dodatnih uređaja energetske elektronike na stezaljke generatora u kombinaciji s kondenzatorskim baterijama i paralelnim prigušnicama. Ovakva proizvodnja jalove snage u slučajevima bez proizvodnje djelatne snage naročito je pogodna u slabim dijelovima mreže i sustavima s velikom penetracijom energije vjetra. Ovakva regulacija napona i jalove snage nastavlja se čak i u slučajevima kad se vjetroelektrana isključi s mreže uslijed kvara.

Za velike vjetroelektrane potrebno je razmotriti dodatne centralizirane hijerarhijske sustave regulacije napona i jalove snage. Svaki pojedini vjetroagregat posjeduje brza regulacijska svojstva u slučaju bilo kakvih naponskih događaja u blizini vjetroagregata.

Hijerarhijskim centraliziranim sustavom regulacije napona i jalove snage omogućava se regulacija napona na mjestu priključka vjetroelektrane i to sljedećim koracima:

- mjerenje i nadzor pojedinačnih vjetroagregata u smislu Q-U regulacije,
- koordinacija ostale opreme za Q-U regulaciju u priključnoj transformatorskoj stanici (npr. kondenzatorske baterije, prigušnice, regulacijski transformatori...),
- sučelja sa centralnim SCADA sustavom glavnog dispečerskog centra,
- mogućnost prihvaćanja komandi iz glavnog dispečerskog centra (npr. postavljanje referentnih vrijednosti napona čvorišta u mjestu priključka i slično).

Zahtjevi za regulacijom napona i jalove snage na mjestu priključka prvenstveno se rješavaju mogućnostima proizvodnje jalove snage od strane vjetroagregata. Iste mogućnosti dodatno su proširene paralelno spojenim uređajima za regulaciju odnosno kondenzatorskim baterijama i prigušnicama. Središnji sustav u sklopu većih vjetroelektrana optimira odzive pojedinih uređaja i na taj način obavlja potrebnu Q-U regulaciju te eliminira potrebu instaliranja dodatnih uređaja za regulaciju unutar mreže u blizini iste vjetroelektrane, ili, u ekstremnim slučajevima, eliminira potrebu izgradnje dodatnih prijenosnih dalekovoda i transformatorskih stanica.

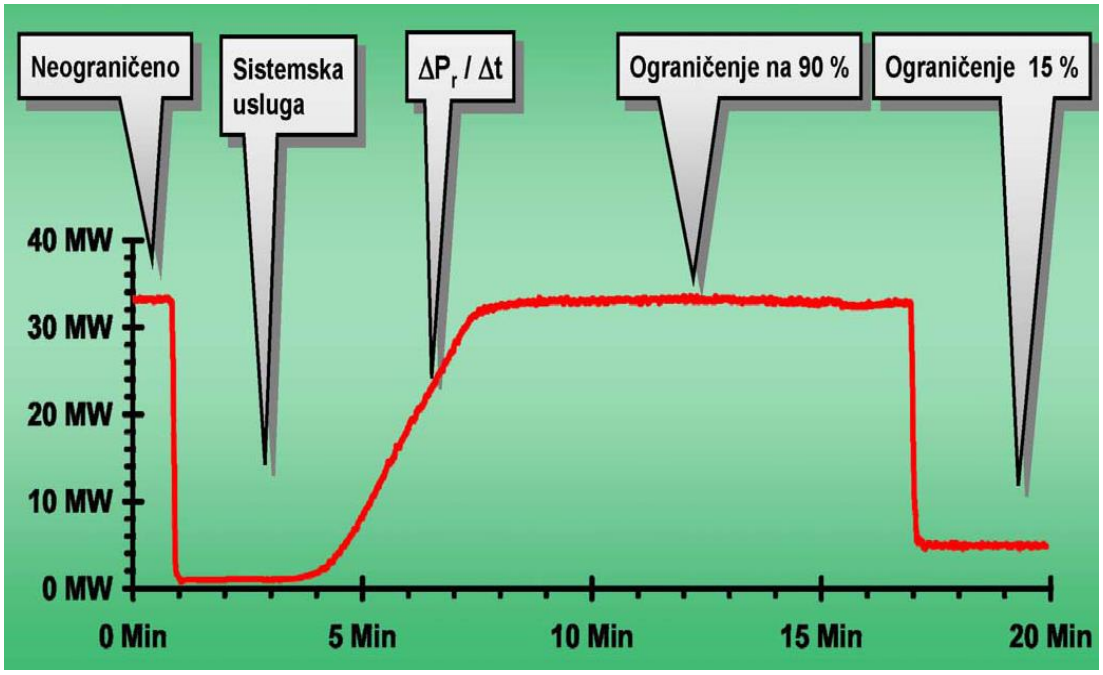
1.5.5 Mogućnost pružanja sistemskih usluga vjetroelektrana

Među najbitnije karakteristike modernih vjetroagregata spadaju mogućnosti regulacije pogona. Naime, vrlo često se vjetroelektrane nalaze na području gdje postoje problemi u zagušenjima u mreži pa je potrebno regulirati pogon same vjetroelektrane ovisno o stanju u mreži. Zbog većih tokova snaga preko zagušenih vodova, evakuacija cjelokupne snage u elektroenergetski sustav neće u nekim slučajevima biti moguća pa će tada biti potrebno ograničiti proizvodnju vjetroelektrane u cjelosti npr. isključivanjem pojedinih vjetroegregata u vjetroelektrani. Veličina ograničenja ovisi o stanju u mreži odnosno o veličini zagušenja.

Također, u slučaju nailaska jače vjetrovne fronte na područje vjetroeletrane ili nekoliko vjetroelektrana, doći će do naglog povećanja snage proizvodnje što bi moglo rezultirati problemima u povećanju frekvencije sustava i slično. Stoga je potrebno ograničiti rast snage proizvodnje (eng. *RU* - ramp-up rate), a koji se može matematički definirati kao derivacija snage proizvodnje u vremenskom intervalu:

$$RU = \frac{\Delta P}{\Delta t} \tag{1.27}$$

Sve navedene karakteristike prikazane su slikovito na sljedećem dijagramskom prikazu proizvodnje vjetroelektrane.



Slika 1.40 Prikaz karakteristika vjetroagregata za pružanje sistemskih usluga te upravljanje zagušenjima u mreži

Iz prethodno opisanih karakteristika slijedi i mogućnost pružanja sistemske usluge regulacije frekvencije i djelatne snage od strane vjetroelektrane. Istu uslugu moguće je pružiti ukoliko postoji dovoljan vjetar za proizvodnju nazivne snage, ali vjetroelektrana nije priključena na mrežu ili se vjetroagregati vrte u praznom hodu. Na taj način, brzo je dostupna određena rezerva snage proizvodnje koja može poslužiti za pružanje navedene sistemske usluge. Naravno, da bi se ovo omogućilo potrebno je da Operator prijenosnog sustava odredi ovakvu shemu pružanja sistemske usluge.
Osim toga potrebno je vrlo pažnjivo definirati i troškove pružanja usluge odnosno oportunitetne troškove zbog nemogućnosti proizvodnje djelatne snage po povlaštenoj feed-in tarifi.

Također, na slici Slika 1.40 prikazano je kretanje snage u vremenu tijekom svih prethodno opisanih sistuacija. Budući da je energija definirana kao integral snage u vremenu, dobije se da je energija opisana kao površina ispod ove krivulje na grafu. Vidljivo je da u određenim vremenskim periodima proizvodnja energija biva uskraćena zbog pružanja sistemske usluge te ograničenja proizvodnje na 90% i 15% snage uslijed zagušenja u mreži. Budući da se energija obračunava po feed-in tarifi, iz ovog slijede izravni oportunitetni troškovi za koje je potrebno definirati sustav nadoknade troškova.

Povećane mogućnosti regulacije pogona modernih vjetroagregata daju i povećanje mogućnosti korištenja istih za pružanje sistemskih usluga, kao i za ograničavanje pogona u slučaju zagušenja u mreži i ostalih kritičnih slučajeva.
Iz svega navedenog slijedi da moderni vjetroagregati rješenjima u projektu uvelike pridonose povećanju mogućnosti instalirane snage vjetroelektrana koju je moguće priključiti na mrežu. Pojedine karakteristike tih strojeva omogućavaju da vjetroelektrane pružaju i ostale sistemske usluge čime će se postići i veća integracija energije vjetra u elektroenergetski sustav u cjelini.

2. NAPREDNE SINKRONIZIRANE MJERNE VELIČINE

2.1. OSNOVNA INFRASTRUKTURA ZA KORIŠTENJE NAPREDNIH SINKRONIZIRANIH MJERENJA

2.1.1 Telekomunikacijska infrastruktura

Jedna od osnovnih pretpostavki rada je visoka dostupnost i raspoloživost naprednih i sinkroniziranih mjerenja. Zbog visokih zahtjeva za raspoloživošću i pouzdanošću sustava vođenja EES-a, važno je da i telekomunikacijska mreža između objekata unutar EES-a, kao jedan dio sustava daljinskog vođenja, također udovoljava takvim visokim zahtjevima [L 46].

Povećanjem količine podataka koji će se prenositi telekomunikacijskom mrežom elektroprivrede u budućnosti, povećat će se i zahtjevi za samu telekomunikacijsku infrastrukturu.

Većina elektroprivrednih poduzeća tradicionalno ima riješenu telekomunikacijsku infrastrukturu tzv. TDM (eng. Time Division Multiplexing) mrežom odnosno pomoću prijenosa sinkrone digitalne hijerarhije iliti SDH protokolom. Iako je bila pouzdana, SDH tehnologija je blizu kraju životnog vijeka, odnosno možemo je smatrati zastarjelom. Operativni troškovi su se povećavali, i elektroprivrede se moraju osloniti na samo nekoliko zaposlenika sa specijaliziranim skupovima vještina kako bi zadržali mrežu.

Zbog specijalizirane prirode i ograničene fleksibilnosti TDM/SDH mreža, elektroprivredne kompanije žele se pripremiti za budućnost i prebaciti svoju korisničku mrežu u paketni način rada odnosno u IP komunikaciju. Nadalje, nove mrežne aplikacije zahtijevaju nove komunikacijske tokove i također konvergencije operacijskih tehnologija (OT).

Osnovna arhitektura sustava definira se kao skup čvorova koji se grupiraju oko okosnice telekom mreže, a koji šalju ključne podatke i informacije glavnom poslužitelju (serveru) ili nekoliko njih. Ova arhitektura zahtijeva snažnu telekomunikacijsku podršku. Napredak tehnologije informacijske i telekomunikacijske tehnologije (ICT) donosi dodatno povećanje korištenja tehnologija naprednih elektroenergetskih mreža. Brzina prijenosa podataka i širina pojasa (eng. Bandwith) ključni su za implementaciju arhitekture koje obuhvaćaju korištenje mjerenja s visokim vrijednostima uzorkovanja kao što su mjerenja sinkroniziranih veličina.

IP multicast [L 76] jedna je od takvih tehnika za komunikaciju u stvarnom vremenu preko IP infrastrukture u mreži. U potpunosti iskorištavajući IP mrežu za prijenos PMU poruka, operatori poboljšavaju vidljivost i kontrolu sustava, smanjuju nepotrebne količine opreme (npr. Koncentratori podataka itd.) i smanjuju troškove operacija i održavanja povezanih s upravljanjem PMU mrežama. Nadalje, MPLS (Multiprotocol Label Switching) je vrsta tehnike prijenosa podataka visokih performansi koja usmjerava podatke s jednog mrežnog čvora na drugi na temelju oznaka kratkog puta umjesto

dugih mrežnih adresa, izbjegavajući složene rezultate u tablici usmjeravanja (eng. Routing table). U osnovi, sve napredne mrežne usluge i protokoli (WAMS, Smart Metering i IEC 61850 itd.) mogu se savršeno prevesti preko IP/MPLS mreže na najvažnijim platformama proizvođača telekomunikacijskih mreža. U većini slučajeva, u prvom koraku za implementaciju mreže IP/MPLS, te se značajke ne koriste komunalnim uslugama, a navedene usluge se čuvaju u postojećoj mreži kao naslijeđene (eng. Legacy). Zapravo, trenutno se SCADA vrlo često temelji na prootokolu IEC 104, a trenutačno ne postoji međusobno povezivanje 61850 tokova izvan trafostanica.

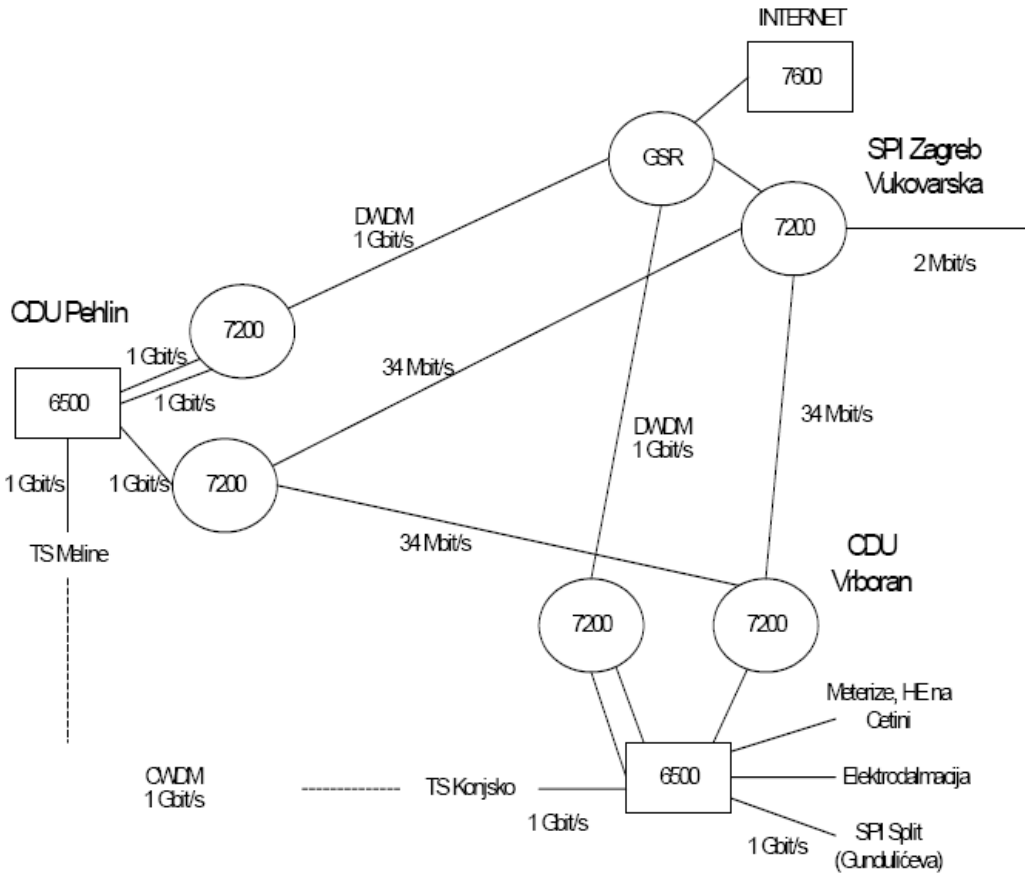
Sukladno tome, elektroprivredne kompanije najčešće odlučuju izgraditi jedan pouzdan IP/Multiprotocol Label Switching (MPLS) sustav kako bi se na kraju sigurno povezali svi sustavi i mrežni uređaji. Nova mreža potrebna je za podršku raznim mrežnim aplikacijama, uključujući i vrlo kritične zaštitne sustave za visokonaponsku mrežu (sustavi distantne i diferencijalne zaštite) koji zahtijevaju da komunikacijska mreža podržava ekstremno nisku latenciju (<10 ms), determinističko ponašanje, kao i vrlo visoku dostupnost.

HEP i HOPS dijele vlasništvo nad telekomunikacijskom mrežom EES-a RH. Predmetna telekomunikacijska mreža projektirana je i građena s visokom pouzdanošću i raspoloživošću.

Sustav telekomunikacija iznimno je bitan za prikupljanje i slanje informacija i naredbi. Telekomunikacijska mreža HEP-a može se radi lakšeg pregleda podijeliti u 4 zone vezane uz centre upravljanja. Centri Zagreb i Rijeka povezani su 1 Gbit DWDM optičkom vezom te iznajmljenom 34 Mbit vezom koja služi kao pomoćna linija u slučaju zatajenja glavne veze. Ovakva konfiguracija s jednom glavnom DWDM 1 Gbit-nom vezom i jednom backup 34 Mbit-nom vezom instalirana je i između centara Zagreb i Split. Centri Split i Rijeka povezani su CWDM 1 Gbit-nom vezom i backup vezom kapaciteta 34 Mbit/s. Centar Osijek povezan je sa centrom Zagreb linijom kapaciteta 1 Gbit/s, ali u tom području ne nalaze vjetroelektrane niti relevantni centri upravljanja za područje rada.

Veza između centara Rijeka i Split realizirana je pomoću CWDM prstena koji prelazi preko 110 kV transformatorskih stanica.

Kompletiranjem telekomunikacijske mreže kapaciteta 1 Gbit/s dobivena je izuzetno snažna i brza mreža koja će omogućavati potreban protok informacija vezanih između ostalog i za vođenje sustava, ali i za brz protok i prikupljanje podataka, koji se ponajprije odnose na proizvodnju vjetroelektrana, ali i mogućnost primjene tehnologija sinkroniziranih mjerenja (eng. SMT - Synchronized Measurements Technology). Time će se pospješiti prikupljanje bitnih informacija kao i slanje potrebnih naredbi.



Slika 2.1 Telekomunikacijski sustav HEP-a i HOPS-a – prikaz središnjeg, zapadnog i južnog dijela sustava

Telekomunikacijski podsustav jednog elektroenergetskog sustava iznimno je bitan za povećanje integracije vjetroelektrana u isti sustav. Naročito se to odnosi na uklapanje najbitnijih transformatorskih stanica i regulacijskih hidroelektrana u isti sustav čime se dobije brza akvizicija mjernih podataka te jednako tako i brza estimacija stanja i odziv potrebnih regulacijskih mjera.
Ipak, kao nužan uvjet je izgradnja fizičke infrastrukture do objekata, bilo optike ili radio veza, jer kakvo god rješenje sustava daljinskog vo!enja bude implementirano u budućnosti, ono će se oslanjati na telekomunikacijsku mrežu koja traženu brzinu, pouzdanost i raspoloživost može postići samo preko optičkih ili digitalnih radio veza.

Budući da je za pogon vjetroelektrana potrebno imati veliku mogućnost brze regulacije sustava, u slučaju izgradnje većih vjetroelektrana, potrebno je iste priključiti brzim optičkim vezama na telekomunikacijsku infrastrukturu operatora sustava. To će se najčešće postići ugradnjom zaštitne užadi s ugrađenim optičkim kabelom tj. OPGW užadi u priključnim visokonaponskim dalekovodima.

2.1.2 Napredna mjerna infrastruktura

Napredna mjerna infrastruktura (eng. AMI – Advanced Metering Infrastructure), i napredni mjerni sustavi sačinjeni su od najsuvremenijeg elektroničkog/digitalnog hardvera i softvera koji kombiniraju intervalna mjerenja podataka s kontinuirano dostupnim daljinskim komunikacijama.

Ti sustavi omogućuju mjerenje detaljnih, vremenski sinkroniziranih informacija i čestih prikupljanja i prosljeđivanja takvih informacija različitim stranama. AMI ili Napredna mjerna infrastruktura obično se odnosi na cijeli sustav mjerenja i prikupljanja koji uključuje mjerila na strani kupca ili proizvođača, telekomunikacijske mreže između korisnika i operatora mreže, te prijem odnosno pohranu podataka za sustave upravljanja koji čine informacije dostupne operatoru i/ili davatelju usluga.

Dakle, obično je osnovna arhitektura napravljena kao mreža podatkovnih čvorova, izgrađena od čvorova za stvaranje podataka od nekoliko do nekoliko stotina ili čak tisuća. U svakom čvoru mreže (poput trafostanice, klastera vjetroelektrane, potrošača, virtualne elektrane itd.) postoji velika količina podataka koji se mogu pohraniti i obrađivati pomoću uređaja za napredno mjerenje.

Praktično, nužna je nova paradigma u kojoj će razmjena podataka i informacija između korisnika mreže biti od velike važnosti. Nova paradigma temelji se na davanju podataka korisnicima mreže umjesto skrivanja istih podataka. Implementacija takve napredne mjerne infrastrukture (AMI) je temeljni rani korak za modernizaciju elektroenergetske mreže.
.
AMI nije jedna tehnologija, već integracija mnogih tehnologija koje pružaju naprednu vezu između potrošača, proizvođača i operatora sustava. AMI korisnicima daje informacije potrebne za njih u cilju donošenja optimalne odluke, sposobnost izvršavanja tih odluka i raznolikosti od izbora koji vode do značajnih koristi koje trenutno ne uživaju.

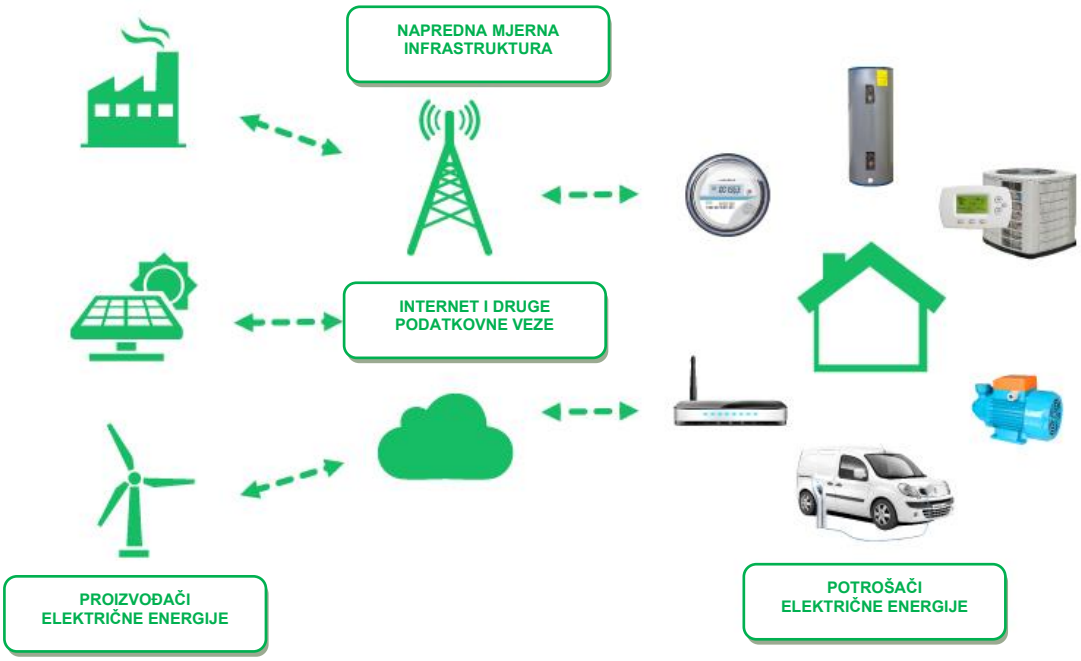
Integracijom višestrukih tehnologija (kao što je napredno mjerenje, integrirana komunikacija, upravljanje podacima, aplikacije i standardizirana sučelja softvera) s postojećim korisničkim operativnim procesima i procesima upravljanja imovinom, AMI pruža bitnu vezu između mreže, potrošača i njihovih tereta, proizvođača i njihove proizvodnje te stvaranja i skladištenja podataka i informacija. Takva povezanost temeljni je zahtjev Moderne elektroenergetske mreže.

Pristup implementaciji sustava naprednih mreža ovisit će o početnoj točki programa, geografiji i topologiji sustava, regulatornoj situaciji i dugoročnoj viziji. Za one elektroprivrede koje već posjeduju nekakav oblik modernijeg mjernog sustava, pitanje će biti hoće li oni moći izgrađivati naprednu mjernu infrastrukturu na tom sustavu ili će morati početi iznova. Ako sustav uključuje dvosmjernu komunikacijsku infrastrukturu, trebalo bi biti moguće nadograditi mjerne komponente za niz AMI aplikacija. Sve opcije treba usporediti s troškovima i koristima instaliranja novog sustava.

Brzina, pouzdanost i sigurnost komunikacijske infrastrukture će odrediti raspon aplikacija koje može podržati. Za elektroprivrede s rasprostranjenim i raznovrsnim teritorijama, možda će biti potrebno više komunikacijskih rješenja. Pilot programi koji istražuju izvedbu različitih rješenja mogu biti korisna rješenja kao prva faza implementacije AMI sustava.

Cjelokupna modernizacija mreže i komunikacijski sustav će se morati prilagoditi za očekivane buduće potrebe i imati fleksibilnost za rukovanje.

Uvođenje AMI sustava je stoga strateška inicijativa koju moraju podržati i regulatori koji pri tom moraju razmotriti mogućnost da tradicionalna ekonomska analiza ne može obuhvatiti cjelokupnu vrijednost implementacije AMI sustava.



Slika 2.2 Osnovna konfiguracija napredne mjerne infrastrukture (AMI)

2.1.3 Pohranjivanje i obrada podataka

Pohranjivanje podataka (eng. Data Storage) izuzetno je bitan dio sustava naprednih elektroenergetskih mreža. Elektroenergetske mreže 21. stoljeća ubrzano se razvijaju u više dimenzija, uključujući razvoj energetskih informacija i operativnih platformi, kao odgovor na usvajanje širokog spektra senzorike, mjernih uređaja, prodiranja i integracije značajnih distribuiranih energetskih resursa (uključujući obnovljive izvore energije, decentraliziranu proizvodnju i upravljanje opterećenjem). Nadalje, omogućavanje sudjelovanja na tržištu od strane milijuna korisnika taj efekt čini još većim.

Ovaj prijelaz s vertikalno orijentiranog lanca vrijednosti na hibridnu, horizontalniju industrijsku strukturu stvara potrebu za konvergencijom podataka, kontrola i transakcija u jedinstvenu elektroenergetsku platformu koja omogućuje pouzdana i sigurna poslovanja na tržištu i mreži.

U ovom novom kontekstu podaci obuhvaćaju širok raspon tipova koji omogućuju upotrebu električnih sustava za planiranje, operacije, upravljanje imovinom i aplikacije tržišta električne energije te nove usluge za krajnje korisnike i druge sudionike na tržištu. U kombinaciji s eksponencijalnim rastom volumena i raznolikosti izvora podataka i raznovrsnim korištenjem i povezanim zahtjevima latencije tj. kašnjenja podataka (eng. Latency), razvoj učinkovite strategije pohrane i upravljanja podacima predstavlja vrlo veliki izazov.

Iako ovaj rast ima izravne implikacije na računalnu aplikaciju, analizu i ulaganja u računalne podatkovne infrastrukture, važno je uzeti u obzir sve korake upravljanja podacima: prikupljati, pohranjivati, organizirati, analizirati i dijeliti. Također je važno napomenuti ulogu koju komunikacijska infrastruktura igra u tom procesu, jer je to često ograničavajući čimbenik u mnogim mrežnim sustavima i postojećim operativnim i poslovnim mrežama.

Za upravljanje velikim količinama podataka nužno je primijeniti tehnološka rješenja prikladna klasi podataka i namjeravanim poslovnim procesima kako bi se postigli očekivani rezultati. Novi izvori podataka i poravnavanje poslovnih procesa u uslužnom programu stvorili su zbunjenost o pravim tehničkim rješenjima. U mnogim slučajevima, nije riječ o jednom tehničkom pristupu u odnosu na drugi, već o tome koja je najbolja kombinacija za poslovnu potrebu.

Količina podataka prikupljenih u ovim projektima i na ovoj novoj vrsti infrastrukture će vjerojatno rapidno porasti, tako da su operatori uvijek zabrinuti za skalabilnost IT sustava u cilju da ti sustavi ostanu visoko pouzdani. Također je potrebno poštivati i industrijske regulatorne zahtjeve.

Gotovo sve na naprednoj elektroenergetskoj mreži može generirati podatke. Ali to nije samo količina podataka koja se generira nego je također frekvencija podataka koji se generiraju, i to u različitim vrstama podataka i s

različitom mogućnosti potvrđivanja. Ove stvari predstavljaju brojne izazove u prikupljanju, prijenosu, pohrani i osiguravanju podataka. Jedni od uređaja koji će generirati najbrojnije količine podataka za pohranu jesu

- Napredna mjerna infrastruktura (AMI)
  (stvarajući prosječno 50 bytes podataka po očitanju)
- Sinkrofazorske veličine (PMU jedinice)
  Generiraju između 50 i 200 bajtova po čitanju – 50 puta u sekundi.
- Senzorske veličine
- Postrojenja za skladištenje električne energije

Ovi uređaji za pohranu podataka trebaju biti osigurani protiv mnogih različitih oblika napada, uključujući i fizičke krađe, ali i protiv napada hakera. S obzirom da se radi o infrastrukturi bitnoj u pogledu sigurnosti i perspektive nacionalne sigurnosti, potrebno je usvojiti čitave nove modele sigurnosti podataka za napredne elektroenergetske mreže.

Zabrinutost, koja se odnosi na privatnost i sigurnost podataka, dovela je do više standarda i propisa u tom području.

Trenutno, mnoge elektroprivrede i operatori održavaju sve svoje podatke, ali to neće u budućnosti biti praktično sa svim podacima koje generira napredna elektroenergetska mreža. Različiti aplikacijski programi trebaju pogledati sve različite izvore podataka i procijeniti koliko dugo i koliko tih podataka treba pohraniti. Ono što je vrlo važno u tim razmatranjima nije samo količina podataka, nego i koliko vremena je taj podatak koristan. Nema smisla pohranjivati podatke samo kako bi zadržali podatke; treba ih pohraniti u formatu tako da se podaci mogu koristiti za različite programe.

Povijesne, neiskoristive podatke treba ukloniti iz skladišta podataka bilo da je to kroz particioniranje baze podataka, arhiviranje podataka ili druge metode. Upravljanje podacima tijekom svog životnog ciklusa je presudno.

Neke od najbitnijih funkcionalnosti pohrane ovakve vrste podataka jesu:

- Sigurnost podataka,
- Oporavak izgubljenih podataka,
- Komprimiranje podataka,
- Vizualizacija i dohvat podataka.

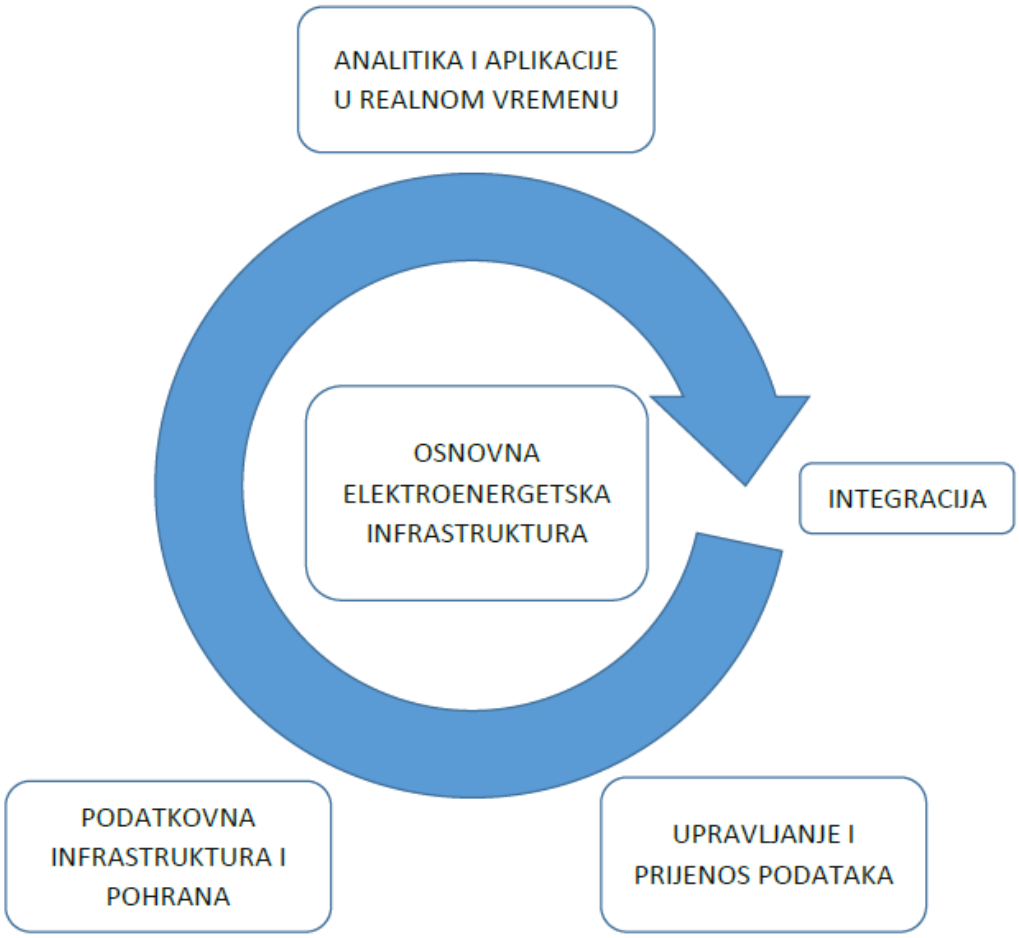
2.1.4 Integracija sustava naprednih mreža

Napredne elektroenergetske mreže (eng. Smart Grid) u posljednjih nekoliko godina imaju niz primjena i implementacija u elektroenergtskim sustavima u Europi i Svijetu. Iako postoji niz projekata koji se definiraju kao smart grid projekti, izuzetno je teško specificirati točnu definiciju tako širokog pojma koji obuhvaća čitav niz primjena ICT tehnologije u elektroenergetskim sustavima.

Smart Grid je sveobuhvatni skup integriranih rješenja informacijske i komunikacijske (ICT) tehnologije adaptivno i modularno implementiranih u postojeću ili rekonstruiranu infrastrukturu elektroenergetskog sustava u cilju povećanja efikasnosti vođenja sustava, smanjenja operativnih troškova, smanjenja kapitalnih investicija i povećanja integracije obnovljivih izvora energije. Smart grid implementacije obuhvaćaju čitav niz međusobno integriranih projekata pri čemu je od iznimne važnosti postojanje ili nadogradnja iznimno snažne telekomunikacijske podrške te dodatnih IT sučelja za obradu velike količine podataka (Big Data) pohranjenih u Data Centrima.

Postojeća elektroenergetska infrastruktura u Europi i Svijetu postupno izlazi iz svog predviđenog 40-godišnjeg vijeka trajanja. Također, pojavljuju se potrebe integracije velike količine intermitirajućih obnovljivih izvora energije u mrežu, a elektroenergetske kompanije kontinuirano prolaze proces daljnje deregulacije i izlaska na otvoreno tržište. Sukladno tome potrebne su iznimno velike kapitalne investicije u cilju rekonstrukcije iste mreže. Većina zemalja poduzima brojne korake u dodatnoj implementaciji smart grid rješenja u cilju optimizacije rekonstrukcije i nadogradnje predmetne mreže.

Rekonstrukcijom i/ili nadogradnjom osnovne infrastrukture elektroenergetskog sustava moguće je izraditi integrirana rješenja naprednih mreža koja će se adaptivno i modularno prilagoditi postojećoj infrastrukturi i budućim rješenjima.



Slika 2.3 Shematski prikaz integracije sustava naprednih mreža

Napredak ICT tehnologije u posljednjih nekoliko godina omogućio je dodatnu primjenu brojnih ICT rješenja koja je moguće implementirati u elektroenergetski sustav, a koja se sastoje od integracije nekoliko bitnih podskupina kao što su:

- napredna mjerna infrastruktura (eng. AMI – Advanced Metering Infrastructure)
- mjerenja sinkrofazorskih veličina (eng. PMU – Phasor Measurement Unit)
- napredne zaštitne funkcije (SPS – Special Protection Schemes)
- brze telekomunikacije veze (optički kabeli, CWDM i DWDM tehnologija)
- IT rješenja u cloud okruženju (integracijske platforme)

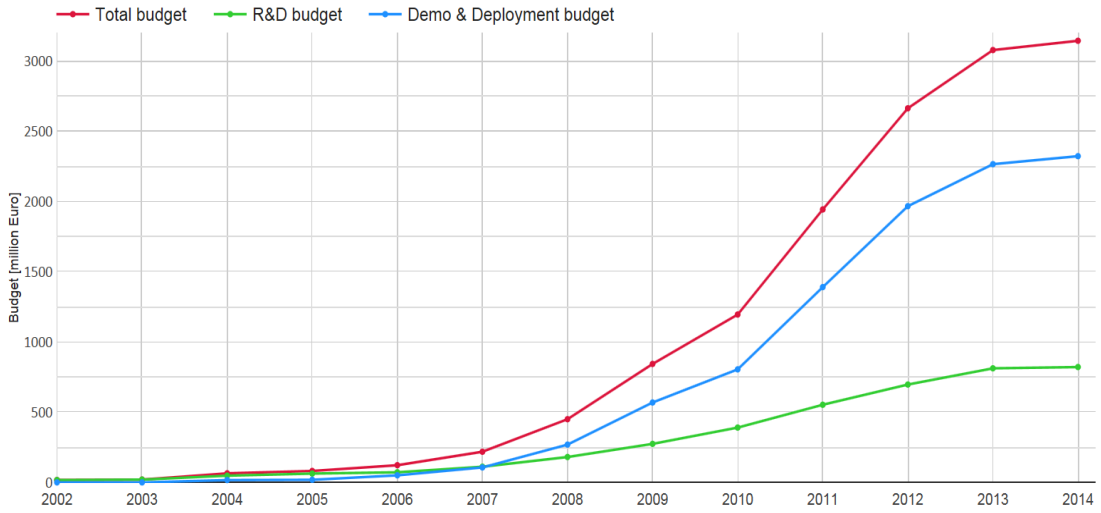
Međusobna integracija i optimizacija navedenih rješenja te adaptivna i modularna implementacija u postojeću ili rekonstruiranu infrastrukturu

elektroenergetskog sustava predstavlja najveći izazov prilikom planiranja modernog elektroenergetskog sustava.

Također, u osnovnoj elektroenergetskoj infrastrukturi moguće je objediniti i niz dodatnih ICT rješenja, a koja se prilagođavaju postojećoj infrastrukturi i nadopunjavaju njezinu osnovnu funkcionalnost, u cilju efikasnijeg korištenja postojeće infrastrukture te optimiranja gradnje nove infrastrukture u budućnosti.

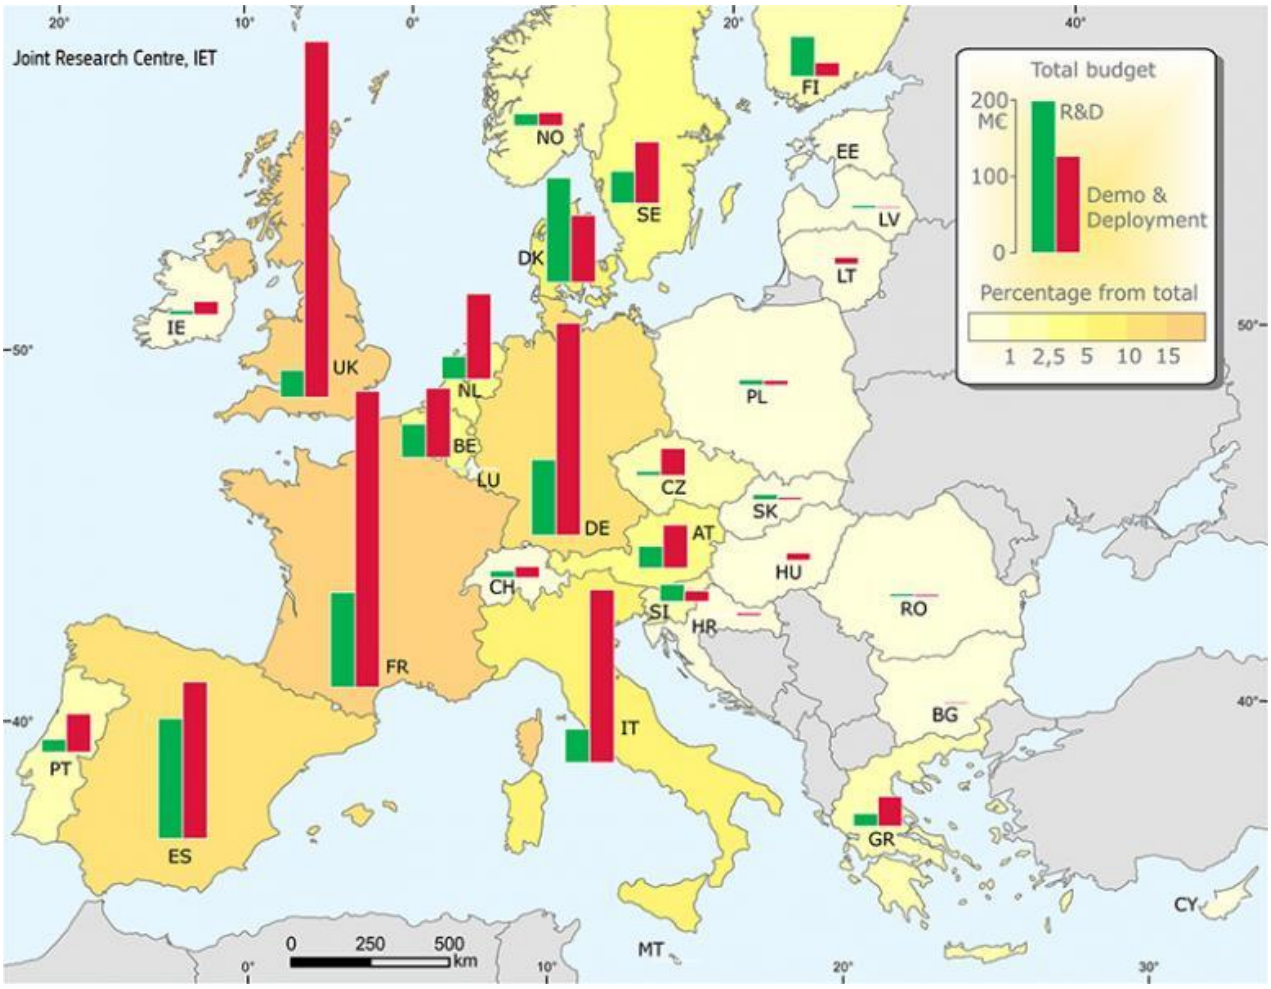
Posljednjih nekoliko godina smart grid rješenja prelaze iz istraživačke u implementacijsku fazu. Zbog svog multiplikativnog učinka na efikasnost korištenja postojeće infrastrukture te smanjenje investicijskih i pogonskih troškova u budućnosti, očekuje se snažan porast ulaganja u takve tehnologije.

Na sljedećoj slici dat je pregled dosadašnjih ulaganja u Smart grid rješenja u Europi pri čemu je vidljiv trend rasta u posljednjih 10ak godina.



Slika 2.4 Grafički prikaz dosadašnjih ulaganja u sustave naprednih mreža - izvor: Joint Research Center (ses.jrc.ec.europa.eu)

Na sljedećoj slici dat je pregled dosadašnjih ulaganja u Smart grid rješenja po pojedinim zemljama u Europi pri čemu je vidljiva slabija zastupljenost nekih Skandinavskih i istočnoeuropskih zemalja.



Slika 2.5 Geografski prikaz dosadašnjih ulaganja u sustave naprednih mreža - izvor: Joint Research Center (ses.jrc.ec.europa.eu)

Sa svojih 135 projekata, Njemačka ima najveći broj inicijativa, a Francuska i Velika Britanija su uložili najviše sredstava, po 500 milijuna € svaka. U obje zemlje oko 5 milijuna eura u prosjeku je budžet u projektu. Danska ima najveće investicije u napredne mreže po glavi stanovnika i po nacionalnoj potrošnji električne energije. Zatim slijedi Slovenija, koja zajedno sa Češkom, je jedna od vodećih zemalja u okviru novijih zemalja članica u uspostavi strategije za pametne mreže. Međutim, zemlje istočne Europe zastupljene su s manje od 1% ukupnog proračuna.

EU-15 organizacija još uvijek zauzima najveći dio investicija u smart grid projektima, a njih 90% podržava neki oblik javnog financiranja.

Oko 200 milijuna pametnih brojila električne energije u Europi (oko 72% kupaca u EU) se očekuje da će se primjenjivati od 2020. godine sa procijenom ulaganja od 35 milijardi €.

Date su neke od procjena svjetskog tržišta u bližoj budućnosti.



Slika 2.6 Grafički prikaz procjene budućeg svjetskog tržišta sustava naprednih mreža - izvor:
Global Smart Grid Technologies and Growth Markets, 2013-2020 report, http://www.greentechmedia.com/research/report/global-smart-grid-technologies-and-growth-markets-2013-2020.

Vidljivo je da je unatrag 5 godina, ukupna godišnja akumulirana stopa rasta (CAGR) reda veličine 8.4%. Sukladno prikazanim podacima, očekuje se stalni porast tržišta smart grid rješenja u Europi i svijetu.

2.2. SINKROFAZORSKE VELIČINE

2.2.1 PMU tehnologija

Tehnologija mjerenja fazora razvijena je u posljednjih 30-ak godina u Europi i Svijetu korištenjem fazorskih mjernih jedinica (eng. PMU – Phasor Measurement Unit). Vremenski sinkronizirane fazorske mjerne veličine (pozitivne, negativne i nulte vrijednosti napona i struja) mjere se u svrhu određivanja stanja mreže. Zbog svoje vremenske sinkroniziranosti nazivaju se i sinkrofazori te su u posljednjih nekoliko godina najvažniji mjerni parametri EES-a. Sinkrofazorske mjerne jedinice mogu biti samostalne ili sastavni dio zaštitnog releja ili nekog drugog uređaja.

Prvu primjenu sinkrofazora proveli su dr. Phadke i dr. Thorp krajem 80-tih godina prošlog stoljeća na Sveučilištu u Virginiji, SAD, koristeći metodu fazora odnosno matematički opis veličina izmjenične struje predstavljene od Steinmetza krajem 19. stoljeća.

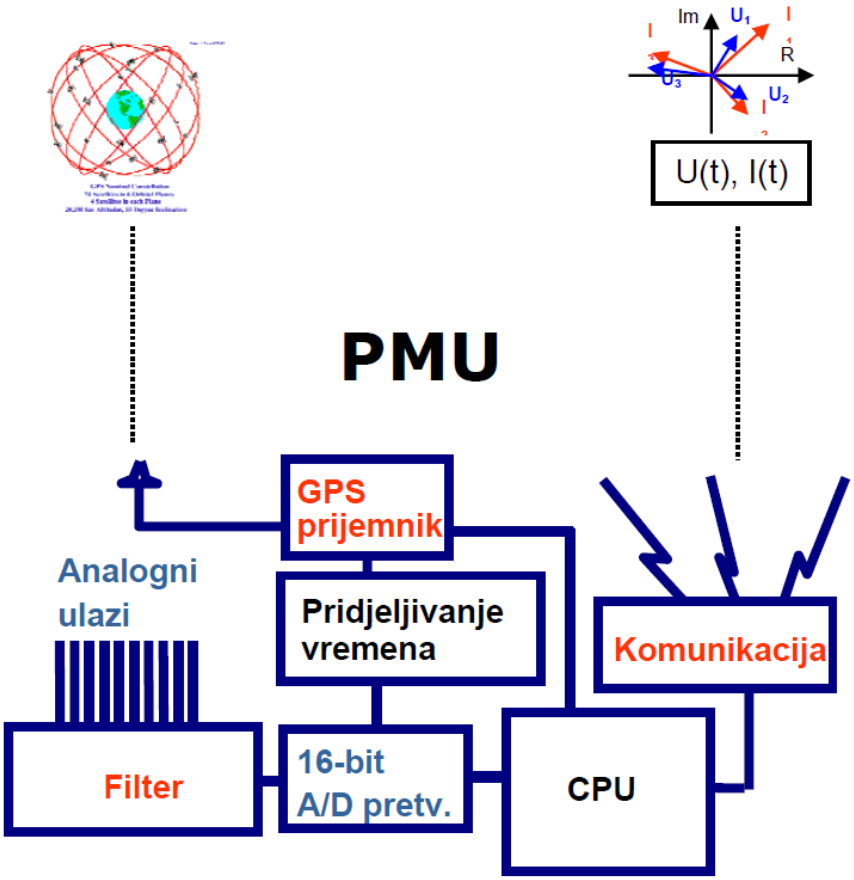
Fazor je kompleksni broj koji sadrži iznos i sinus faznog kuta te se koristi za predstavljanje sinusoidalnih oblika električnih veličina izmjeničnog strujnog kruga. Fazori direktnog sustava koje mjeri PMU prikazujemo kao:

$$F = \frac{\sqrt{2}}{N} \sum_{k=1}^{N} F_k e^{-\frac{j2k\pi}{N}} \qquad (2.1)$$

Ključni podatak je točno vrijeme, u točnosti mikrosekunde, koje se dobije putem GPS sustava (eng. Global Positionig System) bez kojeg sustav ne funkcionira, a ugradnja preciznih satova ili atomskog nije opravdana kod takvih jedinica jer bi bila preskupa. Pridjeljivanje točnog vremena mjernom signalu obavlja se GPS signalom koji je najčešće dobiven preko GPS sklopa koji obuhvaća i samu GPS antenu te prateću opremu.

Uz filtriranje i brzinu uzorkovanja, sinkrone mjerne jedinice pretvaraju analogni signal u digitalni te svakoj dodjeljuju vremensku oznaku. Takav podatak o iznosu napona, struje i frekvencije potom se šalje u centre daljinskog vođenja.

Uzorkovanom iznosu napona i struje pridjeljuje se vrijeme s navedenom točnošću mikro sekunde, što odgovara kutu od 0.018°, uz brzinu uzorkovanja do 50 uzoraka u sekundi [20].



Slika 2.7 Grafički prikaz strukture PMU uređaja

Matematički se može opisati metoda uzorkovanja putem brzog rekurzivnog algoritma diskretne Fourierove transformacije odnosno iznos vektora izmjerenih napona i struja [8].

Razvojem sinkroniziranih mjernih jedinica, izrađena je nova norma, koja je osim u SAD, globalno prihvaćena. Norma nosi oznaku IEEE C.37.118.

2.2.2 Korištenje i funkcionalnosti PMU uređaja

Operatori prijenosnog sustava koriste se sustavom za upravljanje energijom EMS (eng. Energy Management System) u svrhu nadzora i upravljanja u sustavu proizvodnje i prijenosa električne energije. Podaci iz raznih objekata EES-a se putem SCADA sustava prikupljaju i dostavljaju u centar upravljanja.

Tehnološki napredak u korištenju širokomrežnog nadzora postignut je sinkroniziranim mjernim jedinicama te su njegova osnova. Prikupljanje podataka u realnom vremenu zamjenjuje standardne uređaje sekundarnih sustava te omogućuju kvalitetno provođenje sistemskog nadzora, posebno u stresnim uvjetima.

Tradicionalni nadzor, zaštita i vođenje prijenosnog elektroenergetskog sustava (EES) provodi se na osnovu SCADA sustava, te lokalnih mjerenja statičkih vrijednosti - naponi, tokovi snaga, frekvencija. Nakon velikih raspada EES-a u svijetu tijekom 2003. godine razvijaju se i primjenjuju sustavi koji se nazivaju sistemski nadzor, zaštita i vođenje prijenosnog elektroenergetskog sustava, odnosno WAMS sustavi (eng. WAM – Wide Area Monitoring System). WAMS sustavi su zasnovani na ugrađenim PMU uređajima za mjerenje fazora napona i struje u stvarnom vremenu s vremenskom oznakom. PMU uređaji se ovisno o utvrđenoj primjeni (aplikaciji) postavljaju u čvorišta EES-a od posebne važnosti.

WAMS platforma omogućava dinamičku sliku prijenosnog elektroenergetskog sustava u stvarnom vremenu, veću točnost mjerenja, brzu razmjenu podataka i omogućavanje stvaranja algoritama za koordinaciju i brzo djelovanje u slučaju pojave nestabilnosti. Sve navedene prednosti omogućavaju pouzdaniji pogon prijenosnog elektroenergetskog sustava u novostvorenim uvjetima dereguliranog i liberaliziranog tržišta električnom energijom.Predmetne WAMS platforme općenito omogućavaju operatorima EES-a vremenski sinkronizirano mjerenje veličina. Sustav se pojavio na tržištu u zadnjem desetljeću prošlog stoljeća, prvo u SAD-u, te se zajedno s PDC jedinicama primjenjuje diljem svijeta. Postoji više proizvođača koji razvijaju i prodaju PMU i PDC (eng. Phasor Data Concentrator) tehnologiju. Bez obzira na razvoj računalnih aplikacija te velikog broja metoda i algoritama, svrha PMU jedinica je korisno upotrijebiti dobivena mjerenja.

Sinkronizirane mjerne jedinice mjere parametre EES-a (pozitivne, negativne i nulte vrijednosti napona i struja) u svrhu određivanja stanja mreže. Nazivamo ih i sinkrofazori te su najvažniji mjerni parametri EES-a. Sinkronizirane mjerne jedinice mogu biti samostalne ili sastavni dio zaštitnog releja ili nekog drugog uređaja.

Definiranjem parametara i funkcionalnosti PMU uređaja koji će se, prema potrebi, ugrađivati u prijenosni elektroenergetski sustav, generalno se postavljaju sljedeći temeljni zahtjevi:

- PMU uređaj mjeri skup sinkrofazorskih veličina i statusnih podataka koji se prenosi u nekoliko (barem 2) nadređena sustava u 20 ili 40 ms rezoluciji i treba sadržavati sinkrofazore svih faznih i simetričnih komponenti struja i napona,
- uređaj treba prema svim zahtjevima za EE objekta biti izrađen u najmanjoj standardiziranoj formi (visine 1U ili 2U) kako bi njegova ugradnja u postojeće ormare sekundarne opreme bila čim jednostavnija i bez potrebe za rekonfiguracijom postojeće sekundarne opreme,
- uređaj treba omogućavati priključenje kako na mjerne tako i na zaštitne jezgre strujnih transformatora,
- uređaj treba omogućiti povratno djelovanja WAMS sustava na elemente polja, odnosno najbitnije na prekidače u poljima.

Iz postavljenog koncepta izvedeni su osnovni zahtjevi postavljeni prema sklopovlju i algoritmima kako bi se postigla ciljana uloga u sistemskom nadzoru i zaštiti.
Razvojem sinkroniziranih mjernih jedinica, izrađena je nova norma, koja je osim u SAD, globalno prihvaćena. Norma nosi oznaku IEEE C.37.118. Stoga svaki PMU uređaj za slanje podataka treba biti minimalno podržan standardnim protokolom IEEE C37.118 preko TCP ili UDP transportnog protokola (unicast i multicast).

2.2.3 Najbitnije primjene PMU tehnologije

Kako je prethodno opisano, prvu primjenu sinkrofazora proveli su dr. Phadke i dr. Thorp krajem 80-tih godina prošlog stoljeća na Sveučilištu u Virginiji, SAD, koristeći metodu fazora odnosno matematički opis veličina izmjenične struje predstavljene od Steinmetza krajem 19. stoljeća. Nakon toga uslijedio je niz razvoja PDC aplikacija odnosno samih WAMS sustava.

Iako se na razvoju WAMS sustava u svijetu radi već niz godina, ova se tehnologija i dalje smatra novom. Većinom je to posljedica činjenice da u mnogim objektima elektroenergetskih sustava još uvijek ne postoji zadovoljavajuća telekomunikacijska infrastruktura potrebna za implementaciju WAMS sustava. Međutim, kao posljedica revitalizacije objekata u elektroenergetskom sustavu i investicije u izgradnju telekomunikacijske mreže, OPGW mreža itd., trend u svijetu je porast primjene sistemskog nadzora, uz sve veći broj elektroprivreda diljem svijeta koji se odlučuju na primjenu WAMS sustava. Daljnji razvoj se očekuje u smjeru implementacije naprednih funkcija sistemskog upravljanja i sistemske zaštite.

Kao dodatak već postojećim SCADA/EMS sustavima, WAM platforma kombinacijom novih tehnologija pruža dinamičku sliku sustava u realnom vremenu i veću točnost mjerenja. WAMS sustav predstavlja podršku za određivanje optimalnog iskorištenja kapaciteta prijenosne mreže i sprečavanje širenja poremećaja prijenosnom mrežom. Omogućavanjem informacija o granicama stabilnosti i sigurnosti mreže u stvarnom vremenu, WAMS sustav služi kao sustav ranog uzbunjivanja u slučaju mogućih poremećaja u elektroenergetskom sustavu. Najveća prednost ovakvog sistemskog nadzora je njegovo pokrivanje velikog područja (eng. Wide Area Monitoring), tj. cijelog elektroenergetskog sustava, čime operatorima prijenosnog sustava stvara informacije o sistemskim uvjetima na području cijelog elektroenergetskog sustava pokrivenog sistemskim nadzorom, a ne samo na lokalnoj razini, kao što je to do sada većinom bio slučaj.

Ideja o sistemskom nadzoru elektroenergetskog sustava postoji dugi niz godina, međutim praktična primjena, započela je nakon što su ostvareni uvjeti tehnološke dostupnosti uređaja i teorijske podloge o specifičnim poremećajima u EES-u. Razvoj tehnologije ubrzao je izvedbu konkretnih tehničkih rješenja u elektroprivredama za sistemske izvedbe sustava vođenja. Sistemski nadzor zasnovan na PMU tehnologiji predstavlja primjer upotrebe nove tehnologije koja omogućava potpuno drugačiji koncept

vođenja elektroenergetskog sustava, u realnom vremenu, što je dosada bilo neizvedivo. Također je i teorijska postmortem analiza poremećaja dala dobru podlogu za bolje razumijevanje mogućih specifičnih stanja elektroenergetskog sustava.

Temeljem tih postavki omogućeno je ovladavanje i u složenim pogonskim situacijama. U prvom redu tehnološki pomaci dogodili su se razvojem numeričkih sekundarnih sustava, telekomunikacija i ethernet tehnologije. Sva tri čimbenika su se razvijala odvojeno, te su se uspjela objediniti na nizu polja ljudskog djelovanja, a jedno od njih je bilo i elektroenergetika. U posljednjih desetak godina vidljivi su značajni pomaci u kreiranju tehničkih rješenja u elektroenergetskim objektima (transformatorskim stanicama i elektranama) i upravljačkim centrima (nacionalni i regionalni dispečerski centri).

Sekundarni sustavi u objektima se sastoje od sustava upravljanja, sustava relejne zaštite, sistemskih zaštita, sustava mjerenja (obračunska i pogonska mjerenja), nadzornih sustava primarne opreme (monitoring opreme) i lokalnih sustava komunikacija. Svi navedeni sustavi se danas izvode s numeričkim (procesorskim, digitalnim) uređajima, čime se otvara potpuno novi način korištenja i upravljanja elektroenergetskog sustava. Time je omogućeno efikasnije korištenje elektroenergetske opreme, kvalitetnije i brže održavanje, točnije intervencije, brži povrat kapitala i primjena novih tehničkih rješenja. Telekomunikacije u svakodnevnoj primjeni su doživjele revolucionarne promjene, postale su dostupnije, jeftinije, brže, s većim kapacitetima i rasprostranjenije. Razvoj telekomunikacijske opreme omogućilo je u elektroprivrednim poduzećima povezivanje svih objekata i upravljačkih centara s puno većim brzinama od dosadašnjih. Na taj način su pomaknute sve zapreke za razmjenama informacija bilo koje vrste unutar elektroenergetskog sustava. Ethernet tehnologija je od prije poznata, te se počela koristiti i unutar tehničkih rješenja elektroprivrede. Većina novih sekundarnih sustava zasnovana je na korištenju ethernet tehnologije. Nova, međunarodna norma IEC 61850 je zahvaljujući ethernet tehnologiji postala dio standardne prakse projektiranja novih rješenja sekundarnih sustava. Prethodno navedena tri glavna čimbenik, te njihova zajednička koordinacija i implementacija unutar informatičkog sustava EES-a upućuje na nova tehnička rješenja nadzora i vođenja elektroenergetskog sustava. Jedno od takvih rješenja je i sistemski nadzor, odnosno WAMS sustav.

Sistemski nadzor (WAMS sustav) nalazi svoju primjenu u prepoznavanju i sankcioniranju prijelaznih poremećaja. Osobitosti i karakteristike sistemskog nadzora omogućavaju u prvom redu uvid pogonskog stanja u EES-u u realnom vremenu. Pri tome se pojam realnog vremena označava kao kašnjenje prikaza stanja operateru od nekoliko desetaka milisekundi, do najviše 200 ms. Generalno, svi prikazi vremenske rezolucije do 1 s mogu se smatrati prikazima u stvarnom vremenu (real time).

2.2.4 Digitalne trafostanice

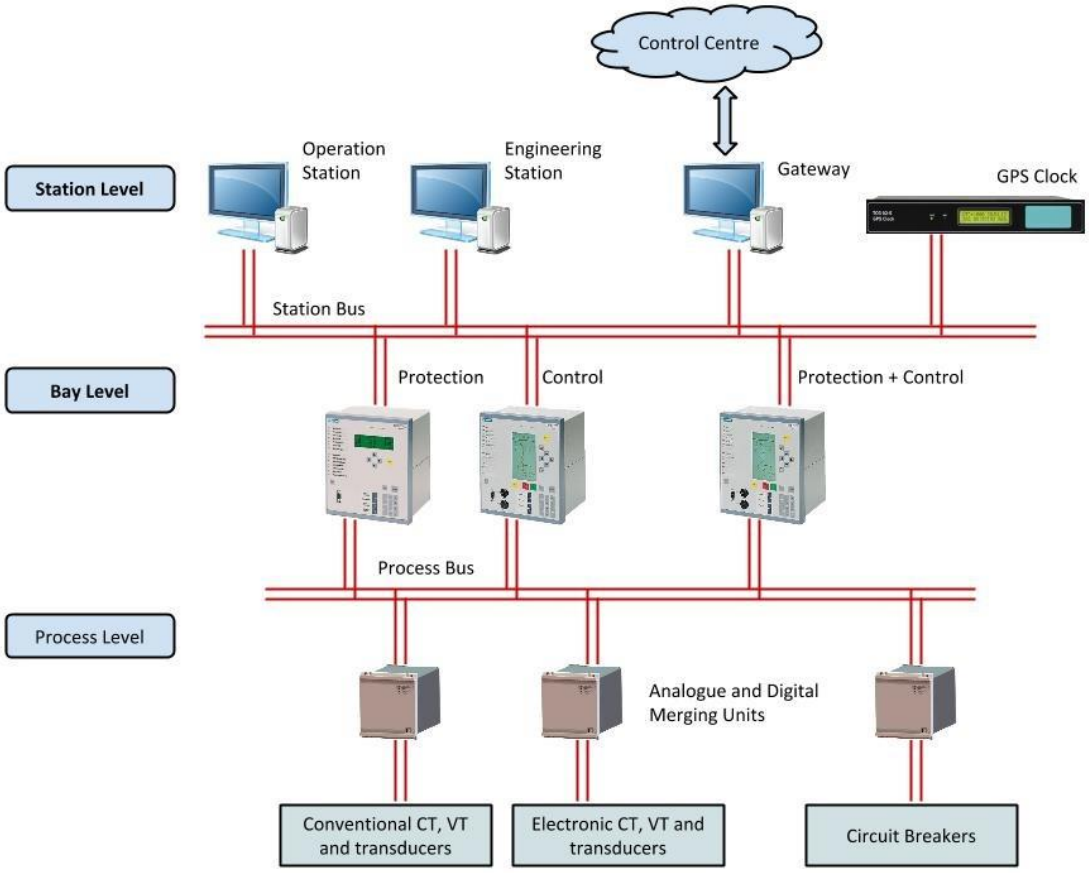
Digitalne tehnologije donijele su mnoge prednosti u području prijenosne elektroenergetske mreže i posebno u trafostanicama. Transformatorske stanice su općenito kritična sprega između prijenosa, proizvodnje i distribucije električne energije. Ova sprega mora biti robusna i pouzdana.

Sustavi za proizvodnju energije, prijenos i distribuciju posljednjih nekoliko godina prolaze kroz radikalnu transformaciju. Tradicionalni model u kojemu se električna energija generira i distribuira na središnjoj razini trenutno je na zalazu i u ovom trenutku se otvara put fleksibilnim sustavima u kojima su instalirani brojni obnovljivi izvori energije, decentralizirani generatori, prosumeri tj. protrošači kao i sustavi za skladištenje električne energije.

Budući da su izvori električne energije sve više distribuirani, te kad se radi o obnovljivim izvorima izuzetno stohastičkog karaktera, intermitirajući i nestabilni, postizanje razine potrebne kontrole i performansi zahtijeva inteligentniju, učinkovitu i pouzdanu mrežu. To je sada moguće zahvaljujući značajnim napretcima u tehnologiji automatizacije mreža posljednjih godina, uključujući razvoj tzv. digitalnih trafostanica.

Kao sastavni dijelovi elektroenergetskih sustava, trafostanice u biti predstavljaju srce napajanja električnom energijom. Kao takve, one imaju ključnu poziciju u ovom novom tehnološkom i niskouglјičnom razvoju. Kada je u pitanju automatizacija, nadzor i zaštita trafostanice, digitalna tehnologija doista dolazi do maksimalnog izražaja. Brojni vodeći svjetski proizvođači opreme danas već nude mrežnim operatorima integrirani portfelj proizvoda i rješenja u području digitalnih trafostanica, a koji se mogu koristiti kako bi postrojenja konzistentno postajala digitalna i sposobna za rukovanje bilo kakvim proizvodnim objektom, opterećenjem ili poremećajem.

Tradicionalno, trafostanice su koristile prekidače, strujne mjerne transformatore, naponske mjerne transformatore i zaštitne releje koji su svi ožičeni zajedno pomoću bakrenih kabela. Uz napredak u digitalnoj tehnologiji, komunikaciji i standardima, ovo se sada mijenja u ono što se naziva digitalna trafostanica.



Prethodna slika prikazuje glavne koncepte povezane s digitalnom trafostanicom. U ovom konceptu, stanična računala, uređaji za zaštitu i ostali eletronički i inteligentni uređaji (IEDs) povezani su zajedno komunikacijskom opremom temeljenom na optičkim vlaknima. Arhitektura sustava trafostanice dijeli se na tri razine:

1. razina trafostanice u kojoj se odvijaju operacije, inženjerske funkcije i izvješćivanje,
2. razina polja na kojoj se provode funkcije zaštite i upravljanja i
3. stupanj procesa gdje se prenose signali iz mjernih uređaja i drugih pretvarača.

Digitalna trafostanica temelji se na standardu IEC 61850 "Komunikacijske mreže i sustavi u trafostanicama". Ovo je međunarodni standard koji definiran i uređuje komunikaciju, SCADA sustave i sustave automatizacije unutar trafostanica. To je okosnica i okvir oko kojeg se gradi digitalna trafostanica.

Digitalna trafostanica implementirana je najčešće pomoću elemenata i komponenti prikazanih na prethodnoj slici. Prikazani raspored nije jedini način implementacije digitalne trafostanice, ali to predstavlja jedan od uobičajenih pristupa.

Postavljanjem različitih elemenata potrebnih za trafostanicu (prekidači, zaštitni releji, mjerni transformatori itd.) te njihovim međusobnim povezivanjem pomoću optičkih vlakana, fizička realizacija trafostanice postaje jednostavnija dok se istodobno povećava pouzdanost i osmotrivost. U usporedbi s tradicionalnom trafostanicom gdje je sve povezano sa stotinama pojedinačnih bakrenih kabela, prednosti postaju očite.

Prednosti digitalnih trafostanica su:

- Sigurnost u pogonu,
- Brzo i jednostavno održavanje,
- Sigurnost investicije,
- Ugrađena cyber sigurnost,
- Povećana raspoloživost i druge.

Osnova digitalne trafostanice jesu stanična i procesna sabirnica. Ove dvije komunikacijske sabirnice omogućuju razmjenu signala između razine releja u polju i razine staničnog računala te ostale opreme.

Digitalne trafostanice i procesni sabirnički sustavi obično se primjenjuju pomoću Ethernet switch-eva, povezanih zajedno u konfiguraciji prstena.

Izgradnjom ili rekonstrukcijom digitalnih trafostanica izgrađuju se digitalni sustavi koji omogućavaju generiranje čitavog niza dodatnih podataka najčešće vremenski sinkroniziranih te dostupnih za prijenos i kasniju analitiku u nadležnim centrima upravljanja.

S obzirom na različitosti protokola IEC 61850 te IEEE C.37.118, u ovom trenutku sve primjene i aplikacije se razvijaju i postavljaju na zasebnim platormama. Može se očekivati u budućnosti određena harmonizacija ovih protokola u cilju daljnje digitalizacije objekata i veličina u EES-ima u Svijetu. Samim tim, može se očekivati „izlazak“ protokola IEC 61850 izvan transformatorske stanice te pridjeljivanje oznake točnog vremena svakoj mjernoj električnoj ili neelektričnoj veličini.

2.3. METEOROLOŠKE VELIČINE

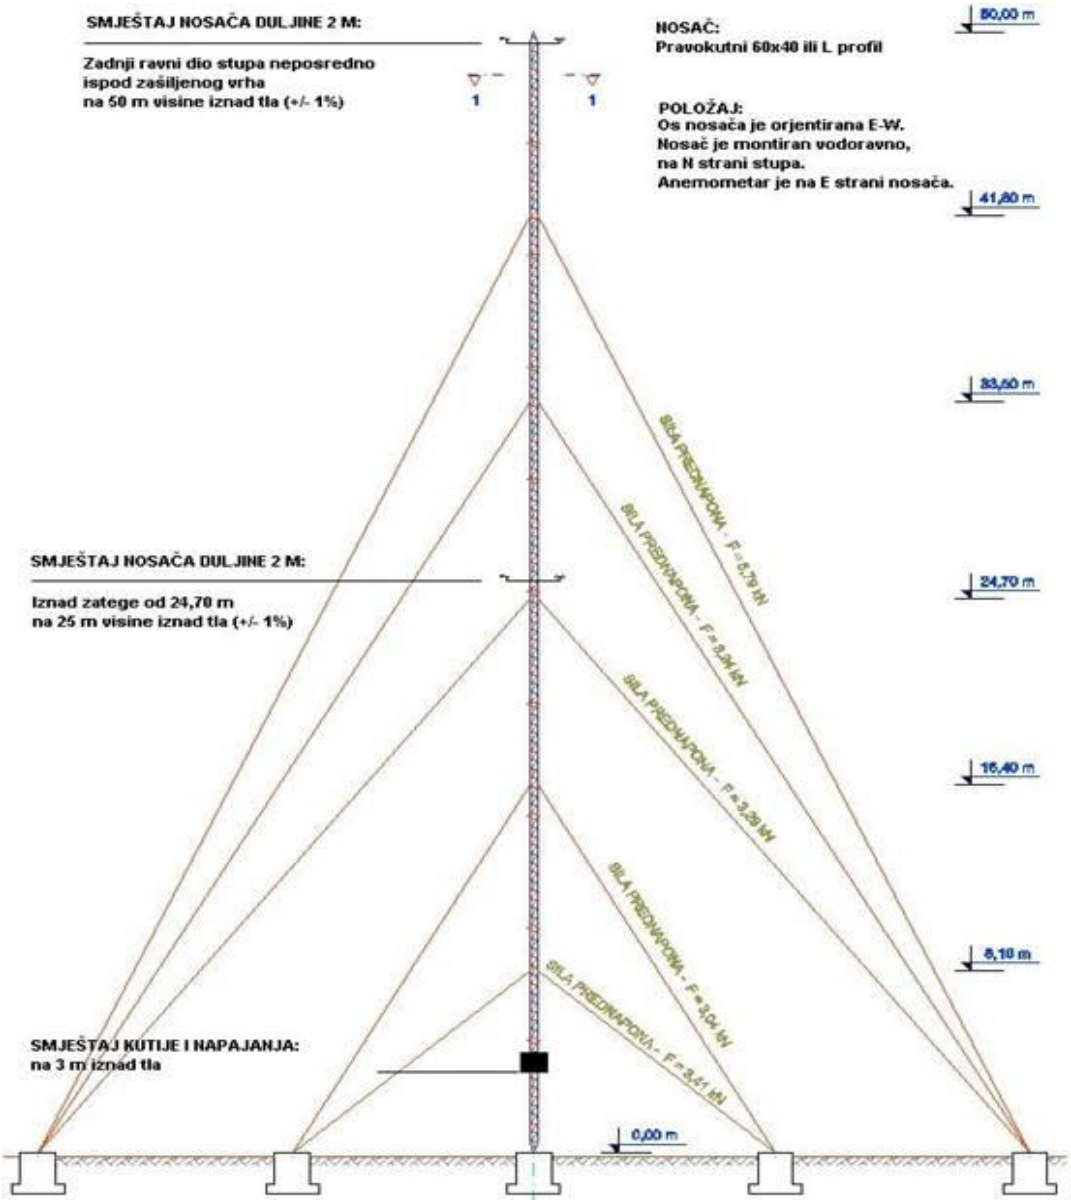
2.3.1 Mjerni stupovi

Izgradnja postrojenja, ali i kasniji pogon vjetroelektrane ili bilo kjeg drugog obnovljivog izvora energije zahtijeva dugi proces mjerenja, istraživanja i inih radnji na lokaciji gradnje. Jedna od najznačajnijih pripremnih i pogonskih radnji je mjerenje karakteristika vjetra i meteoroloških veličina na samoj lokaciji. Budući da je za procjenu isplativosti takvih postrojenja potrebno vrlo dobro poznavanje karakteristika vjetra na određenom području, prije izgradnje vjetroelektrane provode se mjerenja različitih atmosferskih svojstava da bi se što bolje procijenio vjetropotencijal na zadatoj lokaciji. Ista mjerenja moraju se provoditi minimalno godinu dana da bi se dobio što manje odstupanje kasnije proizvodnje električne energije od rezultata dobivenih proračunima temeljenih na predmetnim mjerenjima. Također, tijekom kasnijeg pogona vjetroelektrane, ista mjerenja se koriste za optimiranje samog pogona, verifikaciju krivulja snage, predviđanje proizvodnje itd.

Budući da su u najčešćem broju slučajeva ova mjesta vrlo često zabačena te kao takva udaljena od bilo kakvih energetskih i komunikacijskih instalacija, postavlja se problem napajanja mjernih uređaja te njihove komunikacije s korisnikom odnosno slanja mjernih podataka.

Lokacije koje se istražuju i na kojima se kasnije gradi vjetroelektrana, obično su zabačeni brdsko-planinski predjeli koji su i bogatiji vjetrom. Konkretno, u Hrvatskoj se najčešće radi o priobalnom zaleđu. Takvi prostori gotovo uvijek su udaljeni od bilo kakvih energetskih i komunikacijskih instalacija te se pojavljuje problem napajanja mjerne opreme energijom te komunikacije i prijenosa podataka do korisnika. Tijekom gradnje vjetroelektrane, za predmetni stup se izgradi potrebna energetska i komunikacijska (najčešće optička) mreža. Pri tom treba imati u vidu neke od posebnosti ovog mjernog sustava kao što su: metalni mjerni stup visine 80 - 100 m koji tako predstavlja objekt privlačan atmosferskim pražnjenjima; osjetljiva mjerna oprema kao što su anemometri i pokazivači smjera; osjetljiva elektronika (sustavi za prikupljanje i slanje podataka).

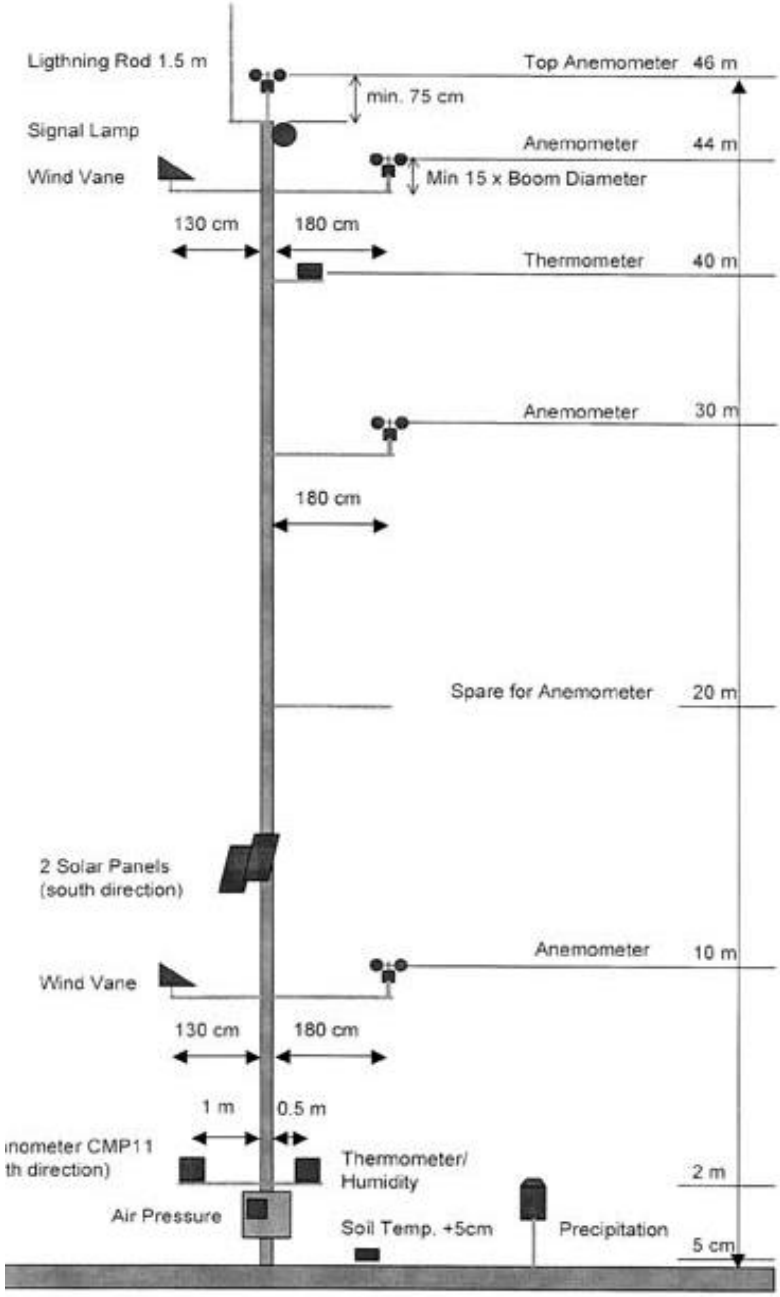
Namjena ovih stupova je nošenje mjerne opreme za ispitivanje klimatskih uvjeta nekog područja. Poprečni presjek stupa ima najčešće oblik jednakostraničnog trokuta i sidren je u tri smjera pod kutem od 120° tj. pridržan je sa 3 x 5 zatega sidrenih u šest temelja.



Slika 2.8 Skica mjernog stupa tip Dalekovod visine 50 m za mjerenje karakteristika vjetra

U ovom radu korištena su mjerenja karakteristika vjetra obavljena od strane tvrtke Dalekovod d.d. – Zagreb te Energetskog Instituta Hrvoje Požar (EIHP) [L 35, L 36, L 37, L 38]. Sva mjerenja obavljena su na prethodno opisanim stupovima, ali uz bitnu razliku u količini mjerne opreme na samom stupu. Prikaz mjernog stupa tip Dalekovod visine 50 m dat je na slici Slika 2.8.

Mjerni stup tip EIHP prikazan je na sljedećoj slici.



Slika 2.9 Skica mjernog stupa tip EIHP

Kao što je vidljivo na slici, anemometri za mjerenje brzine vjetra nalaze se na visinama 10 m, 44 m i 46 m. Pokazivači smjera nalaze se na visinama 10 m i 44 m. Termometri za mjerenje temperature nalaze se na visinama 2 m i 40 m. Također, na visini 2 m nalazi se uređaj za mjerenje vlage, barometar za mjerenje tlaka te piranometar za mjerenje insolacije. Na vrhu stupa nalazi se i gromobranska hvataljka duljine 1.5 m.

Fizički izgled stupa postavljenog na mjernoj lokaciji prikazan je na sljedećoj slici:



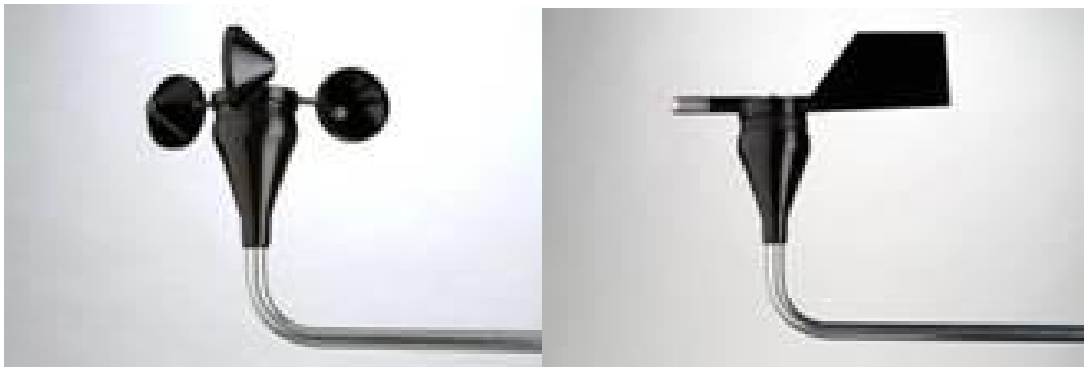
Slika 2.10 Mjerni stup tip Dalekovod visine 50 m

Mjerni stupovi izvedeni u sklopu vjetroelektrana imaju mogućnost priključka na optičku i elektroenergetsku infrastrukturu same vjetroelektrane pa se na taj način svi mjerni podaci mogu isporučiti nadležnim SCADA i ostalim nadzornim sustavima. Prikupljeni podaci koriste se za upravljanje pogonom vjetroelektrane. Međuračunalnom komunikacijom moguće je sve predmetne mjerne podatke poslati i operatorima prijenosnog i distribucijskog sustava.

2.3.2 Mjerenja karakteristika vjetra

Najbitnije mjerne veličine koje se mjere mjernim stupovima su vezane uz mjerenja karakteristika vjetra.

Mjerni uređaj tj. anemometar je smješten na nosačima kao i smjerokaz. Anemometrom se mogu mjeriti vjetrovi brzina najčešće od 1 m/s do 96 m/s što daje i više nego dovoljnu širinu mjernog opsega budući da se radi o 10-minutnim prosjecima. Vrsta signala koju daje mjerni pretvornik u anemometru najčešće je izmjenični sinusni val čija je frekvencija linearno proporcionalna brzini vjetra, ali može biti i standardni analogni signal 0-10 V ili 4-20 mA.



Slika 2.11 Mjerni uređaji tipa NRG instalirani na stupovima tipa Dalekovod

Točnosti anemometara najviše klase točnosti su ispod 1%.

Pokazivač smjera (smjerokaz) zabilježava smjer vjetra u stupnjevima u području od 0° do 360°. Vrsta signala koju daje mjerni pretvornik najčešće je analogni istosmjerni napon dobiven iz potenciometra. Prijenosna funkcija je napon ovisan o trenutnom omjeru na potenciometru. Pri tom je točnost definirana linearnošću potenciometra.

Većinu prošlog desetljeća najsveobuhvatniji centri za ispitivanje vjetra u Europi bili su uključeni u razvoj mjernih standarda kako bi se osiguralo da se mjerenja izvode na razini visoke kvalitete. U istom razdoblju razvijene su ili su još u razvoju nekoliko nacionalnih i međunarodnih preporuka, standarda i zahtjeva za postupke mjerenja brzine vjetra i sustava vjetroagregata. Posljedično, za određena mjerenja postoji nekoliko različitih formalnih postupaka za prikupljanje i vrednovanje podataka i dovode do različitih rezultata mjerenja. Iskustvo je također pokazalo da mjerenja, provedena od strane različitih instituta, nisu dovela do usporedivih rezultata, čak i ako su uzeli u obzir iste preporuke.

Kako bi se poboljšala ova situacija, najiskusniji instituti za razvoj vjetroelektrana odlučili su raditi zajedno u tzv mreži instituta za energiju vjetra pod nazivom MEASNET [L 36] s ciljem izrade pravila i zahtjeva koji će jamčiti da se vrše kvalitetna mjerenja. Potrebno stvaranje mrežnih pravila i uspostavljanje zajednički dogovorenih mjernih metoda potkrijepljeno je od strane Europske komisije u dva zajednički provedena projekta. Po prvi puta, instituti koji su bili u komercijalnoj konkurenciji dogovorili su se zajednički raditi za dobrobit svojih klijenata s ciljem da obavljaju mjerenja jednake kvalitete koja su dovoljna za međusobnu usporedbu i prihvaćanje nužne za industriju na otvorenom svjetskom tržištu.

Također, međunarodna elektrotehnička komisija IEC donijela je standard IEC 61400-12-1 [L 35] koji opisuje postupke i mjernu instrumentaciju za mjerenje vjetra.

Ostale meteorološke veličine koje je potrebno mjeriti, neposredno su vezane uz određivanje gustoće zraka, a tim i neposredno preciziranja proizvodnje električne energije. Sukladno tome, najčešće mjerene ostale meteorološke veličine jesu:

- Temperatura zraka,
- Vlažnost zraka,
- Tlak zraka,
- Insolacija.

Ono što je najbitnije, iz predmetnih meteoroloških veličina, moguće je raditi estimacije i korelacije proizvodnje el. energije iz vjetroelektrana te solarnih elektrana.

Svaki od mjernih instrumenata spojen je zasebnim kabelom na mjernu stanicu (eng. Data logger) odnosno uređaj za prikupljanje mjernih podataka koji se obično nalazi u dnu stupa. Budući da su ti kabeli dosta dugački, problem parazitnih kapaciteta te vanjskih elektromagnetskih utjecaja riješen je posebnom oblogom od aluminijske folije unutar kabelske izolacije. [L 41].

Kabelom se podaci prenose do uređaja za prikupljanje podataka koji sve podatke sprema na memorijsku karticu za sigurnosnu pohranu.

Iste datoteke potrebno je poslati na udaljenu lokaciju gdje se obavlja prikupljanje i obrada podataka te detaljnije analize. Na sljedećoj slici prikazani su neki uređaji za prikupljanje i slanje mjernih podataka.



Slika 2.12 Uređaj za prikupljanje i slanje podataka

Kutija sa mjernom stanicom i solarnim panelom za sigurnosno napajanje smještena je na cca. 3 m iznad tla. Postoje dvije mogućnosti preuzimanja podataka:

- očitavanje memorijske kartice (zahtijeva fizički pristup)
- prijenos 3G/4G ili nekom drugom bežičnom telekomunikacijskom vezom
- prijenos optičkom ili nekom drugom žičanom telekomunikacijskom vezom

Glavni način preuzimanja podataka je optičkom vezom, ali spremanje podataka na memorijsku karticu ostavlja rezervnu (eng. Backup) varijantu u slučaju kvara veze ili komunikacijskog modula.

Standardni uređaji za prikupljanje podataka, danas imaju preko 20 kanala za ulazne podatke, od kojih je određeni broj kanala digitalni, a određeni broj kanala analogni. Interval uzorkovanja iznosi najčešće 1-2 sekunde, a interval usrednjavanja iznosi najčeće 10 minuta.
Za napajanje uređaja koristi se najčešće NN mreža same vjetroelektrane te kao rezerva punjive baterije u kombinaciji s fotonaponskim modulom. Ukoliko nestane primarnog napajanja iz NN mreže vjetroelektrane, noću se baterije prazne i napajaju opremu dok se preko dana pune preko fotonaponskog modula. Na taj način je kompletna oprema autonomna i neovisna o vanjskom napajanju.
Za zaštitu mjernog mjesta (ljudi i mjerne opreme) od nakupljanja električnog naboja i od atmosferskog pražnjenja potrebno je adekvatno uzemljiti stup i opremu.

Slanje podataka najčešće se obavlja preko optičke komunikacijske veze pri čemu sam mjerni stup predstavlja zasebni objekt u računalnoj mreži, a podaci se najčešće šalju nekim od standardnih industrijskih TCP/IP protokola kao što su MODBUS ili slični.

Najčešći problemi vezani uz rad ovog mjernog sustava vezani su uz prenaponsku zaštitu elemenata. Oprema koja se montira na stup sastavljena

je od vrlo osjetljive elektronike i iako je za stup predviđeno vrlo dobro uzemljenje, dogodilo se nekoliko slučajeva kvarova na elektroničkoj opremi uzrokovanih udarom groma u stup. U svim slučajevima, kao najosjetljiviji dio opreme pokazala se mjerna stanica, dok se od mjernih pretvornika kvar najčešće događao na pokazivaču smjera. Također, u nekoliko slučajeva događao se kvar na pojedinom kanalu uređaja za prikupljanje podataka, što je ujedno i najlakši kvar za otklanjanje jer je potrebno samo zamijeniti priključke mjernog pretvonika na drugi kanal koji je dostupan.

Sve predmetne instalacije za mjerenje meteoroloških veličina se u posljednjih nekoliko godina postavljaju i na same stupove nadzemnih prijenosnih dalekovoda kao što je prikazano na sljedećoj slici.



Slika 2.13 Primjer meteorološke mjerne garniture na nadzemnim dalekovodima

Meteorološke mjerne garniture istovjetne ovima prikazanima na prethodnoj slici, najčešće se preko svojih uređaja za prikupljanje i slanje podataka spajaju na nadređene centre upravljanja.

2.4. SENZORSKE VELIČINE

2.4.1 Mjerenje temperature vodiča

U posljednjih nekoliko godina prisutan je snažan trend postavljanja čitavog niza senzorike na elemente elektroenergetske mreže među kojima su najzastupljeniji nadzemni dalekovodi. Jedna od najbitnijih senzorskih veličina koja se na taj način mjeri je temperatura vodiča nadzemnog dalekovoda.

Mjerenje temperature vodiča nadzemnog dalekovoda bitno je jer poznavanjem temperature vodiča moguće je odrediti strujnu opteretivost samog vodiča odnosno odrediti koliko je „rezerve“ ostalo u maksimalnom strujnom opterećenju samog vodiča.

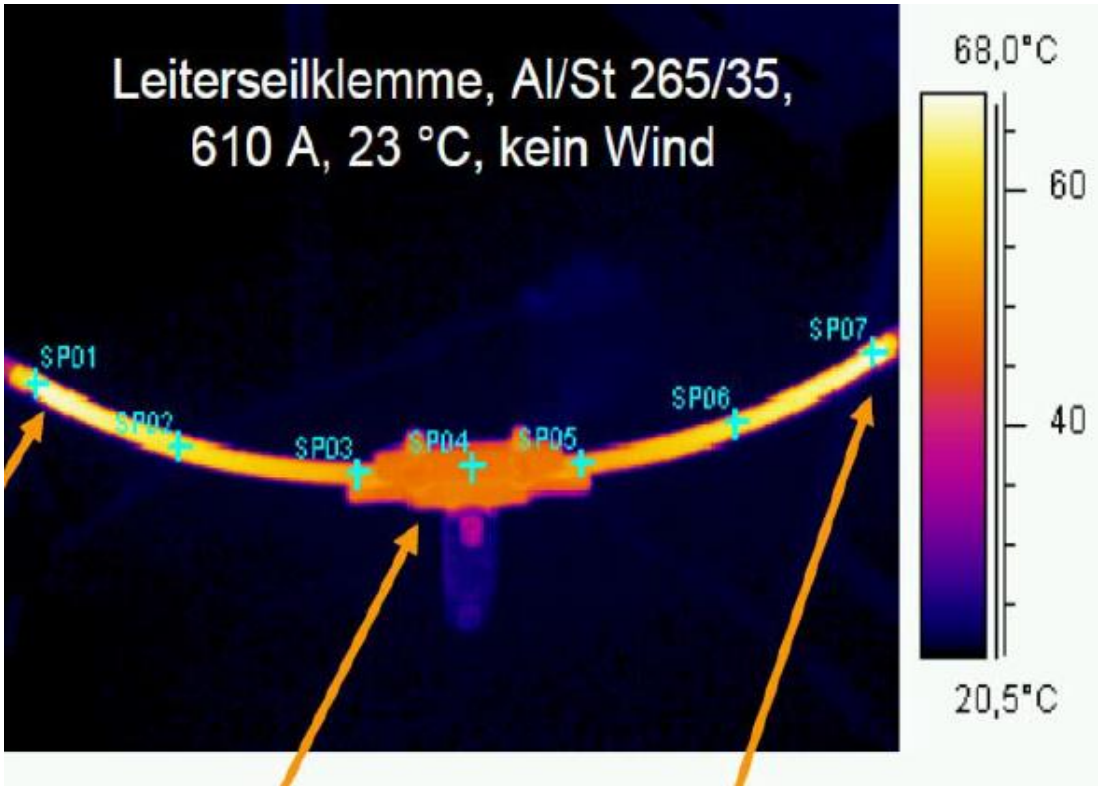
Najčešće korišteni vodič nadzemnih dalekovoda je standardni Al-Če vodič odnosno tzv ACSR (Aluminium Conductor Steel Reinforced). Temperatura alumija koji se koristi u takvim namjenama ne smije premašiti 90˚C.

Konvencionalni termalni senzori, za izravno mjerenje temperature, kao što su termokopleri, termistori i otporni toplinski pretvornici, naširoko su korišteni za mjerenje temperature površine vodiča. Takvi pretvornici pružaju najisplativije rješenje za mjerenje temperature u jednoj točki. Međutim, ako je senzor temperature postavljen na površinu vodiča, time vodič postaje ujedno i toplinski ponor i također može štititi dio vodiča od solarnog zračenja. Prema tome, za postojeće vrste senzora, pogreška uzrokovana ovakvim efektom hladila, je obično reda veličine od ± 5% do 10% porasta temperature iznad ambijentalne temperature.



Slika 2.14 Prikaz tipičnog uređaja za mjerenje temperature vodiča (tzv. Power Donut)

Sve to opisano je u nizu istraživanja među kojima se ističe istraživanje tehničkog sveučilišta u Darmstadtu. Tim straživanjem pokazano je na empirijskim podacima da mjerenja temeprature na istom vodiču ovise i o položaju same mjerne kleme. Ovaj efekt figurativno je oslikan na sljedećoj slici gdje dat i prikaz temepraturnog polja oko same mjerne sonde na vodiču nadzemnog dalekovoda.



Slika 2.15 Prikaz temperaturnog polja oko mjerne sonde na nadzemnim dalekovodima

Također, mjerni podaci sa prethodne slike prikazani su i u sljedećoj tablici.

Tablica 2-1 Mjerni podaci mjerenja temperature na mjernom uzorku ACSR vodiča 265/35, bez vjetra uz vanjsku temepraturu 23˚C (izvor Tehničko Sveučilište Darmstadt)

MJERNO MJESTO	SP01	SP02	SP03	SP04	SP05	SP06	SP07
TEMPERATURA (˚C)	67.1	62.1	54.7	49.8	54.5	62.4	67.4

Iz prethodnih podataka vidljivo je da izravna mjerenja temperature nemaju točnost potrebnu za globalnu procjenu karakteristika vodiča već mogu samo precizirati lokalne temperaturne prilike na samom vodiču. Stoga se i dan danas takva mjerenja koriste u određene aproksimacije te usrednjavanja na temelju niza mjerenja temperature samog vodiča.

2.4.2 Mjerenja provjesa nadzemnih vodova

Maksimalna dopuštena temperatura vodiča kod nadzemnog prijenosnog voda, može dati ograničene informacije o održavanju minimalnih potrebnih sigurnosnih visina i razmaka između strujnih vodiča i tla ili drugih vodiča. Stoga je precizna procjena provjesa nadzemnog vodiča ključna za određivanje prijenosnog kapaciteta voda, kao i za održavanje sigurnosti sustava.

Sljedeća tablica sažeto prikazuje nekoliko izravnih mjernih metoda mjerenja, koje su ili dostupne na tržištu ili još uvijek u razvoju.

Tablica 2-2 Prikaz metoda za mjerenje provjesa nadzemnih dalekovoda

METODA	FUNKCIONALNOST	KARAKTERISTIKE
GPS metoda	Provjes mjeren izravno uporabom GPS tehnologije	Točnost oko 20 cm
INKLINOMETAR	Mjerenje kuta vodiča u odnosu na horizontalnu os	Zahtijeva se precizno mjerenje kuta
OTPORNE ŽICE	Mjerenje el.polja blizu vodiča	Osjetljivost na vanjske utjecaje (vjetar, indukcija...)
MJERENJE NAPREZANJA	Mjerenje naprezanja u stezaljci zateznog stupa	Mjerenje prosječne temperature vodiča
SAGOMETAR	Mjerenje video kamerom i procesnom analizom slike	Točnost oko 5 cm
LASERSKA MJERENJA	Mjerenje udaljenosti laserom	Točnost oko 5 cm

Među najrasprostranjenije metode za mjerenje provjesa spadaju mjerenja tzv. Sagometrom odnosno uređajem za izravno mjerenje pomaka točke provjesa ovješenog vodiča nadzemnog dalekovoda.

Metoda mjerenja provjesa sagometrom sastoji se od kamere za procesuiranje slike montirane na stupu nadzemnog dalekovoda zajednos s uređajima za napajanje i komunikacije te jednostavne mete ovješene na točki najnižeg provjesa raspona nadzemnog dalekovoda. Isti uređaji prikazani su na sljedećim slikama.



Slika 2.16 Montaža kamere za snimanje provjesa i procesuiranje slike te pripadajuće meteorološke i komunikacijske opreme



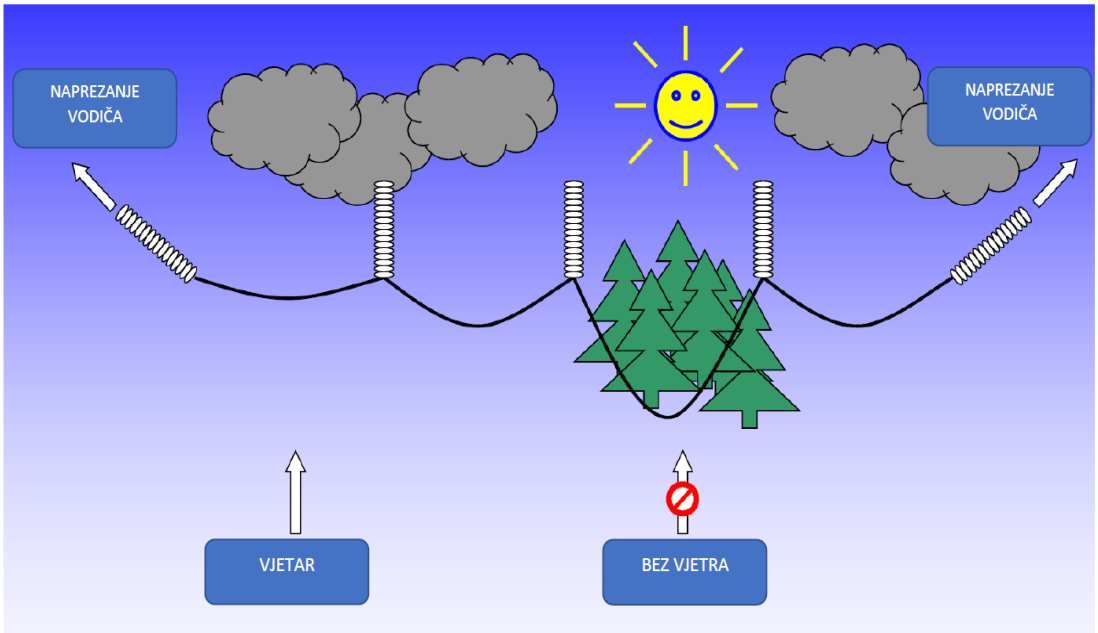
Slika 2.17 Montaža mete za snimanje provjesa i procesuiranje slike te pripadajuće ovjesne i spojne opreme

Većina metoda za mjerenje provjesa zahtijeva sofisticirani i složeni hardverski dizajn senzorskih uređaja i često su skupi i teški za instalaciju. Ta činjenica sprječava njihovo iskorištavanje kao ekonomično, masivnu, rasprostranjenu i široko dostupnu tehnologiju.

2.4.3 Mjerenja naprezanja nadzemnih vodova

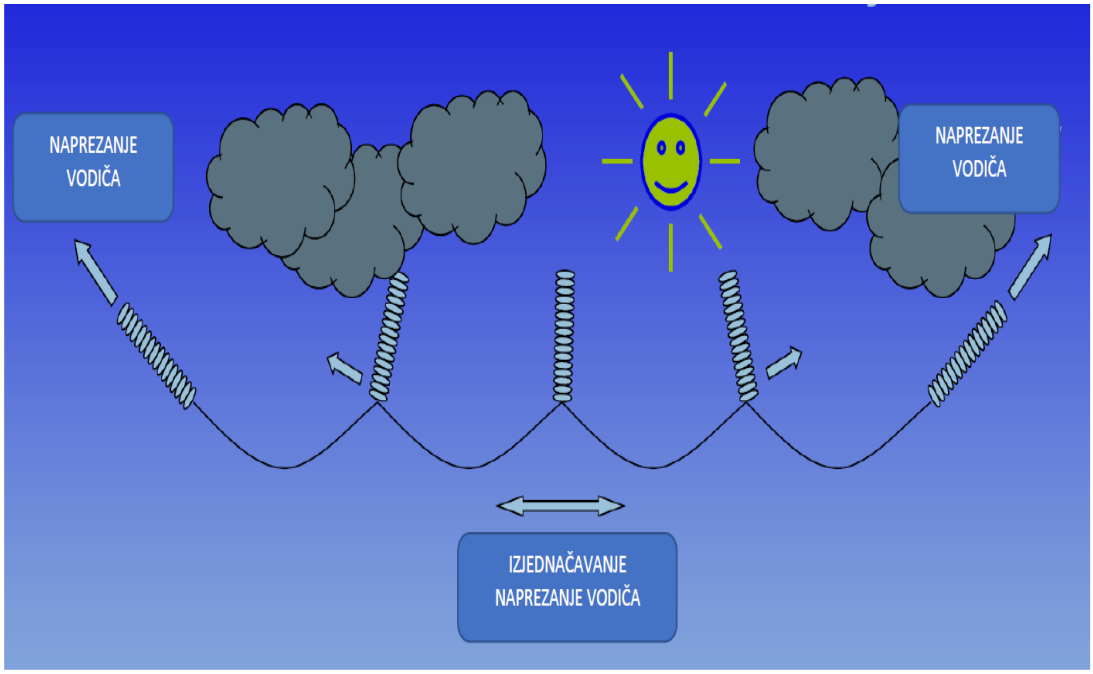
Mehaničko naprezanje vodiča glavni je parametar projektiranja odnosno dizajniranja za nadzemne vodove. Podaci o provjesu i sigurnosnim udaljenostima mogu se izravno izvesti iz ove informacije o mehaničkom naprezanju. Pored toga, prosječna temperatura vodiča u linijskom dijelu izravno je povezana s naprezanjem u tom dijelu cijevi. Povećana temperatura vodiča rezultira produljenjem materijala i time povećava provjes i smanjuje naprezanje. U slučaju smanjenja temperature vodiča povećat će se mehaničko naprezanje.

Važno je napomenuti da mehaničko ponašanje nadzemnog voda ovisi o prosječnoj temperaturi vodiča duž cijelog sekcijskog polja, a ne o lokalnoj temperaturi unutar sekcije. Dok vremenski uvjeti duž koridora mogu puno varirati, a kao posljedica i lokalne temperature vodiča, dizajn nadzemnih vodova omogućava izjednačavanje mehaničkog naprezanja između pojedinih raspona rotacijom izolacijskih lanaca u zateznim stupovima.



Slika 2.18 Kvalitativni prikaz nejednakih provjesa u trenutku pojave različitih meteoroloških prilika uzduž trase zateznog polja

Izjednačavanje horizontalne komponente naprezanja vodiča odvija se otklonima nosivih izolatorskih lanaca na nosivim stupovima unutar zateznog polja dalekovoda. Na taj način, mjerenjem i nadzorom naprezanja u zateznim stupovima, rješava se problematika nejednolikih meteoroloških prilika na trasi zateznog polja dalekovoda odnosno i na čitavoj trasi cjelokupnog dalekovoda.



Slika 2.19 Kvalitativni prikaz izjednačavanja provjesa uzduž trase zateznog polja

Također, zaključak CIGRE Tehničke Brošure br. TB299 „Guide for selection of weather parameters for bare overhead conductor ratings“ u poglavlju 5.3.3. definira da su sustavi za monitoring koji uključuju nadzor provjesa i naprezanja ujedno i najprecizniji sustavi za nadzor dinamičke prijenosne moći nadzemnih vodova pri visokim vrijednostima struje i malim vrijednostima brzine vjetra, a što su ujedno i najčešća pogonska stanja u elektroenergetskim sustavima.

Sukladno navedenom, u posljednje vrijeme razvijaju se i instaliraju mjerni senzori i pripadajuća mjerna i komunikacijska oprema za mjerenja naprezanja vodiča nadzemnih dalekovoda. Mjerni senzor za mjerenje naprezanja nadzemnih vodova najčešće je izrađen od nehrđajućeg čelika. Takav senzor mjeri naprezanje vodiča u ovjesištu vodiča u jednoj fazi. Instaliraju se na "hladnoj strani" žice odnosno na uzemljenom dijelu izolacije odnosno izolatorskog lanca, a prema sljedećoj slici.



Slika 2.20 Montaža sustava za mjerenje naprezanja vodiča nadzemnog dalekovoda te pripadajuće ovjesne i spojne opreme

2.4.4 Dinamička prijenosna moć vodova

Dinamička prijenosna moć vodova (eng. DLR – Dynamic Line Rating) predstavlja stvarnu prijenosnu moć jednog voda u mreži na temelju trenutnih vrijednosti ostalih električkih i neelektričkih parametara koji mogu utjecati na istu prijenosnu moć.

Kad su kabelski vodovi u pitanju, bitni parametri koji utječu na dinamičku prijenosnu moć su temperatura tla i temperatura kabela.

Kad su nadzemni vodovi u pitanju bitno je veći broj ovisnih varijabli, a najbitnije su sljedeće:

- temperatura zraka,
- temperatura vodiča,
- brzina i smjer vjetra,
- insolacija.

Zbog prethodno opisanih problema kod izravnog mjerenja temperature vodiča, često se za izračun prijenosne moći nadzemnih dalekovoda koriste neizravne metode, a naročito mjerenje provjesa i mjerenje naprezanja nadzemnih dalekovoda koji spadaju među preciznije metode za konačno određivanje dinamičke prijenosne moći.

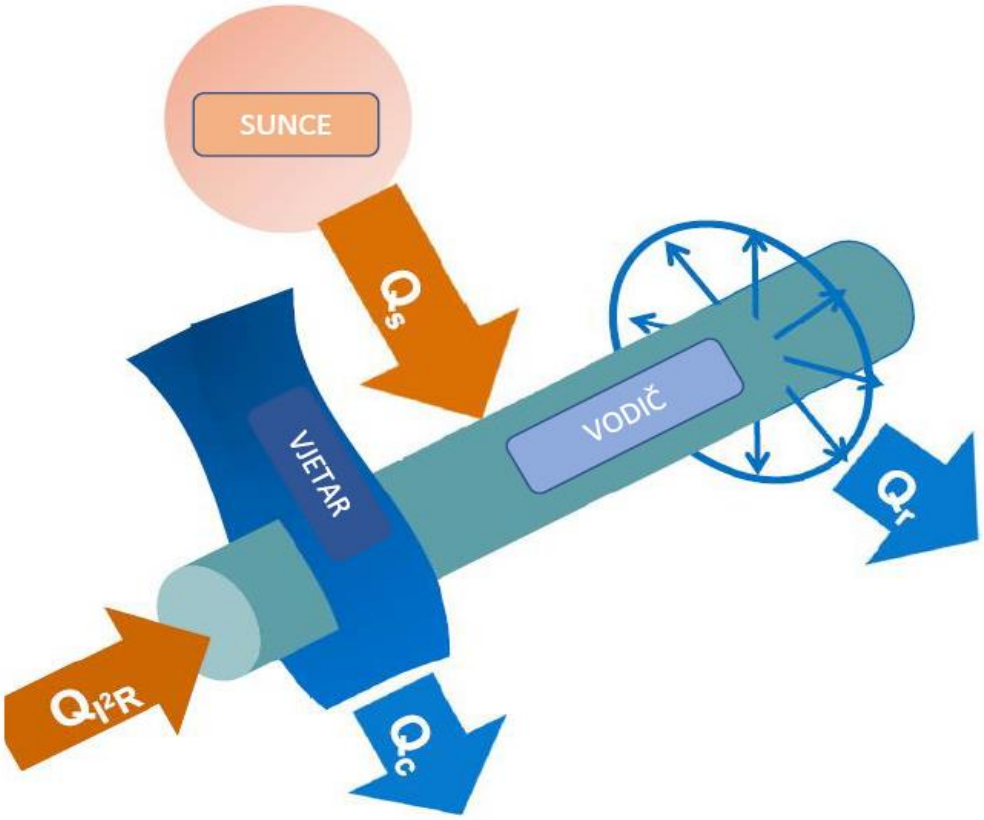
Za izračun trenutne odnosno dinamičke prijenosne moći dalekovoda koristi se standard IEEE 738, kojim se definira osnovna jednadžba stanja za izračun trenutne maksimalne strujne opteretivosti.

$$m_v \cdot c_v \cdot \Delta T_v = I^2 \cdot R_v + Q_s - Q_r - Q_c \qquad \textbf{(2.2)}$$

gdje je

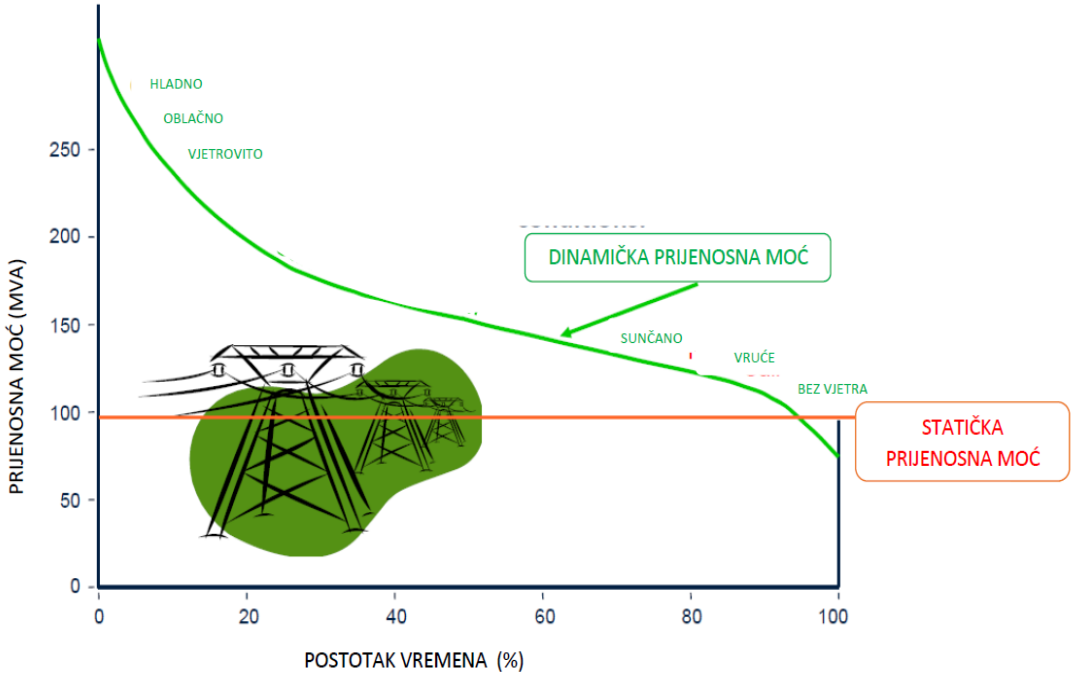
m_v - masa vodiča
c_v - toplinski kapacitet vodiča
ΔT_v - promjena temperature vodiča
I - struja kroz vodič
R_v - djelatni otpor vodiča
Q_s - toplinski dobici uslijed insolacije
Q_r - toplinski gubici uslijed radijacije
Q_c - toplinski gubici uslijed konvekcije

Predmetna jednadžba stanja može se slikovito prikazati kao na sljedećoj slici.



Slika 2.21 Slikoviti prikaz toplinske jednadžbe stanja vodiča nadzemnog dalekovoda

Svi navedeni izmjereni podaci i izračunati parametri mogu se potom iskoristiti u cilju izračuna trenutne raspoložive prijenosne moći dalekovoda, a koja je bitna veličina jer se bitno razlikuje u odnosu na statičku prijenosnu moć nadzemnih dalekovoda definiranom podacima o materijalu vodiča. Kvalitativni grafički prikaz razlike između statičke i dinamičke prijenosne moći dalekovoda dat je na sljedećoj slici.



Slika 2.22 Kvalitativni grafički prikaz statičke i dinamičke prijenosne moći nadzemnog dalekovoda

Svi predmetni mjerni podaci opisani u ovom poglavlju te svi parametri dobiveni proračunima opisanim u ovom poglavlju, mogu služiti u budućim podatkovnim analizama i izvlačenjima korisnih informacija iz istih podataka.

S obzirom da se radi o velikim količinama novih vrsta podataka u elektroenergetskom sustavu, potrebno je razraditi modele korištenja predmetnih podataka u svrhu analize, vođenja, zaštite, nadzora i upravljanja elektroenergetskim sustavom u cjelini ili u dijelu elektroenergetskog sustava.

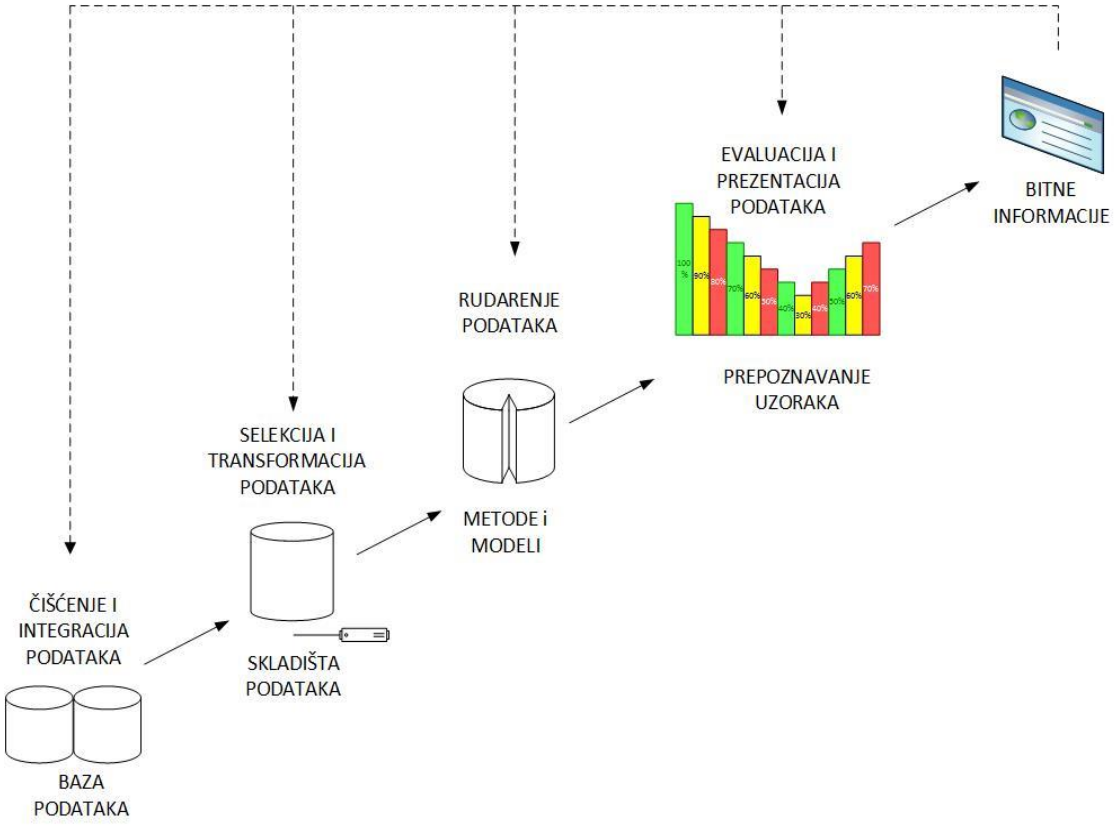
3. RUDARENJE PODATAKA

3.1. OPĆENITO O RUDARENJU PODATAKA

3.1.1 Tehnike rudarenja podataka

Kompjuterizacija društvenih, prirodnih i industrijskih procesa značajno je povećala mogućnosti proizvodnje i skupljanja podataka iz različitih izvora. Takav eksplozivni rast pohranjenih i prijelaznih podataka, stvorio je potrebu za novim tehnikama i automatskim alatima koji mogu dati krucijalnu pomoć u pretvaranju takve velike količine podataka u pouzdane i korisne informacije. Sve navedeno dovelo je do razvoja novih tehnika u računalnoj znanosti, često zvanoj i Rudarenje podataka (eng. Data Mining) [L 53].

Rudarenje podataka je nova metodologija kojom se otkrivaju vrijedni podaci u bazama podataka poduzeća ili procesa. Metoda se naziva rudarenje podataka, jer se u velikim količinama podataka traže informacije koje „vrijede zlata“.



Slika 3.1 Kvalitativni grafički prikaz rudarenja podataka i izvlačenja bitnih informacija za korisnika

Operatori elektroenergetskih sustava dnevno bilježe goleme količine podataka. Za svaku pogonsku operaciju vode se podaci o lokaciji, vremenu, električnim i neelektričnim veličinama. Ovi se podaci bilježe u procesne baze podataka koje su nužne za operativni pogon. Procesne baze podataka općenito obavljaju tri opće funkcije: vođenje evidencije o obavljenim poslovnim događajima, generiranje dokumenata potrebnih u analitici i izvještavanje o stanju operativnog procesa. Najbolje se uči iz iskustva, stoga su prije petnaest godina isprva znanstvenici, a kasnije i menadžeri shvatili da su procesne baze podataka bogat izvor znanja kojim se može poboljšati poslovni procesi. Postalo je jasno da poduzeća imaju mnogo podataka, a malo informacija i vrlo malo znanja o mnogim aspektima svoga poslovanja.

Ovakav jedan multidisciplinarni proces može se definirati na razne načine. Čak ni izraz „rudarenje podataka“ ne preslikava u stvarnosti sve bitne komponente ovog procesa. Rudarenje podataka vrlo često se naziva i proces izvlačenja znanja iz podataka (eng. Knowledge discovery from data) i takav izraz najbolje oslikava sam proces. Široko prihvaćena definicija definira proces rudarenja podataka kao proces otkrivanja bitnih uzoraka i znanja iz velike količine podataka. Izvore podataka mogu uključivati baze podataka, različita skladišta podataka ili, što je u elektroenergetskom sustavu vrlo često, različite mjerne podatke koji se dinamički generiraju iz raznih mjernih uređaja i sustava.

Budući da se radi o tehnici koja je izuzetno aplikabilna, rudarenje podataka inkorporiralo je mnoge tehnike iz drugih područja primjene kao što su statistika, prepoznavanje uzoraka, skladištenje podataka, vizualizacije, razvoj algoritama itd. Interdisciplinarna priroda istraživanja i razvoja ovog područja značajno je pridonijela uspjehu korištenja tehnika rudarenja podataka i značajnim primjenama u brojnim znanstvenim područjima.

Osnovne tehnike rudarenja podataka su:

- klasterizacija podataka
- klasifikacija podataka
- detekcija outliera
- analize vremenskih serija

3.1.2 Aplikacije rudarenja podataka

Tehnika rudarenja podataka može se primijeniti na bilo kakvoj vrsti podataka i izradu modela iz predmetnih podataka, dokle god su podaci smisleni i suvisli za određenu aplikaciju. Takvi podaci mogu biti mjerni podaci, vremenski podaci, sekvencijalni podaci, spacijalni i spacijalnotemporalni podaci itd. Sukladno tome, aplikacije rudarenja podataka mogu biti različite počevši od poslovne inteligencije, bioinformatike, medicine, financija, javne uprave do tehničkih znanosti odnosno konkretno do primjena u istraživanju i analizi elektroenergetskih sustava, primjena u vođenju elektroenergetskih sustava itd [L 51].

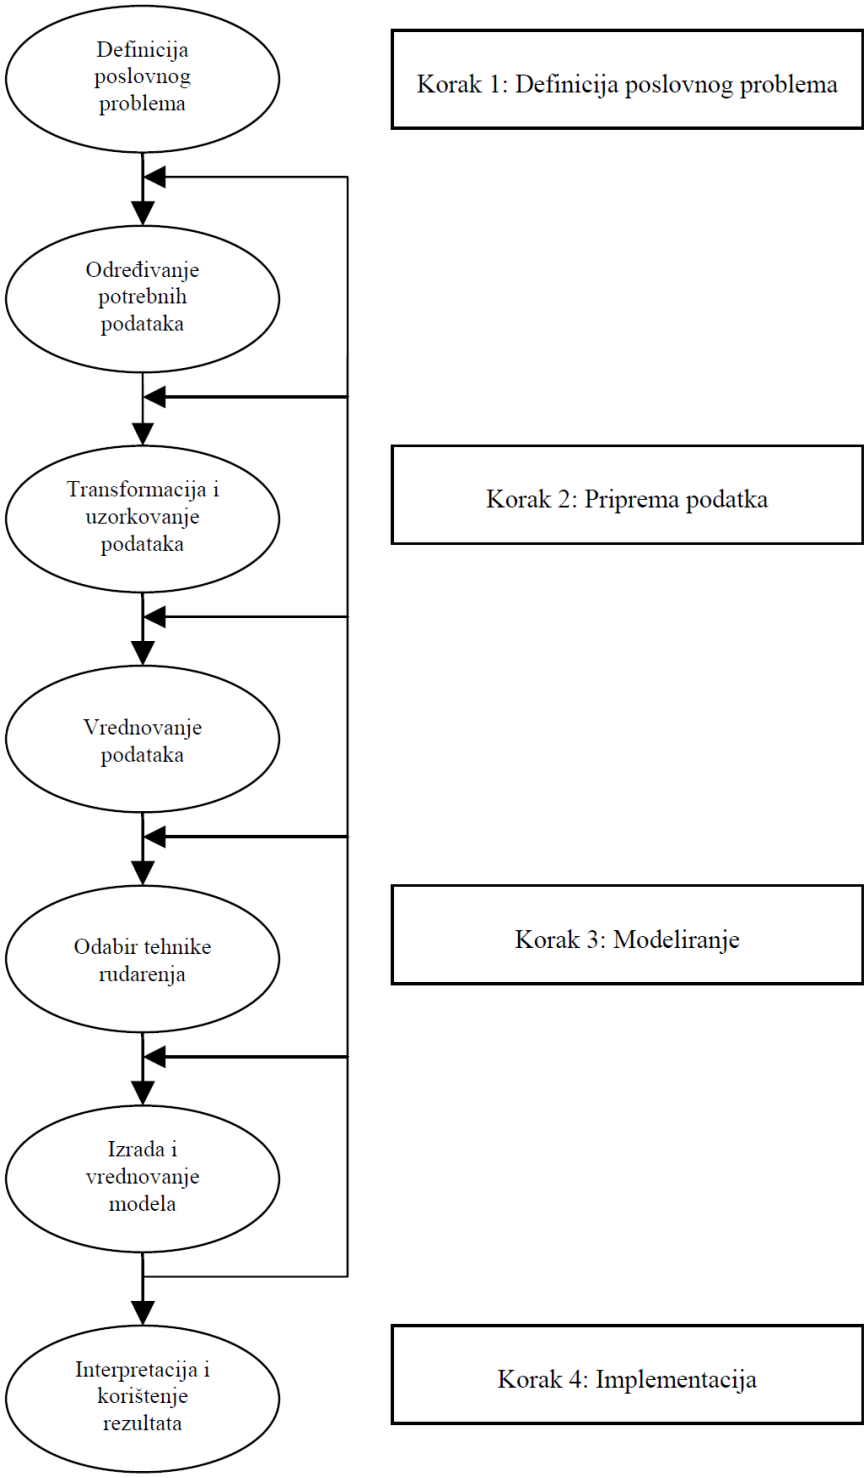
Proces rudarenja podataka je najčešće iterativan, što znači da se je u svakom trenutku moguće vratiti na neki od prethodnih koraka. Primjerice, tijekom procesa odabira tehnike rudarenja možemo shvatiti da nisu dobro odabrani potrebni podaci, stoga se možemo vratiti na drugi korak i početi sve ispočetka. Ovakav iteracija više će biti pravilo nego izuzetak, jer je u rudarenju podataka najvažnije dobro definirati problem te dobro odabrati i pripremiti podatke, što je teško napraviti kako treba odmah u prvoj iteraciji. S druge strane, tijekom procesa rudarenja podataka povećava se znanje o tehničkom ili poslovnom problemu i podacima, te je takva „revidirana “ definicija problema često bolja od originalne pa izrađeni modeli često i evoluiraju tijekom vremena.

U konačnoj fazi procesa rudarenja podataka, nakon što je izrađen matematički odnosno statistički model korištenjem jedne ili nekoliko tehnika induktivnog učenja, jedno pitanje uvijek se provlači kroz nastavak istraživanja ili korištenja modela. Na koji način obaviti verifikaciju odnosno validaciju predmetnog modela?

Validacija modela predstavlja obrazlaganje odnosno potvrdu da se predmetni model, unutar svoje domene primjene, ponaša zadovoljavajućom točnošću i dosljedno u skladu s ciljevima definiranim od strane korisnika. Drugim riječima, pri validaciji izrađenog modela, obrazlaže se odnosno potvrđuje da su se podaci transformirali u model koji ima dovoljnu točnost u prezentaciji promatranog modela. Validacija modela potvrđuje da je izrađen *pravi* model, odnosno model koji odgovara sustavu.

Verifikacija modela predstavlja obrazlaganje da je izrađeni model transformiran iz postojećih podataka te da ima zadovoljavajuću točnost izračuna novih izlaznih podataka. Ukratko, verifikacijom modela se potvrđuje da je model izrađen ispravno, a validacijom da model ima određenu točnost.

Generalno se aplikacije rudarenja podataka mogu opisati sljedećim dijagramom toka



Slika 3.2 Kvalitativni grafički prikaz aplikacija rudarenja podataka

Ovim radom definirana je jedna moguća aplikacija rudarenja podataka korištenjem generalnog dijagrama s prethodne slike. Predmetna aplikacija obuhvaća analizu podataka generiranih u elektroenergetskom sustavu.

3.1.3 Glavni nedostaci rudarenja podataka

Glavni nedostatak svih metoda rudarenja podataka jest što predmetne metode spadaju u tzv. nedeterminističke metode.

Nedeterminizam je fleksibilniji način računanja gdje ishod pojedine računske operacije nije jednoznačno određen. Nedeterminizam treba shvatiti kao misaoni koncept koji pomaže u teorijskim razmatranjima i omogućuje jednostavnije dokazivanje teorema.

Računalni determinizam (i nedeterminizam) opisuje postupak izračuna [L 77]. Deterministički je izračun onaj koji ima funkcionalni prijelaz iz stanja u stanje, što znači da se točno zna iz kojeg će stanja prijeći u koje, dok se u slučaju nedeterminizma prijelaz iz stanja u stanje definira relacijski. Ovo je smisleno, no u praktičnom se smislu može postići jedino tako da se izračun masivno paralelizira i da se svaki od tih procesa paralelno ostvaruje u memoriji.

Uslijed svega navedenog nastaju sljedeći problemi i nedostaci:

- nije poznat točan broj grana na koji se proces izgrana (ovo često ne djeluje kao problem, ali u praksi jest zbog potrebe definiranja memorije na početku procesa),
- broj paralelnih izračuna može biti iznimno velik.

Sukladno navedenom, vrlo često se ističu prednosti determinističkih metoda i izračuna, ali nedeterminističke metode odnosno rudarenje podataka može imati brojne prednosti u otkrivanju skrivenih uzoraka među podacima do kojih neki skriveni uzorci mogu rezultirati signalima ranog upozorenja odnosno tzv. EWS – Early Warning Signals. Predmetni signali se često ne mogu izračunati deterministički pa stoga ove metode mogu imati brojne prednosti takvog tipa.

Općenito, alati razvijeni za podatkovno rudarstvo vrlo su komplicirani i jaki alati. No, zahtijevaju vrlo stručnu osobu za pripremu podataka i razumijevanje rezultata. Budući „podatkovni rudar“ mora poznavati različite obrasce i odnose čiji se odnos mora valjano izvesti.

Nadalje, kako se prikupljaju ogromne količine podataka u sustavima za prikupljanje podataka, neki od tih podataka koji su vrlo kritični i osjetljivi mogu biti hakirani, kao što se i dogodilo s mnogim velikim tvrtkama. Također, informacije generirane tehnikom rudarenja podataka mogu se iskoristiti i u krive svrhe. Kod operatora elektroenergetskih sustava ti podaci i informacije mogu se iskoristiti za različite aktivnosti u sferi terorizma, napada na infrastrukturu zemlje itd. [L 70]

Unatoč brojnim primjerima uspješnog korištenja u znanosti i inženjeringu te ostalim granama istraživanja, metoda rudarenja podataka pokazala je i brojne mane. Pri nepravilnom korištenju, rudarenjem podataka moguće je kao rezultat dobiti nekvalitetne izlazne informacije. Primjeri takvih informacija

poznati su i u povijesti kao primjerice korelacija proizvodnje maslaca u Bangladešu i indeksa dionica S&P 500. Također, rudarenjem podataka dođe se do netočnog zaključka da primjerice pobjeda ekipe iz zapadnog dijela lige u američkom nogometu implicira porast dionica na burzi. Poznat je citat da „uz dovoljno vremena, dovoljno pokušaja i dovoljno mašte, skoro svaki skup podataka može generirati potpuno nesuvisle informacije“.

Generalno, postoje četiri glavne zamke prilikom modeliranja tehnikom rudarenja podataka i to su:

- uvijek postoji izazov za modeliranjem „čudnih“ podataka ili „čudnog“ ponašanja uzorka podataka
- može se pronaći dokaz za svaku teorijsku pretpostavku ako se pusti računalni proces da dovoljno dugo kopa po podacima,
- zaključci imaju više smisla ako postoji plauzibilna teorija koja to može potkrijepiti, ali „zabavni“ zaključak sakriti slabosti u podacima,
- što više faktora ili karakteristika se razmatra u skupu podataka, to je veća vjerojatnost da će se tehnikom rudarenja podataka pronaći određena poveznica bez obzira da li je opravdana ili ne.

Nadalje, prilikom korištenja tehnike rudarenja podataka valja zadržati određeni oprez i nikako ne koristiti rudarenje podataka kao zamjenu za izravne deterministčke metode. Predmetnu metodu treba koristiti kao nadopunu za postojeće dokazane metode ili za inicijalna istraživanja određenih korelacija te za generiranje signala ranog upozorenja koji se ne mogu generirati klasičnim deterministčkim metodama [L 75].

Ovim radom se ne definira da su predmetne nedeterministčke metode bolje, već se sugerira prednost fleksibilnosti istih metoda u određenim primjenama.

3.1.4 Analiza velikih skupova podataka

Analiza velikih skupova podataka (eng. Big Data Analysis) je proces ispitivanja velikih i raznovrsnih skupova podataka - tj. Velikih podataka - otkrivanja skrivenih obrazaca, nepoznatih korelacija, tržišnih trendova, preferencija korisnika i drugih korisnih informacija koje mogu pomoći organizacijama da donose više informirane poslovne odluke. Analiza velikih skupova podataka ispituje velike količine podataka za otkrivanje skrivenih obrazaca, korelacija i drugih spoznaja.

Većina organizacija, uključujući odnedavno i operatere elektroenergetskih sustava, primjećuje da ako obuhvaćaju sve podatke koji se prenose u svoje poslovanje, mogu primijeniti analitiku velikih količina podataka i dobiti značajnu vrijednost od iste. No čak i 1950-ih, desetljeća prije nego što je itko izgovorio pojam "velike količine podataka", tvrtke su koristile osnovnu analizu (u osnovi brojevi u proračunskoj tablici koja je ručno pregledana) kako bi otkrili uvide i trendove u podacima i izvukli korisne informacije.

Međutim, nove okolnosti i postignuća odnosno pogodnosti koje analiza velike količine podataka donosi na određeni skup podataka su brzina i učinkovitost. Dok je prije nekoliko godina organizacija prikupljala informacije, pokrenula analizu i otkrila informacije koje bi se mogle koristiti za buduće odluke, danas se može identificirati kritične podatke za neposredne i brze odluke. Sposobnost bržeg rada - i ostati agilna - daje operaterima dodatnu učinkovitost i prednost koju nisu imali prije.

Analiza velike količine podataka pomaže organizacijama operaterima da iskoriste svoje podatke i koriste ih za ranije prepoznavanje novih mogućnosti, ali i kritičnih stanja npr. u pogonu mreže. To zauzvrat vodi do učinkovitijeg upravljajna i donošenja odluka u korištenju kritične infrastrukture kao što je elektroenergetski sustav.

U svom izvješću Big Data in Big Companies, Direktor istraživačkog odjela IIA Tom Davenport intervjuirao je više od 50 tvrtki kako bi razumjeli kako su koristili velike količine podataka [L 78]. Našao je da se dodatna vrijednost postiže na sljedeće načine:

- Smanjenje troškova. Velike podatkovne tehnologije kao što su Hadoop i analize temeljene na tehnologijama u oblaku (eng. Cloud technologies) donose značajne prednosti u pogledu pohrane velikih količina podataka - a mogu identificirati i učinkovitije načine poslovanja.
- Brže i bolje odlučivanje. Uz brzinu Hadoop i analize u memoriji, u kombinaciji sa sposobnošću analize novih izvora podataka, operateri mogu odmah analizirati podatke - i donositi odluke na temelju proteklih analiza.
- Novi proizvodi i usluge. S mogućnošću procjene potreba kupaca i kroz analitiku postižu se mogućnosti da korisnicima pruže dodatne usluge. Davenport ističe da s velikim analitičkim podacima više tvrtki stvara nove proizvode kako bi zadovoljile potrebe kupaca.

Brojne prednosti nesumnjivo će postojati i u korištenju predmetnih tehnika u vođenju elektroenergetskih kompanija i njezinih pojedinih segmenata, a to je najbolje ilustrirano na sljedećoj slici.



Slika 3.3 Kvalitativni grafički prikaz prednosti aplikacija rudarenja velikih količina podataka

Sukladno svemu navedenom može se očekivati u budućnosti sve veće korištenje aplikacija temeljenih na analizi velikih količina podataka u elektroenergetskim tvrtkama i sustavima.

3.2. OSNOVNE ANALIZE I PROCESI RUDARENJA PODATAKA

3.2.1 Klasterizacija podataka

Klasterizacija podataka ili klaster analiza (eng. CA - Cluster analysis) je proces razdijeljivanja skupa podataka ili skupa promatranja u podskupove. Svaki podskup predstavlja jedan klaster, takav da su objekti unutar jednog klastera slični jedan drugome, te dovoljno različiti od podataka u drugim klasterima.

Različite metode i algoritmi klasterizacije podataka mogu rezultirati različitim klasterima na istom skupu ili uzorku podataka. Proces razdijeljivanja podataka obavlja se algoritmima odnosno takvo razdijeljivanje ne obavlja čovjek pa se iz takvih analiza mogu izvući zaključci i hipoteze koje prije nisu bile poznate unutar tog uzorka ili skupa podataka.

Klasterizacija se naširoko koristi u mnogim aplikacijama kao što su poslovna inteligencija, uzorkovanje slika, pretrage web-a, biologija, sigurnost te naravno analize u elektroenergetskom sustavu i sektoru u cjelini.

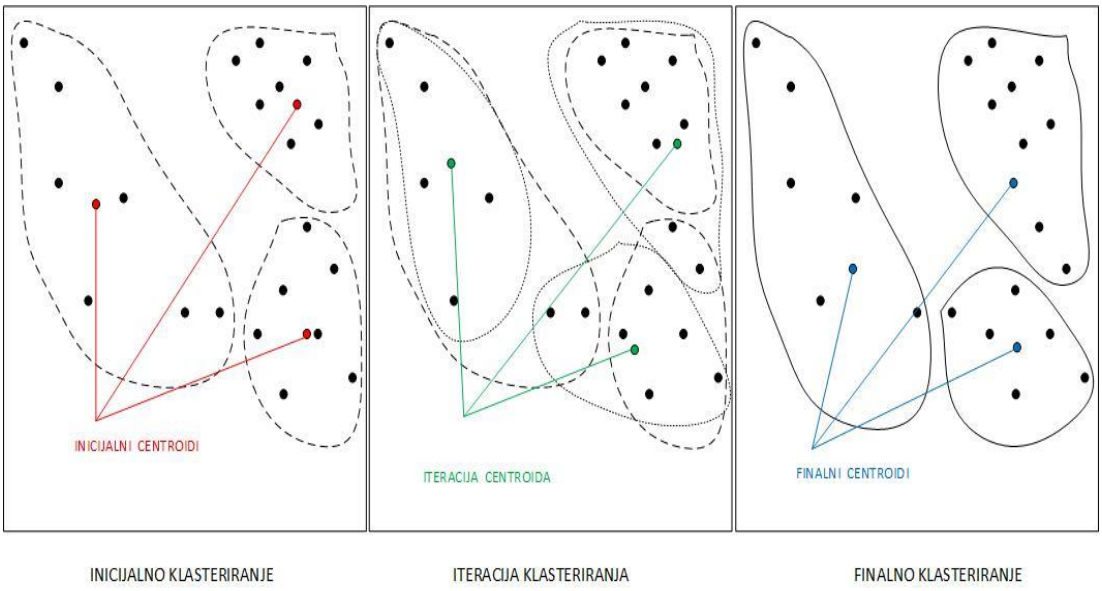
Kao funkcija rudarenja podataka, klasterizacija podataka može biti korištena kao samostalni alat u svrhu analize distribucije podataka, u svrhu promatranja karakteristika svakog klastera te za fokusiranje na pojedini skup klastera podataka. Također, može služiti kao predprocesni korak za druge algoritme kao što je npr. Klasifikacija podataka, a koji onda mogu obavljati analize na detektiranim klasterima podataka i odabranim atributima ili karakteristikama. Upravo takav pristup korišten je i u ovom radu pri čemu je klasterizacija podataka poslužila kao predproces i definiranje različitih klastera podataka, a koji kasnije služe za klasifikaciju novih mjernih podataka u tako definirane skupove.

Klasterizacija se često naziva segmentacija podataka u nekim aplikacijama budući da dijeli velike skupove podataka u skupine ili podskupine prema njihovoj sličnosti.

Niti za jedan zapis nije definiran i pripadajući klaster podataka prilikom učenja, odnosno učenje se obavlja na skupu odnosno uzorku podataka za koje nisu unaprijed poznati pripadajući klasteri podataka. Zbog toga metoda klasterizacije spada u tzv. Metode nenadziranog učenja (eng. Unsupervised Learning Methods).

Klasterizacija podataka je tako multivarijatni postupak za otkrivanje prirodnih grupacija u podacima. Klasifikacija klasterskih analiza temelji se na postavljanju predmeta u više ili manje homogene skupine i na takav način da se otkrije odnos između skupina. Ova analiza nema osnove unutar statističke teorije i heuristička je u prirodi. Klasterizacija podataka zahtijeva donošenje odluka koje se odnose na izračun klastera, odnosno odluke koje imaju snažan utjecaj na rezultate kasnije klasifikacije podataka. Izuzetno je korisna

za izradu ili odair skupina za kasniju klasifikaciju grupa ili objekata [L 58] . Proces klasterizacije slikovito je prikazan na sljedećoj slici.



Slika 3.4 Kvalitativni grafički prikaz metode klasterizacije

Metode klasterizacije mogu biti odozgo prema dolje i pri tom upotrebljavaju logičku podjelu ili odozdo prema gore i pri tom koriste agregaciju. Agregiranje procedura koje se temelje na kombiniranju slučajeva procjenom sličnosti su najčešće i najpopularnije metode te će biti u središtu ovog rada.
Osnovne metode klasterizacije mogu se podijeliti u tri skupine:

- Particijske metode
- Hijerarhijske metode
- Metode temeljene na gustoći

Temeljni zahtjevi na klasterizaciju pri rudarenju podataka su sljedeći:

- Skalabilnost (Pojedini algoritmi klasterizacije rade dobro na manjem skupu podataka, a lošije na većem skupu podataka. Stoga je potrebno da je algoritam klasterizacije skalabilan odnosno da može dati stabilne rezultate na temelju uzorka.
- Sposobnost obrade različitih vrsta atributa (pojedine aplikacije mogu zahtijevati obradu različitih vrsta podataka kao što su numerički binarni, kategorički, ordinalni itd.)
- Nesferikalni oblici klastera podataka (obično su klasteri podataka, nakon završetka procesa klasterizacije, ako ih se prikaže grafički sferikalni ili vrlo slični tome. Potrebno je omogućiti druge vrste oblika klastera podataka koji su pogodni za pojedine analize.)

- Sposobnost rješavanja podataka koji spadaju u šum (većina stvarnih podataka obuhvaća i dio podataka koji spadaju u šum. Sukladno tome, svaka ovakva metoda mora imati sposobno rješavanja tog problema.)
- Neosjetljivost na redoslijed ulaznih podataka (svaka klasterizacija podataka mora biti imuna u smislu rezultata na input novih podataka i krajnji rezultat klasterizacije se ne smije razlikovati dramatično u smislu grupiranja u klastere.)
- Interpretabilnosti i uporabljivost (Korisnici žele da su krajnji rezultati interpretabilni, razumljivi i uporabljivi tj. korisni.)

Treba se pobrinuti da skupine odnosno klasteri imaju na neki način smisla i nisu proizvoljne ili umjetne. Da bi se to učinilo, tehnike klasterizacije pokušavaju imati više zajedničkog s vlastitom skupinom nego s drugim skupinama, minimalizacijom internih varijacija, dok maksimiziraju varijacije između skupina.

Dva ključna koraka unutar klasterske analize su mjerenje udaljenosti između objekata i grupiranje objekata na temelju nastalih udaljenosti (veze). Udaljenost pruža mjeru sličnosti između objekata i može se mjeriti na različite načine, kao što su Euklidska i manhatanska metrička udaljenost. Kriteriji koji se koriste za povezivanje (grupiranje) varijabli mogu se provesti i različitim načinima, što rezultira značajnim promjenama u rezultatima. Poveznice se temelje na tome kako se mjeri povezanost između skupina. Na primjer, jednostavna veza ili najbliža susjedna udaljenost odnosno K-srednja udaljenost (eng. K-nearest), mjeri udaljenost od najbližeg objekta u grupi, dok najudaljenija veza ili potpuna veza mjeri udaljenost između najudaljenijih objekata. Ove veze temelje se na vrijednostima pojedinačnih podataka unutar grupa, dok je prosjek između grupne veze temeljen na udaljenosti od svih objekata u grupi. Centroidna veza ima novu vrijednost, koja predstavlja grupu centroid, koja se uspoređuje s neograničenom točkom za vaganje uključivanja. Wardova metoda je varijansa koja se temelji na varijacijama skupine koja se procjenjuje kako bi omogućila grupiranje. Grupa koja vidi najmanji porast varijance s iterativnim uključivanjem varijable dobit će varijablu.

Standardizacija varijabli poduzeta je kako bi se omogućila usporedba varijabli s ciljem smanjenja pristranosti u ponderiranju koja može biti rezultat različitih mjernih skala i raspona. Format Z bodova računa za razlike između srednjih vrijednosti i smanjuje standardno odstupanje kada varijable imaju multivarijatnu normalnost.

Idealan broj skupina koje treba uspostaviti može se procijeniti grafički ili numerički. Grafički se broj skupina može procijeniti pomoću grafa ili dendrograma. Dendrogram je podijeljen u točki koja će podijeliti slučajeve u klaster na temelju grupiranja do točke u kojoj je došlo do bisekcije. Numerički

se broj slučajeva može procijeniti na rasporedu aglomeracije, računajući od dna do mjesta gdje se javlja značajan prekid nagiba (brojeva).

Optimalan broj skupina može se procijeniti a priori na poznavanju skupa podataka. Skretna ploha koja pretvara dendrogram u krivulju profila imat će ekstremnu točku infleksije gdje se broj grupa značajno mijenja. Broj grupa iznad točke infleksije prikladan je broj grupa. Optimalnost klastera može se procijeniti prema tome kako se "prirodno" klasteri pojavljuju.

U ovom radu korištena je klasterizacija metodom K-srednjih vrijednosti s euklidskom udaljenosti.

3.2.2 Klasifikacija podataka

Klasifikacija podataka (eng. Data Classification) je oblika analize podataka pri kojem se izrađuju matematički modeli koji opisuju najbitnije klase odnosno razrede podataka. Takvi matematički modeli, koji se nazivaju klasifikatori (eng. Classifiers), služe za predviđanje pojedinih kategoričkih (diskretnih i neporedanih) razreda odnosno klasa podataka.Na takav način se primjerice mogu izraditi matematički modeli za kategoriziranje pojedinih pogonskih stanja elektroenergetskih sustava odnosno generalno modu poslužiti za bolje razumijevanje velike količine podataka.

Brojne klasifikacijske metode su posljednjih desetljeća predlagane od strane istraživača u području prirodnih i tehničkih znanosti, a u svrhu strojnog učenja, prepoznavanja uzoraka, statistike i ostalih područja. Najčešća primjena klasifikacijskih metoda je u području otkrivanja prijevara, medicinske dijagnostike, predikcije performansi te sličnih tehničkih i prirodoslovnih područja.

Prilikom definiranja klasifikacijske metode bitno je definirati klasifikacijske razrede i to na način da su klasifikacijski razredi odnosno klase podataka predstavljene odnosno modelirane diskretnim vrijednostima koje ujedno nisu strogo poredane.

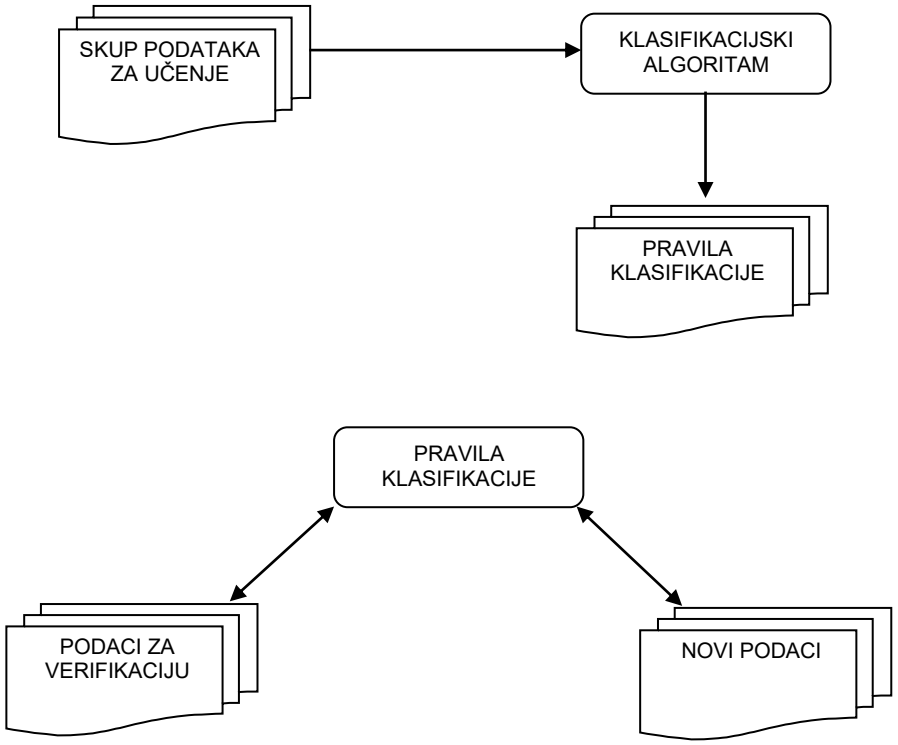
Klasifikacija podataka je proces koji se sastoji od dva osnovna koraka i to:
- Faza učenja (eng. Learning step, training phase),
- Faza klasifikacije (eng. Classification step).

Prilikom faze učenja, klasifikacijski model se izrađuje dok se prilikom faze klasifikacije izrađeni model koristi za predviđanje klasifikacijskih razreda pojedinih skupova odnosno vektora podataka.

U prvom koraku, odnosno u fazi učenja, klasifikatori i pripadajući modeli se izrađuju korištenjem predefiniranih skupova podataka i koncepata. Klasifikacijski algoritam pri tom izrađuje klasifikacijski model analizom

postojećeg skupa podataka odnosno „učenjem iz“ skupa podataka za učenje (eng. Training set). Skup podataka za učenje definiran je iz postojećih zapisa baze podataka i pripadajućih odnosno pridijeljenih poznatih klasa podataka.

Zapis odnosno n-torka podataka **X**, definirana je n-dimenzionalnim atribut vektorom **X=(x1, x2, x3,...xn)**. čime se opisuju mjerenja *n* podataka odnosno atributa. Za svaku n-torku podataka odnosno za svaki pojedini zapis pretpostavlja se da pripada pojedinoj klasi podataka odnosno pridjeljuje se pojedinoj klasi podataka. Pojedine klase podataka su, kako je prethodno već definirano, diskretne i neporedane [L 58].



Slika 3.5 Kvalitativni grafički prikaz metode klasifikacije

Za svaki zapis definirana je i klasa podataka prilikom učenja, odnosno učenje se obavlja na skupu odnosno uzorku podataka za koje su poznate klase podataka. Zbog toga metoda klasifikacije, za razliku od metode klasterizacije, spada u tzv. Metode nadziranog učenja (eng. Supervised Learning Methods).

Najzastupljenije metode klasifikacije su sljedeće:

Metoda diskriminacije analize
Ova metoda konstruira niz linearnih funkcija varijabli prediktora i koristi te funkcije za predviđanje klase nove promatranje s nepoznatom klasom. Uobičajene upotrebe ove metode uključuju: klasificiranje kredita, kreditne kartice ili podnositelja zahtjeva za osiguranje u niske ili visoke rizične kategorije, razvrstavanje studentskih prijava za ulazak u koledž, klasificiranje pacijenata s rakom u kliničke studije itd.

Logistička regresijska metoda
Varijanta obične regresije koja se koristi za predviđanje varijable odgovora, ili izlazne varijable, kada je varijabla odgovora dihotomna varijabla (varijabla koja uzima samo dvije vrijednosti kao što je da/ne, uspjeh/neuspjeh, itd.).,

Metoda stabla klasifikacije (stabla odlučivanja)
Ova vrsta klasifikacije također je poznata kao "stablo odlučivanja" (eng. Decision Tree) i dobar je izbor kada je cilj generirati lako razumljiva i objašnjena "pravila" koja se mogu prevesti na SQL ili jezik upita (eng. Query).

Naivna Bayesova metoda
Ova metoda klasifikacije najprije skenira skup podataka za učenje i pronalazi sve zapise u kojima su prediktorske vrijednosti jednake. Tada se utvrđuje najčešća klasa cijelog skupa i dodjeljuje se čitavoj zbirci promatranja. Ako je nova promatranja prediktorska varijabla jednaka prediktorskoj varijabli ove skupine, nova promatranja će biti dodijeljena ovoj klasi. Zbog jednostavnosti ove metode potrebni su veliki broj zapisa za točnost.

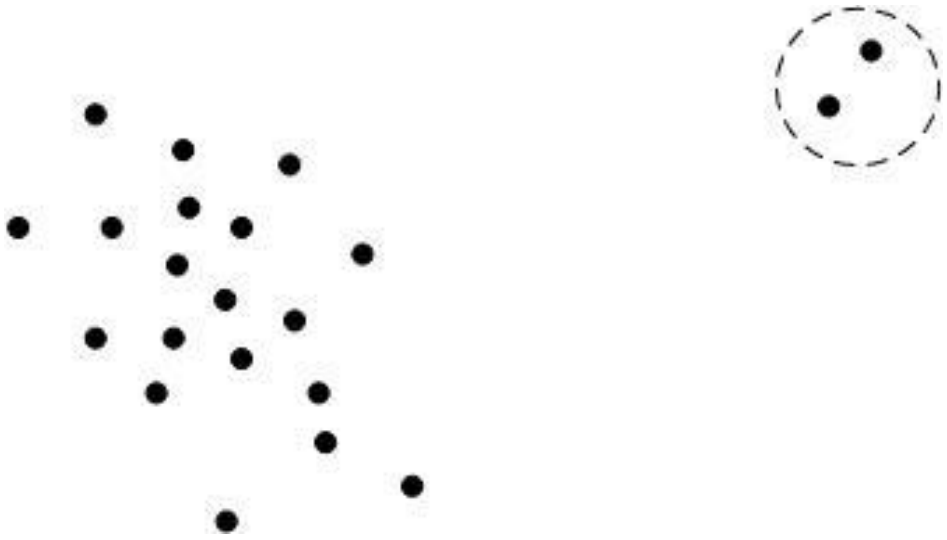
Sukladno svemu navedenom, odabrana je metoda stabla klasifikacije odnosno stabla odlučivanja zbog generiranja lako razumljivih pravila koja se mogu koristiti u SQL ili drugom računalnom jeziku za upite.

3.2.3 Detekcija outliera

Vrlo često kod velikih setova odnosno velikih skupova podataka, postoje uzorci podataka koji se ne mogu uklopiti u generalne karakteristike cjelokupnog skupa svih promatranih podataka. Takvi uzorci, koji su signifikantno odnosno značajno inkonzistentni s ostatkom skupa podataka, nazivaju se outlieri (eng. Outliers).

Outlieri mogu biti uzrokovani mjernim greškama ili mogu biti rezultat inherentne varijabilnosti podataka. Algoritmi rudarenja podataka općenito nastoje minimizirati utjecaj outliera na konačni model ili ih eliminirati u pretprocesnoj fazi. Ukoliko se radi eliminacija outliera u pretprocesnoj fazi obrade podataka, analitičar mora biti jako oprezan ukoliko se radi o automatskoj eliminaciji, budući da se, ako se radi o točnim podacima, gube dragocjene skrivene informacije.

Detekcija outliera ima veliku primjenu i u grafičkim metodama, naročito za dvodimenzionalne i trodimenzionalne matematičke probleme. Međutim, kod višedimenzionalnih problema postoji problem nemogućnosti valjane i precizne grafičke interpretacije takvih situacija i stanja. Najjednostavniji primjer pri tom predstavlja jednodimenzionalni uzorak, gdje se detekcija outliera svodi na određivanje standardne devijacije [L 58].



Slika 3.6 Kvalitativni grafički prikaz metode detekcije outliera

Outlieri su uvijek zanimljivi za istraživanje budući da se obično takvi podaci ne generiraju jednakim mehanizmom kao i preostali set podataka. Stoga je kod detekcije outliera izuzretno bitno istražiti i opravdati razlog ZAŠTO dolazi do detekcije outliera i ZAŠTO su oni generirani nekakvim drugim mehanizmom.

Generalno se outlieri mogu svrstati u tri kategorije i to:
- Globalni outlieri,
- Kontekstualni (uvjetni) outlieri,
- Kolektivni outlieri.

U određenom skupu podataka, jedan podatak predstavlja globalni outlier ukoliko ima značajne devijacije u odnosu na preostali set podataka. Globalni outlieri ujedno predstavljaju najjednostavniji oblik outliera. Za detekciju globalnih outliera, kritično je potrebno izraditi prikladna mjerenja devijacija u odnosu na primjenu podataka koja je predmet istraživanja.

Kontekstualni outlieri predstavljaju podatke unutar skupa podataka koji imaju značajne devijacije u odnosu na specifični kontekst promatranog objekta ili procesa. Pri tome se kontekst mora specificirati kao dio definicije same problematike koja je predmet proučavanja. Primjerice, temperatura koja u Dalmaciji predstavlja outlier za određeno doba godine, u Lici može predstavljati sasvim normalan skup podataka. Jednako vrijedi i za brzine vjetra itd.

Kolektivni outlieri predstavljaju podskup podataka ukoliko takav jedan vektor podataka ima značajnu devijaciju u odnosu na preostali skup podataka. Ono što je bitno, individualni podaci unutar tog podskupa ne moraju nužno predstavljati outliere. Primjerice, set mjernih podataka izmjeren u jednom danu ima identične vrijednosti koje same za sebe ne predstavljaju outliere, ali takav cjelokupni skup se mora podrobnije promotriti jer je očigledno došlo do kvara mjernog uređaja i slično.

Glavni izazovi prilikom detekcije outliera jesu istodobno modeliranje normalnih objekata i outliera unutar istog modela. Vrlo je teško, a neki istraživači kažu i nemoguće, izgraditi prikladni model koji će „pokriti“ sva normalna stanja u određenoj primjeni te je vrlo teško podvući granicu između normalnih podataka i outliera, naročito za višedimenzionalne probleme. Također, različite aplikacije zahtijevaju i različit pristup detekciji outliera. Osim toga, potrebno je razlikovati outliere od šuma (eng. Noise). Šum može biti prisutan u podacima u obliku devijacija u atributima podataka ili čak u podacima kojih nema odnosno koji nedostaju. To može stvoriti određene distorzije podataka pa čak i zamagliti distinkciju između normalnih objekata i outliera.

3.2.4 Indukcija stabala odlučivanja

Indukcija stabala odlučivanja spada u procese statističke teorije učenja (eng. SLT – Statistical Learning Theory) odnosno teorije Vapnik-Chervonenkis (VC Theory). Ista metoda predstavlja izgradnju i učenje modela odlučivanja baziranog na razgranatom grafičkom modelu sastavljenom od pojedinih čvorišta (eng. Nodes) i grana (eng. Branches). Pri tome svako pojedino unutarnje čvorište označava test na određeni atribut podataka, a svaka grana predstavlja rezultat tog testa. Svako terminalno odnosno krajnje čvorište sadržava oznaku klase odnosno razreda podataka.

Proces indukcije stabala odlučivanja je proces učenja stabala odlučivanja iz skupa podataka za učenje, odnosno skupa podataka kojima su već dodijeljene klase odnosno razredi. Stablo odlučivanja, pri tome predstavlja grafičku stablastu strukturu u kojoj svako unutarnje čvorište predstavlja test odnosno pitanje na atribut, svaka grana predstavlja rezultat tog testa odnosno pitanja, a svako krajnje odnosno terminalno čvorište predstavlja oznaku klase odnosno dodijeljenog razreda.

Sukladno tome, stabla odlučivanja se koriste vrlo često u izradi algoritama odlučivanja odnosno za klasifikaciju podataka. Pri tome se vektoru podataka **X**, koji ima nepoznate klase odnosno razrede, testiraju atributi korištenjem pravila unutar stabla odlučivanja.

Konstrukcija odnosno izgradnja stabala odlučivajna ne zahtijeva poznavanje domene izvora podataka, niti poznavanje postavki pripadajućih parametara. Stoga je korištenje stabala odlučivanja vrlo prikladno za istraživačke svrhe. Stabla odlučivanja pri tom mogu koristiti višedimenzionalne podatke. Koraci učenja i klasifikacije podataka u takvim strukturama su prilično jednostavni i generalno takvi klasifikatori imaju popriličnu točnost.

Najčešće korištene metode indukcije stabala odlučivanja su [L 57]:
- C4.5
- ID3 (eng. Iterative Dichotomiser)
- C&RT (eng. Classification and Regression Trees)

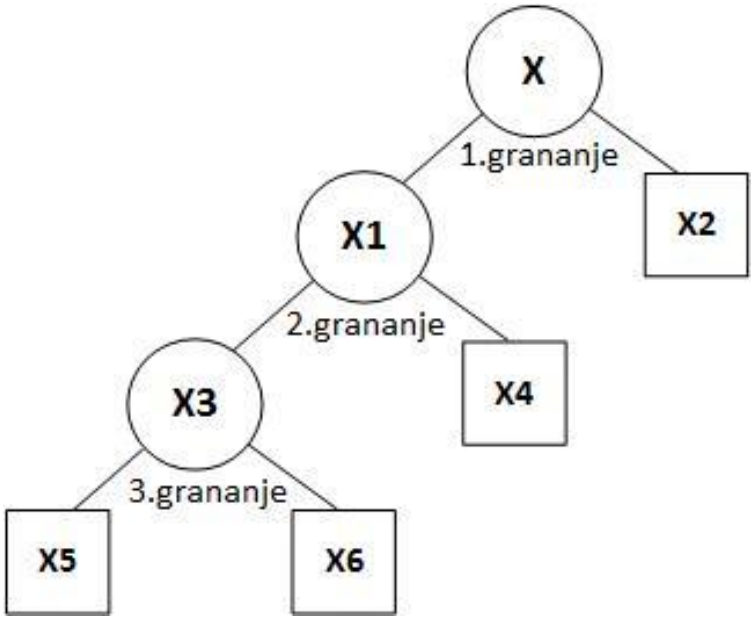
U ovom radu korištena je metoda klasifikacijskih i regresijskih stabala (C&RT) opisana u knjizi Breimana i ostalih iz 1984., a koja se definira na sljedeći način.

Pretpostavimo da postoji skup podataka ili vektor **X** sa n članova koji se trebaju raspodijeliti u *J* klasa, odnosno da postoji skup klasa C, pri čemu je

$$C = \{1, 2, 3, ...J\} \qquad \textbf{(3.1)}$$

Sistematski način pridjeljivanja određene klase iz skupa C, pojedinom članu vektora **X**, predstavlja klasifikator odnosno klasifikacijsku funkciju.

Klasifikacijsko i regresijsko stablo (C&RT) konstruira se repetivitnim dijeljenjem podskupova od **X**, u dva dodatna podskupa, pri čemu je inicijalni početak u samom skupu **X** [L 58]. Kvalitativni prikaz strukture stabla odlučivanja prikazan je na sljedećoj slici.



Slika 3.7 Kvalitativni grafički prikaz strukture stabala odlučivanja

Na prethodnoj slici vrijede sljedeće matematičke relacije iz teorije skupova:

$$\mathbf{X} = \mathbf{X1} \cup \mathbf{X2} \qquad (3.2)$$

$$\mathbf{X1} = \mathbf{X3} \cup \mathbf{X4} \qquad (3.3)$$

$$\mathbf{X3} = \mathbf{X5} \cup \mathbf{X6} \qquad (3.4)$$

Pri tome se skupovi **X2, X4, X5** i **X6,** nazivaju krajnjim ili terminalnim podskupovima.

Samo grananje podskupova u dvije dodatne grane stabla obavlja se korištenjem logičkih uvjeta primijenjenih na koordinate odnosno svojstva i atribute skupa **X,** odnosno podskupova u nižim slojevima stabla. Najjednostavniji logički uvjeti primjerice predstavljaju znakovi jednakosti i nejednakosti.

Stoga se cjelokupna konstrukcija odnosno izgradnja stabala odlučivanja svodi na tri osnovna koraka:

1) Selekciju podskupova pri grananju,
2) Odlučivanje kad proglasiti čvorište krajnjim (terminalnim),
3) Pridjeljivanje svakog krajnjeg čvorišta određenoj klasi podataka.

Selekcija podskupova pri grananju osnovnog skupa podataka i ostalih podskupova u nizu, polazi od osnovnog problema, kako iskoristiti postojeće tj. poznate podatke iz skupa poznatih podataka ***L***, za određivanje uvjeta pojedinog grananja. Fundamentalna ideja je da se svako grananje napravi na način da u svakom rezidualnom podskupu podaci budu „pročišćeni“. Prilikom samog grananja potrebno je odrediti tri kriterija grananja:

a) Odabir vrste pitanja na čvorištima,
b) Odabir najboljeg parametra pitanja na svakom čvorištu za grananje,
c) Određivanje optimalne veličine stabla odlučivanja.

Pitanja za odlučivanje na čvorištima odabiru se iz standardiziranog seta pitanja i odabir pitanja predstavlja iterativni postupak zajedno s ostalim odabirima parametara stabla i određivanjem optimalne veličine stabla.

Odabir najboljih parametara pitanja na svakom čvorištu započinje definiranjem dviju novih veličina:

- Razmjer n-tog čvorišta - $p(j/t)$
  kao udio čvorišta koja pripadaju klasi j, uz $j \in C = \{1, 2, 3, ...J\}$
  takvi da vrijedi
  $p(1/t) + p(2/t) + ... + p(j/t) = 1$

- Nečistoća n-tog čvora - $i(t)$
  kao nenegativna funkcija čiji su argumenti funkcije prethodno definirani razmjeri - $\Phi [p(1/t), p(2/t),...p(j/t)]$ takva da
  $\Phi [1/j, 1/j,... 1/j] = \max$
  $\Phi [1, 0,... 0] = 0$
  $\Phi [0, 1,... 0] = 0$
  Odnosno nečistoća čvora je najveća kad su klase ravnomjerno raspodijeljene u čvoru, a najmanja kad čvor sadrži samo jednu klasu.

Iterativni postupak traje dok se ispod određene granice ne smanji povećanje nečistoće čvorišta na sljedećoj operaciji grananja – *s,* na čvorištu *t,* odnosno:

$$\Delta i(s,t) = i(t) - p_L i(t_L) - p_R i(t_R) \qquad \textbf{(3.5)}$$

gdje su:

$\Delta i(s,t)$	-	povećanje nečistoće čvorišta na sljedećoj operaciji grananja
$i(t)$	-	nečistoća polaznog čvorišta
p_L	-	razmjer čvorišta granatog na lijevu stranu od polaznog
$i(t_L)$	-	nečistoća čvorišta granatog na lijevu stranu od polaznog
p_R	-	razmjer čvorišta granatog na desnu stranu od polaznog
$i(t_R)$	-	nečistoća čvorišta granatog na desnu stranu od polaznog

Smatra se da je stablo odlučivanja generirano odnosno inducirano nakon što se veličina $\Delta i(s,t)$ spusti ispod zadate točnosti [L 48].

Niti jedno generirano stablo odlučivanja nije do kraja točno i u svakom stablu odlučivanja dolazi do veće ili manje pojave misklasifikacije (eng. Missclassification) odnosno do krivog postavljanja pojedinih vrijednosti iz skupa podataka u krive klase podataka. Upravljanje misklasifikacijom obavlja se definiranjem tzv. Troškova misklasifikacije (eng. Missclassification costs).

Troškovi misklasifikacije definiraju se kao ponderske vrijednosti za svaku pojedinu krivu klasifikaciju. Nije svejedno da li je krivo klasificiran podatak iz prve klase u treću ili iz druge klase u četvrtu klasu podataka. Konačna klasifikacija obavlja se minizacijom objektne sljedeće objektne funkcije:

$$min\Sigma_j \, C(i/j)p(j/t) \qquad \textbf{(3.6)}$$

gdje je

C(i/j) - definirani trošak misklasifikacije
p(i/j) - razmjer n-tog čvorišta

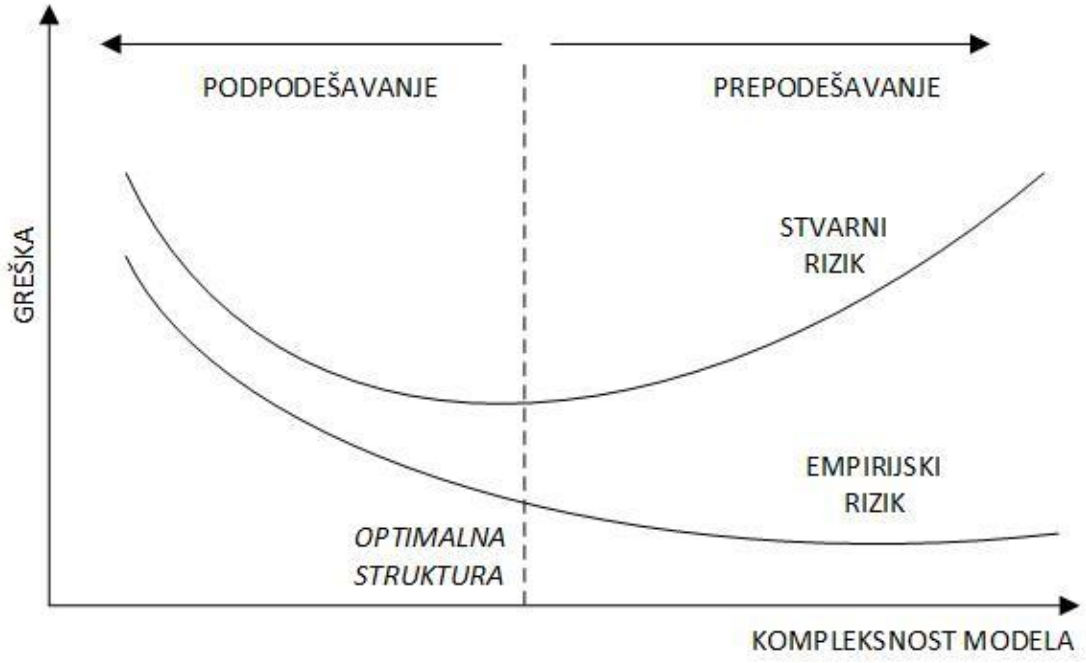
Trošak misklasifikacije, kako je ranije rečeno, definira se za svaku pojedinu misklasifikaciju među klasama podataka. Kvalitativni primjer dat je u sljedećoj tablici. U stupcima su predviđene vrijednosti, a u redovima postojeći podaci.

Tablica 3-1 Kvalitativni primjer troškova misklasifikacije

	KLASA 1	KLASA 2	KLASA 3
KLASA 1	1	2	3
KLASA 2	2	1	2
KLASA 3	3	2	1

Iz ovog primjera vidljivo je da je najveća greška kriva klasifikacije podataka iz prve klase u treću i obratno. Definiranjem ovih pondera moguće je upravljati misklasifikacijom [L 48].

Nakon što je izgrađeno stablo odlučivanja, mnoge grane stabla će reflektirati anomalije u ulaznom skupu podataka zbog netočnih podataka, podataka šuma ili ostalih vrsta outliera. Ova pojava naziva se često i prepodešavanje (eng. Overfitting). Pojava prepodešavanja znači da stablo odlučivanja nije poprimilo svoju optimalnu strukturu [L 57], kako je to slikovito prikazano na grafičkom prikazu na sljedećoj slici.



Slika 3.8 Kvalitativni grafički prikaz pojave prepodešavanja kod indukcije stabala odlučivanja

Za sprečavanje pojava prepodešavanja, koristi se proces obrezivanja stabla (eng. Tree Pruning process) čime se ujedno određuje i optimalna veličina stabla odlučivanja. Metode obrezivanja stabala odlučivanja koriste statističke mjere za uklanjanje najmanje pouzdanih grana stabla. Tako obrađena stabla metodom obrezivanja, manja su u dimenzijama i kompleksnosti, a samim tim i lakša za rukovanje i razumijevanje. Obično su ta stabla odlučivanja brža i bolja u točnom klasificiranju neovisnih podataka. Jednostavnija metoda obrezivanja stabala odlučivanja jest pretprocesna odnosno zaustavljanje daljnje izgradnje stabla u određenom čvorištu po određenom kriteriju. Puno češći slučaj je postprocesna metoda odnosno analiza svih podstabala nakon konačnog zaustavljanja algoritma.

U metodi V-preklopne unakrsne validacije (eng. V-fold cross validation), izvorni uzorak nasumično je podijeljen u *V* podskupova jednakih veličina. Od *V* poduzoraka, jedan poduzorak zadržan je kao skup podataka za provjeru i testiranje modela, a preostali *V*-1 poduzoraka koriste se kao podaci za učenje. Proces preklopne unakrsne validacije ponavlja se *V* puta, pri čemu se svaki od *V* uzoraka koristi točno jednom kao skup podataka za provjeru valjanosti. *V* rezultata tada se mogu uprosječiti kako bi se proizvela jedna procjena. Prednost ove metode tijekom ponovljenog slučajnog uzorkovanja je ta da se sva opažanja koriste za učenje modela, a svako se promatranje koristi za validaciju točno jednom. Najčešće se koristi deseterostruko unakrsno validiranje, ali općenito *V* ostaje nefiksirani parametar.

U ovom radu, za sprečavanje prepodešavanja, korištena je metoda V-preklopne unakrsne validacije (eng. V-fold cross validation) koja spada u postprocesne metode. Predmetna metoda opisuje u radu M.Stonea iz 1977.

3.2.5 Trendovi i istraživanja u rudarenju podataka

Rudarenje podataka predstavlja poprilično mlado istraživačko područje. U svojoj kratkoj povijesti od 1980-ih godina napravilo je značajan razvoj i napredak pokrivajući široki spektar aplikacija. Danas se rudarenje podataka koristi u nizu primjena i područja i danas su dostupni brojni sustavi i servisi u tom području.

Neki najbitniji trendovi i istraživanja u posljednje vrijeme u području rudarenja podataka vezani su za sljedeće teme:

- Rudarenje kompleksnih tipova podataka,
- Novi pristupi rudarenju podataka,
- Primjene rudarenja podataka u području financija, inženjerstva itd,
- Društveni utjecaj rudarenja podataka uključivo zaštita osobnih podataka.

Kompleksni tipovi podataka predstavljaju sekvencijalne, grafičke i mrežne te ostale tipove kompleksnih podataka. Sekvencijalni podaci predstavljaju vremenske serije, simboličke sekvence (npr. Web klik stream podataka) te biološke sekvence (npr. DNA sekvence itd.). Grafičke i mrežne sekvence predstavljaju mrežno homogene (čvorišta i linije su istog tipa) ili nehomogene (čvorišta i linije su različitog tipa) mrežne podatke. Ostali tipovi kompleksnih podataka uključuju spacijalne podatke, spaciotemporalne podatke, multimedijske podatke, web podatke, tokove (streamove) podataka itd.

U području tehničkih znanosti, naročito elektrotehničkog područja najzanimljivije je proučavajne vremenskih serija podataka koje se sastoje od sekvenci numeričkih vrijednosti generiranih ponavljajućim mjerenjima u vremenskom periodu. Ove vrijednosti su tipično mjerene u jednakim vremenskim intervalima. Pri tome, vrlo često istraživanja uzoraka i sličnosti zahtijevaju istraživanja podskupova vremenskih podataka.

Takva istraživanja obuhvaćaju predradnje kao što su dimenzionalna redukcija i transformacija podataka vremenskih sekvenci odnosno nizova. Uslijed toga, vrlo često korištene metode predstavljaju diskretnu Fourierovu transformaciju (eng. DFT – Discrete Fourier Transformation), diskretnu valnu transformaciju (eng. DWT – Discrete Wavelet Transformation), dekompoziciju singularnih vrijednosti (eng. SVD – Singular Value Decomposition) temeljena na analizi principalnih komponenti (eng. PCA – Principal Component Analysis). Svim navedenim metodama, podaci ili signali se mapiraju odnosno translatiraju u kodomenski vektorski prostor gdje se obavljaju jednostavnije matematičke operacije, a rezultati se potom translatiraju natrag u domenski vektorski prostor.

Rudarenje podataka može se sustavno koristiti za vađenje podataka, iskorištavanje već dostupnih podataka iz područja mjerenja, računanja i centraliziranih baza podataka, za izgradnju ili poboljšanje modela, rano predviđanje abnormalnih scenarija i situacija (eng. SA – Situational

Awareness) odnosno kao rani signal upozorenja (eng. EWS – Early Warning Signal) na određenu nestabilnu ili nekontrolabilnu situaciju ili približavanje istog stanja.

Naravno, beskorisno je primijeniti podatkovno rudarstvo na neispravnu bazu podataka s visokim pogreškama mjerenja ili procjene podataka ili pokušati precizno procijeniti numeričke izlaze koji predstavljaju a priori visoku varijancu. Alat za rudarenje podataka objašnjava koliko je informacija pohranjeno u podacima koji se rudare (izvedeni model snažno ovisi o korištenom skupu podataka za učenje). Važan dio grešaka u rezultatima rudarenja podataka je zbog neizvjesnosti u modeliranju i stvaranju scenarija u bazi podataka u suprotnosti s realnim vjerojatnostima ponašanja elemenata sustava. Zato pogreške nemaju samo značenje, oni samo pružaju praktično sredstvo za usporedbu učinkovitosti različitih kriterija primijenjenih na istu bazu podataka.

Zasigurno najveći napori i istraživanja u ovom trenutku su usmjereni na područje analize velike količine podataka. Takav trend prisutan je u svim industrijama uključivo i elektroenergetske sustave, a zbog ranije opisanog generiranje ogromnih količina podataka. Te količine podataka će se u budućnosti sve više povećavati daljnjom digitalizacijom poslovanja i infrastrukture.

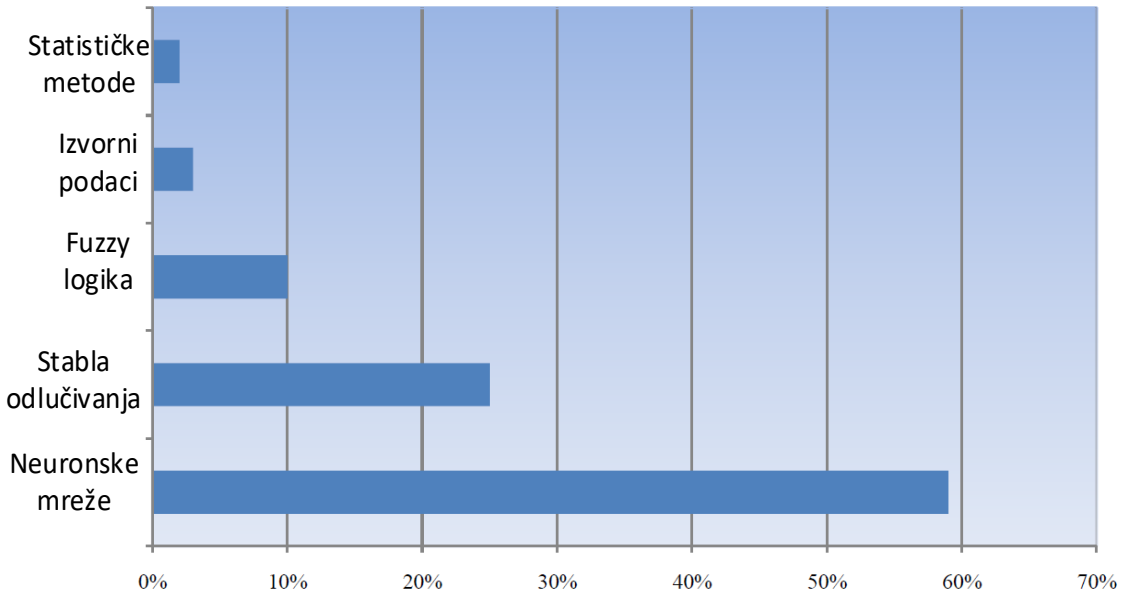
3.3. PRIMJENE RUDARENJA PODATAKA U EES-U

3.3.1 Najčešće tehnike rudarenja podataka u EES-u

Sa sve većim ekološkim, ekonomskim i tehničkim ograničenjima, moderni elektroenergetski sustavi prolaze kroz goleme transformacije na mnoge načine. Količine podataka generiranih u elektroenergetskim sustavima brzo rastu zbog velike baze pogonskih podataka te zbog daljnje digitalizacije poslovanja i infrastrukture kako je opisano u prethodnim poglavljima.

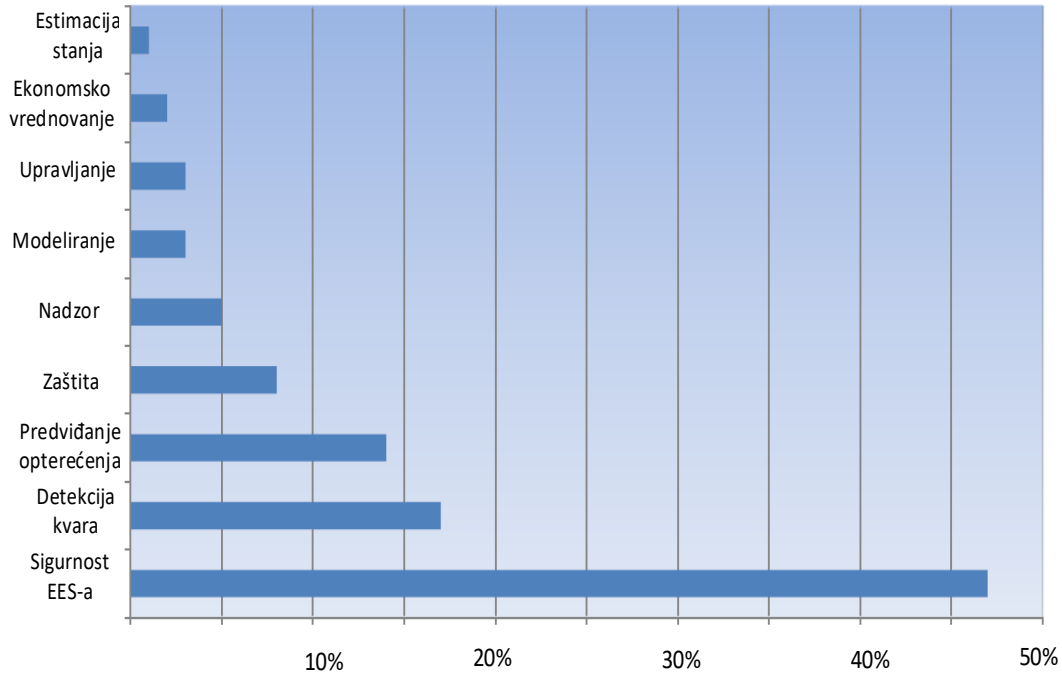
U posljednje vrijeme zbog otvorenosti tržišta električnom energijom, svaki, pa i najmanji propusti poprimaju iznimno visoke cijene i štete koje operateri elektroenergetskih sustava moraju nadoknaditi korisnicima mreže. Ponekad su ti propusti izvan kontrole operatora elektroenergetskog sustava. Pogon i planiranje elektroenergetskih sustava generiraju veliku količinu podataka i teško ih je izdvojiti korisne informacije iz ove velike baze podataka koja se kontinuirano koristi od strane operatera.

Rudarenje podataka, kao matematički alat, nameće se kao korisna tehnika i proces izdvajanja bitnih informacija i prethodno nepoznatih znanja iz skupa podataka. U posljednjih nekoliko godina publiciran je niz radova na temu primjene tehnike rudarenja podataka u pogonu, održavanju i upravljanju imovinom elektroenergetskih sustava. Pri tome su najčešće korištene tehnike rudarenja podataka prikazane na sljedećem dijagramu:



Slika 3.9 Kvalitativni grafički prikaz najčešće korištenih metoda rudarenja podataka u elektroenergetskim sustavima

Također, korištenje tehnike rudarenja podataka je najčešće u primjenama prikazanim na sljedećoj slici:

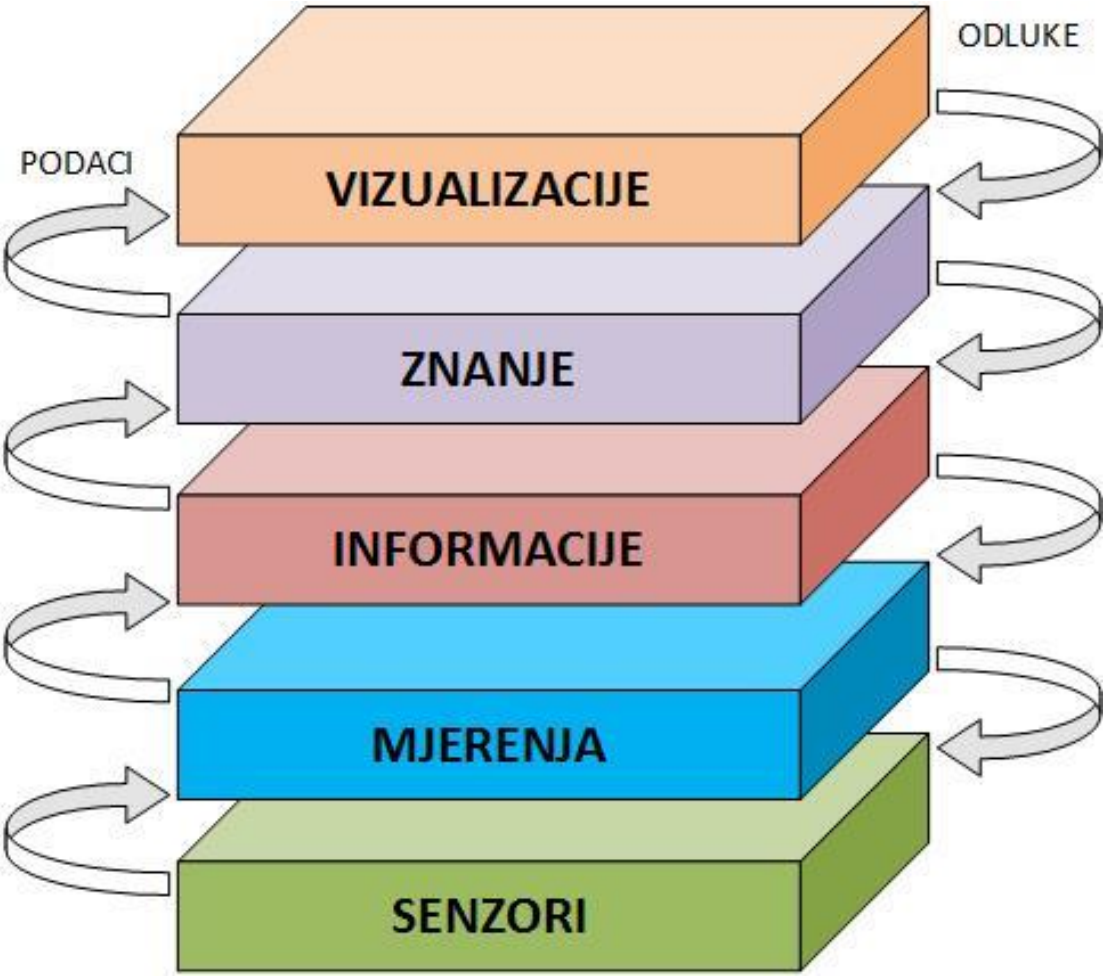


Slika 3.10 Kvalitativni grafički prikaz najčešće korištenih metoda rudarenja podataka u elektroenergetskim sustavima

Vidljivo je iz prethodnih dviju slika da postoji velika primjena stabala odlučivanja u nadzoru i upravljanju u elektroenergetskim sustavima te u cilju sigurnosti elektroenergetskih sustava.

Trendovi u tehnologiji omogućavaju daljnje širenje baza podataka u elektroenergetskim sustavima zbog dodatnog generiranja podataka od strane raznih uređaja zaštite, nadzora, upravljanja, senzora u mreži itd. Jednako tako, drastično smanjenje cijena uređaja za pohranu podataka, a samim tim i smanjenja kapitalnih investicija u podatkovne centre, omogućilo je daljnje širenje i pohranu velikih količina podataka.

Osnovna arhitektura alata za donošenje odluka baziranih na tehnikama rudarenja podataka [L 66] prikazana je na sljedećoj slici.



Slika 3.11 Kvalitativni grafički prikaz arhitekture alata za donošenje odluka zasnovanih na tehnikama rudarenja podataka u elektroenergetskim sustavima

Vrlo vjerojatno će se u budućnosti kombinirati različite tehnike rudarenja podataka u cilju efiaksnijeg vođenja pogona, preciznije detekcije kvara i ranije indikacije problema u sigurnosti pogona elektroenergetskog sustava. Također, sigurno tehnike rudarenja podataka neće zamijeniti klasične deterministčke metode analize i vođenja pogona elektroenergetskog sustava, ali će biti izvrsna nadopuna tim sustavima naročito u dijelu indikacije sigurnosti elektroenergetskog sustava.

3.3.2 Rudarenja podataka u svrhu analize sigurnosti EES-a

Pogonska sigurnost prijenosnog sustava odnosi se na sposobnost elektroenergetskog sustava da odgovori na dinamičke prijelazne pojave kojima je izložen kao što su nepredviđeni ispadi njegovih elemenata. Budući da su u pogonu neizbježni povremeni planirani ili neplanirani zastoji proizvodnih jedinica, ali i elemenata prijenosne mreže, operator prijenosnog elektroenergetskog sustava osigurava određene sigurnosne rezerve i reduncancije u dijelu proizvodnje i prijenosa električne energije.

Sigurnost elektroenergetskih sustava je područje u kojem je i najveća primjena tehnika rudarenja podataka. Najbitniji razlog je što se u tom području generira niz sintetičkih odnosno umjetnih podataka nastalih u simulacijama pogona elektroenergetskih sustava budući da stvarne situacije, a koje se mogu okarakterizirati kao nesigurne situacije, nisu česte i ne mogu se tek tako zabilježiti ili izmjeriti. Stoga se u posljednje vrijeme provodi niz istraživanja u području sigurnosti elektroenergetskog sustava pri čemu se koriste tehnike rudarenja podataka. Pri tome je jedan od najčešćih ciljeva istraživanja, razvoj ranih indikatora sigurnosti odnosno ranih signala upozorenja (eng. EWS – Early Warning Signals) kojima se pospješuje rano predviđanje abnormalnih scenarija i situacija (eng. SA – Situational Awareness).

Generiranje podataka u ovom području spada većinom u laboratorijski rad budući da, kako je ranije navedeno, ovakve situacije u stvarnom pogonu nisu česte. U isto vrijeme, to je u neku ruku i prednost, budući da je moguće generirati nelimitiran broj scenarija koji mogu poslužiti kao uzorak promatranja i istraživanja.

Moguće primjene rudarenja podataka [L 64, L 65, L 66, L 73] u području sigurnosti elektroenergetskih sustava obuhvaćaju sljedeće:

- Izračun indikatora sigurnosnih margina za određeno pogonsko stanje (opterećenje, globalni indikatori, jaki poremećaji...),
- Identifikacija bitnih i relevantnih atributa za predviđanje stupnja sigurnosti elektroenergetskih sustava,
- Određivanje stabilnosti elektroenergetskog sustava nakon određenih poremećaja ili skupa poremećaja,
- Određivanje pogonskih stanja koja mogu dovesti do naponske nestabilnosti pri nekom poremećaju,
- Klasifikacija svih mogućih pogonskih stanja u klase ovisno o sigurnosti elektroenergetskog sustava i određivanje kriterija za klasifikaciju u stvarnom vremenu,
- Mapiranje elektroenergetskog sustava u regije ovisno o naponskim prilikama,
- Rana detekcija naponski opasnih pogonskih stanja,
- Izdvajanje specifičnih pogonskih stanja u određenim uklopnim stanjima...

Za provođenje bilo kakve vrste simulacija, uvijek je potrebno izgraditi matematički model. Kako je već poznato, veliki broj elemenata elektroenergetskog sustava može se vrlo precizno modelirati u različitim matematičkim modelima i alatima. Određeni elementi i pojave unutar elektroenergetskog sustava ne mogu se tako točno i precizno modelirati zbog potrebe redukcije cjelokupnog modela u cilju matematičkog pojednostavljenja i same prezentacije. To je vrlo često slučaj sa modelima opterećenja te nadomjesnim ekvivalentima vanjskih sustava. Nadalje, određeni elementi elektroenergetskog sustava mijenjaju svojstva uslijed starosti odnosno tijekom vremena, i uslijed zamora materijala, što je dosta čest slučaj s nadzemnim prijenosnim dalekovodima. Također, prilikom redovnog ili pojačanog održavanja vrlo često se mogu dodatno izmijeniti takve karakteristike i parametri samih elemenata. Pojedini elementi u mreži mogu izmijeniti karakteristike i uslijed različitih vremenskih odnosno meteoroloških prilika.

Rudarenje podataka nameće se kao vrlo pogodan alat u modeliranju takvih pojava i nadopunjavanju standardnih alata upravljanja, planiranja i analize elektroenergetskih sustava.

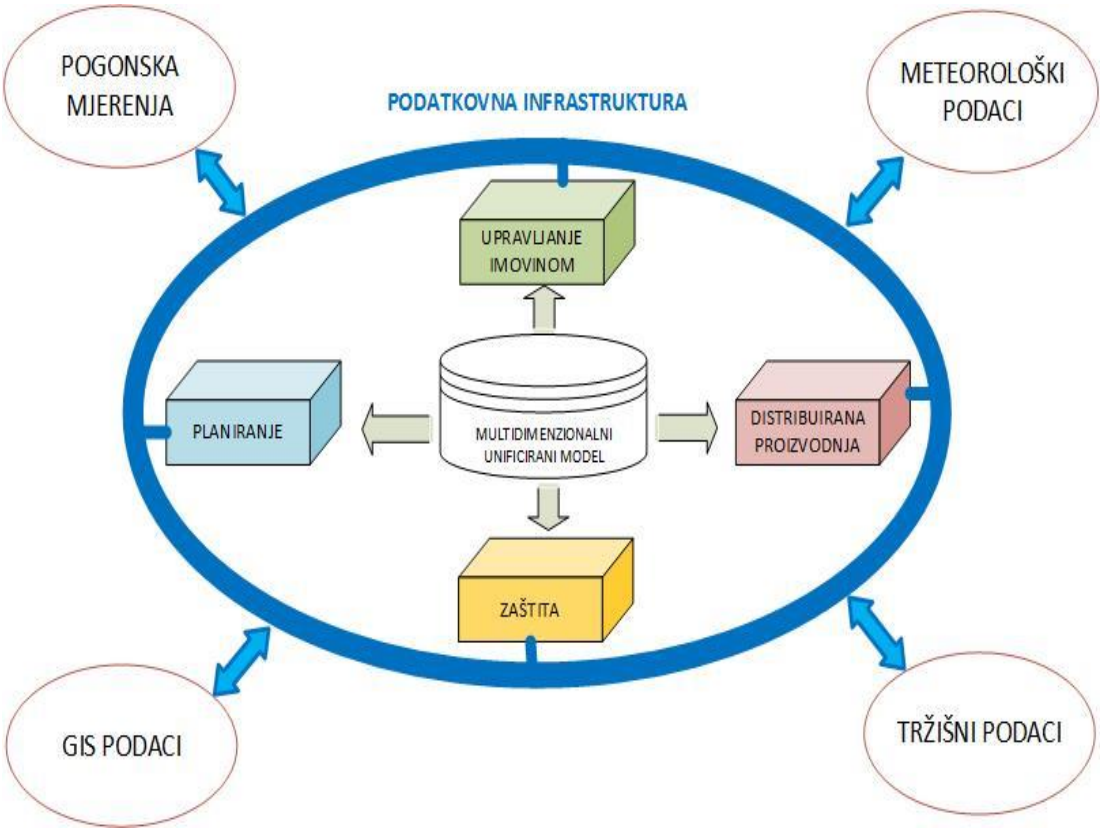
Prilikom analize sigurnosti elektroenergetskog sustava korištenjem tehnika rudarenja podataka mogu se upotrebljavati razni dostupni podaci u različitim bazama podataka od mjerenja u stvarnom vremenu do različitih zapisa kvarova (eng. Disturbance records) na zaštitnim relejima u vodnim i transformatorskim poljima.

Vjeruje se i da postoje brojne nove mogućnosti, ali zahtijevaju daljnje istraživanje. Općenito globalna istraživanja idu u tom smjeru daljnje analize podatkovno izdašnih i nesigurnih elektroenergetskih sustava (eng. Data rich and uncertain power systems).

3.3.3 Rudarenja velikih količina podataka EES-a

Moderni elektroenergetski sustav je vrlo velik i međusobno povezan kompleksni sustav. Zbog svojih složenih problema, složene prirode i pouzdanosti potrebno je prikupiti, analizirati i obrađivati veliku količinu podataka za nesmetano funkcioniranje sustava. Da bi pronašli željene informacije s većom točnošću u minimalnom vremenu, tehnike rudarenja velikih količina podataka koriste se sve više i u energetskim sustavima.

U prethodnim poglavljima također je pokazano kao će u narednim godinama doći do iznimno golemog generiranja velikih količina podataka iz raznoraznih mjernih, nadzornih, zaštitnih, senzorskih i ostalih uređaja. Takve velike količine podataka obuhvaćat će različite električke i neelektričke veličine kao i podatke iz različitih upravljački, mjernih i nadzornih sustava [L 66].



Slika 3.12 Kvalitativni grafički prikaz korištenja podatkovne infrastrukture i različitih upravljački, mjernih i nadzornih sustava u svrhu harmonizirane analize velikih količina podataka u elektroenergetskom sustavu

Među najbitnijm „big data“ izvorima će biti sljedeći izvori podataka:

- SCADA sustavi, odnosno mjerenja napona, struja, tokova snaga...
- WAMS sustavi, odnosno mjerenja faznih pomaka (iz PMU uređaja) u čvorištima i granama,
- Napredna mjerna tehnologija, odnosno mjerenja opterećenja, kvalitete električne energije itd.
- Bi-direkcionalna komunikacija prema elektromobilnim potrošačima,
- Mjerenja raznih meteoroloških veličina kao i mehaničkih i toplinskih parametara nadzemnih i podzemnih dalekovoda te ostala senzorska mjerenja,
- GIS mjerenja odnosno razna mjerenja iz geografskih informacijskih sustava (eng. GIS – Geographical Information Systems)
- Povijesna mjerenja i izvješća raznih post-mortem analiza u svrhu otkrivanja uzroka većih kvarova...

Većina ovih skupina podataka je neharmonizirana u standardima i neusklađena u protokolima prijenosa i pohrane podataka te je samim tim u ovom trenutku njihova obrada iznimno teška i zahtijeva velike količine vremena za obradu. U budućnosti se sigurno mogu očekivati veliki napori u cilju harmonizacije podatkovnih i komunikacijskih standarda u ovim područjima što će zasigurno rezultirati većom primjenom i analizom takvih podataka u budućnosti.

Korištenje takvih iznimno velikih skupova podataka u radu, kontroli i zaštiti elektroenergetskog sustava, koje je teško obraditi tradicionalnim alatima baze podataka često su nazivani velikim količinama podataka ili velikim bazama podataka (eng. Big data). Većina radova u posljednjih nekolikogodina istražuje tri aspekta takvih skupova podataka:

- ekstrakcija značajki,
- sustavna integracija za aplikacije elektroenergetskog sustava
- tipične primjene u elektroenergetskoj industriji.

Analitički alati bazirani na metodologiji analize velikih kočina podataka podataka (eng. Big data analysis) su razrađene na: korektivnim, prediktivnim, distribuiranim i adaptivnim platformama. Kako je već ranije opisano, česte primjene takvih alata su u područjima vezano uz upravljanje imovinom, planiranje rada u stvarnom vremenu praćenje pogona i rano otkrivanje kvarova, zaštita od grešaka u manipulativnim radnjama.

Poseban izazov bit će analiza nestrukturiranih velikih količina podataka kao što su upravo senzorski podaci, podaci procesuiranja slika, kao i podaci vezani uz poslovanje elektroenergetskih operatera i kompanija naročito vezanih uz upravljanje imovinom itd.

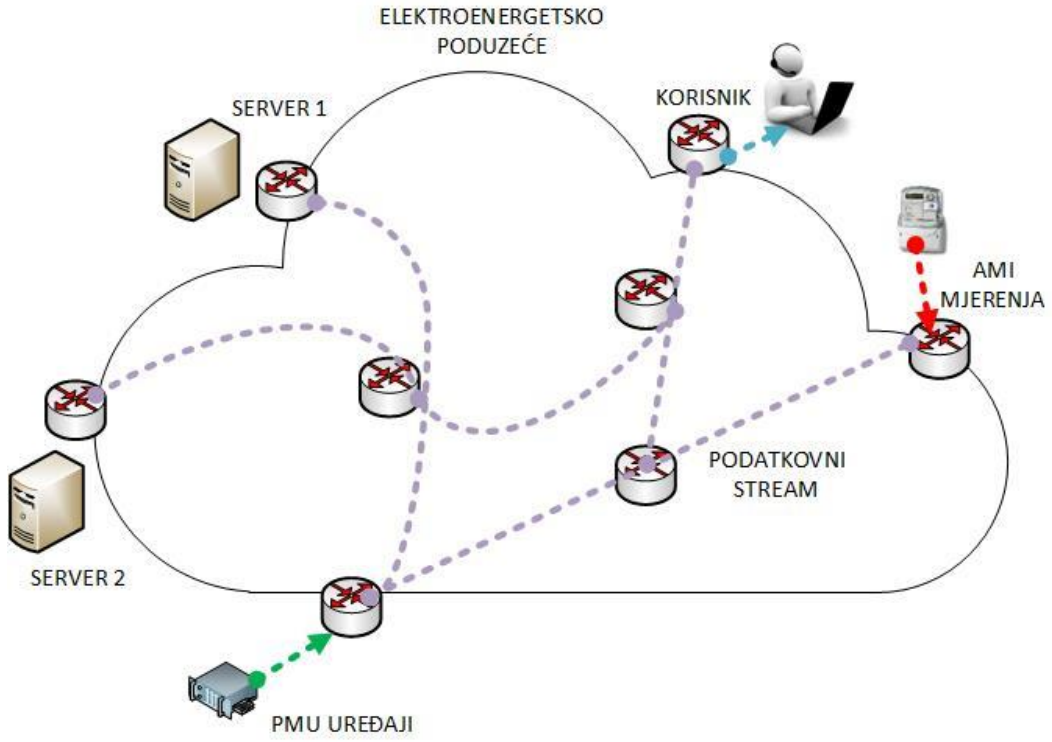
4. VOĐENJE POGONA VJETROELEKTRANE TEHNIKOM RUDARENJA PODATAKA

4.1. OSNOVNI KONCEPT MODELA

4.1.1 Razmjena i prijenos podataka

Osnovna arhitektura razmjene podataka elektroenergetskog sustava definirana je kao skup čvorišta oko telekomunikacijske osnovice te koji šalje ključne podatke vezane za pogon elektroenergetskog sustava na odgovarajuće računalne poslužitelje i postrojenja za pohranu podataka. Ova arhitektura ima visoke tehničke zahtjeve za telekomunikacijsku podršku. Napredak u razvoju informacijske tehnologije i telekomunikacijskih tehnologija (IKT) donosi dodatno povećanje korištenja ove vrste tehnologija u području naprednih elektroenergetskih mreža (eng. Smart Grid). Brzine prijenosa podataka i širina pojasa ključni su za implementaciju novih vrsta arhitektura razmjene podataka koje se sastoje od mjernih tehnologija s visokim vrijednostima uzorkovanja kao što su primjerice PMU uređaji.

Postoji nekoliko novih tehnika koje bi se mogle koristiti za prijenos podataka i njihovo rukovanje te su one pretpostavljen u ovom radu. Takve nove vrste tehnologija temelje se na platformi za komunikaciju od jednog do mnogih i mnogobrojnih točaka u sustavu i u stvarnom vremenu preko IP infrastrukture u mreži.



Slika 4.1 Kvalitativni grafički prikaz razmjene i prijenosa podataka u elektroenergetskom sustavu korištenjem platformi temeljenih na IP tehnologiji

Iskoristivši punu prednost IP mreže za transport PMU poruka, korisnici, kao primjerice vjetroelektrane, mogu potencijalno poboljšati vidljivost i kontrolu postrojenja u mreži, smanjiti nepotrebne dodatne hardvere (npr. PDC servere tj. Fazorske koncentratore) i smanjiti troškove poslovanja i održavanja povezanih s upravljanjem PMU podacima.

U naprednim mrežnim aplikacijama postoje različiti protokoli koji se često trebaju integrirati u jedan sustav kao što je Wide Area Monitoring (protokol IEEE C37.118), zaštita i upravljanje u trafostanicama (protokol IEC 61850) itd. Uglavnom, sve pametne mrežne usluge i protokoli (WAMS, napredna mjerenja i IEC 61850 i sl.) savršeno se mogu prevesti preko takvih novih vrsta podatkovnih mreža i IP platformi za telekomunikacije.

Trenutačno te značajke nisu korištene od strane elektroenergetskih poduzeća i operatera elektroenergetskih sustava, a navedene usluge se zasebno čuvaju u postojećoj mreži samo kao zasebna naslijeđena infrastruktura (eng. Legacy). Zapravo, SCADA sustavi se vrlo često temelje na IEC 104 protokolu, a trenutačno se ne koriste veće interakcije tokova podataka generiranih na protokolu IEC 61850.

Generalno, osnovna arhitektura razmjene i prijenosa podataka je dizajnirana kao podatkovna mreža, izgrađena od čvora za proizvodnju i obradu podataka, u rasponu od nekoliko stotina do nekoliko tisuća čvorišta. U svakom čvorištu mreže (trafo stanice, vjetroelektrane, solarne elektrane i ostali klasteri obnovljivih izvora energije, virtualne elektrane itd.) postoji velika količina podataka koji se mogu pohraniti i obrađivati pomoću uređaja s više resursa, kao što su daljinski locirani poslužitelji.

Stoga je potrebna nova paradigma kako bi se omogućio velika razmjena podataka i informacija i proces između različitih segmenata elektroenergetske mreže i njezinih korisnika kao npr. vjetroelektrana. Kao što je opisano na slici 4.1, postojeća osnovna infrastruktura elektroenergetskog sustava može se opremiti brojnim vrstama novih mjernih tehnologija koje šalju velike količine podataka u stvarnom vremenu na podatkovne poslužitelje. Tamo se podaci mogu pohraniti i analizirati, stvarajući korisne informacije iz ovog okruženja velike količine podataka. Ključna karakteristika ove nove vrste poboljšanja infrastrukture je njegova prilagodljivost tj. adaptivnost, i modularnost (tzv. "Adaptidularna" infrastruktura) prema postojećoj mreži energetskih mreža.

Ovim radom pretpostavljena je dostupnost upravo takve mogućnosti međusobne razmjene podataka između svih bitnih čvorišta u mreži. Na taj način omogućena je dostupnost podataka o vjetroelektrani drugim korisnicima u mreži te obratno. Operateri vjetroelektrana i drugih obnovljivih izvora energije, po tom načelu, mogu imati dostupnost određenim bitnim podacima iz cijele elektroenergetske mreže. Takva široka razmjena podataka među različitim korisnicima zasigurno nosi i sigurnosne izazove, što u suštini nije predmet ovog rada.

4.1.2 Obrada ulaznih podataka

Obrada ulaznih podataka jedan je od najbitnijih i najopsežnijih dijelova bilo koje buduće aplikacije naprednih elektroenergetskih mreža. Kako je opisano u nizu prethodnih poglavlja, čitav niz novih vrsta podataka iz različitih mjernih, nadzornih, zaštitnih i ostalih uređaja, slit će se u nizovima podataka na računalne poslužitelje elektroenergetskih poduzeća i operatera. Ti i takvi podaci bit će često nestrukturirani, neharmonizirani, nesinkronizirani te zapisani različitim podatkovnim protokolima i standardima.

Također, osim mjernih podataka, kao ulazni podaci mogu poslužiti i raznorazni sintetski podaci (eng. Syntex data) proizvedeni korištenjem raznoraznih simulacija na modelima. To se ponajprije odnosi na dinamičke simulacije elektroenergetskih sustava te analize sigurnosti elektroenergetskih sustava. I ovi podaci moraju biti obrađeni na način da su usklađeni, harmonizirani i sinkronizirani s mjernim podacima kako bi mogli poslužiti u svrhu izgradnje odgovarajućih modela baziranih na tehnikama rudarenja podataka.

Uspoređujući se sa standardnim matematičkim modelima, tehnike rudarenja podataka daju rješenje koje nije tako precizno, već jednostavno, sažeto, korisno i lako razumljivo. Uz to je izuzetno ovisno o kvaliteti i obradi ulaznih podataka. Ova je osobina osobito prikladna prilikom obrade velikih količina podataka.

Kao što je već spomenuto, veliki kapaciteti vjetroelektrana priključeni su na elektroenergetske mrežne u Europi i Svijetu. Unutar vjetroelektrana, svaka vjetroturbina, konekcijske trafostanice, mjerni stupovi, različiti senzori i sl. generiraju velike količine podataka svake sekunde. Svi ovi tokovi podataka mogu se dodatno proširiti instaliranjem novih polja senzora i generiranjem podataka koji se u prvoj ruci ne moraju činiti nužnima, ali uz korištenje različitih algoritama može se pronaći način iskorištavanja takvih podataka.

Najvažniji podaci koji se mogu i trebaju koristiti u algoritmima rudarenja podataka elektroenergetskog sustava su podaci za estimaciju stanja i buduća predviđanja sigurnosti elektroenergetskog sustava. Ti tokovi podataka mogu se svrstati u tri glavne skupine:

1) mjerenja sinkrofazorskih veličina,
2) mjerenja opterećenja i mjerenja izlazne proizvodnje na elektranama,
3) mjerenja drugih utjecajnih varijabli.

Fazorske veličine poput fazora napona i struja zajedno s pripadajućim fazorskim kutevima mogu se prikupiti kroz mjerenja PMU uređaja i mogu pružiti vrijedne informacije za pogon elektroenergetskog sustava.

Opterećenja i proizvodnja u elektroenergetskim sustavima lako se mogu mjeriti i prikupljati putem napredne mjerne infratrukture i aplikacija, a zatim se koriste za različite analize.

Druge utjecajne varijable obuhvaćaju veliku količinu dodatnih podataka koji nisu izravno povezani s nadzorom i kontrolom elektroenergetskog sustava, ali su ponekad vrlo utjecajni. To uključuje meteorološke podatke iz različitih vrsta meteo sustava od kojih su najznačajniji mjerenja brzine vjetra i smjera, temperatura i tlaka zraka, mjerenje insolacije i vlažnosti zraka. Zajedno s meteorološkim podacima mogu se prikupljati i druga mjerenja kao što su temperature vodiča nadzemnog dalekovoda, parcijalna izbijanja itd. Također, u posljednjih nekoliko godina vrlo su česti sustavi za nadzor dinamičke strujne opteretivosti (DLR) koji daju stvarni trenutni prijenosni kapacitet prijenosne linije u datom trenutku.

Svi ti nizovi podataka mogu se koristiti u nadzoru i kontroli vjetroelektrana i solarnih elektrana ili drugih obnovljivih izvora električne enerrgije koji predstavljaju stohastičke odnosno intermitirajuće izvore unutar elektroenergetske mreže, kao i za prognoziranje opterećenja i mogućnosti evakuacije snage. Preduvjet je imati učinkovito rješenje prijenosa, razmjene i obrade podataka. Sami podaci se mogu pohraniti i obrađivati na način da donose korisne informacije za dispečere i ostale ključne donositelje odluka u procesu nadzora i upravljanja elektroenergetskog sustava.

Kao što je ranije opisano, goleme količine podataka unutar energetskih sustava bit će proizvedene svake sekunde čime će se stvoriti velike količine podataka. Nelinearna priroda elektroenergetskog sustava čini još više zahtjevnim definiranje novih modela za izdvajanje korisnih informacija iz hrpe prikupljenih podataka. Posebno zahtjevna bit će u budućnosti obrada podataka iz vjetroelektrana budući da ti stohastički izvori proizvode još veće količine podataka zbog jako puno zavisnih varijabli koje utječu na izlaznu snagu. Stoga, kvalitetan opseg podataka za rudarenje integrira široko područje zavisnih varijabli.

Ovaj rad definira model koji obuhvaća obradu sljedećih podataka:

- proizvodnja djelatne snage i jalove snage vjetroelektrane (P_{Wind}, Q_{Wind}), u mjestu priključka vjetroelektrane i predaje električne energije (eng. PCC – point of common coupling)
- Postavke izlazne djelatne i jalove snage vjetroelektrane ($P_{Settings}$, $Q_{Settings}$), koje su operativne odluke za postavke regulatora vjetroelektrane smještenog u točki priključka (PCC),
- mjerenja ukupnog opterećenja sustava (P_L), izražena u postotku, kao postotak nominalnog opterećenja cjelokupnog sustava,
- mjerenja efektivnih vrijednosti napona i kutova (fazori) (V_i, δ_i) na čvorištima u sustavu,
- informacije o raspoloživosti elemenata mreže odnosno dalekovoda, transformatora i generatora.

Gore navedeni podaci mogu se proširiti definiranjem fraktalne strukture podataka kao derivata osnovne strukture i to na sljedeći način:

- ukupna snaga vjetroelektrane može se podijeliti na snagu pojedine vjetroturbine ili klastera turbina;
- ukupno opterećenje sustava može se podijeliti na opterećenja svake pojedine sabirnice, čvorišta, potrošača ili skupine potrošača, uključujući npr. velike gradove, industrijske zone, potrošačke klastere, i bilančne skupine itd.;
- efektivne vrijednsoti i kutevi napona mogu se prikazati naponskim i strujnim efektivnim vrijednostima i kutevima za svaku fazu, kao i mjerenja nadomjesne Theveninove impedancije;
- proizvodnja vjetroelektrane je definirana brzinama vjetra i može se dalje detaljno opisati brzinom i smjerom vjetra, temperaturom zraka i tlakom, sunčevim zračenjem i mjerenjem vlažnosti zraka itd.
- raspoloživost elemenata mreže može se dalje opisati kroz stanje prekidača u vodnim i trafo poljima ili putem informacija i podataka iz transformatora i sustava za praćenje dinamičke strujne opteretivosti (DLR)...

Svi ovi podaci trebaju formirati velike i organizirane baze podataka za daljnju upotrebu u kontroli, planiranju, upravljanju imovinom i algoritmima za optimizaciju pogona i održavanja. Stoga, da bi se u potpunosti iskoristilo dostupne podatke, potrebni su učinkoviti alati za analizu ovakvih podataka.

Osnovna pretpostavka ovog rada jest da su sve ulazne varijable vremenski sinkronizirane, podatkovno harmonizirane te da se mogu prenijeti istom telekomunikacijskom infrastrukturom do mjesta pohrane i obrade podataka.

Prilikom obrade podataka u ovom radu korišten je software STATISTICA proizvođača Statsoft.

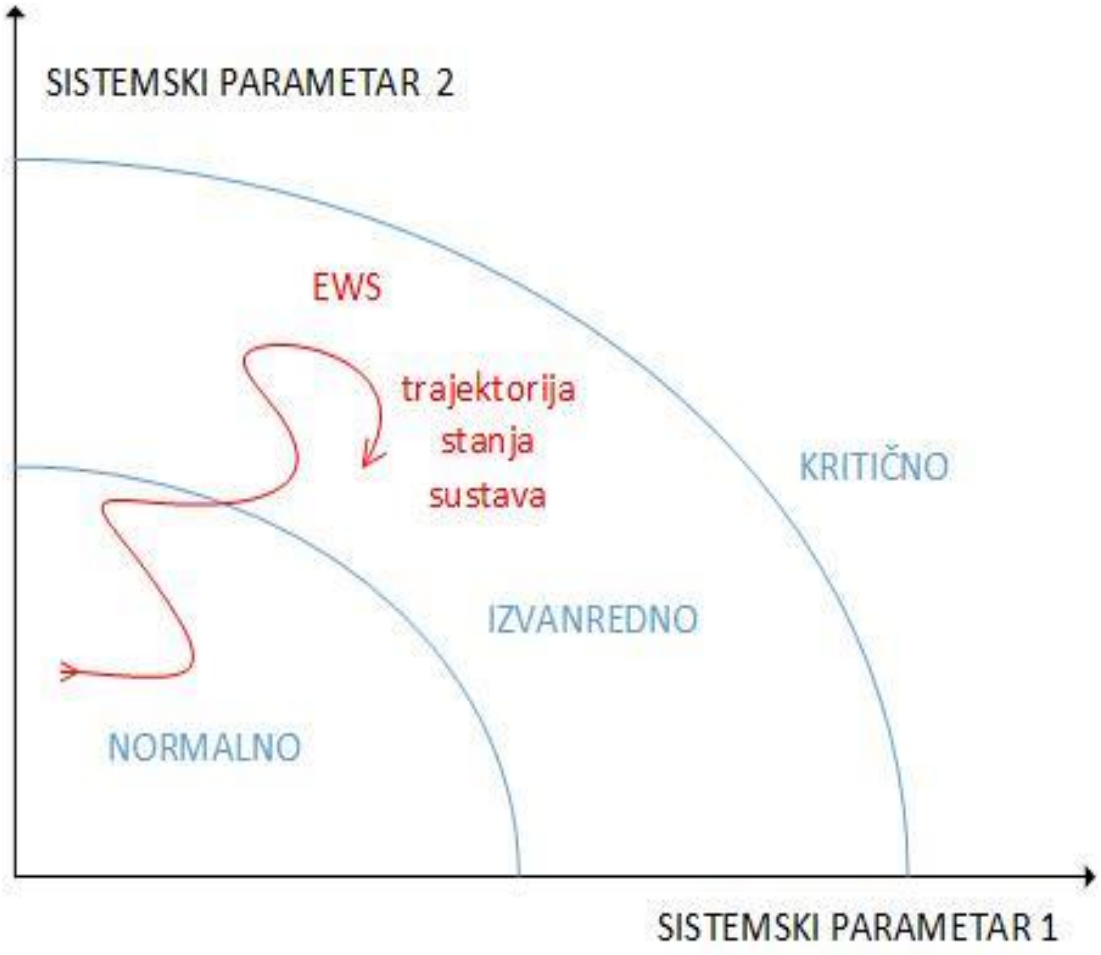
STATISTICA pruža najopsežniju grupu analize podataka, upravljanje podacima, vizualizaciju podataka i postupke rudarenja podataka. Njegove tehnike uključuju najširi izbor prediktivnih modeliranja, klasterizacije, klasifikacije i istraživačkih tehnika u jednoj softverskoj platformi.

STATISTICA je isprobana i testirana platforma za analizu s više od dva desetljeća povijesti u pružanju uspješnih poslovnih rezultata za klijente i globalnu korisničku bazu od preko 600.000 korisnika.

4.1.3 Izlazni podaci i signali

Cilj ovog rada je osim razvoja algoritma i stvoriti novu vrstu ranog upozoravajućeg signala (EWS) i prepoznati određeni uzorak kritičnih događaja i prijelaza stanja sustava među podacima za operatore elektroenergetskog sustava i vjetroelektrana u obliku pokazatelja situacijske sigurnosti (SA).

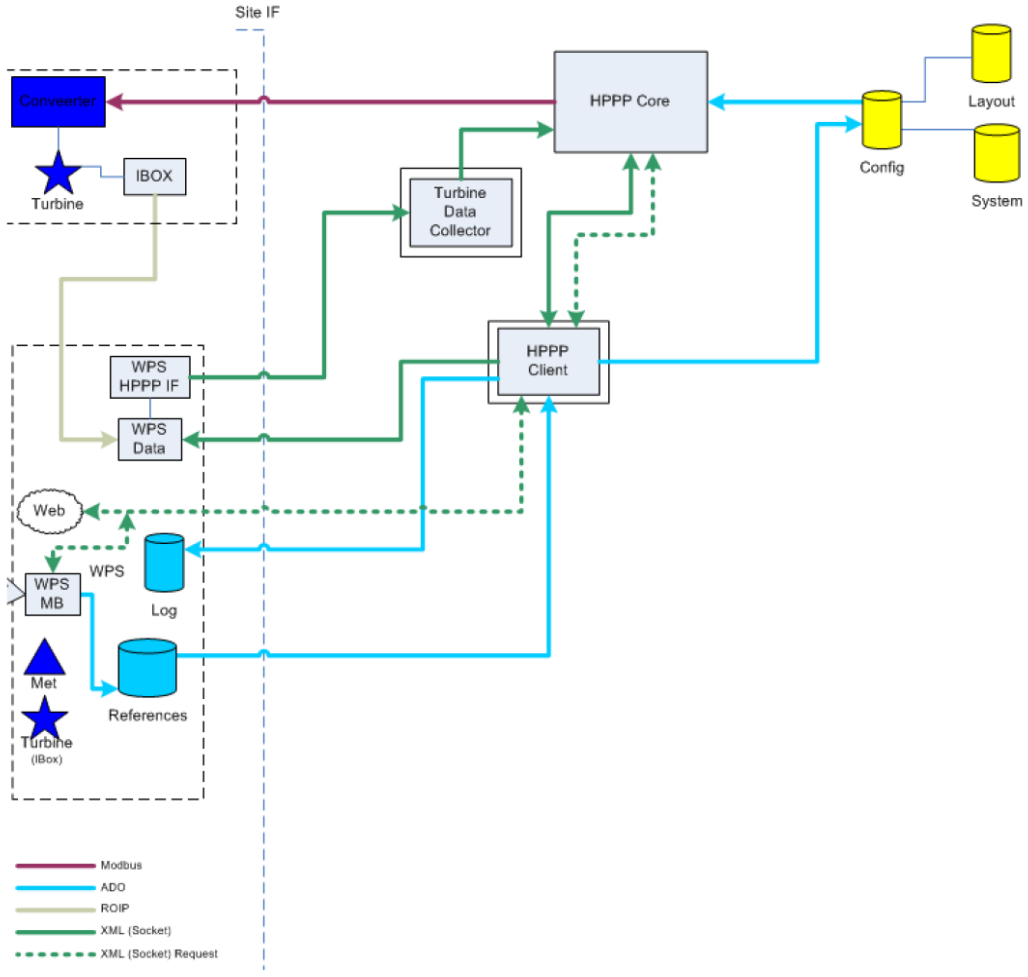
Ti signali trebaju biti strukturirani kako bi upozorili operatore da se može doći do kritičnog pogonskog stanja te da treba poduzeti preventivne ili korektivne radnje (npr. smanjenje proizvodnje djelatne snage vjetroelektrane ili promjena režima proizvodnje jalove snage) i tako vratiti sustav u normalno stanje pogona, kao što je opisano na sljedećoj slici.



Slika 4.2 Kvalitativni grafički prikaz signala ranog upozorenja (EWS) kao pokazatelja situacijske sigurnosti (SA) te kao prva linija obrane koja inducira preventivne i korektivne radnje nakon promjene stanja elektroenergetskog sustava

Stoga bi EWS signal mogao poslužiti kao prva linija obrane kako bi se smanjili rizici totalnih ili djelomičnih nesvjestica sustava i time smanjili troškove prilike koji su povezani s troškovima električne energije koja se ne isporučuje. U ovom radu, predmetni EWS signal služi kao indikator stanja sustava te na temelju toga i donošenje odluka o pogonskim manipulacijama na samoj vjetroelektrani.

Nadalje, izlazni signali obuhvaćaju pogonske odluke vezane za izlaznu djelatnu i jalovu snagu vjetroelektrana, a koje naročito dolaze do izražaja u situacijama kad na mikrolokaciji vjetroelektrane u određenom trenutku ima vrlo malo ili nema vjetra uopće. Sve moderne vjetroelektrane imaju mogućnost regulacije izlaznih vrijednosti u točki priključka pri čemu se regulacija obavlja centralnim staničnim računalom s instaliranim SCADA sustavom za optimiranje pogona pojedinih vjetroagregata.



Slika 4.3 Kvalitativni prikaz tipične blok sheme centralnog staničnog računala za upravljanje vjetroelektranom i pojedinim vjetroagregatima (izvor Siemens)

Iz prethodne blok sheme vidljivo je da centralno stanično računalo vjetroelektrane (eng. HPPP - High Performance Park Pilot) upravlja parametrizacijom pojedinih vjetroagregata na temelju referentnih i izmjerenih vrijednosti na sučelju kompletne vjetroelektrane.

U prethodnim elektroenergetskim suglasnostima gotovo svim vjetroelektrana, najčešće je naveden uvjet proizvodnje jalove snage u opsegu cos φ od otprilike 0.9 induktivno do 0.9 kapacitivno. Dodatni tehnički uvjeti za priključak i pogon vjetroelektrana (HEP OPS d.o.o., prosinac 2008.) definiraju mogućnost proizvodnje vjetroelektrana u opsegu 0.95 induktivno do 0.95 kapacitivno.

U prethodno opisanom slučaju kad vjetroelektrana ne proizvodi djelatnu snagu, ista može aktivno sudjelovati u regulaciji napona i jalove snage proizvodnjom jalove snage pomoću vlastitih kompenzacijskih uređaja izvedenih najčešće elementima energetske elektronike. Međutim, u takvom slučaju, proizvođač odnosno vlasnik vjetroelektrane je često kažnjen plaćanjem prekomjerne jalove energije budući da, prema pogonskom dijagramu, ima sposobnost iznimne proizvodnje jalove snage. Stoga su vrlo često, proizvođači prisiljeni raditi u pogonskom režimu regulacije cos φ ili režimu regulacije izlazne jalove snage u cilju izbjegavanja plaćanja troškova za prekomjernu jalovu snagu. U-Q regulacijom u modu tj. režimu upravljanja regulacije izlazne jalove snage, povratnom petljom regulira se vrijednost izlazne jalove snage na točki priključka. U režimu regulacije cos φ, referentna vrijednost faktora snage pretvara se u internu referentnu vrijednost jalove snage u točki priključka, a na temelju aktualne proizvodnje djelatne snage te se ta ista referentna vrijednost stalno osvježava.

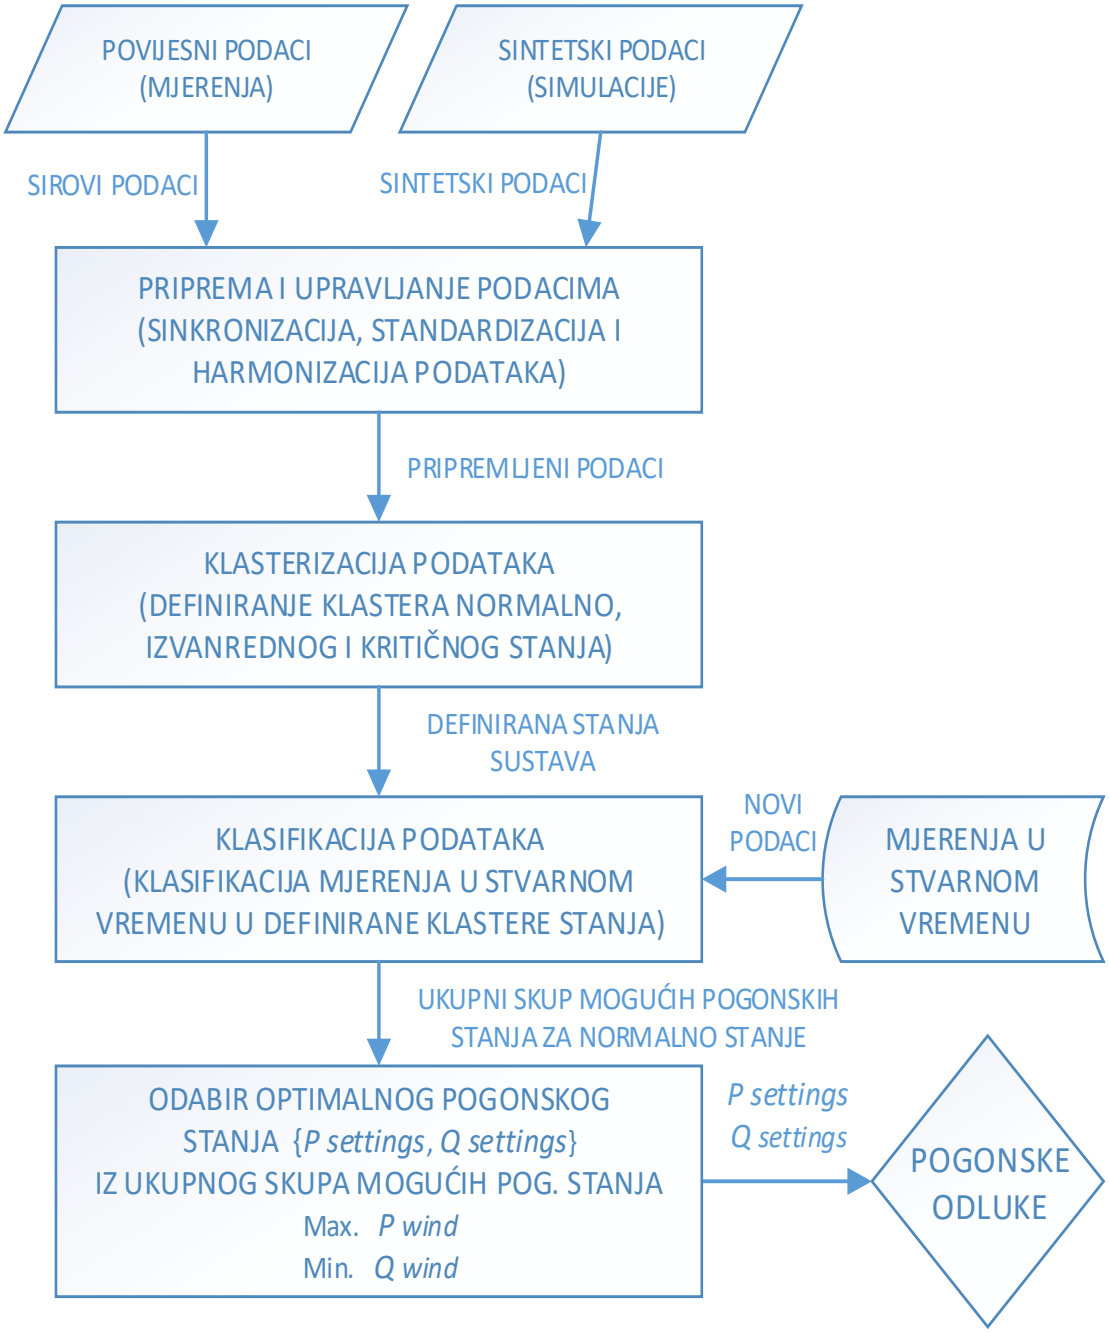
Izlazni signali u obliku pogonskih odluka definirani su kao

$P_{settings}$ - postavke izlazne djelatne snage vjetroelektrane koje su operativne odluke za postavke regulatora vjetroelektrane smještenog u točki priključka (PCC). Ovim se postavlja maksimalna moguća izlazna snaga vjetroelektrane (npr. 20 MW od 36 MW instaliranih). Ukoliko dostupni vjetar na lokaciji ne dopušta veću izlaznu snagu, nego manju (npr. 12 MW od podešenih 20 MW), vjetroeletkrana će proizvoditi dostupnu snagu (12 MW), ali ne preko maksimalne moguće (20 MW).

$Q_{settings}$ - postavke izlazne jalove snage vjetroelektrane koje su operativne odluke za postavke regulatora vjetroelektrane smještenog u točki priključka (PCC). Ovim se postavlja jedan od tri režima regulacije jalove snage u točki priključka (reg. cos φ, reg. Q, reg. U), s definiranim vrijednostima parametara (npr. reg. cos φ = 0.95 ili reg.Q = 0.95 p.u. ili reg. U = 1.02 p.u.)

4.1.4 Dijagram toka modela

Osnovni dijagram toka predloženog modela upravljanja opisan je na sljedećoj slici.



Slika 4.4 Dijagram toka algoritma odlučivanja za promjenu režima rada vjetroelektrane na temelju karakterističnih vrijednosti električnih veličina

Prvi korak u modelu je upravljanje i priprema svih vrsta podataka od sirovih mjernih povijesnih podataka do sintetskih podataka proizašlih iz raznih simulacija na matematičkim modelima. Ovaj korak se sastoji od sinkronizacije vremena, standardizacije zapisa, harmonizacije formata i slaganja svih vrsta podataka. U ovom radu, kao alat za izradu simulacijskih podataka koristili su se DigSilent i PSS/E programski alati za simulaciju modela elektroenergetskih sustava.

Drugi je korak klasterizacija podataka s ciljem definiranja pogonskih stanja sustava na pripremljenoj i dostupnoj bazi podataka odnosno skupu pogonskih stanja. U ovom radu ovaj je dio izrađen u programskom paketu STATISTICA.

Pri tom se, kao i kod kasnije klasifikacije podataka, koristi standardna definicija varijabli iz statističke teorije gdje je:

- nezavisna varijabla, koja se ponekad naziva eksperimentalna ili prediktorska varijabla, varijabla koja se mijenja u eksperimentu kako bi se promatrao učinak na
- zavisnu varijablu, ponekad nazvanu varijablu ishoda.

Bitno je da ukupni skup pogonskih stanja odnosno uzoraka u ovom primjeru mora biti dovoljno velik i prikupiti sva moguća stanja sustava te tako biti reprezentativni uzorak i biti uključeni u metodu klasteriranja.

Treći korak je klasifikacija podataka novih mjernih podataka i definiranje novog pogonskog stanja sustava (eng. Operating Condition - OC) ili skupa mogućih pogonskih stanja koja spadaju u normalno stanje sustava. Pri tome su zadana pogonska stanja, a koja su prethodno određena klasterizacijom podataka (NORMALNO, IZVANREDNO i KRITIČNO) postavljena kao nezavisne varijable.

Za ovu klasifikacijsku analizu korištena je metoda klasifikacijskih i regresijskih stabala odlučivanja (C&RT). U ovom radu ovaj je dio izrađen u programskom paketu STATISTICA.

U finalnom koraku, konačne odluke o pogonu vjetroelektrana donose se prema jednostavnom postupku odabira najboljeg mogućeg rješenja među skupom mogućih pogonskih stanja (OCs) kao maksimiziranje izlazne djelatne snage i minimiziranje izlazne jalove snage.

$$max\ \{P_{Wind}\} \qquad \textbf{(4.1)}$$

$$min\ \{Q_{Wind}\} \qquad \textbf{(4.2)}$$

Time se odabiru konačne postavke izlazne djelatne i jalove snage vjetroelektrane.

Energetski transformatori u točki priključka (PCC) mogu imati ograničenu nazivnu snagu. Stoga u tom slučaju na kraju treba ispuniti i dodatni uvjet kako se ne bi ugrozila ova vrlo važna pogonska ograničenja.

$$S_{TR} \geq (P_{Wind}^2 + Q_{Wind}^2)^{½} \qquad \textbf{(4.3)}$$

Gdje je:

S_{TR} - nazivna snaga transformatora (MVA).

4.2. PODATKOVNO RUDARENJE POGONSKIH STANJA

4.2.1 Definicija pogonskih stanja

Svako pogonsko stanje (eng. OC – operating condition) definirano je kao matematički skup podataka čiji su članovi sljedeći elementI odnosno varijable

$$OC_k = \{V_1, V_2, V_3, V_4, \ldots Vi, \delta_1, \delta_2, \delta_3, \delta_4, \ldots \delta_i, P_L, P_{Wind}, Q_{Wind}, R_{th}, X_{th}\} \quad \textbf{(4.4)}$$

Pri čemu je:

V_1 - efekt. vrijednost napona na čvorištu br. 1,
V_2 - efekt. vrijednost napona na čvorištu br. 2,
V_3 - efekt. vrijednost napona na čvorištu br. 3,
V_4 - efekt. vrijednost napona na čvorištu br. 4,
Vi - efekt. vrijednost napona na čvorištu br. i,
δ_1 - kut napona na čvorištu br. 1,
δ_2 - kut napona na čvorištu br. 2,
δ_3 - kut napona na čvorištu br. 3,
δ_4 - kut napona na čvorištu br. 4,
δ_i - kut napona na čvorištu br. i,
P_L - opterećenje sustava,
P_{Wind} - djelatna snaga vjetroelektrane,
Q_{Wind} - jalova snaga vjetroelektrane,
R_{th}, - djelatni dio nadomjesne Theveninove impedancije na sabirnici vjetroelektrane
X_{th} - reaktivni dio nadomjesne Theveninove impedancije na sabirnici vjetroelektrane

Uz $i = 1, 2, 3, \ldots n$ gdje je n – broj čvorišta na kojima se obavljaju mjerenja efektivnih vrijednosti i kuteva napona u sustavu,

Uz $k = 1, 2, 3, \ldots m$ gdje je m – ukupno broj ulaznih pogonskih stanja nad kojima se obavljaju analize tehnikom rudarenja podataka.

Vektor ulaznih podataka u proces klasterizacije jednak je:

$$OC = [OC_1; OC_2; OC_3; \quad OC_m]^T \quad \textbf{(4.5)}$$

Na taj način matematički su definirana pogonska stanja kao ulazni podaci u algoritam. Bitno je napomenuti, da je osim ovdje definiranih varijabli, ulazni skup pogonskih stanja moguće proširiti čitavim nizom dodatnih ulaznih signala kao što su podaci sa raznih mjernih uređaja za mjerenje električkih i neelektričkih veličina, meteoroloških mjernih uređaja, senzorskih i ostalih uređaja. Model je stoga prilagodljiv i modularan. Lako se nadogradi jednostavnim proširenjem matematičkog skupa podataka *OC.*

4.2.2 Kreiranje pogonskih stanja

Kreiranje pojedinih pogonskih stanja za ulazne podatke u ovom radu je obavljeno sintetički odnosno isključivo su korištena pogonska stanja kreirana u simulacijama na poznatim matematičkim modelima.

Za kasniju validaciju modela, korišteni su u slučaju testnog modela IEEE 14, sintetski podaci, a u slučaju modela vjetroelektrana Zadar 6 te Zadar 2 i 3, mjerni podaci dobiveni mjerenjima na samoj lokaciji vjetroelektrana prilikom izgradnje i puštanja u pogon.

U slučaju modela IEEE 14, pogonska stanja (OCs) izračunata su za nekoliko različitih scenarija.

Scenariji su mijenjani po sljedećem načelu:

- Izlazna djelatna snaga varijabilne vjetroelektrane promijenjena je u intervalima od 0-100% nazivne snage u diskretnim koracima od 25% (0, 25%, 50%, 75%, 100%).
- Postavke izlazne jalove snage vjetroelektrane definirane su u različitim režimima rada, a režim je promijenjen u 3 različita načina i to kao:
    - regulacija faktora snage točka podešavanja promijenjena je sa 0.9 p.u kapacitivno na 0.9 p.u induktivno u koracima od 0,05 p.u. (0.9 kap.; 0.95 kap.; 1; 0.95 ind.; 0.9 ind.)
    - regulacija jalove snage - promjena točke podešavanja od 1,0 p.u kapacitivno do 1,0 p.u induktivno u koracima od 0,5 p.u. (1.0 p.u. kap.; 0.5 p.u. kap.; 0; 0.5 p.u. ind.; 1.0 p.u. ind.)
    - regulacija napona (promjena točke podešenja regulacije napona bila je 0.9 p.u – 1.1 p.u u koracima od 0,05 p.u.
- opterećenje elektroenergetskog sustava istodobno je promijenjeno na svim čvorištima u intervalima od 1 p.u. do 1,6 p.u. (100-160%) u koracima od 0,2 p.u. (20%).
- Dostupnost linije, transformatora i generatora promijenjena je na način da je nekoliko redaka, transformatora i generatora isključeno u različitim pogonskim stanjima.

Na taj je način stvoreno 396 pogonskih stanja s većinom varijabli definiranih kao kontinuirane varijable. Tako je definirana velika baza podataka koja pokriva veliki broj mogućih situacija koje se mogu analizirati.

Proračuni tokova snaga i kratkih spojeva napravljeni su u programskom paketu DigSilent za testni model IEEE 14 te u PSS/E za nadomjesni model vjetroelektrana Zadar 6 te Zadar 2 i 3.

U slučaju modela vjetroelektrana Zadar 6 te Zadar 2 i 3, pogonska stanja izračunata su za nekoliko različitih scenarija.

Scenariji su mijenjani po sljedećem načelu:

- Izlazna djelatna snaga varijabilne vjetroelektrane promijenjena je u intervalima od 0-100% nazivne snage u diskretnim koracima od 25% (0, 25%, 50%, 75%, 100%).
- Postavke izlazne jalove snage vjetroelektrane definirane su u različitim režimima rada, a režim je promijenjen u 3 različita načina i to kao:
    - regulacija faktora snage točka podešavanja promijenjena je sa 0.9 p.u kapacitivno na 0.9 p.u induktivno u koracima od 0,05 p.u. (0.9 kap.; 0.95 kap.; 1; 0.95 ind.; 0.9 ind.)
    - regulacija jalove snage - promjena točke podešavanja od 1,0 p.u kapacitivno do 1,0 p.u induktivno u koracima od 0,5 p.u. (1.0 p.u. kap.; 0.5 p.u. kap.; 0; 0.5 p.u. ind.; 1.0 p.u. ind.)
    - regulacija napona (promjena točke podešenja regulacije napona bila je 0.9 p.u – 1.1 p.u u koracima od 0,05 p.u.
- opterećenje elektroenergetskog sustava istodobno je promijenjeno na svim čvorištima u intervalima od 1 p.u. do 1,6 p.u. (100-160%) u koracima od 0,2 p.u. (20%).
- Dostupnost linije, transformatora i generatora promijenjena je na način da je nekoliko redaka, transformatora i generatora isključeno u različitim pogonskim stanjima.

Na taj su način stvorene 396 pogonskih stanja za testni model IEEE 14, s većinom varijabli definiranih kao kontinuirane varijable. Tako je definirana velika baza podataka koja pokriva veliki broj mogućih situacija koje se mogu analizirati.

Sukladno tome, za svaki od numeričkih primjera kreirano je 150 ulaznih pogonskih stanja za svaku od vjetroelektrana.

4.2.3 Opis klasterizacijskog dijela algoritma

Kako je opisano u poglavlju 3.2.1. klasterizacija podataka ili klaster analiza je proces razdijeljivanja ulaznog skupa podataka ili skupa promatranja u podskupove. Svaki podskup predstavlja jedan klaster, takav da su objekti unutar jednog klastera slični jedan drugome, te dovoljno različiti od podataka u drugim klasterima.

U prethodnom poglavlju opisan je vektor ulaznih podataka u proces klasterizacije koji je jednak:

$$OC = [OC_1; OC_2; OC_3; \quad OC_m]^T \qquad \textbf{(4.6)}$$

Uz $k = 1, 2, 3, ...m$ gdje je m – ukupno broj ulaznih pogonskih stanja nad kojima se obavljaju analize tehnikom rudarenja podataka.

Klasterizacija podataka obavlja se s ciljem definiranja pojedinih skupina stanja sustava na zadatom vektoru pogonskih uvjeta. U ovom radu ovaj je dio izrađen u softverskom paketu STATISTICA.

Koristi se standardna definicija varijabli iz statističke teorije gdje je nezavisna varijabla, koja se ponekad naziva eksperimentalna ili prediktorska varijabla, varijabla kojom se manipulira u eksperimentu kako bi se promatrao učinak na zavisnu varijablu, ponekad nazvanu varijablu ishoda.

Ukupni skup ulaznih vektora pogonskih stanja u svakom primjeru mora biti dovoljno velik i pokrivati sva moguća stanja sustava te tako biti reprezentativni uzorak i biti uključen u metodu klasteriranja. To znači da vektor *OC* mora sadržavati uzorke normalnog, izvanrednog i kritičnog pogonskog stanja.

Za klasteriranje se koristi algoritam k-srednjih vrijednosti s Euklidskim udaljenostima. Isti algoritam korišten je za grupiranje početnog skupova podataka na sljedeći način:

- impedancija Thevenina na čvorištu vjetroelektrane koristi se kao zavisna varijabla,
- pri tom je jedna zavisna varijabla apsolutna vrijednost Theveninove impedancije u čvorištu vjetroelektrane, a druga zavisna varijabla je argument Theveninove impedancija odnosno kut u čvorištu vjetroelektrane,
- klasteriranje se provodi u 3 klastera koji opisuju normalno, izvanredno i kritično pogonsko stanje. Pri tome se koriste oznake NORMAL – za normalno, WARNING – za izvanredno i ALARM – za kritično pogonsko stanje.

Klasteriranjem pogonskih stanja određene su skupine odnosno klasteri za normalno (NORMAL), izvanredno (WARNING) i kritično (ALARM) pogonsko stanje.

Mogu se definirati podskupovi vektora ulaznih podataka kao

$$OC = OC_{NORMAL} \cup OC_{WARNING} \cup OC_{ALARM} \qquad \textbf{(4.7)}$$

Pri čemu je

OC_{NORMAL} - skup pogonskih stanja klasteriranih kao normalna
$OC_{WARNING}$ - skup pogonskih stanja klasteriranih kao izvanredna
OC_{ALARM} - skup pogonskih stanja klasteriranih kao kritična

Iste definicije predmetnih skupina služe kao ulazni podaci za klasifikacijski dio algoritma.

4.2.4 Opis klasifikacijskog dijela algoritma

Nakon što su klasteriranjem pogonskih stanja određene skupine odnosno klasteri za normalno (NORMAL), izvanredno (WARNING) i kritično (ALARM) pogonsko stanje, iste definicije predmetnih skupina služe kao ulazni podaci za klasifikacijski dio algoritma.

Tim klasteriranim podacima, definirane su klase podataka za kasniju analizu novih mjernih ulaznih podataka. Odnosno, generalno vrijedi:

$$C_A = \{C_{NORMAL}, C_{WARNING}, C_{ALARM}\} \qquad \textbf{(4.8)}$$

Pri čemu je

C_A - skup klasa podataka u algoritmu
C_{NORMAL} - klasa podataka za normalno pogonsko stanje
$C_{WARNING}$ - klasa podataka za izvanredno pogonsko stanje
C_{ALARM} - klasa podataka za kritičn pogonsko stanje

Novi mjerni podaci, sukladno svojim parametrima, kalsifikacijskim dijelom algoritma klasificiraju se u tako predefinirane skupine, a sukladno vrijednostima parametara koji se uzimaju kao ulazni podaci. Klasifikacijske grupe definirane su tako kao klasteri nastali ranijom klasterizacijom pogonskih stanja.

Kao zavisne varijable, definirane su varijable novih mjernih podataka u opsegu rudarenja podataka, a koja su i definirana ranije u poglavlju 4.1.2.

- (P_{Wind}, Q_{Wind}) – snaga proizvodnja djelatne snage i jalove snage vjetroelektrane u mjestu priključka vjetroelektrane i predaje električne energije (eng. PCC – point of common coupling)
- ($P_{Settings}$, $Q_{Settings}$) – postavke izlazne djelatne i jalove snage vjetroelektrane koje su operativne odluke za postavke regulatora vjetroelektrane smještenog u točki priključka (PCC),
- (P_L) – mjerenja opterećenja sustava izražena u postotku, kao postotak nominalnog opterećenja cjelokupnog sustava,
- (V_i, δ_i) mjerenja efektivnih vrijednosti napona i kutova (fazori) na čvorištima u sustavu,
- informacije o raspoloživosti elemenata mreže odnosno dalekovoda, transformatora i generatora.

Sve varijable osim proizvodnje jalove snage i postavke izlazne jalove snage definirane su kao kontinuirane varijable. Proizvodnja i postavke izlazne jalove snage definirane su kao kategoričke odnosno diskretne slučajne varijable.

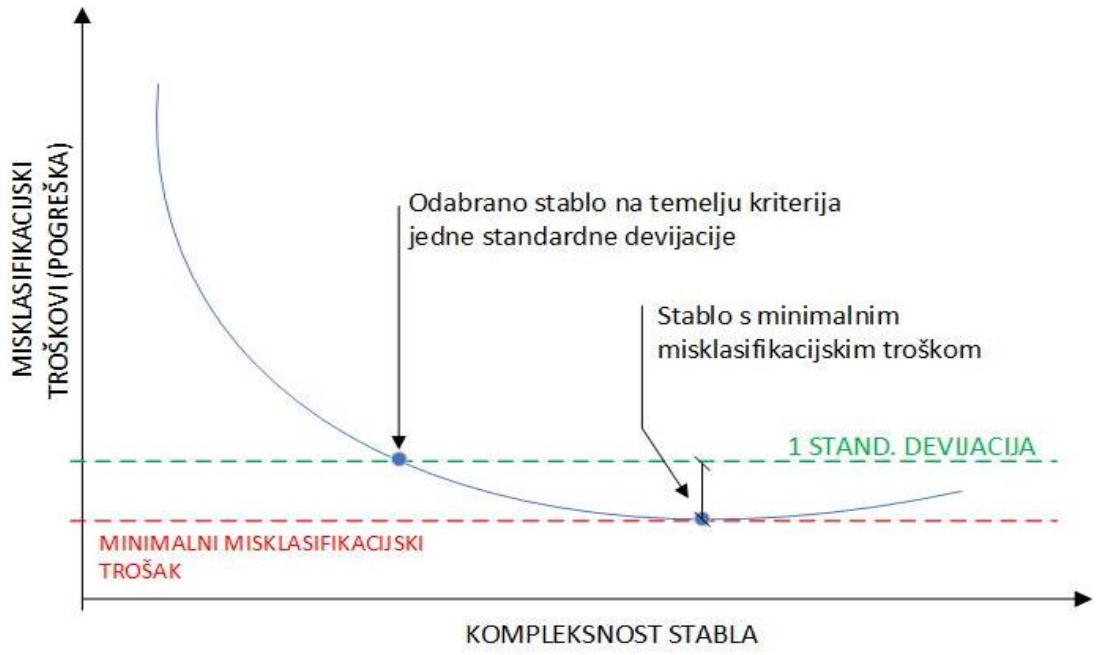
Kontinuirana slučajna varijabla može poprimiti neprebrojivo (beskonačno) mnogo vrijednosti. Područje vrijednosti kontinuirane varijable predstavlja neki interval na brojevnom pravcu ili čak čitav pravac. Područje vrijednosti diskontinuirane varijable predstavlja konačno ili prebrojivo mnogo diskontinuiranih (diskretnih) vrijednosti. Za razliku od diskretnih slučajnih varijabli gdje svaka vrijednost varijable ima neku konačnu vjerojatnost, svaka moguća vrijednost kontinuirane slučajne varijable imat će infinitezimalno malenu vjerojatnost. Stoga, kod kontinuirane varijable vjerojatnost možemo pridružiti nekom intervalu, ali pojedinačna vrijednost varijable ima vjerojatnost nula.

Proizvodnja i postavke izlazne jalove snage su definirane kao kategiričke odnosno diskretne varijable, budući da je domena tih varijabli podijeljena u tri međusobno nezavisna skupa podataka i to konkretno faktor snage - cos φ, jalova snaga i napon. Budući da se želi postići jedinstveni algoritam upravljanja koji bi uključivao i ove vrijednosti, predmetne varijable definirane su kao kategoričke odnosno diskretne varijable s diskretizacijom za koju se smatra da je dovoljno mala.

Klasifikacija se provodi uz korištenje klasteriranih signala EWS-a u pogonskim stanjima kao zavisne varijable. Nezavisne varijable su efektivne vrijednosti i fazni pomaci (kutevi) napona na svim čvorištima, kao i ukupna opterećenja sustava, djelatna snaga vjetroelektrane i jalova snaga vjetroelektrane. Kao pravilo za zaustavljanje kod indukcije klasifikacijskog stabla, koristi se kriterij obrezivanja stabla na temelju misklasifikacijske pogreške. Postupak obrezivanja stabla rezultira nizom obrezanih stabala i treba postojati kriterij za odabir stabla "pravilne veličine". Stablo s najmanjim

misklasifikacijskim troškovima često ima skriven nedostatak u dijelu prepodešavanja. Stoga je potrebno napraviti automatski postupak odabira stabla kako bi se izbjeglo pojavu prepodešavanja ili podpodešavanja podataka.

Da bi se napravila razlika između izračunatih stabala, troškovi resubstitucije i troškovi unakrsne validacije izračunavaju se za sva stabla, a odabire se stablo najmanjih troškova u slijedu stabala s troškovima. U ovom radu koristi se "pravilo jedne standardne devijacije" za odabir stabla "prave veličine". Istim pravilom definira se odabir stabla s najmanje složene strukture stabla čiji se misklasifikacijski troškovi ne razlikuju za jednu standardnu devijaciju od minimalnih misklasifikacijskih troškova.



Slika 4.5 Kvalitativni grafički prikaz odabira optimalnog stabla odlučivanja pravilom jedne standardne devijacije

Konačni rezultat je skup mogućih pogonskih stanja za normalno (NORMAL) pogonsko stanje - OC_P.

4.3. ODLUČIVANJE ZA PROMJENU REŽIMA RADA VJETROELEKTRANE

4.3.1 Definicija režima rada

Promjena režima rada vjetroelektrane odnosi se na promjenu dviju najbitnijih karakterističnih vrijednosti električnih veličina u sustavu i to:

- Izlazne djelatne snage vjetroelektrane - $P_{Settings}$,
- Izlazne jalove snage vjetroelektrane - $Q_{Settings}$

Odluke i signali za postavke ovih dviju veličina tj. za izlaznu djelatnu i jalovu snagu su krajnji rezultat cijelog algoritma odlučivanja o promjeni režima rada vjetroelektrane zasnovanog na sinkroniziranim mjerenjima.

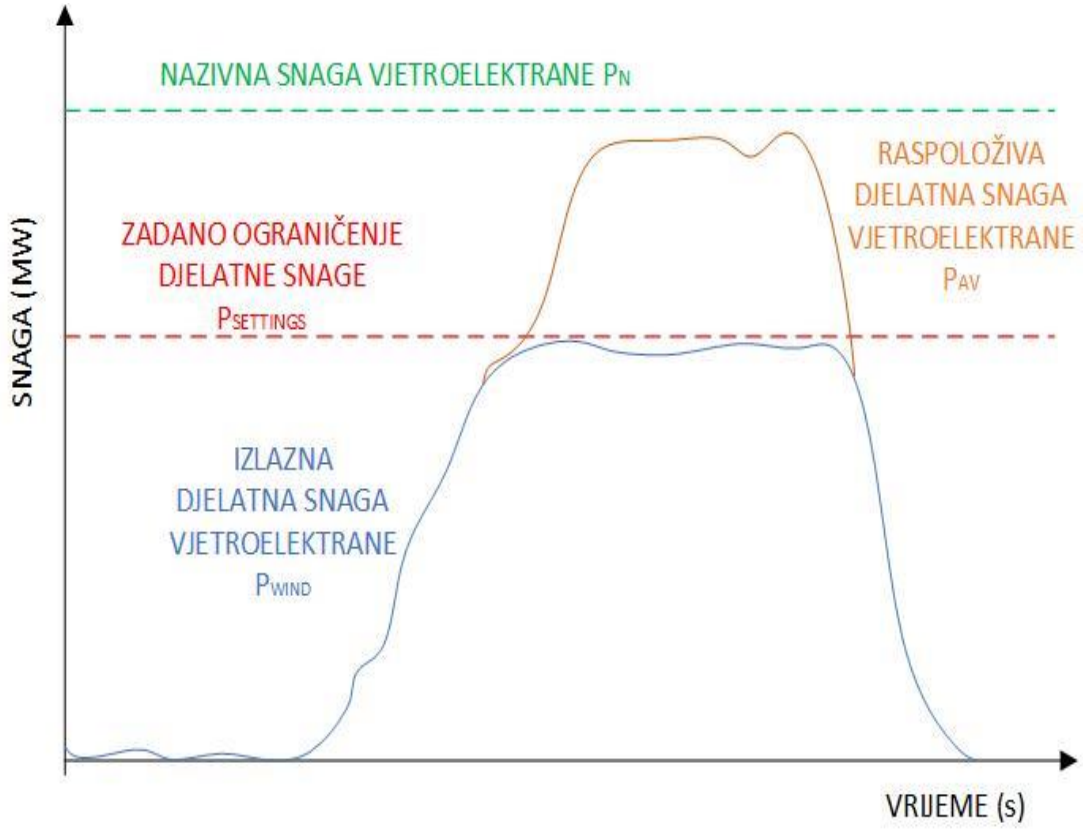
Kreiranjem obaju signala utječe se na centralno stanično računalo vjetroelektrane (HPPP) u cilju mijenjanja postavki za dvije definirane veličine. Predmetnu odluku može, u cilju utjecanja na pogon cijelog elektroenergetskog sustava, donijeti i operator elektroenergetskog sustava.

Mrežnim pravilima niza zemalja u svijetu, pa tako i Hrvatske, data je mogućnost operaterima elektroenergetskih sustava, da donose pogonske odluke ovakvog tipa, ukoliko je to u cilju sigurnosti pogona elektroenergetskog sustava.

Prema „Dodatnim tehničkim uvjetima za priključak i pogon vjetroelektrana na prijenosnoj mreži“ definirani su slijedeći zahtjevi po pitanju upravljanja radnom snagom vjetroelektrane, tj. ograničenja (eng. Wind curtailment) radne snage (poglavlje 3.1):

- upravljačkim sustavom vjetroelektrane mora se omogućiti smanjenje radne snage na referentnu veličinu prema nalogu HOPS-a,
- u slučaju da Proizvođač ne postupi po takvom nalogu, HOPS može privremeno isključiti vjetroelektranu s mreže,
- nalog za smanjenje radne snage potrebno je provesti u roku od 10 s,
- HOPS može zatražiti mijenjanje referentne veličine za smanjenje radne snage u realnom vremenu, što se mora izvesti u roku od 1min nakon prijema naloga.

U sklopu operativnih planova i programa ispitivanja pojedinih vjetroelektrana priključenih na Hrvatski elektroenergetski sustav, naročito za vjetroelektrane priključene na prijenosni elektroenergetski sustav, jedno od obaveznih ispitivanja je i ispitivanje ograničenja izlazne djelatne snage vjetroelektrane. Predmetno ispitivanje provodi se u četiri koraka i to 0%, 25%, 50% i 75% nazivne snage vjetroelektrane. Sukladno tome, tako će se i ovdje definirati pojedini koraci odlučivanja.



Slika 4.6 Kvalitativni grafički prikaz postavke režima rada vjetroelektrane u dijelu ograničenja djelatne snage

Što se tiče regulacije izlazne jalove snage vjetroelektrane, osnovna pretpostavka je da vjetroelektrana posjeduje sustav za regulaciju jalove snage pojedinačnih vjetroagregata u skupnoj regulaciji jalove snage vjetroelektrane kao cjeline, na osnovu mjerenja napona i jalove snage u točki priključka.

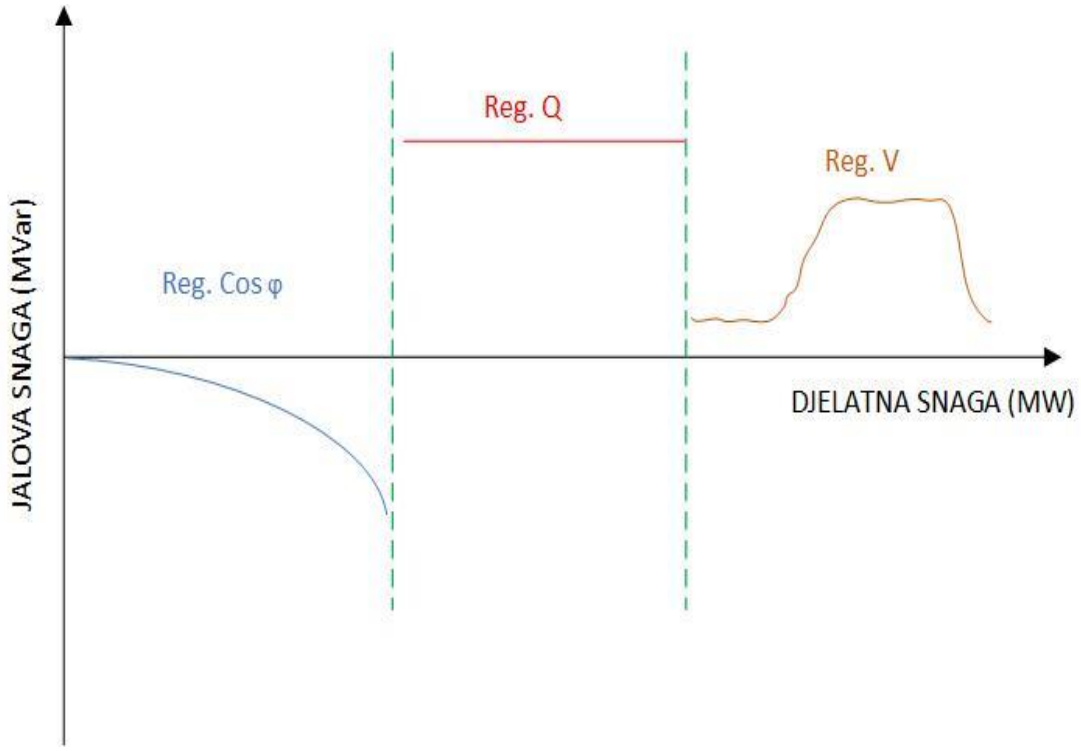
Nadalje, pretpostavljena su tri režima regulacije napona i izlazne jalove snage u točki priključka i to:

- reg. cos φ – regulacija konstantnog faktora snage na sučelju vjetroelektrane
- reg. Q, – regulacija konstante jalvoe snage na sučelju vjetroelektrane
- reg. U, – regulacija konstantnog napona na sučelju vjetroelektrane

U-Q regulacijom u modu tj. režimu upravljanja regulacije konstantne izlazne jalove snage, povratnom petljom regulira se vrijednost izlazne jalove snage na točki priključka.

U režimu regulacije cos φ, referentna vrijednost faktora snage pretvara se u internu referentnu vrijednost jalove snage u točki priključka, a na temelju aktualne proizvodnje djelatne snage te se ta ista referentna vrijednost stalno osvježava.

Navedeni režimi rada vjetroelektrane u dijelu regulacije napona i proizvodnje jalove snage, kvalitativno su prikazani na sljedećem grafičkom prikazu.



Slika 4.7 Kvalitativni grafički prikaz postavke režima rada vjetroelektrane u dijelu regulacije napona i proizvodnje jalove snage

4.3.2 Opis i obrazloženje donošenja odluka

U finalnom koraku, konačne odluke o pogonu vjetroelektrana donose se prema jednostavnom postupku odabira najboljeg mogućeg rješenja među skupom mogućih pogonskih stanja (OC_P) pri čemu je:

$$OC_P = [OC_2;\ OC_3;\ \ OC_p]^T \qquad \textbf{(4.9)}$$

Uz uvjet da je svaki element OC_P ujedno i element C_{NORMAL}.

U dijelu promjene izlazne djelatne snage vjetroelektrane - $P_{Settings}$, glavni cilj je smanjenje oportunitetnih troškova vjetroelektrane. Budući da vjetroelektrana svoj prihod, a samim tim i isplativost projekta temelji na prodaji električne energije bilo kroz feed-in-tarifu ili na otvorenom tržištu, glavni cilj je maksimalno iskorištenje raspoložive snage proizvodnje električne energije. Sukladno tome, glavna ciljna funkcija u procesu donošenja odluka u dijelu promjene izlazne djelatne snage vjetroelektrane je minimizacija oportunitetnih troškova iste.

$$min\ \{C_{WOPP}\} \qquad \textbf{(4.10)}$$

C_{WOPP} - oportunitetni troškovi vjetroelektrane

Minimizacija oportunitetnih troškova dalje se definira kao minimizacija umnoška cijene električne energije i smanjenja djelatne snage vjetroelektrane

$$min\ \{c_{EL\text{-}EN} \cdot \Delta P_{VE}\} \qquad \textbf{(4.11)}$$

$c_{EL\text{-}EN}$ - cijena električne energije
ΔP_{VE} - smanjenje djelatne snage vjetroelektrane

Odnosno

$$min\ \{c_{EL\text{-}EN} \cdot (P_{AV} - P_{Wind})\} \qquad \textbf{(4.12)}$$

P_{AV} - raspoloživa snaga proizvodnje vjetroelektrane
P_{Wind} - stvarna snaga proizvodnje vjetroelektrane

Veličina $c_{EL\text{-}EN}$ spada u domenu tržišta električnom energijom i često je ili fiksna u obliku feed-in-tarife, ili je nepromjenjiva u tako kratkom vremenu u kojem se zbivaju potrebne odluke u domeni sigurnosti elektroenergetskog sustava. Stoga se za potrebe ovog rada ista veličina može smatrati fiksnom.

Veličina P_{AV} predstavlja raspoloživu snagu proizvodnje vjetroelektrane i ona nije ovisna o prilikama u sustavu već je ovisna o meteorološkim prilikama i prilikama u internoj kabelskoj mreži odnosno o raspoloživosti pojedinog vjetroagregata.

Iz svega navedenog, jedina veličina na koju se u ovom dijelu odlučivanja može utjecati jest stvarna snaga proizvodnje postavljanjem ograničenja.
Sukladno tome, konačni uvjet funkcije cilja u dijelu promjene izlazne djelatne snage vjetroelektrane glasi

$$max \{P_{Wind}\} \qquad \textbf{(4.13)}$$

U dijelu promjene izlazne jalove snage vjetroelektrane - $Q_{Settings}$, glavni cilj je smanjenje pogonskih troškova vjetroelektrane i produljenje vijeka trajanja same vjetroelektrane.

Na temelju toplinskih podataka uređaja energetske elektronike, naročito u najčešće korištenom modelu vjetroelektrana s dvostrukim konverterom (eng. Full scale converter), provedeno je nekoliko istraživanja o utjecaju rada takvih vjetroelektrana u području induktivne i kapacitivne jalove snage. Korištenjem najčešće primjenjivanog modela životnog vijeka tzv. Coffin-Mansonovog modela, istraživanja i modeli su pokazali da će pogon vjetroagregata u području proizvodnje jalove snage, bitno skratiti vijek trajanja samog vjetroagregata.

Sukladno tome, konačni uvjet funkcije cilja u dijelu promjene izlazne jalove snage vjetroelektrane glasi

$$min \{Q_{Wind}\} \qquad \textbf{(4.14)}$$

Time se odabiru konačne postavke izlazne djelatne i jalove snage vjetroelektrane.

Postoji i krajnji uvjet koji se pri tom mora ispoštovati. Naime, energetski transformatori u točki priključka (PCC) mogu imati ograničenu nazivnu snagu. Stoga u tom slučaju na kraju treba ispuniti i dodatni kriterij pogonskog ograničenja kako se ne bi ugrozila ova vrlo važna komponenta.

$$S_{TR} \geq (P_{Wind}^2 + Q_{Wind}^2)^{1/2} \qquad \textbf{(4.15)}$$

Gdje je:

S_{TR} - nazivna snaga transformatora (MVA).

4.3.3 Dodatne mogućnosti i nadopune

Među mogućim nadopunama, valja prvenstveno istaknuti mogućnost rankiranja ulaznih varijabli odnosno elemenata matematičkog skupa koji definiraju pogonsko stanja. Rankiranje se obavlja po važnosti odnosno signifikantnosti. Kao mjera signifikantnosti koristi se definicija usvojena od Breimana [L 48], odnosno kako slijedi:

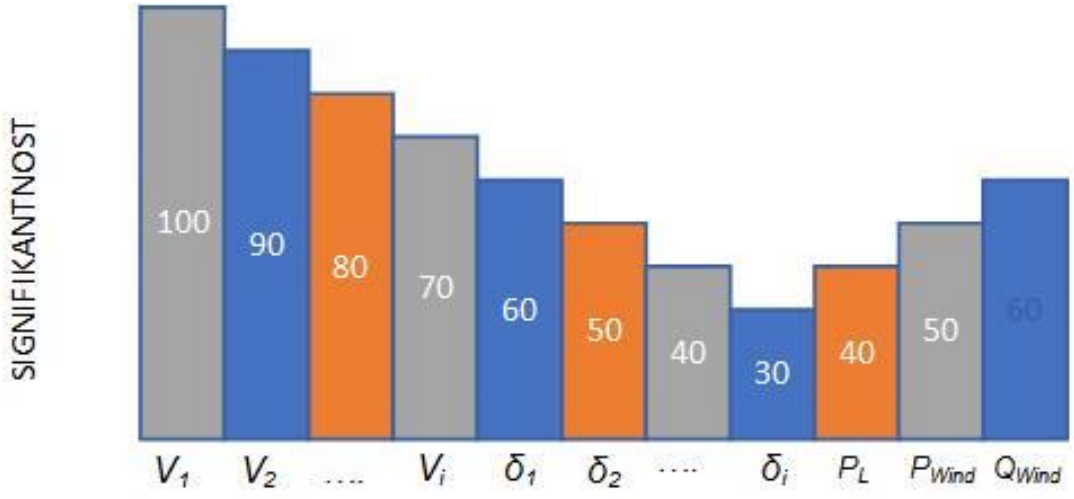
$$M(x_m) = \Sigma\, \Delta i\, (\underline{s_m},\, t) \qquad \textbf{(4.16)}$$

gdje je:

$\underline{s_m}$ - operacija alternativnog ili surogat grananja u čvorištu t

$\Delta i\, (\underline{s_m},\, t)$ - povećanje nečistoće čvorišta na surogat operaciji grananja s_m, na grani t

Rezultat se može prikazati i grafički za rankiranje pojedinih varijabli.



Slika 4.8 Kvalitativni grafički prikaz signifikantnosti varijabli

Prilikom definiranja varijabli u dijelu parametara izlazne jalove snage, kao očigledna dodatna mogućnost i nadopuna nameće se definiranje istiha varijabli kao kontinuiranih varijabli. Da bi se takvo nešto moglo obaviti potrebno je predmetnu funkciju definirati kao određenu vrstu konvolucijske funkcije.

$$Q_{CON} = f(\cos\varphi)\ ¤\ g(Q)\ ¤\ h\,(U) \qquad \textbf{(4.17)}$$

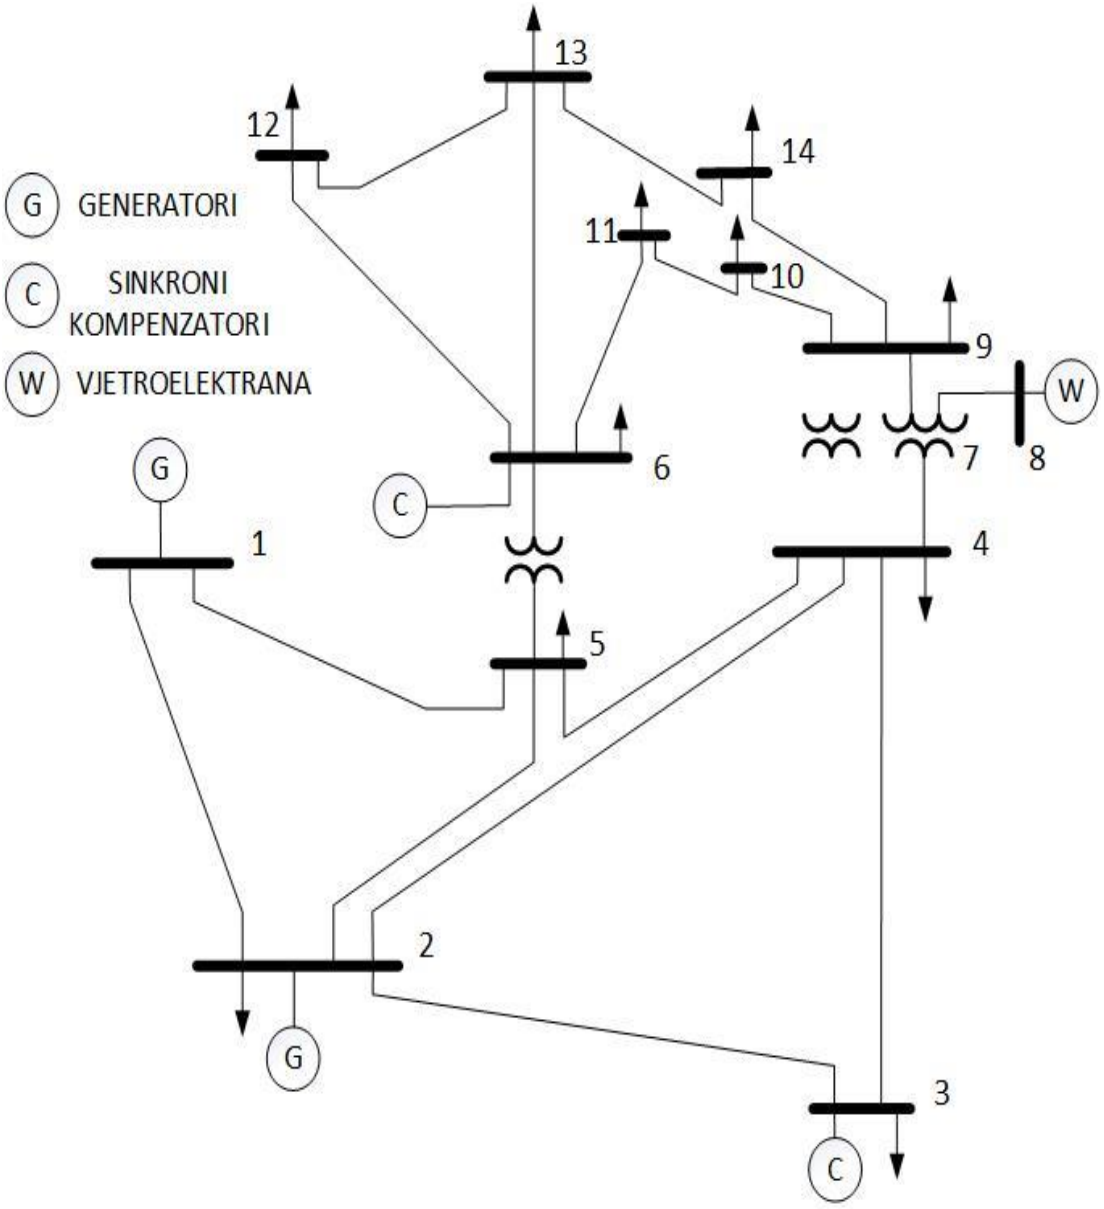
Ukoliko ovako definirana konvolucije ne daje zadovoljavajuće rezultate, uvijek je moguće napraviti diskretizaciju na jako male diskretne intervale u pojedinim područjima koja obuhvaćaju regulaciju jalove snaga. Tako se, za razliku od metodologije kreiranja pogonskih stanja definirane u poglavlju 4.2.2., ti koraci mogu dodatno usitniti i približiti kontinuiranom obliku varijable.

5. NUMERIČKI PRIMJERI I VALIDACIJA MODELA

5.1. IEEE MODEL SA 14 ČVORIŠTA

5.1.1 Osnovni ulazni podaci

Kao prvi numerički primjer za validaciju modela korišten je standardizirani IEEE model sa 14 čvorišta. Umjesto sinkronog kompenzatora na čvorištu br. 8 definirana je vjetroelektrana nazivne snage 20 MW. Izračuni elektroenergetskog sustava izrađeni su u DigSilent softveru.



Slika 5.1 Grafički prikaz standardiziranog testnog modela IEEE-14 sa 14 čvorišta

U ovom numeričkom primjeru, mogli su se proizvesti samo sintetički podaci i kao takvi i analizirati. Budući da je IEEE 14 testni sustav, nije bilo stvarnih povijesnih podataka o mjerenjima ili pogonskim događajima, pa je sukladno tome korištena simulacija. Stoga je korak pripreme podataka bio pojednostavljen i nije bilo potrebe za formatiranjem/unifikacijom podataka i vremenskoj sinkronizaciji. Pogonska stanja (OC) definirana su sukladno poglavlju 4.2.1. čiji su članovi sljedeći elementi

$$OC_k = \{V_1, V_2, V_3, V_4, V_5, V_6, V_7, V_8, V_9, V_{10}, V_{11}, V_{12}, V_{13}, V_{14}, \delta_1, \delta_2, \delta_3, \delta_4, \delta_5, \delta_6, \delta_7, \delta_8, \delta_9, \delta_{10}, \delta_{11}, \delta_{12}, \delta_{13}, \delta_{14}, P_L, P_{Wind}, Q_{Wind}, R_{th}, X_{th}\} \quad \textbf{(5.1)}$$

Pri čemu je:

V_1 - efekt. vrijednost napona na čvorištu br. 1,
V_2 - efekt. vrijednost napona na čvorištu br. 2,
V_3 - efekt. vrijednost napona na čvorištu br. 3,
V_4 - efekt. vrijednost napona na čvorištu br. 4,
V_5 - efekt. vrijednost napona na čvorištu br. 5,
V_6 - efekt. vrijednost napona na čvorištu br. 6,
V_7 - efekt. vrijednost napona na čvorištu br. 7,
V_8 - efekt. vrijednost napona na čvorištu br. 8,
V_9 - efekt. vrijednost napona na čvorištu br. 9,
V_{10} - efekt. vrijednost napona na čvorištu br. 10,
V_{11} - efekt. vrijednost napona na čvorištu br. 11,
V_{12} - efekt. vrijednost napona na čvorištu br. 12,
V_{13} - efekt. vrijednost napona na čvorištu br. 13,
V_{14} - efekt. vrijednost napona na čvorištu br. 14,
δ_1 - kut napona na čvorištu br. 1,
δ_2 - kut napona na čvorištu br. 2,
δ_3 - kut napona na čvorištu br. 3,
δ_4 - kut napona na čvorištu br. 4,
δ_5 - kut napona na čvorištu br. 5,
δ_6 - kut napona na čvorištu br. 6,
δ_7 - kut napona na čvorištu br. 7,
δ_8 - kut napona na čvorištu br. 8,
δ_9 - kut napona na čvorištu br. 9,
δ_{10} - kut napona na čvorištu br. 10,
δ_{11} - kut napona na čvorištu br. 11,
δ_{12} - kut napona na čvorištu br. 12,
δ_{13} - kut napona na čvorištu br. 13,
δ_{14} - kut napona na čvorištu br. 14,
P_L - opterećenje sustava,
P_{Wind} - djelatna snaga vjetroelektrane,
Q_{Wind} - jalova snaga vjetroelektrane,
R_{th}, - djelatni dio nadomjesne Theveninove impedancije na čvoru 8
X_{th} - reaktivni dio nadomjesne Theveninove impedancije na čvoru 8

Uz k = 1, 2, 3, ...396

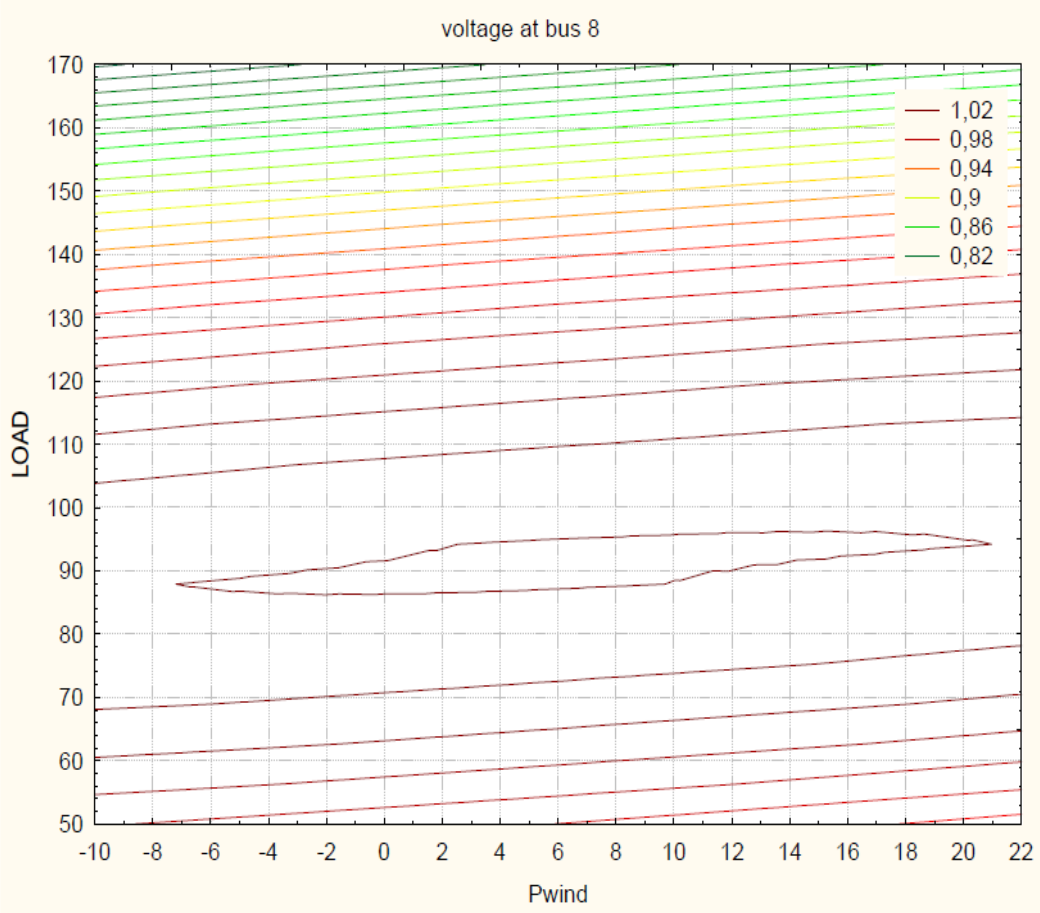
Vektor ulaznih podataka u proces klasterizacije jednak je:

$$OC = [OC_1; OC_2; OC_3; \quad OC_{396}]^T \qquad \textbf{(5.2)}$$

Na taj način matematički su definirana pogonska stanja kao ulazni podaci u algoritam.

5.1.2 Rezultati modela

Analiza je provedena u programu STATISTICA. Na taj je način moguće napraviti niz različitih analiza. Primjerice, izolinije napona za čvorište 8 na testnom sustavu IEEE 14 u različitim opterećenjima sustava i različitoj proizvodnji vjetroelektrane koja radi u režimu regulacije cos φ uz postavku cos φ = 1, prikazane su na sljedećoj slici.



Slika 5.2 Grafički prikaz napona na čvorištu br. 8 standardiziranog testnog modela IEEE-14 sa 14 čvorišta u ovisnosti o opterećenju cijelog sustava i proizvodnji vjetroelektrane na čvorištu br. 8

Iz prethodne slike vidljivo je kako su s povećanjem opterećenja i/ili proizvodnje vjetroelektrane, naponske izolinije gusto raspoređene, što se objašnjava većom osjetljivošću napona u ovim pogonskim stanjima.

Nakon klasteriranja podataka, korištenjem algoritma k-srednjih vrijednosti, dobiveni centroidi triju klastera Theveninovog ekvivalenta, temeljeno na ukupno 396 slučajeva obuke, dati su u sljedećoj tablici:

Tablica 5-1 Centroidi Theveninog ekvivalenta triju klastera EWS signala dobivenih algoritom k-srednjih vrijednosti primijenjenih na IEEE 14 testnom modelu sa 14 čvorišta

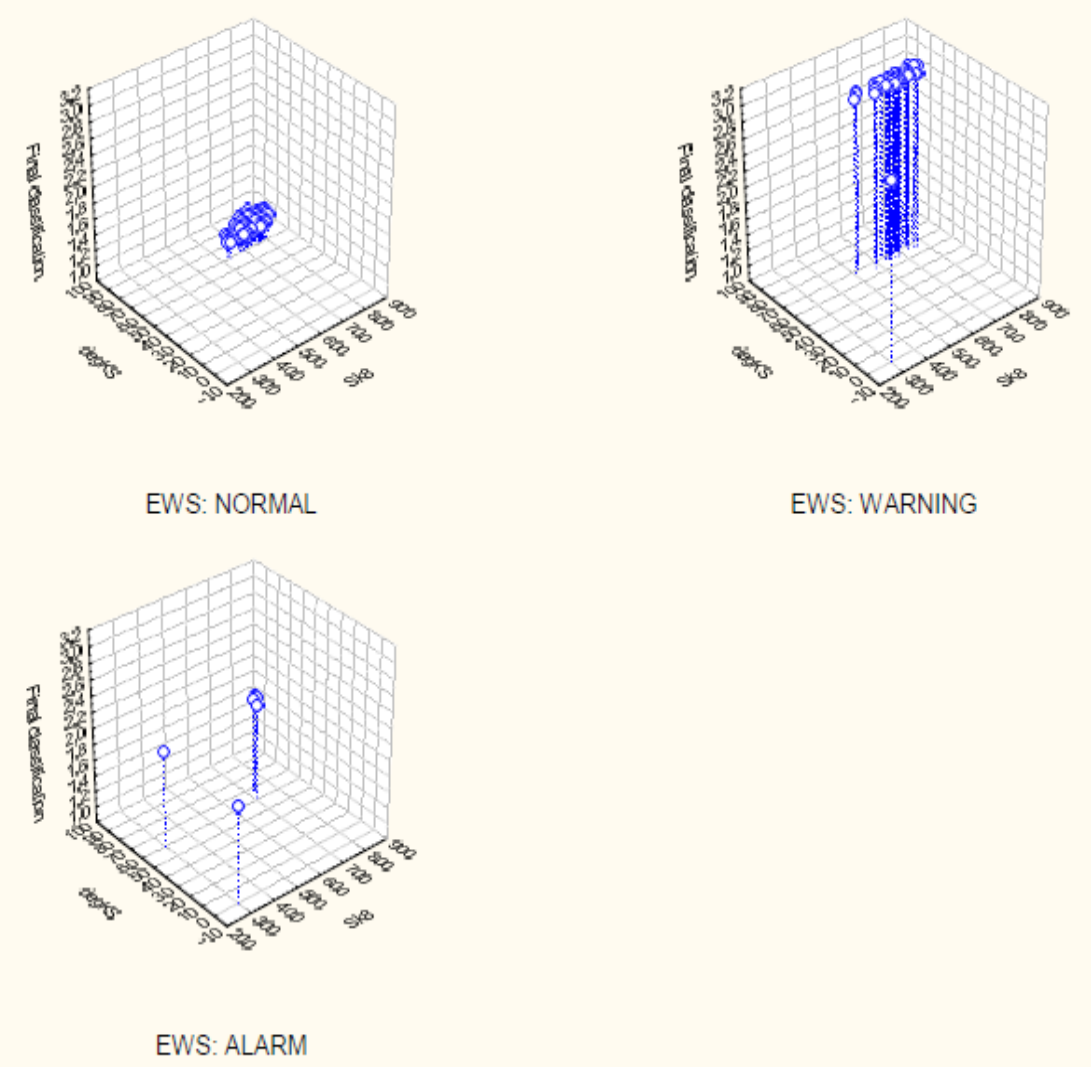
EWS	Z_{th} abs	Z_{th} arg	Broj slučajeva
NORMALNO (NORMAL)	0,438743	87,91876	295
IZVANREDNO (WARNING)	0,554339	80,64339	85
KRITIČNO (ALARM)	2,179344	69,31481	16

Pri čemu je

EWS - signal ranog upozorenja (eng. Early warning signal)
Z_{th} abs - apsolutna vrijednost impedancije Theveninovog ekvivalenta u točki priključka vjetroelektrane
Z_{th} arg - argument impedancije Theveninovog ekvivalenta u točki priključka vjetroelektrane

Vidljivo je da najveći broj slučajeva otpada na pogonska stanja u normalnom pogonskom stanju što je i očekivano. Simulacijama se sustav morao modelirati u izvanrednom i kritičnom pogonskom stanju da bi se mogao izraditi i uzorak istih pogonskih stanja. U realnim slučajevima stvarnih elektroenergetskih sustava, takva pogonska stanja će biti vrlo rijetko izmjerena odnosno snimljena u svojim karakteristikama i parametrima. Stoga će uzorak takvih stanja gotovo uvijek biti izrađen sintetički odnosno korištenjem simulacija.

Theveninove impedancije mogu se prikazati pomoću snaga kratkog spoja tako da su klasteri vrijednosti signala EWS prema snazi kratkog spoja na čvorištu 8 i pripadajući fazni pomak odnosno kut struje kratkog spoja prikazani na sljedećoj slici



Slika 5.3 Grafički prikaz triju klastera standardiziranog testnog modela IEEE-14 sa 14 čvorišta korištenjem snaga kratkog spoja na čvorištu br. 8 i faznog pomaka struje kratkog spoja na čvorištu br. 8 na priključku vjetroelektrane

Prema centroidima signala EWS i njihovom grupiranju prikazanom na slici 5.3, vidljivo je kako elektroenergetski sustav mijenja svoju ekvivalentnu impedanciju na veće apsolutne i više reaktivne (induktivne) vrijednosti tijekom pogonskih stanja koja spadaju u izvanredno i kritično pogonsko stanje što predstavlja i očekivano ponašanje.

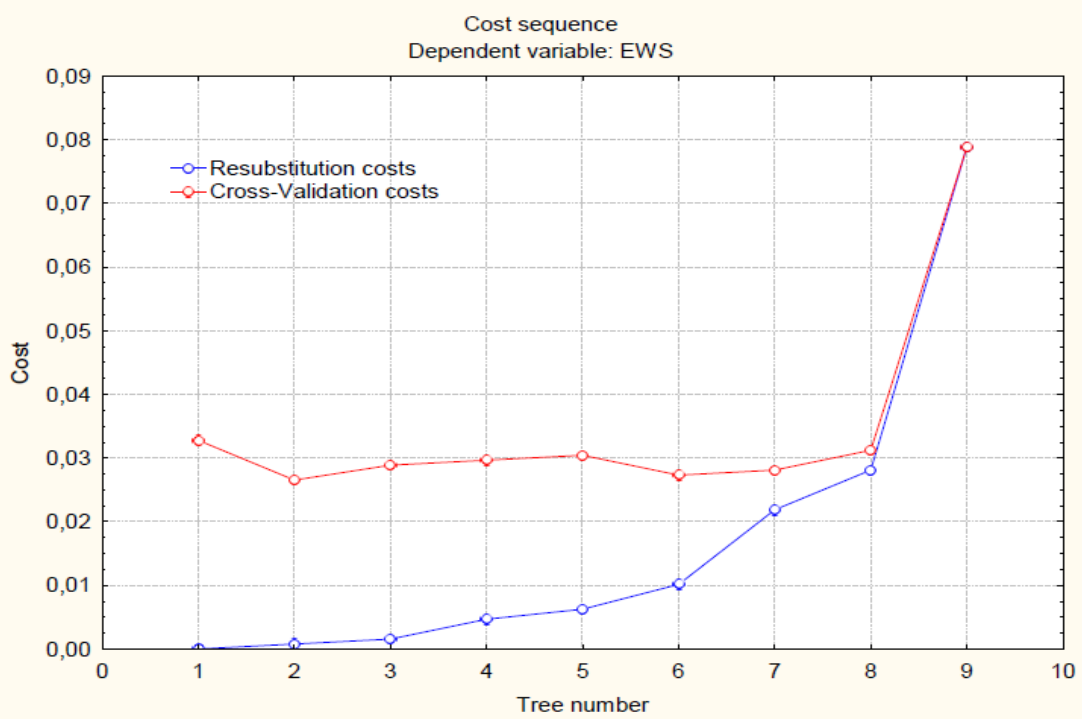
Izračunati klasteri se koriste u daljnjem tijeku algoritma za klasifikaciju novih stanja. Klasifikacija je provedena uz korištenje klasteriranih signala EWS-a u pogonskim stanjima kao zavisne varijable. Nezavisne varijable su efekt. vrijednosti i fazni pomaci (kutevi) napona na svim čvorištima, kao i ukupna opterećenja sustava, djelatna snaga vjetroelektrane i jalova snaga vjetroelektrane.

Kao pravilo za zaustavljanje kod klasifikacijskog stabla, korišten je kriterij obrezivanja stabla odlučivanja na temelju misklasifikacijske pogreške. Misklasifikacijski troškovi za sve modele određeni su uniformno za sve modele i to heurističkom metodom te su prikazani u sljedećoj tablici:

Tablica 5-2 Definirani troškovi misklasifikacije za sve modele

	NORMAL	WARNING	ALARM
NORMAL	0	1	5
WARNING	1	0	3
ALARM	1	1	0

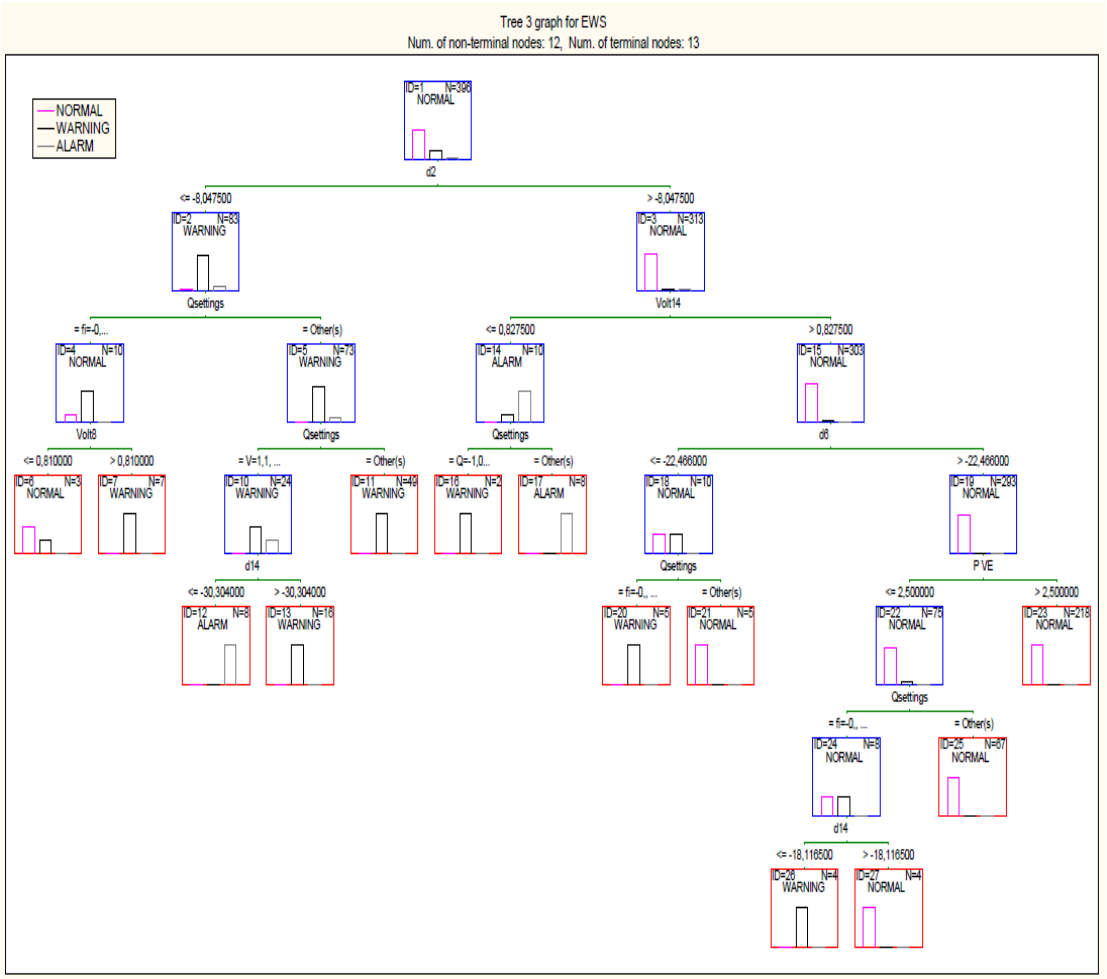
Troškovi resubstitucije i troškovi unakrsne validacije izračunavaju se za sva stabla, a slijed troškova prikazan je na sljedećoj slici:



Slika 5.4 Grafički prikaz odabira optimalnog stabla odlučivanja testnog modela IEEE-14 sa 14 čvorišta korištenjem metode misklasifikacijskih troškova

U ovom radu koristi se "pravilo jedne standardne pogreške" za odabir stabla "prave veličine". Na taj način odabire se stablo br. 2 kako bi se izbjeglo prepodešavanje ili podpodešavanje podataka.

Optimalno odabrano stablo dato je na sljedećoj slici:



Slika 5.5 Grafički prikaz optimalnog stabla odlučivanja testnog modela IEEE-14 sa 14 čvorišta

Vidljivo je iz generiranog stabla odlučivanja da su dovoljna mjerenja PMU uređaja na čvorištima 2, 6, 8 i 14. Stoga i ovaj rad ide u prilog tezi smanjenja količine podataka i mjerenja u sustavu odnosno optimiranju instalacija PMU uređaja i ostale napredne mjerne tehnologije.

Nadalje, vidljivo je da u režimu regulacije napona reg. cos φ = 1, ukoliko i nastupi izvanredno ili kritično pogonsko stanje, potrebno je promijeniti režim regulacije napona najčešće u reg. Q. To oslikava i situacije iz stvarnog pogona vjetroelektrana gdje će u kritičnim situacijama biti potrebno osigurati jalovu snagu za regulaciju napona i jalove snage.

5.1.3 Validacija modela IEEE 14

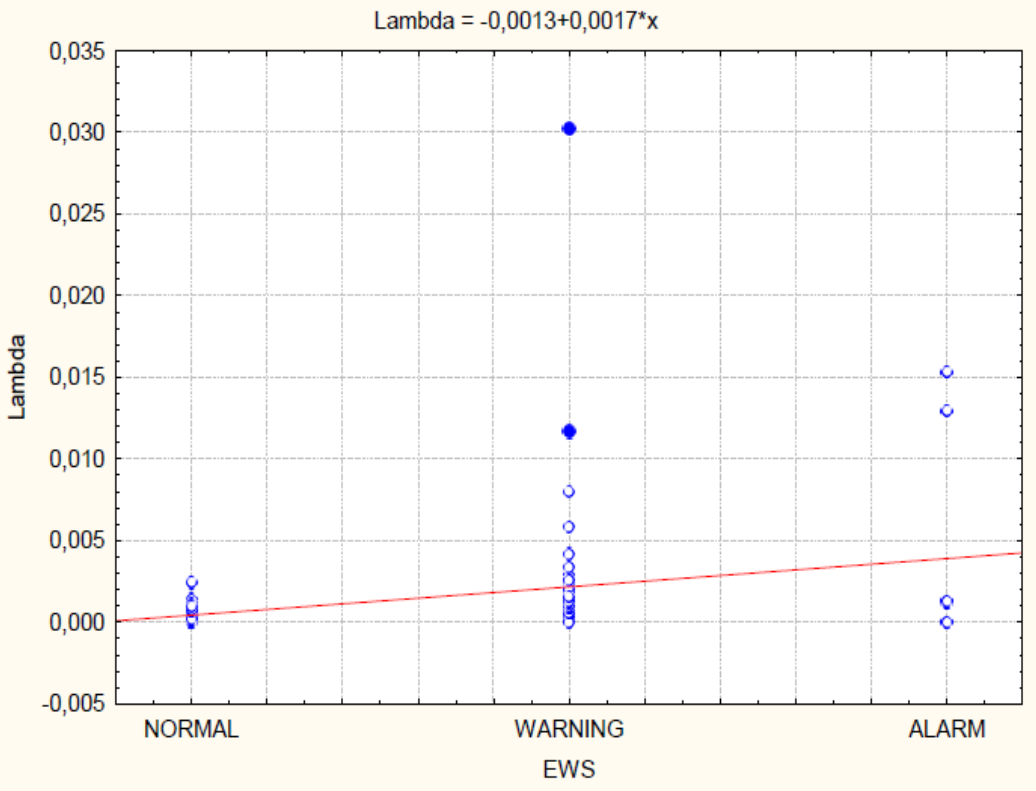
Validacija klasteriranja napravljena je koristeći svojstvene vrijednosti Jacobijeve matrice. Budući da je Jacobi matrica za IEEE 14 testni sustav imala 14 svojstvenih vrijednosti, srednja efektivna vrijednost svih 14 vrijednosti korištena je kao nova varijabla koja je označena kao λ.

$$\lambda = (\lambda_1^2 + \lambda_2^2 + \lambda_3^2 + \lambda_4^2 + \ldots \lambda_n^2)^{1/2} \qquad \textbf{(5.3)}$$

gdje je:

λ - srednja efektivna vrijednost svojstvenih vrijednosti Jacobi matrice
λ_1 - 1. svojstvena vrijednost Jacobi matrice
λ_2 - 2. svojstvena vrijednost Jacobi matrice
...
λ_n - n-ta svojstvena vrijednost Jacobi matrice (u ovom slučaju 14.)

Na sljedećoj slici vidljivo je kako su lambda vrijednosti grupirane za normalno, kritično i izvanredno pogonsko stanje kao graf raspršenja.

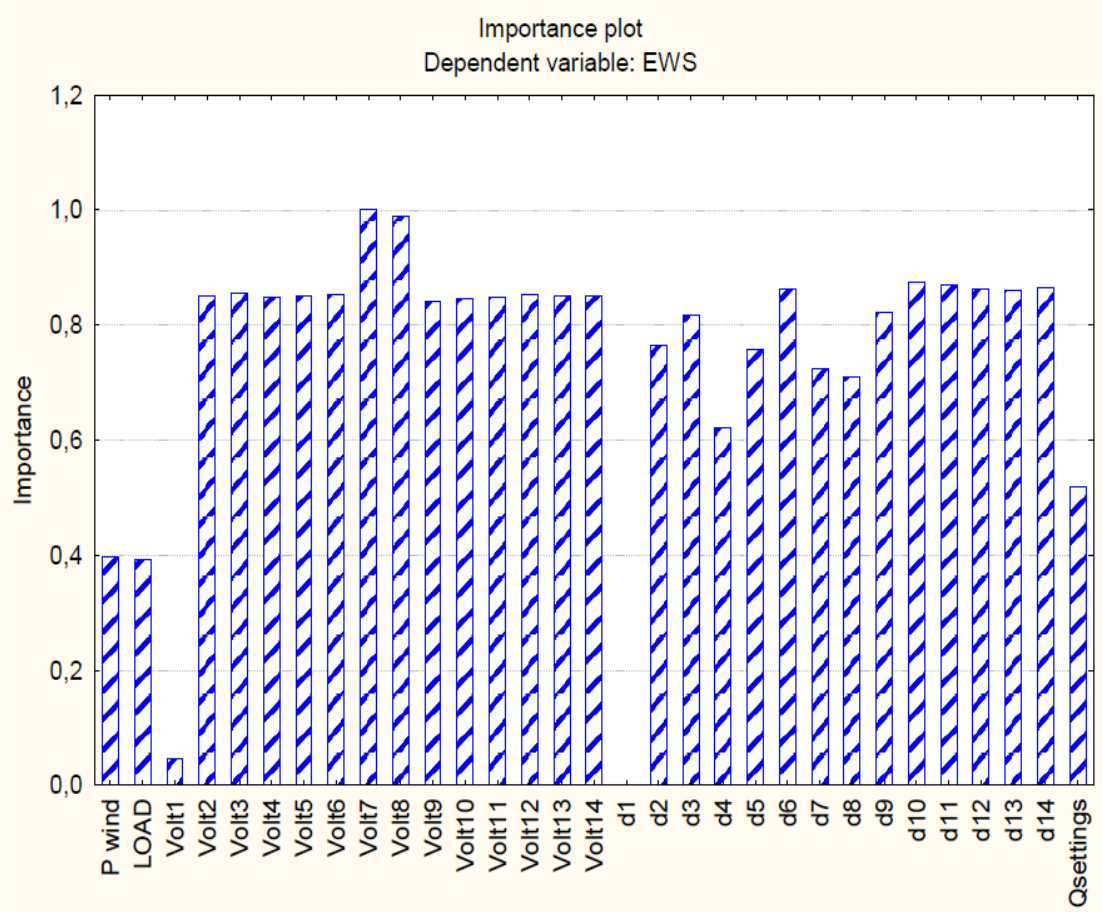


Slika 5.6 Grafički prikaz efektivne vrijednosti svojstvenih vrijednosti Jacobi matrice testnog modela IEEE-14 sa 14 čvorišta za sva tri klastera pogonskih stanja

Na taj način, signal ranog upozorenja provjerava se pomoću svojstvenih svojstava Jacobijeve matrice.

Također, kroz ovu klasifikacijsku analizu, moguće je izračunati signifikantnost za sve neovisne varijable prema definiciji varijabilne signifikantnosti.

Signifikantnost za sve zavisne varijable prikazana je na sljedećoj slici.



Slika 5.7 Grafički prikaz signifikantnosti neovisnih varijabli testnog modela IEEE-14 sa 14 čvorišta za ovisnu varijablu signala EWS

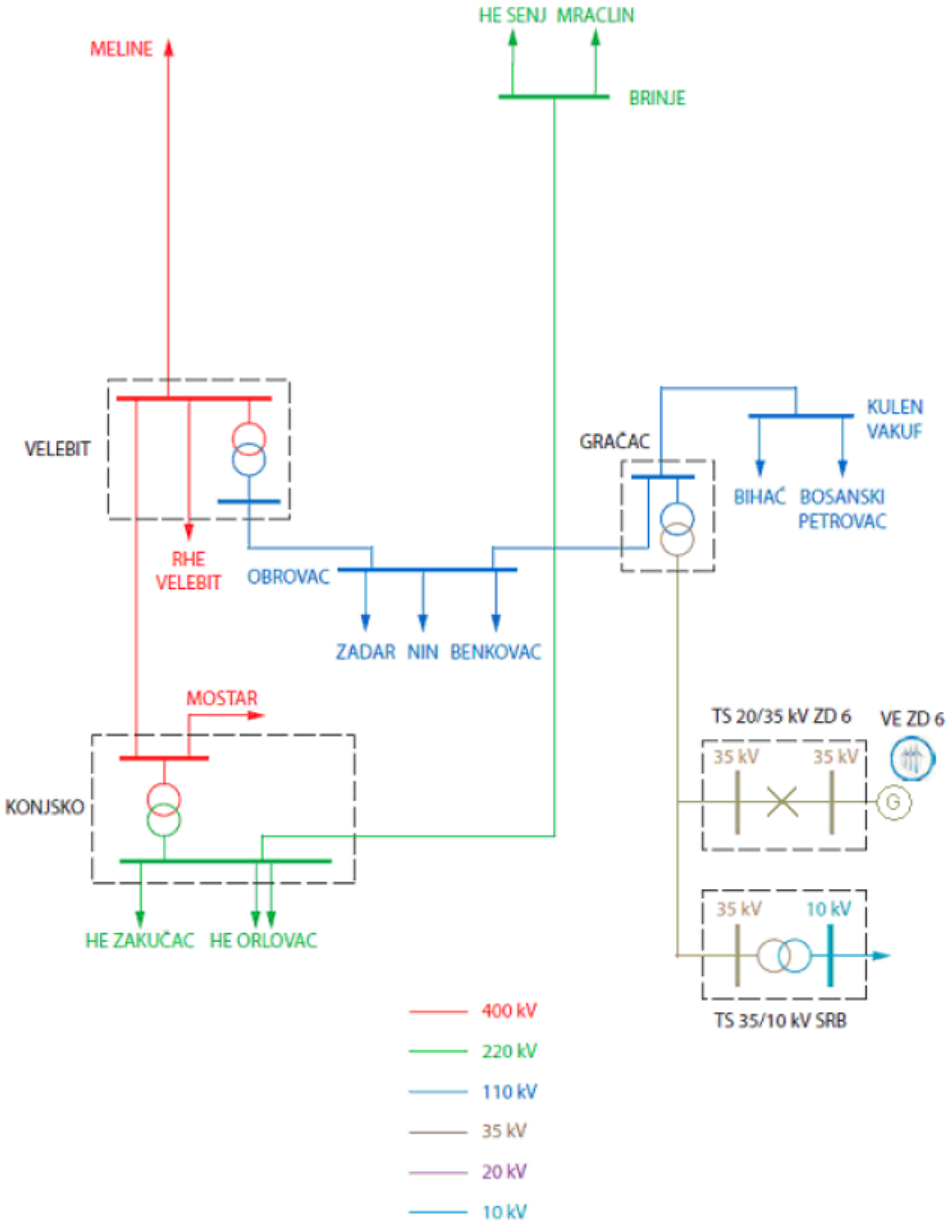
Može se vidjeti da praktički svi rezultati efekt. vrijednosti i kuta napona iz PMU uređaja imaju vrlo veliku signifikantnost, osim mjerenja iz čvorišta 1 koji je izabrano kao referentna sabirnica.

Kutevi napona (d1, d2, ... d14) imaju vrlo veliku važnost koja je razumljiva jer praktički predstavljaju glavne tokove snage. Djelatna snaga vjetroelektrane i postavke za jalovu snagu imaju manju važnost koja se može opisati putem umjerene instalirane snage vjetroelektrane u usporedbi s veličinom mreže.

5.2. MODEL VJETROELEKTRANE ZADAR 6

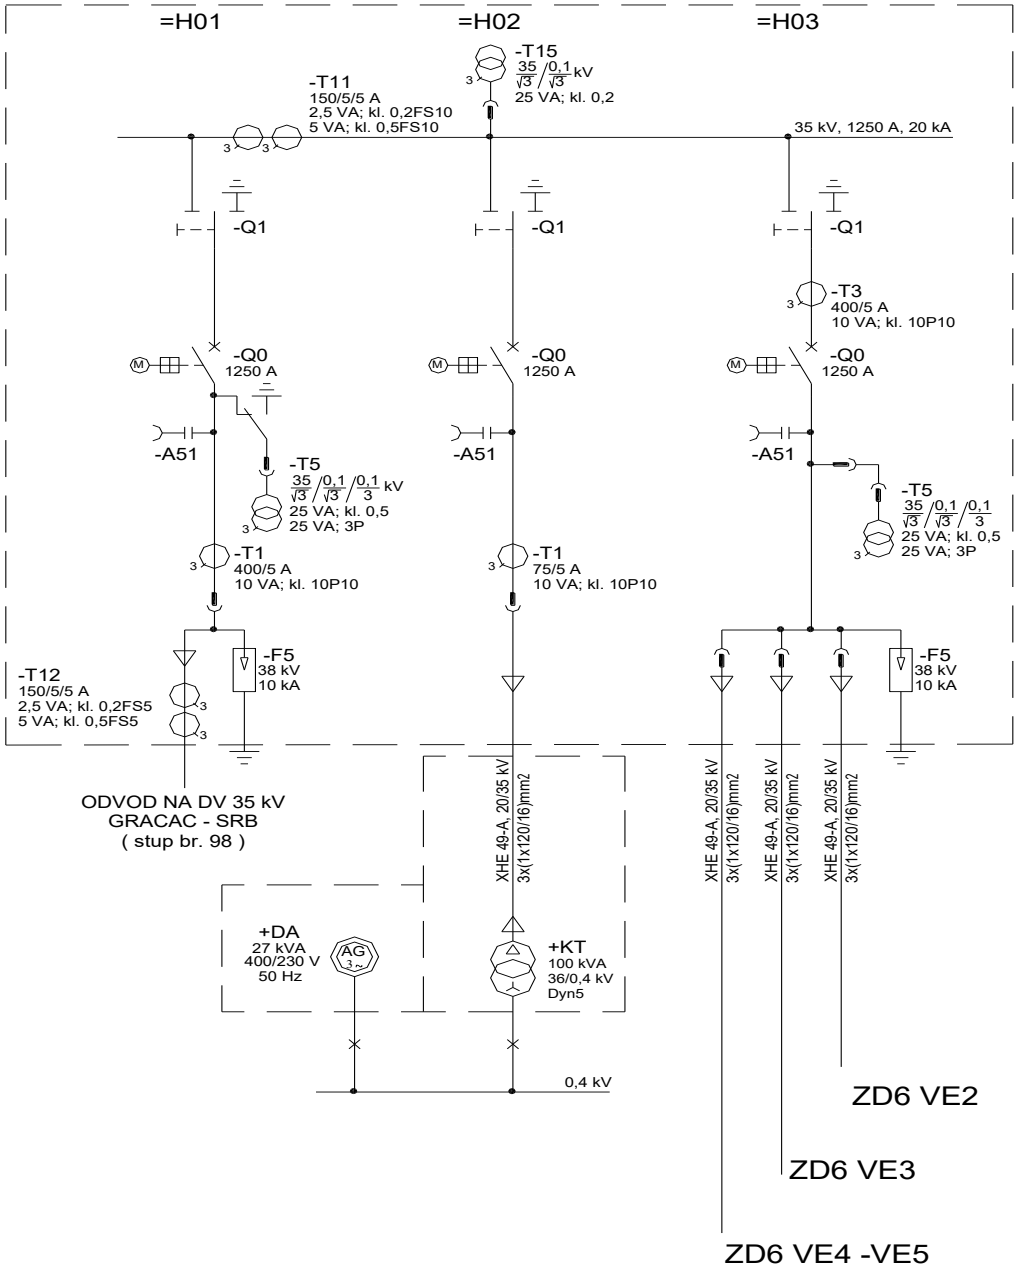
5.2.1 Osnovni ulazni podaci

Vjetroelektrana Zadar 6 (VE ZD6) smještena je na području u blizini grada Gračaca i sastoji se od 4 vjetroagregata (naziva VE2, VE3, VE4, VE5) proizvođača Siemens tip SWT-2.3 VS pojedinačne snage 2.3 MW odnosno ukupne instalirane snage vjetroelektrane od 9.2 MW. Priključena je na radijalni 35 kV vod Gračac – Srb, prema sljedećoj blok shemi:



Slika 5.8 Blok shema priključka vjetroelektrane Zadar 6 na elektroenergetsku mrežu

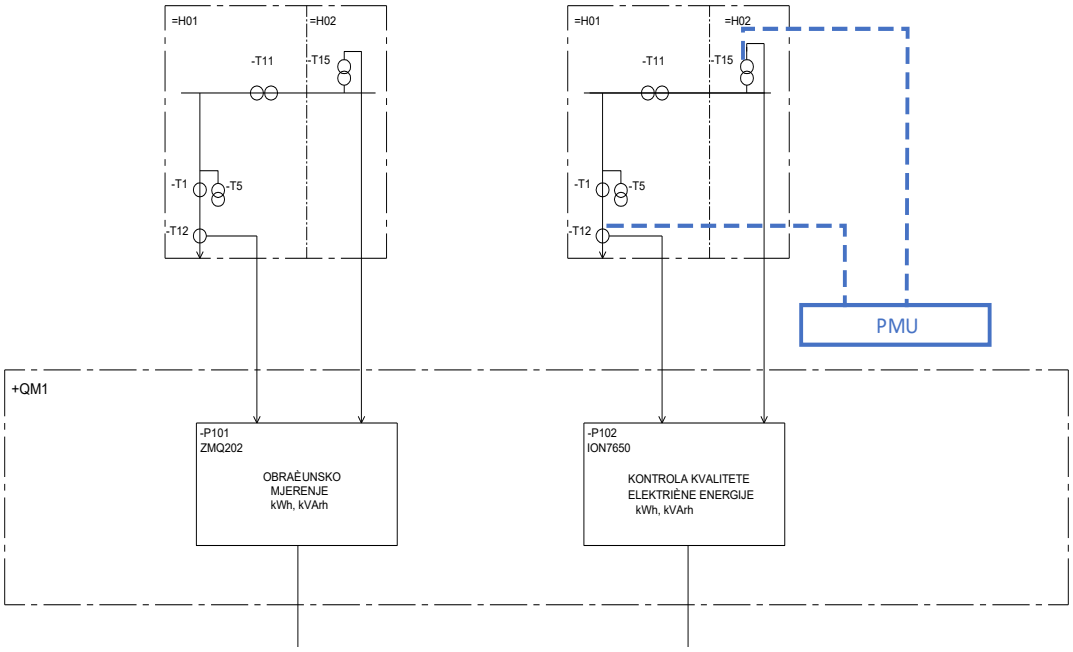
U samoj točki priključka, izgrađeno je priključno rasklopno postrojenje čija je jednopolna shema data na sljedećoj slici.



Slika 5.9 Jednopolna shema vjetroelektrane Zadar 6 i priključka u rasklopnoj stanici TS 35 kV Zadar 6

Vjetroagregati daju dodatnu mogućnost regulacije napona na mjestu priključka vjetroelektrane na mrežu. Vjetroagregati instalirani na VE ZD 6 imaju priključak na internu kabelsku mrežu preko frekvencijskog pretvarača (eng. FSFC – Full Scale Frequency Converter) izvedenog u tehnici IGBT tranzistora, a koji radi u režimu pulsno širinske modulacije (eng. PWM – Pulse Width Modulation). Na taj način omogućen je pogon vjetroelektrane u širokom spektru faktora snage.

Mjerenja su obavljena na sučelju vjetroelektrane odnosno na izlaznom vodnom polju



Slika 5.10 Blok shema mjernih uređaja vjetroelektrane Zadar 6

Mjerni uređaji za obračunsko mjerenje (LandysGyr ZMQ202) i kontrolu kvalitete el energije (ION 7660) instalirani su u ormaru +QM1. Korišteni PMU uređaj (Arbiter 1133a) instaliran je privremeno u ormar +QM1 za vrijeme pokusnog rada vjetroelektrane odnosno obavljanja mjerenja.

5.2.2 Definicija varijabli i pogonskih stanja

Svako pogonsko stanje (OC) definirano je kao matematički skup podataka sukladno definiciji pogonskih stanja i varijabli u poglavlju 4.2.1. čiji su članovi sljedeći elementi

$$OC_k = \{V_{ZD6}, V_{SRB}, V_{GRA35}, V_{GRA110}, V_{OBR110}, \delta_{ZD6}, \delta_{SRB}, \delta_{GRA35}, \delta_{GRA110}, \delta_{OBR110}, P_L, P_{Wind}, Q_{Wind}, R_{th}, X_{th}\} \quad \textbf{(5.4)}$$

Pri čemu je:

V_{ZD6}	-	efekt. vrijednost napona na čvorištu 35 kV VE ZD6,
V_{SRB}	-	efekt. vrijednost napona na čvorištu 35 kV Srb,
V_{GRA35}	-	efekt. vrijednost napona na čvorištu 35 kV Gračac,
V_{GRA110}	-	efekt. vrijednost napona na čvorištu 110 kV Gračac,
V_{OBR110}	-	efekt. vrijednost napona na čvorištu 110 kV Obrovac,
δ_{ZD6}	-	kut napona na čvorištu 35 kV VE ZD6,
δ_{SRB}	-	kut napona na čvorištu 35 kV Srb,
δ_{GRA35}	-	kut napona na čvorištu 35 kV Gračac,
δ_{GRA110}	-	kut napona na čvorištu 110 kV Gračac,
δ_{OBR110}	-	kut napona na čvorištu 110 kV Obrovac,
P_L	-	opterećenje sustava,
P_{Wind}	-	djelatna snaga vjetroelektrane,
Q_{Wind}	-	jalova snaga vjetroelektrane,
R_{th},	-	djelatni dio nadomjesne Theveninove impedancije na sabirnici vjetroelektrane
X_{th}		- reaktivni dio nadomjesne Theveninove impedancije na sabirnici vjetroelektrane

Uz $k = 1, 2, 3, ...135$ gdje je m – broj ulaznih pogonskih stanja nad kojima se obavljaju analize tehnikom rudarenja podataka.

Vektor ulaznih podataka u proces klasterizacije jednak je:

$$OC = [OC_1; OC_2; OC_3; \quad OC_{135}]^T \quad \textbf{(5.5)}$$

Na taj način matematički su definirane varijable i pogonska stanja kao ulazni podaci u algoritam.

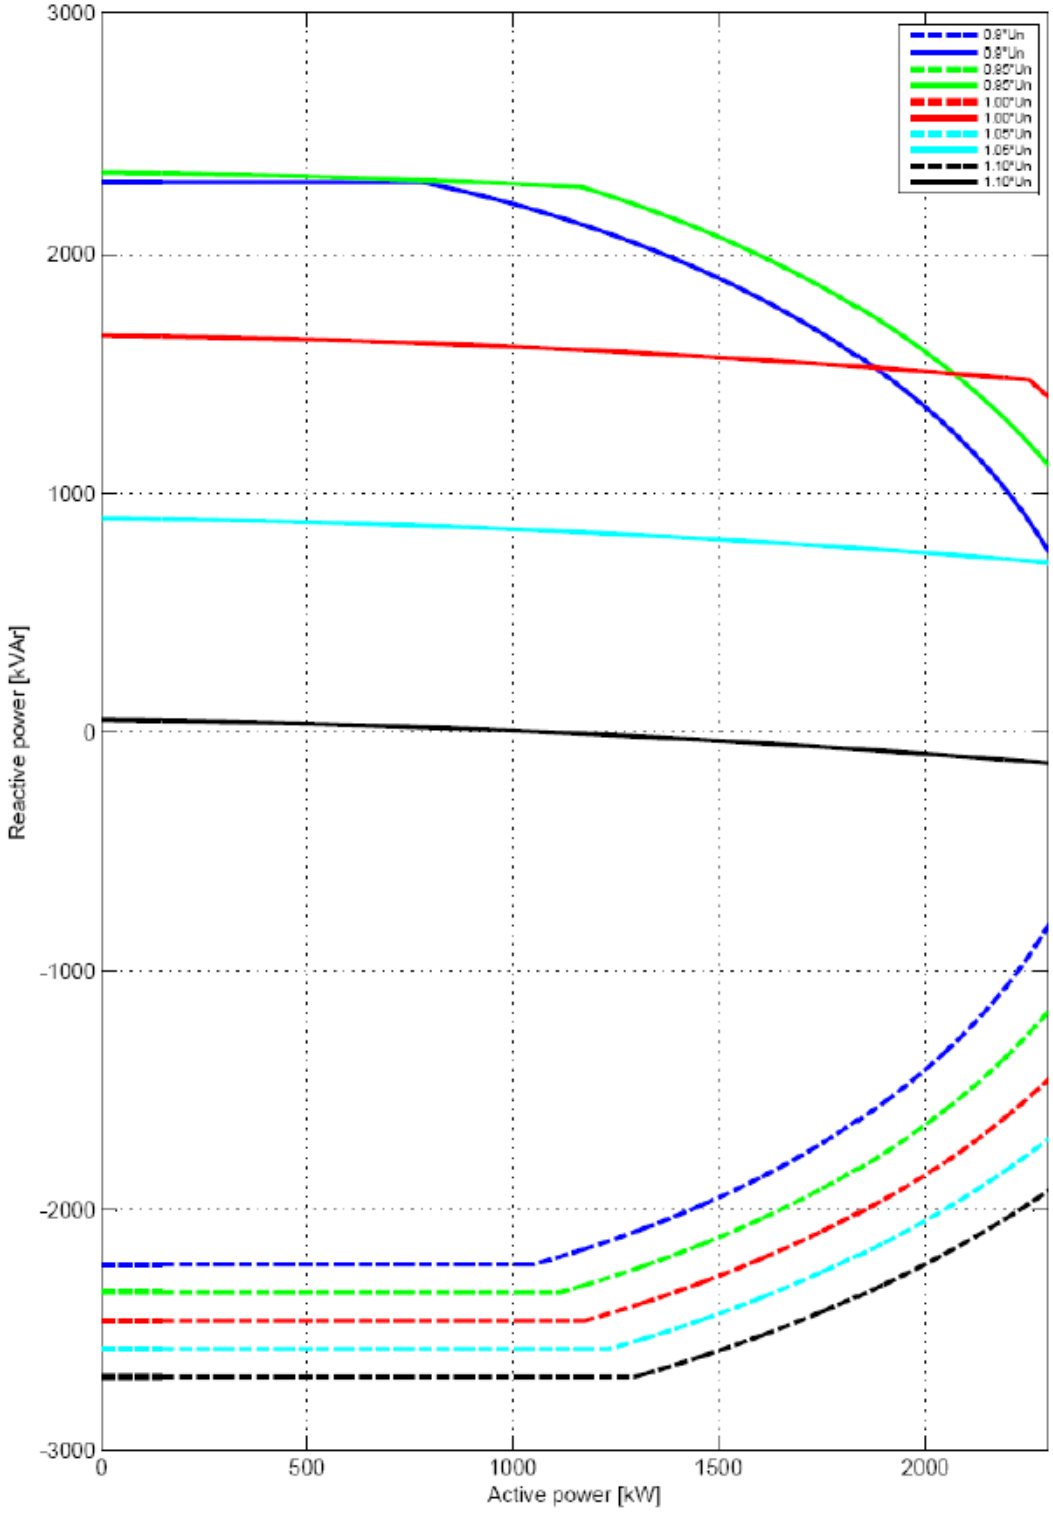
Vjetroelektrana s instaliranim agregatima SWT-2.3 VS, a zajedno s uključenom funkcijom tzv. Park Pilot regulacije (HPPP) posjeduje dvije razine regulacije napona. Prva povratna petlja realizirana je lokalno u regulatoru vjetroagregata. Radi se o brzom regulatoru koji prati referentnu vrijednost zadatu od strane centralnog regulatora koji je priključen na mjerne uređaje na mjestu priključka vjetroelektrane. Centralni regulator šalje nove referentne podatke u pojedini vjetroagregat svakih 150 – 200 ms. Referentne vrijednosti izračunavaju se na temelju broja vjetroagregata, postavljene referentne vrijednosti centralnog regulatora, izmjerenog napona i tokova jalove snage na mjestu priključka vjetroelektrane.

Vjetroelektrana s instaliranom Park Pilot funkcijom ima mogućnost U-Q regulacije u tri režima upravljanja i to:

- regulacija napona u mjestu priključka (reg. U),
- regulacija izlazne vrijednosti faktora snage (reg. cos φ),
- regulacija izlazne jalove snage (reg. Q).

U-Q regulacija u modu upravljanja regulacije izlazne jalove snage, povratnom petljom regulira se vrijednost izlazne jalove snage na točki priključka. U ovom konkretnom slučaju VE ZD 6, točka priključka je TS Zadar 6 (rasklopište Sučević Brdo). U modu regulacije cos φ, referentna vrijednost faktora snage pretvara se u internu referentnu vrijednost jalove snage u točki priključka, a na temelju aktualne proizvodnje djelatne snage te se ta ista referentna vrijednost stalno osvježava.

Stoga je definirana varijabla $Q_{Settings}$ kao podešenje regulatora jalove snage i to kao kategorička odnosno diskretna varijabla.



Slika 5.11 Pogonski dijagram pojedinačnog vjetroagregata Siemens tip SWT-2.3 VS

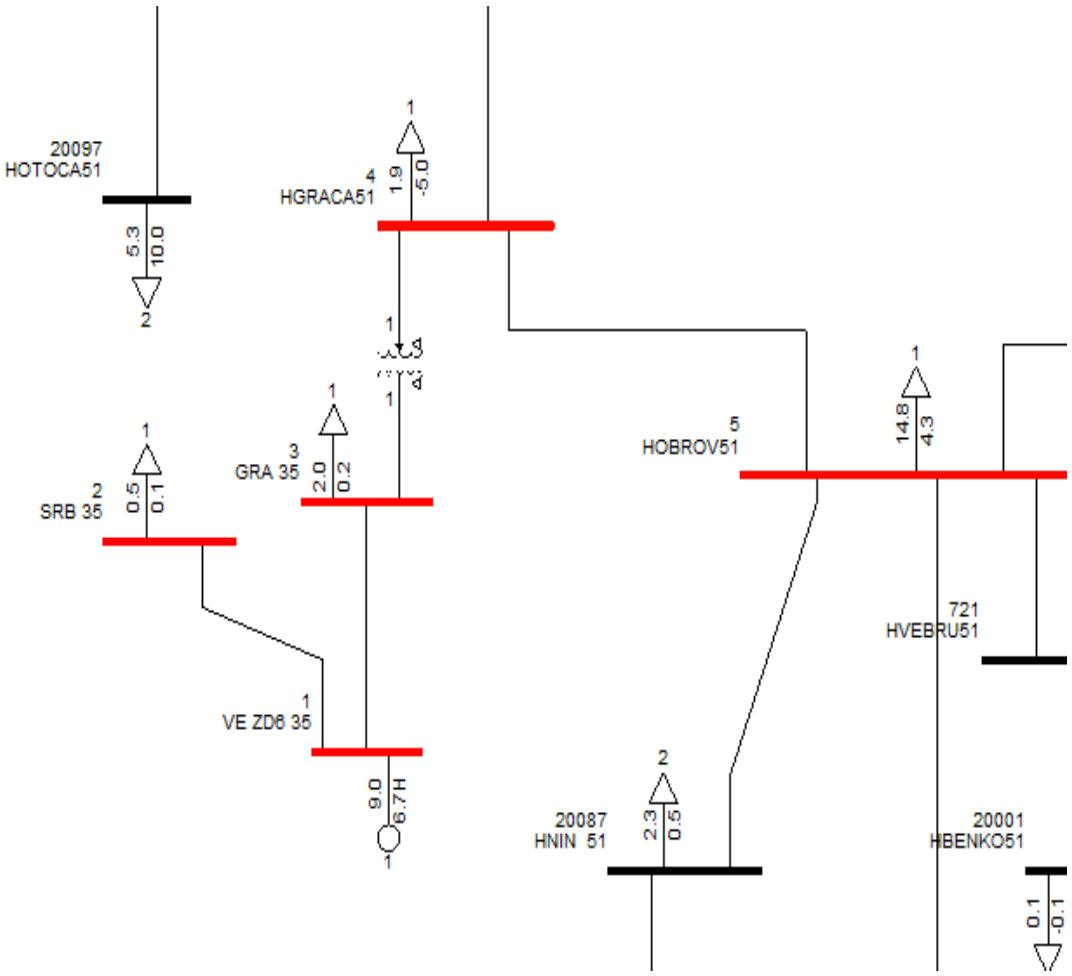
S obzirom na zahtjev iz prethodne elektroenergetske suglasnosti o radu u režimu u kojem je izlazna vrijednost cos φ na sučelju vjetroelektrane u području 0.95 induktivno – 0.95 kapacitivno, ukoliko se za trajni pogon vjetroelektrane odabere režim regulacije napona U, u točki priključka vrlo često će se pojaviti tok jalove snage uzrokovan potrebom regulacije napona u toj točki koja se nalazi na dugačkom neopterećenom vodu. Uslijed toga, vjetroagregati bi svojom sposobnošću regulacije, proizvodili jalovu snagu izvan područja 0.95 induktivno – 0.95 kapacitivno definiranog u prethodnoj elektroenergetskoj suglasnosti.

Stoga se proizvođač mora zaštititi od prekomjerne jalove energije. Postavkom rada u režimu regulacije cos φ, pogon vjetroelektrane odvija se u granicama faktora snage definiranim prethodnom elektroenergetskom suglasnosti odnosno u području 0.95 induktivno – 0.95 kapacitivno. Simulacije za proizvodnju sintetičkih podataka u režimu regulacije cos φ, napravljene su isključivo za režim regulacije cos φ = 1.

5.2.3 Rezultati modela

Proračuni na modelu obavljeni su u programskom paketu PSS/E. Obavljen je proračun 135 pogonskih stanja. Sva izračunata pogonska stanja data su u prilogu B.

Na sljedećoj slici dat je ekranski prikaz proračuna tokova snaga u programskom paketu PSS/E.



Slika 5.12 Ekranski prikaz proračuna tokova snaga u programskom paketu PSS/E za model vjetroelektrane Zadar 6

Nakon klasteriranja podataka, korištenjem algoritma k-srednjih vrijednosti, dobiveni centroidi triju klastera Theveninovog ekvivalenta, temeljeno na vektoru *OC* odnosno u ovom primjeru ukupno 135 slučajeva za učenje modela, dati su u sljedećoj tablici:

Tablica 5-3 Centroidi Theveninog ekvivalenta triju klastera EWS signala dobivenih algoritom k-srednjih vrijednosti primijenjenih na modelu vjetroelektrane Zadar 6

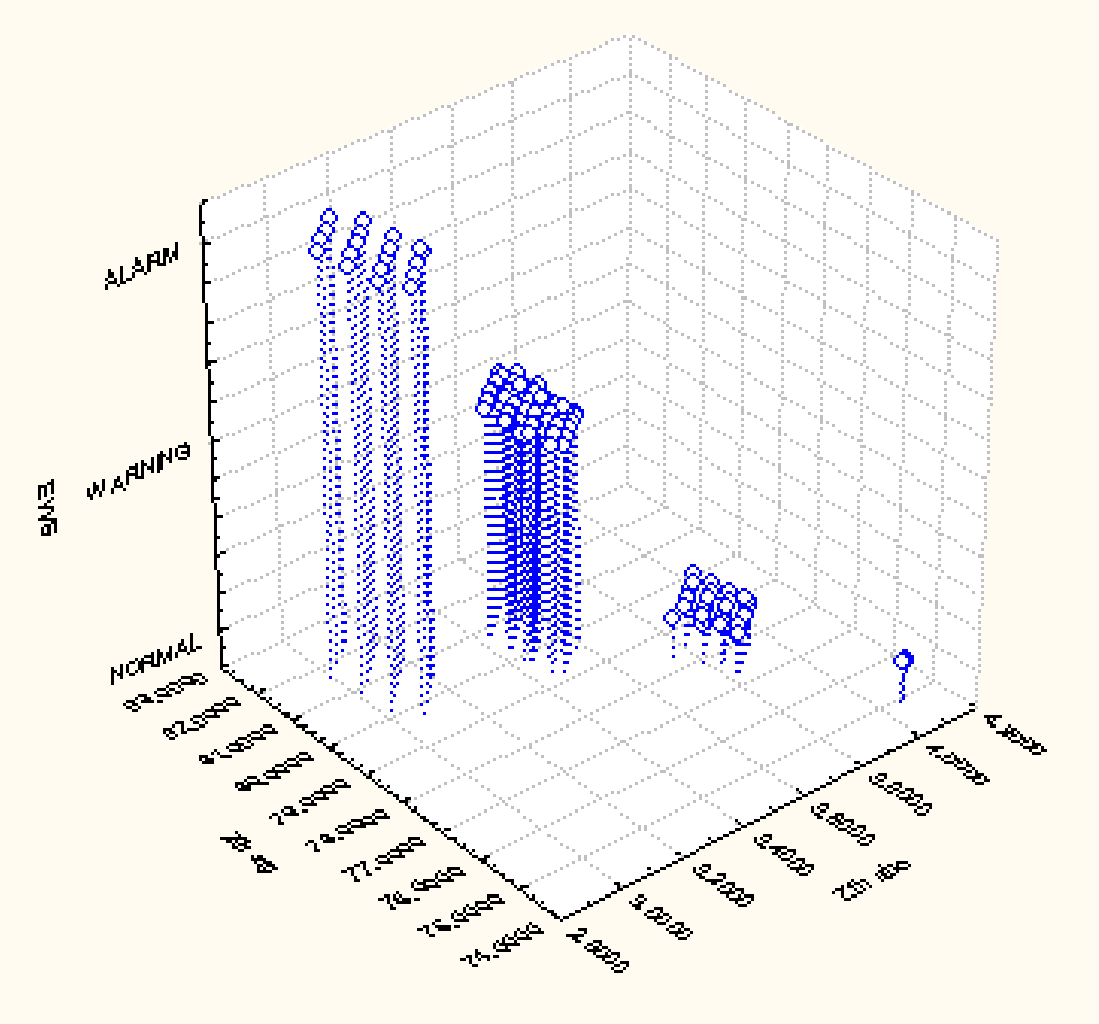
EWS	Z_{th} abs	Z_{th} arg	Broj slučajeva
NORMALNO (NORMAL)	4,090202	74,98206	41
IZVANREDNO (WARNING)	3,781597	78,12948	71
KRITIČNO (ALARM)	3,228652	80,60002	23

Pri čemu je

EWS - signal ranog upozorenja (eng. Early warning signal)
Z_{th} abs - apsolutna vrijednost impedancije Theveninovog ekvivalenta u točki priključka vjetroelektrane
Z_{th} arg - argument impedancije Theveninovog ekvivalenta u točki priključka vjetroelektrane

Simulacijama se sustav morao modelirati u izvanrednom i kritičnom pogonskom stanju da bi se mogao izraditi i uzorak istih pogonskih stanja. U realnim slučajevima stvarnih elektroenergetskih sustava, takva pogonska stanja će biti vrlo rijetko izmjerena odnosno snimljena u svojim karakteristikama i parametrima. Stoga će uzorak takvih pogonskih stanja većinom biti izrađen sintetički odnosno korištenjem simulacija.

Klasteri vrijednosti signala EWS prema ekvivalentnoj Theveninovoj impedanciji na čvorištu priključka VE Zadar 6, odnosno pripadajućoj apsolutnoj vrijednosti i argumentu iste impedancije, prikazani su na sljedećoj slici



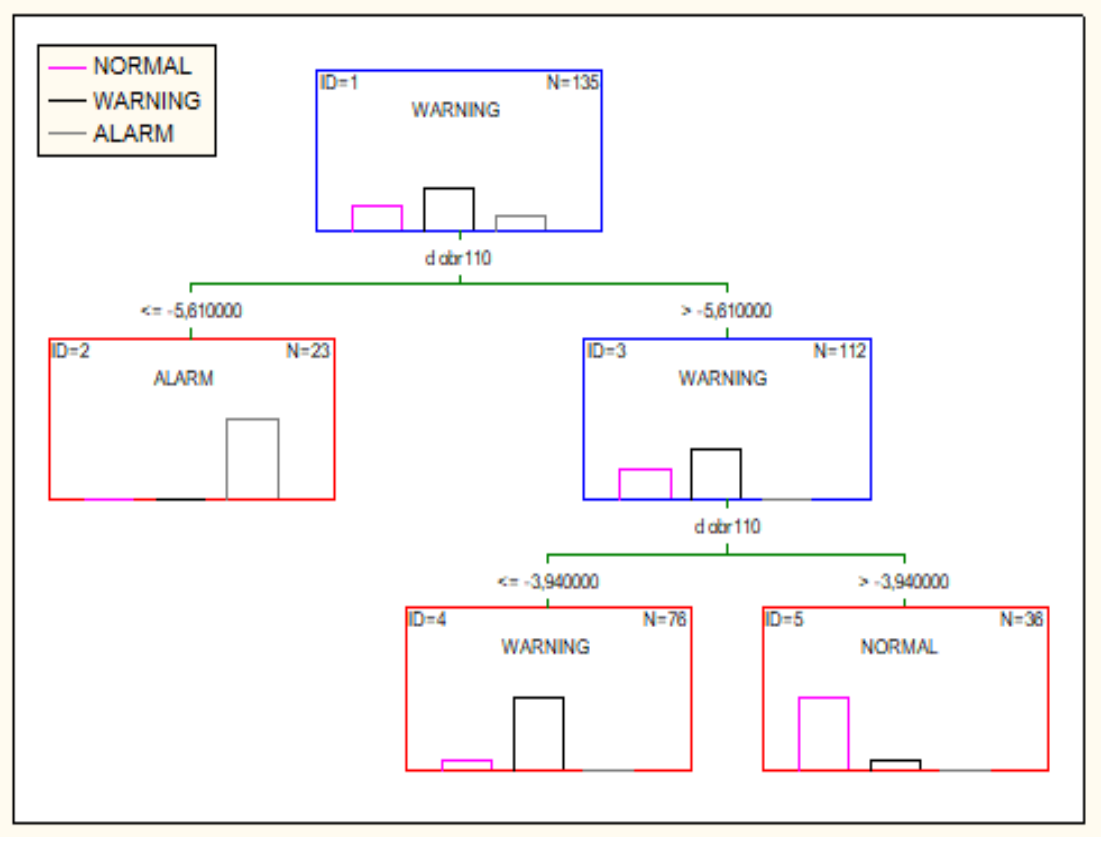
Slika 5.13 Grafički prikaz triju klastera pogonskih stanja modela vjetroelektrane Zadar 6 korištenjem apsolutne vrijednosti i argumenta ekvivalentne Theveninove impedancije na priključku vjetroelektrane

Prema medijanima signala EWS i njihovom grupiranju prikazanom na prethodnoj slici, vidljivo je kako elektroenergetski sustav mijenja svoju ekvivalentnu impedanciju tijekom pogonskih stanja koja spadaju u izvanredno i kritično pogonsko stanje što predstavlja i očekivano ponašanje.

Izračunati klasteri se koriste u daljnjem tijeku algoritma za klasifikaciju novih izmjerenih ili simuliranih stanja. Klasifikacija je provedena uz korištenje klasteriranih signala EWS-a u pogonskim stanjima kao zavisne varijable. Nezavisne varijable su efekt. vrijednosti i fazni pomaci (kutevi) napona na svim čvorištima, kao i ukupna opterećenja sustava, djelatna snaga vjetroelektrane i jalova snaga vjetroelektrane.

Kao pravilo za zaustavljanje kod klasifikacijskog stabla, korišten je kriterij obrezivanja stabla odlučivanja na temelju misklasifikacijske pogreške. Definirani troškovi misklasifikacije uzeti su jednaki kao i za model IEEE 14 te su dati u tablici 5.2.

Ukoliko se kao nezavisne varijable definiraju efekt. vrijednosti i fazni pomaci (kutevi) napona na svim čvorištima, kao i ukupna opterećenja sustava, djelatna snaga vjetroelektrane i jalova snaga vjetroelektrane, odnosno cjelokupni skup podataka OC_k, optimalno stablo odlučivanja dato je na sljedećoj slici.



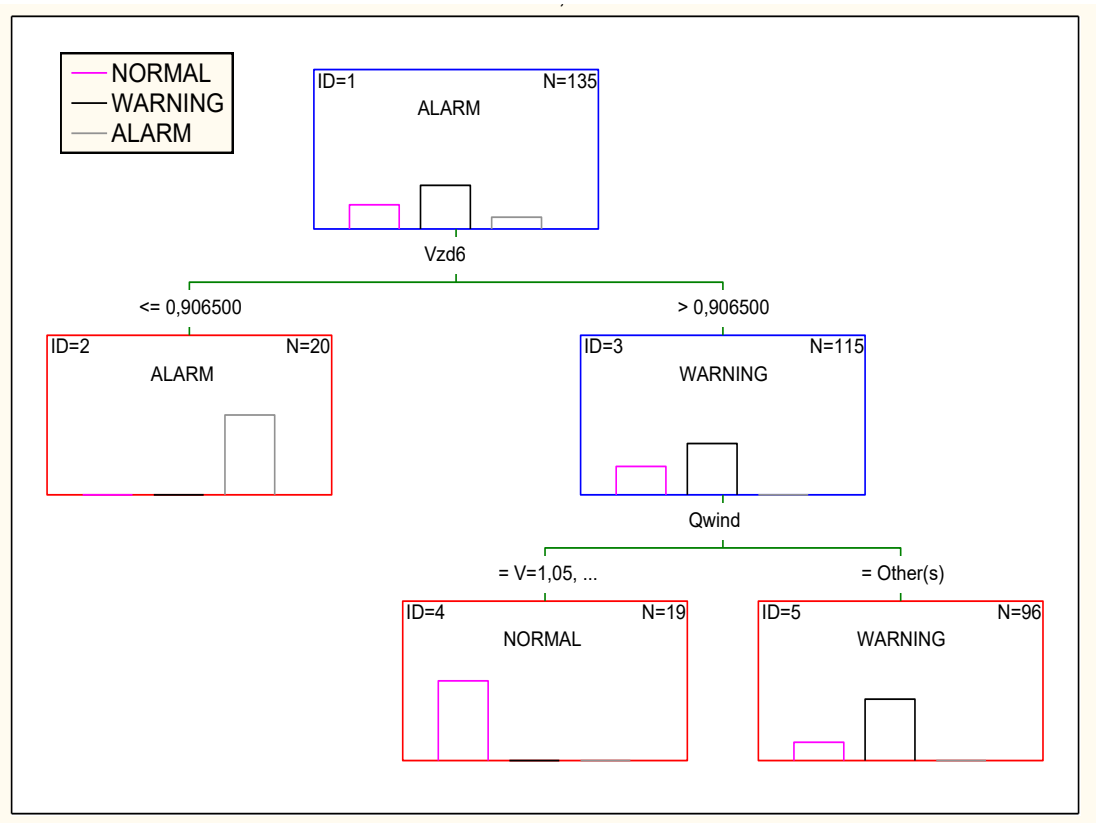
Slika 5.14 Grafički prikaz odabira optimalnog stabla odlučivanja modela vjetroelektrane Zadar 6 korištenjem metode misklasifikacijskih troškova uz cjelokupni skup ulaznih podataka OC_k

Vidljivo je da je u klasifikacijskom stablu odlučivanja sadržana samo varijabla faznog pomaka (kuta) između čvorišta Obrovac 110 kV i referentnog čvorišta (u ovom slučaju Velebit 400 kV). Time je, za definiranje prilika u okolnoj mreži, dovoljno pratiti kuteve napona u toj mjernoj točki.

Međutim, budući da za verifikaciju modela, nije bilo moguće obaviti mjerenja na svim čvorištima u mreži, pa tako i na čvorištu Obrovac 110 kV, te budući da su bila dostupna isključivo mjerenja efekt. vrijednosti i faznog pomaka napona na samoj točki priključka vjetroelektrane, klasifikacijski proračun za verifikaciju modela obavljen je korištenjem reduciranog skupa dostupnih mjernih podataka $OC_{k\text{-}r}$, odnosno:

$$OC_{k\text{-}r} = \{V_{ZD6},\ \delta_{ZD6},\ P_{Wind},\ Q_{Wind}\} \qquad \textbf{(5.6)}$$

Uz takav ulazni skup podataka, kao rezultat dobije se sljedeće stablo odlučivanja:

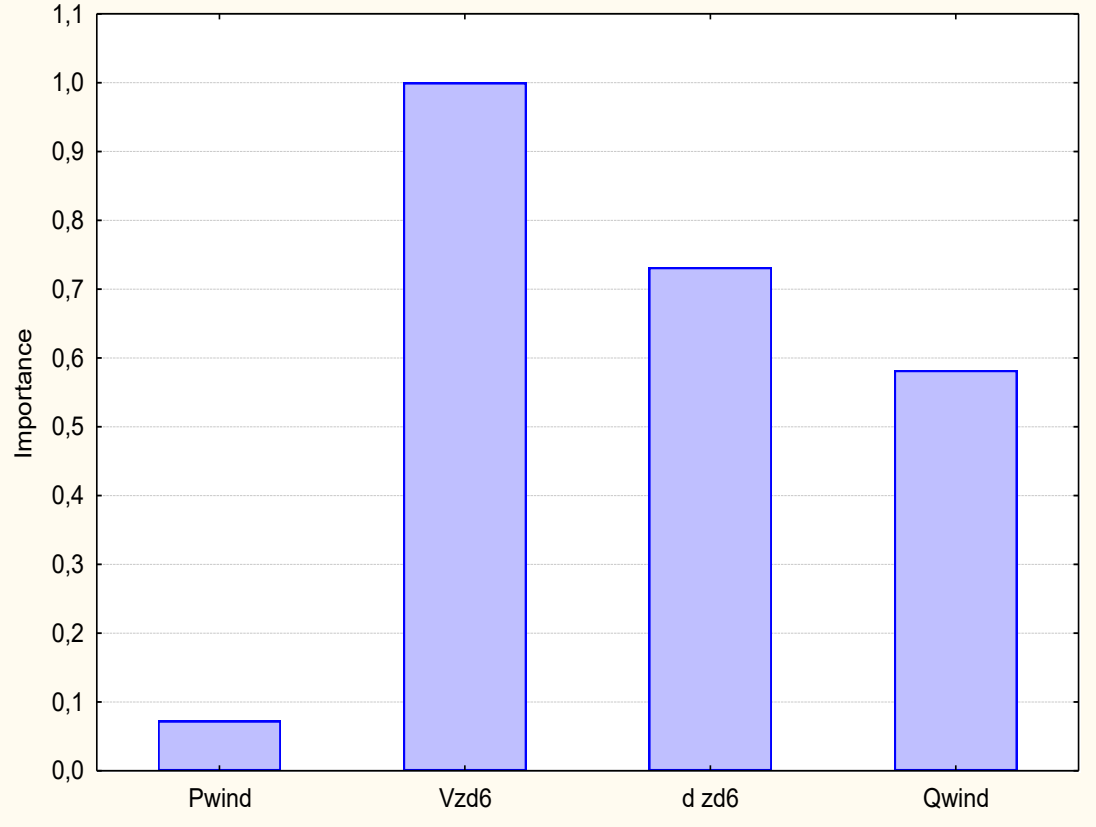


Slika 5.15 Grafički prikaz odabira optimalnog stabla odlučivanja modela vjetroelektrane Zadar 6 korištenjem metode misklasifikacijskih troškova uz reducirani skup ulaznih podataka $OC_{k\text{-}r}$

Vidljivo je da su u klasifikacijskom stablu odlučivanja sadržane samo dvije varijable i to efektivna vrijednosti napona na čvorištu VE Zadar 6 (sabirnice RS Sučević Brdo) te podešenja režima rada proizvodnje jalove snage vjetroelektrane. Time je, za definiranje prilika u lokalnoj mreži oko same vjetroelektrane, dovoljno pratiti efektivne vrijednosti napona u toj mjernoj točki te izraditi donošenje odluka na temelju te varijable.

Kao kritična vrijednost napona pokazala se vrijednost od 0,9065 p.u. odnosno 31,7275 kV. Padom napona na sabirnicama VE Zadar 6 ispod navedene vrijednosti mogu se očekivati kritične pojave u sustavu. Sama podnaponska zaštita vjetroelektrane u točki priključka odnosno na sabirnicama 35 kV u RS Sučević Brdo, podešena je na vrijednost 0,88 p.u.

Donošenje odluka u ovom slučaju odnosi se samo na promjenu režima rada vjetroelektrane u dijelu proizvodnje jalove snage. Predmetni rezultati predstavljaju i logičku cjelinu sa strane tokova snaga jer je instalirana djelatna snaga vjetroelektrane 9,2 MW što ne predstavlja problem u dijelu prijenosa snage na udaljenosti od otprilike 16 km nadzemnim 35 kV dalekovodom. Stoga je jedini problem sa strane sigurnosti elektroenergetskog sustava, problem regulacije napona i jalove snage.
Na sljedećem dijagramu dat je izračun signifikantnosti pojedinih varijabli.



Slika 5.16 Grafički prikaz signifikantnosti varijabli modela vjetroelektrane Zadar 6 uz reducirani skup ulaznih podataka OC_{k-r}

Kao određeno dodatno poboljšanje generiranog stabla odlučivanja, moguće je odrediti i određenu sigurnosnu marginu na vrijednost napona na kojoj se događa odlučivanje o izmijeni režima rada vjetroelektrane, npr. na 0,92 p.u. ili slično.

S obzirom da se u posljednjoj grani klasifikacijskog stabla odlučivanja nalazi logički uvjet vezan za podešenja režima rada proizvodnje jalove snage vjetroelektrane i to u grananju na lijevo (ID4):

- Const V = 1,05 p.u.
- Const. V = 1.00 p.u.
- Const. Q = 6,7 Mvar
- Const. Q = 3,35 Mvar
- Const. Q = 0 Mvar
- Const. Cos φ = 1

Konačna odluka iznosi

$$P_{settings} = \max (P_{WIND}) = 9{,}2 \text{ MW}$$

$$Q_{settings} = \min (Q_{WIND}) = \text{Const. } \varphi = 1$$

Iz svega navedenog, slijedi zaključak, da su potrebna samo određena mjerenja efektivne vrijednosti napona i kuta napona na nekim sabirnicama u sustavu da bi se došlo do vrijednih zaključaka u pogledu sigurnosti elektroenergetskog sustava, a predmetni signali se mogu iskoristiti u sustavu vođenja.

Također, u radijalnim distribucijskim sustavima, sa priključenim vjetroelektranama, situacija će biti vrlo slična, naročito ako su vjetroelektrane priključene na 35 kV dalekovode. Neće postojati problem evakuacije djelatne snage već će isključivi problem biti u regulaciji napona i jalove snage.

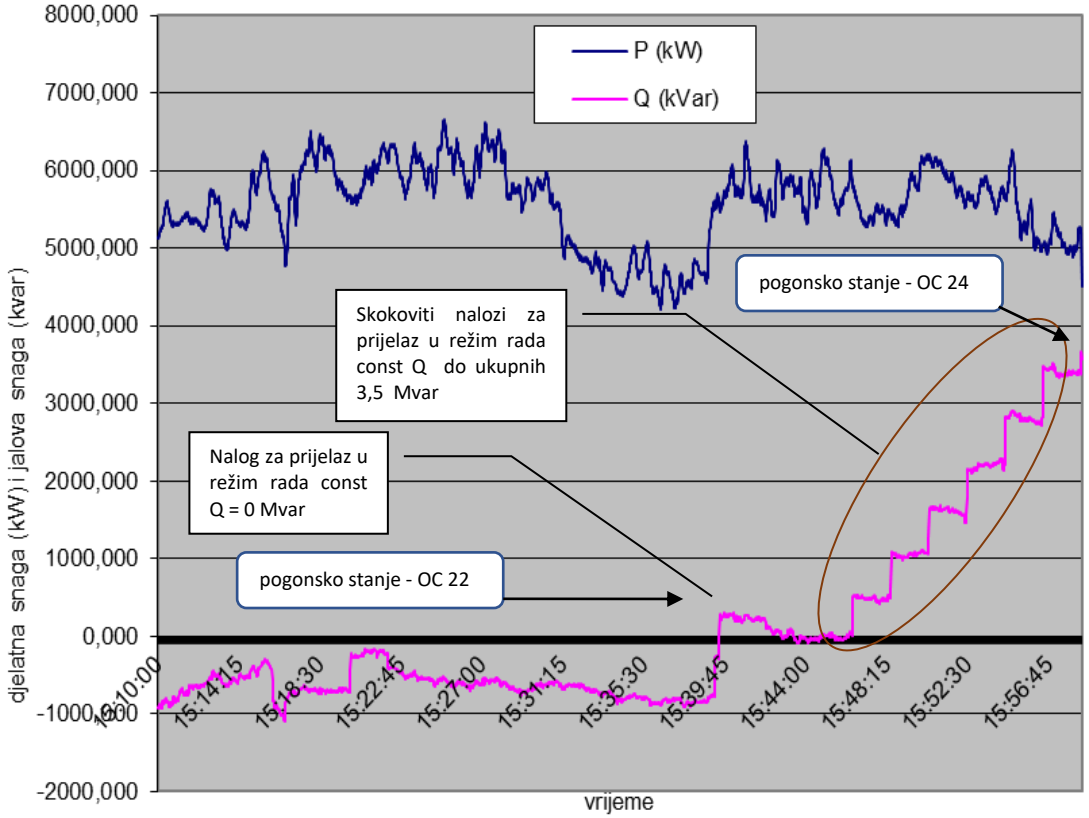
Predmetne 35 kV mreže imaju veće razine snaga kratkog spoja od npr. 20 kV mreža, pa samim tim je manji i omjer P_{WIND}/Sk što ukazuje na manji utjecaj elektrane na istu mrežu.

5.2.4 Validacija modela VE Zadar 6 mjernim podacima

Mjerenja na VE Zadar 6 provedena su tijekom pokusnog rada i puštanja u pogon u periodu od listopada 2010. do siječnja 2011., a sukladno metodologiji u poglavlju 5.2.1.

Sukladno prethodnim poglavljima, za verifikaciju modela izdvojena su mjerenja djelatne i jalove snage, faktora snage i napona na pragu elektrane.

Na sljedećem dijagramu data su mjerenja kretanja napona i jalove snage na pragu vjetroelektrane Zadar 6, mjereno u RS Sučević Brdo za vrijeme provedbe ispitivanja izmjene režima rada u dijelu regulacije napona i jalove snage.



Slika 5.17 Kretanje vrijednosti napona i jalove snage na pragu VE ZD6 mjereno u RS Sučević Brdo za vrijeme provedbe ispitivanja izmjene režima rada u dijelu regulacije napona i jalove snage

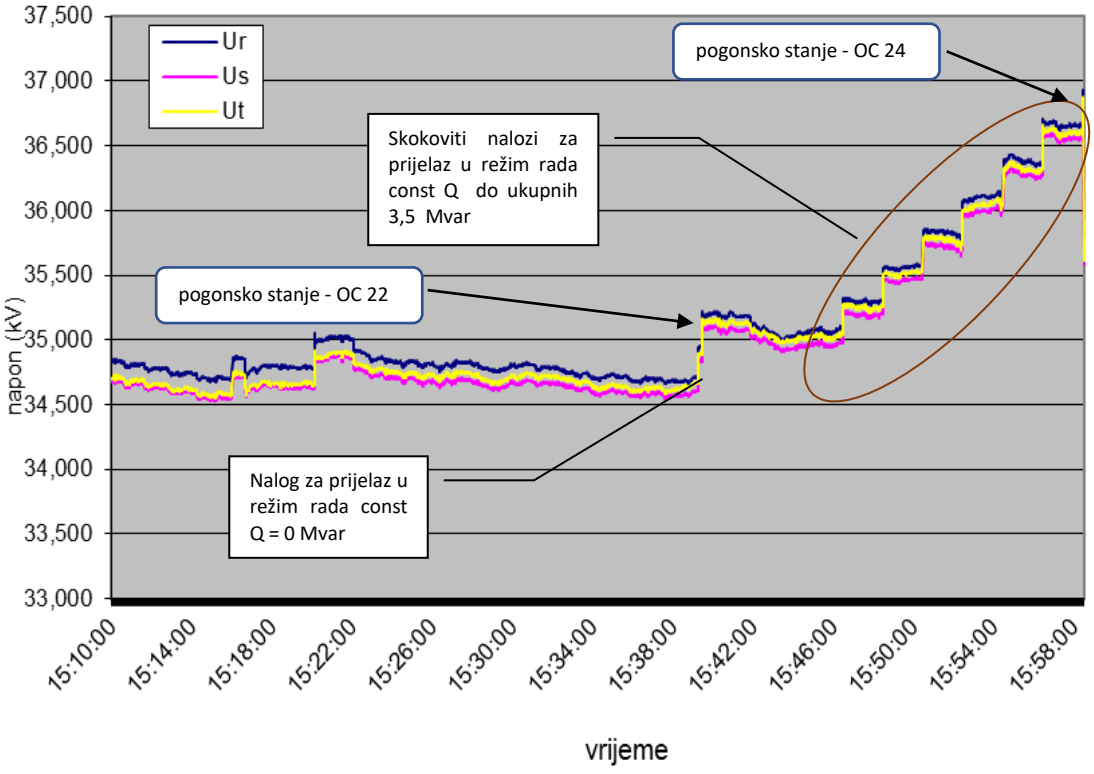
Na prethodnoj slici vidljivo je da u početnom trenutku vjetroelektrana radi u režimu regulacije napona i jalove snage const. V uz podešenje const. V = 0,993 p.u. Na taj način napon se održava na razini od 34,75 kV. Budući da je proizvodnja djelatne snage tada se kretala oko 5 MW, rezultati najbliže odgovaraju pogonskom stanju $OC_{22\text{-}r}$ koje je opisano skupom

$$OC_{22\text{-}r} = \{V_{ZD6} = 1{,}00 \text{ p.u.}, \delta_{ZD6} = -3{,}42^{\circ}, P_{WIND} = 5 \text{ MW}, Q_{WIND} = 0 \text{ Mvar}\}$$

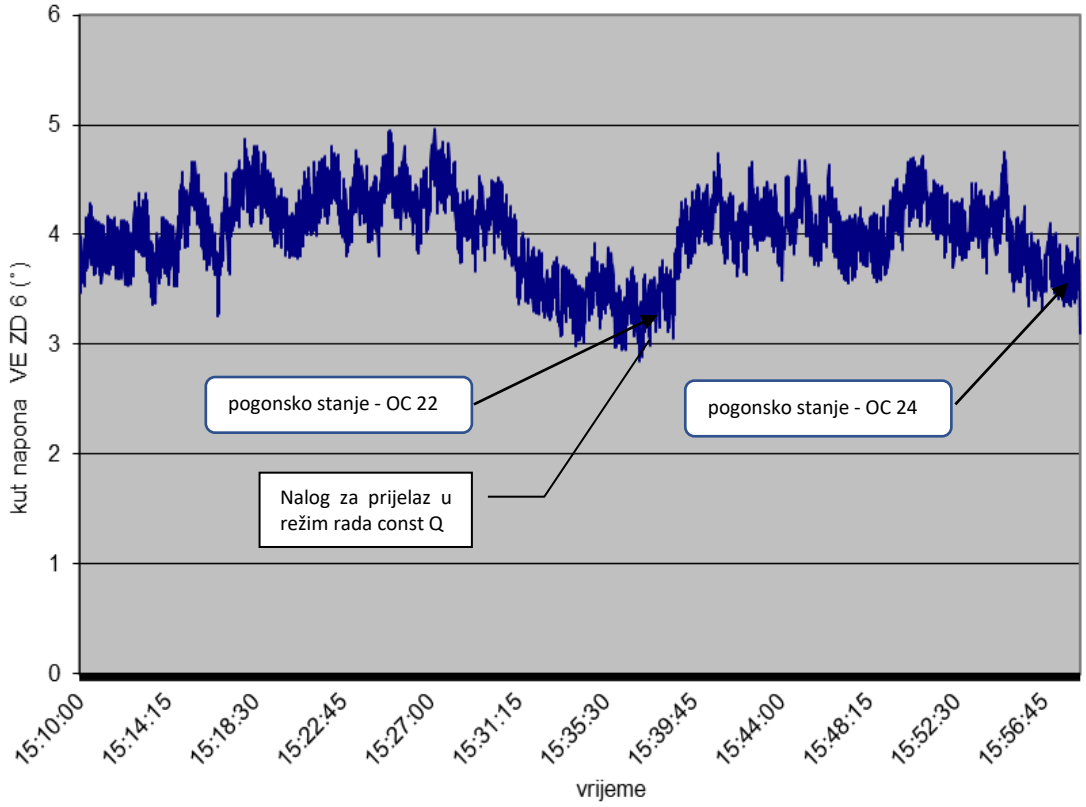
Nakon 20 minuta, dat je nalog za prelaza u režim rada regulacije jalove snage na pragu elektrane odnosno const. Q uz podešenje const. Q = 0 Mvar. Nakon toga je u skokovitim iznosima mijenjano podešenje režima rada regulacije jalove snage vjetroelektrane do ukupnih 3,5 Mvar.
Budući da je proizvodnja djelatne snage tada se kretala oko 6 MW, rezultati najbliže odgovaraju pogonskom stanju $OC_{24\text{-}r}$ koje je opisano skupom

$$OC_{24\text{-}r} = \{V_{ZD6} = 1{,}07 \text{ p.u.}, \ \delta_{ZD6} = -3{,}58^{\circ}, \ P_{WIND} = 6 \text{ MW}, \ Q_{WIND} = \text{const. Q} = 3{,}35 \text{ Mvar}\}$$

Kako se pri tim izmjenama pogonskih stanja kretao napon svih triju faza (R, S i T) u točki priključka, prikazano je na sljedećoj slici.



Slika 5.18 Kretanje vrijednosti djelatne i jalove snage na pragu VE ZD6 mjereno u RS Sučević Brdo za vrijeme provedbe ispitivanja izmjene režima rada u dijelu regulacije napona i jalove snage



Slika 5.19 Kretanje vrijednosti kuta napona na pragu VE ZD6 mjereno u RS Sučević Brdo za vrijeme provedbe ispitivanja izmjene režima rada u dijelu regulacije napona i jalove snage

Mjerni podaci kuta napona na VE Zadar 6, mjereni u RS Sučević Brdo, uz referentni kut napona u 400 kV čvorištu RHE Velebit, prikazani su na slici 5.17. Predmetna veličina nije bitna u smislu upravljanja pogonom vjetroelektrane u ovom slučaju. Sva mjerenjima prikazana pogonska stanja pripadaju u normalna pogonska stanja odnosno u klasu C_{NORMAL}, a sukladno klasterizaciji pogonskih stanja obrađenoj u poglavlju 5.2.3.

U stvarnom pogonu vrlo je teško dobiti pogonska stanja koja odgovaraju izvanrednom i kritičnom pogonskom stanju, odnosno pogonskim stanjima koja spadaju u klase $C_{WARNING}$, i C_{ALARM}. Naime, predmetna vjetroelektrana priključena je na dugom i slabo opterećenom 35 kV nadzemnom dalekovodu pa sukladno tome, vrlo su rijetke pogonske prilike niskih napona i prevelikih opterećenja koje bi mogle ugroziti na taj način pogon iste vjetroelektrane, iako su i takva pogonska stanja obrađena u cilju dobivanja cijelog spektra mogućih rješenja.
Stoga je u stvarnom pogonu odabran stalni režim rada uz

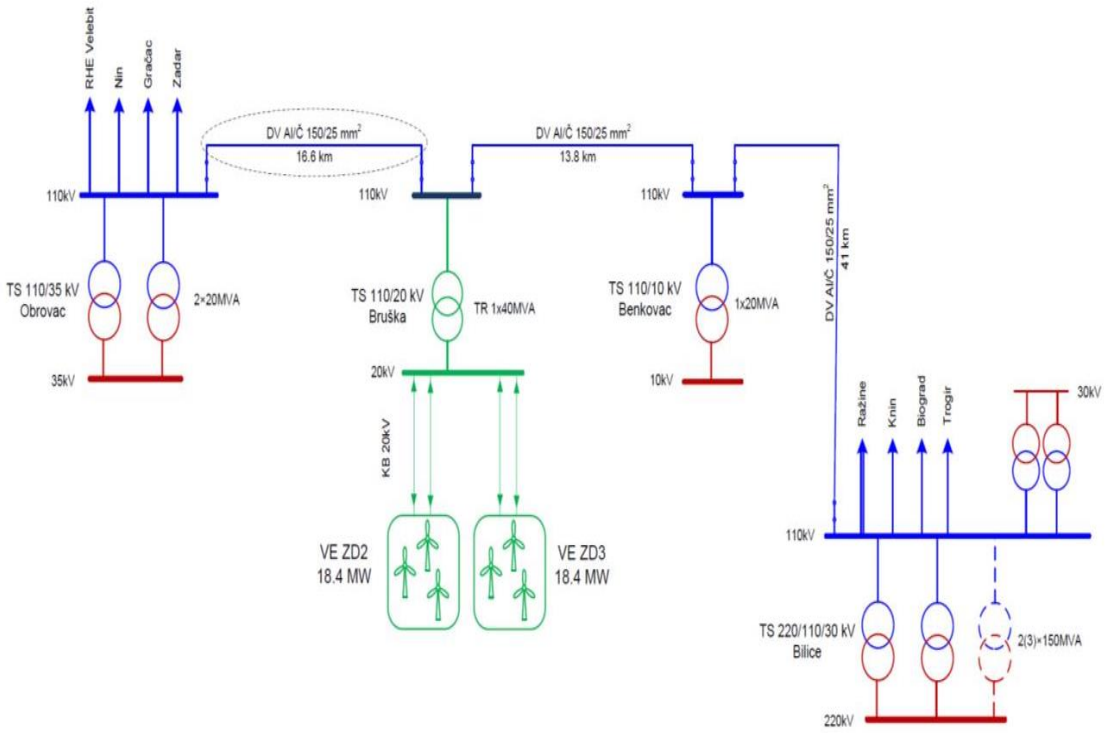
$$P_{settings} = \max (P_{WIND}) = 9{,}2 \text{ MW}$$

$$Q_{settings} = \min (Q_{WIND}) = \text{Const. } \varphi = 1$$

5.3. MODEL VJETROELEKTRANE ZADAR 2 I 3

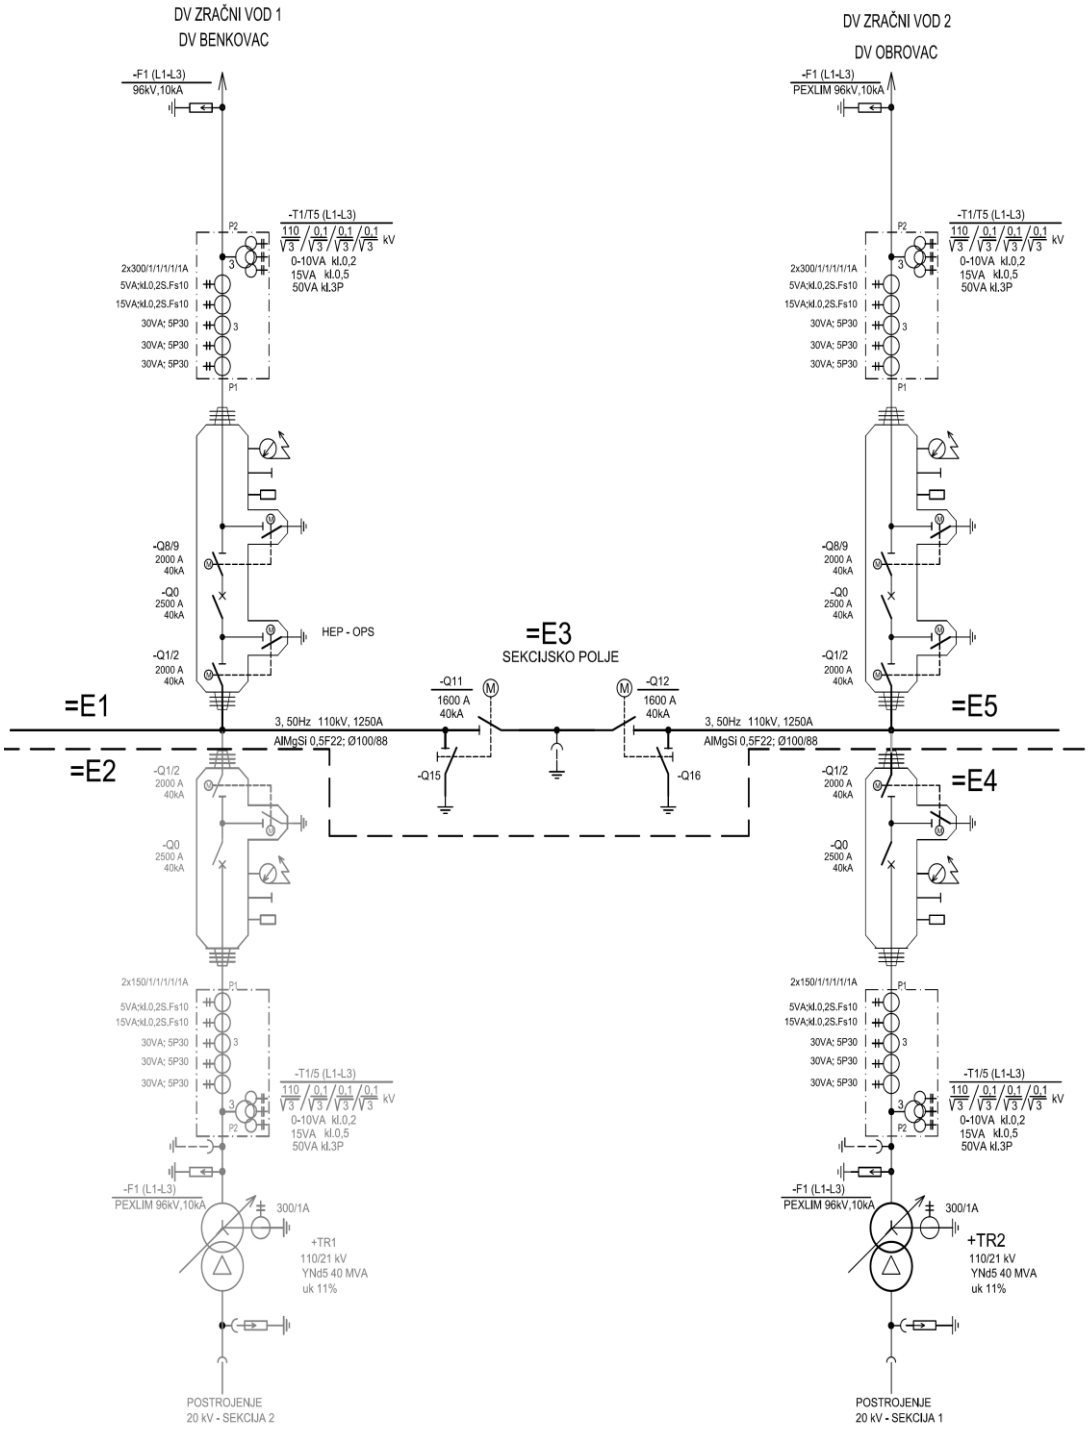
5.3.1 Osnovni ulazni podaci

Vjetroelektrana Zadar 2i3 (VE ZD2i3) smještena je na području u blizini grada Benkovca i sastoji se od 16 vjetroagregata proizvođača Siemens tip SWT-2.3 VS pojedinačne snage 2.3 MW odnosno ukupne instalirane snage vjetroelektrane od 36.8 MW.



Slika 5.20 Blok shema priključka vjetroelektrane Zadar 2 i 3 na elektroenergetsku mrežu

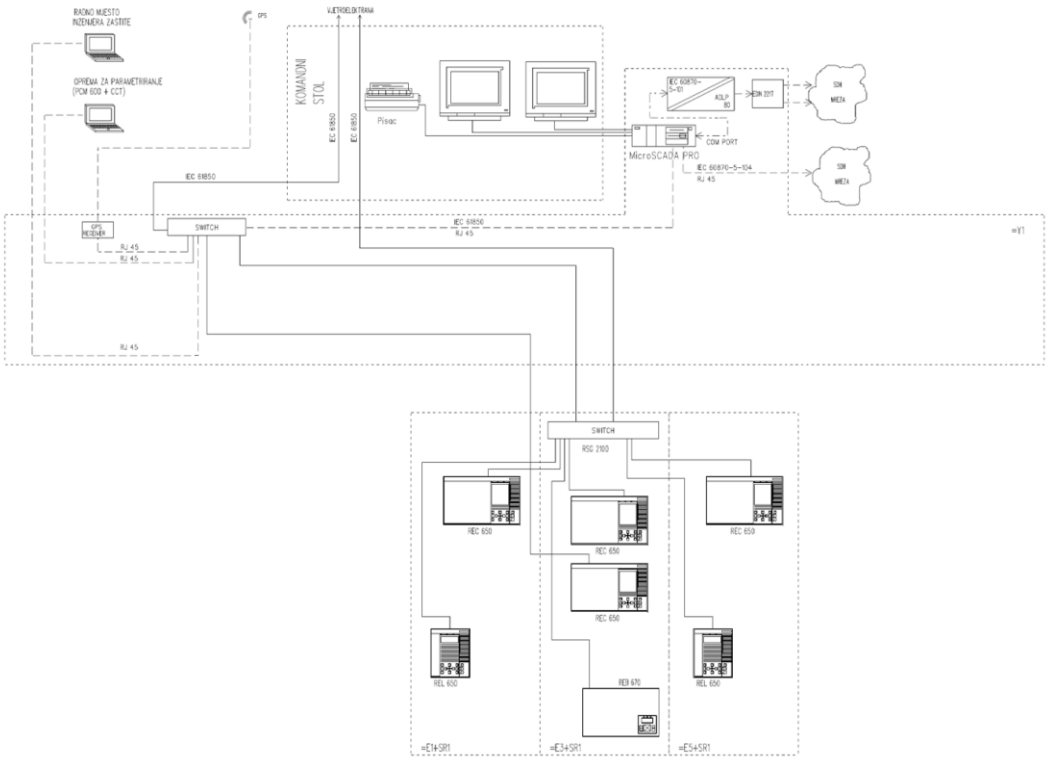
U samoj točki priključka, izgrađeno je priključno rasklopno postrojenje i trafostanica TS 110/20 kV Bruška, čija je jednopolna shema data na sljedećoj slici.



Slika 5.21 Jednopolna shema priključka vjetroelektrane Zadar 2 i 3 u transformatorskoj stanici TS 110/20 kV Bruška

Vjetroagregati su spojeni na internu 20 kV mrežu i daju dodatnu mogućnost regulacije napona na mjestu priključka vjetroelektrane na mrežu. Vjetroagregati instalirani na VE Zadar 2 i 3 imaju priključak na internu kabelsku mrežu preko frekvencijskog pretvarača (eng. FSFC – Full Scale Frequency Converter) izvedenog u tehnici IGBT tranzistora, a koji radi u režimu pulsno širinske modulacije (eng. PWM – Pulse Width Modulation). Na taj način omogućen je pogon vjetroelektrane u širokom spektru faktora snage.

Mjerenja su obavljena na sučelju vjetroelektrane odnosno na izlaznom transformatorskom polju i vodnim poljima transformatorske stanice.



Slika 5.22 Blok shema komunikacijskog sustava TS Bruška

Mjerni uređaji za obračunsko mjerenje (LandysGyr ZMQ202) i kontrolu kvalitete el energije (ION 8800) instalirani su u ormaru +QM1. Korišteni PMU uređaj (Arbiter 1133a) instaliran je u vodnom polju VP 110 kV Obrovac i fizički smješten privremeno u zasebno montažno kućište za vrijeme pokusnog rada vjetroelektrane odnosno obavljanja mjerenja.

5.3.2 Definicija varijabli

Svako pogonsko stanje (OC) definirano je kao matematički skup podataka sukladno definiciji pogonskih stanja i varijabli u poglavlju 4.2.1. čiji su članovi sljedeći elementi

$$OC_k = \{V_{BRUSKA}, V_{BENKOVAC}, V_{ZADARCENTAR}, V_{ZADAR}, V_{BIOGRAD}, V_{GRACAC}, V_{VELEBIT110}, V_{VELEBIT400}, \delta_{BRUSKA}, \delta_{BENKOVAC}, \delta_{ZADARCENTAR}, \delta_{ZADAR}, \delta_{BIOGRAD}, \delta_{GRACAC}, \delta_{VELEBIT110}, \delta_{VELEBIT400}, P_L, P_{Wind}, Q_{Wind}, R_{th}, X_{th}\} \quad \textbf{(5.7)}$$

Pri čemu je:

V_{BRUSKA} - efekt. vrijednost napona na čvorištu 110 kV Bruška,
$V_{BENKOVAC}$ - efekt. vrijednost napona na čvorištu 110 kV Benkovac,
$V_{ZADARCENTAR}$ - efekt. vrijednost napona na čvorištu 110 kV Zadar Cent.,
V_{ZADAR} - efekt. vrijednost napona na čvorištu 110 kV Zadar,
$V_{BIOGRAD}$ - efekt. vrijednost napona na čvorištu 110 kV Biograd,
V_{BILICE} - efekt. vrijednost napona na čvorištu 110 kV Bilice,
$V_{OBROVAC}$ - efekt. vrijednost napona na čvorištu 110 kV Obrovac,
V_{KNIN} - efekt. vrijednost napona na čvorištu 110 kV Knin,
V_{GRACAC} - efekt. vrijednost napona na čvorištu 110 kV Gračac
$V_{VELEBIT110}$ - efekt. vrijednost napona na čvorištu 110 kV Velebit
$V_{VELEBIT400}$, - efekt. vrijednost napona na čvorištu 400 kV Velebit

δ_{BRUSKA} - kut napona na čvorištu 110 kV Bruška,
$\delta_{BENKOVAC}$ - kut napona na čvorištu 110 kV Benkovac,
$\delta_{ZADARCENTAR}$ - kut napona na čvorištu 110 kV Zadar Cent.,
δ_{ZADAR} - kut napona na čvorištu 110 kV Zadar,
$\delta_{BIOGRAD}$ - kut napona na čvorištu 110 kV Biograd,
δ_{BILICE} - kut napona na čvorištu 110 kV Bilice,
$\delta_{OBROVAC}$ - kut napona na čvorištu 110 kV Obrovac,
δ_{KNIN} - kut napona na čvorištu 110 kV Knin,
δ_{GRACAC} - kut napona na čvorištu 110 kV Gračac
$\delta_{VELEBIT110}$ - kut napona na čvorištu 110 kV Velebit
$\delta_{VELEBIT400}$, - kut napona na čvorištu 400 kV Velebit

P_L - opterećenje sustava,
P_{Wind} - djelatna snaga vjetroelektrane,
Q_{Wind} - jalova snaga vjetroelektrane,
R_{th}, - djelatni dio nadomjesne Theveninove impedancije na sabirnici vjetroelektrane
X_{th} - reaktivni dio nadomjesne Theveninove impedancije na sabirnici vjetroelektrane

Uz $k = 1, 2, 3, ...150$.

Vektor ulaznih podataka u proces klasterizacije jednak je:

$$OC = [OC_1; OC_2; OC_3; \quad OC_{160}]^T \qquad \textbf{(5.8)}$$

Na taj način matematički su definirane varijable i pogonska stanja kao ulazni podaci u algoritam.

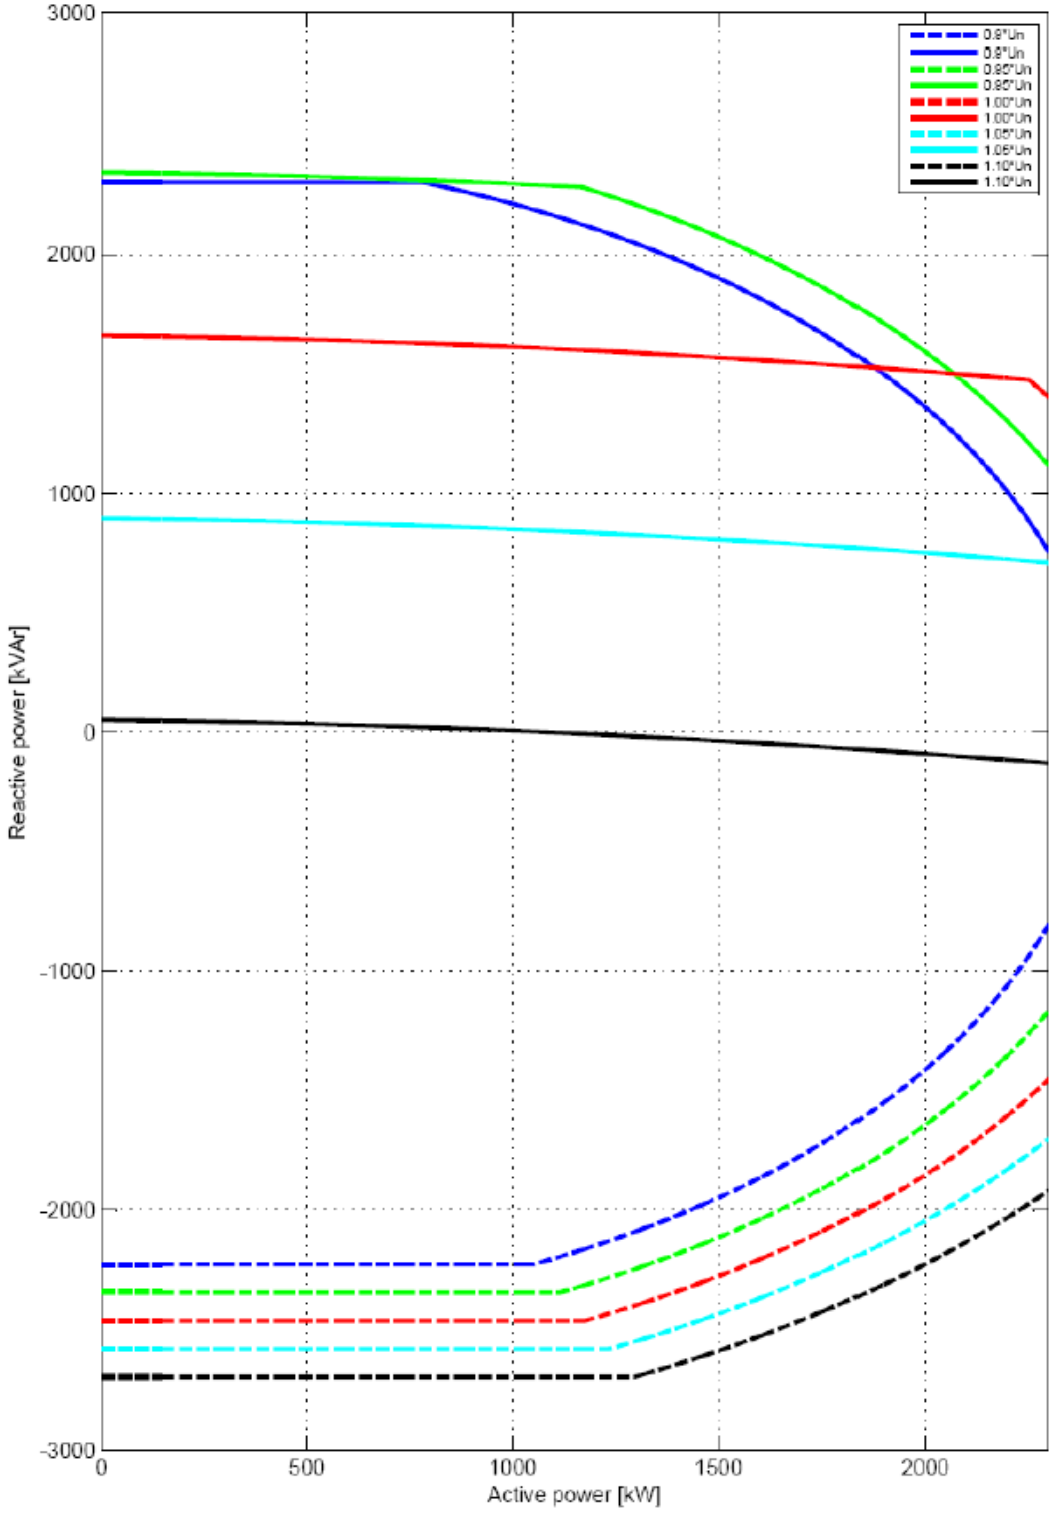
Vjetroelektrana s instaliranim agregatima SWT-2.3 VS, a zajedno s uključenom funkcijom tzv. Park Pilot regulacije (HPPP) posjeduje dvije razine regulacije napona. Prva povratna petlja realizirana je lokalno u regulatoru vjetroagregata. Radi se o brzom regulatoru koji prati referentnu vrijednost zadatu od strane centralnog regulatora koji je priključen na mjerne uređaje na mjestu priključka vjetroelektrane. Centralni regulator šalje nove referentne podatke u pojedini vjetroagregat svakih 150 – 200 ms. Referentne vrijednosti izračunavaju se na temelju broja vjetroagregata, postavljene referentne vrijednosti centralnog regulatora, izmjerenog napona i tokova jalove snage na mjestu priključka vjetroelektrane.

Vjetroelektrana s instaliranom Park Pilot funkcijom ima mogućnost U-Q regulacije u tri režima upravljanja i to:

- regulacija napona u mjestu priključka (reg. U),
- regulacija izlazne vrijednosti faktora snage (reg. cos φ),
- regulacija izlazne jalove snage (reg. Q).

U-Q regulacija u modu upravljanja regulacije izlazne jalove snage, povratnom petljom regulira se vrijednost izlazne jalove snage na točki priključka. U ovom konkretnom slučaju VE ZD 6, točka priključka je TS Zadar 6. U modu regulacije cos φ, referentna vrijednost faktora snage pretvara se u internu referentnu vrijednost jalove snage u točki priključka, a na temelju aktualne proizvodnje djelatne snage te se ta ista referentna vrijednost stalno osvježava.

Stoga je definirana varijabla $Q_{Settings}$ kao podešenje regulatora jalove snage i to kao kategorička odnosno diskretna varijabla.



Slika 5.23 Pogonski dijagram pojedinačnog vjetroagregata Siemens tip SWT-2.3 VS

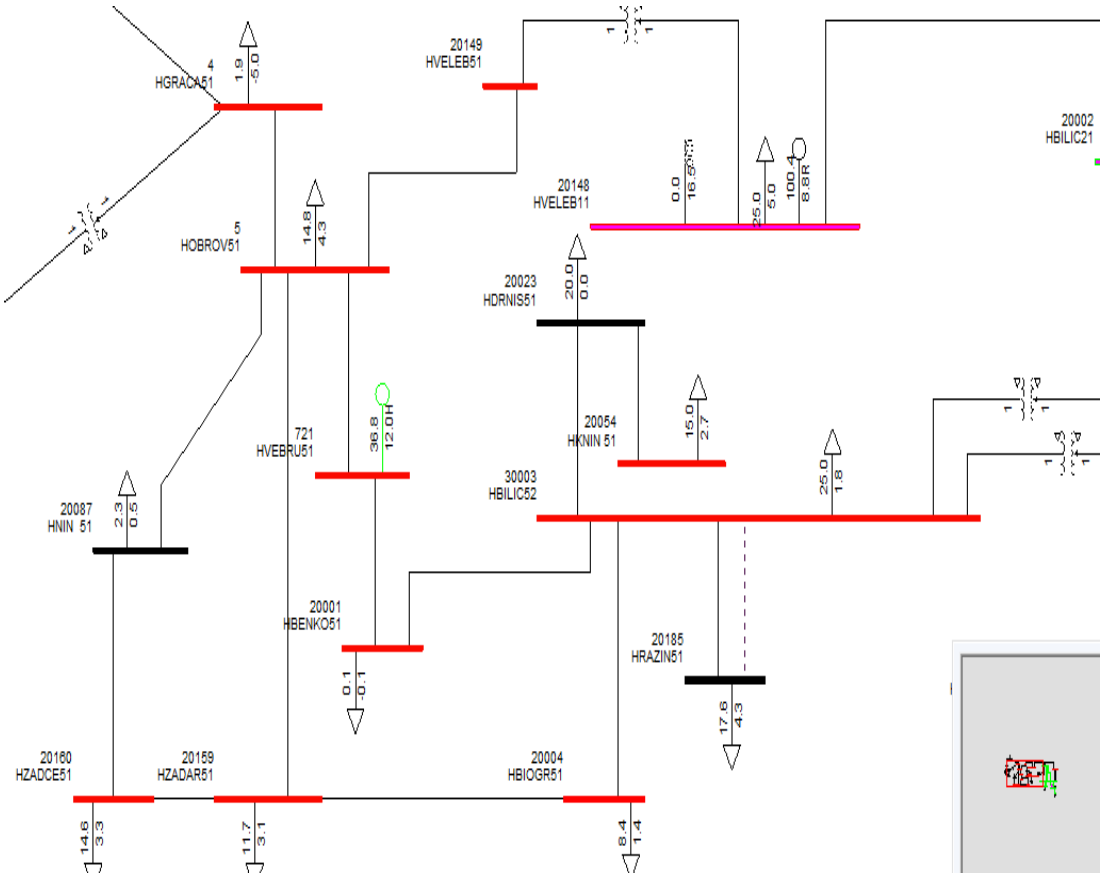
S obzirom na zahtjev iz prethodne elektroenergetske suglasnosti o radu u režimu u kojem je izlazna vrijednost cos φ na sučelju vjetroelektrane u području 0.95 induktivno – 0.95 kapacitivno, ukoliko se za trajni pogon vjetroelektrane odabere režim regulacije napona U, u točki priključka vrlo često će se pojaviti tok jalove snage uzrokovan potrebom regulacije napona u toj točki koja se nalazi na dugačkom neopterećenom vodu. Uslijed toga, vjetroagregati bi svojom sposobnošću regulacije, proizvodili jalovu snagu izvan područja 0.95 induktivno – 0.95 kapacitivno definiranog u prethodnoj elektroenergetskoj suglasnosti.

Stoga se proizvođač mora zaštititi od prekomjerne jalove energije. Postavkom rada u režimu regulacije cos φ, pogon vjetroelektrane odvija se u granicama faktora snage definiranim prethodnom elektroenergetskom suglasnosti odnosno u području 0.95 induktivno – 0.95 kapacitivno. Simulacije za proizvodnju sintetički podataka u režimu regulacije cos φ, napravljene su isključivo za režim regulacije cos φ = 1.

5.3.3 Rezultati modela

Proračuni na modelu obavljeni su u programskom paketu PSS/E. Obavljen je proračun 150 pogonskih stanja. Sva izračunata pogonska stajna data su u prilogu C.

Na sljedećoj slici dat je ekranski prikaz proračuna tokova snaga u programskom paketu PSS/E.



Slika 5.24 Ekranski prikaz proračuna tokova snaga u programskom paketu PSS/E za model vjetroelektrane Zadar 2 i 3

Nakon klasteriranja podataka, korištenjem algoritma k-srednjih vrijednosti, dobiveni centroidi triju klastera Theveninovog ekvivalenta, temeljeno na vektoru *OC* odnosno u ovom primjeru ukupno 150 slučajeva za učenje modela, dati su u sljedećoj tablici:

Tablica 5-4 Centroidi Theveninog ekvivalenta triju klastera EWS signala dobivenih algoritom k-srednjih vrijednosti primijenjenih na modelu vjetroelektrane Zadar 2 i 3

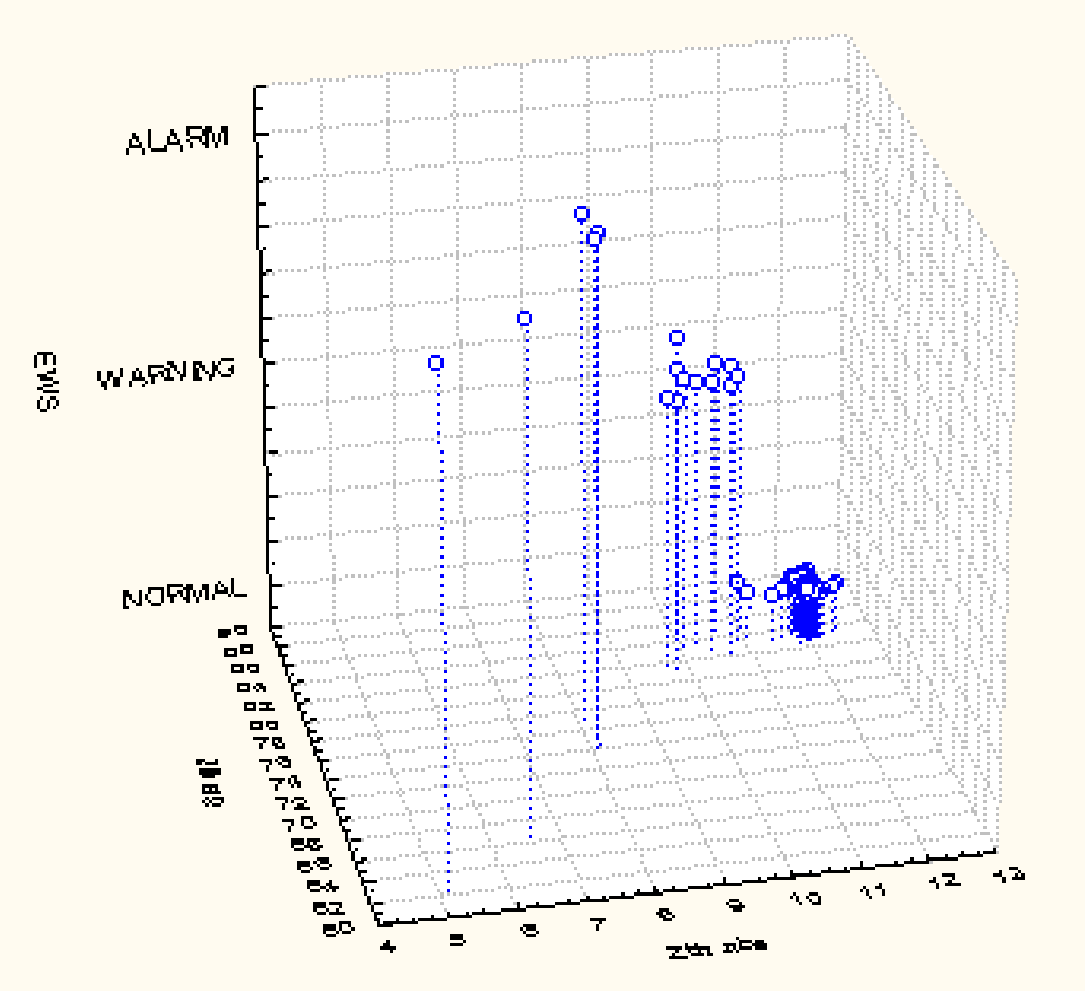
EWS	Z_{th} abs	Z_{th} arg	Broj slučajeva
NORMALNO (NORMAL)	11,98351	83,80223	130
IZVANREDNO (WARNING)	10,42744	81,64916	14
KRITIČNO (ALARM)	7,33635	71,44346	6

Pri čemu je

EWS - signal ranog upozorenja (eng. Early warning signal)
Z_{th} abs - apsolutna vrijednost impedancije Theveninovog ekvivalenta u točki priključka vjetroelektrane
Z_{th} arg - argument impedancije Theveninovog ekvivalenta u točki priključka vjetroelektrane

Simulacijama se sustav morao modelirati u izvanrednom i kritičnom pogonskom stanju da bi se mogao izraditi i uzorak istih pogonskih stanja. U realnim slučajevima stvarnih elektroenergetskih sustava, takva pogonska stanja će biti vrlo rijetko izmjerena odnosno snimljena u svojim karakteristikama i parametrima. Stoga će uzorak takvih pogonskih stanja većinom biti izrađen sintetički odnosno korištenjem simulacija.

Klasteri vrijednosti signala EWS prema ekvivalentnoj Theveninovoj impedanciji na čvorištu priključka VE Zadar 2 i 3, odnosno pripadajućoj apsolutnoj vrijednosti i argumentu iste impedancije, prikazani su na sljedećoj slici



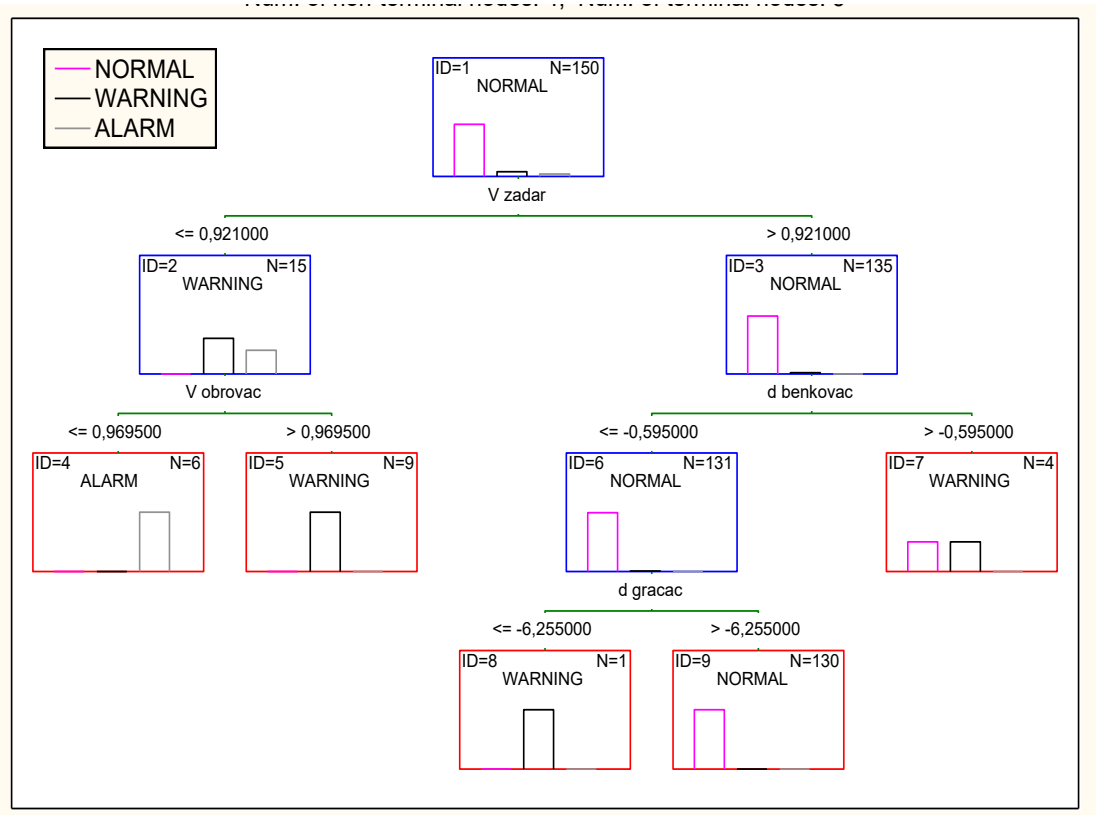
Slika 5.25 Grafički prikaz triju klastera pogonskih stanja modela vjetroelektrane Zadar 2 i 3 korištenjem apsolutne vrijednosti i argumenta ekvivalentne Theveninove impedancije na priključku vjetroelektrane

Prema medijanima signala EWS i njihovom grupiranju prikazanom na prethodnoj slici, vidljivo je kako elektroenergetski sustav mijenja svoju ekvivalentnu impedanciju vrijednosti tijekom pogonskih stanja koja spadaju u izvanredno i kritično pogonsko stanje što predstavlja i očekivano ponašanje.

Izračunati klasteri se koriste u daljnjem tijeku algoritma za klasifikaciju novih izmjerenih ili simuliranih stanja. Klasifikacija je provedena uz korištenje klasteriranih signala EWS-a u pogonskim stanjima kao zavisne varijable. Nezavisne varijable su efekt. vrijednosti i fazni pomaci (kutevi) napona na svim čvorištima, kao i ukupna opterećenja sustava, djelatna snaga vjetroelektrane i jalova snaga vjetroelektrane.

Kao pravilo za zaustavljanje kod klasifikacijskog stabla, korišten je kriterij obrezivanja stabla odlučivanja na temelju misklasifikacijske pogreške. Definirani troškovi misklasifikacije uzeti su jednaki kao i za model IEEE 14 te su dati u tablici 5.2.

Ukoliko se kao nezavisne varijable definiraju efekt. vrijednosti i fazni pomaci (kutevi) napona na svim čvorištima, kao i ukupna opterećenja sustava, djelatna snaga vjetroelektrane i jalova snaga vjetroelektrane, odnosno cjelokupni skup podataka OC_k, optimalno stablo odlučivanja dato je na sljedećoj slici.



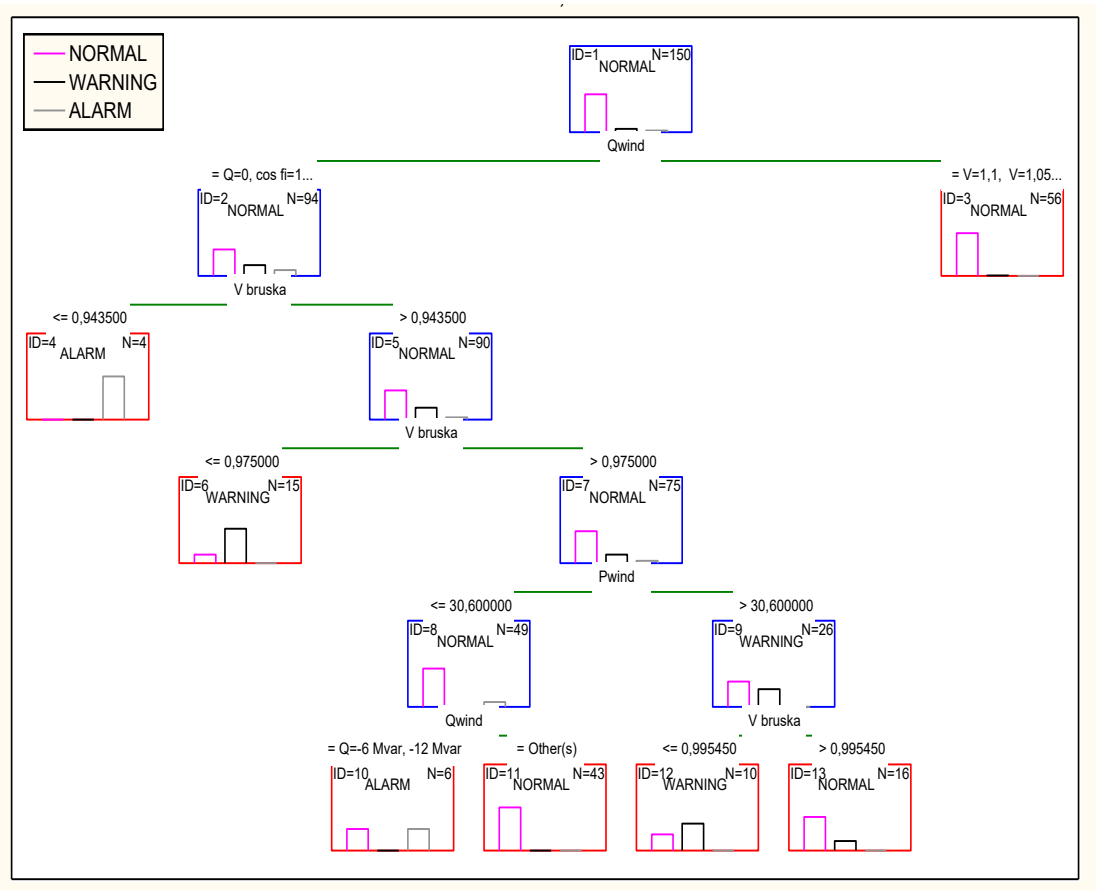
Slika 5.26 Grafički prikaz odabira optimalnog stabla odlučivanja modela vjetroelektrane Zadar 2 i 3 korištenjem metode misklasifikacijskih troškova uz cjelokupni skup ulaznih podataka OC_k

Vidljivo je da su u klasifikacijskom stablu odlučivanja sadržane varijable efektivne vrijednosti napona u čvorištima Zadar i Obrovac te varijabla faznog pomaka (kuta) između čvorišta referentnog čvorišta (u ovom slučaju Velebit 400 kV) te Obrovac 110 kV i Gračac 110 kV. Time je, za definiranje prilika u okolnoj mreži, dovoljno pratiti efektivne vrijednosti i kuteve napona u tim mjernim točkama.

Međutim, budući da za verifikaciju modela, nije bilo moguće obaviti mjerenja na svim čvorištima u mreži, pa tako i na predmetnim čvorištima, te budući da su bila dostupna isključivo mjerenja efekt. vrijednosti i faznog pomaka napona na samoj točki priključka vjetroelektrane, klasifikacijski proračun za verifikaciju modela obavljen je korištenjem reduciranog skupa dostupnih mjernih podataka $OC_{k\text{-}r}$, odnosno:

$$OC_{k\text{-}r} = \{V_{BRUSKA},\ \delta_{BRUSKA},\ P_{Wind},\ Q_{Wind}\} \qquad \textbf{(5.9)}$$

Uz takav ulazni skup podataka, kao rezultat dobije se sljedeće stablo odlučivanja:



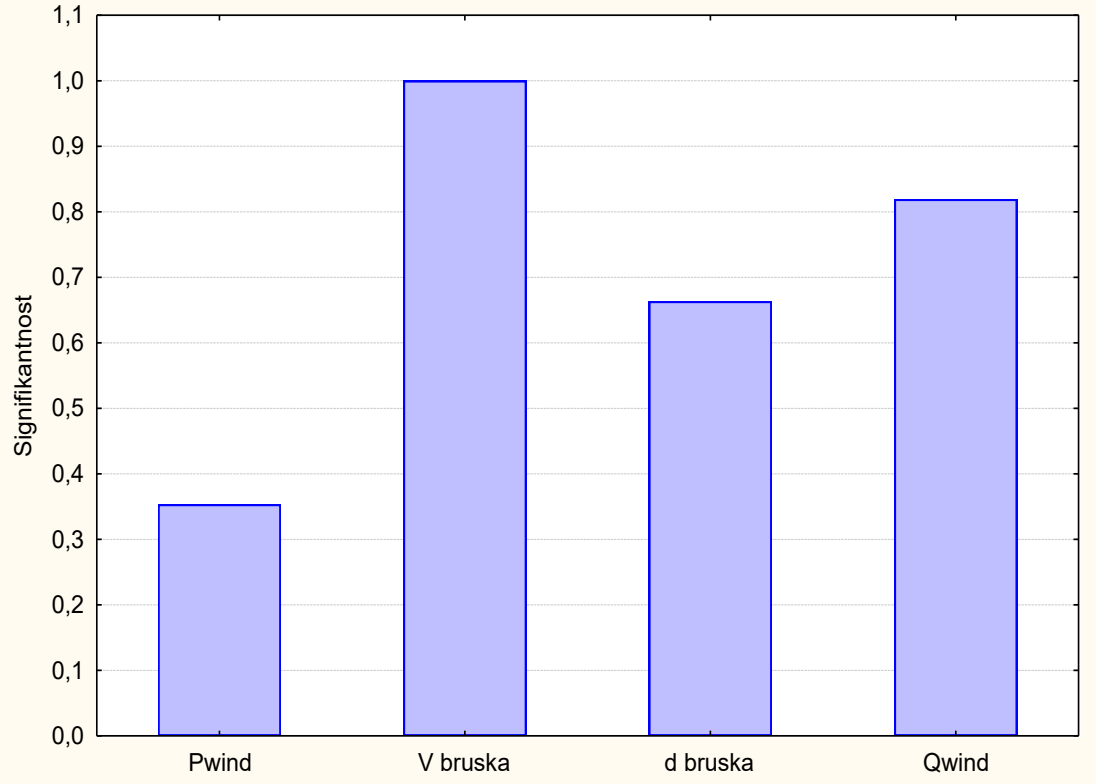
Slika 5.27 Grafički prikaz odabira optimalnog stabla odlučivanja modela vjetroelektrane Zadar 2 i 3 korištenjem metode misklasifikacijskih troškova uz reducirani skup ulaznih podataka $OC_{k\text{-}r}$

Vidljivo je da je u klasifikacijskom stablu odlučivanja sadržano nekoliko varijabli i to:

- podešenja režima rada proizvodnje jalove snage vjetroelektrane,
- efekt. vrijednosti napona na čvorištu TS Bruška (VE Zadar 2 i 3),
- podešenje ograničenja proizvodnje djelatne snage vjetroelektrane.

Time je, za definiranje prilika u lokalnoj mreži oko same vjetroelektrane, dovoljno pratiti efekt. vrijednosti napona u toj mjernoj točki te izraditi donošenje odluka na temelju te varijable. Kao kritična vrijednost napona pokazala se vrijednost od 0,9435 p.u. odnosno 103,785 kV. Padom napona na sabirnicama VE Zadar 2 i 3, odnosno TS Bruška ispod navedene vrijednosti mogu se očekivati kritične pojave u sustavu.

Donošenje odluka prvenstveno se odnosi na promjenu režima rada vjetroelektrane u dijelu proizvodnje jalove snage. Predmetni rezultati predstavljaju i logičku cjelinu sa strane tokova snaga jer je instalirana djelatna snaga vjetroelektrane 36,8 MW što ne predstavlja problem u dijelu prijenosa snage na udaljenosti od otprilike 16 km nadzemnim 110 kV dalekovodom prema TS Obrovac i prema TS Benkovac. Stoga je jedini problem sa strane sigurnosti elektroenergetskog sustava, problem regulacije napona i jalove snage. Na sljedećem dijagramu dat je izračun signifikantnosti pojedinih varijabli.



Slika 5.28 Grafički prikaz odabira optimalnog stabla odlučivanja modela vjetroelektrane Zadar 6 korištenjem metode misklasifikacijskih troškova uz reducirani skup ulaznih podataka $OC_{k\text{-}r}$

Kao određeno dodatno poboljšanje generiranog stabla odlučivanja, moguće je odrediti i određenu sigurnosnu marginu na vrijednost napona na kojoj se događa odlučivanje o izmijeni režima rada vjetroelektrane, npr. na 0,945 p.u. ili slično.

Iz svega navedenog, slijedi zaključak, da su potrebna samo određena mjerenja efektivne vrijednosti napona i kuta napona na nekim sabirnicama u sustavu da bi se došlo do vrijednih zaključaka u pogledu sigurnosti elektroenergetskog sustava, a predmetni signali se mogu iskoristiti u sustavu vođenja.

Također, u Hrvatskom prijenosnom elektroenergetskom sustavu, na naponskoj razini 110 kV, sa priključenim vjetroelektranama, situacija će biti vrlo slična. Problem evakuacije snage javljat će se u situacijama gde postoji priključak vjetroelektrane vrlo blizu hidroelektrane u sustavu gdje će se javiti zagušena u mreži. Takav problem mogao bi se otkloniti ovakvim sustavom i u tom slučaju, razlika kuteva napona bi imala dominantniju ulogu. U tom slučaju, potrebno je i drukčije odrediti kriterij klasteriranja pogonskih stanja u prvom dijelu algoritma i uzeti u obzir zagušenja u mreži kao dio kriterija za klasteriranje.

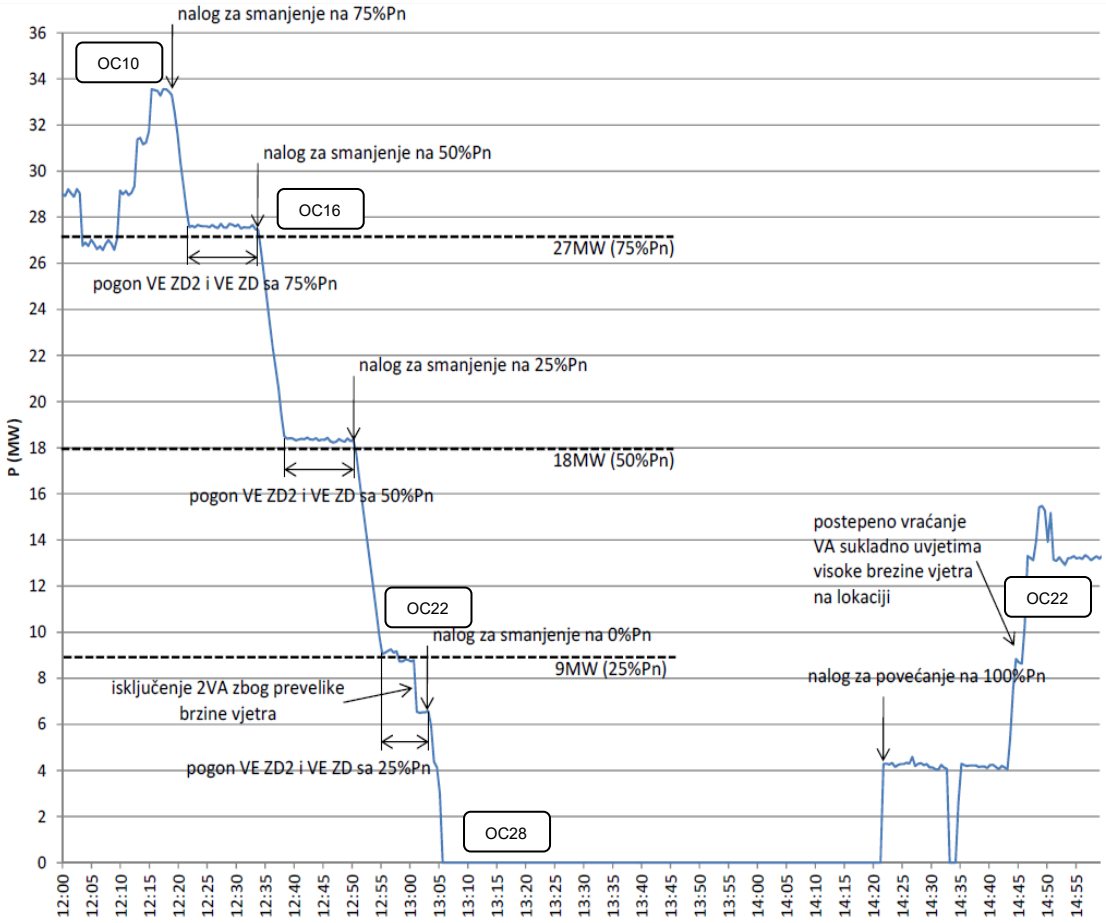
5.3.4 Validacija modela VE Zadar 2 i 3 mjernim podacima

Za validaciju modela VE Zadar 2 i 3, provedeno je nekoliko ispitivanja u sklopu verifikacijskih ispitivanja vjetroelektrane prilikom puštanja u pogon. Predmetna ispitivanja detaljno su opisana u Operativnom planu i programu ispitivanja (OPIP) te u Elaboratu verifikacijskih ispitivanja VE ZD2 i VE ZD3 – Završni Izvještaj.

U sklopu ovog rada, analizirana su sljedeća ispitivanja:

- Ispitivanje ograničenja djelatne snage,
- Isključenje DV 110 kV Obrovac – Bruška,
- Ispitivanje promjene režima regulacije jalove snage,

Ispitivanje ograničenja djelatne snage provedeno je sukladno dijagramu na sljedećoj slici zajedno s pripadajućim pogonskim stanjima.



Slika 5.29 Kretanje djelatne snage VE ZD2 i VE ZD3 mjereno u TR polju 110 kV za vrijeme provedbe ispitivanja ograničenja djelatne snage

Vidljivo je na prethodnoj slici da je ispitivanje ograničenja djelatne snage napravljeno u četiri koraka i to smanjenjem na 75%, 50%, 25% i 0% nazivne snage vjetroelektrane. Vjetroelektrana je u točki priključka odradila sve zadate naloge, a što je rezultiralo snimanjem sljedećih pogonskih stanja odnosno slučajeva najbližih sljedećim pogonskim stanjima definiranim proračunima na modelu:

OC_{10} – uz najbitnije parametre*:*

V_{BRUSKA}	1,058 p.u.
$V_{BENKOVAC}$	1,054 p.u.
$V_{ZADARCENTAR}$	1,016 p.u.
V_{ZADAR}	1,016 p.u.
$V_{BIOGRAD}$	1,022 p.u.
V_{BILICE}	1,04 p.u.
V_{KNIN}	1,015 p.u.
$V_{OBROVAC}$	1,046 p.u.
V_{GRACAC}	1,049 p.u.
$V_{VELEBIT110}$	1,048 p.u.
$V_{VELEBIT400}$	1,05 p.u.
δ_{BRUSKA}	-0,06˚
$\delta_{BENKOVAC}$	-0,79˚
$\delta_{ZADARCENTAR}$	-4,35˚
δ_{ZADAR}	-4,35˚
$\delta_{BIOGRAD}$	-4,12˚
δ_{BILICE}	-2,91˚
δ_{KNIN}	-5,64˚
$\delta_{OBROVAC}$	-1,23˚
δ_{GRACAC}	-1,53˚
$\delta_{VELEBIT110}$	-0,86˚
$\delta_{VELEBIT400}$	0˚
P_{Wind}	36,8 MW
Q_{Wind}	0 Mvar

OC_{16} – uz najbitnije parametre*:*

V_{BRUSKA}	1,056 p.u.
$V_{BENKOVAC}$	1,052 p.u.
$V_{ZADARCENTAR}$	1,016 p.u.
V_{ZADAR}	1,016 p.u.
$V_{BIOGRAD}$	1,022 p.u.
V_{BILICE}	1,04 p.u.
V_{KNIN}	1,015 p.u.
$V_{OBROVAC}$	1,046 p.u.
V_{GRACAC}	1,049 p.u.
$V_{VELEBIT110}$	1,048 p.u.
$V_{VELEBIT400}$	1,05 p.u.

δ_{BRUSKA}	-0,6˚
$\delta_{BENKOVAC}$	-1,25˚
$\delta_{ZADARCENTAR}$	-4,61˚
δ_{ZADAR}	-4,6˚
$\delta_{BIOGRAD}$	-4,37˚
δ_{BILICE}	-3,12˚
δ_{KNIN}	-5,86˚
$\delta_{OBROVAC}$	-1,51˚
δ_{GRACAC}	-1,8˚
$\delta_{VELEBIT110}$	-1,05˚
$\delta_{VELEBIT400}$	0˚
P_{Wind}	24,4 MW
Q_{Wind}	0 Mvar

OC_{22} – uz najbitnije parametre:

V_{BRUSKA}	1,053 p.u.
$V_{BENKOVAC}$	1,05 p.u.
$V_{ZADARCENTAR}$	1,016 p.u.
V_{ZADAR}	1,016 p.u.
$V_{BIOGRAD}$	1,022 p.u.
V_{BILICE}	1,04 p.u.
V_{KNIN}	1,014 p.u.
$V_{OBROVAC}$	1,046 p.u.
V_{GRACAC}	1,048 p.u.
$V_{VELEBIT110}$	1,048 p.u.
$V_{VELEBIT400}$	1,05 p.u.
δ_{BRUSKA}	-1,14˚
$\delta_{BENKOVAC}$	-1,71˚
$\delta_{ZADARCENTAR}$	-4,87˚
δ_{ZADAR}	-4,86˚
$\delta_{BIOGRAD}$	-4,61˚
δ_{BILICE}	-3,34˚
δ_{KNIN}	-6,08˚
$\delta_{OBROVAC}$	-1,78˚
δ_{GRACAC}	-2,07˚
$\delta_{VELEBIT110}$	-1,24˚
$\delta_{VELEBIT400}$	0˚
P_{Wind}	12,2 MW
Q_{Wind}	0 Mvar

OC_{28} – uz najbitnije parametre*:*

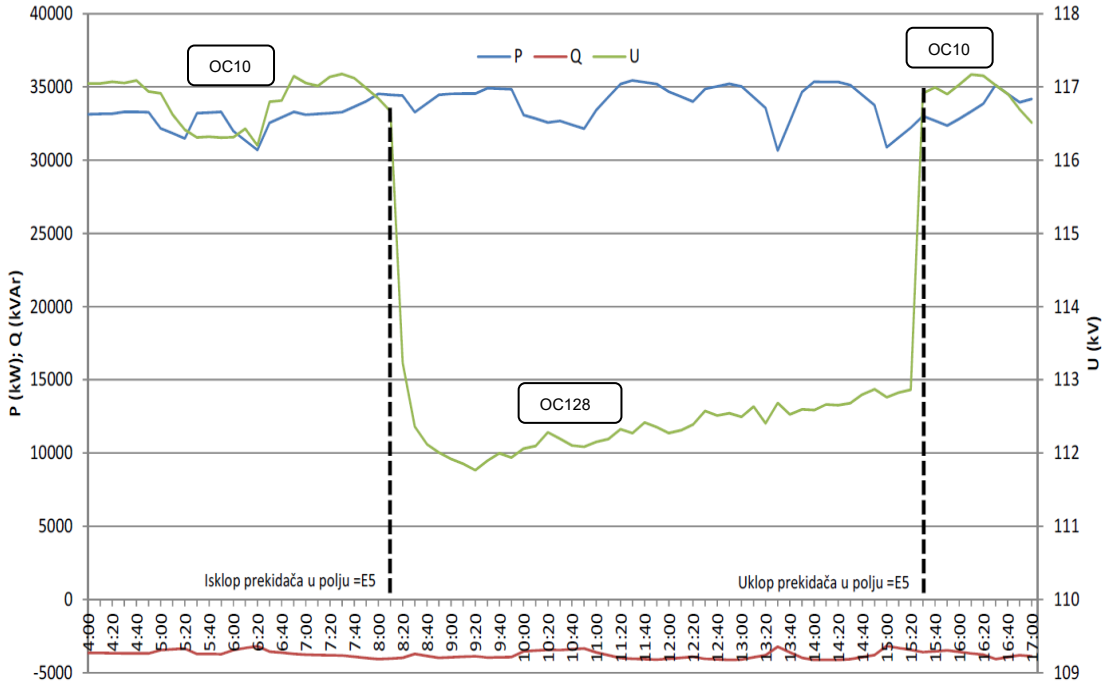
V_{BRUSKA}	1,051 p.u.
$V_{BENKOVAC}$	1,48 p.u.
$V_{ZADARCENTAR}$	1,016 p.u.
V_{ZADAR}	1,016 p.u.
$V_{BIOGRAD}$	1,021 p.u.
V_{BILICE}	1,039 p.u.
V_{KNIN}	1,014 p.u.
$V_{OBROVAC}$	1,045 p.u.
V_{GRACAC}	1,048 p.u.
$V_{VELEBIT110}$	1,047 p.u.
$V_{VELEBIT400}$	1,05 p.u.
δ_{BRUSKA}	-1,67˚
$\delta_{BENKOVAC}$	-2,16˚
$\delta_{ZADARCENTAR}$	-5,12˚
δ_{ZADAR}	-5,12˚
$\delta_{BIOGRAD}$	-4,85˚
δ_{BILICE}	-3,56˚
δ_{KNIN}	-6,29˚
$\delta_{OBROVAC}$	-2,05˚
δ_{GRACAC}	-2,34˚
$\delta_{VELEBIT110}$	-1,42˚
$\delta_{VELEBIT400}$	0˚
P_{Wind}	0 MW
Q_{Wind}	const. cos φ = 1

Isključenje DV Obrovac – Bruška, provedeno je isklopom prekidača u vodnom polju =E5, trafostanice TS 110/20 kV Bruška. Time je simuliran prijelaz iz pogonskog stanja koje najbliže odgovara pogonskom stanju OC_{10} u pogonsko stanje koje najbliže odgovara pogonskom stanju $OC_{128.}$

OC_{128} – uz najbitnije parametre*:*

V_{BRUSKA}	1,025 p.u.
$V_{BENKOVAC}$	1,017 p.u.
$V_{ZADARCENTAR}$	1,018 p.u.
V_{ZADAR}	1,018 p.u.
$V_{BIOGRAD}$	1,029 p.u.
V_{BILICE}	1,056 p.u.
V_{KNIN}	1,031 p.u.
$V_{OBROVAC}$	1,044 p.u.
V_{GRACAC}	1,047 p.u.
$V_{VELEBIT110}$	1,046 p.u.
$V_{VELEBIT400}$	1,05 p.u.
δ_{BRUSKA}	4,47˚
$\delta_{BENKOVAC}$	3,05˚
$\delta_{ZADARCENTAR}$	-4,53˚
δ_{ZADAR}	-4,52˚
$\delta_{BIOGRAD}$	-3,66˚
δ_{BILICE}	-1,31
δ_{KNIN}	-3,96˚
$\delta_{OBROVAC}$	-2,11˚
δ_{GRACAC}	-2,41˚
$\delta_{VELEBIT110}$	-1,47˚
$\delta_{VELEBIT400}$	0˚
P_{Wind}	36,8 MW
Q_{Wind}	const. cos Q = 12 Mvar

Ispitivanje je provedeno sukladno dijagramu na sljedećoj slici zajedno s pripadajućim pogonskim stanjima.



Slika 5.30 Kretanje djelatne i jalove snage VE ZD2 i 3 te napona na sabirnici 110 kV u TS Bruška prilikom isključenja DV 110 kV Obrovac-Bruška

Sukladno prethodnom klasterizacijskom proračunu, pogonsko stanje OC_{10} spada u normalno pogonsko stanje, a pogonsko stanje OC_{128} u izvanredno, odnosno vrijedi:

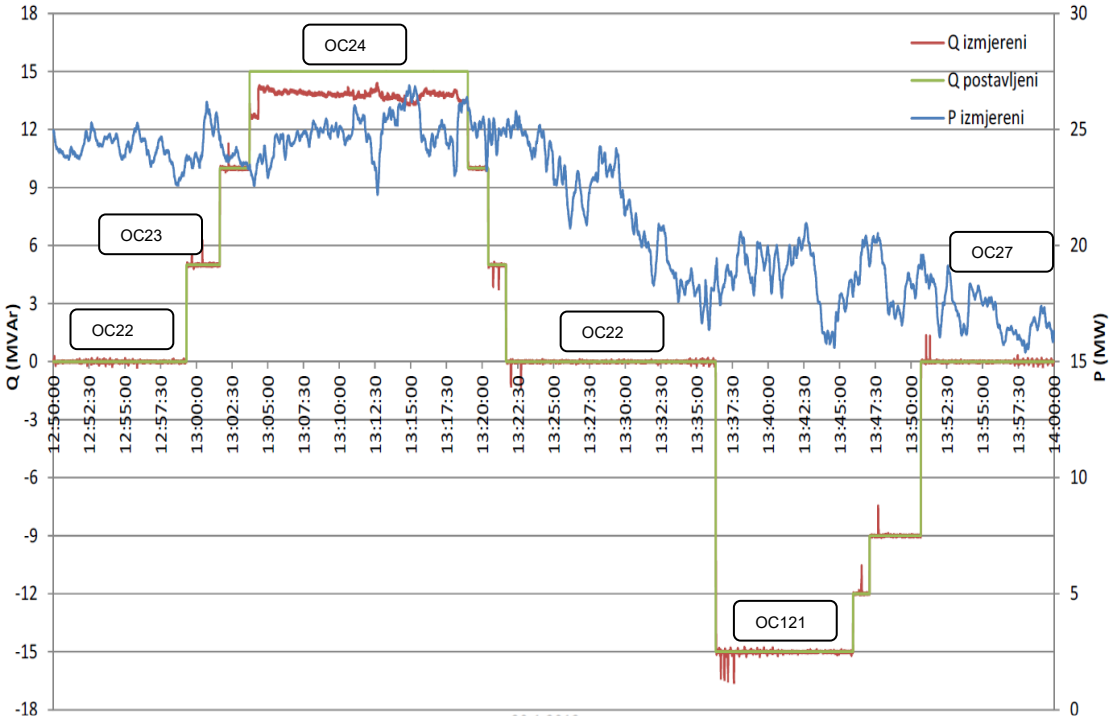
OC_{10} - spada u klasu podataka C_{NORMAL}
OC_{128} - spada u klasu podataka $C_{WARNING}$

Ispitivanje promjene režima regulacije jalove snage, provedeno je nalogom na centralnom računalu vjetroelektrane. Time je simuliran prijelaz iz pogonskog stanja koje najbliže odgovara pogonskom stanju OC_{22} u pogonsko stanje koje najbliže odgovara pogonskom stanju OC_{23} i OC_{24}.

OC_{23} – uz najbitnije parametre:

V_{BRUSKA}	1,058 p.u.
$V_{BENKOVAC}$	1,054 p.u.
$V_{ZADARCENTAR}$	1,018 p.u.
V_{ZADAR}	1,018 p.u.
$V_{BIOGRAD}$	1,024 p.u.
V_{BILICE}	1,042 p.u.
V_{KNIN}	1,017 p.u.
$V_{OBROVAC}$	1,048 p.u.
V_{GRACAC}	1,051 p.u.
$V_{VELEBIT110}$	1,049 p.u.
$V_{VELEBIT400}$	1,05 p.u.
δ_{BRUSKA}	-1,21˚
$\delta_{BENKOVAC}$	-1,76˚
$\delta_{ZADARCENTAR}$	-4,86˚
δ_{ZADAR}	-4,85˚
$\delta_{BIOGRAD}$	-4,60˚
δ_{BILICE}	-3,34˚
δ_{KNIN}	-6,06˚
$\delta_{OBROVAC}$	-1,78˚
δ_{GRACAC}	-2,08˚
$\delta_{VELEBIT110}$	-1,24˚
$\delta_{VELEBIT400}$	0˚
P_{Wind}	12,2 MW
Q_{Wind}	6 Mvar

Ispitivanje je provedeno sukladno dijagramu na sljedećoj slici zajedno s pripadajućim pogonskim stanjima.



Slika 5.31 Prikaz zadane reference jalove snage VE ZD2 i ZD3 i ostvarene jalove snage te djelatne snage u TP 20 kV u TS Bruška

Sva navedena pogonska stanja, osim pogonskog stanja OC_{128} sukladno prethodnom klasterizacijskom izračunu spadaju u normalno pogonsko stanje. Pogonsko stanje OC_{128} spada u izvanredno pogonsko stanje, odnosno vrijedi:

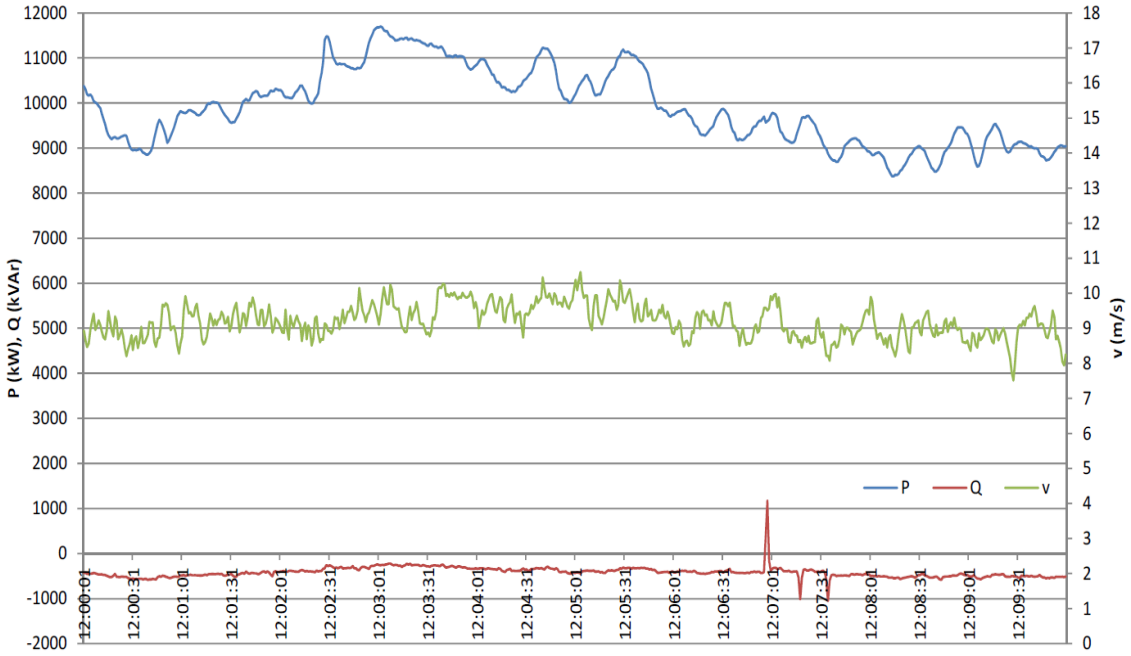
OC_{121} - spada u klasu podataka $C_{WARNING}$

Nakon svih ispitivanja, vjetroelektrana je postavljena u režim rada

$P_{settings}$ = 36,8 MW
$Q_{settings}$ = const. cos φ = 1

što odgovara pogonskom stanju $OC_{10.}$

Isto pogonsko stanje prikazano je na sljedećem dijagramu.



Slika 5.32 Ukupna proizvodnja djelatne i jalove snage VE ZD2 i 3 te brzina vjetra izmjerena na vjetroagregatu VT-1

Budući da je trenutno važećom elektroenergetskom suglasnosti predmetnog objekta za proizvodnju električne energije definirano da ista vjetroelektrana može raditi u području proizvodnje jalove snage definirano faktorom snage na mjestu priključka u rasponu

cos φ = 0,95 kapacitivno - 0,95 induktivno

vrlo vjerojatno u stvarnom pogonu u skoro vrijeme neće doći do mijenjanja istih postavki dok se ne definira tržište sistemskih usluga regulacije napona i jalove snage. Ovim ispitivanjima vjetroelektrana je dokazala mogućnost predmetne regulacije kao i većina vjetroelektrana u okolnoj mreži, ali bi aktivnosti u dijelu prekomjerne proizvodnje jalove energije rezultirale naplatom iste sukladno mjerenjima na obračunskom mjernom mjestu.

6. ZAKLJUČAK

Povećanje broja inteligentnih elektroničkih uređaja odnosno raznoraznih mjernih, nadzornih, upravljačkih i senzorskih uređaja instaliranih u elektroenergetskom sustavu rezultira stalnim povećanjem količine podataka koji se prenose i pohranjuju u nadležnim centrima upravljanja i ostalim hijerarhijskim razinama. Opisana količina podataka bivat će sve veća u budućnosti jer se može očekivati daljnji rast broja instaliranih predmetnih uređaja. Pri tom se nameće mogućnost i potreba analize ovih novih vrsta podataka klasičnim determinističkim, ali i novim nedeterminističkim matematičkim modelima. Jedan od ključnih preduvjeta pri tom je usklađenost, harmoniziranost i sinkroniziranost podataka.

U ovom radu opisana je jedna od mogućnosti korištenja takvih harmoniziranih i sinkroniziranih podataka korištenjem tehnike rudarenja podataka u svrhu upravljanja pogonom vjetroelektrana.

Predloženi model upravljanja pogonom vjetroelektrane sastoji se od klasterizacijskog dijela, čime se postojeći mjerni i simulacijski podaci dijele u tri klastera podataka za normalno, izvanredno i kritično pogonsko stanje, te zatim klasifikacijskog dijela, čime se novim mjernim podacima pridjeljuju prethodno definirane klase podataka. Izradom modela upravljanja pogonom vjetroelektrane zasnovanog na sinkroniziranim mjerenjima definiran je i prvi znanstveni doprinos ovog rada.

Na taj način se novim mjernim podacima može definirati prelazak odnosno tranzicija elektroenergetskog sustava iz normalnog u izvanredno ili kritično stanje sustava pri čemu je definiran novi tzv. Rani signal upozorenja (eng. EWS – Early Warning Signal) kao mjera sigurnosne svjesnosti (eng. SA – Situational Awareness).

Klasifikacijski dio modela rezultira izrađenim stablom odlučivanja u kojem su sadržane mjerne varijable, kao što su sinkronizirani mjerni podaci, te upravljačke varijable, kao što su izlazna djelatna i jalova snaga. Inducirano stablo odlučivanja rezultira mogućim pogonskim stanjima koja spadaju u normalno, izvanredno i kritično pogonsko stanje. Kao krajnji dio algoritma odlučivanja o režimu rada provodi se jednostavni optimizacijski postupak odabirom mogućeg normalnog pogonskog stanja s minimalnom proizvodnjom jalove snage i maksimalnom proizvodnjom djelatne snage. Definiranjem prethodno opisanog stabla odlučivanja i provođenjem jednostavnog optimizacijskog postupka, definiran je algoritam odlučivanja za promjenu režima rada vjetroelektrana na temelju karakterističnih vrijednosti električnih veličina sustava u cilju optimiranja pogona elektroenergetskog sustava i time je definiran drugi znanstveni doprinos ovog rada.

Verifikacija razvijenog matematičkog modela na temelju mjerenja u realnom elektroenergetskom sustavu napravljena je korištenjem mjerenja obavljenih u

stvarnom pogonu vjetroelektrane Zadar 6, priključene na 35 kV distribucijsku mrežu, te vjetroelektrane Zadar 2 i 3, priključene na 110 kV prijenosnu mrežu. Verifikacijom matematičkog modela potvrđen je predmetni matematički model i izrađeni algoritam te je tim definiran i treći znanstveni doprinos ovog rada.

Predmetni model može se smatrati robusnim budući da kao ulazni podaci u algoritam mogu služiti bilo kakve vrste mjerenja parametara koji su identificirani kao bitni parametri za pogon vjetroelektrana i elektroenergetskog sustava u cjelini. Bitan preduvjet je da svi mjerni podaci budu standardizirani, harmonizirani i sinkronizirani što je u ovom trenutku poprilično teško za postići, naročito uzevši u obzir neharmoniziranost mjernih i komunikacijskih standarda i protokola za ove različite veličine.

Također, potrebni preduvjet jest postojanje zapisa pogonskih stanja u svim definiranim područjima rada odnosno u normalnom, izvanrednom i kritičnom pogonskom stanju. Vrlo teško je dobiti zapise izvanrednog, a naročito kritičnog pogonskog stanja u stvarnom pogonu. Stoga je predmetne zapise u kritičnom pogonskom stanju potrebno izraditi najčešće simulacijama.

Nastavak istraživanja u ovom području prvenstveno obuhvaća izradu većeg broja simulacijskih zapisa i podataka u dijelu za izvanredno i kritično pogonsko stanje. Time se dobije preciznija granulacija prilikom izrade klastera podataka. Daljnja nadogradnja obuhvaća uzimanje u obzir dodatnh setova drgih vrsta mjernih podataka kao što su ponajprije senzorski podaci sa niza senzora koji će se sve više instalirati u elektroenergetskom sustavu.

Što se tiče primjene matematičkog modela i izrađenog algoritma, trenutno u Hrvatskom elektroenergetskom sustavu je potrebno definirati tržište sistemskom uslugom regulacije jalove snage. Također, potrebno je i sustavno definirati načine ograničenja djelatne snage vjetroelektrane u smislu pokrivanja gubitaka vlasnika vjetroelektrane.

7. POPIS LITERATURE

L 1 IEA, „Renewable energy – medium term market report“, International Energy Agency, Paris, Francuska, 2016

L 2 M. Klaric, ,,EMF calculations and measurements according to Croatian legislative", International Colloquium Power Frequency Electromagnetic Fields ELF EMF, Sarajevo, June 2009

L 3 N. Malbaša, ,,Analiza mogućih problema pri implementaciji ciljeva Europske Unije u vezi s obnovljivim izvorima energije", HED – Dan Energije, Zagreb, 2009.

L 4 EU energy and transport in figures, Statistical Pocketbook 2009

L 5 B. M. Petersen, T. F. Pedersen, H. Klug, N.van der Borg, N. Kelley, J. Alke Dahlberg, edited by R. S. Hunter, “Wind speed measurement and use of cup anemometry”, Recommended practices for wind turbine testing, 2003.

L 6 Directive 2009/28/EC on the promotion of the use of energy from renewable sources amending and subsequently repealing Directives 2001/77/EC and 2003/30/EC, Brussels, 26 March 2009.

L 7 Dalekovod d.d. Tipski projekt stupa visine 50 m za mjerenje vjetra, Dalekovod d.d. – Zagreb, 2006.

L 8 NRG Systems, Symphonie data logger and accessories, Hinesburg, USA, 2003.

L 9 Walmsley,J.L., Salmon J.R. and Taylor,P.A. “On the Application of a Model of Boundary-Layer Flow over Low Hills to Real Terrain”, Boundary-Layer Meteorology, 23, pp17-46, 1982

L 10 Walmsley,J.L., Taylor,P.A. and Keith,T. “A Simple Model of Neutrally Stratified Boundary-Layer Flow over Complex Terrain with Surface Roughness Modulations - MS3DJH/3R”, Boundary-Layer Meteorology, 36, p157-186, 1986.

L 11 Wilmshurst,S. Metherall,A.J.H., Wilson,D.M.A., Milborrow,D.J. and Ross,J.N. “Wind Turbine Rotor Performance in the High Thrust Region”, 6th BWEA Conference, Reading 1984, p268-278.

L 12 Anderson,M.B., Milborrow,D.J. and Ross,J.N. “Performance and Wake Measurements on a 3m Diameter Horizontal Axis Wind Turbine Rotor”, Proc. 4th Intl. Symposium on Wind Energy Systems, Stockholm, 1982.

L 13 Ainslie,J.F. “Calculating the Flowfield in the Wake of Wind Turbines”, Journal of Wind Engineering and Industrial Aerodynamics, 27, 1988, p213-224.

L 14 Frandsen,S., Chacon,L., Crespo,A., Enevoldsen,P., Gomez-Elvira,R., Hernandez,J., Holstrup,J., Manuel,F., Thomsen,K. and Sorensen,P. “Measurements on and Modelling of Offshore Wind Farms”, Riso-R-903 report, June 1996.

L 15 Garrad Hassan and Partners. “The Effect of Rotor Characteristics on the Loading Spectrum and Fatigue Life of a Wind Turbine within a Wind Farm” GH Report 197/R/2 December 1991.

L 16 Smith.D and Taylor,G.J. “Further Analysis of Turbine Wake Development and Interaction Data” 13th BWEA Conference, Swansea 1991.

L 17 Lalas, DP and Ratto CF (editors), “Modelling of Atmospheric Flow Fields”, pages 213-245, ISBN 9810225091, World Scientific Publishing Co.1996.

L 18 Troen, I, Petersen, EL, “European Wind Atlas”, ISBN 8755014828, Riso National Laboratory, Roskilde, Denmark, 1989.

L 19 Sempreviva, AM, Larsen, SE, Mortensen, NG and Troen, I, “Roughness Change for Small and Large Fetches”, Ris-M-2749, Riso National laboratory, Roskilde, Denmark, 1988.

L 20 Burch, SF, Ravenscroft, F, “Computer Modelling of the UK Wind Resource”, ETSU WN 7056, 1992.

L 21 ESDU 82026, “Strong Winds in the Atmospheric Boundary Layer, Part 1 Mean Hourly Wind Speeds”, Engineering Sciences Data Unit Ltd., 251 Regent St. London.

L 22 Smith.D “Multiple Wake Measurements and Analysis”, 12th BWEA Conference, Norwich 1990, p53-58

L 23 Hassan,U., Glendinning,A.G., Morgan,C.A. “A Wind Tunnel Investigation of the Wake Structure and Machine Loads within Small Wind Turbine Farms”, 12th BWEA Conference, Norwich 1990, p47-52.

L 24 Beyer,H.G., Pahlke,T., Schmidt,W.,Waldl,H-P. and de Witt,U. “Operational Behaviour of a Small Straight Line Wind Farm”, EWEC 89 Conference, Glasgow 1989, p311-315

L 25 Larsen.,A. and Velk,P. “Wind Turbine Wake Inteference - A Validation Study”, EWEC 89 Conference, Glasgow 1989, p311-315

L 26 Hojstrup,J., Katic,I. and Norgard,P. “Supervising and Measuring at Taendpibe Windfarm”, Proc. Euroforum New Energies Conference, Saarbruchen 1988.

L 27 Harris, A. “Wind Farm Test Data and the Assessment of Topographic and Wake Models of Wind Farm Output” ETSU Report W/32/00228/45/REP, 1995

L 28 Larsen,GC. “Cookery Book for Wind Farm Load Calculations”, RISO Laboratory, November 1997

L 29 “European Wind Turbine Standards II”, ECN-C--99-073

L 30 G. Knight na "Control Applications for Power System Security", Firenze 1983.

L 31 Fink – Carlsen "Operating under stress and strain". IEEE Spectrum, ožujak 1978

L 32 Dodatni tehnički uvjeti za priključak i pogon vjetroelektrana, HEP-OPS d.o.o., prosinac 2008.

L 33 Mrežna pravila elektroenergetskog sustava, Ministarstvo gospodarstva, (NN 36/2006)

L 34 Scott E. Fahlman, Christian Lebiere: “The cascade-correlation learning architecture”; Advances in Neural Information Processing Systems 2; D. S. Touretzky (ed.), Morgan-Kaufmann, Los Altos CA, 1990.

L 35 HRN IEC 61400-12

L 36 MEASNET

L 37 Dalekovod d.d. Tipski projekt stupa visine 50 m za mjerenje vjetra, Dalekovod d.d. – Zagreb, 2006.

L 38 M. Klarić, D. Đurđević, M. Guberina: “Autonomno daljinsko mjerenje karakteristika vjetra”, MIPRO 2008, Opatija 26.-30.05.2008.

L 39 Scott E. Fahlman, Christian Lebiere: “The cascade- learning architecture”; Advances in Neural Information Processing Systems 2; D. S. Touretzky (ed.), Morgan-Kaufmann, Los Altos CA, 1990.

L 40 Hoehfeld, M. and S. E. Fahlman (1992) "Learning with Limited Numerical Precision Using the Cascade-Correlation Learning Algorithm", in IEEE Transactions on Neural Networks, vol. 3, no. 4, pp. 602-611, July 1992.

L 41 NRG Systems, Symphonie data logger and accessories, Hinesburg, USA, 2003.

L 42 B. M. Petersen, T. F. Pedersen, H. Klug, N.van der Borg, N. Kelley, J. Alke Dahlberg, edited by R. S. Hunter, “Wind speed measurement and use of cup anemometry”, Recommended practices for wind turbine testing, 2003.

L 43 I.J. Ramírez-Rosado, L.A. Fernández-Jiménez (Spain), and C. Monteiro (Portugal); “Artificial Neural Network Models for Wind Power Short-Term Forecasting using Weather Predictions”; Modelling, Identification, and Control, MIC 2006; Lanzarote, Canary Islands, Spain

L 44 GE Energy: „Analysis of Wind Generation Impact on ERCOT Ancillary Services Requirements“; prepared for Electric Reliability Council of Texas, March 2008.

L 45 GE Energy: „The Effects of Integrating Wind Power on Transmission System Planning, Reliability and Operations“; prepared for the New York State Energy Research and Development Authority, March 2005.

L 46 Hrvoje Korasić, Alen Varžić, Končar - Inženjering za energetiku i transport, Zagreb, „Telekomunikacijske veze centara upravljanja s nadziranim i upravljanim elektroenergetskim objektima”; HO-CIGRE

L 47 DOE, (July 2000), Carbon Dioxide Emissions from the Generation of Electric Power in the United States, Environmental Protection Agency, Washington, USA

L 48 L. Breiman, J.H. Friedman, R.A. Olshen, and C.T. Stone. Classification and Regression Trees. Wadsworth, Belmont, California, 1984.

L 49 C.L. Blake D.J. Newman, S. Hettich and C.J. Merz. UCI repository of machine learning databases, 1998.

L 50 T. Elomaa and M. Kaariainen. An analysis of reduced error pruning. Journal of Articial Intelligence Research, 15:163–187, 2001.

L 51 Usama M. Fayyad. Data mining and knowledge discovery: Making sense out of data. IEEE Expert: Intelligent Systems and Their Applications, 11(5):20–25, 1996.

L 52 A. Feelders. Classification trees; dostupno na web adresi http://www.cs.uu.nl/docs/vakken/adm/trees.pdf.

L 53 R. Kruse G. Della Riccia and H. Lenz. Computational Intelligence in Data Mining. Springer, New York, NY, USA, 2000.

L 54 N. Landwehr, M. Hall, and E. Frank. Logistic model trees, 2003.

L 55 J. Ross Quinlan. C4.5: programs for machine learning. Morgan¸ Kaufmann Publishers Inc., San Francisco, CA, USA, 1993.

L 56 Ian H. Witten and Eibe Frank. Data Mining: Practical machine learning tools and techniques. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 2nd edition, 2005.

L 57 M. Kantardzic, Data Mining – Concepts, Models, Methods and Algorithms; IEEE Wiley Interscience, Piscataway, New Jersey, SAD, 1993***.***

L 58 J. Han, M. Kamber, J. Pei; Data Mining – Concepts and Techniques, Elsevier - Morgan Kaufmann, Waltham, Massachusets, SAD, 2012***.***

L 59 P. Panciatici, G. Bareux, L. Wehenkel, "Operating in the fog", IEEE Power and Energy Magazine, October 2012, pp. 40-49

L 60 I. Kamwa, S.R. Samantaray, G. Joos, "Development of Rule based Classifiers for Rapid Stability Assesment of Wide Area Post-Disturbance Records", IEEE Transactions on Power Systems, vol. 24, no. 1, February 2009, pp. 258-270

L 61 M. He, J. Zhang, V. Vittal, "Robust Online Dynamic Security Assessment Using Adaptive Ensemble Decision-Tree Learning", IEEE Transactions on Power Systems, vol. 28, no. 4, October 2009, pp. 4089-4098

L 62 S. Abdelkaber"Online Tracking of Thévenin Equivalent Parameters Using PMU Measurements", IEEE Transactions on Power Systems, vol. 27, no. 2, April 2012, pp. 975-983

L 63 I. Ivanković; I. Kuzle; N. Holjevac; „Multifunctional WAMPAC system concept for out-of-step protection based on synchrophasor measurements"// International journal of electrical power & energy systems, 87 (2017) 77-88. doi:10.1016/j.ijepes.2016.11.005

L 64 A. Marinakis, M.Larsson, "Survey of Measurement and Intelligence-based Applications in Power Systems", IEEE PowerTech Conference 2013, Grenoble, France, October 2011, pp. 1-6

L 65 P. Ranganathan, K. Nygard, "Smart Grid Data Analytics for Decision Support" IEEE Electrical Power and Energy Conference (EPEC) 2011, Winnipeg, Canada, October 2011, pp. 315-321

L 66 M. Kezunovic, L. Xie, S. Grijalva, "The role of big data in improving power system operation and protection", Bulk Power System Dynamics and Control - IX Optimization, Security and Control of the Emerging Power Grid (IREP), 2013 IREP Symposium, Rethymno, Greece, August 2013, pp. 1-9

L 67 F. Cleveland, “Use of Wireless Data Communications in Power System Operations,” 2006 Power System Conference and Exposition, Atlanta, USA, pp. 631-640.

L 68 Y. Yorozu, M. Hirano, K. Oka, and Y. Tagawa, “Low Throughput Networks for the IoT: Lessons learned from industrial implementations”, 2015 IEEE 2nd World Forum on Internet of Things (WF-IoT), Milan, Italy, December 2015, pp. 181 – 186

L 69 Z. Li, W. Wu, “Phasor Measurement Aided Decision Trees for Power System Security Assessment”, 2nd International Conference on Information and Computing Science 2009, Manchester, UK, May 2009, pp 358-361

L 70 E. Cotilla-Sanchez, P. Hines, C. Danforth, “Predicting critical transitions from time series synchrophasor data”, 2013 IEEE Power and Energy Society General Meeting, Vancouver, Canada, July 2013

L 71 D. Zhou, F. Blaajberg, “Reactive Power Impact on Lifetime Prediction of Two-level Wind Power Converter”, PCIM Europe 2013, Nuremberg, Germany, May 2013, pp. 564-571

L 72 I. Ivanković; I. Kuzle; N. Holjevac; “Algorithm for Out-of-Step Condition Detection and Early Warning Using Phasor Measurement Unit Data“ // 2017 IEEE 17th International Conference on Environment and Electrical Engineering IEEE, 2017. and 2017 IEEE Industrial and Commercial Power System Europe (EEEIC / I&CPS Europe); Milan: 2017 IEEE, 2017. pp 1-6

L 73 I. Ivanković; I. Kuzle; N. Holjevac, “Wide Area Information-Based Transmission System Centralized Out-of-Step Protection Scheme”// Energies, 10 (2017), 5; 633-1. doi:10.3390/en10050633

L 74 I. Ivanković; R. Rubeša; I. Kuzle, “Modeling 400 kV Transmission Grid with System Protection and Disturbance Analysis”// IEEE International Energy Conference, Leuven: IEEE, 2016. pp. 1-7

L 75 M. Kazerooni, H. Zhu, T. Overbye, “Literature review on the applications of data mining in power systems”// Power and Energy Conference at Illinois, 2014

L 76 CISCO, “PMU Networking with IP Multicast”, www.cisco.com, document ID 1458164583372983, March 2014.

L 77 M. Sipser, “Introduction to the theory of computation”, Cengage Learning, 2013, Boston, Massachusets, SAD.

L 78 T. Davenport, “Big data in big companies”, International Institute for Analytics IIA, 2013, Portland, Oregon, SAD.

POPIS OZNAKA

α	- eksponent proporcionalnosti brzine vjetra s visinom
a	- iskustveni koeficijent za procjenu regulacijske pričuve
b	- iskustveni koeficijent za procjenu regulacijske pričuve
C	- skup klasa podataka
C_A	- skup klasa podataka u algoritmu
C_{NORMAL}	- klasa podataka za normalno pogonsko stanje
$C_{WARNING}$	- klasa podataka za izvanredno pogonsko stanje
C_{ALARM}	- klasa podataka za kritičn pogonsko stanje
C_{WOPP}	- oportunitetni troškovi vjetroelektrane
$C(i/j)$	- definirani trošak misklasifikacije
$c_{EL\text{-}EN}$.	- cijena električne energije
c_p	- stupanj aerodinamičke pretvorbe vjetroagregata
c_T	- koeficijent potiska vjetroagregata
c_v.	- toplinski kapacitet vodiča
$\Delta i(s,t)$	- povećanje nečistoće čvorišta na sljedećoj operaciji grananja
$\Delta i\ (\underline{s_m}, t)$	- povećanje nečistoće čvorišta na surogat grananju
ΔP_{VE}	- smanjenje djelatne snage vjetroelektrane
ΔT_v	- promjena temperature vodiča
δ_i	- kut napona na čvorištu i,
$E_{el,god}$	- električna energija dobivena u jednoj godini
E_{god}	- (moguća) ukupna godišnja proizvedena energija
$E_{k,vj}$	- kinetička energija vjetra po površini
EWS	- signal ranog upozorenja (eng. Early warning signal)
Φ	- nnegativna funkcija nečistoće čvorišta u stablu odlučivanja
f	- frekvencija sustava
$H(i)$	- ukupni broj sati u određenom području brzina
I	- struja kroz vodič
$i(t)$	- nečistoća čvorišta u stablu odlučivanja
$i(t_L)$	- nečistoća čvorišta granatog na lijevu stranu od polaznog
$i(t_R)$	- nečistoća čvorišta granatog na desnu stranu od polaznog
IT	- intenzitet turbulencije (bezdimenzionalan)
j	- redni broj klase podataka
J	- broj klasa podataka u skupu klasa C
L_{max}	- očekivana maks. snaga potrošnje regulacijskog područja
λ	- srednja efekt. vrijednost svojstvenih vrijednosti Jacobi matrice
λ_n	- n-ta svojstvena vrijednost Jacobi matrice
m_v	- masa vodiča
η_{god}	- godišnji faktor opterećenja (FLH)
OC_k	- skup podataka o pogonskim stanjima
$OC_{k\text{-}r}$	- reduciran skup podataka o pogonskim stanjima
p_0	- tlak zraka pri standardnim atmosferskim prilikama
p_B	- barometarski tlak
p_{sl}	- tlak zraka vrijednosti ovisnih parametara

$p(i/j)$ - razmjer *i*-tog čvorišta i *j*-te grane čvorišta
$p(j/t)$ - razmjer čvorišta u stablu odlučivanja
p_L - razmjer čvorišta granatog na lijevu stranu od polaznog
p_R - razmjer čvorišta granatog na desnu stranu od polaznog
P_L - opterećenje sustava,
P_n - nazivna snaga
$P_{settings}$ - postavke izlazne djelatne snage vjetroelektrane koje su
P_{AV} - raspoloživa snaga proizvodnje vjetroelektrane
P_{Wind} - djelatna snaga vjetroelektrane,
Q_{Wind} - jalova snaga vjetroelektrane,
P_t - transformirana snaga vjetroagregata
$p(v_i)$ - vjerojatnost pojave centralne vrijednosti u *i*-tom intervalu
P_{vj} - ukupna specifična snaga vjetra,
Q_c - toplinski gubici uslijed konvekcije
Q_r - toplinski gubici uslijed radijacije
Q_s - toplinski dobici uslijed insolacije
Q_{CON} - konvolucijska funkcija izlazne jalove snage vjetroelektrane
$Q_{settings}$ - postavke izlazne jalove snage vjetroelektrane
ρ - gustoća zraka
ρ_0 - gustoća zraka pri standardnim uvjetima: 288 K i 760mmHg
ρ_{sl} - gustoća zraka pri promjenjenoj vrijednosti ovisnih parametara
RP - zahtijevana vrijednost sekundarne regulacijske rezerve
RU - rast snage proizvodnje vjetroagregata u vremenu
R_v - djelatni otpor vodiča
R_{th}, - djelatni dio nadomjesne Theveninove impedancije
σ_{vj} - varijanca brzine vjetra (m/s)
S_{TR} - nazivna snaga transformatora (MVA).
$\underline{s_m}$ - operacija alternativnog ili surogat grananja u čvorištu *t*
T - apsolutna temperatura zraka
T_0 - temperatura zraka pri standardnim atmosferskim prilikama
T_{sl} - temperatura zraka vrijednosti ovisnih parametara
t - vrijeme
T_T - vremenski interval
U_w - brzina vjetra nakon rada na prvom vjetroagregatu u sjeni
U_i - brzina vjetra na *i*–tom vjetroagregatu
U_{ij} - brzina vjetra na *i*-tom vjetroagregatu uslijed rada u sjeni *j*-tog
v - brzina vjetra
v_i - centralna vrijednost (medijan) brzina vjetra *i*-tog intervala,
VD - smanjenje brzine vjetra zbog rada u vjetroagregata sjeni
v_{h1} - brzina vjetra na visini h_1
v_{h2} - brzina vjetra na visini h_2
v_{sr} - srednja brzina vjetra,
v_p - brzina vjetra za pokretanje vjetroagregata (cut-in speed),
Vi - efektivna vrijednost napona na čvorištu *i*,

$W(i)$	- izlazna snaga vjetra u određenom području brzina
X	- udaljenost između vjetroagregata u smjeru niz vjetar
X_D	- udaljenost između vjetroagregata u promjerima vjetroagregata
X_n	- dužina područja bliskog rada u sjeni
X_{th}	- reaktivni dio nadomjesne Theveninove impedancije
X	- atribut vektor, zapis odnosno n-torka podataka,
X1, X2,...Xn	- podskupovi osnovnog skupa **X**
x1, x2,...xn	- atributi atribut vektora, opisuju mjerenja *n* podataka tj. atributa.
Z_{th} abs	- apsolutna vrijednost impedancije Theveninovog ekvivalenta
Z_{th} arg	- argument impedancije Theveninovog ekvivalenta

POPIS SKRAĆENICA

AMI	– eng. Advanced Metering Infrastructure
CDU	– centar daljinskog upravljanja,
CWDM	– eng. Coarse Wavelength Division Multiplexing,
DC	– dispečerski centar distribucijskog područja,
DP	– distribucijsko područje
DV	– dalekovod
DWDM	– eng. Dense Wavelength Division Multiplexing,
EES	– elektroenergetski sustav
EL	– elektrana
ENTSO-E	– eng. European Network of Transmission System Operators
EU	– Europska Unija
EWEA	– eng. European Wind Energy Association
EWS	– eng. Early Warning Signal, signal ranog upozorenja
FLH	– eng. Full Load Hours, godišnji broj sati rada na nazivnoj snazi
GE	– General Electric
HE	– hidroelektrana
HEP	– Hrvatska elektroprivreda
HERA	– Hrvatska energetska regulatorna agencija
HPPP	– eng. High Performance Park Pilot
HROTE	– Hrvatski regulator tržišta energijom
HWRT	– eng. High Wind Ride Through
ICT	– information and communication technology)
IED	– eng. Intelligent Energy Device
IKT	– informacijska i komunikacijska tehnologija
IP	– eng. Internet Protokol
IPP	– eng. Independent Power Producer
KL	– komanda lanca
KS	– komanda sliva
LVRT	– eng. Low Voltage Ride Through
MC	– mrežni centar,
MPLS	– eng. Multiprotocol Label Switching,
NDC	– nacionalni dispečerski centar,
NN	– Narodne novine
ODS	– Operator Distribucijskog Sustava
OPGW	– eng. Optical Ground Wire (zaštitno uže s optičkim kabelom)
OPS	– Operator Prijenosnog Sustava
PCC	– eng. Point of Common Coupling – točka tj. mjesto priključka
PDC	– eng. Phasor Data Concentrator
PMU	– eng. Phasor Measurement Unit,
PPA	– eng. Power Purchase Agreement
RP	– rasklopno postrojenje,
RH	– Republika Hrvatska
RHE	– reverzibilna hidroelektrana
SA	– eng. Situational Awareness, situacijska svjesnost
SAD	– Sjedinjene Američke Države

SCADA	– eng. Supervisory Control And Data Acquisition
SDH	– Sinkrona Digitalna Arhitektura
SMT	– eng. Synchronized Measurement Technology
SN	– srednji napon
TE	– termoelektrana
TEN	– Transeuropean Network (transeuropska mreža)
TS	– transformatorska stanica
UCTE	– eng. Union for the Coordination of Transmission of Electricity
VA	– vjetroagregat
VE	– vjetroelektrana
WAM	– eng. wide area monitoring
ZVRT	– eng. Zero Voltage Ride Through

PRILOG A – POGONSKA STANJA MODELA IEEE 14

OC	P VE	Q VE	VE 8	Bus 1	Bus 2	Bus 3	Bus 4	Bus 5	Bus 6	Bus 7	Bus 8
OC1	9	4,4	1,05	1,057	1,037	1,037	1,02	-2,4	-2,5	-2,7	-2,7
OC2	5	2,4	1,047	1,049	1,034	1,034	1,023	-2,84	-2,93	-2,9	-2,9
OC3	9	4,4	1,004	1,006	0,984	0,985	0,973	-2,61	-2,71	-2,94	-2,95
OC4	5	2,4	0,995	0,997	0,981	0,982	0,972	-3,2	-3,22	-3,21	-3,21
OC5	9	4,4	0,91	0,912	0,891	0,891	0,879	-4,48	-4,59	-4,94	-4,94
OC6	9	4,4	1,091	1,093	1,072	1,073	1,06	-2,2	-2,47	-2,47	-2,72
OC7	5	2,4	1,116	1,119	1,103	1,103	1,092	-3,39	-3,48	-3,42	-3,42
OC8	9	6,7	1,081	1,083	1,059	1,059	1,045	-3,34	-3,44	-3,53	-3,53
OC9	5	3,7	1,06	1,044	1,01	1,007	1,012	-3,74	-3,83	-3,74	-3,74
OC10	9	6,7	1,027	1,029	1,005	1,005	0,991	-3,69	-3,79	-3,92	-3,92
OC11	5	3,7	1,016	1,018	1,001	1,001	0,99	-4,13	-4,22	-4,16	-4,16
OC12	9	-6,7	1,047	1,049	1,043	1,043	1,039	-2,69	-2,78	-3,34	-3,34
OC13	9	-3,35	1,056	1,058	1,047	1,047	1,04	-2,85	-2,95	-3,39	-3,39
OC14	9	-3	1,057	1,059	1,048	1,048	1,04	-2,87	-2,97	-3,39	-3,39
OC15	9	0	1,064	1,066	1,052	1,052	1,042	-3,02	-3,11	-3,44	-3,44
OC16	9	0	1,064	1,066	1,052	1,052	1,042	-3,02	-3,11	-3,44	-3,44
OC17	9	3,35	1,073	1,075	1,055	1,055	1,044	-3,18	-3,27	-3,48	-3,48
OC18	9	3	1,072	1,074	1,055	1,055	1,044	-3,16	-3,25	-3,48	-3,48
OC19	9	6,7	1,081	1,083	1,059	1,059	1,045	-3,34	-3,43	-3,53	-3,53
OC20	6	-6,7	1,045	1,047	1,043	1,043	1,038	-3,1	-3,19	-3,53	-3,54
OC21	6	-3,35	1,053	1,055	1,047	1,047	1,04	-3,26	-3,35	-3,58	-3,58
OC22	6	0	1,062	1,064	1,051	1,051	1,042	-3,42	-3,51	-3,63	-3,63
OC23	6	0	1,062	1,064	1,051	1,051	1,042	-3,42	-3,51	-3,63	-3,63
OC24	6	3,35	1,07	1,072	1,055	1,055	1,044	-3,58	-3,67	-3,67	-3,67
OC25	6	6,7	1,078	1,08	1,059	1,059	1,045	-3,74	-3,83	-3,72	-3,72
OC26	3	-6,7	1,042	1,044	1,042	1,042	1,038	-3,51	-3,6	-3,73	-3,73
OC27	3	-3,35	1,051	1,053	1,046	1,046	1,04	-3,67	-3,76	-3,77	-3,77
OC28	3	0	1,059	1,061	1,05	1,05	1,042	-3,82	-3,92	-3,82	-3,82
OC29	3	0	1,059	1,061	1,05	1,05	1,042	-3,82	-3,92	-3,82	-3,82
OC30	3	3,35	1,068	1,07	1,054	1,054	1,043	-3,98	-4,07	-3,86	-3,86
OC31	3	6,7	1,076	1,078	1,058	1,058	1,045	-4,14	-4,23	-3,91	-3,91
OC32	0	-6,7	1,039	1,041	1,041	1,041	1,038	-3,92	-4,01	-3,92	-3,92
OC33	0	-3,35	1,048	1,05	1,045	1,045	1,04	-4,08	-4,17	-3,96	-3,96
OC34	0	0	1,057	1,059	1,049	1,049	1,041	-4,23	-4,33	-4,01	-4,01
OC35	0	0	1,057	1,059	1,049	1,049	1,041	-4,23	-4,33	-4,01	-4,01
OC36	0	3,35	1,065	1,067	1,053	1,053	1,045	-4,38	-4,48	-4,05	-4,05
OC37	0	6,7	1,073	1,075	1,057	1,057	1,045	-4,54	-4,63	-4,1	-4,1
OC38	9	-6,7	1,042	1,044	1,039	1,039	1,034	-2,94	-3,04	-3,6	-3,6
OC39	9	-3,35	1,051	1,053	1,041	1,043	1,036	-3,11	-3,21	-3,64	-3,64
OC40	9	-3	1,052	1,054	1,042	1,043	1,036	-3,11	-3,21	-3,63	-3,64

PRILOG B – POGONSKA STANJA MODELA VE ZADAR 6

OC	P VE	Q VE	VE ZD6	SRB 35	GRA 35	GRA 110	OBROVAC 110	VE ZD6	SRB 35	GRA 35	GRA 110	OBROVAC 110
OC1	9	4,4	1,05	1,057	1,037	1,037	1,02	-2,4	-2,5	-2,7	-2,7	-2,92
OC2	5	2,4	1,047	1,049	1,034	1,034	1,023	-2,84	-2,93	-2,9	-2,9	-3,05
OC3	9	4,4	1,004	1,006	0,984	0,985	0,973	-2,61	-2,71	-2,94	-2,95	-3,26
OC4	5	2,4	0,995	0,997	0,981	0,982	0,972	-3,2	-3,22	-3,21	-3,21	-3,39
OC5	9	4,4	0,91	0,912	0,891	0,891	0,879	-4,48	-4,59	-4,94	-4,94	-5,36
OC6	9	4,4	1,091	1,093	1,072	1,073	1,06	-2,2	-2,47	-2,47	-2,72	-3,44
OC7	5	2,4	1,116	1,119	1,103	1,103	1,092	-3,39	-3,48	-3,42	-3,42	-3,53
OC8	9	6,7	1,081	1,083	1,059	1,059	1,045	-3,34	-3,44	-3,53	-3,53	-3,76
OC9	5	3,7	1,06	1,044	1,01	1,007	1,012	-3,74	-3,83	-3,74	-3,74	-3,86
OC10	9	6,7	1,027	1,029	1,005	1,005	0,991	-3,69	-3,79	-3,92	-3,92	-4,19
OC11	5	3,7	1,016	1,018	1,001	1,001	0,99	-4,13	-4,22	-4,16	-4,16	-4,3
OC12	9	-6,7	1,047	1,049	1,043	1,043	1,039	-2,69	-2,78	-3,34	-3,34	-3,74
OC13	9	-3,35	1,056	1,058	1,047	1,047	1,04	-2,85	-2,95	-3,39	-3,39	-3,74
OC14	9	-3	1,057	1,059	1,048	1,048	1,04	-2,87	-2,97	-3,39	-3,39	-3,74
OC15	9	0	1,064	1,066	1,052	1,052	1,042	-3,02	-3,11	-3,44	-3,44	-3,75
OC16	9	0	1,064	1,066	1,052	1,052	1,042	-3,02	-3,11	-3,44	-3,44	-3,75
OC17	9	3,35	1,073	1,075	1,055	1,055	1,044	-3,18	-3,27	-3,48	-3,48	-3,76
OC18	9	3	1,072	1,074	1,055	1,055	1,044	-3,16	-3,25	-3,48	-3,48	-3,76
OC19	9	6,7	1,081	1,083	1,059	1,059	1,045	-3,34	-3,43	-3,53	-3,53	-3,76
OC20	6	-6,7	1,045	1,047	1,043	1,043	1,038	-3,1	-3,19	-3,53	-3,54	-3,82
OC21	6	-3,35	1,053	1,055	1,047	1,047	1,04	-3,26	-3,35	-3,58	-3,58	-3,82
OC22	6	0	1,062	1,064	1,051	1,051	1,042	-3,42	-3,51	-3,63	-3,63	-3,83
OC23	6	0	1,062	1,064	1,051	1,051	1,042	-3,42	-3,51	-3,63	-3,63	-3,83
OC24	6	3,35	1,07	1,072	1,055	1,055	1,044	-3,58	-3,67	-3,67	-3,67	-3,83
OC25	6	6,7	1,078	1,08	1,059	1,059	1,045	-3,74	-3,83	-3,72	-3,72	-3,84
OC26	3	-6,7	1,042	1,044	1,042	1,042	1,038	-3,51	-3,6	-3,73	-3,73	-3,89
OC27	3	-3,35	1,051	1,053	1,046	1,046	1,04	-3,67	-3,76	-3,77	-3,77	-3,9
OC28	3	0	1,059	1,061	1,05	1,05	1,042	-3,82	-3,92	-3,82	-3,82	-3,9
OC29	3	0	1,059	1,061	1,05	1,05	1,042	-3,82	-3,92	-3,82	-3,82	-3,9
OC30	3	3,35	1,068	1,07	1,054	1,054	1,043	-3,98	-4,07	-3,86	-3,86	-3,91
OC31	3	6,7	1,076	1,078	1,058	1,058	1,045	-4,14	-4,23	-3,91	-3,91	-3,92
OC32	0	-6,7	1,039	1,041	1,041	1,041	1,038	-3,92	-4,01	-3,92	-3,92	-3,97
OC33	0	-3,35	1,048	1,05	1,045	1,045	1,04	-4,08	-4,17	-3,96	-3,96	-3,98
OC34	0	0	1,057	1,059	1,049	1,049	1,041	-4,23	-4,33	-4,01	-4,01	-3,98
OC35	0	0	1,057	1,059	1,049	1,049	1,041	-4,23	-4,33	-4,01	-4,01	-3,98
OC36	0	3,35	1,065	1,067	1,053	1,053	1,045	-4,38	-4,48	-4,05	-4,05	-3,99
OC37	0	6,7	1,073	1,075	1,057	1,057	1,045	-4,54	-4,63	-4,1	-4,1	-3,99
OC38	9	-6,7	1,042	1,044	1,039	1,039	1,034	-2,94	-3,04	-3,6	-3,6	-3,88
OC39	9	-3,35	1,051	1,053	1,041	1,043	1,036	-3,11	-3,21	-3,64	-3,64	-3,88
OC40	9	-3	1,052	1,054	1,042	1,043	1,036	-3,11	-3,21	-3,63	-3,64	-3,88

PRILOG C – POGONSKA STANJA MODELA VE ZADAR 2I3

OC	P VE	Q VE	VE BRUSK	BENK	ZADAR CENT	ZAD	BIOGR	BILICE	KNIN	OBROVAC	GRAČAC
OC1	36,8	17,8	1,04	1,024	0,989	0,989	0,983	0,98	0,931	1,033	1,023
OC2	18	8,7	1,028	1,014	0,984	0,984	0,978	0,976	0,927	1,028	1,018
OC3	36,8	17,8	0,985	0,967	0,93	0,929	0,923	0,918	0,866	0,978	0,967
OC4	18	8,7	0,986	0,969	0,939	0,939	0,93	0,922	0,869	0,989	0,991
OC5	36,8	-17,8	1,094	1,091	1,062	1,062	1,067	1,082	1,042	1,09	1,094
OC6	18	-8,7	1,098	1,095	1,065	1,065	1,07	1,085	1,045	1,094	1,097
OC7	36,8	-12	1,046	-1,042	1,009	1,009	1,013	1,029	1,01	1,04	1,043
OC8	36,8	-6	1,053	1,049	1,014	1,014	1,02	1,038	1,013	1,044	1,046
OC9	36,8	0	1,058	1,054	1,016	1,016	1,022	1,04	1,015	1,046	1,049
OC10	36,8	6	1,063	1,058	1,019	1,019	1,025	1,042	1,017	1,049	1,052
OC11	36,8	12	1,068	1,062	1,022	1,022	1,027	1,044	1,019	1,051	1,054
OC12	24,4	-12	1,046	1,043	1,011	1,011	1,017	1,036	1,01	1,041	1,044
OC13	24,4	-6	1,051	1,047	1,014	1,014	1,02	1,038	1,013	1,044	1,046
OC14	24,4	0	1,056	1,052	1,016	1,016	1,022	1,04	1,015	1,046	1,049
OC15	24,4	6	1,061	1,056	1,019	1,019	1,024	1,042	1,017	1,049	1,051
OC16	24,4	12	1,065	-1,36	1,021	1,021	1,027	1,045	1,019	1,051	1,054
OC17	12,2	-12	1,043	1,041	1,011	1,011	1,017	1,035	1,01	1,04	1,043
OC18	12,2	-6	1,048	1,046	1,013	1,013	1,019	1,037	1,012	1,043	1,046
OC19	12,2	0	1,053	1,05	1,016	1,016	1,022	1,04	1,014	1,046	1,048
OC20	12,2	6	1,058	1,054	1,018	1,018	1,024	1,042	1,017	1,048	1,051
OC21	12,2	12	1,063	1,058	1,021	1,021	1,026	1,044	1,019	1,051	1,054
OC22	0	-12	1,04	1,039	1,01	1,01	1,016	1,035	1,01	1,04	1,043
OC23	0	-6	1,046	1,044	1,013	1,013	1,019	1,037	1,012	1,043	1,045
OC24	0	0	1,051	1,048	1,016	1,016	1,021	1,039	1,014	1,045	1,048
OC25	0	6	1,055	1,052	1,018	1,018	1,024	1,042	1,016	1,048	1,051
OC26	0	12	1,06	1,056	1,021	1,021	1,026	1,044	1,018	1,05	1,053
OC27	36,8	-12	1,039	1,036	0,995	0,995	1,003	1,028	0,999	1,032	1,026
OC28	36,8	-6	1,044	1,04	0,997	0,997	1,005	1,03	1,001	1,035	1,029
OC29	36,8	0	1,049	1,045	1	1	1,008	1,032	1,003	1,037	1,032
OC30	36,8	6	1,054	1,049	1,003	1,003	1,01	1,034	1,005	1,04	1,034
OC31	36,8	12	1,059	1,053	1,005	1,005	1,013	1,036	1,008	1,042	1,037
OC32	24,4	-12	1,036	1,034	0,994	0,994	1,003	1,028	0,998	1,032	1,026
OC33	24,4	-6	1,041	1,038	0,997	0,997	1,005	1,03	1,001	1,034	1,029
OC34	24,4	0	1,047	1,043	1	1	1,008	1,032	1,033	1,037	1,032
OC35	24,4	6	1,052	1,047	1,002	1,002	1,01	1,034	1,005	1,039	1,034
OC36	24,4	12	1,057	1,051	1,005	1,005	1,013	1,036	1,007	1,042	1,037
OC37	12,2	-12	1,034	1,032	0,994	0,994	1,002	1,027	0,998	1,031	1,026
OC38	12,2	-6	1,039	1,037	0,997	0,997	1,005	1,029	1	1,034	1,028
OC39	12,2	0	1,044	1,041	0,999	0,999	1,007	1,032	1,003	1,036	1,031

ŽIVOTOPIS

Mario Klarić rođen je 1979. u Šibeniku gdje je završio osnovnu i srednju školu. 2002. diplomirao je na Fakultetu elektrotehnike i računarstva u Zagrebu. Iste godine radio je u Budimpešti u firmi LEAR Corporation kao projektant u automobilskoj industriji. Od 2003. do 2005. radio je na Fakultetu elektrotehnike i računarstva na Zavodu za visoki napon i energetiku kao Zavodski suradnik gdje je i magistrirao 2006. na temu ,,Podnaponsko rasterećenje elektroenergetskog sustava". Od 2005.-2007. radi u firmi Dalekovod d.d. – Zagreb na poslovima projektiranja elektroenergetskih postrojenja. Od 2007. – 2009. radi u Dalekovodu u poslovnoj cjelini Inženjering na poslovima razvoja projekata obnovljivih izvora energije. Od 2009. – 2015. radi u firmi Dalekovod-Projekt d.o.o. na poslovima razvoja i projektiranja elektroenergetskih objekata i postrojenja obnovljivih izvora energije. 2010. sudjelovao u programu Future Energy Leaders u okviru svjetske energetske konferencije u Montrealu. 2011. završio je specijalistički poslijediplomski studij – MBA na Ekonomskom fakultetu u Zagrebu. 2013. stekao je certifikat PMP – Project Management Professional. Od 2015. radi na poziciji pomoćnika predsjednika uprave tvrtke Dalekovod za poslove razvoja novih proizvoda i usluga. Član je hrvatske komore ovlaštenih inženjera elektrotehnike te udruga IEEE, PMI, Hrvatskog energetskog društva te Hrvatskog odbora CIGRE.

POPIS RADOVA

Znanstveni radovi u CC i SCI časopisima

1. Klarić, Mario; Kuzle, Igor; Holjevac, Ninoslav. **Wind power monitoring and control based on synchrophasor measurement data mining**. // *Energies* (ISSN 1996-1073; CODEN: ENERGA)*:* (2019), (članak, znanstveni).

Znanstveni radovi u drugim časopisima

1. Kuzle, Igor; Klarić, Mario; Pandžić, Hrvoje. **Feasibility Assessment of Wind Power Plant with Scarce Local Wind Data Using Cascade-Correlating Algorithm**. // *Strojarstvo : časopis za teoriju i praksu u strojarstvu*. **53** (2011) , 6; 455-462 (članak, znanstveni).

Objavljena pozvana predavanja na skupovima

1. Goić, Ranko; Jakus, Damir; Penović, Ivan; Vasilj, Josip; Kovačević, Aleksandar; Lovrić, Marko; Klarić, Mario. **Integracija vjetroelektrana u hrvatski elektroenergetski sustav** // *8. simpozij o sustavu vođenja EES-a : referati = 8th Symposium on Power System Management : Papers* / Filipović-Grčić, Božidar ; Tomiša, Irena (ur.). Zagreb : Hrvatski ogranak CIGRE, 2008. (pozvano predavanje,domaća recenzija,objavljeni rad,znanstveni).

Znanstveni radovi u zbornicima skupova s međunar.rec.

1. Klarić, M.; Kuzle, I.; Livaja, I.
Adaptive and modular urban smart infrastructure // *39th International Convention MIPRO 2016* / Biljanović, Petar (ur.). Rijeka : Croatian Society for Information and Communication Technology, Electronics and Microelectronics - MIPRO, 2016. 1538-1542 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

2. Klarić, Mario; Kuzle, Igor.
Grid integration of wind power plants in congested line // *Proceedings of the International IEEE Conference EUROCON 2009* /Mikerov, Alexander (ur.). Piscataway : IEEE, 2009. 611-616 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

3. Klarić, Mario; Kuzle, Igor.
Optimal grid integration of wind power plants in Croatian 110 kV network // *IEEE Bucharest PowerTech 2009 : Proceedings* / Eremia, Mircea (ur.). Bucharest : IEEE, 2009. 1-6 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

4. Klarić, Mario; Kuzle, Igor; Tešnjak, Sejid.
Example of Undervoltage Load Shedding Implementation // *Proceeding of Africon '07* / Singha, S. (ur.). Windhoek : IEEE Press, 2007. S26.1-S26.5 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

5. Klarić, Mario; Kuzle, Igor; Tomiša, Tomislav.
Simulation of Undervoltage Load Shedding to Prevent Voltage Collapse // *Proceedings of the IEEE PowerTech 2005 ; Ref. 193* / Voropai, Nikolai I. (ur.). Irkutsk : IEEE PES&Energy Systems Institute, 2005. 1-6 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

6. Klarić, Mario; Kuzle, Igor; Tešnjak, Sejid.
Undervoltage Load Shedding Using Global Voltage Collapse Index // *Proceedings of the 2004 Power Systems Conference and Exposition (PSCE'04)*. New York : IEEE Press, 2004. (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

7. Kuzle, Igor; Klarić, Mario; Tešnjak, Sejid.
Reactive Power Evaluation and Market Power in Deregulated Ancillary Services Market // *Proceeding of The 12th IEEE Mediterranean Electrotechnical Conference (MELECON 2004)*. 2004. (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

Drugi radovi u zbornicima skupova s recenzijom

1. Klarić, Mario; Salkić, Hidajet.
Regulacija napona i jalove snage vjetroelektrana// (predavanje,domaća recenzija,objavljeni rad,stručni).

2. Klarić, Mario; Salkić, Hidajet; Petričević, Ante.
Mjerenja vjetropotencijala na većim visinama// (predavanje,domaća recenzija,objavljeni rad,stručni).

3. Klarić, Mario; Guberina, Marko; Bartak, Vedran.
Mjerni stup visine 80 m za mjerenje vjetropotencijala // . (predavanje,domaća recenzija,objavljeni rad,stručni).

4. Klarić, Mario; Guberina, Marko; Đurđević, Davor.
Mjerenja vjetra na potencijalnim lokacijama gradnje vjetroelektrana // .
(predavanje,domaća recenzija,objavljeni rad,stručni).

5. Klarić, Mario; Guberina, Marko; Đurđević, Davor.
Autonomno daljinsko mjerenje karakteristika vjetra // . 2008. (predavanje,domaća recenzija,objavljeni rad,stručni).

6. Klarić, Mario; Kuzle, Igor; Tešnjak, Sejid.
Sekundarna regulacija napona i jalove snage – temeljni koncepti // *7. savjetovanje HO CIGRE : Pregled referata ; C2-06* / Moser, Josip ; Tomiša, Irena (ur.). Zagreb : Hrvatski ogranak CIGRE, 2005. 1-10 (predavanje,domaća recenzija,objavljeni rad,stručni).

7. Kuzle, Igor; Klarić, Mario; Plavšić, Tomislav; Grujić, Vladimir.
Pregled naponskih stanja i prilika u elektroenergetskom sustavu

RH // *Zbornik Šestog simpozija o sustavu vođenja elektroenergetskog sistema hrvatskog ogranka CIGRE* / Tomiša, Irena (ur.). Zagreb : Hrvatski ogranak CIGRE, 2004. 49-55 (predavanje,domaća recenzija,objavljeni rad,stručni).

8. Klarić, Mario; Kuzle, Igor; Tešnjak, Sejid.
Potrošači jalove snage u uvjetima otvorenog tržišta // *Zbornik 12. foruma Dan energije u Hrvatskoj : Potrošači energije u uvjetima otvorenog tržišta* / Granić, Goran ; Jelavić, Branka (ur.). Zagreb : Hrvatsko energetsko društvo, 2003. 145-153 (predavanje,domaća recenzija,objavljeni rad,stručni).

9. Kuzle, Igor; Tešnjak, Sejid; Klarić, Mario.
Otvoreno tržište jalovom snagom // *Zbornik Šestog savjetovanja HK CIGRE Pogon i vođenje EES-a* / Tomiša, Irena (ur.). Zagreb : HK CIGRE, 2003. 51-58 (predavanje,domaća recenzija,objavljeni rad,stručni).

Neobjavljena sudjelovanja na skupovima

1. Klarić, Mario.
Mogućnosti poboljšanja pogona vjetroelektrana s aspekta vođenja elektroenergetskog sustava RH // . Opatija : Hrvatski ogranak CIGRE, 2013. (pozvano predavanje, neobjavljeni rad, znanstveni).

Druge vrste radova

1. Kuzle, Igor; Tomiša, Tomislav; Marušić, Ante; Klarić, Mario.
Električna mjerenja na uzemljivačkom sustavu TS 35/10 kV Bulinac, 2004. (studija).

2. Kuzle, Igor; Marušić, Ante; Klarić, Mario.
Paralelni rad transformatora 35/10 kV u TS 110/35/10 kV Novalja, 2003. (studija).

CURRICULUM VITAE

Mario Klaric was born in Sibenik in 1979, where he finished his primary and secondary school. In 2002. he received his BScEE at the Faculty of Electrotechnics and Computing in Zagreb. In the same year, he was working in Lear Corporation in Budapest as a design engineer in car industry. From 2003 till 2005 he has been working at the Faculty of Electrotechnics and Computing in Zagreb in the Power System Department as a researcher. He received his MScEE at the same Faculty on the subject "Power system undervoltage load shedding". From 2005 till 2007 he has been working in company Dalekovod as a power system facility designer. From 2007 till 2009 he has been working in the same company in business unit Engineering on developing renewable energy sources projects. From 2009-2015 he has been working in company Dalekovod-Projekt as a designer of renewable energy facilities. In 2010. he enrolled Future Energy Leaders Programme in World Energy Congress in Montreal. In 2011. he finished specialized Masters degree – MBA on the Faculty of Economy in Zagreb. In 2013. he was certified as PMP – Project Management Professional. Since 2015. he works on the position of CEO Associate for research and development activities. He is a member of IEEE, PMI Croatian Energy Society and CIGRE.