

Metodologija izračuna zajedničke pogonske karte grupe paralelno spojenih generatora

Glavan, Boris

Doctoral thesis / Disertacija

2022

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:168:737204>

Rights / Prava: [In copyright / Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-05-21**



Repository / Repozitorij:

[FER Repository - University of Zagreb Faculty of Electrical Engineering and Computing repository](#)





Sveučilište u Zagrebu
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Boris Glavan

**METODOLOGIJA IZRAČUNA ZAJEDNIČKE
POGONSKE KARTE GRUPE PARALELNO
SPOJENIH GENERATORA**

DOKTORSKI RAD

Zagreb, 2022.



Sveučilište u Zagrebu
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Boris Glavan

**METODOLOGIJA IZRAČUNA ZAJEDNIČKE
POGONSKE KARTE GRUPE PARALELNO
SPOJENIH GENERATORA**

DOKTORSKI RAD

Mentor: Doc. dr. sc. Zlatko Hanić

Zagreb, 2022.



University of Zagreb

FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING

Boris Glavan

**CALCULATION METHODOLOGY OF COMMON
CAPABILITY DIAGRAM FOR PARALLELLY
CONNECTED GENERATOR GROUP**

DOCTORAL THESIS

Supervisor: Assistant Professor Zlatko Hanić, PhD

Zagreb, 2022

Doktorski rad izrađen je na Sveučilištu u Zagrebu Fakultetu elektrotehnike i računarstva,
na Zavodu za elektrostrojarstvo i automatizaciju.

Mentor: doc. dr. sc. Zlatko Hanić

Doktorski rad ima: 135 stranica

Doktorski rad br.: _____

O mentoru

Zlatko Hanić diplomirao je na Fakultetu elektrotehnike i računarstva na Sveučilištu u Zagrebu 2009. godine. Iste godine zapošljava se na Zavodu za elektrostrojarstvo i automatizaciju na Fakultetu elektrotehnike i računarstva na Sveučilištu u Zagrebu kao zavodski suradnik, a zatim kao asistent. Doktorirao je 2017. godine na istom fakultetu i sveučilištu te je za doktorski rad nagrađen srebrnom plaketom „Josip Lončar“. Na matičnom fakultetu i sveučilištu 2018. godine izabran je u znanstveno-nastavno zvanje docent. Njegovi stručni interesi uključuju analizu rada, dizajn, optimizaciju i matematičko modeliranje električnih strojeva te elektromehaničkih i elektromagnetskih uređaja. Osim što se trenutno bavi nastavnim radom te je nositelj na nekoliko predmeta na preddiplomskom i diplomskom studiju, sudjelovao je u realizaciji brojnih znanstvenih i stručnih projekata. Trenutno je voditelj IRI projekta pod nazivom *Razvoj inovativnog polifaznog elektromotornog pogona – PEP*.

Zlatko Hanić je autor ili koautor 12 radova u znanstvenim časopisima, 25 radova na znanstvenim konferencijama te 14 stručnih studija i elaborata. Član je stručne udruge IEEE.

About the Supervisor

Zlatko Hanić graduated from the Faculty of Electrical Engineering and Computing at the University of Zagreb in 2009. Same year, he was employed at the Department of Electric Machines, Drives and Automation at the Faculty of Electrical Engineering and Computing at the University of Zagreb as an associate and as a teaching assistant afterwards. He received his doctorate in 2017 from the same faculty and university and was awarded a silver plaque “Josip Lončar” for his doctoral dissertation. In 2018, he was promoted to assistant professor at the home faculty and university. His professional interests include performance analysis, design, optimization, and mathematical modelling of electrical machines as well as electromechanical and electromagnetic devices. He is a lecturer in several subjects at the undergraduate and graduate levels. Furthermore, he participated in the implementation of numerous scientific and professional projects. He is currently the leader of the IRI project entitled *Development of an innovative polyphase electric motor drive - PEP*.

Zlatko Hanić is the author or co-author of 12 papers in scientific journals, 25 papers at scientific conferences and 14 professional studies. He is a member of the IEEE.

Zahvala

Veliku zahvalnost, u prvom redu, dugujem svom mentoru doc. dr. sc. Zlatku Haniću i prethodnom mentoru prof. dr. sc. Mariu Vražiću na usmjeravanju, sugestijama, raspravama i konstruktivnim savjetima tijekom ovog doktorskog rada.

Mnogo je osoba svojim djelovanjem direktno ili indirektno u većoj ili manjoj mjeri pomoglo u oblikovanju ovog rada i teško se prisjetiti svih, stoga se unaprijed ispričavam što ih pojedinačno ne navodim, a svatko će se jako dobro prepoznati u tome. Želim se zahvaliti svojim kolegama u HE Vinodol koji su mi svojim razumijevanjem, strpljenjem i znatiželjnim diskusijama pomogli u mojem znanstvenom radu.

Zahvaljujem se svojim roditeljima na savjetima i mudrosti koje su mi dali. Najveće hvala mojoj supruzi i dječici na podršci, pomoći i radosti koju su mi pružili. Vedrana i Tomislave, fala van ča ste mi tako dobri, vi ste moja inspiracija.

Vedrani i Tomislavu, posvećujem

Sažetak

Električni strojevi projektiraju se optimirano s maksimalnim iskorištenjem materijala. Posljedica toga je radno područje stroja u nelinearnom području magnetske karakteristike željeza i velikim strujnim opterećenjima. U tom radnom području induktiviteti u stroju izrazito su promjenjivi s radnim točkama opterećenja stroja, te u takvim uvjetima određivanje granica dozvoljenog radnog područja velikih proizvodnih jedinica složen je problem. Prezentiran je niz postojećih objavljenih načina za izračun utjecaja nelinearnosti na odnose elektromagnetskih veličina u stroju. U traženju najjednostavnijeg i najefikasnijeg načina opisivanja stacionarnih radnih stanja sinkronih strojeva koji bi obuhvatio magnetsko zasićenje (magnetic saturation) i efekt poprečne magnetizacije (cross-magnetization effect), modeli sa strujno ovisnim funkcijama ulančenih tokova (u daljnjem tekstu $\Psi(I)$ funkcije) pokazali su se najpraktičnijima.

U slučaju opisivanja ulančenih tokova polinomnim $\Psi(I)$ funkcijama osnovna prednost u postavljanju modela je ta da se identifikacija koeficijenata složenog nelinearnog sustava svodi na rješavanje linearnog sustava jednadžbi. Jednom identificiran model nadalje se jednostavno koristi pomoću polinomnih $\Psi(I)$ funkcija u svim pogonskim stanjima na kojima je model identificiran. Međutim, u daljnjem testiranju polinomnih $\Psi(I)$ funkcija uočena je njihova nezgodna karakteristika s kojom znatno gube točnost odmah izvan područja u kojem su identificirane, premda su vrlo točne unutar tog područja.

Osnovni problem pri postavljanju modela stacionarnih stanja sinkronog generatora čija namjena bi bila izračunavanje granica pogonske karte je u tome što traženi model treba čim točnije opisivati ponašanje stroja u rubnom području oko granica pogonske karte i izvan dozvoljenog područja, a u tom području u praksi na velikim generatorima u komercijalnoj upotrebi nije dozvoljeno niti moguće napraviti mjerenja na kojima bi se taj model identificirao. Zbog registriranih nepovoljnih karakteristika polinomnih $\Psi(I)$ funkcija istaknuta je potreba za pronalaženjem takvog modela koji bi na osnovi poznatog ponašanja stroja u dozvoljenom području rada čim točnije opisivao ponašanje stroja u nedozvoljenom području rada, odnosno izvan granica pogonske karte. Prezentiran je model sigmoidnih $\Psi(I)$ funkcija, čiji oblik odgovara izgledu nelinearne krivulje magnetiziranja aktivnih dijelova sinkronog generatora, koja je odraz magnetskog zasićenja i drugih nelinearnih pojava, poput efekta poprečne magnetizacije. Takvom funkcijom omogućava se bolje predviđanje nelinearnih magnetskih pojava u stroju, izvan dozvoljenog područja u kojemu je model identificiran.. Greške ulančenih tokova izračunatih pomoću sigmoidnih $\Psi(I)$ funkcija uspoređene su s greškama izračuna pomoću polinomnih $\Psi(I)$ funkcija i pomoću klasičnog modela. Sigmoidne $\Psi(I)$ funkcije imaju značajno manje srednje i maksimalne greške, gledajući sumarno u cijelom području unutar i izvan zone dozvoljenog rada. Gledajući samo zonu dozvoljenog rada, odnosno zonu u kojoj su identificirane, polinomne $\Psi(I)$ funkcije imaju najveću točnost, bez velikih odstupanja u pojedinim radnim točkama, ali

izvan zone identifikacije znatno gube svoju točnost uz velika odstupanja među pojedinim radnim točkama. Sigmoidne $\Psi(I)$ funkcije omogućuju kvalitetan opis stroja u područjima dubokih zasićenja čak i u slučaju kada se identificiraju pomoću radnih točaka izvan područja zasićenja ili na njegovom rubnom dijelu. Prema navedenom, sigmoidne $\Psi(I)$ funkcije prikladne su za izračunavanje granica pogonske karte.

Izračunate su granice pogonske karte pomoću identificiranih sigmoidnih $\Psi(I)$ funkcija i uspoređene s granicama dobivenim pomoću polinomnih $\Psi(I)$ funkcija i pomoću klasičnog modela. Granice pogonske karte izračunate sigmoidnim $\Psi(I)$ funkcijama najbolje se poklapaju s granicama izračunatima pomoću referentnog FEM modela i opisuju znatno šire dozvoljeno radno područje od granica pogonske karte izračunatih klasičnim modelom, koji ne uzima u obzir magnetsko zasićenje stroja niti efekt poprečne magnetizacije. Granice pogonske karte izračunate polinomnim $\Psi(I)$ funkcijama u područjima izvan zona u kojima su te funkcije identificirane, gube svoj fizikalni smisao, na primjer na krivuljama konstantne struje uzbude odstupajući značajno od oblika sličnog Pascalovim krivuljama. Širi pogonski dijagram daje veće mogućnosti korištenja stroja, što je vrlo korisno operaterima proizvodnje i elektroenergetske mreže.

Zbog toga što se granice pogonske karte dinamički mijenjaju s radnim točkama stroja i zbog omogućavanja njihove implementacije u industrijsko programabilno sklopovlje sustava vođenja elektrane koje radi u stvarnom vremenu istaknuta je potreba za izražavanjem dinamičkih granica računalno nezahtjevnim funkcijama oblika $Q = f(U, P)$. U radu će biti predložene računalno nezahtjevne funkcije s oblikom ovisnim o kojoj se granici radi i identificirane rasterom točaka granica pogonske karte izračunatih sigmoidnim $\Psi(I)$ funkcijama. Takve funkcije nakon njihove identifikacije s granicama, mogu se implementirati u industrijsko programabilno sklopovlje sustava vođenja elektrane i u stvarnom vremenu efikasno dinamički izražavati granice pogonske karte, ovisno o pogonskim uvjetima.

Potreba istaknuta u [1] bit će ostvarena u sklopu ovog rada koji opisuje instalirani sustav za nadzor, identifikaciju i prikaz dinamičke pogonske karte. Pogonska karta u kombinaciji s modelom stacionarnih stanja generatora može imati svoju ulogu i u sustavu monitoringa, gdje bi se za pogonske točke unutar granica uspoređivanjem šireg seta parametara dobivenih mjerenjem i dobivenih iz validiranog modela, moglo dobivati rane informacije o poremećaju ili kvaru, što može spriječiti daljnje veće štetne posljedice.

U komponenti unaprijedne regulacije regulacije uzbude sinkronog generatora ključne veličine su struja uzbude I_f i kut opterećenja δ , koje bi trebale biti poznate za svaku željenu radnu točku u prostoru Q, P, U . Unaprijednom regulacijom postiže se veća brzina regulacije uz manji iznos oscilacija oko postavne vrijednosti. Zbog toga je istaknuta potreba za postavljanjem računalno nezahtjevnih funkcija kojima se u cijelom radnom području sinkronog generatora definiranom prostorom Q, P, U mogu izraziti struja uzbude I_f i kut opterećenja δ , koje bi bile

jednostavno primjenjive u programabilnom industrijskom sklopovlju regulatora uzbude. Opisane su polinomne računalno nezahtjevne funkcije te njihova identifikacija i validacija s gustim rasterom radnih točaka izračunatih modelom stacionarnih stanja sinkronog generatora baziranim na sigmoidnim $\Psi(I)$ funkcijama.

Budući da je u praksi uvijek zanimljiv trenutni prikaz mogućnosti isporuke djelatne i jalove snage elektrane s više generatora kao cjeline uz uvijek dobrodošlo optimiranje rada, za to je potrebno istražiti način određivanja zajedničke pogonske karte grupe paralelno spojenih generatora. Postavljena je metodologija prikaza zajedničke pogonske karte grupe paralelno spojenih sinkronih generatora. Prezentirana metodologija pokazala je da granice zajedničke pogonske karte grupe paralelno spojenih sinkronih generatora ovise o načinu raspoređivanja ukupne djelatne snage među pojedinim generatorima. Prikazani su načini raspoređivanja ukupne djelatne snage koji elektrani kao cjelini omogućavaju da pruži veći dozvoljeni raspon jalove snage za istu djelatnu snagu. U praksi, djelatna snaga po generatorima raspoređuje se po raznim principima, a granice zajedničke pogonske karte ovise o tom rasporedu. Među ostalima, principi raspoređivanja djelatne snage po pojedinim generatorima mogu biti utemeljeni na primjer na sekvencijalnom terećenju (generatori sekvencijalno jedan za drugim daju svoj doprinos u ukupnoj snazi), paralelnom terećenju (istovremeni raspored na jednake iznose) ili optimiranom radu.

U radu su $\Psi(I)$ funkcije potvrđene kao jednostavan i efikasan način opisivanja stacionarnih radnih stanja sinkronog generatora. Prezentiran je daljnji razvoj modela s polinomnih prema sigmoidnim $\Psi(I)$ funkcijama. Opisano je daljnje istraživanje primjene sigmoidnih $\Psi(I)$ funkcija kroz izračunavanje granica pogonske karte, postavljanje temelja za identifikaciju računalno nezahtjevnih funkcija za izračun struje uzbude i kuta opterećenja te za izračun granica pogonske karte. Prikazana je daljnja primjena računalno nezahtjevnih funkcija za izračun granica pogonske karte u svrhu postavljanja metodologije za izračun zajedničke pogonske karte grupe paralelno spojenih sinkronih generatora, sve u želji da prezentirane metode pronađu svoju praktičnu primjenu.

Ključne riječi: sinkroni generator, izračun stacionarnih stanja, matematičko modeliranje, pogonska karta, ulančeni tokovi, sigmoidne funkcije, računalno nezahtjevne funkcije

Abstract

Calculation Methodology of Common Capability Diagram for Parallely Connected Generator Group

In an electric power system, the most efficient and cost-effective way of voltage regulation is the one that provides corrective measures closest to the part of the network where the consumption is, i.e., the cause of voltage condition deterioration and where the deviations from the nominal voltage are significant. This way, the unnecessary flows of reactive power are reduced, which produces active losses, overwhelms the network, and thus reduces the transmission capacity for the primary line task, which is the transmission of active power. Therefore, in a classic strategy of the electric power system control, synchronous generators have been used as sources of active power, while the rest of the equipment, such as capacitor banks, thyristor-controlled capacitors (TSC), inductances (TSR), and synchronous compensators were used to produce reactive power and to regulate voltage in the network.

Due to their abundance and distributed arrangement in all parts of the network, the most appropriate solution is to use the existing production units for this purpose. Due to their capability of working in inductive and capacitive areas with continuous, quick, and precise regulation, they present the best solution for regulating voltage conditions in an electric power system. Historically, the purpose of a power plant was focused on producing active power, while the production of reactive power was not considered as a relevant option. Because of this, the operating points of the generator in real conditions could be kept conservatively in a safe area, far from the permitted reactive power border area. Synchronous generator manufacturers provide capability diagrams of generators with fixed limits based on calculated data from the classic vector-phaser diagram with constant reactances and are verified once as a part of warranty tests during machine handovers. Users of the units were not motivated to precisely determine safe limits by the reactive power coordinate, which considers complex electromagnetic effects in the machine that can be confirmed with measurements. Due to this, the possible generator production capacity was idle in large zones of the generator capability diagram, while it could safely be utilized and contribute to the stability of voltage conditions of the electric power system, avoiding voltage breakdown or reducing over-voltages.

Today's market of electric energy recognizes the regulation of reactive power and voltage as a valuable auxiliary service in which both transmission system operators and electric energy producers show financial interest. Reliable knowledge of the real capabilities of production units is of great importance in the area of engineering, while considering economic aspects is no less important, especially in the conditions of market competition. Capability diagrams of synchronous generators are a basic tool for their efficient management. Since the capability diagram is used to supervise the actual operating point and the limitations of the machine, it is

only correct to update its limits with the actual operating conditions of the machine and the part of the electric power system the machine is connected to. Some assessments show that with a capability diagram that has been verified and identified with measurements, the working range can be increased by 30 % in the capacitive area and up to 10 % in the inductive area on both existing and up to 40-year-old units. Significant financial resources can be more effectively used here instead of investing in new compensation assets.

Furthermore, a capability diagram that has been combined with a steady-state model can have a significant role in machine monitoring. Calculated and measured current operating points of an operating machine can be compared, which can show changes and indicate possible issues. Early discovery of any work disruptions and machine malfunctions is crucial for a timely reaction to avoid further damage and negative consequences. By comparing measured and modelled electromagnetic quantities in real-time and analyzing types and amounts of deviations, it is possible to discover a deviation and its source quickly and reliably.

Electric machines are designed to be optimized with maximum utilization of materials. As a consequence, this means that the operating area of the machine is in a nonlinear area of magnetic characteristics of iron and under a large current load. Under these conditions, the inductance of the unit is highly variable within the operating points of the machine load, and therefore determining limits of the permitted operating area in large production units is a complex issue. Multiple already existing published ways of calculating the effects of nonlinearity on electromagnetic quantities in a machine have been presented. While searching for the simplest and most efficient ways to describe steady-state operating conditions of synchronous machines that would envelop both magnetic saturation and the cross-magnetization effect, models that include current-dependent magnetic flux linkage functions (hereinafter referred to as $\Psi(I)$ functions) have been shown to be the most practical. When describing magnetic flux linkage by polynomial current dependent $\Psi(I)$ functions, the main advantage in setting up the model is that the identification of the coefficients of a complex nonlinear system is reduced to solving a linear system of equations. Once identified, the model is simply used by using polynomial $\Psi(I)$ functions in all operating conditions at which the model is identified. However, in further testing of polynomial $\Psi(I)$ functions, an inconvenient characteristic has been observed that they significantly lose accuracy immediately outside of the area in which they were identified, although they are correct within that area. Errors of the polynomial $\Psi(I)$ functions and of the classic model were calculated, and their comparison indicates that the polynomial $\Psi(I)$ functions, on average, give more accurate values than the classic model in the entire observed area, with better accuracy of 3 orders of magnitude. However, in the area beyond their identification, i.e., zones determined for model validation, polynomial $\Psi(I)$ functions give only 1,5 (direct axes) to 2,5 (quadrature axes) times more accurate average values, and the maximum error values are higher than of the classic model which is linear and does not include phenomena such as the

cross-magnetization effect, and in some cases, error values can be extremely high (e.g., 1,325 p.u.).

The main problem when setting a model for the steady-states of a synchronous generator, the purpose of which would be to calculate the limits of the capability diagram, is that the required model should describe the behavior of the machine as accurately as possible in the peripheral area around the capability diagram limits and outside the permitted area, and in that area, in practice on large generators in commercial use, it is not allowed or possible to make measurements to identify that model. This highlights the need to find such a model that, based on the known behavior of the machine in the permitted area of operation, would describe the behavior of the machine in the prohibited operating area, i.e., outside of the capability diagram limits, as accurately as possible. To model the steady-states of a synchronous generator, it is necessary to set up functions that follow the natural B-H curve of iron magnetization of active parts of the synchronous generator. Therefore, instead of expressing $\Psi(I)$ functions with polynomials, sigmoid functions were used, the shape of which corresponds to the appearance of a nonlinear curve of magnetization of the active parts of a synchronous generator, which is a reflection of magnetic saturation and other nonlinear phenomena, such as the cross-magnetization effect. Such a function enables us to better predict nonlinear magnetic phenomena in the machine outside of the permitted area in which the model is identified.

As part of model development, for its validation, it is necessary to know the electromagnetic conditions in operating points outside the zone of the permitted operating area. Since measurement of such points is not possible, the necessary data must be obtained by calculation, and to achieve consistency in model development to avoid discontinuities, it is important that the calculations for both sets, identification, and validation are applied the same way. The finite element method (FEM) is suitable for this kind of calculation and has been chosen as a reference in model development. This method was used to calculate the required operating points and individual limits of the capability diagram. It is important to emphasize that this calculation is not a procedure that would be carried out for each synchronous generator in the identification of a specific model but for the development of a common universal model for all synchronous generators, so the speed of the process is not important, but the highest possible accuracy certainly is.

Errors in linked magnetic flux calculated using sigmoid $\Psi(I)$ functions were compared with calculation errors obtained using polynomial $\Psi(I)$ functions and the classic model. Sigmoid $\Psi(I)$ functions have significantly smaller mean and maximum errors, observing, in summary, the entire area that includes both zones of identification and validation. Regarding only the zone in which they are identified, polynomial $\Psi(I)$ functions have the highest accuracy, without large deviations in individual operating points, but they significantly lose their accuracy outside the identification zone with large deviations between individual operating points. In conclu-

sion, these model error statistics confirm a good path in setting a stable model for describing steady-states, which would be identified based on a set of operating points in a narrower area of permitted operation, in which measurements are also available, while also describing electromagnetic phenomena of the machine at the capability diagram limits and beyond them, i.e., outside the zone of the permitted operating area. Sigmoid $\Psi(I)$ functions provide a high-quality description of the machine in deep saturation areas, even in the case when they are identified using operating points outside the saturation region or on its border. According to all of this, sigmoid $\Psi(I)$ functions are suitable for calculating the limits of the capability diagram.

Furthermore, capability diagram limits were calculated using the identified sigmoid $\Psi(I)$ functions and compared with the limits obtained using polynomial $\Psi(I)$ functions and the classic model. The capability diagram limits calculated with sigmoid $\Psi(I)$ functions best match with the limits that were calculated by using the reference FEM model, and they describe a much wider permitted operating area than the capability diagram limits calculated by the classic model, which does not take into account the magnetic saturation of the machine nor the cross-magnetization effect. Capability diagram limits calculated by polynomial $\Psi(I)$ functions in areas outside the zones where these functions were identified lose their physical meaning. For example, limits for the constant current of excitation, curves deviate significantly from the shape similar to Pascal curves. A wider capability diagram provides greater possibilities for machine utilization, which is very useful for production and power plant operators.

The previously described functions can be used to precisely calculate the operating points of a synchronous generator in three-dimensional space. Complex calculations consisting of a system of nonlinear equations and optimization algorithms are used in the process of determining the limits of the capability diagram. Such calculations are computationally time-consuming, which is why they are performed outside of real-time.

The capability diagram limits change dynamically with the operating points of the machine, and because of its continuous monitoring, it needs to be implemented in the industrial programmable hardware of the power plant's control system, such as programmable logic controllers (PLC) and supervisory control and data acquisition (SCADA) systems. The function of the mentioned system is managing the process in real-time, with it is not possible to perform complex computational optimization algorithms but simple mathematical operations, so the limits of the capability diagram need to be expressed with computationally efficient functions. The main idea is to first calculate, outside of real-time, an abundant and detailed set of capability diagram limit data for the entire operating voltage range at the terminals of the synchronous generator. Computationally efficient functions of the form $Q = f(U, P)$ were proposed, depending on which boundary is involved and identified by a raster of boundary points calculated by sigmoid $\Psi(I)$ functions. After identification of the capability diagram limits with computationally efficient functions, a comparison was made and established an almost complete match

with the limits with which they were identified, i.e., that the functions in question faithfully describe the original capability diagram limits. The model with sigmoid $\Psi(I)$ functions was used to calculate a large detailed group of capability diagram limits curves at all realistically expected voltages on the generator terminals so that computationally efficient functions express the capability diagram limits in the widest possible expected range of the operating area of the generator. Computationally efficient calculation of the capability diagram limits is carried out beforehand, outside of real-time, as well as the identification of computationally efficient functions. After their identification with the limits, computationally efficient functions can be implemented in the programmable industrial hardware of the power plant control system and, in real-time, efficiently and dynamically express the capability diagram limits, depending on operating conditions.

In the application of excitation regulation of a synchronous generator, the key quantities in the feed-forward regulation component are the excitation current I_f and the load angle δ , which should be known for each desired operating point in the space Q, P, U . A higher regulation speed with a smaller number of oscillations around the set value can be achieved using feed-forward regulation. For this reason, there is a need to set computationally efficient functions that can express the excitation current I_f and the load angle δ in the entire working area of the synchronous generator defined by the space Q, P, U , which is simple to apply in the programmable industrial hardware of the excitation regulator. Polynomial computationally efficient functions have been described, as well as their identification and validation with a dense set of steady-state operating points in the full range of the operating area, with completely defined electromagnetic quantities of a synchronous generator. The set for identification should have a larger number of operating points with coordinates Q and P in the permitted operating area of the synchronous generator and in the possible range of voltage values U on generator terminals in parallel operation on the electrical network. Such a comprehensive set of operating points is practically impossible to obtain by measurements on large synchronous generators in commercial operation due to the demands on the generator, the state of the power system, and the voltage conditions in the network. Therefore, a set of operating points for identification was obtained by using a synchronous generator steady-state model based on sigmoid $\Psi(I)$ functions.

The functions for expressing the excitation current and load angle are computationally efficient functions that are identified by practically the same method as the previously described computationally efficient functions for expressing the capability diagram limits of a synchronous generator. The possibility of implementing polynomial functions in industrial programmable hardware highlights computationally efficient functions as simple and effective for practical application. The described computationally efficient functions reliably describe the excitation current I_f and load angle δ in the space Q, P, U . Their maximum errors are up to 0,0135 p.u. for excitation current and 0,67 ° el. for the load angle confirm the stability of the functions and

their mean errors of 0,0036 p.u. for excitation current and $0,12^\circ$ el. for load angle, confirming their high precision.

In practice, it is always interesting to present the possibility of delivering the active and reactive power of a power plant with multiple generators as a whole. With the always-welcome optimization of operation, it is necessary to explore the way of determining the common capability diagram of a group of parallelly connected synchronous generators. A methodology that displays a common capability diagram of a group of parallelly connected synchronous generators has been presented. The presented methodology shows that the limits of a common capability diagram of a group of parallelly connected synchronous generators depend on the way of distributing the total active power among them.

In a plant with two or more generators, any given total active power can theoretically be distributed among the generators in an infinite number of combinations. In practice, the active power per generator is distributed according to various principles. Among others, the principles of distribution of active power by individual generators can be based, for example, on sequential loading (generators sequentially contribute to the total power one after the other), parallel loading (simultaneous distribution of equal amounts), or optimized operation according to various criteria.

The presented methodology has shown that the limits of a common capability diagram for a parallelly connected synchronous generator group depend on the way of arranging the total active power between each generator. Specific ways of allocating total active power have been described, one of which is calculated by the optimizing process with the goal of achieving the biggest width of the permitted operating area of the capability diagram. This optimized way results in the greatest width of limits of the common capability diagram. The second and third ways are parallel and sequential, where the sequential shows the weakest results because the limits of the common capability diagram are calculated to describe the narrowest permitted operating area. Ways of allocating total active power that enable an electric plant as a whole to provide a wider permitted range of reactive power for the same amount of active power were presented. The presented optimizing functions can also be combined with other goals, such as minimizing total losses, which is always an interesting objective for a power plant user.

In conclusion, $\Psi(I)$ functions were shown to be a simple and efficient way of describing the steady-state operating conditions of a synchronous generator. Further development of a model with polynomial to sigmoid $\Psi(I)$ functions has been described. Additional research of sigmoid $\Psi(I)$ functions has been described to calculate capability diagram limits, setting a foundation for the identification of computationally efficient functions that can be used to calculate excitation currents, load angle, and capability diagram limits. Further applications of computationally efficient functions to calculate capability diagram limits have been shown to achieve setting a methodology that can be used to calculate a common capability diagram for

parallelly connected synchronous generators, with the practical application being the ultimate goal.

This PhD thesis has been carried out at the University of Zagreb Faculty of Electrical Engineering and Computing at Department of Electric Machines, Drives and Automation.

Key words: synchronous generator, steady-state condition calculation, mathematical modelling, capability diagram, flux linkages, sigmoid functions, computationally efficient functions

Sadržaj

1. Uvod	1
1.1. Motivacija	.1
1.2. Izvorni znanstveni doprinos	.2
1.3. Struktura rada	.4
2. Postojeće spoznaje	6
2.1. Pregled spoznaja dostupnih u dosadašnjim radovima	.6
2.2. Teorijske podloge	.12
2.2.1. Dvoosni model sinkronog generatora	.12
2.2.2. Klasični model sinkronog generatora za stacionarna radna stanja	.17
2.2.3. Jedinični sustav veličina	.19
2.2.4. Tvorba pogonske karte pomoću klasičnog modela	.20
2.3. Polinomne $\Psi(I)$ funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora	.24
2.4. Identifikacija polinomnih $\Psi(I)$ funkcija	.26
2.5. Izračun granica u pogonskoj karti pomoću polinomnih $\Psi(I)$ funkcija	.29
2.5.1. Granice konstantne struje armature i djelatne snage	.29
2.5.2. Granica konstantne uzbude	.29
2.5.3. Statička granica stabilnosti	.30
2.5.4. Praktična granica stabilnosti	.32
2.6. Diferencijalna evolucija	.32
2.6.1. Inicijalizacija	.33
2.6.2. Mutacija	.34
2.6.3. Rekombinacija	.34
2.6.4. Selekcija	.35
2.6.5. Postupak izračuna	.35
3. Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora	37

3.1.	Izvod modela	37
3.2.	Određivanje granica pogonske karte sinkronog generatora	52
3.2.1.	Granice konstantne struje armature i djelatne snage	52
3.2.2.	Granice uzbudne struje	52
3.2.3.	Statička granica stabilnosti	56
3.2.4.	Praktična granica stabilnosti	60
3.2.5.	Pogonska karta	63
4.	Računalno nezahtjevne metode za prikaz granica pogonske karte sinkronog generatora	65
4.1.	Uvod	65
4.2.	Opis metode	66
4.2.1.	Granice praktične stabilnosti i maksimalne struje uzbude	66
4.2.2.	Granice minimalne struje uzbude	67
4.3.	Sustav za nadzor, identifikaciju i prikaz dinamičke pogonske karte implementiran u HE Vinodol	72
4.3.1.	Topologija sustava	72
4.3.2.	Nestandardna mjerenja i mogućnosti u sustavu za identifikaciju i prikaz dinamičke pogonske karte	76
4.3.3.	Mjereni podatci i identifikacija modela sinkronog generatora	79
5.	Metoda za određivanje uzbudne struje i kuta opterećenja sinkronog generatora kao $f(Q,P,U)$	83
5.1.	Uvod	83
5.2.	Opis metode	84
6.	Zajednička pogonska karta grupe paralelno spojenih generatora	96
6.1.	Uvod	96
6.2.	Opis metode	97
7.	Zaključak	106
8.	Dodatci	110
	Dodatak A	110
	Literatura	122
	Životopis	133
	Biography	135

Poglavlje 1

Uvod

1.1 Motivacija

Praktične mogućnosti pogonske karte sinkronog generatora u prošlosti su slabo korištene zbog toga što sudionici u elektroenergetskom sektoru uglavnom nisu bili zainteresirani za rad u širem radnom području generatora. U životnom vijeku sinkronog generatora prvi u kronološkom slijedu su njegovi proizvođači čiji interes je napraviti generator koji će ispuniti garantirane parametre i garantni period, a tijekom korištenja imati čim manje problema u radu, naravno sve to uz korištenje što povoljnijih materijala. Čim uže radno područje stroja ide k tome u prilog, a tvornička pogonska karta bila je izrađivana uglavnom na bazi klasičnog vektorsko-fazorskog dijagrama s konstantnim sinkronim reaktancijama. Sve je to bilo jednostavno ostvarivo budući da njihovi kupci, tj. proizvođači električne energije, nisu bili stimulirani za rad u širem području i uvijek su skloni konzervativnom korištenju u smislu čuvanja stroja radom u sigurnom području daleko od graničnog, izbjegavajući rizične načine rada, što se svodilo na nepotrebno restriktivnu i konzervativnu paradigmu. Na primjer, u poduzbuđenom dijelu pogonske karte proizvođač generatora klasičnim izračunom odredi teoretsku granicu stabilnosti iz koje proizlazi praktička granica stabilnosti (kod hidroagregata određivanjem jalove snage na istoj krivulji konstantne uzbude na kojoj je djelatna snaga od prekretnice umanjena za 0,1 p.u., a kod turboagregata uglavnom na fiksnih 70° kuta opterećenja), projektanti električnih zaštita odrede granice prorada zaštite uz dalju marginu sužavanja područja, projektanti uzbuđenog sustava odrede limite uzbude uz još daljnju marginu u odnosu na proradu zaštite, a korisnici naravno izbjegavaju približavati se limitima nadograđujući svoju daljnju marginu i svodeći se u svega 20-tak % ukupnog područja u njegovom kapacitivnom dijelu. Pogonska karta koja bi umjesto na bazi teoretskog izračuna, bila verificirana ispitivanjima u kojoj bi bile određene stvarne granice mogućnosti rada stroja i koja bi se prilagođavala trenutnim radnim uvjetima stroja i sustava pružala bi korisnicima punu sigurnost u korištenju cijelog radnog područja stroja.

Korisnici strojeva, kako proizvođači električne energije tako i operateri sustava (prijenosnog

ili distributivnog), danas u uvjetima tržišnog pružanja energetske usluge imaju interes koristiti strojeve u širem radnom području u reguliranju naponskih prilika u mreži s ciljem izbjegavanja previsokih napona ili naponskog sloma. Korigiranje naponskih prilika u mreži najefikasnije je raditi čim bliže zoni poremećaja, a time se izbjegavaju i nepotrebni tokovi jalovih snaga koji zagušuju mrežu i uzrokuju djelatne gubitke. Elektrane sa svojom brojnošću, distribuiranošću diljem mreže, te svojim regulacijskim svojstvima (raspon u oba smjera, kapacitivnom i induktivnom, brzina, kontinuiranost, točnost) predstavljaju tehnički najbolji način za reguliranje naponskih prilika, a uzevši u obzir da se u najvećem dijelu radi o postojećim i amortiziranim postrojenjima kojima nisu potrebne nikakve dogradnje, definitivno i najjeftiniji. U ovom radu cilj je prikazati tehničke mogućnosti ne zadirući dublje od osnovnih tržišnih i regulatornih postavki. Pogonska karta proizvođačima i dispečerima pruža detaljni vizualni pregled u trenutne mogućnosti stroja. U kombinaciji s modelom pogonska karta može imati svoju ulogu i u sustavu monitoringa agregata gdje bi se za pogonske točke unutar granica uspoređivanjem šireg seta parametara dobivenih mjerenjem i dobivenih iz validiranog modela, moglo dobivati rane informacije o poremećaju ili kvaru, što može spriječiti daljnje veće štetne posljedice.

Navedena problematika, potrebe i mogućnosti korištenja pogonske karte predstavljaju motivaciju za istraživanje novih metoda modeliranja i izračuna stacionarnih stanja sinkronih strojeva s uzbudnim namotom za što točniji i jednostavniji opis rada sinkronih strojeva u stacionarnom radu u svrhu određivanja njihovih stvarnih granica pogonske karte. Želja da takva pogonska karta bude prepoznata i u praktičnoj primjeni motiv je za traženje metoda izražavanja njenih granica na čim točniji, a pritom računalno nezahtjevan način. Također, u praksi uvijek zanimljiv je trenutni prikaz mogućnosti isporuke djelatne i jalove snage elektrane s više generatora kao cjeline uz uvijek dobrodošlo optimiranje rada, za što je potrebno istražiti način određivanja zajedničke pogonske karte grupe paralelno spojenih generatora. Svaka od navedenih cjelina predstavlja dio izvornog znanstvenog doprinosa rada.

1.2 Izvorni znanstveni doprinos

Izvorni znanstveni doprinos ovog doktorskog rada vezan je za nove pristupe u modeliranje stacionarnih stanja sinkronih strojeva s ciljem određivanja granica pogonske karte pojedinog kao i grupe paralelno spojenih generatora, te izražavanje granica pomoću računalno nezahtjevnih funkcija. Izvorni znanstveni doprinos je:

1. **Model sinkronog stroja za stacionarna stanja temeljen na sigmoidnim strujno ovisnim funkcijama ulančenih tokova te primjena modela na izračun granica pogonske karte**

U okviru ovog doprinosa postavljen je model sinkronog stroja sa strujno ovisnim funkcijama ulančenih tokova, u daljnjem tekstu $\Psi(I)$ funkcije, izraženim pomoću sigmoidnih

funkcija, njihova identifikacija, metoda za izračun ostalih stacionarnih radnih točaka te izračun granica u pogonskoj karti primjenom predloženog modela.

Funkcije $\Psi(I)$ predstavljaju funkcije ulančenog toka u direktnoj i poprečnoj osi koje su ovisne o struji armature u direktnoj i poprečnoj osi te o struji uzbude - $\Psi_d(I_d, I_q, I_f)$ i $\Psi_q(I_d, I_q, I_f)$. Funkcije $\Psi(I)$ moguće je odrediti na temelju skupa podataka dobivenih mjerenjem ili numeričkim izračunom za stacionarni rad sinkronog stroja. Pod pojmom skupa podataka misli se na četvorke $(I_{d,i}, I_{q,i}, I_{f,i}, \Psi_{d,i})$ i $(I_{d,i}, I_{q,i}, I_{f,i}, \Psi_{q,i})$ koji se mogu dobiti mjerenjem ili izračunom. Funkcije $\Psi(I)$ modelirane kao sigmoidne funkcije s varijablama I_d , I_q i I_f identificiraju se metodom najmanjih kvadrata u kombinaciji s heurističkim optimizacijskim algoritmima. Jednom kada se identificiraju i odrede $\Psi(I)$ funkcije moguće je izračunati ostale stacionarne radne točke primjenom predloženog modela. Opisano je i kako se predloženi model može primijeniti na izračun granica pogonske karte.

2. Računalno nezahtjevne metode visoke točnosti za određivanje uzbudne struje i kuta opterećenja te za prikaz granica pogonske karte sinkronog stroja s uračunatim magnetskim zasićenjem

U cijelom radnom području sinkronog generatora definiranom prostorom Q, P, U struju uzbude I_f i kut opterećenja δ moguće je definirati kao funkcije koje bi mogle biti primijenjene u regulatoru uzbude u sklopu komponente unaprijedne regulacije. U određivanju uzbudne struje i kuta opterećenja te granica pogonske karte sinkronog stroja pomoću sigmoidnih $\Psi(I)$ funkcija koriste se računski postupci koji koriste složene heurističke metode optimiranja i rješavanja sustava nelinearnih jednadžbi. Za praktičnu implementaciju u digitalne sustave vođenja elektrana u stvarnom vremenu prikladnije su računalno nezahtjevne metode pomoću polinomnih funkcija. Funkcije za izražavanje I_f i δ kao $f(Q, P, U)$ i za izražavanje granica pogonske karte kao $Q = f(P, U)$ identificiraju se na skupu stacionarnih radnih točaka s cjelovito definiranim elektromagnetskim veličinama sinkronog generatora. Skup za identifikaciju treba imati veći broj radnih točaka s koordinatama (Q, P, U) u dopuštenom radnom području sinkronog generatora i u mogućem rasponu vrijednosti napona U na stezaljkama generatora u paralelnom radu na električnoj mreži. Takav sveobuhvatan skup radnih točaka praktički je nemoguće dobiti mjerenjima na velikim sinkronim generatorima u komercijalnom radu zbog zahtjeva na generator, stanja elektroenergetskog sustava i naponskih prilika u mreži. Stoga je skup radnih točaka za identifikaciju dobiven pomoću modela stacionarnih stanja sinkronog generatora baziranog na modelu sigmoidnih $\Psi(I)$ funkcija, pri čemu su uzeti u obzir nelinearnost magnetske karakteristike stroja i ostale pojave kao što su npr. efekt poprečne magnetizacije.

3. Izračun zajedničke pogonske karte grupe paralelno spojenih generatora

Ovaj doprinos postavlja metodologiju izračuna granica zajedničke pogonske karte grupe

paralelno spojenih generatora. Granice zajedničke pogonske karte ovise o načinu raspoređivanja ukupne djelatne snage među pojedinim agregatima u elektrani, budući da se u pogonu s dva ili više generatora svaka ukupna djelatna snaga teoretski može rasporediti po generatorima u beskonačnom broju kombinacija. Među raznim principima raspoređivanja djelatne snage može se primijeniti optimiranje po raznim kriterijima. Ukoliko se napravi optimiranje s ciljem šireg radnog područja, dobiva se zajednička pogonska karta koja omogućava elektrani kao cjelini da pruži veći dozvoljeni raspon jalove snage za istu djelatnu snagu.

1.3 Struktura rada

Rad je strukturiran u 8 poglavlja.

Poglavlje 1. - Uvod

Ovo poglavlje opisuje motivaciju za razvoj metoda predloženih u ovom radu. Prikazan je i detaljno opisan izvorni znanstveni doprinos doktorskog rada kao i njegova struktura.

Poglavlje 2. - Postojeće spoznaje

U ovom poglavlju napravljen je pregled spoznaja skupljenih iz dosadašnjih istraživanja na području modeliranja sinkronih generatora, čiji put je vodio u smjeru znanstvenog doprinosa ovog rada. Budući da se često u radu referencira na klasični model, zbog osiguravanja potpunosti tematike obuhvaćen je izvod klasičnog modela za stacionarna stanja sinkronog stroja. Napravljen je pregled spoznaja dostupnih iz literature s dosadašnjim radovima za cjelokupnu tematiku ovog rada. Prikazana je dosad najrazvijenija metoda polinomnih $\Psi(I)$ funkcija ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora, na temelju koje je u ovom radu napravljen daljnji razvoj modela.

Poglavlje 3. - Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora

U poglavlju je prikazan detaljan izvod modela za opis stacionarnih stanja sinkronih strojeva temeljen na sigmoidnim $\Psi(I)$ funkcijama. Prikazano je kako je moguće identificirati $\Psi(I)$ funkcije pomoću metode najmanjih kvadrata u kombinaciji s heurističkim optimizacijskim algoritmima. Nadalje, pokazano je kako se pomoću sigmoidnih $\Psi(I)$ funkcija mogu izračunati bilo koje druge radne točke u stacionarnom stanju. Također je izvedeno kako se mogu izračunati granice u pogonskoj karti pomoću sigmoidnih $\Psi(I)$ funkcija. Napravljena je usporedba rezultata klasičnog modela, polinomnih i sigmoidnih $\Psi(I)$ funkcija.

Poglavlje 4. - Računalno nezahtjevne metode za prikaz granica pogonske karte sinkronog generatora

U ovom poglavlju obrađene su računalno nezahtjevne metode za određivanje stacionarnih radnih stanja sinkronog generatora. Opisani su postavljanje, identifikacija, i validacija metoda.

Prikazana je primjena računalno nezahtjevnih metoda za prikaz granica pogonske karte sinkronog generatora. Prezentiran je sustav instaliran u HE Vinodol u kojemu su primijenjene računalno nezahtjevnije metode za određivanje stacionarnih radnih stanja i granica dinamičke pogonske karte sinkronog generatora.

Poglavlje 5. - Metoda za određivanje uzbudne struje i kuta opterećenja sinkronog generatora kao $f(Q, P, U)$

U ovom poglavlju opisana je metoda za postavljanje i identifikaciju računalno nezahtjevnih funkcija za izražavanje struje uzbude i kuta opterećenja sinkronog generatora. Iste funkcije provjerene su i u prijelaznim stanjima sinkronog generatora.

Poglavlje 6. - Zajednička pogonska karta grupe paralelno spojenih generatora

U ovom poglavlju opisana je metodologija izračuna granica zajedničke pogonske karte grupe paralelno spojenih generatora. Prikazana je primjena metodologije na primjerima hidroelektrane s tri identična i tri različita hidrogregata i to za slučajeve različitih principa rasporeda djelatne snage među njima.

Poglavlje 7. - Zaključak

U zaključku je dan kratak pregled cijelog doktorskog rada te su izneseni zaključci. Na kraju je dan prijedlog za buduća istraživanja.

Poglavlje 8. - Dodatci

U ovom poglavlju prikazane su radne točke na kojima je model stacionarnih pojava sinkronog generatora identificiran i validiran.

Poglavlje 2

Postojeće spoznaje

2.1 Pregled spoznaja dostupnih u dosadašnjim radovima

Pogonske karte sinkronih generatora bazni su alat za efikasno vođenje elektroenergetskog sustava. U standardnoj strategiji vođenja elektroenergetskog sustava sinkroni generatori koriste se kao izvori djelatne snage, a ostala oprema kao kondenzatorske baterije, tiristorski upravljani kondenzatori (TSC), induktiviteti (TSR) i sinkroni kompenzatori korišteni su za proizvodnju jalove snage i regulaciju napona u mreži.

Povijesno, uloga elektrana bila je fokusirana na proizvodnju djelatne energije [2], pri čemu proizvodnja jalove energije nije bila razmatrana kao bitna opcija. Stoga su se u realnim pogonskim uvjetima radne točke generatora mogle držati konzervativno u sigurnom području, daleko od granica mogućeg rada po jalovoj snazi, a stvarno korišteno ograničenje bilo je po djelatnoj snazi pogonskog stroja, koja se je naravno nalazila unutar maksimalne prividne snage generatora. Proizvođači stroja daju pogonske karte generatora s fiksnim granicama, zasnovane na računskim podacima klasičnog vektorsko-fazorskog dijagrama s konstantnim reaktancijama [3] i verificirane jednokratno u sklopu garantnih ispitivanja prilikom primopredaje stroja [4]. Korisnici stroja time nisu bili niti motivirani za preciznije određivanje sigurnih granica po koordinati jalove snage, koje uzimaju u obzir složene elektromagnetske efekte u stroju i koje su potvrđene mjerenjima. Na taj način mogući proizvodni kapaciteti generatora bili su neiskorišteni [5, 6, 7] u velikim zonama pogonske karte generatora u kojima mogu sigurno raditi i puno doprinijeti stabilnosti naponskih prilika elektroenergetskog sustava, izbjegavanju naponskog sloma ili smanjivanju previsokih napona [8]. U elektroenergetskom sustavu najefikasniji i najekonomičniji način reguliranja naponskih prilika je onaj koji pruža korektivne mjere čim bliže dijelu mreže gdje je potrošnja [2, 9], tj. uzrok pogoršavanja naponskih prilika i u kojem su najveća odstupanja od regularnih napona, čime se smanjuju nepotrebni tokovi jalove snage koji proizvode djelatne gubitke, zagušuju mrežu i time smanjuju prijenosne kapacitete vodova za osnovnu zadaću, a to je prijenos djelatne snage. Svojom brojnošću i distribuiranim razmještajem u

svim dijelovima mreže najprikladnije za tu namjenu su postojeće proizvodne jedinice, a uzimanjem u obzir njihove mogućnosti rada u induktivnom i kapacitivnom području s kontinuiranom, brzom i preciznom regulacijom, predstavljaju najbolje rješenje za reguliranje naponskih prilika u elektroenergetskom sustavu [10]. Tržište električne energije prepoznaje regulaciju jalove snage i napona proizvodnih jedinica kao pomoćnu uslugu koja se vrednuje [11], pa operateri prijenosnog sustava i proizvođači nalaze svoj interes, čime im pogonska karta postaje neophodan alat [12]. Pouzdana spoznaja o stvarnim mogućnostima proizvodnih jedinica od vitalne je važnosti naravno u sferi tehnike, ali ništa manje važno nije niti s ekonomskog aspekta, posebice u uvjetima tržišnog natjecanja. Budući da pogonska karta služi za nadzor aktualne radne točke i mogućnosti stroja, jedino je ispravno da i njene granice budu aktualizirane s trenutnim radnim stanjem stroja i dijelova elektroenergetskog sustava na koji je priključen [6, 13] i takva se karta naziva dinamička pogonska karta. Nadalje, u kombinaciji sa stacionarnim modelom pogonska karta može imati značajnu ulogu i u sklopu sustava monitoringa stroja, na taj način da se za aktualne radne točke usporedbom izmjerenih s izračunatima modelom validiranim na stroju u njegovu ispravnom stanju može rano uočiti promjene, koje na vrijeme mogu ukazati na probleme. Rano otkrivanje poremećaja u radu i kvarova stroja vrlo je bitno za pravovremenu reakciju u izbjegavanju većih šteta i širih posljedica. U toj funkciji sustav monitoringa predstavlja snažan alat [14, 15]. Usporedbom elektromagnetskih mjerenih i modeliranih veličina u realnom vremenu u radnom području pogonske karte te ekspertnom analizom vrste i iznosa odstupanja može se na brz i pouzdan način registrirati poremećaj ili kvar te njihov uzrok. Uključivanje dinamičke pogonske karte u postojeći sustav upravljanja i monitoringa elektrane relativno je jednostavan i jeftin zahvat, a vizualizacija u realnom vremenu pruža detaljan uvid u trenutnu radnu točku i stanje stroja. Neke procjene ukazuju da se dinamičkom pogonskom kartom može radno područje povećati do 30 % u kapacitivnom dijelu i do 10 % u induktivnom dijelu [7]. Znatna investicijska financijska sredstva mogu biti korisnije upotrijebljena umjesto u investiranje u nove kompenzacijske kapacitete, kao što je to na primjeru [2] prikazano da su na postojećim proizvodnim pogonima u jednom proizvodnom području u praksi ukupni kapaciteti rada s jalovom snagom povećani za 54 % povećanjem granica radnih područja agregata do realno mogućih, čak i na do 40 godina starim agregatima. Razlozi za precizniji izračun granica pogonske karte i implementaciju dinamičke korisničke pogonske karte u nadzorni sustav elektrane mogu se sistematizirati prema sljedećem:

1. Sinkrone reaktancije stroja nisu jednake u svim radnim točkama zbog magnetskog zasićenja stroja i efekta poprečne magnetizacije [5, 6, 13, 16, 17, 18].
2. Napon mreže nije fiksna te doživljava dnevne i sezonske promjene [9].
3. Nadomjesna shema elektroenergetskog sustava ima nezanemarivu nadomjesnu reaktanciju [7], koja nije fiksna i također doživljava dnevne i sezonske promjene, a utječe na napon generatora. Radna točka stroja utječe na naponske prilike u elektroenergetskom

- sustavu, što povratno utječe na granice pogonske karte. Također, kroz godine kontinuiranog razvoja elektroenergetskog sustava mijenja se i njegova shema [3, 19], tako da izgradnjom postaje krući.
4. Granice pogonske karte svakog sinkronog generatora trebaju biti uspoređene s limitima rada u poduzbuđenom stanju zbog pregrijavanja u čeonom prostoru. Kako bi se ispravno odredilo koji limit treba određivati pravo ograničenje dozvoljenog radnog područja u poduzbuđenom dijelu, potrebno je čim točnije odrediti praktičnu granicu stabilnosti [1, 12, 20, 21, 22, 23].
 5. Starenjem stroja mijenjaju se njegove osobine [10], mehaničke (npr. zagušenje protočnog dijela rashladnog sustava zbog kamenca i sedimenta, smanjena moć prijenosa topline na rashladni medij zbog oksidacije bakra i željeza i sl.) i električke (npr. slabljenje izolacije namota, oštećenje izolacije među limovima statorskog paketa, njegova zagrijavanja i sl.).
 6. Promjena osobina stroja zbog kvarnog stanja na koje ne reagiraju zaštite (npr. međuzavojni spoj u uzbuđnom namotu [3, 18], kvar na mjernim ili izvršnim članovima sustava regulacije hlađenja i sl.).
 7. Promjena pogonskih uvjeta u sustavu hlađenja agregata (sezonska znatna oscilacija temperature rashladnog medija iz prirodnog recipijenta, kontrolirana promjena u regulaciji tlaka i protoka rashladnog medija, npr. tlaka H_2 u turbogeneratorima [3] i sl.).
 8. Vlasnicima agregata u komercijalnoj upotrebi skupa je i potencijalno opasna svaka neraspoloživost agregata zbog ugovorenih usluga elektroenergetskom sustavu i uloge hidroagregata u reguliranju i zaštiti od štetnog djelovanja vodotoka. Zbog toga je vrlo teško [3], a za veće jedinice gotovo nemoguće organizirati i provesti ispitivanja snimanjem brojnih točaka unutar cijelog radnog područja s ciljem identifikacije modela stroja. Kontinuiranim mjerenjem u sklopu sustava dinamičke pogonske karte kroz duži vremenski period moguće je prikupiti dovoljan broj radnih točaka unutar cijelog radnog područja za preciznu identifikaciju modela. Nakon što u odnosu na svaka daljnja mjerenja u realnim pogonskim uvjetima model zadovoljava željenu točnost, može se smatrati validiranim te se s visokom dozom pouzdanosti može koristiti za dobivanje granica pogonske karte, koje općenito nisu fiksne. Osoblju elektrane koje uvijek nastoji držati parametre stroja u provjereno sigurnim granicama [2] daje se sigurnost u korištenju šireg radnog područja.
 9. U sustavu monitoringa agregata, pogonska karta kontinuiranom usporedbom mjerenih veličina s odgovarajućim istim veličinama izračunatima pomoću modela validiranog na stroju u njegovu ispravnom stanju, u slučaju pojave značajnijeg odstupanja, može rano ukazati na poremećaj u radu stroja ili nastanak kvara.
 10. Edukacija je bitan faktor kojeg omogućava dinamička pogonska karta, na kojoj pogonsko osoblje vizualno može bolje razumijevati i učiti ponašanje granica dozvoljenog područja ovisno o raznim ulaznim parametrima, što se modelom može dobiti [24, 25].

U dosadašnjim istraživanjima razvijen je velik broj modela koji su dinamički te uz modeliranje i analizu sinkronih strojeva kao dijelova elektromehaničkih sustava ili regulaciju uzbudne struje [26, 27, 28, 29, 30] često su korišteni za određivanje stabilnosti sinkronih generatora na elektroenergetskoj mreži [31, 32, 33, 34]. Ti modeli mogu se podijeliti na one koji bazirani na dvoosnoj teoriji električnih strojeva [16, 17, 30, 35, 36, 37, 38, 39, 40, 41, 42, 43, 44, 45, 46, 47, 48], i na one kojima je težište elektroenergetski sustav za kojeg je prikladniji *abc* sustav [49, 50], a pritom svaki ima svoje specifičnosti, razvijen je s određenom namjenom i ima svoje prednosti i nedostatke [18]. Modeliranje stroja s analitičkim izrazima temeljenima na klasičnom vektorsko-fazorskom dijagramu s konstantnim sinkronim reaktancijama [24, 51] opisuje radna stanja stroja ne uzimajući u obzir složene nelinearne pojave magnetskog zasićenja i efekta poprečne magnetizacije, pa time ovisno o dijelovima radnog područja dolazi do manjih ili većih odstupanja od realnih radnih veličina.

U modernom projektiranju električnih strojeva nastoji se što bolje iskoristiti materijale, što rezultira s većim specifičnim opterećenjima, većim razinama magnetskog zasićenja i većim strujnim opterećenjima strojeva. U takvim uvjetima induktiviteti se mijenjaju s radnim točkama, odnosno s razinom opterećenja električnih strojeva [52, 53, 54, 55, 56]. Za kvalitetan opis rada u stacionarnim i dinamičkim stanjima električnog stroja potrebno je uzeti u obzir promjenjive induktivitete. Magnetsko zasićenje dolazi do izražaja u naduzbuđenom (desnom) dijelu pogonske karte, utjecaj napona mreže izrazitiji je u poduzbuđenom (lijevom) dijelu pogonske karte. Što je veći teret (bez obzira djelatni ili jalovi) tim je veći utjecaj efekta poprečne magnetizacije, koji je uzet u obzir u pojedinim razvijenim modelima [36, 37, 57, 58, 59, 60, 61]. Numerički izračuni uzimaju u obzir promjenjive induktivitete zbog magnetskog zasićenja, međutim njihovo identificiranje i mjerenje u praksi nije lagan zadatak. U tom smislu, napravljena su modeliranja koja opisuju promjenjivost sinkronih reaktancija [16] ili induktiviteta [62], čime obuhvaćaju složene pojave u stroju, ali su složena i računski zahtjevnija, a pritom treba paziti o kojim se induktivitetima radi, o statičkim ili dinamičkim [18], što općenito autori rijetko naglašavaju. Zanimljiv pristup prezentiran je u [16, 17, 40], gdje se identifikacija dinamičkog modela sinkronog generatora temelji na mjerenjima stacionarnih radnih točaka u radu na električnoj mreži. Posebnu grupu modela u *abc* sustavu predstavljaju *Napon iza reaktancije* (*Voltage behind reactance*) modeli [42, 43, 44, 45, 46, 47, 48, 50], koji su prikladniji za modeliranje sinkronog generatora kao dijela elektroenergetskog sustava. Neki modeli su čisto matematički, na principu crne kutije bez fizikalne podloge [26, 27, 28, 41, 63, 64, 65, 66, 67, 68, 69, 70]. Njihova namjena je modeliranje odnosa ulaznih i izlaznih veličina na ispravan način, ali često nisu prikladni u primjenama drugačijim od usko onih za koje su razvijeni.

Stroj se vrlo precizno može modelirati pomoću metode konačnih elemenata, koja je složena i računski zahtjevnija, pa time nije primjenjiva u sustavu vođenja i nadzora elektrane, koji radi u

stvarnom vremenu.

Manji broj modela odnosi se na modele stacionarnih stanja sinkronih strojeva [5, 12, 71, 72, 73, 74, 75, 76, 77]. Jedna od primjena modela stacionarnih stanja sinkronog stroja može biti određivanje granica pogonske karte. Relativno je mali broj modela koji opisuje stacionarna stanja sinkronih generatora s glavnom primjenom u tvorbi pogonske karte [6, 12, 78, 79]. Zbog magnetskog zasićenja, efekta poprečne magnetizacije, napona armature, granice pogonske karte mijenjaju se u stvarnom vremenu. Pogonski dijagram s promjenjivim granicama analiziran je u [5, 12, 62, 76, 77, 80, 81]. Među razvijenim sustavima nadzora stanja sinkronih generatora [5, 6, 82, 83], u literaturi [84] opisan je sustav dinamičke pogonske karte koji ima opciju prikupljanja i obrade rezultata mjerenja s ciljem identifikacije granica pogonskih karata više generatora u elektrani.

Na tragu postavljenog zadatka odabira najprikladnijeg modela je pristup kojim se model identificira na temelju stacionarnih radnih točaka [16, 17, 85]. Takav model obuhvaća složene nelinearne pojave magnetskog zasićenja i efekta poprečne magnetizacije, a da pritom nije računski zahtjevan, već brz i pouzdan. Relativno jednostavno modeliranje koje nije računski zahtjevno analitički definira granice pogonske karte pomoću direktne funkcije $Q=f(P,U)$ izražene polinomom drugog stupnja, identificiranim metodom najmanjih kvadrata na osnovi eksperimentalnih mjerenja [13], međutim ne obuhvaća sve parametre potrebne za detaljan opis radnih točaka na granicama, kao niti unutar radnog područja.

Model s $\Psi(I)$ funkcijama opisuje stacionarna stanja sinkronog generatora uzimajući u obzir nelinearne pojave magnetskog zasićenja i efekta poprečne magnetizacije [18, 79]. Funkcije ulančenih tokova u d i q osi mogu se definirati s polinomnim funkcijama ovisnim o tri varijable - strujama armature u uzdužnoj i poprečnoj osi i uzbudnoj struji (I_d , I_q i I_f). Koeficijenti polinomnih funkcija identificiraju se tako da te funkcije interpoliraju eksperimentalne mjerne točke metodom najmanjih kvadrata. Problem identifikacije modela sveden je na rješavanje linearnog sustava jednadžbi. Relativno jednostavnim modelom, koji se umjesto 6 funkcija induktiviteta svodi na dvije funkcije ulančenih tokova ovisne o tri iste varijable, postiže se opisivanje složenih nelinearnih pojava sinkronog stroja u stacionarni stanjima. S jednom identificiranim funkcijama moguće je određivati sve bitne elektromagnetske veličine proizvoljnih radnih točaka stroja, kao i granice pogonske karte. Zbog svoje efikasnosti i jednostavnosti navedena metoda je u ovom radu prikazana i korištena kao korak u daljnjem razvoju metoda za određivanje granica i radnih točaka na pogonskoj karti sinkronog generatora. U sklopu sustava dinamičke pogonske karte provode se trajna mjerenja standardnih i nestandardnih veličina za identifikaciju, validaciju modela i monitoring stanja stroja. Daljnji razvoj sustava dinamičke pogonske karte mogao bi ići u smjeru objedinjavanja zajedničke pogonske karte generatora i pripadajućih blok-transformatora [86, 87] za cijelu elektranu koja se sastoji od više agregata, što je pogotovo zanimljivo operateru prijenosnog sustava, koji elektranu promatra kao cjelinu.

U daljnjem razvoju metoda modeliranja stacionarnih stanja i određivanja granica pogonskih karti sinkronih generatora korišteni su postupci globalne optimizacije. Globalna optimizacija potrebna je u raznim poljima, kao što su inženjerstvo, financije i statistika. U praksi mnogi problemi imaju funkcije cilja koje nisu linearne, predvidljive, kontinuirane niti diferencijalne. Skoro u pravilu takve funkcije su višedimenzionalne, s mnogo lokalnih ekstrema i ograničenja i dodatno još imaju šumove. Analitičko rješavanje takvih problema je teško ili nemoguće. Posljednjih desetljeća uvođenje stohastičkih optimizacijskih algoritama imalo je utjecaj na različita područja istraživanja i značajan doprinos u razvoju novih načina rješavanja problema u industrijskim procesima. Među takvim algoritmima evolucijski algoritmi (EA) postigli su najširu primjenu zahvaljujući svojoj osobini koja ih svrstava u globalne optimizatore [88, 89, 90, 91]. EA su se pokazali efikasnim u rješavanju složenih optimizacijskih problema usprkos svojoj jednostavnoj primjeni s malim brojem upravljačkih parametara. Glavni limitirajući nedostatak male brzine konvergencije ublažen je mogućnostima današnjih osobnih računala s paralelnim procesiranjem.

Premda se je dosta pažnje posvetilo ostalim EA (npr. Realno-kodiranom genetičkom algoritmu (RGA) [92], Optimizatoru primjenom roja čestica (PSO – Particle Swarm Optimizer) [93, 94]), recentnija DE uspješno je korištena i potvrđena u velikom broju istraživačkih radova generalno u optimiranju, kao i u polju elektromagnetizma [90]. Diferencijalna evolucija (DE) je heuristički optimizacijski populacijski evolucijski algoritam koji su razvili Storn i Price 1995. godine [95] za traženje globalnog optimuma kontinuiranih funkcija s realnim varijablama u multidimenzionalnim prostorima. Poput genetskih algoritama, DE je modeliran na natjecateljskom mehanizmu prirodnog selekcijskog pritiska proučavanog od Darwina i uspješno primijenjenog od Hollanda 96 na rješavanju problema koji nisu u prirodi. Premda mehanizam DE koristi iste evolucijske operatore kao genetički algoritmi, algoritam se izvršava drugačijim redoslijedom. Nasuprot genetičkom algoritmu, mutacija i rekombinacija modificiraju vektore parametara prije selekcije. Destrukcijski efekt mutacije se izbjegava, jer se ona provodi na početku svake generacijske petlje. Vrijednosti funkcije cilja mijenjaju se monotonno, budući da se natjecanje između roditelja i djece, tj. selekcija provodi nakon rekombinacije. Također je osigurano efikasno uzorkovanje u prostoru rješenja jer se cijela populacija probnih rješenja koristi kao bazen parenja, bez davanja prednosti individualnim vektorima s najboljom vrijednošću funkcije cilja i mutirani vektori dobivaju se od drugih slučajno odabranih vektora iz populacije. Osnovna razlika DE u odnosu na EA nalazi se u mutaciji, koja kod EA djeluje na samo jedan vektor, za razliku od DE, gdje djeluje na sve vektore u populaciji. DE se može koristiti u službi identifikacije parametara složenih sustava [97, 98], čija efikasnost u toj primjeni je uspoređena s genetičkim algoritmima [99].

2.2 Teorijske podloge

2.2.1 Dvoosni model sinkronog generatora

Zbog sveobuhvatnog pregleda problematike na početku je razrađen klasični dinamički model sinkronog generatora, iz kojega proizlazi model za opis stacionarnih stanja sinkronog stroja [100]. Sinkroni generator ima višefazni, uglavnom trofazni armaturni namot na statoru, uzbudni namot na rotoru, čija os polova i magnetizacije definira direktnu os (d os). Poprečna os (q os) pomaknuta je za električkih 90° u odnosu na d os i u generatorskom referentnom sustavu zaostaje za d osi, kao što je to vidljivo na slici 2.1a. Na rotoru se još također može nalaziti i prigušni namot (ili prigušni kavez), koji u dinamičkim stanjima djeluje u d i q osi. U dinamičkom modelu stroja često se modelira kao po jedan ili dva ekvivalentna kratko spojena namota u d i q osi smještena na rotoru (slika 2.1a). Također, pomoću kratko spojenih ekvivalentnih namota na rotoru također se mogu nadomještati i vrtložne struje koje u prijelaznim pojavama nastaju u električki vodljivim polovima rotora.

Ulančeni tok fazorski gledajući prethodi induciranom naponu, pri čemu su povezani u skladu Faraday-Lenz-ovim zakonom $E = -d\Psi/dt$. Predznaci napona na namotima definirani su logikom aktivnog izvora, protjecanjem struje kroz njega u smjeru od nižeg prema višem potencijalu. Sukladno navedenome i prikazanom na slikama 2.1a i 2.1b, naponska jednadžba namota sinkronog generatora matrično iskazana ima oblik

$$\mathbf{U} = -\mathbf{R}\mathbf{I} - \frac{d\Psi(\gamma)}{dt} \quad (2.1)$$

gdje je $\mathbf{U}$ vektor napona narinutog na stezaljkama generatora

$$\mathbf{U} = \begin{bmatrix} U_a & U_b & U_c & U_f & 0 & 0 \end{bmatrix}^T \quad (2.2)$$


$\mathbf{I}$ je vektor struje

$$\mathbf{I} = \begin{bmatrix} I_a & I_b & I_c & I_f & I_D & I_Q \end{bmatrix}^T \quad (2.3)$$

$\mathbf{R}$ je dijagonalna matrica otpora pojedinih namota

$$\mathbf{R} = \text{diag} \begin{bmatrix} R_a & R_b & R_c & R_f & R_D & R_Q \end{bmatrix} \quad (2.4)$$

i $\Psi(\gamma)$ je simetrična matrica ulančenih tokova pojedinih namota koja je ovisna o položaju rotora,



Slika 2.1: Prikaz namota i definiranje koordinatnih osi te smjera napona sinkronog generatora

odnosno o kutu γ

$$\Psi(\gamma) = \begin{bmatrix} \Psi_{aa}(\gamma) & \Psi_{ab}(\gamma) & \Psi_{ac}(\gamma) & \Psi_{af}(\gamma) & \Psi_{aD}(\gamma) & \Psi_{aQ}(\gamma) \\ \Psi_{ab}(\gamma) & \Psi_{bb}(\gamma) & \Psi_{bc}(\gamma) & \Psi_{bf}(\gamma) & \Psi_{bD}(\gamma) & \Psi_{bQ}(\gamma) \\ \Psi_{ac}(\gamma) & \Psi_{bc}(\gamma) & \Psi_{cc}(\gamma) & \Psi_{cf}(\gamma) & \Psi_{cD}(\gamma) & \Psi_{cQ}(\gamma) \\ \Psi_{af}(\gamma) & \Psi_{bf}(\gamma) & \Psi_{cf}(\gamma) & \Psi_{ff} & \Psi_{fD} & 0 \\ \Psi_{aD}(\gamma) & \Psi_{bD}(\gamma) & \Psi_{cD}(\gamma) & \Psi_{fD} & \Psi_{DD} & 0 \\ \Psi_{aQ}(\gamma) & \Psi_{bQ}(\gamma) & \Psi_{cQ}(\gamma) & 0 & 0 & \Psi_{QQ} \end{bmatrix} \quad (2.5)$$

gdje su a, b, c, f, D i Q indeksi koji označavaju redom faze a, b i c , uzbudni namot, prigušne namote u d i q osi, a kut γ predstavlja položaj rotora, odnosno električni kut između magnetske osi uzbudnog namota i magnetske osi faze a .

Otpori faza a, b i c u praksi dovoljno se malo razlikuju da se mogu smatrati jednakima i označiti samo s R , tako da izraz (2.4) može glasiti prema sljedećem

$$\mathbf{R} = \text{diag} \begin{bmatrix} R & R & R & R_f & R_D & R_Q \end{bmatrix} \quad (2.6)$$

Klasična teorija utemeljena je na pretpostavkama linearnosti materijala, konstantnih induktiviteta u stroju, odnosno proporcionalnosti ulančenog toka sa strujom, jer je induktivitet kons-

tanta proporcionalnosti između ulančenog toka i struje i može se izraziti kao $\Psi = LI$. Shodno navedenom, naponska matrična jednažba (2.1) može se izraziti pomoću induktiviteta

$$\begin{aligned} \mathbf{U} &= -\mathbf{RI} - \frac{d\Psi(\gamma)}{dt} = -\mathbf{RI} - \frac{d}{dt}(\mathbf{L}(\gamma)\mathbf{I}) = -\mathbf{RI} - \frac{d\gamma}{dt} \frac{d\mathbf{L}(\gamma)}{d\gamma} \mathbf{I} - \mathbf{L}(\gamma) \frac{d\mathbf{I}}{dt} \\ \mathbf{U} &= -\mathbf{RI} - \omega \frac{d\mathbf{L}(\gamma)}{d\gamma} \mathbf{I} - \mathbf{L}(\gamma) \frac{d\mathbf{I}}{dt} \end{aligned} \quad (2.7)$$

gdje je $\omega = d\gamma/dt$ električna kutna brzina rotora. Matrica induktiviteta $\mathbf{L}(\gamma)$ simetrična je i ovisna o položaju rotora te ima oblik

$$\mathbf{L}(\gamma) = \begin{bmatrix} \mathbf{L}_s(\gamma) & \mathbf{L}_{sr}(\gamma) \\ \mathbf{L}_{sr}^T(\gamma) & \mathbf{L}_r \end{bmatrix} \quad (2.8)$$

u kojoj su $\mathbf{L}_s(\gamma)$, $\mathbf{L}_r$ i $\mathbf{L}_{sr}(\gamma)$ simetrične submatrice induktiviteta statoskih namota, rotorskih namota i nesimetrična matrica međuinduktiviteta između namota na statoru i namota na rotoru.

Raspisana matrica $\mathbf{L}_s(\gamma)$ glasi:

$$\mathbf{L}_s(\gamma) = \begin{bmatrix} L_{aa}(\gamma) & M_{ab}(\gamma) & M_{ac}(\gamma) \\ M_{ab}(\gamma) & L_{bb}(\gamma) & M_{bc}(\gamma) \\ M_{ac}(\gamma) & M_{bc}(\gamma) & L_{cc}(\gamma) \end{bmatrix} \quad (2.9)$$

Raspisana matrica $\mathbf{L}_{sr}(\gamma)$ glasi:

$$\mathbf{L}_{sr}(\gamma) = \begin{bmatrix} M_{af}(\gamma) & M_{aD}(\gamma) & M_{aQ}(\gamma) \\ M_{bf}(\gamma) & M_{bD}(\gamma) & M_{bQ}(\gamma) \\ M_{cf}(\gamma) & M_{cD}(\gamma) & M_{cQ}(\gamma) \end{bmatrix} \quad (2.10)$$

Raspisana matrica $\mathbf{L}_r$ glasi:

$$\mathbf{L}_r = \begin{bmatrix} L_{ff} & M_{fD} & 0 \\ M_{fD} & L_{DD} & 0 \\ 0 & 0 & L_{QQ} \end{bmatrix} \quad (2.11)$$

Veličine induktiviteta, međuinduktiviteta a time i ulančenih tokova u prikazanom modelu

mijenja se ovisno o položaju rotora zbog istaknutih polova na rotoru i zbog statorskih ili rotorskih utora. To je nepraktično svojstvo u daljnjem razvoju i korištenju modela stroja, pa je napravljena transformacija modela s ciljem izbjegavanja njegove ovisnosti o položaju rotora. Pomoću pogodne matrice transformacije koja je sama ovisna o položaju rotora postiže se poništavanje ovisnosti induktiviteta i međuinuktiviteta u modelu o položaju rotora. Primijenjena je Parkova transformacija koordinata koja statorski abc sustav prevodi u rotirajući dq0 sustav [101]. Matrica Parkove transformacije glasi

$$\mathbf{P}_g = \frac{2}{3} \begin{bmatrix} \cos(\gamma) & \cos(\gamma - \frac{\pi}{3}) & \cos(\gamma + \frac{2\pi}{3}) \\ \sin(\gamma) & \sin(\gamma - \frac{2\pi}{3}) & \sin(\gamma + \frac{2\pi}{3}) \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix} \quad (2.12)$$

Budući da model sinkronog generatora osim statorskih namota obuhvaća još i rotorski uzbudni namot kao i prigušne namote u d i q osi, koje ne zahvaća Parkova transformacija 2.12, matrica transformacije sustava jednadžbi cijelog modela (2.1) i (2.7) širi se u oblik

$$\mathbf{T}_g = \begin{bmatrix} \mathbf{P}_g & 0 \\ 0 & \mathbf{I} \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 2\cos(\gamma) & 2\cos(\gamma - \frac{2\pi}{3}) & 2\cos(\gamma + \frac{2\pi}{3}) & 0 & 0 & 0 \\ 2\sin(\gamma) & 2\sin(\gamma - \frac{2\pi}{3}) & 2\sin(\gamma + \frac{2\pi}{3}) & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 3 & 0 & 0 \\ 0 & 0 & 0 & 0 & 3 & 0 \\ 0 & 0 & 0 & 0 & 0 & 3 \end{bmatrix} \quad (2.13)$$

Pomoću proširene matrice transformacije (2.13) moguće je transformiranje iz a, b, c, f, D, Q sustava u sustav $d, q, 0, f, D, Q$ sljedećom metodom:

$$\begin{aligned} \mathbf{U}_{dq0fDQ} &= \mathbf{T}_g \mathbf{U}_{abcfDQ} \\ \mathbf{I}_{dq0fDQ} &= \mathbf{T}_g \mathbf{I}_{abcfDQ} \\ \Psi_{dq0fDQ} &= \mathbf{T}_g \Psi_{abcfDQ} \end{aligned} \quad (2.14)$$

gdje je $\mathbf{U}_{dq0fDQ}$ vektor napona,

$$\mathbf{U}_{dq0fDQ} = \begin{bmatrix} U_d & U_q & U_0 & U_f & U_D & U_Q \end{bmatrix}^T \quad (2.15)$$

$\mathbf{I}_{dq0fDQ}$ je vektor struje,

$$\mathbf{I}_{dq0fDQ} = \begin{bmatrix} I_d & I_q & I_0 & I_f & I_D & I_Q \end{bmatrix}^T \quad (2.16)$$

i Ψ_{dq0fDQ} je vektor ulančenih tokova.

$$\Psi_{dq0fDQ} = \begin{bmatrix} \Psi_d & \Psi_q & \Psi_0 & \Psi_f & \Psi_D & \Psi_Q \end{bmatrix}^T \quad (2.17)$$

Primjenom metode (2.14) na (2.1) dobiva se:

$$\mathbf{T}_g^{-1} \mathbf{U}_{dq0fDQ} = -\mathbf{R} \mathbf{T}_g^{-1} \mathbf{I}_{dq0fDQ} - \frac{d}{dt} \left(\mathbf{T}_g^{-1} \Psi_{dq0fDQ} \right) \quad (2.18)$$

što sređivanjem daje

$$\mathbf{U}_{dq0fDQ} = -\mathbf{R} \mathbf{I}_{dq0fDQ} - \omega \begin{bmatrix} \Psi_q \\ -\Psi_d \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} - \frac{d\Psi_{dq0fDQ}}{dt} \quad (2.19)$$

Ekvivalentni statorki namoti proizašli iz transformacije koordinata, označeni indeksima d , q i 0 rotiraju u dq0 sustavu sinkronom brzinom.

Dinamički model sinkronog generatora sadrži sljedeću mehaničku jednadžbu gibanja rotora

$$J \frac{d\omega}{dt} = M_t - M_{em} \quad (2.20)$$

gdje je J moment inercije agregata, M_t zakretni moment turbine, a M_{em} elektromagnetski zakretni moment sinkronog generatora.

Općeniti izraz za elektromagnetski moment električnog stroja glasi

$$M_{em} = -p \mathbf{I}^T \frac{\partial \Psi(\gamma)}{\partial \gamma} \quad (2.21)$$

Parkovom transformacijom izraza (2.21) dobiva se izraz za elektromagnetski moment sinkronog

generatora u transformiranim dq0 koordinatama prema

$$M_{em} = \frac{3}{2}p(\Psi_d I_q - \Psi_q I_d) \quad (2.22)$$

Relacije u matričnom obliku (2.19) i mehanička jednačba gibanja (2.20) predstavljaju cjeloviti dvoosni klasični linearni dinamički model sinkronog generatora, koji je sedmog reda.

2.2.2 Klasični model sinkronog generatora za stacionarna radna stanja

Model sinkronog generatora za stacionarna stanja dobiva se kao specijalni oblik prikazanog dinamičkog modela sinkronog stroja u kojemu su sve veličine konstantne, nema njihovih vremenskih promjena, odnosno sve vremenske derivacije jednake su nuli. Struje prigušnih namota jednake su nuli jer ih uzrokuje inducirani napon koji nastaje u prijelaznim stanjima, zbog promjene ulančenih tokova u d i q osi. Jednačbe prigušnih namota se zbog toga u stacionarnom stanju mogu izuzeti iz razmatranja. Struja uzbude I_f je konstantna. Konstantne armaturne struje i naponi u d i q osi transformirani u abc sustav su u osnovnom harmoniku sinusne i simetrične trofazne struje i naponi, što znači da u nultom sustavu nema pobuda i da se jednačba nultih veličina također može izuzeti. Brzina vrtnje rotora konstantna je i jednaka brzini armaturnog okretnog magnetskog polja. Nelinearnosti zbog histereze krivulje magnetiziranja gubitci u željezu zanemaruju se. Iz navedenog proizlaze jednačbe koje opisuju stacionarno stanje sinkronog generatora prema sljedećem

$$U_d = -RI_d - \omega \Psi_q \quad (2.23)$$

$$U_q = -RI_q + \omega \Psi_d \quad (2.24)$$

$$U_f = R_f I_f \quad (2.25)$$

$$M_{em} = M_t = \frac{3}{2}p(\Psi_d I_q - \Psi_q I_d) \quad (2.26)$$

Budući da je magnetska os uzbudnog namota u d osi, izrazi za ulančene tokove u d i q osi glase

$$\Psi_d = M_{df} I_f + L_d I_d \quad (2.27)$$

$$\Psi_q = L_q I_q \quad (2.28)$$

Uvrštavanjem (2.27) i (2.28) u (2.23) i (2.24) dobivaju se jednačbe napona armaturnih namota u d i q osi za stacionarno stanje

$$U_d = -RI_d - \omega \Psi_q = -RI_d - \omega L_q I_q = -RI_d - X_q I_q \quad (2.29)$$

$$U_q = -RI_q + \omega\Psi_d = -RI_q + \omega M_{df}I_f + \omega L_d I_d = -RI_q + E_0 + X_d I_d \quad (2.30)$$

gdje su $X_d = \omega L_d$ i $X_q = \omega L_q$ sinkrone reaktancije u d i q osi, a izraz

$$E_0 = \omega M_{df}I_f \quad (2.31)$$

predstavlja fiktivni inducirani napon. Jednadžbe (2.29) i (2.30) moguće je izraziti u fazorskom obliku. Jednadžba napona armaturnog namota sinkronog generatora dobiva se ako se (2.29) pomnoži s -1 i pribroji izrazu (2.30) pomnoženim s imaginarnom jedinicom j . Nakon sređivanja dobiva se izraz

$$-U_d + jU_q + R(-I_d + jI_q) - jX_d I_d - X_q I_q = jE_0 \quad (2.32)$$

Izražavanjem člana $-X_q I_q$ kao $jX_q jI_q$ dobiva se

$$-U_d + jU_q + R(-I_d + jI_q) - jX_d I_d + jX_q jI_q = jE_0 \quad (2.33)$$

Ukoliko se uvedu fazori $\overline{U_s} = -U_d + jU_q$, $\overline{I_s} = -I_d + jI_q$, $\overline{I_q} = jI_q$, $\overline{I_d} = -I_d$ i $\overline{E_0} = jE_0$, dobiva se naponska jednadžba sinkronog generatora u fazorskom obliku za opis stacionarnih stanja

$$\overline{U_s} + \overline{I_s}R + jX_q \overline{I_q} + jX_d \overline{I_d} = \overline{E_0} \quad (2.34)$$

na temelju koje se može formirati vektorsko-fazorski dijagram sinkronog generatora (slika 2.2). Na tom dijagramu kut δ između fazora armaturnog napona i fiktivnog induciraniog napona, odnosno q osi predstavlja kut opterećenja i izračunava se prema

$$\delta = \arctan\left(\frac{U_d}{U_q}\right) \quad (2.35)$$

Zbog cjelovitosti prikaza modela, nadalje su dane jednadžbe za izračunavanje elektromagnetskog momenta, djelatne i jalove snage.

$$M_{em} = \frac{3}{2}p(\Psi_d I_q - \Psi_q I_d) \quad (2.36)$$

$$P = \frac{3}{2}p\omega(\Psi_d I_q - \Psi_q I_d) - \frac{3}{2}(I_d^2 + I_q^2)R \quad (2.37)$$

$$Q = \frac{3}{2}p\omega(-\Psi_d I_d - \Psi_q I_q) \quad (2.38)$$

Vezano za klasični modelu postoje načini procjene magnetske nelinearnosti, poput metoda temeljenih na Potierovom dijagramu, švedskom i američkom dijagramu [100]. To su grafičke metode temeljene na parametrima za koje ne postoje načini za njihovo određivanje i mjerenje a imaju preveliki raspon procjene, kao što se za *Potierovu reaktanciju* procjenjuje da je za 5 % do

20 % veća od rasipne reaktancije armature, odnosno $x_p = (1,05 \div 1,2)x_\sigma$. Parametri se uzimaju konstantni, a u stvarnosti su promjenjivi s magnetskim zasićenjem, za što navedene metode nisu prilagođene. Magnetsko zasićenje procjenjuje se preračunavanjem krivulje praznog hoda, koja opisuje magnetsko zasićenje u d osi, a pri raznim teretima magnetski uvjeti u stroju su znatno drugačiji i složeniji pri čemu se ne uzima u obzir niti efekt poprečne magnetizacije. Stoga navedene metode u uvjetima magnetskog zasićenja ne mogu dati dobre rezultate, za što je pogodniji drugačiji pristup koji se ostvaruje pomoću $\Psi(I)$ funkcija, opisanih u daljnjem tekstu.

2.2.3 Jedinični sustav veličina

Zbog lakše usporedbe različitih tipova i veličina sinkronih generatora uvodi se jedinični, relativni, odnosno tzv. *per unit* (p.u.) sustav veličina. Njegovo uvođenje u model provodi se na taj način da se sve veličine podijele s njihovim pripadajućim baznim vrijednostima, čime se dobivaju veličine izražene relativno u odnosu na bazne vrijednosti. Način odabira baznih vrijednosti nije striktno definiran, pa se na primjer u abc sustavu, u kojemu se naponi i struje uglavnom računaju u efektivnim vrijednostima, obično za bazne vrijednosti uzimaju nazivne efektivne vrijednosti.

$$U_B^{abc} = U_{ef} \quad I_B^{abc} = I_{ef} \quad (2.39)$$

Kako tip prikazane Parkove transformacije (2.12) prikazan u poglavlju 2.2.1 ima fazno invarijantni oblik, to znači da fazne veličine napona, struja i ulančenih tokova u dq0 sustavu ostaju nepromijenjeni s iznosima njihovih maksimalnih faznih vrijednosti iz abc sustava. To je razlog da se za odabir baznih vrijednosti u dq0 sustavu uzimaju maksimalne vrijednosti 2.40.

$$U_B^{dq} = U_{max} \quad I_B^{dq} = I_{max} \quad \Psi_B^{dq} = \Psi_{max} \quad (2.40)$$

U slučaju da se Parkova transformacija koristi u obliku invarijantnom s obzirom na snagu, tada se u dq0 sustavu za bazne vrijednosti odabiru efektivne vrijednosti pomnožene s $\sqrt{3}$. Premda se bilo koja vrijednost može uzeti za baznu vrijednost struje uzbude, uglavnom se za tu vrijednost uzima struja uzbude praznog hoda.

$$I_{fB} = I_{f0} \quad (2.41)$$

Za električnu kutnu brzinu obično se odabire bazna vrijednost prema

$$\omega_B = 2\pi f_n \quad (2.42)$$


gdje je f_n nazivna frekvencija elektroenergetskog sustava. Bazne vrijednosti za induktivitet,

impedanciju, ulančeni tok, snagu i mehaničku kutnu brzinu iznose:


$$L_B = \frac{Z_B}{\omega_B} \quad Z_B = \frac{U_B}{I_B} \quad \Psi_B = \frac{U_B}{\omega_B} = L_B I_B \quad S_B = \frac{3}{2} U_B I_B \quad \omega_{mB} = \frac{\omega_B}{p} \quad (2.43)$$

2.2.4 Tvorba pogonske karte pomoću klasičnog modela


Na slici 2.2 prikazana je složenija varijanta vektorsko fazorskog dijagrama – dijagram od hidrogenatora (a), zajedno s međukorakom prema tvorbi pogonske karte (b). Pogonska karta izvedena je na taj način da se cijeli vektorsko-fazorski dijagram pomnoži s U/X_d (sve u p.u.) i zarotira za 90° u negativnom smjeru [100], kao što je prikazano na slici 2.3. Granice pogonske karte na bazi klasičnog vektorsko-fazorskog dijagrama izračunate s konstantnim induktivitetima prikazane su na slici 2.4, za slučaj pri nazivnom naponu generatora.



Slika 2.2: Vektorsko fazorski dijagram sinkronog generatora



Slika 2.3: Tvorba pogonske karte sinkronog generatora



Slika 2.4: Pogonska karta sinkronog generatora

Granica maksimalne struje armature - 1.

Granica maksimalne struje armature jednostavno se opisuje kružnicom polumjera koji predstavlja prividnu snagu S , što se matematički izražava sljedećim analitičkim izrazom:

$$P = \sqrt{S^2 - Q^2} = \sqrt{(UI)^2 - (UI \sin \varphi)^2} = UI \cos \varphi \quad (2.44)$$

Polumjer kružnice proporcionalan je struji i naponu armature.

Granice uzbudne struje - 2., 3. i 4.

Grafovi koji u Kartezijevim P-Q koordinatama pogonske karte predstavljaju konstantnu uzбудu opisani su Pascalovim krivuljama, čiji opći oblik glasi:

$$(X^2 + Y^2 - aX)^2 = l^2 (X^2 + Y^2) \quad (2.45)$$

gdje su a i l promjer osnovne kružnice i udaljenost Pascalove krivulje od osnovne kružnice, a prevodeći u koordinate P-Q pogonske karte pojedini dijelovi (2.45) glase:

$$\begin{aligned} X &= Q, \quad Y = P, \quad a = \frac{U^2 (X_d - X_q)}{X_d X_q}, \\ l &= \frac{E_0 \cdot U}{X_d}, \quad E_0 = I_f X_{mf}, \quad Q_0 = \frac{-U^2}{X_q} \end{aligned} \quad (2.46)$$

U sklopu pogonske karte, Pascalove krivulje su pomaknute na Q osi za Q_0 , što je lijevi kraj manje kružnice (za $E_0 = 0$) na slici 2.3. Uvrstivši sve dijelove (2.46) za prevođenje u okruženje P-Q pogonske karte u (2.45), dobivamo složeni izraz četvrtog stupnja za Pascalove krivulje u P-Q koordinatama, prema sljedećem:

$$\left[\left(Q + \frac{U^2}{X_q} \right)^2 + P^2 - \frac{U^2 (X_d - X_q)}{X_d X_q} \left(Q + \frac{U^2}{X_q} \right) \right]^2 = \left(\frac{E_0 \cdot U}{X_d} \right)^2 \left[\left(Q + \frac{U^2}{X_q} \right)^2 + P^2 \right] \quad (2.47)$$

Jednostavniji način za opisivanje krivulja konstantne uzbuđe na analitički način proizlazi iz vektorsko-fazorskog dijagrama sa slike 2.2, prema sljedećem:

$$I_d = \frac{E_0 - \sqrt{U^2 - (I_q X_q)^2}}{X_d} \quad (2.48)$$

$$P = \Psi_d I_q - \Psi_q I_d - (I_d^2 + I_q^2) R = (E_0 + I_d X_d) I_q - I_q X_q I_d - (I_d^2 + I_q^2) R \quad (2.49)$$

$$Q = -\Psi_d I_d - \Psi_q I_q = -(E_0 + I_d X_d) I_d - I_q X_q I_q \quad (2.50)$$

Za konstantnu uzbudnu struju I_f , iz koje se izračunava fiktivni inducirani napon E_0 , uz napon armature U , i za vektor raspona vrijednosti struje I_q , posredno preko izračuna vrijednosti struja I_d , mogu se izračunati točke (Q, P) krivulje konstantne uzbuđe. Uvrštavanjem minimalne konstantne uzbudne struje dobiva se krivulja granice minimalne uzbuđe i isto tako i za maksimalnu uzbudnu struju. Za uzbudnu struju $I_f = 0$ dobiva se osnovna kružnica Pascalovih krivulja, koja je prikazana kao manji polukrug na slici 2.3 i krivulja polukrug br 4. na slici 2.4.

Statička i praktična granica stabilnosti - 5. i 6.

Povećanjem zakretnog momenta pogonskog stroja, uz konstantnu uzбудnu struju i napon armature, povećava se djelatna snaga agregata i kut opterećenja δ generatora, ali do iznosa kuta nakon kojeg se smanjuju zakretni moment i djelatna snaga generatora, koji bi tada ispao iz sinkronizma. Izraz koji opisuje djelatnu snagu generatora ovisno o kutu opterećenja δ , uz određeni napon armature i uzбудu je [100]:

$$P = \frac{E_0 \cdot U}{X_d} \sin \delta + \frac{U^2 (X_d - X_q)}{X_d X_q} \sin(2\delta) \quad (2.51)$$

Deriviranjem (2.51) po δ i izjednačavanjem s nulom te sređivanjem jednadžbe, dobiva se izraz za prekretni kut δ_{pr} , prema sljedećem:

$$\delta_{pr} = \arccos \left(\frac{-E_0 \cdot X_q + \sqrt{8U^2 (X_d - X_q)^2 + E_0^2 X_q^2}}{4U (X_d - X_q)} \right) \quad (2.52)$$

Upotrebom δ_{pr} računa se prekretna djelatna snaga prema (2.51) i jalova snaga prema:

$$Q = \frac{E_0 \cdot U}{X_d} \cos \delta + \frac{U^2 (X_d - X_q)}{2X_d X_q} \cos(2\delta) - \frac{U^2 (X_d - X_q)}{2X_d X_q} \quad (2.53)$$

Za razne iznose uzbude dobivaju se točke (Q, P) , koje svojim povezivanjem tvore krivulju statičke granice stabilnosti. Statička granica stabilnosti samo je teoretska granica kojoj se u praksi radna točka generatora ne smije približiti zbog dinamičkih pojava koje se događaju uslijed unutarnjih u elektrani ili vanjskih promjena ili poremećaja. Zbog toga se uzima sigurnosna margina koja sužava dozvoljeno radno područje generatora korigiranjem točaka (Q, P) koje tvore krivulju statičke granice stabilnosti. Za fiksnu uzбудnu struju odredi se prekretna djelatna snaga, koja se umanji za 0,1 p.u.. i onda se traži presjecište horizontalne linije na toj novoj djelatnoj snazi s krivuljom konstantne uzbude, koje predstavlja točku na krivulji praktične granice stabilnosti. Variranjem uzbude po vektoru raspona vrijednosti dobije se više točaka (Q, P) , čijim povezivanjem dobivamo krivulju praktične granice stabilnosti u obliku krivulje br. 6 na slici 2.4.

Granice konstantne djelatne snage pogonskog stroja - 7. i 8.

Granice konstantne djelatne snage su trivijalne i u pogonskoj karti predstavljaju ih horizontalne linije koje opisuju donju granicu zbog tehnološkog minimuma pogonskog stroja i gornju granicu maksimalne dozvoljene trajne snage pogonskog stroja. Na primjeru na slici 2.4 vidljivo je da je donja granica djelatne snage jednaka nuli, zbog toga što su u tom primjeru pogonski strojevi

tipa Pelton turbine koji nemaju ograničenja zbog tehnološkog minimuma.

2.3 Polinomne $\Psi(I)$ funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora

U poglavlju 2.2.2 opisanom klasičnom modelu za stacionarna radna stanja sinkronog generatora nije uzet u obzir efekt poprečne magnetizacije. Uvođenjem efekta poprečne magnetizacije u izraze za ulančene tokove u direktnoj i poprečnoj osi (2.27) (2.28), ti izrazi dobivaju sljedeći oblik:

$$\Psi_d = M_{df}I_f + L_dI_d + M_{dq}I_q \quad (2.54)$$

$$\Psi_q = L_qI_q + M_{qd}I_d + M_{qf}I_f \quad (2.55)$$

U izrazima 2.54 i 2.55 članovi M_{dq} , M_{qd} i M_{qf} predstavljaju međuinduktivite poprečne magnetizacije. Budući da magnetska indukcija u magnetskom materijalu s magnetskim zasićenjem ovisi nelinearno o magnetskom polju, tako u električnom stroju s dijelovima načinjenima od materijala s magnetskim zasićenjem svi induktiviteti i međuinduktiviteti nelinearno ovise o magnetskom polju koje mu je narinuto. Drugim riječima, za izražavanje veličina sinkronog stroja u stacionarnim stanjima potrebno je poznavati šest funkcija (2.56) ovisnosti induktiviteta i međuinduktiviteta (M_{df} , L_d , M_{dq} , L_q , M_{qd} i M_{qf}) o 3 struje, odnosno o strujama armature u direktnoj i poprečnoj osi (I_d , I_q) i o uzbudnoj struji (I_f), što nije jednostavan problem.

$$\begin{aligned} M_{df} &= f(I_d, I_q, I_f) & L_d &= f(I_d, I_q, I_f) & M_{dq} &= f(I_d, I_q, I_f) \\ L_q &= f(I_d, I_q, I_f) & M_{qd} &= f(I_d, I_q, I_f) & M_{qf} &= f(I_d, I_q, I_f) \end{aligned} \quad (2.56)$$

S ciljem pojednostavljenja problema rodila se je ideja s direktnim izražavanjem ulančenih tokova o strujama [18], čime se opis stacionarnih stanja sinkronog stroja sa šest funkcija pojednostavljuje na poznavanje dviju funkcija $\Psi(I)$, koje nastaju uvrštavanjem 2.56 u 2.54 i 2.55 rezultirajući u jednostavnom obliku:

$$\Psi_d = f(I_d, I_q, I_f) \quad \Psi_q = f(I_d, I_q, I_f) \quad (2.57)$$

Naponske jednadžbe koje izražavaju stacionarna stanja sinkronog generatora 2.23 i 2.24 korištenjem $\Psi(I)$ funkcija dobivaju sljedeći oblik:

$$U_d = -RI_d - \omega\Psi_q = -RI_d - \omega(L_qI_q + L_{qd}I_d + L_{qf}I_f) = -RI_d - \omega\Psi_q(I_d, I_q, I_f) \quad (2.58)$$

$$U_q = -RI_q + \omega\Psi_d = -RI_q + \omega(L_{df}I_f + L_dI_d + L_{dq}I_q) = -RI_q + \omega\Psi_d(I_d, I_q, I_f) \quad (2.59)$$

Na slici 2.5 prikazan je vektorsko fazorski dijagram sinkronog generatora za opis stacionarnih stanja za referentni generatorski sustav upotrebom $\Psi(I)$ funkcija. Prema tom dijagramu, naponi, struje i ulančeni tokovi u $d-q$ sustavu mogu se izračunati ako je poznat kut opterećenja δ i fazni kut φ .


$$U_d = U \sin \delta \quad U_q = U \cos \delta \quad (2.60)$$

$$I_d = I \sin(\delta - \varphi) \quad I_q = I \cos(\delta - \varphi) \quad (2.61)$$

Iz naponskih jednadžbi sinkronog generatora za stacionarno stanje ulančeni tokovi se mogu dobiti poznavanjem struja, napona, otpora armaturnog namota i kutne brzine prema (2.62). Kod velikih sinkronih strojeva armaturni otpor malog je iznosa te se može zanemariti.

$$\Psi_d = \frac{U_q + I_q R_a}{\omega} \approx \frac{U_q}{\omega} \quad \Psi_q = -\frac{U_d + I_d R_a}{\omega} \approx -\frac{U_d}{\omega} \quad (2.62)$$

Funkcije $\Psi(I)$ mogu se izraziti na različite načine, a u inicijalnom obliku [18] ovisnosti ulančenih tokova o strujama mogu se modelirati polinomima (2.63) i (2.64). Ako magnetizacija djeluje u samo jednoj osi, tada se efekt poprečne magnetizacije ne događa. Toj je činjenici prilagođen oblik polinoma, jer na primjer uz $I_d = I_f = 0$ djelovanje struje I_q neće stvoriti tok u d osi. Isto tako djelovanje I_d i I_f uz $I_q = 0$ neće stvoriti nikakav ulančeni tok u q osi. Dodavanjem



Slika 2.5: Vektorsko fazorski dijagram sinkronog generatora za opis stacionarnih stanja upotrebom $\Psi(I)$ funkcija

viših članova polinoma postiže se kvalitetniji opis.

$$\begin{aligned}\Psi_d(I_d, I_q, I_f) = & d_1 + d_2 I_d + d_3 I_q + d_4 I_f + d_5 I_d^2 + d_6 I_q^2 + d_7 I_f^2 + d_8 I_d I_q + d_9 I_d I_f \\ & + d_{10} I_q I_f + d_{11} I_d^3 + d_{12} I_q^3 + d_{13} I_f^3 + d_{14} I_d^2 I_q + d_{15} I_d^2 I_f + d_{16} I_q^2 I_d \\ & + d_{17} I_q^2 I_f + d_{18} I_f^2 I_d + d_{19} I_f^2 I_q + d_{20} I_d I_q I_f\end{aligned}\quad (2.63)$$

$$\begin{aligned}\Psi_q(I_d, I_q, I_f) = & q_1 + q_2 I_d + q_3 I_q + q_4 I_f + q_5 I_d^2 + q_6 I_q^2 + q_7 I_f^2 + q_8 I_d I_q + q_9 I_d I_f \\ & + q_{10} I_q I_f + q_{11} I_d^3 + q_{12} I_q^3 + q_{13} I_f^3 + q_{14} I_d^2 I_q + q_{15} I_d^2 I_f + q_{16} I_q^2 I_d \\ & + q_{17} I_q^2 I_f + q_{18} I_f^2 I_d + q_{19} I_f^2 I_q + q_{20} I_d I_q I_f\end{aligned}\quad (2.64)$$

Dakle, za opis stacionarnih stanja sinkronog generatora potrebno je identificirati konstante $d_1 \dots d_{20}$ i $q_1 \dots q_{20}$, što je moguće napraviti na temelju skupa podataka stacionarnih radnih točaka dobivenih mjerenjem ili izračunom.

2.4 Identifikacija polinomnih $\Psi(I)$ funkcija

Da bi se pomoću (2.63) i (2.64) mogla opisivati stacionarna stanja sinkronih generatora potrebno je odrediti konstante $d_1 \dots d_{20}$ i $q_1 \dots q_{20}$, što predstavlja identifikaciju polinomnog $\Psi(I)$ modela. Identifikacija se može napraviti prema skupu podataka stacionarnih radnih točaka u cijelom radnom području, dobivenih mjerenjem ili izračunom, npr. pomoću metode konačnih elemenata. Stacionarne radne točke definirane su četvorkama $I_{d,i}, I_{q,i}, I_{f,i}$ i $\Psi_{d,i}$ za direktnu os i $I_{d,i}, I_{q,i}, I_{f,i}$ i $\Psi_{q,i}$ za poprečnu os. Identifikaciju je moguće provesti pomoću metode najmanjih kvadrata koja pronalazi takve koeficijente $d_1 \dots d_{20}$ i $q_1 \dots q_{20}$ s kojima bi suma kvadrata odstupanja funkcija za sve točke bila najmanja, što matematički opisano pomoću funkcija cilja G_d i G_q glasi:

$$G_d = \sum_{i=1}^N [\Psi_{d,i} - \psi_d(I_{d,i}, I_{q,i}, I_{f,i})]^2 \rightarrow \min! \quad (2.65)$$

$$G_q = \sum_{i=1}^N [\Psi_{q,i} - \psi_q(I_{d,i}, I_{q,i}, I_{f,i})]^2 \rightarrow \min! \quad (2.66)$$

Lokalni ekstrem, tj. minimum se pronalazi izjednačavanjem s nulom parcijalnih derivacija funkcija cilja po traženim koeficijentima $d_1 \dots d_{20}$ i $q_1 \dots q_{20}$, prema:

$$\frac{\partial G_d}{\partial d_k} = 0 \quad \text{za } k = 1 \dots 20 \quad (2.67)$$

$$\frac{\partial G_q}{\partial q_k} = 0 \quad \text{za } k = 1 \dots 20 \quad (2.68)$$

što primjenom (2.67) i (2.68) na (2.65) i (2.66) u razvijenom obliku za direktnu os glasi:

$$\begin{aligned}
 \frac{\partial G_d}{\partial d_1} &= -2 \sum_{i=1}^N [\Psi_{d,i} - \psi_d(I_{d,i}, I_{q,i}, I_{f,i})] = 0 \\
 \frac{\partial G_d}{\partial d_2} &= -2 \sum_{i=1}^N [\Psi_{d,i} - \psi_d(I_{d,i}, I_{q,i}, I_{f,i})] I_{d,i} = 0 \\
 \frac{\partial G_d}{\partial d_3} &= -2 \sum_{i=1}^N [\Psi_{d,i} - \psi_d(I_{d,i}, I_{q,i}, I_{f,i})] I_{q,i} = 0 \\
 &\vdots \\
 \frac{\partial G_d}{\partial d_{19}} &= -2 \sum_{i=1}^N [\psi_{d,i} - \psi_d(I_{d,i}, I_{q,i}, I_{f,i})] I_{f,i}^2 I_{q,i} = 0 \\
 \frac{\partial G_d}{\partial d_{20}} &= -2 \sum_{i=1}^N [\psi_{d,i} - \psi_d(I_{d,i}, I_{q,i}, I_{f,i})] I_{d,i} I_{q,i} I_{f,i} = 0
 \end{aligned} \tag{2.69}$$

i isto za poprečnu os:

$$\begin{aligned}
 \frac{\partial G_q}{\partial q_1} &= -2 \sum_{i=1}^N [\Psi_{q,i} - \psi_q(I_{d,i}, I_{q,i}, I_{f,i})] = 0 \\
 \frac{\partial G_q}{\partial q_2} &= -2 \sum_{i=1}^N [\Psi_{q,i} - \psi_q(I_{d,i}, I_{q,i}, I_{f,i})] I_{d,i} = 0 \\
 \frac{\partial G_q}{\partial q_3} &= -2 \sum_{i=1}^N [\Psi_{q,i} - \psi_q(I_{d,i}, I_{q,i}, I_{f,i})] I_{q,i} = 0 \\
 &\vdots \\
 \frac{\partial G_q}{\partial q_{19}} &= -2 \sum_{i=1}^N [\psi_{q,i} - \psi_q(I_{d,i}, I_{q,i}, I_{f,i})] I_{f,i}^2 I_{q,i} = 0 \\
 \frac{\partial G_q}{\partial q_{20}} &= -2 \sum_{i=1}^N [\psi_{q,i} - \psi_q(I_{d,i}, I_{q,i}, I_{f,i})] I_{d,i} I_{q,i} I_{f,i} = 0
 \end{aligned} \tag{2.70}$$

što se može opisati u matričnom obliku za direktnu i poprečnu os:

$$\mathbf{A_d d} = \mathbf{b_d} \tag{2.71}$$

$$\mathbf{A_q q} = \mathbf{b_q} \tag{2.72}$$

gdje matrica i vektori u razvijenom obliku za direktnu os glase:

$$\mathbf{A_d} = \begin{bmatrix} 1 & \Sigma I_{d,i} & \Sigma I_{q,i} & \cdots & \Sigma I_{f,i}^2 I_{q,i} & \Sigma I_{d,i} I_{q,i} I_{f,i} \\ \Sigma I_{d,i} & \Sigma I_{d,i} I_{d,i} & \Sigma I_{q,i} I_{d,i} & \cdots & \Sigma I_{f,i}^2 I_{q,i} I_{d,i} & \Sigma I_{d,i} I_{q,i} I_{f,i} I_{d,i} \\ \Sigma I_{q,i} & \Sigma I_{d,i} I_{q,i} & \Sigma I_{q,i} I_{q,i} & \cdots & \Sigma I_{f,i}^2 I_{q,i} I_{q,i} & \Sigma I_{d,i} I_{q,i} I_{f,i} I_{q,i} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \Sigma I_{f,i}^2 I_{q,i} & \Sigma I_{d,i} I_{f,i}^2 I_{q,i} & \Sigma I_{q,i} I_{f,i}^2 I_{q,i} & \cdots & \Sigma I_{f,i}^2 I_{q,i} I_{f,i}^2 I_{q,i} & \Sigma I_{d,i} I_{q,i} I_{f,i} I_{f,i}^2 I_{q,i} \\ \Sigma I_{d,i} I_{q,i} I_{f,i} & \Sigma I_{d,i} I_{d,i} I_{q,i} I_{f,i} & \Sigma I_{q,i} I_{d,i} I_{q,i} I_{f,i} & \cdots & \Sigma I_{f,i}^2 I_{q,i} I_{d,i} I_{q,i} I_{f,i} & \Sigma I_{d,i} I_{q,i} I_{f,i} I_{d,i} I_{q,i} I_{f,i} \end{bmatrix} \quad (2.73)$$

$$\mathbf{d} = [d_1 \quad d_2 \quad \cdots \quad d_{20}]^T \quad (2.74)$$

$$\mathbf{b_d} = [\Sigma \Psi_{d,i} \quad \Sigma \Psi_{d,i} I_{d,i} \quad \Sigma \Psi_{d,i} I_{q,i} \quad \cdots \quad \Sigma \Psi_{d,i} I_{f,i}^2 I_{q,i} \quad \Sigma \Psi_{d,i} I_{d,i} I_{q,i} I_{f,i}]^T \quad (2.75)$$

i analogno za poprečnu os:

$$\mathbf{A_q} = \begin{bmatrix} 1 & \Sigma I_{d,i} & \Sigma I_{q,i} & \cdots & \Sigma I_{f,i}^2 I_{q,i} & \Sigma I_{d,i} I_{q,i} I_{f,i} \\ \Sigma I_{d,i} & \Sigma I_{d,i} I_{d,i} & \Sigma I_{q,i} I_{d,i} & \cdots & \Sigma I_{f,i}^2 I_{q,i} I_{d,i} & \Sigma I_{d,i} I_{q,i} I_{f,i} I_{d,i} \\ \Sigma I_{q,i} & \Sigma I_{d,i} I_{q,i} & \Sigma I_{q,i} I_{q,i} & \cdots & \Sigma I_{f,i}^2 I_{q,i} I_{q,i} & \Sigma I_{d,i} I_{q,i} I_{f,i} I_{q,i} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \Sigma I_{f,i}^2 I_{q,i} & \Sigma I_{d,i} I_{f,i}^2 I_{q,i} & \Sigma I_{q,i} I_{f,i}^2 I_{q,i} & \cdots & \Sigma I_{f,i}^2 I_{q,i} I_{f,i}^2 I_{q,i} & \Sigma I_{d,i} I_{q,i} I_{f,i} I_{f,i}^2 I_{q,i} \\ \Sigma I_{d,i} I_{q,i} I_{f,i} & \Sigma I_{d,i} I_{d,i} I_{q,i} I_{f,i} & \Sigma I_{q,i} I_{d,i} I_{q,i} I_{f,i} & \cdots & \Sigma I_{f,i}^2 I_{q,i} I_{d,i} I_{q,i} I_{f,i} & \Sigma I_{d,i} I_{q,i} I_{f,i} I_{d,i} I_{q,i} I_{f,i} \end{bmatrix} \quad (2.76)$$

$$\mathbf{q} = [q_1 \quad q_2 \quad \cdots \quad q_{20}]^T \quad (2.77)$$

$$\mathbf{b_q} = [\Sigma \Psi_{q,i} \quad \Sigma \Psi_{q,i} I_{d,i} \quad \Sigma \Psi_{q,i} I_{q,i} \quad \cdots \quad \Sigma \Psi_{q,i} I_{f,i}^2 I_{q,i} \quad \Sigma \Psi_{q,i} I_{d,i} I_{q,i} I_{f,i}]^T \quad (2.78)$$

Koeficijenti $d_1 \dots d_{20}$ i $q_1 \dots q_{20}$ sadržani su u vektorima $\mathbf{d}$ i $\mathbf{q}$ koji se izračunavaju rješavanjem linearnih sustava za direktnu i poprečnu os:

$$\mathbf{d} = \mathbf{A_d}^{-1} \mathbf{b_d} \quad (2.79)$$

$$\mathbf{q} = \mathbf{A_q}^{-1} \mathbf{b_q} \quad (2.80)$$

Prikazanom metodom nelinearni problem sveden je na rješavanje sustava linearnih jednadžbi. U poglavlju 3.1 je na konkretnom slučaju generatora primijenjena opisana metoda identifikacije polinomnih $\Psi(I)$ funkcija. Prikazani su identificirani koeficijenti $d_1 \dots d_{20}$ i $q_1 \dots q_{20}$. Na točkama identifikacije i validacije izračunate su greške i uspoređene s greškama klasičnog modela, na osnovi čega se nametnula potreba za daljnjim razvojem modela i usporedbom ukupnih rezultata.

Minimalni broj točaka za identifikaciju jednak je broju koeficijenata koji se u funkciji identificiraju. U praksi se pokazalo da je identifikaciju $\Psi(I)$ funkcija s razinama točnosti navedenima u tablicama 3.4 i 3.11 moguće napraviti s 80-tak snimljenih radnih točaka, ali od broja točaka bitnija je njihova rasprostranjenost u cijelom trodimenzionalnom radnom području sinkronog generatora definiranom prostorom Q, P, U . Radne točke s istim Q i P koordinatama potrebno je snimiti pri različitim naponima armature. To se npr. kod elektrana s dva ili više agregata može postići tako da se za iste radne točke generatora na kojem se obavljaju mjerenja definirane Q i P koordinatama, preostali generatori u elektrani sinkroniziraju na mrežu na istim sabirnicama kao i generator na kojem se obavljaju mjerenja i varira im se uzbudna struja istovremeno i na isti način od minimalne do maksimalne jalove snage.

2.5 Izračun granica u pogonskoj karti pomoću polinomnih $\Psi(I)$ funkcija

Uz jednom određene koeficijente $d_1 \dots d_{20}$ i $q_1 \dots q_{20}$, polinomni $\Psi(I)$ model je identificiran i nakon verifikacije njegove točnosti može se koristiti za određivanje svih veličina stacionarnih radnih stanja u cijelom radnom području sinkronog generatora. Dio zanimljivih stacionarnih radnih točki sinkronog generatora je u rubnom području pogonske karte u kojemu su određene granice dozvoljenog trajnog rada, koje se mogu dobiti pomoću ovog modela.

2.5.1 Granice konstantne struje armature i djelatne snage

Granica konstantne struje armature jednako kao i kod klasičnog modela, prema opisanom u poglavlju 2.2.4, jednostavno se opisuje kružnicom čiji polumjer je proporcionalan struji i naponu armature, kako je opisano u izrazu 2.44.

Granice konstantne djelatne snage su također jednake kao i kod klasičnog modela, prema opisu u poglavlju 2.2.4, trivijalne su i u pogonskoj karti opisane su horizontalnim linijama koje određuju donju granicu zbog tehnološkog minimuma pogonskog stroja i gornju granicu maksimalne dozvoljene trajne snage pogonskog stroja.

2.5.2 Granica konstantne uzbude

Granice uzbudne struje određuju se tako da se definiraju minimalni i maksimalni iznos uzbudne struje koji se u izračunu drže konstantnim:

$$\begin{aligned} I_{f,\min} &= \text{konst.} = I_{f,\min,\text{konst}} \\ I_{f,\max} &= \text{konst.} = I_{f,\max,\text{konst}} \end{aligned} \quad (2.81)$$

Budući da se granice izračunavaju za stacionarna stanja pri određenom konstantnom naponu, potrebno je jednadžbu koja definira napon armature (2.82), proizvoljnim variranjem različitih vrijednosti $I_{q,var}$ riješiti po I_d :

$$U_{konst} = \sqrt{(\omega \Psi_d(I_d, I_{q,var}, I_{f,konst}) - I_{q,var}R)^2 + (-\omega \Psi_q(I_d, I_{q,var}, I_{f,konst}) - I_dR)^2} \quad (2.82)$$

Rješavanje po I_d za svaku stacionarnu točku predstavlja rješavanje jedne nelinearne jednadžbe s jednom nepoznanicom, za što se koriste standardne iterativne metode kao što je Newtonova metoda. Time se dolazi do trojke $(I_d, I_{q,var}, I_{f,konst})$ čijim se uvrštavanjem u izraze za električnu djelatnu i jalovu snagu (2.49) i (2.50) dobivaju koordinate radne točke za prikaz na pogonskoj karti. U svim izrazima (2.49), (2.50) i (2.82) se koristi polinomni $\Psi(I)$ model. Isti prikazani postupak primjenjuje se za sve proizvoljno varirane vrijednosti $I_{q,i,var}$ za $i = 1 \dots n$ iz dijagrama toka 2.83 sa slijedom izračuna točaka granice uzbudne struje, čime se dolazi do koordinata $(Q_{KU,i}, P_{KU,i})$ drugih radnih točaka, čijim se povezivanjem postiže krivulja konstantne struje uzbude u pogonskoj karti, koje za minimalnu i maksimalnu uzbudnu struju predstavljaju dijelove granice pogonske karte.

$$\begin{array}{ccccccc}
 I_{f,konst} & I_{q,1,var} & & & I_{d,1} & & \\
 \vdots & I_{q,2,var} & & U_{konst} & I_{q,2} & & \\
 \vdots & \vdots & \xlongequal{\hspace{1cm}} & & \vdots & & \\
 I_{f,konst} & I_{q,n,var} & & (2.82) & I_{d,n} & & \\
 & & & & & & (2.83)
 \end{array}$$

$$\begin{array}{ccccccc}
 & \Psi_{d,1}, \Psi_{q,1} & & & Q_{KU,1}, P_{KU,1} & & \\
 \Psi(I) & \Psi_{d,2}, \Psi_{q,2} & & Q, P & Q_{KU,2}, P_{KU,2} & & \\
 \xlongequal{\hspace{1cm}} & \vdots & \xlongequal{\hspace{1cm}} & & \vdots & & \\
 (2.63), (2.64) & \Psi_{d,n}, \Psi_{q,n} & & (2.49), (2.50) & Q_{KU,n}, P_{KU,n} & &
 \end{array}$$

2.5.3 Statička granica stabilnosti

Kao što je opisano u poglavlju 2.2.4, za svaku vrijednost uzbudne struje pri određenom konstantnom armaturnom naponu postoji jedan maksimum djelatne snage, tj. elektromagnetskog

momenta generatora, koji se naziva prekretni moment ili snaga. Prema tome izraz prema kojemu se traži uvjetni ekstrem je onaj pomoću kojeg se za svaku određenu točku iznosa uzbudne struje traži maksimum funkcije djelatne snage generatora (2.49). U ovom postupku primijenjena je Lagrangeova funkcija uvjetnog ekstrema $L(I_d, I_q, \lambda)$, a uvjet koji treba biti zadovoljen je konstantan napon armature koji se izražava pomoću (2.82). Prema navedenom, predmetna funkcija uvjetnog ekstrema može se izraziti na sljedeći način:

$$\begin{aligned} L(I_d, I_q, \lambda) &= P(\psi_d, \psi_q, I_d, I_q, I_{f,var}) + \lambda \left(U_{konst}^2 - U(\psi_d, \psi_q, I_d, I_q, I_{f,var})^2 \right) = \\ &= \omega [\psi_d(I_d, I_q, I_{f,var}) I_q - \psi_q(I_d, I_q, I_{f,var}) I_d] - (I_d^2 - I_q^2) R \\ &+ \lambda \left\{ U_{konst}^2 - \left[(\omega \psi_d(I_d, I_q, I_{f,var}) - I_q R)^2 + (-\omega \psi_q(I_d, I_q, I_{f,var}) - I_d R)^2 \right] \right\} \rightarrow \max! \end{aligned} \quad (2.84)$$

Traženje maksimuma (2.84) svodi se na sustav od tri nelinearne jednačbe s tri nepoznanice I_d , I_q i λ :

$$\begin{aligned} \frac{\partial L(I_d, I_q, \lambda)}{\partial I_d} &= 0 \\ \frac{\partial L(I_d, I_q, \lambda)}{\partial I_q} &= 0 \\ \frac{\partial L(I_d, I_q, \lambda)}{\partial \lambda} &= 0 \end{aligned} \quad (2.85)$$

$I_{f,1,var}$	$L(I_d, I_q, \lambda) \rightarrow \max!$	$I_{d,1}$	$I_{q,1}$
$\vdots$		$I_{d,2}$	$I_{q,2}$
$\vdots$	$\Rightarrow$	$\vdots$	$\vdots$
$I_{f,n,var}$	(2.85)	$I_{d,n}$	$I_{q,n}$

$\Psi(I)$	$\Psi_{d,1}, \Psi_{q,1}$	$Q_{SGS,1}, P_{SGS,1}$
	$\Psi_{d,2}, \Psi_{q,2}$	Q, P
$\Rightarrow$	$\vdots$	$\Rightarrow$
$(2.63), (2.64)$	$\Psi_{d,n}, \Psi_{q,n}$	$(2.49), (2.50)$
		$Q_{SGS,n}, P_{SGS,n}$

(2.86)

Taj sustav također se može riješiti Newtonovom metodom i za svaku $I_{f,var}$ dolazi se do I_d, I_q , što predstavlja trojku pomoću koje se mogu izračunati koordinate (Q, P) konkretne radne točke

ekstrema u koordinatnom sustavu pogonske karte. Ponavljanjem istog postupka prikazanog na dijagramu toka 2.86 i za sve ostale proizvoljne $I_{f,var}$ u zoni nižih vrijednosti dobivaju se nove trojke, tj. nove koordinate, čijim povezivanjem se dobiva krivulja statičke granice stabilnosti.

2.5.4 Praktična granica stabilnosti

Za svaku proizvoljno variranu vrijednost struje uzbude $I_{f,var}$ prvo se izračuna prekretna snaga generatora metodom opisanom u dijagramu toka (2.86). Zatim se iz izraza za djelatnu snagu (2.49) za koju se prekretna snaga umanjuje za 0,1 p.u. prema dijagramu toka 2.87 za svaku variranu $I_{f,var}$ metodom optimiranja DE pronalaze veličine I_d i I_q za kompletiranje trojke potrebne za izračun ulančenih tokova pomoću polinomnih funkcija $\Psi(I)$. Njihovim uvrštavanjem u izraze za električnu djelatnu i jalovu snagu (2.49) i (2.50) dobivaju se koordinate točke na praktičnoj granici stabilnosti za prikaz na pogonskoj karti.

$$\begin{array}{ccc}
 I_{f,1,var} & & I_{d,1} \quad I_{q,1} \\
 \vdots & (P(\Psi_d, \Psi_q, I_d, I_q) - (P_{SGS} - 0,1))^2 \rightarrow \min! & I_{d,2} \quad I_{q,2} \\
 \vdots & \text{=====} \Rightarrow & \vdots \quad \vdots \\
 I_{f,n,var} & (2.49) & I_{d,n} \quad I_{q,n}
 \end{array}$$

$$\begin{array}{ccc}
 & \Psi_{d,1}, \Psi_{q,1} & Q_{PGS,1}, P_{PGS,1} \\
 \Psi(I) & \Psi_{d,2}, \Psi_{q,2} & Q, P \quad Q_{PGS,2}, P_{PGS,2} \\
 \text{=====} \Rightarrow & \vdots & \text{=====} \Rightarrow \quad \vdots \\
 (2.63), (2.64) & \Psi_{d,n}, \Psi_{q,n} & (2.49), (2.50) \quad Q_{PGS,n}, P_{PGS,n} \\
 & & (2.87)
 \end{array}$$

2.6 Diferencijalna evolucija

Diferencijalna evolucija (DE) je postupak globalnog optimiranja koji se koristi u razvoju i identifikaciji $\Psi(I)$ modela, kao i u njegovoj daljnjoj primjeni, pa je u ovom poglavlju napravljen pregled njegovih teoretskih postavki.

Algoritam DE ima cilj pronalaženja globalnog rješenja optimuma problema među populacijom od S probnih vektora. Tri slučajno odabrana vektora obrađuju se tako da se jedan vektor zbroji s razlikom druga dva vektora pomnoženom težinskim koeficijentom. Prema toj razlici

(diferencija), algoritam DE je dobio ime. Općeniti problem optimizacije definira se sljedećom formulacijom:

Za funkciju cilja (eng. objective function, u nekim izvorima naziva se i funkcija cijene eng. cost function)

$$f : X \subseteq \mathbb{R}^D \rightarrow \mathbb{R} \quad (2.88)$$

u kojoj skup svih mogućih rješenja optimizacijskog problema X nije prazan, minimizacijski problem rješava se pronalaženjem:

$$\underline{x} \in X \text{ za kojeg vrijedi } f(\underline{x}) \leq f(x), \forall x \in X, f(\underline{x}) \neq -\infty \quad (2.89)$$

U slučajevima višeciljne optimizacije funkcija cilja može se sastojati i od više funkcija [102]:

$$f_t(\underline{x}), t = 1, 2, \dots, T \quad (2.90)$$

2.6.1 Inicijalizacija

U postupku optimizacije funkcije f s D realnih parametara, x_i , $i = 1, \dots, D$, prvo se definira područje pretrage sa svojim donjim ($x_i^{\min}$, $i = 1, \dots, D$) i gornjim granicama ($x_i^{\max}$, $i = 1, \dots, D$). Istraživanje područja pretrage može biti podvrgnuto ograničenjima matematički izraženim jednadžbama $l_m(\underline{x})$, $m = 1, \dots, M$ ili nejednadžbama $u_n(\underline{x})$, $n = 1, \dots, N$.

Primjenjuje se iterativni proces kroz G generacija nad vektorima sadržanima u populaciji veličine N_p , koja mora biti veća od 3. Parametri vektora izražavaju se sljedećim oblikom:

$$\underline{x}_{j,k} = [x_{1,j,k}, x_{2,j,k}, \dots, x_{i,j,k}, \dots, x_{D,j,k}], i = 1, 2, \dots, D, j = 1, 2, \dots, N_p, k = 1, 2, \dots, G \quad (2.91)$$

U inicijalnoj fazi probni vektor $\underline{x}_{j,0}$, $j = 1, 2, \dots, N_p$ određuje se uzimanjem uzoraka u području pretrage s ravnomjernom vjerojatnošću zadovoljavanjem sljedećeg odnosa:

$$x_{i,j,0} = rand(i, j) x_{i,j,0}^{\max} + [1 - rand(i, j)] x_{i,j,0}^{\min} \quad (2.92)$$

gdje je $rand(i, j)$ stohastička varijabla ravnomjerno raspoređena unutar $rand \in [0, 1]$ i varira s indeksima i i j ili se stohastički generira oko pretpostavljenog rješenja s normalnom distribucijom [103, 104]. Tijekom iterativnog procesa generiraju se nova rješenja (djeca) koja se zadržavaju u populaciji za daljnje iteracije ukoliko imaju bolje vrijednosti funkcije cilja u odnosu na prethodne iteracije (roditelje). U svakoj generaciji, tj. iteraciji provode se obavezni

koraci sljedećim redosljedom: prvo mutacija, zatim rekombinacija i završno selekcija. Mutacijom se dobiva mutantski vektor (eng. mutant vector) $\underline{v}_{j,k}$, rekombinacijom probni vektor (eng. trial vector) $\underline{u}_{j,k}$ i selekcijom se dobiva ciljni vektor (eng. target vector) $\underline{x}_{j,k}$.

2.6.2 Mutacija

Mutacija proširuje donorske vektore kroz prostor potrage rješenja. Za svaki vektor u populaciji i generaciji $\underline{x}_{j,k}$ izračunava se mutantski vektor prema sljedećem:

$$\underline{v}_{j,k} = \underline{x}_{\alpha,k} + F \sum_y \left[\underline{x}_{\beta_y,k} - \underline{x}_{\gamma_y,k} \right], \quad k = 1, 2, \dots, G \quad (2.93)$$

gdje je F mutacijski faktor. To je konstanta na intervalu $[0, 2]$ koja kontrolira brzinu i robustnost potrage rješenja. Smanjenjem njegove vrijednosti povećava se vjerojatnost konvergencije, ali isto tako i povećava rizik od zaustavljanja u lokalnom ekstremu. Varijabla y je broj diferencijalnih varijacija, a α , β_y i γ_y su slučajno odabrani indeksi pod uvjetom da su međusobno različiti ($\alpha \neq \beta_y \neq \gamma_y$). Vektori $\underline{v}_{j,k}$ i $\underline{x}_{\alpha,k}$ nazivaju se primarni i sekundarni roditelj, a $\underline{x}_{\beta_y,k}$ i $\underline{x}_{\gamma_y,k}$ su donorski vektori. Iz 2.93 se jednostavno može registrirati da diferencijalne varijacije određuju “smjer” mutacije, a mutacijski faktor F skalira veličinu koraka traženja. Kao rezultat, diferencijalna mutacija djeluje kao lokalno pretraživanje u regijama prostora parametara pokrivenih primarnim roditeljima. Odabir sekundarnih roditelja po raznim načelima ($\alpha = j$ ili $\alpha = \text{najbolji}$ ili $\alpha = \text{slučajni}$) uvelike utječe na evoluciju u postupku pretraživanja. Postoje unaprijedne strategije koje djeluju tako da tijekom iterativnog procesa prilagođavaju mutaciju [105, 106].

2.6.3 Rekombinacija

Rekombinacija koristi rješenja od prijašnje generacije i njihove mutacije. Probni vektor $\underline{u}_{j,k}$ tvori se od pojedinih elemenata ciljnog vektora $\underline{x}_{j,k}$ (primarni roditelj) i pojedinih elemenata mutirajućeg vektora $\underline{v}_{j,k}$ križanjem u D točaka i ovisno o slučajno odabranim realnim brojevima iz intervala $[0, 1]$ [107]. U literaturi su uglavnom korištene dvije osnovne metode rekombinacije: binomna rekombinacija [95] i eksponencijalna rekombinacija [108]. U prvoj metodi probni vektor se tvori na sljedeći način:

$$u_{i,j,k} = \begin{cases} v_{i,j,k} & \text{ako je } rand(i, j) \leq \eta_{CR} \\ x_{i,j,k} & \text{ostalo} \end{cases}, \quad i = 1, \dots, D \quad (2.94)$$

gdje je vjerojatnost križanja (eng. crossover) η_{CR} ulazna konstanta iz intervala $[0, 1]$. Elementi mutanskog vektora ulaze u probni vektor s vjerojatnošću η_{CR} . Druga metoda, eksponencijalna

rekombinacija bazirana je na drugačiji način:

$$u_{i,j,k} = \begin{cases} v_{i,j,k} & \text{ako je } L_1 \leq n \leq L_2 \\ x_{i,j,k} & \text{ostalo} \end{cases}, \quad i = 1, \dots, D \quad (2.95)$$

gdje su L_1, L_2 slučajni cijeli brojevi prema rasponu $1 \leq L_1 \leq L_2 \leq D$.

2.6.4 Selekcija

Selekcija funkcionira deterministički, odbacujući lošije vektore, tj. vektore sa slabijom vrijednošću funkcije cilja. Ciljni vektor novonastajuće generacije $x_{i,j,k+1}$ nastaje selekcijom između probnog vektora $u_{i,j,k}$ nastalog rekombinacijom i ciljnog vektora $x_{i,j,k}$ starije generacije. Usporedbom tih dvaju vektora odabire se onaj s boljom vrijednošću funkcije cilja (tj. manjom funkcijskom vrijednosti) i taj prolazi u sljedeću generaciju.


$$\underline{x}_{j,k+1} = \begin{cases} \underline{u}_{j,k} & \text{ako je } f(\underline{u}_{j,k}) \leq f(\underline{x}_{j,k}) \\ \underline{x}_{j,k} & \text{ostalo} \end{cases} \quad (2.96)$$

Selekcija predstavlja elitizam jer se prosječna funkcijska vrijednost nikada ne pogoršava.

2.6.5 Postupak izračuna

Mutacija, rekombinacija i selekcija nastavljaju se iterativno iz generacije u generaciju, kao što je prikazano na slici 2.6, sve dok se ne zadovolji neki postavljeni uvjet zaustavljanja algoritma.

U uvjetu zaustavljanja najčešće se zadaje postizanje broja odrađenih generacija G ili postizanje zadane vrijednosti funkcije cilja, pri čemu se zadaje točnost rezultata. Veći broj generacija svakako poboljšava točnost rezultata, međutim time se produljuje vrijeme izvršavanja algoritma. Klasično podešenje mutacijskog faktora je $F = 0,5 \div 0,8$, a vjerojatnosti križanja konstanti je $\eta_{CR} = 0,8 \div 0,9$. Na funkciji $f(\underline{x})$ pomoću DE može se tražiti maksimum na taj način da se opisani postupak primijeni na funkciji $h(\underline{x}) = -f(\underline{x})$.



Slika 2.6: Dijagram toka diferencijalne evolucije


Poglavlje 3

Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora


3.1 Izvod modela

Osnovni problem pri postavljanju modela čija namjena bi bila izračunavanje granica pogonske karte je u tome što traženi model treba čim točnije opisivati ponašanje stroja u rubnom području oko granica pogonske karte i izvan njih, a u tom području u praksi na velikim generatorima u komercijalnoj upotrebi nije moguće napraviti mjerenja na kojima bi se taj model identificirao. Dakle, potrebno je pronaći takav model koji bi na osnovi poznatog ponašanja stroja u dozvoljenom području rada čim točnije opisivao ponašanje stroja u nedozvoljenom području rada, tj. izvan granica pogonske karte. U sklopu razvoja modela, za njegovu validaciju potrebno je poznavati elektromagnetske prilike i u radnim točkama izvan zone dozvoljenog radnog područja. Budući da mjerenje takvih točaka nije moguće, preostaje do potrebnih podataka doći izračunom, a zbog dosljednosti u razvoju modela bitno je da su za oba skupa, za identifikaciju i validaciju, s ciljem izbjegavanja diskontinuiteta primijenjene točke koje su dobivene na isti način. Za ovakav izračun prikladna je metoda konačnih elemenata (MKE), koja je u razvoju modela odabrana kao referentna. Tom metodom izračunate su potrebne radne točke i pojedine granice pogonske karte. Bitno je naglasiti da ovaj izračun nije postupak koji bi se provodio za svaki konkretni sinkroni generator u identifikaciji postavljenog modela, već za razvoj zajedničkog univerzalnog modela za sve sinkrone generatore, pa brzina postupka nije bitna, ali čim veća točnost svakako jest. Stoga su područja identifikacije i validacije podijeljena u dvije zasebne zone rada generatora: unutarnja zona u kojoj je realno moguće napraviti mjerenja radnih točaka

prikazana na slici 3.1a, koja se koristi za identifikaciju modela i vanjska zona u kojoj je s aspekta modeliranja rubno dozvoljenih stanja generatora (npr. granica pogonske karte) potrebna čim veća točnost modela prikazana na slici 3.1b, koja se koristi za validaciju modela.



(a)



(b)

Slika 3.1: Unutarnja zona za identifikaciju modela (a) i vanjska zona za validaciju modela (b)

U tablici A.1 u Dodatku A prikazano je 136 radnih točaka u izvornom obliku u fizikalnim veličinama, izračunatih pomoću MKE. Dobivene točke za identifikaciju modela nadalje su obrađene tako da su prevedene u "per unit" (p.u.) veličine, preračunate u dvoosni $d - q$ koordinatni sustav i prikazane su u tablici A.3. Nazivne veličine analiziranog generatora agregata br. 1 u HE Vinodol prikazane su u tablici 3.1 i korištene su kao bazne za preračunavanje u p.u. vrijednosti. Bazna vrijednost uzbudne struje je $I_{f0} = 391\text{A}$, što odgovara uzbudi praznog hoda.


Tablica 3.1: Nazivni podaci analiziranog generatora

Sinkroni generator G1 HE Vinodol	
Nazivna snaga	35 MVA
Nazivni napon	10,5 kV
Frekvencija	50 Hz
Nazivna struja	1925 A
Nazivna brzina	500 min ⁻¹
Nazivni faktor snage	0,9
Nazivna uzbudna struja	643 A

Nakon razvoja univerzalnog modela, navedeni skup radnih točaka će se za korištenje u identifikaciji modela pojedinog konkretnog generatora dobivati mjerenjem. Za sada, u fazi razvoja univerzalnog modela, zbog konzistentnosti s vanjskim točkama za validaciju razvijanog modela, ovaj skup radnih točaka dobiven je pomoću MKE. Skup podataka postavljenih mjernih točaka, uz standardne armaturne veličine kao što su napon, struja, djelatna i jalova snaga, obuhvaća uzbudnu struju I_f i kut opterećenja δ . U obradi i pripremi podataka mjernih točaka za razvoj modela veličine I_d , I_q , Ψ_d i Ψ_q izračunavaju se prema (2.60), (2.61) i (2.62).

Također, tablici A.2 u Dodatku A prikazano je 127 radnih točaka za validaciju modela, u izvornom obliku u fizikalnim veličinama, izračunatih pomoću MKE, a u tablici A.4 su prikazane radne točke za validaciju, obrađene za razvoj modela.


Radne točke za ulančene tokove u d-osi Ψ_d prikazane su u grafičkom obliku na slici 3.2, u koordinatama pogonskog dijagrama (Q-P) zbog lakšeg pregleda, te dvodimenzionalno i trodimenzionalno za bolji uvid u ponašanje ulančenih tokova. Na isti način, na slici 3.3 prikazane su radne točke za ulančene tokove u q-osi Ψ_q . Za određivanje radnih točaka uzet je rad generatora na krutoj mreži, pri čemu je odstupanje iznosa napona na stezaljkama generatora bilo $\pm 2\%$ od nazivnog. Vidljivo je da se u magnetsko zasićenje u direktnoj osi ulazi s povećavanjem jalove snage vrlo rano, tj. već u kapacitivnom dijelu radnog područja, s koljenom u zoni raspona jalove snage od $-1,2$ p.u. pri manjim djelatnim snagama, do $-0,5$ p.u. pri većim djelatnim snagama.



Slika 3.2: Radne točke za identifikaciju (X) i validaciju (●) modela $\Psi_d = f(Q, P, U)$, $U = 1$ p.u.

U zasićenje u poprečnoj osi ulazi se smanjivanjem jalove snage u kapacitivnom dijelu radnog područja, s koljenom u zoni raspona jalove snage od $-0,4$ p.u. pri većim djelatnim snagama, do $-1, 1$ p.u. pri manjim djelatnim snagama.

Za polinomne $\Psi(I)$ funkcije opisane u poglavlju 2.3 napravljena je identifikacija i validacija stacionarnog modela sinkronog generatora na pripremljenom skupu radnih točaka, kako je opisano u potpoglavlju 2.4 te su dobivene konstante polinoma $d_1, \dots, d_{20}$ i $q_1, \dots, q_{20}$ navedene u tablicama 3.2 i 3.3.



Slika 3.3: Radne točke za identifikaciju (X) i validaciju (●) modela $\Psi_q = f(Q, P, U)$, $U = 1$ p.u.

Točnost identificiranih polinomnih $\Psi(I)$ funkcija ocijenjena je temeljem maksimalne i srednje apsolutne greške između postavnih vrijednosti ulančenih tokova dobivenih pomoću MKE za identifikaciju i validaciju modela, te vrijednosti ulančenih tokova dobivenih pomoću identificiranih funkcija $\Psi_d(I_d, I_q, I_f)$ i $\Psi_q(I_d, I_q, I_f)$, prema (3.1).

$$\begin{aligned}
 E_{maks\psi_d} &= \max(|\psi_{d,i} - \psi_d(I_{d,i}, I_{q,i}, I_{f,i})|), \quad \text{za } i = 1 \dots n \\
 E_{maks\psi_q} &= \max(|\psi_{q,i} - \psi_q(I_{d,i}, I_{q,i}, I_{f,i})|), \quad \text{za } i = 1 \dots n \\
 E_{sred\psi_d} &= \langle |\psi_{d,i} - \psi_d(I_{d,i}, I_{q,i}, I_{f,i})| \rangle, \quad \text{za } i = 1 \dots n \\
 E_{sred\psi_q} &= \langle |\psi_{q,i} - \psi_q(I_{d,i}, I_{q,i}, I_{f,i})| \rangle, \quad \text{za } i = 1 \dots n
 \end{aligned} \tag{3.1}$$

Po istom kriteriju točnost identificiranih polinomnih $\Psi(I)$ funkcija uspoređena je s klasičnim modelom opisanim pomoću konstantnih reaktancija X_d i X_q identificiranih metodom najmanjih kvadrata na sljedeći način:

$$X_d = \frac{\sum \Psi_{f,i} I_{d,i} + \sum \Psi_{d,i} I_{d,i}}{\sum I_{d,i}^2} \quad (3.2)$$

$$X_q = \frac{\sum \Psi_{q,i} I_{q,i}}{\sum I_{q,i}^2} \quad (3.3)$$

Za analizirani generator agregata br. 1 u HE Vinodol prikazanom metodom dobivene su vrijednosti $X_d = 1,771$ p.u. i $X_q = 0,656$ p.u., te su klasičnim modelom ulančeni tokovi u direktnoj i poprečnoj osi izračunati prema:

$$\begin{aligned} \Psi_{d,i,kl}(I_{d,i}, I_{f,i}) &= \Psi_{f,i} + X_d I_{d,i} \\ \Psi_{q,i,kl}(I_{q,i}) &= X_q I_{q,i} \end{aligned} \quad (3.4)$$

Izračunate greške polinomnih $\Psi(I)$ funkcija i klasičnog modela te njihova usporedba prikazani su u tablici 3.4, u kojoj se može vidjeti da polinomne $\Psi(I)$ funkcije daju prosječno točnije vrijednosti od klasičnog modela u cijelom promatranom području, od čega im je točnost u području njihove identifikacije za 3 reda veličine bolja. Međutim, u području izvan njihove identifikacije, tj. u zonama koje su određene za validaciju modela, polinomne $\Psi(I)$ funkcije daju samo 1,5 (q-os) do 2,5 (d-os) puta prosječno točnije vrijednosti, a maksimalne vrijednosti grešaka imaju veće iznose od klasičnog modela koji je linearan i ne obuhvaća pojave poput efekta poprečne magnetizacije, dok u nekim točkama mogu poprimiti i ekstremno velike vrijednosti (1,325 p.u.). Polinomne funkcije korištene u interpolaciji imaju slabu točnost izvan zone identifikacije, gdje brzo prestaju pratiti fizikalne funkcije na čije su točke interpolirane u zoni identifikacije. Iz navedenog proizlazi zaključak da je za modeliranje stacionarnih stanja sinkronog generatora potrebno, poput u [109], postaviti funkcije koje prate prirodnu B-H krivulju magnetiziranja željeza aktivnih dijelova sinkronog generatora.

Zbog prikazanih nedostataka polinomnog $\Psi(I)$ modela ističe se potreba za drugačijim mo-

Tablica 3.2: Vrijednosti koeficijenata $d_1, \dots, d_{20}$ identificirane polinomne funkcije $\Psi_d(I_d, I_q, I_f)$

Koeficijent:	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}
Vrijednost:	-1,682	9,161	0,786	6,736	-10,986	-0,347	-5,873	-1,959	-16,075	-1,43
Koeficijent:	d_{11}	d_{12}	d_{13}	d_{14}	d_{15}	d_{16}	d_{17}	d_{18}	d_{19}	d_{20}
Vrijednost:	4,56	0,019	1,819	1,24	10,098	0,142	0,182	7,455	0,644	1,773

Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora

Tablica 3.3: Vrijednosti koeficijenata $q_1, \dots, q_{20}$ identificirane polinomne funkcije $\Psi_q(I_d, I_q, I_f)$

Koeficijent:	q_1	q_2	q_3	q_4	q_5	q_6	q_7	q_8	q_9	q_{10}
Vrijednost:	2,03	-8,33	-1,607	-5,574	11,415	0,746	5,362	5,522	15,785	3,729
Koeficijent:	q_{11}	q_{12}	q_{13}	q_{14}	q_{15}	q_{16}	q_{17}	q_{18}	q_{19}	q_{20}
Vrijednost:	-5,225	0,013	-1,821	-3,224	-11,057	-1,088	-0,771	-7,838	-1,519	-4,37

Tablica 3.4: Usporedba grešaka polinomnih $\Psi(I)$ funkcija i klasičnog modela

Greška modela, p.u.		d-os			q-os		
		Ident.	Valid.	Sve	Ident.	Valid.	Sve
Maks.	Klasični	0,3174	0,5543	0,5543	0,1466	0,1773	0,1773
	Polinom.	0,00044	1,3249	1,3249	0,00095	0,3844	0,3844
Sred.	Klasični	0,1619	0,2223	0,1911	0,0469	0,059	0,0527
	Polinom.	0,00011	0,0872	0,0421	0,00032	0,0373	0,0182

delom koji je dovoljno točan u opisivanju stacionarnih stanja sinkronog generatora na rubu i izvan granica pogonske karte, premda identificiranom na užem skupu radnih točaka, gdje je realno provedivo dozvoljeno mjerenje, a to je unutar dozvoljenog radnog područja. Cilj je postaviti univerzalni model za opisivanje stacionarnih stanja, koji bi se za svaki sinkroni generator mogao identificirati na skupu radnih točaka izmjerenih u dozvoljenom radnom području, a s dovoljnom točnošću bi opisivao elektromagnetske pojave stroja u stacionarnim uvjetima na granicama pogonske karte i izvan njih, tj. izvan zone dozvoljenog radnog područja.

Stoga su u razvoju modela umjesto polinomnih odabrane sigmoidne funkcije čiji se oblik dobro poklapa s prirodnom krivuljom magnetiziranja aktivnih dijelova sinkronog generatora, koja je odraz magnetskog zasićenja i drugih nelinearnih pojava, poput efekta poprečne magnetizacije. Postavljena je osnovna sigmoidna funkcija s jednom varijablom, koja glasi:

$$f(x) = a_1 \cdot x + a_2 \cdot \frac{x}{\left(a_3 + \left|\frac{x}{a_4}\right|^{a_5}\right)^{\frac{1}{a_5}}} \quad (3.5)$$

Aproksimacija mjerenih podataka krivulje praznog hoda sigmoidnom funkcijom napravljena je metodom najmanjih kvadrata pomoću "Trust-Region" algoritma. Provedenom aproksimacijom postignuti su njeni pokazatelji s izvrsnim vrijednostima koeficijenta determinacije $R^2 = 0,9999$ i sume kvadrata $SS_E = 0.0004439$. Koeficijent determinacije je omjer zbrojeva kvadrata (3.6) i što mu je vrijednost bliža jedinici to je regresijski model reprezentativniji, tj. aproksimacija bolja.

$$R^2 = \frac{SS_R}{SS_T} = 1 - \frac{SS_E}{SS_T} \quad 0 \leq R^2 \leq 1 \quad (3.6)$$

gdje su:


- $SS_E = \sum_{i=1}^n (y_i - \hat{y}_i)^2$ (engl. sum of squares error), suma kvadrata odstupanja stvarnih vrijednosti zavisne varijable od pripadajućih vrijednosti funkcije kojom su stvarne vrijednosti zavisne varijable aproksimirane
- $SS_R = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$ (engl. sum of squares due to regression), suma kvadrata odstupanja vrijednosti funkcije kojom su stvarne vrijednosti zavisne varijable aproksimirane od prosjeka stvarnih vrijednosti zavisne varijable
- $SS_T = \sum_{i=1}^n (y_i - \bar{y})^2$ (engl. sum of squares total), suma kvadrata odstupanja stvarnih vrijednosti zavisne varijable od njihova prosjeka

U tablici 3.5 prikazane su vrijednosti koeficijenata sigmoidne funkcije (3.5) aproksimirane na krivulju praznog hoda generatora agregata br. 1 u HE Vinodol.

Tablica 3.5: Vrijednosti koeficijenata $a_1, \dots, a_5$ sigmoidne funkcije $f(x)$ aproksimirane na krivulju praznog hoda sinkronog generatora

Koeficijent:	a_1	a_2	a_3	a_4	a_5
Vrijednost:	0,07371	1,72	4,903	-0,6348	3,946

Na slici 3.4 prikazana je usporedba krivulje praznog hoda generatora agregata br. 1 u HE Vinodol izražene s mjerenim točkama sa sigmoidnom funkcijom koja je aproksimirana na nju, gdje je vidljivo međusobno dobro poklapanje.



Slika 3.4: Snimljene točke krivulje praznog hoda sinkronog generatora (●) i s njima aproksimirana sigmoidna funkcija (—)

S ciljem da model stacionarnih stanja sinkronog generatora prirodno prati fizikalne pojave poput magnetskog zasićenja željeza i efekta poprečne magnetizacije, ulančeni tokovi u uzdužnoj i poprečnoj osi izražavaju se funkcijama koje ovise o tri varijable – o strujama armature I_d i I_q

te o uzbudnoj struji I_f , na način da se definiraju poopćenim sigmoidnim funkcijama, prema sljedećem:

$$\Psi_d(I_d, I_q, I_f) = d_1 I_d + d_2 I_f + \left(\frac{d_3 I_d + d_4 I_f}{\left(d_5 + d_6 I_d^2 + d_7 I_q^2 + d_8 I_f^2 + |d_9 I_d + d_{10} I_f|^{d_{11}} \right)^{\frac{1}{d_{11}}}} \right) \quad (3.7)$$

$$\Psi_q(I_d, I_q, I_f) = q_1 I_q + \left(\frac{q_2 I_q}{\left(q_3 + q_4 I_d^2 + q_5 I_q^2 + q_6 I_f^2 \right)^{\frac{1}{q_7}}} \right) \quad (3.8)$$

Funkcije (3.7) i (3.8) nazivaju se sigmoidne $\Psi(I)$ funkcije i u fazi razvoja univerzalnog modela identificiraju se na pripremljenom skupu radnih točaka prikazanom u tablici A.3 i na slikama 3.2 i 3.3. Međutim sama struktura sigmoidnih $\Psi(I)$ funkcija nije pogodna za provođenje identifikacije na isti način kao kod polinomnih $\Psi(I)$ funkcija kako je opisano u potpoglavlju 2.4, tj. kombinacijom metode najmanjih kvadrata, diferencijalnog i matričnog izračuna, gdje je problem sveden na rješavanje sustava linearnih jednadžbi. Zbog složene nelinearne strukture sigmoidnih $\Psi(I)$ funkcija, u rješavanju problema identifikacije pribjeglo se je heurističkoj metodi globalnog optimiranja Diferencijalnom evolucijom (DE), opisanoj u potpoglavlju 2.6. Stacionarne radne točke za identifikaciju definirane su četvorkama $I_{d,i}$, $I_{q,i}$, $I_{f,i}$, $\Psi_{d,i}$ za direktnu os i $I_{d,i}$, $I_{q,i}$, $I_{f,i}$, $\Psi_{q,i}$ za poprečnu os, izračunatima pomoću referentnog MKE modela. Identifikacija se provodi pomoću metode najmanjih kvadrata koja pronalazi takve koeficijente $d_1, d_2, \dots, d_{11}$ i $q_1, q_2, \dots, q_7$ s kojima bi suma kvadrata odstupanja funkcija za sve točke bila najmanja. Funkcije cilja za traženje globalnog minimuma definiraju se prema sljedećem:

$$G_d(d_1, d_2, \dots, d_{11}) = \sum_{i=1}^N [\Psi_{d,i} - \Psi_d(I_{d,i}, I_{q,i}, I_{f,i})]^2 \rightarrow \min! \quad (3.9)$$

$$G_q(q_1, q_2, \dots, q_7) = \sum_{i=1}^N [\Psi_{q,i} - \Psi_q(I_{d,i}, I_{q,i}, I_{f,i})]^2 \rightarrow \min! \quad (3.10)$$

Postupak optimiranja provodi se zasebno za direktnu i za poprečnu os. Prvo se provodi faza inicijalizacije u kojoj se postavljaju svi parametri za provođenje postupka optimiranja, opisani u potpoglavlju 2.6.1. Parametri koji su postavljeni s istim vrijednostima za postupak optimiranja za direktnu i za poprečnu os prikazani su u tablici 3.6. Parametri koji su specifični zasebno za svaku os prikazani su u tablicama 3.7 i 3.8. Svi parametri podešeni su na uobičajene predložene vrijednosti, osim parametra populacije N_{pd} i N_{pq} , za koje se je pokazalo da postupak bolje konvergira ako se njegova vrijednost, osim predloženih $10D$ odredi još cca 8 puta veća. Uz funkcije cilja nije bio potrebno postaviti nikakva funkcionalna ograničenja.

Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora

Tablica 3.6: Parametri postupka optimiranja koji su zajednički za direktnu i za poprečnu os

OPIS	PARAMETAR
Mutacijski faktor	$F_d = F_q = 0,8$
Vjerojatnost križanja	$\eta_{CR_d} = \eta_{CR_q} = 0,7$
Ciljana vrijednost funkcije cilja kao 1. uvjet završetka (eng. value to reach)	$VTR_d = VTR_q = 2 \cdot 10^{-5}$ p.u.
Broj generacija kao 2. uvjet završetka	$G_d = G_q = 50000$
Maksimalno vrijeme izvršavanja kao 3. uvjet završetka	$T_d = T_q = 5400$ s

Postupak optimiranja se prema dijagramu toka prikazanom na slici 2.6 nadalje iterativno provodi kroz generacije, sve dok se ne zadovolji jedan od postavljenih uvjeta zaustavljanja algoritma. Optimiranje je trajalo 1 sat i 8 minuta za identifikaciju sigmoidne funkcije u direktnoj osi i 53 minute za isto u poprečnoj osi, i u oba slučaja zaustavljeno je po uvjetu završetka postizanjem ciljne vrijednosti funkcije cilja. Ciljana vrijednost postignuta je kroz 36499 generacija, pri čemu je napravljeno 29199200 evaluacija za direktnu os te 27354 generacije i 23735414 evaluacija sigmoidne $\Psi(I)$ funkcije u poprečnoj osi. Pronađeni su globalni minimumi funkcija cilja $G_d(d_1, d_2, \dots, d_{11})$ i $G_q(q_1, q_2, \dots, q_7)$ u vrijednostima manjima od vrijednosti koje su postavljene kao uvjet završetka postupka optimiranja $VTR_d = VTR_q = 2 \cdot 10^{-5}$ p.u..

Tablica 3.7: Parametri postupka optimiranja koji su specifični za direktnu os

OPIS	PARAMETAR
Broj parametara vektora čija optimalna vrijednost se traži	$D_d = 11$
Minimalne vrijednosti parametara vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$d_{min} = [-1; -1; -1; -1; 0; 0; 0; 0; -10; -1; -1]$
Maksimalne vrijednosti parametara vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$d_{max} = [10; 10; 10; 10; 5000; 5000; 10000; 1000; 10; 10; 10]$
Populacija (premda se u postupku sugerira 10D, bolja konvergencija se postiže uz navedenu vrijednost parametra)	$N_{pd} = 800$

Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora

Tablica 3.8: Parametri postupka optimiranja koji su specifični za poprečnu os

OPIS	PARAMETAR
Broj parametara vektora čija optimalna vrijednost se traži	$D_q = 7$
Minimalne vrijednosti parametara vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$q_{min} = [-1; -1; 0; 0; 0; 0; -1]$
Maksimalne vrijednosti parametara vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$q_{max} = [2; 10; 10; 10; 10; 2; 2]$
Populacija (premda se u postupku sugerira 10D, bolja konvergencija se postiže uz navedenu vrijednost parametra)	$N_{p_q} = 500$

Pronađeni minimum funkcije cilja lociran je u 11-dimenzionalnom prostoru na koordinatama $d_1, d_2, \dots, d_{11}$ prikazanima u tablici 3.9, što su zapravo koeficijenti identificirane sigmoidne $\Psi(I)$ funkcije u direktnoj osi.

Tablica 3.9: Vrijednosti koeficijenata $d_1, d_2, \dots, d_{11}$ identificirane sigmoidne $\Psi(I)$ funkcije u direktnoj osi

Koeficijent:	d_1	d_2	d_3	d_4	d_5	d_6
Vrijednost:	0,529	0,155	2,736	4,01	2396,153	1706,259
Koeficijent:	d_7	d_8	d_9	d_{10}	d_{11}	
Vrijednost:	7164,97	910,583	4,51	4,185	5,643	

Na analogni način lociran je i minimum funkcije cilja za poprečnu os u 7-dimenzionalnom prostoru na koordinatama $q_1, q_2, \dots, q_7$, tj. koeficijentima identificirane sigmoidne $\Psi(I)$ funkcije u poprečnoj osi prikazanima u tablici 3.10.

Tablica 3.10: Vrijednosti koeficijenata $q_1, q_2, \dots, q_7$ identificirane sigmoidne $\Psi(I)$ funkcije u poprečnoj osi

Koeficijent:	q_1	q_2	q_3	q_4	q_5	q_6	q_7
Vrijednost:	0,368	4,114	1,054	0,00047	0,00023	0,009	0,021

Koeficijenti q_4 i q_5 sa svojim malim vrijednostima ukazuju da bi se pripadajući im članovi sigmoidne $\Psi(I)$ funkcije u poprečnoj osi mogli u ovom konkretnom slučaju izostaviti, ali zbog dosljednosti u formiranju univerzalnog modela zadržan je integralni oblik funkcije.

U tablici 3.11 prikazane su greške izračuna ulančenih tokova pomoću sigmoidnih $\Psi(I)$ funkcija


Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora

dobivene na isti način prema (3.1) i uspoređene s greškama izračuna polinomnih $\Psi(I)$ funkcija i klasičnog modela. Greške su izračunate na istim radnim točkama za identifikaciju i validaciju pripremljenim pomoću MKE.


Tablica 3.11: Usporedba grešaka klasičnog modela, sigmoidnih i polinomnih $\Psi(I)$ funkcija

Greška modela, p.u.		d-os			q-os		
		Ident.	Valid.	Sve	Ident.	Valid.	Sve
Maks.	Klasični	0,3174	0,5543	0,5543	0,1466	0,1773	0,1773
	Polinom.	0,00044	1,3249	1,3249	0,00095	0,3844	0,3844
	Sigmoid.	0,0013	0,0266	0,0266	0,0079	0,0995	0,0995
Sred.	Klasični	0,1619	0,2223	0,1911	0,0469	0,059	0,0527
	Polinom.	0,00011	0,0872	0,0421	0,00032	0,0373	0,0182
	Sigmoid.	0,00032	0,0063	0,0032	0,0018	0,0128	0,0071

Usporedbom grešaka može se zaključiti da sigmoidne $\Psi(I)$ funkcije imaju značajno manje srednje i maksimalne greške u cijelom području koje obuhvaća obje zone identifikacije i validacije. Također, u zoni validacije, sigmoidne $\Psi(I)$ funkcije imaju bitno veću točnost, bez velikih odstupanja u pojedinim radnim točkama. Zorni pregledi koji trodimenzionalno prikazuju greške modela u svim radnim točkama identifikacije i validacije, na osnovi kojih je napravljen statistički izračun grešaka u tablici 3.11, nalaze se zasebno za direktnu os na slici 3.5 i poprečnu os na slici 3.6. Zbog lakšeg pregleda i poistovjećivanja s pogonskom kartom, kao baza za trodimenzionalni prikaz grešaka je formirana ravnina njenog sustava (Q,P) koordinata. Rezultati




Slika 3.5: Greške ulančenih tokova u direktnoj osi u radnim točkama pripremljenima za identifikaciju izračunate pomoću sigmoidnih (●) i polinomnih (●) $\Psi(I)$ funkcija i u radnim točkama pripremljenima za validaciju izračunate pomoću sigmoidnih (●) i polinomnih (●) $\Psi(I)$ funkcija




Slika 3.6: Greške ulančenih tokova u poprečnoj osi u radnim točkama pripremljenima za identifikaciju izračunate pomoću sigmoidnih (●) i polinomnih (●) $\Psi(I)$ funkcija i u radnim točkama pripremljenima za validaciju izračunate pomoću sigmoidnih (●) i polinomnih (●) $\Psi(I)$ funkcija

izračuna grešaka klasičnog modela nisu prikazani na slikama grafičkih usporedbi jer su greške klasičnog modela do dva reda veće od uspoređivanih grešaka polinomnih i sigmoidnih $\Psi(I)$ funkcija, zbog čega ih na istom prikazu nije moguće vizualno uspoređivati. Na prikazanim tro-dimenzionalnim slikama vidljivo je veliko rasipanje točaka grešaka polinomne $\Psi(I)$ funkcije u zoni koja je korištena za validaciju, izvan zone dozvoljenog rada generatora, što govori da te funkcije nisu dobar alat za izračunavanje granica pogonske karte. Rasipanje u zoni validacije ruši ukupnu prosječnu točnost polinomnih $\Psi(I)$ funkcija, premda im je prosječna greška u zoni identifikacije najmanja među tri prikazana modela. Polinomne $\Psi(I)$ funkcije najprikladnije su za opisivanje stacionarnih stanja sinkronog generatora u zoni radnog područja gdje su identificirane. Zbog boljeg uvida u razlike točnosti polinomnih i sigmoidnih $\Psi(I)$ funkcija napravljena je usporedba grešaka izraženih paletom boja na četiri dvodimenzionalna grafa zasebno za direktnu i za poprečnu os, što je vidljivo na slici 3.7. Polinomne $\Psi(I)$ funkcije u manjem broju točaka u području validacije imaju puno veći iznos greške u odnosu na ostale radne točke koje su u znatnoj većini. Radne točke s velikom greškom bi na grafu tipa kao na slici 3.7 uzrokovale skalu palete boja s velikim rasponom u kojoj bi za preostali većinski broj radnih točaka greška zbog svojeg puno manjeg iznosa bila prikazana s gotovo nerazpoznatljivom razlikom vrlo sličnih nijansi boje, praktički skoro s istom bojom. Zbog toga je prikaz iznosa grešaka polinomnih funkcija paletom boja ograničen do iznosa 0,025 p.u. za d-os i do iznosa 0,1 p.u. za q-os. Kako bi se greške mogle jednostavno vizualno uspoređivati između sigmoidnih i polinomnih $\Psi(I)$ funkcija, također i područje izražavanja grešaka sigmoidnih $\Psi(I)$ funkcija ograničeno je do iznosa 0,025 p.u. za d-os i do iznosa 0,1 p.u. za q-os.

Zaključno, statistika grešaka modela u tablici 3.11 i grafički prikazi na slikama 3.5, 3.6 i 3.7 potvrđuju dobar put u postavljanju stabilnog modela za opisivanje stacionarnih stanja, koji bi se identificirao na skupu radnih točaka u užem području dozvoljenog rada u kojemu su dostupna i mjerenja, a dobro bi opisivao elektromagnetske pojave stroja na granicama pogonske karte i izvan njih, tj. izvan zone dozvoljenog radnog područja. Sigmoidne funkcije ulančenog toka omogućuju kvalitetan opis stroja u područjima dubokih zasićenja čak i u slučaju kada se identificiraju pomoću radnih točaka izvan područja zasićenja ili na njegovom rubnom dijelu. Prema navedenom, sigmoidne $\Psi(I)$ funkcije prikladne su za izračunavanje granica pogonske karte. Nadalje, predložen je izgled sigmoidnih $\Psi(I)$ funkcija.




Slika 3.7: Greške ulančenih tokova u direktnoj i poprečnoj osi u radnim točkama korištenim za identifikaciju i validaciju izračunate sigmoidnim $\Psi(I)$ funkcijama prikazane na grafovima a) i c) i polinomnim $\Psi(I)$ funkcijama prikazane na grafovima b) i d), izražene paletom boja



Slika 3.8: Ulančeni tokovi u direktnoj osi izračunati sigmoidnom $\Psi_d(I)$ funkcijom u radnim točkama korištenima za identifikaciju i validaciju, prikazani paletom boja u koordinatnom sustavu (I_d, I_q, I_f)


Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora

Ulančeni tokovi izračunati sigmoidnim $\Psi(I)$ funkcijama u radnim točkama korištenima za identifikaciju i validaciju izraženi su u trodimenzionalnom (I_d, I_q, I_f) prostoru paletom boja za direktnu os na slici 3.8 i za poprečnu os na slici 3.9. Zbog boljeg uvida u sigmoidne $\Psi_d(I)$




Slika 3.9: Ulančeni tokovi u poprečnoj osi izračunati sigmoidnom $\Psi_q(I)$ funkcijom u radnim točkama korištenima za identifikaciju i validaciju, prikazani paletom boja u koordinatnom sustavu (I_d, I_q, I_f)

funkcije, njihov oblik kroz paletu boja na rezovima u cjelokupnom (I_d, I_q, I_f) prostoru, koji u širem smislu obuhvaća radno područje sinkronog generatora i njegov okoliš prikazan je na slici 3.10 za direktnu os i na slici 3.11 za poprečnu os. Vidljivo je magnetsko zasićenje u direktnoj osi pri većim iznosima armaturne struje u direktnoj osi i uzbudne struje, kao i u poprečnoj osi pri većem iznosu armaturne struje u poprečnoj osi i manjem iznosu uzbudne struje.



Slika 3.10: Sigmoidna $\Psi(I)$ funkcija u direktnoj osi, prikazana paletom boja na rezovima u trodimenzionalnom koordinatnom sustavu (I_d, I_q, I_f) , izraženo u p.u. vrijednostima



Slika 3.11: Sigmoidna $\Psi(I)$ funkcija u poprečnoj osi, prikazana paletom boja na rezovima u trodimenzionalnom koordinatnom sustavu (I_d, I_q, I_f), izraženo u p.u. vrijednostima

3.2 Određivanje granica pogonske karte sinkronog generatora

Nakon određivanja koeficijenata $d_1, d_2, \dots, d_{11}$ i $q_1, q_2, \dots, q_7$ pomoću prethodno opisanog postupka optimiranja, sigmoidne $\Psi(I)$ funkcije su identificirane i mogu se koristiti za određivanje svih veličina stacionarnih radnih stanja u cijelom radnom području sinkronog generatora. Dio zanimljivih stacionarnih radnih točaka sinkronog generatora je u rubnom području pogonske karte u kojemu su određene granice dozvoljenog trajnog rada, a koje se mogu dobiti pomoću ovog modela. U nastavku su opisani načini određivanja pojedinih granica pogonske karte.

3.2.1 Granice konstantne struje armature i djelatne snage

Granica konstantne struje armature jednako kao i kod klasičnog modela i polinomnog $\Psi(I)$ modela, prema opisanom u poglavljima 2.2.4 i 2.5.1 jednostavno se opisuje kružnicom čiji polumjer je proporcionalan struji i naponu armature, kako je opisano u izrazu 2.44. Granice konstantne djelatne snage su također jednake kao i kod klasičnog modela i polinomnog $\Psi(I)$ modela, prema opisanom u poglavljima 2.2.4 i 2.5.1, trivijalne su i u pogonskoj karti opisane su horizontalnim linijama koje određuju donju granicu zbog tehnološkog minimuma pogonskog stroja i gornju granicu maksimalne dozvoljene trajne snage pogonskog stroja.

3.2.2 Granice uzbudne struje

Granice uzbudne struje određuju se tako da se definiraju minimalni i maksimalni iznos uz-

budne struje koji se u izračunu drže konstantnim:

$$\begin{aligned} I_{f,min} &= \text{konst.} = I_{f,min,konst} \\ I_{f,max} &= \text{konst.} = I_{f,max,konst} \end{aligned} \quad (3.11)$$

Budući da se granice izračunavaju za stacionarna stanja pri određenom konstantnom naponu na stezaljkama generatora, potrebno je jednadžbu koja definira napon armature (2.82), uz poznatu konstantnu struju uzbude $I_{f,konst}$, proizvoljnim variranjem različitih vrijednosti $I_{q,var}$ riješiti po I_d . Ulančeni magnetski tokovi računaju se pomoću sigmoidnih $\Psi(I)$ funkcija. Rješavanje 2.82 po I_d za svaku stacionarnu točku predstavlja rješavanje jedne nelinearne jednadžbe s jednom nepoznanicom, za čije rješavanje se koristi prethodno opisana heuristička metoda globalnog optimiranja DE. Za određeni konstantni napon na stezaljkama generatora U_{konst} postavlja se funkcija cilja $G_{KU}(I_d)$ za koju se traži minimum, prema sljedećem:

$$\begin{aligned} G_{KU}(I_q) &= (U - U_{konst})^2 = \\ &= \left(\sqrt{(\omega \Psi_d(I_d, I_{q,var}, I_{f,konst}) - I_{q,var}R)^2 + (-\omega \Psi_q(I_d, I_{q,var}, I_{f,konst}) - I_d R)^2} \right. \\ &\quad \left. - U_{konst} \right)^2 \rightarrow \min! \end{aligned} \quad (3.12)$$

Uz postavljenu funkciju cilja nije potrebno postaviti nikakva funkcionalna ograničenja. U fazi inicijalizacije svi parametri postupka optimiranja podešeni su na uobičajene predložene vrijednosti prilagođene funkciji cilja s jednim parametrom i prikazane u tablici 3.12. Postupak optimiranja za svaku točku na granici uzbudne struje se prema dijagramu toka prikazanom na slici 2.6 iterativno provodi kroz generacije, sve dok se ne zadovolji jedan od postavljenih uvjeta zaustavljanja algoritma. Optimiranja pojedinih točaka prosječno traju oko 40 milisekundi i redovno se zaustavljaju po uvjetu završetka postizanjem ciljane vrijednosti funkcije cilja. Ciljane vrijednosti postižu se prosječno kroz cca 21 generaciju i 210 evaluacija. Globalni minimumi funkcije cilja $G_{KU}(I_d)$ unutar uvjeta završetka postupka optimiranja $VTR = 1 \cdot 10^{-8}$ pronalaze se locirani na parametrima I_d .

Izračunati parametri funkcije cilja, što su u stvari struje armature u direktnoj osi $I_{d,i}$, uz variranu struju armature u poprečnoj osi $I_{q,i,var}$ i konstantnu struju uzbude $I_{f,konst}$ sačinjavaju trojku čijim se uvrštavanjem u izraze za jalovu (3.13) i djelatnu snagu (3.14) dobivaju koordinate radne točke za prikaz na pogonskoj karti.

$$Q_{KU,i} = \omega \left(-\Psi_d(I_{d,i}, I_{q,i,var}, I_{f,konst}) I_{d,i} - \Psi_q(I_{d,i}, I_{q,i,var}, I_{f,konst}) I_{q,i,var} \right) \quad (3.13)$$

$$\begin{aligned} P_{KU,i} &= \omega \left(\Psi_d(I_{d,i}, I_{q,i,var}, I_{f,konst}) I_{q,i,var} - \Psi_q(I_{d,i}, I_{q,i,var}, I_{f,konst}) I_{d,i} \right) \\ &\quad - (I_{d,i}^2 + I_{q,i,var}^2) R \end{aligned} \quad (3.14)$$

$$\begin{array}{cccc}
 I_{f,konst} & I_{q,1,var} & & I_{d,1} \\
 \vdots & I_{q,2,var} & G_{KU}(I_d) = (U - U_{konst})^2 \rightarrow \min! & I_{q,2} \\
 \vdots & \vdots & \Longrightarrow & \vdots \\
 I_{f,konst} & I_{q,n,var} & (3.12) & I_{d,n}
 \end{array} \tag{3.15}$$


$$\begin{array}{cccc}
 & \Psi_{d,1}, \Psi_{q,1} & & Q_{KU,1}, P_{KU,1} \\
 \Psi(I) & \Psi_{d,2}, \Psi_{q,2} & Q, P & Q_{KU,2}, P_{KU,2} \\
 \Longrightarrow & \vdots & \Longrightarrow & \vdots \\
 (3.7), (3.8) & \Psi_{d,n}, \Psi_{q,n} & (3.13), (3.14) & Q_{KU,n}, P_{KU,n}
 \end{array}$$

Prikazani postupak primjenjuje se za sve proizvoljno varirane vrijednosti $I_{q,i,var}$ za $i = 1 \dots n$ iz dijagrama toka 3.15 sa slijedom izračuna točaka granice uzbudne struje, čime se dolazi do

Tablica 3.12: Parametri postupka optimiranja za rješavanje (3.12) po I_q

OPIS	PARAMETAR
Mutacijski faktor	$F = 0,8$
Vjerojatnost križanja	$\eta_{CR} = 0,7$
Ciljana vrijednost funkcije cilja kao 1. uvjet završetka (eng. value to reach)	$VTR = 1 \cdot 10^{-8}$ p.u.
Broj generacija kao 2. uvjet završetka	$G = 100$
Maksimalno vrijeme izvršavanja kao 3. uvjet završetka	$T = 3$ s
Broj parametara vektora čija optimalna vrijednost se traži	$D_d = 1$
Minimalna vrijednost parametara vektora u prostoru u kojemu se traži rješenje	$d_{min} = -1,5$ p.u.
Maksimalna vrijednost parametara vektora u prostoru u kojemu se traži rješenje	$d_{max} = 1,5$ p.u.
Populacija	$N_p = 10$


koordinata ($Q_{KU,i}, P_{KU,i}$) drugih radnih točaka, čijim se povezivanjem postiže krivulja konstantne struje uzbude u pogonskoj karti, koje za minimalnu i maksimalnu uzbudnu struju predstavljaju dijelove granice pogonske karte. Na slikama 3.12, 3.13 i 3.14 prikazane su krivulje konstantne uzbude izračunate pomoću MKE, klasičnim modelom, polinomnim i sigmoidnim $\Psi(I)$ funkcijama pri konstantnim naponima na stezaljkama generatora u iznosima određenima na $U = 0,95$ p.u., $U = 1,00$ p.u. i $U = 1,05$ p.u.. Krivulje su izračunate za iznose uzbudne struje I_f fiksirane na vrijednosti 0,0 p.u., 0,2 p.u., 0,5 p.u., 1,0 p.u., 1,5 p.u. i 2,0 p.u.. Krivulje konstantne uzbude izračunate su pomoću MKE za iznose minimalne (0,2 p.u.) i maksimalne struje uzbude (2,0 p.u.), kao bitnih krajnjih vrijednosti koje se realno u praksi postižu. Najbolje poklapanje s referentnim modelom dobivenim pomoću MKE (krivulje označene punim kružićima) postižu krivulje izračunate pomoću sigmoidnih $\Psi(I)$ funkcija (crtkane krivulje). Krivulje konstantne uzbude dobivene pomoću polinomnih $\Psi(I)$ funkcija (pune linije), u područjima izvan zona u kojima su te funkcije identificirane, gube svoj fizikalni smisao odstupajući značajno od oblika sličnog Pascalovim krivuljama. To potvrđuje statistika točnosti modela prikazana




Slika 3.12: Krivulje konstantne uzbude pri konstantnom naponu na stezaljkama generatora $U = 0,95$ p.u.

u tablici 3.11 i njeno tumačenje te motiv za istraživanjem modela koji bolje prati magnetsko zasićenje stroja. Krivulje izračunate klasičnim modelom bitno drugačije su pozicionirane od ostalih modela i može se zaključiti da svojim rasprostranjem od minimalne do maksimalne uzbudne struje kroz užu površinu pogonskog dijagrama prekonzervativno opisuju dozvoljeno radno područje generatora.

Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora



Slika 3.13: Krivulje konstantne uzbude pri konstantnom naponu na stezaljkama generatora $U = 1,00$ p.u.



Slika 3.14: Krivulje konstantne uzbude pri konstantnom naponu na stezaljkama generatora $U = 1,05$ p.u.

3.2.3 Statička granica stabilnosti

Statička granica stabilnosti dobiva se tako da se za svaki iznos uzbudne struje $I_{f,var}$ koji se varira u nizu unutar definiranog raspona traže koordinate maksimuma funkcije

$$P_{SGS}(I_d, I_q, I_{f,var}) = \omega (\Psi_d(I_d, I_q, I_{f,var}) I_q - \Psi_q(I_d, I_q, I_{f,var}) I_d) - (I_d^2 + I_q^2) R \quad (3.16)$$

uz ispunjavanje uvjeta konstantnog napona

$$U_{konst}(I_d, I_q, I_{f,var}) = \sqrt{(\omega \Psi_d(I_d, I_q, I_{f,var}) - I_q R)^2 + (-\omega \Psi_q(I_d, I_q, I_{f,var}) - I_d R)^2} \quad (3.17)$$

Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora

Tablica 3.13: Parametri postupka optimiranja za rješavanje (3.18) po I_d i I_q

OPIS	PARAMETAR
Mutacijski faktor	$F = 0,8$
Vjerojatnost križanja	$\eta_{CR} = 0,7$
Ciljana vrijednost funkcije cilja kao 1. uvjet završetka (eng. value to reach)	<i>Global.</i> <i>Min.</i>
Broj generacija kao 2. uvjet završetka	$G = 100$
Maksimalno vrijeme izvršavanja kao 3. uvjet završetka	$T = 1 \text{ s}$
Broj parametara vektora čija optimalna vrijednost se traži	$D_d = 2$
Minimalna vrijednost parametara vektora u prostoru u kojemu se traži rješenje	$d_{min} = -1,5 \text{ p.u.}$
Maksimalna vrijednost parametara vektora u prostoru u kojemu se traži rješenje	$d_{max} = 1,5 \text{ p.u.}$
Populacija	$N_p = 20$

Za optimizacijski algoritam DE koji traži minimum postavlja se funkcija cilja:

$$\begin{aligned}
 G_{SGS}(I_d, I_q) &= -P_{SGS}(I_d, I_q, I_{f,var}) = \\
 &= -(\omega(\Psi_d(I_d, I_q, I_{f,var}) I_q - \Psi_q(I_d, I_q, I_{f,var}) I_d) - (I_d^2 + I_q^2) R) \rightarrow \min!
 \end{aligned} \quad (3.18)$$

uz postavljeno funkcionalno ograničenje

$$\begin{aligned}
 |U - U_{konst}| &= \\
 &= \left| \sqrt{(\omega \Psi_d(I_d, I_q, I_{f,var}) - I_q R)^2 + (-\omega \Psi_q(I_d, I_q, I_{f,var}) - I_d R)^2} - U_{konst} \right| \leq 10^{-5}
 \end{aligned} \quad (3.19)$$

U fazi inicijalizacije svi parametri postupka optimiranja podešeni su na uobičajene predložene vrijednosti prilagođene funkciji cilja s dva parametra i prikazane u tablici 3.13. Postupak optimiranja za svaku točku na statičkoj granici stabilnosti se prema dijagramu toka 3.22 iterativno provodi kroz generacije, sve dok se ne zadovolji jedan od postavljenih uvjeta zaustavljanja algoritma. Optimiranja pojedinih točaka prosječno traju oko 0,2 sekunde i redovno se zaustavljaju po uvjetu završetka postizanjem globalnog minimuma funkcije cilja. Ciljane vrijednosti postižu se prosječno kroz cca 80 generacija i 1100 evaluacija. Globalni minimumi funkcije cilja $G_{SGS}(I_d, I_q)$ pronalaze se locirani na parametrima I_d i I_q .

Izračunati parametri funkcije cilja, što su u stvari struje armature u direktnoj osi $I_{d,i}$ i poprečnoj

Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora

osi $I_{q,i}$, uz variranu uzбудnu struju $I_{f,i,var}$ sačinjavaju trojku čijim se uvrštavanjem u izraze za jalovu (3.20) i djelatnu snagu (3.21) dobivaju koordinate radne točke za prikaz na pogonskoj karti.

$$Q_{SGS,i} = \omega \left(-\Psi_d(I_{d,i}, I_{q,i}, I_{f,i,var}) I_{d,i} - \Psi_q(I_{d,i}, I_{q,i}, I_{f,i,var}) I_{q,i} \right) \quad (3.20)$$

$$P_{SGS,i} = \omega \left(\Psi_d(I_{d,i}, I_{q,i}, I_{f,i,var}) I_{q,i} - \Psi_q(I_{d,i}, I_{q,i}, I_{f,i,var}) I_{d,i} \right) - (I_{d,i}^2 + I_{q,i}^2) R \quad (3.21)$$


$$\begin{array}{cccc} I_{f,1,var} & G_{SGS}(I_d, I_q) = & I_{d,1} & I_{q,1} \\ \vdots & -P_{SGS}(I_d, I_q, I_{f,var}) \rightarrow \min! & I_{d,2} & I_{q,2} \\ \vdots & =====> & \vdots & \vdots \\ I_{f,n,var} & (3.18) & I_{d,n} & I_{q,n} \end{array}$$

$$\begin{array}{cccc} & \Psi_{d,1}, \Psi_{q,1} & & Q_{SGS,1}, P_{SGS,1} \\ \Psi(I) & \Psi_{d,2}, \Psi_{q,2} & Q, P & Q_{SGS,2}, P_{SGS,2} \\ =====> & \vdots & =====> & \vdots \\ (3.7), (3.8) & \Psi_{d,n}, \Psi_{q,n} & (3.20), (3.21) & Q_{SGS,n}, P_{SGS,n} \end{array} \quad (3.22)$$


Na slikama 3.15, 3.16 i 3.17 prikazane su statičke granice stabilnosti izračunate polinomnim i sigmoidnim $\Psi(I)$ funkcijama te klasičnim modelom pri konstantnim naponima na stezaljkama generatora u iznosima određenima na $U = 0,95$ p.u., $U = 1,00$ p.u. i $U = 1,05$ p.u.. Granice konstantne uzbude pomoću polinomnih $\Psi(I)$ funkcija bilo je moguće izračunati samo za napon na stezaljkama $U = 0,95$ p.u. jer u tom slučaju krivulje konstantne uzbude dobivene pomoću tih funkcija imaju svoj maksimum, a u slučajevima većih napona na stezaljkama generatora gube svoj fizikalni oblik, pri čemu nemaju niti svoj maksimum čije koordinate bi bile na statičkoj granici stabilnosti.

Kao pomoćne krivulje tankim linijama prikazane su krivulje konstantne uzbude $I_{f,konst}$ fiksirane na vrijednosti 0,0 p.u., 0,2 p.u., 0,5 p.u., 0,8 p.u., 1,0 p.u., 1,2 p.u. i 1,4 p.u.. Kroz njihove maksimume prolaze statičke granice stabilnosti.

Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora




Slika 3.15: Krivulje statičke granice stabilnosti pri konstantnom naponu na stezaljkama generatora $U = 0,95$ p.u. i s krivuljama konstantne uzbude kao pomoćnim linijama



Slika 3.16: Krivulje statičke granice stabilnosti pri konstantnom naponu na stezaljkama generatora $U = 1,00$ p.u. i s krivuljama konstantne uzbude kao pomoćnim linijama

Izračun statičke granice stabilnosti napravljen je do iznosa uzbudne struje ovisno o naponu na stezaljkama generatora, koliko je potrebno za pripremu izrade granica pogonske karte, tj. za napon $U = 0,95$ p.u. do $I_{f,konst} = 1,4$ p.u., za $U = 1,0$ p.u. do $I_{f,konst} = 1,2$ p.u. i za $U = 1,05$ p.u. do $I_{f,konst} = 1,0$ p.u..

Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora



Slika 3.17: Krivulje statičke granice stabilnosti pri konstantnom naponu na stezaljkama generatora $U = 1,05$ p.u. i s krivuljama konstantne uzbude kao pomoćnim linijama

3.2.4 Praktična granica stabilnosti

Praktična granica stabilnosti dobiva se na način da se za svaku proizvoljno variranu vrijednost struje uzbude ($I_{f,var}$) traži radna točka na krivulji konstantne uzbude kojoj je prekretna djelatna snaga P_{SGS} umanjena za 0,1 p.u.. Funkcija cilja na kojoj optimizacijski algoritam DE traži minimum postavlja se prema sljedećem:

$$\begin{aligned} G_{PGS}(I_d, I_q) &= (P(I_d, I_q, I_{f,var}) - (P_{SGS} - 0, 1))^2 \\ &= (\omega(\Psi_d(I_d, I_q, I_{f,var})I_q - \Psi_q(I_d, I_q, I_{f,var})I_d) - (I_d^2 + I_q^2)R \\ &\quad - (P_{SGS} - 0, 1))^2 \rightarrow \min! \end{aligned} \quad (3.23)$$

uz ispunjavanje uvjeta konstantnog napona

$$U_{konst}(I_d, I_q, I_{f,var}) = \sqrt{(\omega\Psi_d(I_d, I_q, I_{f,var}) - I_q R)^2 + (-\omega\Psi_q(I_d, I_q, I_{f,var}) - I_d R)^2} \quad (3.24)$$

koji se postavlja kao sljedeće funkcionalno ograničenje

$$\begin{aligned} |U - U_{konst}| &= \\ &= \left| \sqrt{(\omega\Psi_d(I_d, I_q, I_{f,var}) - I_q R)^2 + (-\omega\Psi_q(I_d, I_q, I_{f,var}) - I_d R)^2} - U_{konst} \right| \leq 10^{-5} \end{aligned} \quad (3.25)$$

U fazi inicijalizacije svi parametri postupka optimiranja podešeni su na uobičajene predložene vrijednosti prilagođene funkciji cilja s dva parametra i prikazane u tablici 3.14.

Postupak optimiranja za svaku točku na praktičnoj granici stabilnosti se prema dijagramu toka 3.26 iterativno provodi kroz generacije, sve dok se ne zadovolji jedan od postavljenih uvjeta zaustavljanja algoritma. Optimiranja pojedinih točaka prosječno traju oko 1 sekundu i redovno se zaustavljaju po uvjetu završetka postizanjem ciljane vrijednosti funkcije cilja. Ciljane vrijed-

Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora


Tablica 3.14: Parametri postupka optimiranja za rješavanje (3.23) po I_d i I_q

OPIS	PARAMETAR
Mutacijski faktor	$F = 0,8$
Vjerojatnost križanja	$\eta_{CR} = 0,7$
Ciljana vrijednost funkcije cilja kao 1. uvjet završetka (eng. value to reach)	$VTR = 1 \cdot 10^{-8}$ p.u.
Broj generacija kao 2. uvjet završetka	$G = 220$
Maksimalno vrijeme izvršavanja kao 3. uvjet završetka	$T = 2$ s
Broj parametara vektora čija optimalna vrijednost se traži	$D_d = 2$
Minimalna vrijednost parametara vektora u prostoru u kojemu se traži rješenje	$d_{min} = -1,5$ p.u.
Maksimalna vrijednost parametara vektora u prostoru u kojemu se traži rješenje	$d_{max} = 1,5$ p.u.
Populacija	$N_p = 20$


nosti postižu se prosječno kroz cca 200 generacija i 700 evaluacija. Globalni minimumi funkcije cilja $G_{PGS}(I_d, I_q)$ pronalaze se locirani na parametrima $I_{d,i}$ i $I_{q,i}$, koji uz variranu uzbudnu struju $I_{f,i,var}$ sačinjavaju trojku čijim se uvrštavanjem u izraze za jalovu (3.20) i djelatnu snagu (3.21) dobivaju koordinate točaka na praktičnoj granici stabilnosti.

$$\begin{array}{cccc}
 I_{f,1,var} & G_{PGS}(I_d, I_q) = & I_{d,1} & I_{q,1} \\
 \vdots & (P - (P_{SGS} - 0, 1))^2 \rightarrow \min! & I_{d,2} & I_{q,2} \\
 \vdots & \text{=====} \Rightarrow & \vdots & \vdots \\
 I_{f,n,var} & (3.23) & I_{d,n} & I_{q,n} \\
 \\
 & \Psi_{d,1}, \Psi_{q,1} & & Q_{SGS,1}, P_{SGS,1} \\
 \Psi(I) & \Psi_{d,2}, \Psi_{q,2} & Q, P & Q_{SGS,2}, P_{SGS,2} \\
 \text{=====} \Rightarrow & \vdots & \text{=====} \Rightarrow & \vdots \\
 (3.7), (3.8) & \Psi_{d,n}, \Psi_{q,n} & (3.20), (3.21) & Q_{SGS,n}, P_{SGS,n} \\
 & & & (3.26)
 \end{array}$$

Na slikama 3.18, 3.19 i 3.20 prikazane su praktične granice stabilnosti izračunate polinomnim i sigmoidnim $\Psi(I)$ funkcijama te klasičnim modelom pri konstantnim naponima na stezaljkama generatora u iznosima određenima na $U = 0,95$ p.u., $U = 1,00$ p.u. i $U = 1,05$ p.u.. Krivulju praktične granice stabilnosti je iz istog razloga kao i za statičke granice stabilnosti bilo moguće odrediti samo za slučaj napona na stezaljkama $U = 0,95$ p.u.. Uz krivulje konstantne uzbude koje su izražene tankim linijama za iznose iste struje uzbude jednako kao i na odgovarajućim slikama u prethodnom poglavlju, također kao pomoćne krivulje prikazane su i statičke granice stabilnosti.




Slika 3.18: Krivulje praktične granice stabilnosti pri konstantnom naponu na stezaljkama generatora $U = 0,95$ p.u. i s krivuljama konstantne uzbude i statičkim granicama stabilnosti kao pomoćnim linijama



Slika 3.19: Krivulje praktične granice stabilnosti pri konstantnom naponu na stezaljkama generatora $U = 1$ p.u. i s krivuljama konstantne uzbude i statičkim granicama stabilnosti kao pomoćnim linijama

Logičan je odnos statičkih i praktičnih granica stabilnosti koje se nalaze na istim krivuljama konstantne uzbude s razlikom u rezervi djelatne snage od 0,1 p.u.. Vidljiva je znatna razlika između granica izračunatih pomoću klasičnog modela i sigmoidnih $\Psi(I)$ funkcija, pri čemu je

Sigmoidne $\Psi(I)$ strujno ovisne funkcije ulančenih tokova za modeliranje stacionarnih radnih stanja sinkronog generatora




Slika 3.20: Krivulje praktične granice stabilnosti pri konstantnom naponu na stezaljkama generatora $U = 1,05$ p.u. i s krivuljama konstantne uzbude i statičkim granicama stabilnosti kao pomoćnim linijama

šire dozvoljeno radno područje opisano granicama dobivenima sigmoidnim $\Psi(I)$ funkcijama.


3.2.5 Pogonska karta

Objedinjujući granice izračunate u poglavljima 2.5.1, 2.5.2, 2.5.3, 2.5.4, 3.2.1, 3.2.2, 3.2.3 i 3.2.4 u istom dijagramu dobiva se pogonska karta sinkronog generatora u kojoj pojedine krivulje zatvaraju površinu koja predstavlja dozvoljeno radno područje sinkronog generatora. Na slikama 3.21, 3.22 i 3.23 prikazane su pogonske karte za nazivni napon na stezaljkama generatora te 5% viši i niži napon. Granice pogonske karte izračunate su klasičnim modelom i sigmoidnim $\Psi(I)$ funkcijama, dok je s polinomnim $\Psi(I)$ funkcijama bilo moguće izračunati granice pogonske karte samo za napon na stezaljkama generatora $U = 0,95$ p.u.. Povećavanjem napona proširuju se granice pogonske karte u kapacitivnom dijelu i čime se dolazi u radna područja izvan zona identifikacije modela u kojima se je pokazalo da polinomnim $\Psi(I)$ funkcijama znatno opada točnost. Za napone na stezaljkama $U = 1,00$ p.u. i $U = 1,05$ p.u., uz pogonske karte su zbog ilustracije prikazane granice minimalne uzbude koje nemaju svoj fizički smisao, izračunate polinomnim $\Psi(I)$ funkcijama.


Zaključno, može se utvrditi da granice pogonske karte izračunate sigmoidnim $\Psi(I)$ funkcijama koje se najbolje poklapaju s granicama izračunatima pomoću referentnog MKE modela opisuju znatno šire dozvoljeno radno područje nego granice pogonske karte izračunate klasičnim modelom koji ne uzima u obzir magnetsko zasićenje stroja niti efekt poprečne magnetizacije. Širi pogonski dijagram daje veće mogućnosti korištenja stroja, što je vrlo korisno operaterima proizvodnje i elektroenergetske mreže.



Slika 3.21: Pogonska karta sinkronog generatora pri konstantnom naponu na stezaljkama generatora $U = 0,95$ p.u.



Slika 3.22: Pogonska karta sinkronog generatora pri konstantnom naponu na stezaljkama generatora $U = 1,00$ p.u.



Slika 3.23: Pogonska karta sinkronog generatora pri konstantnom naponu na stezaljkama generatora $U = 1,05$ p.u.

Poglavlje 4

Računalno nezahtjevne metode za prikaz granica pogonske karte sinkronog generatora

4.1 Uvod

Budući da se oblik granica pogonske karte mijenja ovisno o aktualnoj radnoj točki generatora, granice pogonske karte potrebno je izračunavati, koristiti i prikazivati u stvarnom vremenu unutar sustava vođenja elektrane, njegovim programabilnim logičkim kontrolerima (PLC) i sustavu sučelja za upravljanje i akviziciju (SCADA).

Metodom opisanom u prethodnom poglavlju mogu se precizno izračunavati radne točke sinkronog generatora u trodimenzionalnom prostoru. U slučaju određivanja granica pogonske karte koriste se složeni izračuni koji se sastoje od sustava nelinearnih jednadžbi i optimizacijskih algoritama. Takvi izračuni računalno i vremenski su zahtjevni, što je razlog tome da se provode izvan stvarnog vremena.

Osnovna uloga računalno nezahtjevnih funkcija je u implementaciji u industrijskim sustavima vođenja, čija funkcija je vođenje procesa u stvarnom vremenu, pa u njima nije moguće izvoditi složene optimizacijske algoritme, već jednostavne matematičke operacije. Granice pogonske karte izražene računalno nezahtjevnim funkcijama imaju daljnje mogućnosti interpretacije i korištenja u izračunima granica pogonske karte, kao što su model zajedničke pogonske karte za više generatora, izražavanje ovisnosti granica pogonske karte o konfiguraciji realne električne mreže i sl.

Osnovna ideja je u tome da se prvo izvan stvarnog vremena izračuna obilan i detaljan set podataka o granicama pogonske karte za cijeli operativni raspon napona na stezaljkama sinkronog generatora. Postavljaju se računalno nezahtjevne funkcije koje opisuju granice pogonske karte i mogu biti implementirane u sustav vođenja elektrane koji djeluje u stvarnom vremenu.

Računalno nezahtjevne funkcije potrebno je identificirati na prethodno izračunati detaljni set granica pogonske karte.

4.2 Opis metode

4.2.1 Granice praktične stabilnosti i maksimalne struje uzbude

Granice praktične stabilnosti i maksimalne struje uzbude moguće je izraziti kroz sljedeću polinomnu funkciju četvrtog stupnja:

$$\begin{aligned} Q_{PS,MaxIf} = f(U, P) = & l_1 + l_{10}(U + l_2) + l_{20}(U + l_2)^2 + l_{30}(U + l_2)^3 + l_{40}(U + l_2)^4 \\ & + l_{11}(U + l_2)(P + l_3) + l_{12}(U + l_2)(P + l_3)^2 + l_{13}(U + l_2)(P + l_3)^3 \\ & + l_{14}(U + l_2)(P + l_3)^4 + l_{21}(U + l_2)^2(P + l_3) + l_{22}(U + l_2)^2(P + l_3)^2 \\ & + l_{31}(U + l_2)^3(P + l_3) \end{aligned} \quad (4.1)$$

Koeficijenti l_{xy} su varijable po kojima se provodi optimiranje, prema sljedećoj funkciji cilja:

$$G_{PS,MaxIf}(l_1, \dots, l_{31}) = \sum_{i=1}^N [Q_i - Q_{PS,MaxIf}(P_i, U_i, l_1, \dots, l_{31})]^2 \rightarrow \min! \quad (4.2)$$

Postupak optimiranja DE se prema postavljenim parametrima prikazanima u tablici 4.1 za točke praktičnih granica stabilnosti iterativno provodi kroz generacije, sve dok se ne zadovolji jedan od postavljenih uvjeta zaustavljanja algoritma.

Inicijalne vrijednosti svih koeficijenata postavljene su na nulu. Optimiranje traje 63 sekunde i zaustavlja se po uvjetu završetka postizanjem ciljane vrijednosti funkcije cilja $VTR = 1 \cdot 10^{-4}$ p.u.. Ciljana vrijednost postiže se kroz 3256 generaciju i 455840 evaluacija uz srednje vrijeme evaluacije od 0,1394 ms.

Pronađeni globalni minimum funkcije cilja $G_{PS,MaxIf}$ lociran je u 14-dimenzionalnom prostoru na koordinatama l_{xy} prikazanima u tablici 4.2.

Na slici 4.1 prikazana je usporedba praktičnih granica stabilnosti dobivenih računalno nezahtevnom funkcijom $Q_{PS,MaxIf}(U, P)$ (4.1) u usporedbi s krivuljama na koje je ista funkcija identificirana, izračunatim pomoću sigmoidnih $\Psi(I)$ funkcija.

Ista računalno nezahtjevna polinomna funkcija može se identificirati na krivulje maksimalne uzbudne struje. Postupak optimiranja za svaku točku krivulje se prema postavljenim parametrima prikazanima u tablici 4.3 iterativno provodi kroz generacije, sve dok se ne zadovolji jedan od postavljenih uvjeta zaustavljanja algoritma. Inicijalne vrijednosti svih koeficijenata postavljene su na nulu. Optimiranje traje 1801 sekundu i zaustavlja se po uvjetu završetka postizanjem ciljane vrijednosti funkcije cilja $VTR = 1 \cdot 10^{-4}$ p.u.. Ciljana vrijednost postiže se kroz 16621

Tablica 4.1: Parametri postupka optimiranja za rješavanje (4.2) po l_{xy} za granicu praktične stabilnosti

OPIS	PARAMETAR
Mutacijski faktor	$F = 0,8$
Vjerojatnost križanja	$\eta_{CR} = 0,7$
Ciljana vrijednost funkcije cilja kao 1. uvjet završetka (eng. value to reach)	$VTR = 1 \cdot 10^{-4}$ p.u.
Broj generacija kao 2. uvjet završetka	$G = 3500$
Maksimalno vrijeme izvršavanja kao 3. uvjet završetka	$T = 90$ s
Broj parametara vektora čija optimalna vrijednost se traži	$D_d = 14$
Minimalna vrijednost parametara vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$d_{min} = -5$ p.u.
Maksimalna vrijednost parametara vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$d_{max} = 5$ p.u.
Populacija	$N_p = 140$

generaciju i 4654160 evaluacija uz srednje vrijeme evaluacije od 0,3871 ms.

Pronađeni globalni minimum funkcije cilja $G_{PS,MaxIf}$ lociran je u 14-dimenzionalnom prostoru na koordinatama l_{xy} prikazanima u tablici 4.4.

Na slici 4.2 prikazana je usporedba granica maksimalne uzbude $I_f = 2$ p.u. dobivenih računalno nezahitjevnom funkcijom $Q_{PS,MaxIf}(U, P)$ (4.1) u usporedbi s krivuljama na koje je ista funkcija identificirana, izračunatima pomoću sigmoidnih $\Psi(I)$ funkcija.

4.2.2 Granice minimalne struje uzbude

Granice minimalne struje uzbude moguće je izraziti kroz parametarsku funkciju elipse u polarnom koordinatnom sustavu, prema sljedećem:

$$\begin{aligned}
 P_{MinIf} &= f(R_p, \alpha) = R_p(U) \sin(\alpha) \\
 Q_{MinIf} &= f(R_q, \alpha) = Q_0 + R_q(U) \cos(\alpha)
 \end{aligned}
 \tag{4.3}$$

Tablica 4.2: Vrijednosti koeficijenta l_{xy} identificirane računalno nezahitjve funkcije $Q_{PS,MaxFC}$ za granicu praktične stabilnosti

Koeficijent:	l_1	l_2	l_3	l_{10}	l_{20}	l_{30}	l_{40}
Vrijednost:	-0,156	-0,705	-0,592	-1,425	-0,217	-4,749	3,784
Koeficijent:	l_{11}	l_{12}	l_{13}	l_{14}	l_{21}	l_{22}	l_{31}
Vrijednost:	1,728	-2,407	0,674	-1,63	-4,936	4,852	5

gdje su:

$$\begin{aligned}
 R_p(U) &= a_1 U^{a_2} + a_3 U^{a_4} \\
 R_q(U) &= b_1 U^{b_2} + b_3 U^{b_4} \\
 Q_0(U) &= c_1 U^{c_2} + c_3 U^{c_4}
 \end{aligned}
 \tag{4.4}$$


Koeficijenti $a_1...a_4$, $b_1...b_4$ i $c_1...c_4$ su varijable po kojima se provodi optimiranje, prema sljedećoj funkciji cilja:

$$G_{MinIf}(a_1...a_4, b_1...b_4, c_1...c_4) = \sum_{i=1}^N [P_i - P_{MinIf}(Q_i, U_i)]^2 \rightarrow \min!
 \tag{4.5}$$

gdje je:

$$P_{MinIf}(Q_i, U_i) = R_p(U) \sqrt{1 - \frac{|Q_i - Q_0(U_i)|^2}{R_q^2(U_i)}}
 \tag{4.6}$$

Postupak optimiranja za sve točke krivulje se prema postavljenim parametrima prikazanima u tablici 4.5 iterativno provodi kroz generacije, sve dok se ne zadovolji jedan od postavljenih uvjeta zaustavljanja algoritma.



Slika 4.1: Praktične granice stabilnosti izračunate računalno nezahitjvom funkcijom $Q_{PS,MaxIf}(U, P)$ u usporedbi s granicama dobivenima pomoću sigmoidnih $\Psi(I)$ funkcija

Tablica 4.3: Parametri postupka optimiranja za rješavanje (4.2) po l_{xy}


OPIS	PARAMETAR
Mutacijski faktor	$F = 0,8$
Vjerojatnost križanja	$\eta_{CR} = 0,7$
Ciljana vrijednost funkcije cilja kao 1. uvjet završetka (eng. value to reach)	$VTR = 1 \cdot 10^{-4}$ p.u.
Broj generacija kao 2. uvjet završetka	$G = 20000$
Maksimalno vrijeme izvršavanja kao 3. uvjet završetka	$T = 2000$ s
Broj parametara vektora čija optimalna vrijednost se traži	$D_d = 14$
Minimalna vrijednost parametara vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$d_{min} = -5$ p.u.
Maksimalna vrijednost parametara vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$d_{max} = 5$ p.u.
Populacija	$N_p = 280$

Tablica 4.4: Vrijednosti koeficijenata l_{xy} identificirane računalno nezahtjevne funkcije $Q_{PS,MaxFC}$ za granicu maksimalne uzbude $I_f = 2$ p.u.

Koeficijent:	l_1	l_2	l_3	l_{10}	l_{20}	l_{30}	l_{40}
Vrijednost:	-0,427	-1,312	-1,248	-3,242	-4,721	-3,143	-5
Koeficijent:	l_{11}	l_{12}	l_{13}	l_{14}	l_{21}	l_{22}	l_{31}
Vrijednost:	4,111	1,573	0,359	0,089	4,923	0,502	2,526

Inicijalne vrijednosti svih koeficijenata postavljene su na nulu. Optimiranje traje 851 sekundu i zaustavlja se po uvjetu završetka postizanjem ciljane vrijednosti funkcije cilja $VTR = 0,105$ p.u.. Ciljana vrijednost postiže se kroz 8365 generacija i 1003800 evaluacija uz srednje vrijeme evaluacije od 0,8487 ms. Pronađeni globalni minimum funkcije cilja G_{MinIf} lociran je u 12-dimenzionalnom prostoru na koordinatama $a_1 \dots a_4$, $b_1 \dots b_4$ i $c_1 \dots c_4$ prikazanima u tablici 4.6

Na slici 4.3 prikazana je usporedba granica minimalne uzbude $I_f = 0,2$ p.u. dobivenih računalno nezahtjevnom funkcijom $P_{MinIf}(Q, U)$ (4.6) u usporedbi s krivuljama na koje je ista funkcija identificirana, izračunatima pomoću sigmoidnih $\Psi(I)$ funkcija.



Slika 4.2: Granice maksimalne uzbude $I_f = 2$ p.u. izračunate računalo nezahtjevnom funkcijom $Q_{PS,MaxIf}(U, P)$ u usporedbi s granicama dobivenima pomoću sigmoidnih $\Psi(I)$ funkcija


Tablica 4.5: Parametri postupka optimiranja za rješavanje 4.5 po $a_1 \dots a_4$, $b_1 \dots b_4$ i $c_1 \dots c_4$

OPIS	PARAMETAR
Mutacijski faktor	$F = 0,8$
Vjerojatnost križanja	$\eta_{CR} = 0,7$
Ciljana vrijednost funkcije cilja kao 1. uvjet završetka (eng. value to reach)	$VTR = 0,105$ p.u.
Broj generacija kao 2. uvjet završetka	$G = 10000$
Maksimalno vrijeme izvršavanja kao 3. uvjet završetka	$T = 1000$ s
Broj parametara vektora čija optimalna vrijednost se traži	$D_d = 12$
Minimalna vrijednost parametara vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$d_{min} = -5$ p.u.
Maksimalna vrijednost parametara vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$d_{max} = 5$ p.u.
Populacija	$N_p = 120$


Na slici 4.4 objedinjene su sve granice izražene računalo nezahtjevnim funkcijama i prikazane na slikama 4.1, 4.2 i 4.3, tvoreći pogonsku kartu.

Tablica 4.6: Vrijednosti koeficijenata $a_1 \dots a_4$, $b_1 \dots b_4$ i $c_1 \dots c_4$ identificirane računalno nezahtjevne funkcije P_{MinIf} za granicu minimalne uzbude

Koeficijent:	a_1	a_2	a_3	a_4	b_1	b_2
Vrijednost:	0,065	0,214	0,229	1,528	0,133	2,605
Koeficijent:	b_3	b_4	c_1	c_2	c_3	c_4
Vrijednost:	0,236	0	-0,791	3,003	-0,301	0,001



Slika 4.3: Granice minimalne uzbude $I_f = 0,2$ p.u. izračunate računalno nezahtjevnom funkcijom $P_{MinIf}(Q, U)$ u usporedbi s granicama dobivenima pomoću sigmoidnih $\Psi(I)$ funkcija



Slika 4.4: Granice pogonske karte za $I_{f,min} = 0,2$ p.u. i $I_{f,max} = 2$ p.u. izračunate računalno nezahtjevnom funkcijom $P_{MinIf}(Q, U)$ u usporedbi s granicama dobivenima pomoću sigmoidnih $\Psi(I)$ funkcija

Kako je na slikama 4.1 do 4.4 vidljivo gotovo potpuno poklapanje granica izračunatih računalno nezahtjevnim funkcijama s granicama s kojima su iste identificirane, može se zaključiti da predmetne funkcije vjerno opisuju izvorne granice pogonske karte. Model sa sigmoidnim $\Psi(I)$ funkcijama u ovoj metodi služi za izračun velike detaljne grupe granica pogonske karte, pri svim realno očekivanim naponima na stezaljkama generatora, kako bi računalno nezahtjevne funkcije izražavale granice pogonske karte u čim širem očekivanom rasponu radnog područja generatora. Izračun grupe granica pogonske karte pomoću sigmoidnih $\Psi(I)$ funkcija računalno je zahtjevan i provodi se prethodno, izvan stvarnog vremena, kao i identifikacija računalno nezahtjevnih funkcija. Nakon njihove identifikacije, računalno nezahtjevne funkcije mogu se implementirati u industrijsko programabilno sklopovlje sustava vođenja elektrane i u stvarnom vremenu efikasno dinamički izražavati granice pogonske karte, ovisno o pogonskim uvjetima.


4.3 Sustav za nadzor, identifikaciju i prikaz dinamičke pogonske karte implementiran u HE Vinodol

4.3.1 Topologija sustava

U hidroelektrani Vinodol instalirana su tri hidroagregata od kojih je svaki pokretan s dvije Pelton turbine. Strojarnica HE Vinodol prikazana je na slici 4.5). Nazivni podatci generatora prikazani su u tablici 3.1. Topologija sustava za identifikaciju i prikaz dinamičke pogonske karte implementiranog u HE Vinodol prikazana je na slici 4.6.




Slika 4.5: Strojarnica hidroelektrane Vinodol



Slika 4.6: Topologija sustava za identifikaciju i prikaz dinamičke pogonske karte implementiran u HE Vinodol

Sustav za identifikaciju i prikaz dinamičke pogonske karte prikuplja i obrađuje podatke relevantne za identifikaciju modela sinkronog stroja korištenog za izračun granica pogonske karte, kao što su napon i struja armature, fazni kut između armaturnog napona i struje, kut opterećenja i uzbudna struja. Sve mjerene veličine se arhiviraju u bazu tijekom redovnog rada generatora. Uz uobičajenu opremu za mjerenje napona i struje, na svaki generator instalirana je dodatna mjerna oprema. U zračnom rasporu generatora instalirane su Hallove sonde, u krajnje zone statorskih tlačnih ploča montirane su temperaturne sonde Pt1000, a položaj vratila generatora nadziru beskontaktni induktivni davači. Stabilizirani strujni izvori CS1, CS2 i CS3 prikazani na slici 4.6 napajaju Hallove sonde. Naponski signali iz Hallovih sondi obrađuju se u izolacijskim pojačalima IA1, IA2 i IA3, prikazanima također na slici 4.6. Signali temperaturno ovisnih otpora PT1000 sonde obrađuju se u mjernim pretvornicima RTD otpornog signala TIA1, TIA2 i TI3 s galvanskom izolacijom, prikazanima na slici 4.6. Vizualni pregled glavnih dijelova predmetnog sustava nalazi se na fotografijama u sklopu slike 4.7. Budući da Hallove i temperaturne sonde generiraju signale niske energije, zbog velike količine elektromagnetskih smetnji u okruženju strojarnice hidroelektrane strujni izvori, izolacijska pojačala i temperaturni mjerni pretvornici locirani su u ormarićima montiranim u blizini pojedinih generatora.



Slika 4.7: Oprema instalirana u ormariću pogonske karte (lijevo) i serverskoj sobi (desno)

Također s ciljem izbjegavanja šuma na mjernim linijama, korišteni su signalni kabeli s oklopljenim i ukrižanim paricama i zajedničkim oklopom cijelog kabela. Jedan od zahtjeva na sustav bio je korištenje standardnih industrijskih komponenti zbog pouzdanosti, unificiranosti i smanjenja troškova održavanja i osiguranja rezervnih dijelova. Za standardna mjerenja struja i napona korištena je postojeća oprema, signali su preuzeti sa strujnih i naponskih mjernih transformatora u ormaru sinkronizacije, uz primijenjena rješenja zaštite, naponska dijelila i izolacijska pojačala. Ormarić pogonske karte je centralna jedinica sustava za sva tri generatora, nalazi se u strojarnici iza ploče središnjeg stroja (G2) i svi signali se dovode u njega, gdje se obrađuju i procesiraju. Signali s beskontaktnih induktivnih davača koriste se zajedno sa statorskim naponom za mjerenje kuta opterećenja pomoću mjernog pretvornika lociranog u istom ormariću.

Prikupljanje i obrada signala obavlja se pomoću sklopovlja National Instrument NI c9205 montiranog na okvir postolja NI cDAQ 9181 s ethernet komunikacijom. Frekvencija uzorkovanja je 20 kHz. Ethernet veza povučena je kroz elektranu svjetlovodom do serverskog prostora s TK opremom gdje se nalazi ormar s glavnim računalom predmetnog sustava. Na slici 4.6 ethernet veze ostvarene bakrenim vodičima označene su s linijama plave boje, a svjetloводи su označeni s linijama narančaste boje. Osim što obrađuje prikupljene signale koristeći LabView, računalo komunicira sa SCADA (Supervisory Control and Acquisition) sustavom elektrane kroz industrijsku mrežu koristeći PLC (Programmable Logic Controller) Siemens S7-300. Računalo u SCADA sustav šalje podatke o magnetskoj indukciji u zračnom rasporu, temperaturi tlačnih ploča i kutu opterećenja. Također, očitava radnu, jalovu i prividnu snagu te uzбудnu struju svakog generatora. Nakon obrade signala i računanja granica pogonske karte, računalo izračunata podatke šalje u SCADA sustav, gdje se koriste za ostvarenje njihove vizualizacije u upravljačkoj sobi elektrane. Granice pogonske karte izračunavaju se pomoću računalno nezahtjevnih funkcija postavljenih metodama opisanima u poglavljima 3 i 4.

Glavnom računalu predmetnog sustava moguće je pristupiti iz poslovne mreže elektrane za svrhe pregleda i prijenosa podataka. Uloga PLC-a u ovom sustavu je da bude međusklopovlje za pristup opreme predmetnog sustava procesnoj mreži i SCADA sustavu. Kako elektrana predstavlja vitalni dio elektroenergetskog sustava, a ona je u cijelosti upravljana programabilnim digitalnim uređajima povezanim procesnom mrežom, vrlo je bitno zaštititi je od kibernetičkih napada, pa stoga procesna mreža treba striktno biti odvojena od poslovne mreže. PLC predstavlja sigurnosnu barijeru među tim mrežama uz omogućavanje razmjene mjernih podataka i podataka potrebnih za prikaz granica pogonske karte na SCADA računalu. Predmetni PLC ne može provoditi niti jednu upravljačku akciju u procesnoj mreži, što je osnovno u izbjegavanju kibernetičkih napada kroz predmetni sustav.

Svi relevantni dijelovi predmetnog sustava prikazani su u tablici 4.7.

Tablica 4.7: Lista korištene opreme


OPREMA	OZNAKA I TIP
Postojeći naponski mjerni transformator u elektrani	10kV/100V, klasa: 0.5
Postojeći strujni mjerni transformator u elektrani	2000A/1A, klasa: 0.5
Strujni mjerni transformator	Dent CT-SRS-005-U, 2.5A/0.333V, klasa 0.2
Naponsko dijelilo	2x 22 k Ω
Beskontaktni induktivni davač	Balluff BES M18MI-PSC50B-BV10
Temperaturno osjetilo	PT1000
Hallova sonda	HGT-2010
Napojna jedinica za Hallove sonde	24V, 50 mA, korisnički izrađen
Mjerni pretvornik za PT1000	Weidmueller WAS5 PRO RTD 1000
Mjerni pretvornik za mjerenja napona i struja	Weidmueller WAS4 PRO DC/DC
Okvir	NI cDAQ 9181
Naponski ulazni modul	NI 9205
Svjetlovodni pretvornik	Planet, IGT-905A, SFP modul
Mjerni pretvornik kuta opterećenja	Korisnički izrađen
PLC	Simatic S7-300 CPU 315-2 PN/DP

4.3.2 Nestandardna mjerenja i mogućnosti u sustavu za identifikaciju i prikaz dinamičke pogonske karte

U sustavu za identifikaciju i prikaz dinamičke pogonske karte nalaze se nestandardna mjerenja i metode prikupljanja i obrade signala, kakva nisu obuhvaćena u standardnom sustavu vođenja elektrane. Na primjer, mjerena je magnetska indukcija u zračnom rasporu koja može biti korištena za dijagnostiku ekscentriciteta rotora, međuzavoynih kratkih spojeva uzbudnog namota ili bilo kojih drugih pojava koje uzrokuju nesimetrična magnetska stanja u zračnom rasporu.

Dodatno, u predmetni sustav implementirano je snimanje prijelaznih pojava, koje kontinuirano obrađuje 20 sekundi valnih oblika svih prikupljenih signala. U slučaju ispunjavanja zadanog kriterija prijelazne pojave, vremenski prozor od 20 sekundi svih signala se pohranjuje. Kriterij

je ispunjen kada standardna devijacija efektivne vrijednosti struje armature u vremenskom prozoru od 20 sekundi postane veća od 0,05 p.u. i napon armature veći od 0,5 p.u. Pohranjuje se vremenski prozor unutar kojeg je vremenski interval 5 sekundi prije i 15 sekundi nakon zadovoljenja kriterija. Primjer snimljene prijelazne pojave sinkronizacije generatora prikazan je na slici 4.8.




Slika 4.8: Primjer snimljene prijelazne pojave sinkronizacije generatora. Donja slika prikazuje detaljniji uvid u početni dio prijelazne pojave

Period od 5 sekundi prije zadovoljenja kriterija služi za određivanja radnih uvjeta stroja prije nastanka prijelazne pojave, što je vrlo korisno pri analizama uzroka prorada zaštita i pojava kvara. Nakon prorade zaštita i ispada dijelova postrojenja iz rada, a prije ponovnog pokretanja obavezno je provesti analizu uvjeta i uzroka tih događaja. Troškovi neplaniranih obustava postrojenja su visoki i mogućnost snimanja prijelaznih pojava omogućava bržu i efikasniju analizu, čime se smanjuje vrijeme i troškove neraspložitosti elektrane.

Mjerenje kuta opterećenja jedno je od nestandardnih mjerenja koje je ključno za identifikaciju modela sinkronog generatora. Za to mjerenje razvijen je mikroprocesorski mjerni pretvornik, čiji princip rada je prikazan na slici 4.9.

U metodi određivanja kuta opterećenja, potrebno je mjerenje valnog oblika napona armature, proizvoljne faze ili proizvoljnog linijskog napona. Signal s naponskog mjernog transformatora digitalizira se korištenjem komparatora, koji uspoređuje napon armature s naponom 0 V i generira logički "1" ako je mjereni napon veći od 0 V, i logičku "0" ako je mjereni napon manji od 0 V. Signal s beskontaktnog induktivnog (proximity) senzora pretvara se u logički signal pomoću komparatora, istom metodom kao i signal mjerenja napona. Uređaj mjeri vrijeme između pozitivnog brida logičkog signala beskontaktnog induktivnog davača i pozitivnog brida logičkog signala mjerenog napona, što je T_1 na slici 4.9.



Slika 4.9: Princip mjerenja kuta opterećenja sinkronog generatora korištenjem signala rotorskog beskontaktnog induktivnog (proximity) senzora i mjerenja valnog oblika napona arature

Također, mjereno je trajanje periode armaturnog napona, što je pokazano na slici 4.9 kao vrijeme T_2 . Vrijeme T_1 proporcionalno je kutu opterećenja, ali ima pomak koji kalibracijom treba biti kompenziran. Budući da kut opterećenja iznosi 0° pri neopterećenom stroju, kalibracija treba biti provedena u pogonskom stanju praznog hoda, prije sinkronizacije na mrežu. Sukladno navedenom kut opterećenja može se izračunati prema:


$$\delta = \text{mod}(\varphi_{prox,U} - \varphi_{kalib}, 360^\circ) = \text{mod}\left(\frac{T_1}{T_2} \cdot 360^\circ - \frac{T_1 \text{ prazni hod}}{T_2 \text{ prazni hod}} \cdot 360^\circ, 360^\circ\right) \quad (4.7)$$

gdje $\varphi_{prox,U}$ fazni kut između pozitivnog brida signala beskontaktnog induktivnog davača i pozitivnog brida digitaliziranog logičkog signala mjerenog napona i može se izračunati kao $\frac{T_1}{T_2} \cdot 360^\circ$ i φ_{kalib} je kut korišten za kalibraciju koji se izračunava na isti način, samo u pogonskom stanju praznog hoda $\frac{T_1 \text{ prazni hod}}{T_2 \text{ prazni hod}} \cdot 360^\circ$.

Nakon provedene kalibracije, kut φ_{kalib} pohranjuje se u memoriju mjernog pretvornika. Funkcija modulo koristi se za osiguranje korektnog izračuna kuta opterećenja za slučaj da fazni kut $\varphi_{prox,U}$ počne zaostajati u odnosu na fazni kut armaturnog napona. Uobičajeno, signal kuta opterećenja nalazi se u rasponu $\langle -180^\circ, 180^\circ \rangle$, gdje negativne vrijednosti predstavljaju motorski način rada. Budući da (4.7) daje vrijednosti od $\langle 0^\circ, 360^\circ \rangle$, u slučaju da je kut izračunat u (4.7) veći od 180° , vrijednost 360° treba biti oduzeta od (4.7) kako bi vrijednost kuta opterećenja bila unutar intervala $\langle -180^\circ, 180^\circ \rangle$. Opisana metoda mjerenja kuta opterećenja zadovoljava primjenu u analizi stacionarnih stanja potrebnih u postupku identifikacije modela sinkronog generatora. Zbog redundancije sustava, kut opterećenja još se dodatno izračunava u programu Labview, gdje je moguće primijeniti isti prezentirani algoritam mjerenja budući da su na raspolaganju u sustavu ulazni podatci prihvaćenih mjerenja armaturnog napona i signala beskontaktnog induktivnog davača.

4.3.3 Mjereni podatci i identifikacija modela sinkronog generatora

Za identifikaciju modela sinkronog generatora potrebno je raspolagati s čim više snimljenih stacionarnih radnih točaka u svim dijelovima pogonske karte pri raznim naponskim prilikama mreže na koju je stroj sinkroniziran. Stacionarne radne točke snimljene za identifikaciju modela na primjeru sinkronog generatora agregata A u HE Vinodol prikazane su na slici 4.10. Uz registrirane veličine djelatne i jalove snage te napona armature, za svaku radnu točku također su snimljeni kut opterećenja i uzbudna struja. Na osnovi snimljenih radnih točaka prikazanih na slici 4.10 identificirane su sigmoidne $\Psi(I)$ funkcije opisane u poglavlju 3.1 i metodologijom opisanom u poglavlju 3.2 izračunate su granice pogonske karte za realno moguć raspon napona na stezaljkama generatora. Zbog implementacije u sustav vođenja elektrane, granice pogonske karte izražene gustim rasterom izračunatih točaka prevedene su u računalno nezahtjeвне funkcije metodologijom opisanom u poglavlju 4.2.



Slika 4.10: Stacionarne radne točke za identifikaciju modela sinkronog generatora agregata A snimljene sustavom za identifikaciju i prikaz dinamičke pogonske karte

Granice maksimalne struje uzbude i praktične granice stabilnosti identificirane su funkcijom (4.1). Vrijednosti izračunatih koeficijenata računalno nezahtjevne funkcije za limite maksimalne struje uzbude i praktične granice stabilnosti prikazane u tablicama 4.8 i 4.9 implementirane su u podsustav monitoringa u sklopu sustava vođenja HE Vinodol.

Tablica 4.8: Parametri računalno nezahtjevne funkcije maksimalne struje uzbude za generator A

Koeficijent:	l_1	l_2	l_3	l_{10}	l_{20}	l_{30}	l_{40}
Vrijednost:	-2.5218	-0.6113	11.7493	16.1356	4.3135	1.9123	0.4471
Koeficijent:	l_{11}	l_{12}	l_{13}	l_{14}	l_{21}	l_{22}	l_{31}
Vrijednost:	0.4784	16.7959	2.5011	23.1500	-1.2690	-0.5822	0.0311

Tablica 4.9: Parametri računalno nezahtjevne funkcije praktične granice stabilnosti za generator A


Koeficijent:	l_1	l_2	l_3	l_{10}	l_{20}	l_{30}	l_{40}
Vrijednost:	-0.4758	-6.5909	7.7139	-0.7563	5.1385	-2.8508	1.0655
Koeficijent:	l_{11}	l_{12}	l_{13}	l_{14}	l_{21}	l_{22}	l_{31}
Vrijednost:	-0.3801	-21.5621	5.5480	29.9799	-0.7824	-0.3616	-0.3120

Na granice minimalne struje izražene gustim rasterom izračunatih točaka identificirana je parametarska računalno nezahtjevna funkcija prema (4.3), (4.4) i (4.6). Vrijednosti izračunatih koeficijenata računalno nezahtjevne funkcije limita minimalne struje uzbude prikazane u tablici 4.10 također su implementirane u podsustav monitoringa u sklopu sustava vođenja HE Vinodol.

Tablica 4.10: Parametri računalno nezahtjevne funkcije minimalne struje uzbude za generator agregata A


Koeficijent:	a_1	a_2	a_3	a_4	b_1	b_2
Vrijednost:	-10.9797	-2.5184	11.2941	-2.4025	0.2906	4.3559
Koeficijent:	b_3	b_4	c_1	c_2	c_3	c_4
Vrijednost:	-0.6975	3.1745	-0.9663	2.6970	-0.0674	1.5778

Granice pogonske karte generatora agregata A izražene točkama izračunatima pomoću identificiranih sigmoidnih $\Psi(I)$ funkcija (križići) u usporedbi s granicama izračunatima pomoću računalno nezahtjevnih funkcija (linija) za tri različita napona na stezaljkama generatora prikazane su na slici 4.11. Gotovo su nezamjetne razlike u poklapanju granica pogonske karte izraženih točkama s istim granicama izraženima računalno nezahtjevnim funkcijama koje su pomoću tih točaka identificirane.



Slika 4.11: Granice pogonske karte generatora agregata A izražene točkama izračunatima pomoću identificiranih sigmoidnih $\Psi(I)$ funkcija (križići) u usporedbi s granicama izračunatima pomoću računalno nezahtjevnih funkcija (linije) za tri različita napona

Vizualni izgled ekranskog prikaza granica generatora jednog agregata izraženih računalno nezahitjevnim funkcijama implementiran u sustav vođenja HE Vinodol prikazan je na slici 4.12.



Slika 4.12: Granice pogonske karte generatora jednog agregata implementirane u sustav vođenja elektrane

Poglavlje 5

Metoda za određivanje uzbudne struje i kuta opterećenja sinkronog generatora kao $f(Q, P, U)$

5.1 Uvod

U primjeni regulacije uzbude sinkronog generatora, u komponenti unaprijedne regulacije ključne veličine su struja uzbude I_f i kut opterećenja δ , koje bi trebale biti poznate za svaku željenu radnu točku u prostoru Q, P, U . Unaprijednom regulacijom postiže se veća brzina regulacije uz manji iznos oscilacija oko postavne vrijednosti. Računalno nezahtjevnim funkcijama se u cijelom radnom području sinkronog generatora definiranom prostorom Q, P, U mogu izraziti struja uzbude I_f i kut opterećenja δ , što je jednostavno primjenjivo u programabilnom industrijskom sklopovlju regulatora uzbude.

Veličine I_f i δ izražene kroz polinomne funkcije $f(Q, P, U)$ identificiraju se na gustom skupu stacionarnih radnih točaka u punom rasponu radnog područja, s cjelovito definiranim elektromagnetskim veličinama sinkronog generatora. Skup za identifikaciju treba imati veći broj radnih točaka s koordinatama Q i P u dopuštenom radnom području sinkronog generatora i u mogućem rasponu vrijednosti napona U na stezaljkama generatora u paralelnom radu na električnoj mreži. Takav sveobuhvatan skup radnih točaka praktički je nemoguće dobiti mjerenjima na velikim sinkronim generatorima u komercijalnom radu zbog zahtjeva na generator, stanja elektroenergetskog sustava i naponskih prilika u mreži. Stoga je skup radnih točaka za identifikaciju dobiven pomoću modela stacionarnih stanja sinkronog generatora baziranog na sigmoidnim $\Psi(I)$ funkcijama.

5.2 Opis metode

Struju uzbuđene I_f i kut opterećenja δ moguće je izraziti kroz sljedeće polinomne funkcije trećeg stupnja:

$$\begin{aligned}
 I_f = f(Q, P, U) = & kf_1 + kf_2(Q - kf_{21}) + kf_3(P - kf_{22}) + kf_4(U - kf_{23}) \\
 & + kf_5(Q - kf_{21})^2 + kf_6(P - kf_{22})^2 + kf_7(U - kf_{23})^2 + kf_8(Q - kf_{21})(P - kf_{22}) \\
 & + kf_9(Q - kf_{21})(U - kf_{23}) + kf_{10}(P - kf_{22})(U - kf_{23}) + kf_{11}(Q - kf_{21})^3 \\
 & + kf_{12}(P - kf_{22})^3 + kf_{13}(U - kf_{23})^3 + kf_{14}(Q - kf_{21})^2(P - kf_{22}) \\
 & + kf_{15}(Q - kf_{21})^2(U - kf_{23}) + kf_{16}(P - kf_{22})^2(Q - kf_{21}) \\
 & + kf_{17}(P - kf_{22})^2(U - kf_{23}) + kf_{18}(U - kf_{23})^2(Q - kf_{21}) \\
 & + kf_{19}(U - kf_{23})^2(P - kf_{22}) + kf_{20}(Q - kf_{21})(P - kf_{22})(U - kf_{23})
 \end{aligned} \tag{5.1}$$

$$\begin{aligned}
 \delta = f(Q, P, U) = & kd_1 + kd_2(Q - kd_{21}) + kd_3(P - kd_{22}) + kd_4(U - kd_{23}) \\
 & + kd_5(Q - kd_{21})^2 + kd_6(P - kd_{22})^2 + kd_7(U - kd_{23})^2 + kd_8(Q - kd_{21})(P - kd_{22}) \\
 & + kd_9(Q - kd_{21})(U - kd_{23}) + kd_{10}(P - kd_{22})(U - kd_{23}) + kd_{11}(Q - kd_{21})^3 \\
 & + kd_{12}(P - kd_{22})^3 + kd_{13}(U - kd_{23})^3 + kd_{14}(Q - kd_{21})^2(P - kd_{22}) \\
 & + kd_{15}(Q - kd_{21})^2(U - kd_{23}) + kd_{16}(P - kd_{22})^2(Q - kd_{21}) \\
 & + kd_{17}(P - kd_{22})^2(U - kd_{23}) + kd_{18}(U - kd_{23})^2(Q - kd_{21}) \\
 & + kd_{19}(U - kd_{23})^2(P - kd_{22}) + kd_{20}(Q - kd_{21})(P - kd_{22})(U - kd_{23})
 \end{aligned} \tag{5.2}$$


Identifikacija se provodi pomoću metode najmanjih kvadrata koja pronalazi takve koeficijente $kf_1 \dots kf_{23}$ i $kd_1 \dots kd_{23}$ s kojima bi suma kvadrata odstupanja funkcija za sve točke bila najmanja, pri čemu se za traženje globalnog minimuma koristi postupak optimiranja DE. Funkcije cilja $G_f(kf_1 \dots kf_{23})$ i $G_\delta(kd_1 \dots kd_{23})$ za koje se traži globalni minimum definiraju se kao sume kvadrata odstupanja funkcija (5.1) i (5.2) modela za N radnih točaka, a koeficijenti $kf_1 \dots kf_{23}$ i $kd_1 \dots kd_{23}$ u ovom dijelu postupka su varijable funkcija po kojima se provodi optimiranje, prema sljedećem za funkciju struje uzbuđene I_f :

$$G_f(kf_1, \dots, kf_{23}) = \sum_{i=1}^N [I_{f,i} - I_f(Q_i, P_i, U_i, kf_1, \dots, kf_{23})]^2 \rightarrow \min! \tag{5.3}$$


i za funkciju kuta opterećenja δ :

$$G_\delta(kd_1, \dots, kd_{23}) = \sum_{i=1}^N [\delta_i - \delta(Q_i, P_i, U_i, kd_1, \dots, kd_{23})]^2 \rightarrow \min! \tag{5.4}$$

Raster radnih točaka za identifikaciju (plave točke) i validaciju (crvene točke) u Q - P koordinatnom sustavu prikazan je na slici 5.1.



Slika 5.1: Raster radnih točaka za identifikaciju (plavo) i validaciju (crveno) u Q – P koordinatnom sustavu generatora



Slika 5.2: Radne točke za identifikaciju $I_f = f(Q, P, U)$


Na slici 5.2 prikazane su radne točke za identifikaciju funkcije $I_f = f(Q, P, U)$ s vrijednostima uzbudne struje u trodimenzionalnom prikazu na bazi koordinatnog sustava $Q - P$ pogonske karte, iz dvije perspektive zbog zornijeg prikaza. Identifikacija funkcija (5.1) i (5.2) napravljena je na istom primjeru generatora G1 u HE Vinodol, obrađenom u 3 poglavlju. Skup stacionarnih radnih točaka za identifikaciju treba biti sveobuhvatan, sastojati se od većeg broja radnih točaka. Pomoću sigmoidnih $\Psi(I)$ funkcija izračunat je skup od 1197 stacionarnih radnih točaka za identifikaciju, određen u rasteru po Q i P s inkrementom od 0,05 p.u. i limitima $S < 1$ p.u., $-0,5 < Q < 0,7$ p.u., $0 < P < 0,9$ p.u. i naponom na stezaljkama generatora u paralelnom radu na mreži $0,95 < U < 1,05$ p.u., što predstavlja gusti raster radnih točaka, realno moguć s obzirom na električnu mrežu i dozvoljen s obzirom na pogonsku kartu. Također, točke za identifikaciju $\delta = f(Q, P, U)$ s vrijednostima kuta opterećenja prikazane su trodimenzionalno na bazi koordinatnog sustava $Q - P$ pogonske karte na slici 5.3, isto tako iz dvije perspektive.

Uz postavljene funkcije cilja (5.3) i (5.4) dodatno nisu postavljene funkcije ograničenja, kao niti ograničenja za varijable $kf_1 \dots kf_{23}$ i $kd_1 \dots kd_{23}$. Postupkom optimiranja dobiva se iznos minimuma za funkcije cilja $G_f(kf_1 \dots kf_{23})$ i $G_\delta(kd_1 \dots kd_{23})$ pri varijablama $kf_1 \dots kf_{23}$ i $kd_1 \dots kd_{23}$ koje su rješenje problema.

Postupak optimiranja DE se prema postavljenim parametrima prikazanim u tablici 5.1 za funkciju struje uzbuđene iterativno provodi kroz generacije, sve dok se ne zadovolji jedan od postavljenih uvjeta zaustavljanja algoritma.

Inicijalne vrijednosti svih koeficijenata postavljene su na nulu. Optimiranje traje 2983 sekunde i zaustavlja se po uvjetu završetka postizanjem ciljane vrijednosti funkcije cilja $VTR = 1 \cdot 10^{-2}$ p.u.. Ciljana vrijednost postiže se kroz 22149 generacija i 5537404 evaluacije uz srednje vrijeme evaluacije od 0,5387 ms. Pronađeni globalni minimum funkcije cilja $G_f(kf_1 \dots kf_{23})$ lociran je u 23-dimenzionalnom prostoru na koordinatama $kf_1 \dots kf_{23}$ prikazanim u tablici 5.2. Identificirana funkcija $I_f = f(Q, P, U)$ validirana je na skupu od 1179 radnih točaka prikazanih na slici 5.4 koje se razlikuju od točaka za identifikaciju i nalaze između njih.

Vizualni izgled identificirane funkcije na slici 5.5, s vrijednostima I_f po koordinatama Q i P , kao površinama u trodimenzionalnom prostoru izraženima parametarski po tri vrijednosti napona U na stezaljkama generatora, prikazan je iz dvije perspektive zbog zornijeg prikaza. Na istoj slici, uz površinski prikaz funkcije prikazane su i točke po kojima je funkcija identificirana, gdje je vidljivo dobro poklapanje.



Slika 5.3: Radne točke za identifikaciju $\delta = f(Q, P, U)$

Napravljena je provjera točnosti identificirane funkcije $I_f = f(Q, P, U)$ kojom se za svaku i -tu validacijsku radnu točku izračunava apsolutna greška na sljedeći način:

$$E_{Af,i} = |I_{f,i} - I_f(Q_i, P_i, U_i)| \quad (5.5)$$

i relativna greška na sljedeći način:

$$E_{Rf,i} = \left| \frac{I_{f,i} - I_f(Q_i, P_i, U_i)}{I_{f,i}} \right| \quad (5.6)$$

Srednja i maksimalna vrijednost greške uzbudne struje izračunate prema (5.5) i (5.6) su u tablici 5.5 prikazane zajedno s greškama za kut opterećenja generatora, tj. usporedno za obje funkcije


Tablica 5.1: Parametri postupka optimiranja za rješavanje (5.3) po $kf_1 \dots kf_{23}$

OPIS	PARAMETAR
Mutacijski faktor	$F = 0,8$
Vjerojatnost križanja	$\eta_{CR} = 0,7$
Ciljana vrijednost funkcije cilja kao 1. uvjet završetka (eng. value to reach)	$VTR = 1 \cdot 10^{-2}$ p.u.
Broj generacija kao 2. uvjet završetka	$G = 30000$
Maksimalno vrijeme izvršavanja kao 3. uvjet završetka	$T = 4000$ s
Broj parametara vektora čija optimalna vrijednost se traži	$D_d = 23$
Minimalna vrijednost parametara vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$d_{min} = -20$ p.u.
Maksimalna vrijednost parametara vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$d_{max} = 20$ p.u.
Populacija	$N_p = 250$

Tablica 5.2: Vrijednosti koeficijenata $kf_1 \dots kf_{23}$ identificirane računalno nezahtjevne funkcije
 $I_f = f(Q, P, U)$


Koeficijent:	kf_1	kf_2	kf_3	kf_4	kf_5	kf_6	kf_7	kf_8
Vrijednost:	1,1726	1,1335	0,593	1,4618	0,3019	0,4294	5,5989	-0,2642
Koeficijent:	kf_9	kf_{10}	kf_{11}	kf_{12}	kf_{13}	kf_{14}	kf_{15}	kf_{16}
Vrijednost:	0,6938	-1,1746	0,0427	-0,2399	15,8023	0,2211	0,4158	-0,1053
Koeficijent:	kf_{17}	kf_{18}	kf_{19}	kf_{20}	kf_{21}	kf_{22}	kf_{23}	
Vrijednost:	-0,7761	6,9262	1,4838	1,7551	0,0261	0,4292	0,9952	

$I_f = f(Q, P, U)$ i $\delta = f(Q, P, U)$. Apsolutne greške za svaku pojedinu točku prikazane su na slici 5.6 u trodimenzionalnom prikazu, u dvije perspektive prikazane bojom koja izražava njen iznos.




Slika 5.4: Radne točke za validaciju funkcije $I_f = f(Q, P, U)$

Za funkciju kuta opterećenja generatora postupak optimiranja DE iterativno se provodi kroz generacije, sve dok se ne zadovolji jedan od postavljenih uvjeta zaustavljanja algoritma, prema postavljenim parametrima prikazanim u tablici 5.3 .



Slika 5.5: Preklapanje funkcije $I_f = f(Q, P, U)$ s radnim točkama za validaciju

Inicijalne vrijednosti svih koeficijenata su i za ovu funkciju postavljene su na nulu. Optimiranje traje 2865 sekundi i zaustavlja se po uvjetu završetka postizanjem ciljane vrijednosti funkcije cilja $VTR = 1 \cdot 10^{-2}$ p.u.. Ciljana vrijednost postiže se kroz 21113 generacija i 5278335 evaluacija uz srednje vrijeme evaluacije od 0,5428 ms. Pronađeni globalni minimum funkcije cilja $G_\delta(kd_1 \dots kd_{23})$ lociran je u 23-dimenzionalnom prostoru na koordinatama $kd_1 \dots kd_{23}$ prikazanim u tablici 5.4.



Slika 5.6: Greške funkcije $I_f = f(Q, P, U)$

Identificirana funkcija $\delta = f(Q, P, U)$ također je validirana je na skupu od 1179 radnih točaka prikazanih na slici 5.7 koje se razlikuju od točaka za identifikaciju i nalaze između njih. Isto tako, vizualni izgled identificirane funkcije na slici 5.8, s vrijednostima δ po Q i P , kao površinama u trodimenzionalnom prostoru izraženima parametarski po tri vrijednosti napona U na stezaljakama generatora, prikazan je iz dvije perspektive zbog zornijeg prikaza, zajedno s radnim točkama po kojima je funkcija identificirana, pri čemu se vidi dobro poklapanje.

Tablica 5.3: Parametri postupka optimiranja za rješavanje (5.4) po $kd_1 \dots kd_{23}$

OPIS	PARAMETAR
Mutacijski faktor	$F = 0,8$
Vjerojatnost križanja	$\eta_{CR} = 0,7$
Ciljana vrijednost funkcije cilja kao 1. uvjet završetka (eng. value to reach)	$VTR = 1 \cdot 10^{-2}$ p.u.
Broj generacija kao 2. uvjet završetka	$G = 30000$
Maksimalno vrijeme izvršavanja kao 3. uvjet završetka	$T = 4000$ s
Broj parametara vektora čija optimalna vrijednost se traži	$D_d = 23$
Minimalna vrijednost parametra vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$d_{min} = -5$ p.u.
Maksimalna vrijednost parametra vektora u višedimenzionalnom prostoru u kojemu se traži rješenje	$d_{max} = 5$ p.u.
Populacija	$N_p = 250$

Tablica 5.4: Vrijednosti koeficijenata $kd_1 \dots kd_{23}$ identificirane računalno nezahtjevne funkcije $\delta = f(Q, P, U)$


Koeficijent:	kd_1	kd_2	kd_3	kd_4	kd_5	kd_6	kd_7	kd_8
Vrijednost:	0,2157	-0,1977	0,4928	-0,534	0,1545	-0,242	0,5204	-0,3681
Koeficijent:	kd_9	kd_{10}	kd_{11}	kd_{12}	kd_{13}	kd_{14}	kd_{15}	kd_{16}
Vrijednost:	0,645	-1,0317	-0,0651	0,0435	-1,0357	0,1777	-0,5174	0,4417
Koeficijent:	kd_{17}	kd_{18}	kd_{19}	kd_{20}	kd_{21}	kd_{22}	kd_{23}	
Vrijednost:	1,2048	-1,1097	0,1337	0,8176	-0,0007	0,3801	0,9903	

Napravljena je provjera točnosti identificirane funkcije $\delta = f(Q, P, U)$ kojom se za svaku i -tu validacijsku radnu točku izračunava apsolutna greška na sljedeći način:

$$E_{A\delta,i} = |\delta_i - \delta(Q_i, P_i, U_i)| \quad (5.7)$$

i relativna greška na sljedeći način:

$$E_{R\delta,i} = \left| \frac{\delta_i - \delta(Q_i, P_i, U_i)}{\delta_i} \right| \quad (5.8)$$




Slika 5.7: Radne točke za validaciju funkcije $\delta = f(Q, P, U)$

Za greške po radnim točkama izračunate prema (5.5), (5.6), (5.7) i (5.8) izdvojene su maksimalne vrijednosti i izračunate srednje vrijednosti za obje funkcije $I_f = f(Q, P, U)$ i $\delta = f(Q, P, U)$, što je prikazano u tablici 5.5.

Apsolutne greške funkcije $\delta = f(Q, P, U)$ za svaku pojedinu točku prikazane su trodimenzionalno na slici 5.9, u dvije perspektive i bojom koja izražava njihov iznos.

Zaključno, može se utvrditi da opisane polinomne funkcije pouzdano opisuju struju uzbuđene I_f i kut opterećenja δ u prostoru Q, P, U . Njihove maksimalne apsolutne greške u iznosima od 0,0135 p.u. za struju uzbuđene i 0,67° el. za kut opterećenja potvrđuju stabilnost funkcija, a srednje greške u iznosima od 0,0036 p.u. za struju uzbuđene i 0,12° el. za kut opterećenja njihovu




Slika 5.8: Preklapanje funkcije $\delta = f(Q, P, U)$ s radnim točkama za validaciju

Tablica 5.5: Vrijednosti grešaka funkcija $I_f = f(Q, P, U)$ i $\delta = f(Q, P, U)$

GREŠKA	E_{Af} , p.u.	E_{Rf} , %	$E_{A\delta}$, °el.	$E_{R\delta}$, %
Maksimalna	0,0135	2,33	0,67	807,58
Srednja	0,0036	0,31	0,12	4,59

visoku preciznost. Točnost funkcije $\delta = f(Q, P, U)$ izraženu s relativnim greškama znatno kvari činjenica da se najveće greške funkcije pojavljuju u dijelu s najmanjim vrijednostima kuta opterećenja, što je vidljivo u prvom dijelu slike 5.9. Trodimenzionalni pregled na slikama 5.5 i 5.8 vizualno prikazuje gotovo potpuno poklapanje vrijednosti funkcija s radnim točkama na kojima su te funkcije identificirane. S druge strane, mogućnost implementacije polinomnih funkcija



Slika 5.9: Greške funkcije $\delta = f(Q, P, U)$


u industrijsko programabilno sklopovlje, predmetne funkcije ističe kao jednostavne i učinkovite za praktičnu primjenu. Sveobuhvatni skupovi radnih točaka za identifikaciju i validaciju opisanih funkcija izračunati su modelom stacionarnih stanja sinkronog generatora baziranim na sigmoidnim $\Psi(I)$ funkcijama. Funkcije za izražavanje struje uzbuđene i kuta opterećenja su računalno nezahtjevne funkcije koje se identificiraju praktički jednakom metodom kao i prethodno opisane računalno nezahtjevne funkcije za izražavanje granica pogonske karte sinkronog generatora.

Poglavlje 6


Zajednička pogonska karta grupe paralelno spojenih generatora

6.1 Uvod

U pogonu s dva ili više generatora svaka ukupna djelatna snaga teoretski se može rasporediti po generatorima u beskonačnom broju kombinacija. Djelatna snaga po generatorima može se rasporediti po raznim principima, a granice zajedničke pogonske karte ovise o tom rasporedu. Principi raspoređivanja djelatne snage po pojedinim generatorima mogu biti utemeljeni npr. na sekvencijalnom terećenju (generatori sekvencijalno jedan za drugim daju svoj doprinos u ukupnoj snazi) kao što je prikazano na slici 6.1, paralelnom terećenju (istovremeni raspored na jednake iznose) prikazanom na slici 6.2 ili npr. optimiranom radu po raznim kriterijima.



Slika 6.1: Sekvencijalno terećenje grupe od tri generatora



Slika 6.2: Paralelno terećenje grupe od tri generatora

Za sve principe raspoređivanja među generatorima moraju važiti sljedeći osnovni uvjeti:


$$P_{sum} = P_1 + P_2 + P_3 \quad (6.1)$$

$$P_1 \geq 0, P_2 \geq 0, P_3 \geq 0 \quad (6.2)$$

6.2 Opis metode

Na slici 6.3 prikazana je metodologija određivanja granica u kapacitivnom dijelu zajedničke pogonske karte grupe jednakih generatora koji rade u načinu rada sekvencijalnim terećenjem pojedinih generatora. Osnovni preduvjet metodologije je poznavanje granica pogonske karte svakog generatora, izražene računalno nezahtevnim funkcijama.

U ovom dijelu opisa metodologije koji se odnosi na predmetnu sliku razrađene su granice pogonske karte u njenom lijevom, kapacitivnom dijelu. Na istoj slici se s ciljem efikasnijeg prikaza metodologije nalaze tri dijagrama koji su međusobno povezani. U sredini se nalazi manja pogonska karta pojedinih jednakih generatora, a koncentrično izvan nje nalazi se velika zajednička pogonska karta koja je rezultat ove metodologije, prikazana u zajedničkom jediničnom (p.u.) sustavu veličina svedenom na bazne veličine pojedinog jednakog generatora. U desnom dijelu dijagrama umetnut je raspored sekvencijalnog terećenja pojedinih generatora. Za jedan primjer točke na zajedničkoj pogonskoj karti sa zahtijevanom ukupnom djelatnom snagom P_{sum} prikazanoj na apscisi, od njenog iznosa povučenom vertikalnom linijom određuju se djelatne snage raspoređene na pojedine generatore P_1 , P_2 i P_3 . Za pojedine raspoređene djelatne snage s granice u kapacitivnom dijelu manjeg dijagrama u sredini, koji predstavlja pogonsku kartu jednakih pojedinih generatora očitavaju se pripadajuće pojedinačne jalove snage Q_1 , Q_2 i Q_3 . Očitane pojedinačne jalove snage se sumiraju u Q_{sum} , što predstavlja apscisu točke na granici



Slika 6.3: Određivanje granica u kapacitivnom dijelu zajedničke pogonske karte grupe jednakih generatora u sekvencijalnom terećenju


zajedničke pogonske karte, čija ordinata je prvobitno zadana ukupna djelatna snaga P_{sum} grupe paralelno spojenih generatora. Ponavljanjem istog postupka za sve zadane ukupne djelatne snage za grupu generatora u pravilnom rasteru unutar cijelog raspona snage grupe generatora dobiva se skup točaka koje tvore granicu zajedničke pogonske karte u njenom kapacitivnom dijelu, koja je na ovoj slici označena crvenom bojom.

Na slici 6.4 prikazana je metodologija primijenjena za određivanja granica u kapacitivnom dijelu zajedničke pogonske karte grupe jednakih generatora koji rade u načinu rada paralelnim terećenjem pojedinih generatora. Paralelnim terećenjem ukupna djelatna snaga raspoređuje se u jednakim iznosima na pojedine generatore P_1 , P_2 i P_3 .


Za jednake iznose djelatne snage na granici pogonske karte jednakih generatora u ovom slučaju očitavaju se međusobno jednake jalove snage, čija je suma na jednak način kao i na prethodnoj slici koordinata točke na granici zajedničke pogonske karte.

Ista metodologija primijenjena na grupu različitih generatora, u sekvencijalnom i u paralelnom radu prezentirana je na slikama 6.5 i 6.6. Primjenjuje se zajednički jedinični (p.u.) sustav veličina sveden na bazne veličine onog pojedinog generatora koji ima najveću snagu. Zbog lakšeg razumijevanja suštine metode i izbjegavanja manje bitnih preračunavanja, varijanta primjene metode na različitim generatorima opisana na slikama 6.5, 6.6, 6.8 i 6.10 prezentirana je za slučaj grupe paralelno spojenih generatora s različitim elektromagnetskim svojstvima, ali s jednakim pojedinačnim snagama i ostalim baznim veličinama.

Pojedinačne jalove snage očitavaju se s različitih krivulja granica pogonskih karti, ali njihove sume na jednak način predstavljaju apscise točaka na granici zajedničke pogonske karte




Slika 6.4: Određivanje granica u kapacitivnom dijelu zajedničke pogonske karte grupe jednakih generatora u paralelnom terećenju



Slika 6.5: Određivanje granica u kapacitivnom dijelu zajedničke pogonske karte grupe različitih generatora u sekvencijalnom terećenju

grupe generatora.

U prethodna dva primjera različitih načina raspoređivanja ukupne djelatne snage unutar grupe paralelno spojenih generatora prikazano je da se dobivaju različite granice zajedničke pogonske karte. Nadalje, doktrina raspoređivanja djelatne snage među generatorima umjesto unaprijed predodređenog jednostavnog načina (sekvencijalni ili paralelni), može se temeljiti na principu optimiranja po nekom od kriterija. U kontekstu metodologije izračuna zajedničke pogonske karte zanimljivo je postizanje što veće širine njenih granica koje omeđuju dozvoljeno radno područje, što drugim riječima znači postavljanje cilja što veće dopuštene jalove snage u



Slika 6.6: Određivanje granica u kapacitivnom dijelu zajedničke pogonske karte grupe različitih generatora u paralelnom terećenju

induktivnom i kapacitivnom radu generatora. Budući da je u kapacitivnom radu jalova snaga negativna, u tom smjeru proizlazi kriterij optimiranja zajedničke pogonske karte s traženjem minimuma sume jalove snage, a u induktivnom smjeru njenog maksimuma. Na primjeru pogona s tri hidrogeneratora, bez tehnološkog minimuma djelatne snage (pogon s Pelton turbinama), za određivanje granica zajedničke pogonske karte u kapacitivnom dijelu može se postaviti funkcija cilja optimiranja za svaku ukupnu djelatnu snagu elektrane P_{uk} , od 0 do $P_{uk,max}$:

$$\begin{aligned}
 F_{Q, \text{kap}}(P_1, P_2) = & Q_{1, \text{limit}}(P_1, U) + Q_{2, \text{limit}}(P_2, U) \\
 & + Q_{3, \text{limit}}((P_{uk} - P_1 - P_2), U) \rightarrow \min!
 \end{aligned} \tag{6.3}$$

i također u induktivnom dijelu:

$$\begin{aligned}
 F_{Q, \text{ind}}(P_1, P_2) = & -Q_{1, \text{limit}}(P_1, U) - Q_{2, \text{limit}}(P_2, U) \\
 & - Q_{3, \text{limit}}((P_{uk} - P_1 - P_2), U) \rightarrow \min!
 \end{aligned} \tag{6.4}$$

uz sljedeća ograničenja za oba smjera:

$$P_{uk} \geq P_1 + P_2 \tag{6.5}$$

$$P_{uk} - P_1 - P_2 \leq P_{3,max} \tag{6.6}$$

Postupak optimiranja DE se za svaku pojedinu točku u pravilnom rasteru unutar cijelog raspona snage grupe generatora, prema postavljenim parametrima prikazanima u tablici 6.1 iterativno


Tablica 6.1: Parametri postupka optimiranja za rješavanje (6.3) i (6.4) po P_1 i P_2

OPIS	PARAMETAR
Mutacijski faktor	$F = 0,8$
Vjerojatnost križanja	$\eta_{CR} = 0,7$
Ciljana vrijednost funkcije cilja kao 1. uvjet završetka (eng. value to reach)	<i>Global.</i> <i>Min.</i>
Broj generacija kao 2. uvjet završetka	$G = 35$
Maksimalno vrijeme izvršavanja kao 3. uvjet završetka	$T = 120 \text{ s}$
Broj parametara vektora čija optimalna vrijednost se traži	$D_d = 2$
Minimalna vrijednost parametara vektora u prostoru u kojemu se traži rješenje	$d_{min} = 0 \text{ p.u.}$
Maksimalna vrijednost parametara vektora u prostoru u kojemu se traži rješenje	$d_{max} = 0,9 \text{ p.u.}$
Populacija	$N_p = 40$

provodi kroz generacije, sve dok se ne zadovolji jedan od postavljenih uvjeta zaustavljanja algoritma. Inicijalne vrijednosti koeficijenata postavljene su na nulu. Optimiranje za većinu točaka traje 20 sekundi uz 10 do 14 provedenih iteracija i oko 400 evaluacija. Postupkom optimiranja dobiva se iznos minimuma za funkcije cilja $F_{Q, \text{kap}}$ i $F_{Q, \text{ind}}$ pri varijablama P_1 i P_2 koje su rješenje problema. Pronađeni globalni minimumi funkcija cilja $F_{Q, \text{kap}}$ i $F_{Q, \text{ind}}$ locirani su u trodimenzionalnom prostoru na koordinatama P_1 i P_2 , pomoću kojih se iz zadanog P_{uk} za svaku točku granice pomoću (6.1) izračunava treća koordinata P_3 . Ova rješenja postupka optimiranja prikazana su na slikama 6.7 i 6.8 gdje u desnom dijelu predstavljaju raspored tereta, tj. djelatnih snaga među generatorima optimiran s ciljem postizanja čim šire zajedničke pogonske karte u smislu jalove snage.


Raspored je složeniji nego kod prethodno opisanih principa, terećenje djelatnom snagom među generatorima prepliće se ovisno o položaju točke na granici pogonske karte, ali rezultira najširim granicama pogonske karte, u ovom slučaju u njenom lijevom, kapacitivnom dijelu, za grupe od tri jednaka i tri različita generatora.

Na slikama od 6.3 do 6.8 prikazana je metodologija izračuna zajedničke pogonske karte u njenom kapacitivnom dijelu za grupe jednakih i različitih generatora u tri različita načina raspodjele djelatne snage. Principi izračuna zajedničke pogonske karte u njenom induktivnom dijelu su jednaki, s jedinom razlikom koja se nalazi u postupku optimiranja, u kojem se za funkciju cilja umjesto (6.3) koristi (6.4). Rezultati izračuna pogonske karte u njenom induktivnom dijelu




Slika 6.7: Određivanje granica u kapacitivnom dijelu zajedničke pogonske karte grupe jednakih generatora u optimiranom načinu rada


prikazani su u sklopu zajedničke pogonske karte za grupu jednakih generatora na slikama 6.9 i za grupu različitih generatora na slikama 6.10. Izračunate su granice zajedničke pogonske karte za tri različita principa raspodjele djelatne snage među generatorima, što je usporedno prikazano na svakoj od slika. Na zasebnim slikama prikazane su izračunate varijante za vrijednosti napona armature $U = 0,95$ p.u., $U = 1,00$ p.u. i $U = 1,05$ p.u..



Slika 6.8: Određivanje granica u kapacitivnom dijelu zajedničke pogonske karte grupe različitih generatora u optimiranom načinu rada



Slika 6.9: Granice zajedničke pogonske karte grupe jednakih generatora pri $U = 0,95$ p.u., $U = 1,00$ p.u. i $U = 1,05$ p.u.



Slika 6.10: Granice zajedničke pogonske karte grupe različitih generatora pri $U = 0,95$ p.u., $U = 1,00$ p.u. i $U = 1,05$ p.u.

Zaključno, prezentirana metodologija pokazala je da granice zajedničke pogonske karte grupe paralelno spojenih sinkronih generatora ovise o načinu raspoređivanja ukupne djelatne snage među pojedinim generatorima. Opisani su pojedini načini raspoređivanja ukupne djelatne snage, a među njima je prikazan jedan od mogućih načina raspoređivanja izračunat pomoću postupka optimiranja čiji cilj može biti što veća širina dozvoljenog radnog područja pogonske karte. Taj optimirani način raspoređivanja rezultira s najširim granicama zajedničke pogonske karte. S te točke gledišta, paralelno terećenje je drugo po redu, a sekvencijalno terećenje ima najslabiji rezultat, jer granice zajedničke pogonske karte koje proizlaze iz takvog načina rada opisuju najuže dozvoljeno radno područje. Prikazani su načini raspoređivanja ukupne djelatne snage koji elektrani kao cjelini omogućavaju da pruži veći dozvoljeni raspon jalove snage za istu djelatnu snagu. U postupku optimiranja može se prikazana funkcija cilja kombinirati s drugim ciljevima, kao što su minimiziranje ukupnih gubitaka, što je korisniku elektrane uvijek zanimljiv cilj.

Poglavlje 7

Zaključak

Moderni električni strojevi projektiraju se optimirano s maksimalnim iskorištenjem materijala. Posljedica toga je radno područje stroja u nelinearnom području magnetske karakteristike željeza i velikim strujnim opterećenjima. U takvim radnim uvjetima induktiviteti u stroju izrazito su promjenjivi s radnim točkama opterećenja stroja. S druge strane, otvaranjem tržišta električne energije i definiranjem pomoćnih usluga elektroenergetskom sustavu koje su dio istog tržišta, korisnicima strojeva, odnosno operaterima proizvodnje i elektroenergetske mreže porastao je interes za mogućnošću korištenja strojeva u što širem radnom području. Zbog toga je potrebno čim pouzdanije i točnije odrediti stvarne granice dozvoljenog radnog područja velikih proizvodnih jedinica, što u prethodno navedenim uvjetima nelinearnosti nije jednostavan problem.

Postoji niz načina za izračun utjecaja nelinearnosti na odnose elektromagnetskih veličina u stroju, čiji pregled je napravljen u uvodnom dijelu ovog rada. U traženju najjednostavnijeg i najefikasnijeg načina opisivanja stacionarnih radnih stanja sinkronih strojeva, model sa strujno ovisnim funkcijama ulančenih tokova ($\Psi(I)$) pokazao se je najboljim. U slučaju njihova opisivanja polinomnim funkcijama osnovna prednost u postavljanju modela je ta da se identifikacija koeficijenata složenog nelinearnog sustava svodi na rješavanje linearnog sustava jednadžbi. Jednom identificiran model nadalje se jednostavno koristi pomoću polinomnih $\Psi(I)$ funkcija u svim pogonskim stanjima na kojima je model identificiran. U daljnjem testiranju polinomnih $\Psi(I)$ funkcija uočena je njihova nezgodna karakteristika u kojoj znatno gube točnost odmah izvan područja u kojem su identificirane, premda su vrlo točne unutar tog područja.

Osnovni problem pri postavljanju modela stacionarnih stanja sinkronog generatora čija namjena bi bila izračunavanje granica pogonske karte je u tome što traženi model treba čim točnije opisivati ponašanje stroja u rubnom području oko granica pogonske karte i izvan dozvoljenog područja, a u tom području u praksi na velikim generatorima u komercijalnoj upotrebi nije dozvoljeno niti moguće napraviti mjerenja na kojima bi se taj model identificirao. Time je istaknuta potreba za pronalaženjem takvog modela koji bi na osnovi poznatog ponašanja stroja

u dozvoljenom području rada čim točnije opisivao ponašanje stroja u nedozvoljenom području rada, odnosno izvan granica pogonske karte. Stoga se je za izražavanje $\Psi(I)$ funkcija umjesto polinomnih pribjeglo korištenju sigmoidnih funkcija, čiji oblik odgovara izgledu nelinearne krivulje magnetiziranja stroja. Takvom funkcijom omogućava se bolje predviđanje nelinearnih magnetskih pojava u stroju, izvan dozvoljenog područja u kojemu je model identificiran.

U sklopu razvoja modela, za njegovu validaciju bilo je potrebno poznavati elektromagnetske prilike i u radnim točkama izvan zone dozvoljenog radnog područja. Budući da mjerenje takvih točaka nije moguće, preostalo je do potrebnih podataka doći izračunom, a zbog dosljednosti u razvoju modela bitno je da su za oba skupa, za identifikaciju i validaciju, s ciljem izbjegavanja diskontinuiteta primijenjene točke koje su dobivene na isti način. Za ovakav izračun prikladna je metoda konačnih elemenata (MKE), koja je u razvoju modela odabrana kao referentna. Tom metodom izračunate su potrebne radne točke i pojedine granice pogonske karte. Bitno je naglasiti da ovaj izračun nije postupak koji bi se provodio za svaki konkretni sinkroni generator u identifikaciji postavljenog modela, već za razvoj zajedničkog univerzalnog modela za sve sinkrone generatore, pa brzina postupka nije bitna, ali čim veća točnost svakako jest.

Greške ulančenih tokova izračunatih pomoću sigmoidnih $\Psi(I)$ funkcija uspoređene su s greškama izračuna pomoću polinomnih $\Psi(I)$ funkcija i pomoću klasičnog modela. Može se zaključiti da sigmoidne $\Psi(I)$ funkcije imaju značajno manje srednje i maksimalne greške, gledajući sumarno u cijelom području koje obuhvaća obje zone identifikacije i validacije. Gledajući samo zonu identifikacije, polinomne $\Psi(I)$ funkcije imaju veću točnost, bez velikih odstupanja u pojedinim radnim točkama, ali izvan zone identifikacije znatno gube svoju točnost uz velika odstupanja među pojedinim radnim točkama. Nadalje, izračunate su granice pogonske karte pomoću identificiranih sigmoidnih $\Psi(I)$ funkcija i uspoređene s granicama dobivenim pomoću polinomnih $\Psi(I)$ funkcija i pomoću klasičnog modela. Granice pogonske karte izračunate sigmoidnim $\Psi(I)$ funkcijama najbolje se poklapaju s granicama izračunatima pomoću referentnog MKE modela i opisuju znatno šire dozvoljeno radno područje od granica pogonske karte izračunatih klasičnim modelom, koji ne uzima u obzir magnetsko zasićenje stroja niti efekt poprečne magnetizacije. Granice pogonske karte izračunate polinomnim $\Psi(I)$ funkcijama u područjima izvan zona u kojima su te funkcije identificirane, gube svoj fizikalni smisao, na primjer na krivuljama konstantne struje uzbude odstupajući značajno od oblika sličnog Pascalovim krivuljama.

Zbog toga što se granice pogonske karte dinamički mijenjaju s radnim točkama stroja i zbog omogućavanja njihove implementacije u industrijsko programabilno sklopovlje sustava vođenja elektrane koje radi u stvarnom vremenu, istaknula se je potreba za izražavanjem dinamičkih granica računalno nezahtjevnim funkcijama oblika $Q = f(U, P)$. U radu su predložene računalno nezahtjevne funkcije oblikom ovisnim o kojoj se granici radi i identificirane rasterom točaka granica izračunatih sigmoidnim $\Psi(I)$ funkcijama. Usporedbom je utvrđeno gotovo potpuno poklapanje granica izračunatih računalno nezahtjevnim funkcijama s granicama s kojima

su one identificirane i može se zaključiti da predmetne funkcije vjerno opisuju izvorne granice pogonske karte. Model sa sigmoidnim $\Psi(I)$ funkcijama u ovoj metodi poslužio je za izračun velike detaljne grupe granica pogonske karte, pri svim realno očekivanim naponima na stezaljkama generatora, kako bi računalno nezahtjevne funkcije izražavale granice pogonske karte u čim širem očekivanom rasponu radnog područja generatora. Izračun grupe granica pogonske karte pomoću sigmoidnih $\Psi(I)$ funkcija računalno je zahtjevan i provodi se prethodno, izvan stvarnog vremena, kao i identifikacija računalno nezahtjevnih funkcija. Nakon njihove identifikacije s granicama, računalno nezahtjevne funkcije mogu se implementirati u industrijsko programabilno sklopovlje sustava vođenja elektrane i u stvarnom vremenu efikasno dinamički izražavati granice pogonske karte, ovisno o pogonskim uvjetima. U komponenti unaprijedne regulacije regulacije uzbude sinkronog generatora ključne veličine su struja uzbude I_f i kut opterećenja δ , koje bi trebale biti poznate za svaku željenu radnu točku u prostoru Q, P, U . Unaprijednom regulacijom postiže se veća brzina regulacije uz manji iznos oscilacija oko postavne vrijednosti. Zbog toga se je istaknula potreba za postavljanjem računalno nezahtjevnih funkcija kojima se u cijelom radnom području sinkronog generatora definiranom prostorom Q, P, U mogu izraziti struja uzbude I_f i kut opterećenja δ , što je jednostavno primjenjivo u programabilnom industrijskom sklopovlju regulatora uzbude. U radu su opisane polinomne računalno nezahtjevne funkcije te njihova identifikacija i validacija s gustim rasterom radnih točaka izračunatih modelom stacionarnih stanja sinkronog generatora baziranim na sigmoidnim $\Psi(I)$ funkcijama. Opisane polinomne funkcije pouzdano opisuju struju uzbude I_f i kut opterećenja δ u prostoru Q, P, U . Njihove maksimalne greške u iznosima od 0,0135 p.u. za struju uzbude i $0,67^\circ$ el. za kut opterećenja potvrđuju stabilnost funkcija, a srednje greške u iznosima od 0,0036 p.u. za struju uzbude i $0,12^\circ$ el. za kut opterećenja njihovu visoku preciznost.

Budući da je u praksi uvijek zanimljiv trenutni prikaz mogućnosti isporuke djelatne i jalove snage elektrane s više generatora kao cjeline uz uvijek dobrodošlo optimiranje rada, za to je potrebno istražiti način određivanja zajedničke pogonske karte grupe paralelno spojenih sinkronih generatora. U radu je postavljena metodologija prikaza zajedničke pogonske karte grupe paralelno spojenih sinkronih generatora. Prezentirana metodologija pokazala je da granice zajedničke pogonske karte grupe paralelno spojenih sinkronih generatora ovise o načinu raspoređivanja ukupne djelatne snage među pojedinim generatorima. Opisani su pojedini načini raspoređivanja ukupne djelatne snage, a među njima je prikazan jedan od mogućih načina raspoređivanja izračunat pomoću postupka optimiranja čiji cilj može biti što veća širina dozvoljenog radnog područja pogonske karte. Optimirani način raspoređivanja rezultira s najširim granicama zajedničke pogonske karte. S te točke gledišta, paralelno terećenje je drugo po redu, a sekvencijalno terećenje ima najslabiji rezultat, jer granice zajedničke pogonske karte koje proizlaze iz takvog načina rada opisuju najuže dozvoljeno radno područje. Prikazani su načini raspoređivanja ukupne djelatne snage koji elektrani kao cjelini omogućavaju da pruži veći

dozvoljeni raspon jalove snage za istu djelatnu snagu.

Sumarno u radu su $\Psi(I)$ funkcije potvrđene kao jednostavan i efikasan način opisivanja stacionarnih radnih stanja sinkronog generatora. Prezentiran je daljnji razvoj modela s polinomnih prema sigmoidnim $\Psi(I)$ funkcijama. Opisano je daljnje istraživanje primjene sigmoidnih $\Psi(I)$ funkcija kroz izračunavanje granica pogonske karte, postavljanje temelja za identifikaciju računalno nezahtjevnih funkcija za izračun struje uzbude i kuta opterećenja te za izračun granica pogonske karte. Prikazana je daljnja primjena računalno nezahtjevnih funkcija za izračun granica pogonske karte u svrhu postavljanja metodologije za izračun zajedničke pogonske karte grupe paralelno spojenih sinkronih generatora, sve u želji da prezentirane metode pronađu svoju praktičnu primjenu.

Pogonska karta u kombinaciji s modelom može imati svoju ulogu i u sustavu monitoringa agregata gdje bi se za pogonske točke unutar granica uspoređivanjem šireg seta parametara dobivenih mjerenjem i dobivenih iz validiranog modela, moglo dobivati rane informacije o poremećaju ili kvaru, što može spriječiti daljnje veće štetne posljedice. Potreba istaknuta u [1] ostvarena je u sklopu ovog rada koji opisuje instalirani sustav za nadzor, identifikaciju i prikaz dinamičke pogonske karte.

Mogućnosti daljnjih istraživanja koja bi mogla biti nastavak ovog rada su:

- U postupku optimiranja rasporeda tereta među paralelno spojenim generatorima može se prikazana funkcija cilja uz ciljano što šire radno područje kombinirati i s drugim ciljevima, kao što su minimiziranje ukupnih gubitaka, što je korisniku elektrane uvijek zanimljiv cilj.
- Mreža nije savršeno kruta i nadomješta se s nezanemarivim sinkronim reaktancijama. Jalova komponenta snage stroja uzrokuje takve tokove snaga koji posljedično mijenjaju napon mreže, koji povratno utječe na granice kako je to spomenuto u prethodnoj točki. Generator treba promatrati cjelovito zajedno s bliskim dijelom mreže kako bi se mogle odrediti stvarne granice dopuštenog rada. Slijedom razvoja ove ideje može se postaviti pogonska karta koja ne bi bila ovisna o naponu mreže na spoju s proizvodnim jedinicama, već o topologiji mreže.
- Sustav za nadzor, identifikaciju i prikaz dinamičke pogonske karte može se proširiti s modulom za periodičko uspoređivanje veličina izračunatih pomoću validiranog stacionarnog modela i aktualnih mjerenih stacionarnih veličina. Svaka nova odstupanja ukazivala bi na promjene u stroju, i takav sustav bio bi temelj za razvoj ekspertnog sustava.

Poglavlje 8

Dodatci

Dodatak A

Radne točke u izvornom obliku izračunate iz MKE

U ovom dijelu prikazane su radne točke u izvornom obliku izračunate pomoću MKE za identifikaciju i validaciju modela.

Tablica A.1: Radne točke za identifikaciju modela u izvornom obliku dobivenom iz MKE

Identifikacija							
Radna točka br.	U [V]	I [A]	If [A]	$\varphi, ^\circ$	$\delta, ^\circ$	P [W]	Q [W]
1	10416	970,2	163,438	-90,0117	-0,17189	0	-1,8E+07
2	10426,5	773,85	206,057	-89,8972	-0,0573	35000	-1,4E+07
3	10447,5	579,425	250,24	-90,0117	-0,0573	0	-1,1E+07
4	10447,5	386,925	294,814	-90,0117	-0,0573	0	-7000000
5	10458	192,5	340,561	-90,0117	-0,0573	0	-3500000
6	10468,5	192,5	436,747	90,01175	0	0	3500000
7	10489,5	383,075	487,186	90,01175	0	0	6965000
8	10500	575,575	539,58	90,01175	0	0	10465000
9	10521	766,15	593,147	90,01175	0,057296	0	13965000
10	10552,5	954,8	649,06	90,01175	0,057296	0	17465000
11	10573,5	1143,45	707,71	90,01175	0,057296	0	20965000
12	10605	1334,025	768,706	90,01175	0,057296	0	24465000
13	10626	1520,75	833,221	90,01175	0,057296	0	28000000
14	10636,5	1709,4	900,864	90,01175	0,114592	0	31500000
15	10647	1896,125	971,635	90,01175	0,114592	0	34965000
16	10416	989,45	167,739	-78,7245	6,245245	3500000	-1,8E+07
17	10437	798,875	210,749	-75,9743	5,500399	3500000	-1,4E+07
18	10447,5	612,15	253,759	-71,5625	4,870145	3500000	-1,1E+07
19	10447,5	431,2	297,942	-63,4265	4,297187	3500000	-7000000
20	10458	271,425	343,298	-45,0345	3,781525	3500000	-3500000
21	10468,5	192,5	390,609	-0,0573	3,380454	3500000	0
22	10468,5	273,35	439,093	44,91993	3,036679	3500000	3465000
23	10489,5	429,275	489,532	63,36919	2,7502	3500000	6965000

24	10500	606,375	541,535	71,50519	2,521016	3500000	10465000
25	10531,5	787,325	595,102	75,91697	2,349129	3500000	13965000
26	10552,5	974,05	651,015	78,66717	2,234537	3500000	17465000
27	10584	1160,775	709,274	80,50064	2,06265	3500000	20965000
28	10605	1345,575	770,27	81,87574	1,948058	3500000	24465000
29	10626	1532,3	834,785	82,84977	1,833466	3500000	28000000
30	10636,5	1719,025	902,428	83,65191	1,776171	3500000	31500000
31	10416	1045,275	180,642	-68,2393	12,14672	7000000	-1,8E+07
32	10437	866,25	222,088	-63,4265	10,71432	7000000	-1,4E+07
33	10447,5	696,85	264,316	-56,3218	9,511107	7000000	-1,1E+07
34	10458	546,7	307,717	-45,0345	8,422487	7000000	-7000000
35	10468,5	431,2	352,682	-26,5853	7,505753	6965000	-3500000
36	10468,5	385	398,82	-0,0573	6,703612	6965000	0
37	10479	429,275	446,522	26,47067	6,016062	6965000	3465000
38	10500	542,85	496,179	44,91993	5,500399	7000000	6965000
39	10510,5	691,075	547,791	56,20721	5,042033	7000000	10465000
40	10531,5	854,7	600,967	63,36919	4,640962	7000000	13930000
41	10552,5	1029,875	656,88	68,12474	4,354483	7000000	17465000
42	10584	1206,975	714,748	71,50519	4,068004	7000000	20965000
43	10605	1386	775,744	74,02621	3,83882	7000000	24500000
44	10626	1568,875	839,868	75,97427	3,609637	7000000	28000000
45	10647	1749,825	907,12	77,46396	3,380454	7000000	31500000
46	10416	1129,975	200,583	-59,072	17,41793	10500000	-1,8E+07
47	10437	968,275	240,074	-53,1132	15,41258	10500000	-1,4E+07
48	10447,5	820,05	281,129	-44,9772	13,6937	10500000	-1,1E+07
49	10458	694,925	323,357	-33,6899	12,26131	10500000	-7000000
50	10468,5	610,225	366,758	-18,5066	10,9435	10465000	-3500000
51	10479	577,5	412,114	-0,0573	9,854882	10465000	0
52	10521	608,3	461,771	18,44926	8,823557	10500000	3500000
53	10531,5	691,075	510,646	33,68995	8,021416	10500000	7000000
54	10542	814,275	561,476	44,97722	7,391162	10500000	10500000
55	10531,5	956,725	611,133	53,05594	6,932795	10500000	13965000
56	10552,5	1114,575	666,264	58,95741	6,417133	10500000	17465000
57	10584	1280,125	724,132	63,36919	6,016062	10500000	20965000
58	10605	1449,525	784,346	66,80694	5,672287	10500000	24500000
59	10626	1624,7	848,079	69,44254	5,328512	10500000	28000000
60	10647	1799,875	914,94	71,56249	5,042033	10500000	31500000
61	10416	1241,625	226,78	-51,3371	21,9443	14000000	-1,8E+07
62	10426,5	1095,325	263,925	-44,9772	19,53788	14000000	-1,4E+07
63	10447,5	966,35	302,634	-36,8412	17,53252	14000000	-1,1E+07
64	10458	862,4	343,298	-26,5853	15,75635	14000000	-7000000
65	10479	795,025	385,917	-14,0948	14,20937	13965000	-3500000
66	10479	770	429,709	-0,0573	12,89156	13965000	0
67	10521	791,175	477,411	14,03748	11,63105	14000000	3500000
68	10531,5	856,625	525,504	26,58526	10,59973	14000000	7000000
69	10542	958,65	575,161	36,89851	9,740291	14000000	10500000
70	10552,5	1083,775	624,818	44,91993	9,110037	14000000	13965000
71	10563	1222,375	679,558	51,27977	8,479783	14000000	17465000
72	10594,5	1374,45	736,644	56,2645	7,906824	14000000	20965000
73	10615,5	1536,15	796,467	60,27521	7,448458	14000000	24500000

74	10636,5	1701,7	859,809	63,48378	7,047387	14000000	28035000
75	10647	1871,1	926,279	66,06209	6,646316	13965000	31535000
76	10416	1370,6	257,278	-44,9772	26,01231	17465000	-1,7E+07
77	10426,5	1239,7	292,077	-38,6174	23,3194	17500000	-1,4E+07
78	10447,5	1128,05	328,831	-30,9397	20,97027	17500000	-1E+07
79	10458	1039,5	367,931	-21,7724	18,96492	17500000	-7000000
80	10479	983,675	408,595	-11,2873	17,24604	17500000	-3500000
81	10489,5	962,5	451,214	-0,0573	15,64176	17500000	0
82	10500	979,825	495,788	11,22998	14,26666	17500000	3465000
83	10531,5	1033,725	543,49	21,82971	13,06345	17500000	7000000
84	10552,5	1118,425	592,365	30,93975	12,03212	17500000	10500000
85	10552,5	1224,3	642,022	38,56009	11,17269	17500000	13965000
86	10584	1351,35	695,98	44,97722	10,42784	17500000	17465000
87	10605	1489,95	752,284	50,19115	9,740291	17500000	21000000
88	10615,5	1638,175	811,716	54,48833	9,167332	17500000	24535000
89	10636,5	1794,1	874,276	58,04067	8,708966	17500000	28035000
90	10405,5	1513,05	291,686	-39,7633	29,56465	20965000	-1,7E+07
91	10416	1395,625	323,748	-33,6327	26,64256	21000000	-1,4E+07
92	10447,5	1297,45	358,547	-26,4707	24,12154	21000000	-1E+07
93	10458	1220,45	395,692	-18,3347	21,9443	21000000	-6965000
94	10479	1172,325	435,183	-9,39652	19,99624	21000000	-3465000
95	10489,5	1155	476,238	0	18,27737	21000000	0
96	10510,5	1168,475	519,639	9,453812	16,73038	21000000	3500000
97	10531,5	1212,75	564,604	18,39196	15,35528	21000000	6965000
98	10552,5	1283,975	612,306	26,47067	14,20937	21000000	10465000
99	10563	1380,225	662,354	33,63265	13,17804	21000000	14000000
100	10584	1491,875	715,139	39,8206	12,3186	21000000	17500000
101	10594,5	1618,925	771,052	45,03452	11,57376	21000000	21035000
102	10626	1755,6	829,702	49,4463	10,88621	21000000	24570000
103	10636,5	1899,975	891,48	53,22782	10,31325	20965000	28070000
104	10426,5	1667,05	328,44	-35,5234	32,54403	24500000	-1,8E+07
105	10437	1561,175	358,156	-29,7365	29,56465	24500000	-1,4E+07
106	10458	1472,625	390,609	-23,2048	26,92904	24500000	-1,1E+07
107	10468,5	1405,25	426,19	-15,9282	24,63721	24500000	-7000000
108	10479	1362,9	463,726	-8,13601	22,57456	24500000	-3500000
109	10500	1345,575	503,999	0,114592	20,68379	24500000	35000
110	10521	1359,05	545,836	8,193303	19,02221	24500000	3535000
111	10542	1395,625	590,019	15,98554	17,53252	24500000	7000000
112	10552,5	1459,15	636,548	23,20481	16,21472	24535000	10500000
113	10573,5	1541,925	685,423	29,73653	15,0688	24535000	14035000
114	10584	1643,95	737,426	35,58071	14,09477	24500000	17535000
115	10615,5	1759,45	792,166	40,68004	13,29263	24500000	21070000
116	10605	1886,5	846,906	44,97722	12,60508	24500000	24500000
117	10426,5	1830,675	367,149	-32,0284	35,23693	28000000	-1,8E+07
118	10437	1730,575	394,519	-26,5853	32,20026	28000000	-1,4E+07
119	10458	1651,65	425,017	-20,5692	29,50735	28000000	-1,1E+07
120	10468,5	1591,975	458,643	-14,0375	27,10093	28000000	-7000000
121	10489,5	1555,4	494,615	-7,10468	24,92369	28000000	-3500000
122	10500	1538,075	532,542	0	22,97563	28000000	0
123	10521	1547,7	573,206	7,104683	21,19946	28000000	3500000

124	10531,5	1582,35	615,825	14,03748	19,65247	28000000	7000000
125	10563	1638,175	663,136	20,6265	18,16278	28035000	10570000
126	10584	1711,325	711,229	26,64256	16,90227	28035000	14070000
127	10584	1801,8	758,931	32,02837	15,98554	28000000	17500000
128	10437	1907,675	432,446	-23,9497	34,54938	31500000	-1,4E+07
129	10447,5	1834,525	461,38	-18,4493	31,79918	31500000	-1,1E+07
130	10468,5	1778,7	493,051	-12,5478	29,33546	31500000	-7000000
131	10489,5	1745,975	527,459	-6,35984	27,10093	31500000	-3500000
132	10500	1732,5	564,213	0	25,09557	31500000	0
133	10510,5	1740,2	603,313	6,359837	23,26211	31500000	3500000
134	10531,5	1769,075	644,368	12,54779	21,60053	31500000	7000000
135	10542	1817,2	688,551	18,44926	20,11084	31500000	10500000
136	10563	1884,575	735,08	23,94966	18,79303	31500000	14000000

Tablica A.2: Radne točke za validaciju modela u izvornom obliku dobivenom iz MKE

Validacija							
Radna točka br.	U [V]	I [A]	If [A]	fi	delta	P [W]	Q [W]
1	10311	1557,325	32,844	-90,0117	-0,45837	0	-2,8E+07
2	10353	1360,975	76,636	-90,0117	-0,34377	0	-2,4E+07
3	10395	1164,625	120,037	-90,0117	-0,22918	0	-2,1E+07
4	10657,5	2082,85	1045,534	90,01175	0,114592	0	38430000
5	10647	2267,65	1122,17	90,01175	0,114592	0	41825000
6	10636,5	2454,375	1201,152	90,01175	0,114592	0	45220000
7	10615,5	2639,175	1282,48	90,01175	0,114592	0	48545000
8	10731	2823,975	1409,164	90,01175	0,114592	0	52465000
9	10374	1668,975	23,851	-83,3081	10,82891	3500000	-3E+07
10	10384,5	1472,625	64,124	-82,3914	8,995445	3500000	-2,6E+07
11	10384,5	1278,2	104,006	-81,3028	7,677641	3465000	-2,3E+07
12	10405,5	1083,775	146,234	-79,6985	6,646316	3500000	-1,9E+07
13	10647	1998,15	1009,562	84,56864	1,661579	3500000	36715000
14	10647	2182,95	1084,634	85,02701	1,604283	3500000	40145000
15	10636,5	2369,675	1162,443	85,42808	1,546987	3465000	43540000
16	10626	2554,475	1242,598	85,77185	1,489692	3465000	46865000
17	10720,5	2737,35	1361,071	86,05833	1,432396	3500000	50750000
18	10300,5	2483,25	43,01	-80,9017	73,91162	7000000	-4,4E+07
19	10342,5	1896,125	15,249	-78,0942	25,78312	7000000	-3,3E+07
20	10374	1701,7	46,92	-76,7764	20,85568	7000000	-3E+07
21	10384,5	1511,125	82,892	-75,0575	17,47523	7000000	-2,6E+07
22	10374	1320,55	119,646	-72,9949	14,95421	6965000	-2,3E+07
23	10405,5	1135,75	159,919	-70,0728	13,00615	7000000	-1,9E+07
24	10657,5	2025,1	1013,863	79,24013	3,151271	6965000	36715000
25	10647	2207,975	1088,935	80,15686	3,036679	6965000	40145000
26	10636,5	2390,85	1166,353	80,90171	2,922087	6965000	43540000
27	10626	2573,725	1246,508	81,58926	2,807496	6930000	46865000
28	10720,5	2756,6	1364,59	82,16222	2,692904	7000000	50750000
29	10300,5	2519,825	100,096	-76,4899	77,86503	10500000	-4,4E+07
30	10321,5	2329,25	53,176	-75,4013	57,18124	10500000	-4E+07

31	10332	2134,825	44,574	-74,0262	43,71672	10500000	-3,7E+07
32	10353	1946,175	57,086	-72,4792	34,95046	10500000	-3,3E+07
33	10363,5	1757,525	80,937	-70,5312	28,93439	10500000	-3E+07
34	10374	1572,725	111,435	-68,182	24,52261	10500000	-2,6E+07
35	10395	1391,775	145,061	-65,2027	21,19946	10500000	-2,3E+07
36	10405,5	1216,6	181,424	-61,4211	18,56385	10465000	-1,9E+07
37	10647	2069,375	1021,292	74,08351	4,698258	10465000	36715000
38	10647	2248,4	1095,973	75,40131	4,469075	10430000	40145000
39	10647	2427,425	1173,391	76,54723	4,297187	10430000	43540000
40	10636,5	2608,375	1252,764	77,52126	4,182595	10395000	46865000
41	10720,5	2789,325	1371,237	78,3234	3,953412	10500000	50750000
42	10290	2669,975	173,604	-72,8803	87,37614	14000000	-4,6E+07
43	10300,5	2479,4	127,466	-71,5625	70,53116	14000000	-4,2E+07
44	10332	2290,75	101,269	-70,0155	56,03532	14000000	-3,9E+07
45	10332	2104,025	99,314	-68,182	45,66477	14000000	-3,5E+07
46	10353	1921,15	111,435	-66,0048	38,15902	14000000	-3,2E+07
47	10374	1742,125	133,331	-63,4265	32,54403	14000000	-2,8E+07
48	10395	1568,875	161,092	-60,2752	28,24684	14000000	-2,5E+07
49	10395	1401,4	191,59	-56,3791	24,80909	13965000	-2,1E+07
50	10647	2042,425	995,877	68,23933	6,359837	13965000	35000000
51	10657,5	2217,6	1068,603	70,0728	6,073358	13930000	38430000
52	10647	2390,85	1144,066	71,61978	5,786879	13895000	41860000
53	10636,5	2567,95	1222,266	72,93759	5,614991	13860000	45220000
54	10615,5	2745,05	1302,421	74,08351	5,385808	13825000	48545000
55	10290	2733,5	214,659	-68,9842	85,94374	17500000	-4,6E+07
56	10290	2546,775	179,469	-67,2653	72,7657	17535000	-4,2E+07
57	10311	2363,9	154,836	-65,6037	60,50439	17430000	-3,8E+07
58	10342,5	2182,95	149,753	-63,4265	50,59222	17500000	-3,5E+07
59	10353	2009,7	157,573	-60,9628	43,20105	17500000	-3,2E+07
60	10374	1838,375	174,386	-57,9834	37,41418	17500000	-2,8E+07
61	10395	1672,825	198,237	-54,4883	32,83051	17500000	-2,5E+07
62	10384,5	1516,9	225,216	-50,2484	29,16358	17430000	-2,1E+07
63	10647	1955,8	939,964	61,02006	8,250599	17465000	31535000
64	10657,5	2121,35	1009,171	63,54107	7,849528	17430000	35000000
65	10657,5	2286,9	1081,506	65,66102	7,505753	17395000	38465000
66	10647	2458,225	1156,578	67,49449	7,219274	17360000	41860000
67	10626	2629,55	1233,996	69,04147	6,932795	17325000	45220000
68	10615,5	2802,8	1314,151	70,41657	6,703612	17290000	48545000
69	10300,5	2720,025	240,074	-64,3432	79,01095	21000000	-4,4E+07
70	10321,5	2541	214,268	-62,4525	67,89556	21000000	-4E+07
71	10300,5	2363,9	202,147	-60,2179	58,90011	20965000	-3,7E+07
72	10353	2194,5	200,974	-57,7542	50,53492	21000000	-3,3E+07
73	10342,5	2027,025	209,576	-54,8894	44,46156	20895000	-3E+07
74	10363,5	1869,175	226,389	-51,3944	39,19035	20930000	-2,6E+07
75	10374	1719,025	249,067	-47,3264	34,83586	20965000	-2,3E+07
76	10395	1580,425	276,437	-42,5135	31,16893	20965000	-1,9E+07
77	10636,5	1976,975	921,196	54,77481	10,08407	21000000	29750000
78	10647	2132,9	989,621	57,6969	9,568403	21000000	33250000
79	10668	2290,75	1062,738	60,27521	9,167332	21000000	36750000
80	10678,5	2454,375	1140,938	62,45245	8,708966	21000000	40250000

81	10699,5	2618	1224,612	64,34321	8,365191	21000000	43750000
82	10710	2787,4	1312,978	66,06209	8,021416	21000000	47250000
83	10290	2897,125	299,115	-61,7076	83,59461	24500000	-4,6E+07
84	10311	2723,875	273,309	-59,7595	73,85432	24500000	-4,2E+07
85	10321,5	2552,55	255,714	-57,525	64,80158	24500000	-3,9E+07
86	10342,5	2385,075	248,676	-55,004	56,95205	24500000	-3,5E+07
87	10311	2223,375	252,195	-52,0819	50,8787	24395000	-3,1E+07
88	10332	2069,375	263,143	-48,7587	45,09182	24465000	-2,8E+07
89	10384,5	1925	280,347	-44,9772	39,99249	24500000	-2,5E+07
90	10405,5	1790,25	302,243	-40,6227	35,98178	24500000	-2,1E+07
91	10626	2021,25	907,902	48,81605	11,97483	24500000	28000000
92	10647	2163,7	973,59	52,1392	11,34457	24500000	31500000
93	10657,5	2313,85	1043,579	55,00399	10,82891	24500000	35000000
94	10678,5	2467,85	1119,042	57,52501	10,37054	24500000	38500000
95	10689	2625,7	1199,979	59,75955	9,912178	24500000	42000000
96	10699,5	2785,475	1285,608	61,70761	9,511107	24500000	45500000
97	10300,5	2910,6	330,395	-57,3531	78,3234	28000000	-4,4E+07
98	10321,5	2743,125	311,236	-55,1759	70,0155	28000000	-4E+07
99	10332	2579,5	299,897	-52,7122	62,45245	28000000	-3,7E+07
100	10342,5	2425,5	297,551	-49,9047	55,80614	28000000	-3,3E+07
101	10363,5	2275,35	303,416	-46,7534	49,96196	28000000	-3E+07
102	10384,5	2134,825	315,537	-43,1438	44,97722	28000000	-2,6E+07
103	10395	2002	332,741	-39,0758	40,68004	28000000	-2,3E+07
104	10416	1884,575	354,637	-34,4921	36,95581	28000000	-1,9E+07
105	10605	1965,425	840,259	39,07575	14,61044	28000000	22750000
106	10615,5	2086,7	898,518	43,14376	13,86559	28000000	26250000
107	10636,5	2217,6	961,469	46,7534	13,17804	28000000	29750000
108	10647	2356,2	1028,721	49,90467	12,54779	28000000	33250000
109	10668	2500,575	1101,447	52,71216	11,97483	28000000	36750000
110	10678,5	2650,725	1179,256	55,17588	11,45917	28000000	40250000
111	10699,5	2804,725	1262,148	57,35312	11,0008	28000000	43750000
112	10311	2939,475	365,976	-53,1132	74,1981	31500000	-4,2E+07
113	10332	2781,625	352,291	-50,7068	67,09341	31500000	-3,9E+07
114	10342,5	2629,55	346,035	-48,0139	60,56169	31500000	-3,5E+07
115	10363,5	2483,25	346,817	-44,9772	54,71752	31500000	-3,2E+07
116	10363,5	2346,575	354,637	-41,6541	49,61819	31500000	-2,8E+07
117	10395	2217,6	367,54	-37,8725	45,09182	31500000	-2,5E+07
118	10405,5	2100,175	385,526	-33,6899	41,1384	31500000	-2,1E+07
119	10416	1996,225	407,031	-29,049	37,64336	31500000	-1,8E+07
120	10584	1967,35	784,346	29,04898	17,70441	31500000	17500000
121	10594,5	2063,6	836,74	33,68995	16,67309	31500000	21000000
122	10605	2171,4	893,044	37,87254	15,81365	31500000	24500000
123	10626	2290,75	953,258	41,65407	15,01151	31500000	28000000
124	10647	2417,8	1017,773	44,97722	14,32396	31500000	31500000
125	10657,5	2552,55	1087,371	48,0139	13,6937	31500000	35000000
126	10668	2691,15	1162,443	50,70681	13,06345	31500000	38500000
127	10689	2835,525	1242,598	53,11323	12,54779	31500000	42000000

Radne točke obrađene za razvoj modela

U ovom dijelu prikazane su radne točke dobivene na osnovi izračunatih primjenom MKE i obrađenih i pripremljenih za razvoj univerzalnog modela za izračun stacionarnih stanja i određivanje granica pogonske karte sinkronog generatora.

Tablica A.3: Obrađene radne točke za identifikaciju modela, izražene u p.u., kutovi u rad

Identifikacija									
Radna točka br.	Id	I _q	I _f	Ψ_d	Ψ_q	f _i	delta	P	Q
1	0,504	-0,002	0,418	0,992	-0,003	-1,571	-0,003	0	-0,5
2	0,402	0,00E+00	0,527	0,993	-0,001	-1,569	-0,001	0,001	-0,4
3	0,301	0	0,64	0,995	-0,001	-1,571	-0,001	0	-0,3
4	0,201	0	0,754	0,995	-0,001	-1,571	-0,001	0	-0,2
5	0,1	0,00E+00	0,871	0,996	-0,001	-1,571	-0,001	0	-0,1
6	-0,1	0,00E+00	1,117	0,997	0,00E+00	1,57E+00	0,00E+00	0,00E+00	1,00E-01
7	-0,199	0,00E+00	1,246	0,999	0	1,571	0	0	0,199
8	-0,299	0	1,38	1	0	1,571	0	0	0,299
9	-0,398	0	1,517	1,002	0,001	1,571	0,001	0	0,399
10	-0,496	0	1,66	1,005	0,001	1,571	0,001	0	0,499
11	-0,594	-0,001	1,81	1,007	0,001	1,571	0,001	0	0,599
12	-0,693	-0,001	1,966	1,01	0,001	1,571	0,001	0	0,699
13	-0,79	-0,001	2,131	1,012	0,001	1,571	0,001	0	0,8
14	-0,888	-0,001	2,304	1,013	0,002	1,571	0,002	0	0,9
15	-0,985	-0,002	2,485	1,014	0,002	1,571	0,002	0	0,999
16	0,49	0,155	0,429	0,986	0,108	-1,374	0,109	0,1	-0,5
17	0,391	0,139	0,539	0,989	0,095	-1,326	0,096	0,1	-0,4
18	0,292	0,126	0,649	0,991	0,084	-1,249	0,085	0,1	-0,3
19	0,192	0,115	0,762	0,992	0,075	-1,107	0,075	0,1	-0,2
20	0,093	0,106	0,878	0,994	0,066	-0,786	0,066	0,1	-0,1
21	-0,006	0,1	0,999	0,995	0,059	-0,001	0,059	0,1	0
22	-0,105	0,095	1,123	0,996	0,053	0,784	0,053	0,1	0,099
23	-0,204	0,09	1,252	0,998	0,048	1,106	0,048	0,1	0,199
24	-0,303	0,086	1,385	0,999	0,044	1,248	0,044	0,1	0,299
25	-0,401	0,083	1,522	1,002	0,041	1,325	0,041	0,1	0,399
26	-0,5	0,08	1,665	1,004	0,039	1,373	0,039	0,1	0,499
27	-0,598	0,078	1,814	1,007	0,036	1,405	0,036	0,1	0,599
28	-0,695	0,075	1,97	1,009	0,034	1,429	0,034	0,1	0,699
29	-0,793	0,073	2,135	1,011	0,033	1,446	0,032	0,1	0,8
30	-0,89	0,071	2,308	1,013	0,031	1,46	0,031	0,1	0,9
31	0,45	0,303	0,462	0,97	0,209	-1,191	0,212	0,2	-0,5
32	0,358	0,273	0,568	0,977	0,185	-1,107	0,187	0,2	-0,4
33	0,264	0,248	0,676	0,981	0,164	-0,983	0,166	0,2	-0,3
34	0,169	0,228	0,787	0,985	0,146	-0,786	0,147	0,2	-0,2
35	0,073	0,212	0,902	0,988	0,13	-0,464	0,131	0,199	-0,1
36	-0,023	0,199	1,02	0,99	0,116	-0,001	0,117	0,199	0
37	-0,12	0,188	1,142	0,992	0,105	0,462	0,105	0,199	0,099
38	-0,217	0,18	1,269	0,995	0,095	0,784	0,096	0,2	0,199
39	-0,315	0,173	1,401	0,997	0,088	0,981	0,088	0,2	0,299

40	-0,412	0,166	1,537	1	0,082	1,106	0,081	0,2	0,398
41	-0,51	0,161	1,68	1,002	0,076	1,189	0,076	0,2	0,499
42	-0,607	0,156	1,828	1,005	0,071	1,248	0,071	0,2	0,599
43	-0,704	0,152	1,984	1,008	0,067	1,292	0,067	0,2	0,7
44	-0,801	0,148	2,148	1,01	0,064	1,326	0,063	0,2	0,8
45	-0,898	0,144	2,32	1,012	0,06	1,352	0,059	0,2	0,9
46	0,39	0,439	0,513	0,947	0,297	-1,031	0,304	0,3	-0,5
47	0,308	0,398	0,614	0,958	0,264	-0,927	0,269	0,3	-0,4
48	0,221	0,364	0,719	0,967	0,236	-0,785	0,239	0,3	-0,3
49	0,132	0,336	0,827	0,973	0,211	-0,588	0,214	0,3	-0,2
50	0,041	0,314	0,938	0,979	0,19	-0,323	0,191	0,299	-0,1
51	-0,051	0,296	1,054	0,983	0,171	-0,001	0,172	0,299	0
52	-0,145	0,281	1,181	0,99	0,154	0,322	0,154	0,3	0,1
53	-0,239	0,268	1,306	0,993	0,14	0,588	0,14	0,3	0,2
54	-0,335	0,258	1,436	0,996	0,129	0,785	0,129	0,3	0,3
55	-0,43	0,249	1,563	0,996	0,121	0,926	0,121	0,3	0,399
56	-0,526	0,241	1,704	0,999	0,113	1,029	0,112	0,3	0,499
57	-0,622	0,234	1,852	1,002	0,106	1,106	0,105	0,3	0,599
58	-0,718	0,227	2,006	1,005	0,099	1,166	0,099	0,3	0,7
59	-0,814	0,222	2,169	1,008	0,094	1,212	0,093	0,3	0,8
60	-0,91	0,216	2,34	1,01	0,089	1,249	0,088	0,3	0,9
61	0,317	0,562	0,58	0,92	0,371	-0,896	0,383	0,4	-0,5
62	0,244	0,514	0,675	0,936	0,333	-0,785	0,341	0,4	-0,4
63	0,166	0,474	0,774	0,949	0,299	-0,643	0,306	0,4	-0,3
64	0,084	0,44	0,878	0,959	0,27	-0,464	0,275	0,4	-0,2
65	-0,001	0,413	0,987	0,967	0,245	-0,246	0,248	0,399	-0,1
66	-0,089	0,39	1,099	0,973	0,222	-0,001	0,225	0,399	0
67	-0,178	0,371	1,221	0,981	0,202	0,245	0,203	0,4	0,1
68	-0,269	0,355	1,344	0,986	0,184	0,464	0,185	0,4	0,2
69	-0,362	0,342	1,471	0,99	0,17	0,644	0,17	0,4	0,3
70	-0,455	0,331	1,598	0,992	0,159	0,784	0,159	0,4	0,399
71	-0,549	0,32	1,738	0,995	0,148	0,895	0,148	0,4	0,499
72	-0,643	0,311	1,884	0,999	0,139	0,982	0,138	0,4	0,599
73	-0,738	0,303	2,037	1,002	0,131	1,052	0,13	0,4	0,7
74	-0,833	0,295	2,199	1,005	0,124	1,108	0,123	0,4	0,801
75	-0,928	0,288	2,369	1,007	0,118	1,153	0,116	0,399	0,901
76	0,232	0,673	0,658	0,891	0,435	-0,785	0,454	0,499	-0,499
77	0,17	0,621	0,747	0,912	0,393	-0,674	0,407	0,5	-0,399
78	0,101	0,577	0,841	0,929	0,356	-0,54	0,366	0,5	-0,299
79	0,026	0,539	0,941	0,942	0,324	-0,38	0,331	0,5	-0,2
80	-0,053	0,508	1,045	0,953	0,295	-0,197	0,301	0,5	-0,1
81	-0,135	0,481	1,154	0,962	0,27	-0,001	0,273	0,5	0
82	-0,219	0,459	1,268	0,969	0,247	0,196	0,249	0,5	0,099
83	-0,307	0,441	1,39	0,977	0,226	0,381	0,228	0,5	0,2
84	-0,396	0,425	1,515	0,983	0,209	0,54	0,21	0,5	0,3
85	-0,486	0,411	1,642	0,986	0,195	0,673	0,195	0,5	0,399
86	-0,577	0,399	1,78	0,991	0,182	0,785	0,182	0,5	0,499
87	-0,67	0,388	1,924	0,995	0,171	0,876	0,17	0,5	0,6
88	-0,763	0,377	2,076	0,998	0,162	0,951	0,16	0,5	0,701
89	-0,856	0,368	2,236	1,001	0,153	1,013	0,152	0,5	0,801

90	0,139	0,774	0,746	0,862	0,489	-0,694	0,516	0,599	-0,499
91	0,088	0,72	0,828	0,887	0,445	-0,587	0,465	0,6	-0,399
92	0,027	0,673	0,917	0,908	0,407	-0,462	0,421	0,6	-0,299
93	-0,04	0,633	1,012	0,924	0,372	-0,32	0,383	0,6	-0,199
94	-0,112	0,599	1,113	0,938	0,341	-0,164	0,349	0,6	-0,099
95	-0,188	0,57	1,218	0,949	0,313	0	0,319	0,6	0
96	-0,268	0,545	1,329	0,959	0,288	0,165	0,292	0,6	0,1
97	-0,35	0,524	1,444	0,967	0,266	0,321	0,268	0,6	0,199
98	-0,435	0,506	1,566	0,974	0,246	0,462	0,248	0,6	0,299
99	-0,523	0,49	1,694	0,98	0,229	0,587	0,23	0,6	0,4
100	-0,612	0,476	1,829	0,985	0,215	0,695	0,215	0,6	0,5
101	-0,702	0,463	1,972	0,989	0,202	0,786	0,202	0,6	0,601
102	-0,793	0,451	2,122	0,994	0,191	0,863	0,19	0,6	0,702
103	-0,884	0,44	2,28	0,997	0,181	0,929	0,18	0,599	0,802
104	0,046	0,865	0,84	0,837	0,534	-0,62	0,568	0,7	-0,5
105	0,003	0,811	0,916	0,865	0,49	-0,519	0,516	0,7	-0,4
106	-0,05	0,763	0,999	0,888	0,451	-0,405	0,47	0,7	-0,3
107	-0,11	0,722	1,09	0,906	0,415	-0,278	0,43	0,7	-0,2
108	-0,176	0,686	1,186	0,922	0,383	-0,142	0,394	0,7	-0,1
109	-0,248	0,654	1,289	0,936	0,353	0,002	0,361	0,7	0,001
110	-0,323	0,628	1,396	0,947	0,326	0,143	0,332	0,7	0,101
111	-0,4	0,605	1,509	0,957	0,302	0,279	0,306	0,7	0,2
112	-0,481	0,586	1,628	0,965	0,281	0,405	0,283	0,701	0,3
113	-0,565	0,568	1,753	0,972	0,262	0,519	0,263	0,701	0,401
114	-0,651	0,552	1,886	0,978	0,246	0,621	0,246	0,7	0,501
115	-0,739	0,537	2,026	0,984	0,232	0,71	0,232	0,7	0,602
116	-0,827	0,525	2,166	0,986	0,221	0,785	0,22	0,7	0,7
117	-0,054	0,949	0,939	0,811	0,573	-0,559	0,615	0,8	-0,5
118	-0,088	0,895	1,009	0,841	0,529	-0,464	0,562	0,8	-0,4
119	-0,133	0,848	1,087	0,867	0,49	-0,359	0,515	0,8	-0,3
120	-0,187	0,806	1,173	0,888	0,454	-0,245	0,473	0,8	-0,2
121	-0,247	0,769	1,265	0,906	0,421	-0,124	0,435	0,8	-0,1
122	-0,312	0,736	1,362	0,921	0,39	0	0,401	0,8	0
123	-0,382	0,708	1,466	0,934	0,362	0,124	0,37	0,8	0,1
124	-0,456	0,684	1,575	0,945	0,337	0,245	0,343	0,8	0,2
125	-0,533	0,663	1,696	0,956	0,313	0,36	0,317	0,801	0,302
126	-0,613	0,644	1,819	0,964	0,293	0,465	0,295	0,801	0,402
127	-0,695	0,627	1,941	0,969	0,277	0,559	0,279	0,8	0,5
128	-0,182	0,974	1,106	0,819	0,564	-0,418	0,603	0,9	-0,4
129	-0,22	0,927	1,18	0,846	0,524	-0,322	0,555	0,9	-0,3
130	-0,267	0,885	1,261	0,869	0,488	-0,219	0,512	0,9	-0,2
131	-0,321	0,848	1,349	0,889	0,455	-0,111	0,473	0,9	-0,1
132	-0,381	0,815	1,443	0,906	0,424	0	0,438	0,9	0
133	-0,446	0,786	1,543	0,92	0,395	0,111	0,406	0,9	0,1
134	-0,515	0,761	1,648	0,933	0,369	0,219	0,377	0,9	0,2
135	-0,588	0,738	1,761	0,943	0,346	0,322	0,351	0,9	0,3
136	-0,665	0,718	1,88	0,952	0,324	0,418	0,328	0,9	0,4

Tablica A.4: Obrađene radne točke za validaciju modela, izražene u p.u., kutovi u rad

Validacija									
Radna točka br.	Id	I _q	I _f	Ψ_d	Ψ_q	f _i	delta	P	Q
1	0,809	-0,007	0,084	0,982	-0,008	-1,571	-0,008	0	-0,795
2	0,707	-0,004	0,196	0,986	-0,006	-1,571	-0,006	0	-0,698
3	0,605	-0,003	0,307	0,99	-0,004	-1,571	-0,004	0	-0,599
4	-1,082	-0,002	2,674	1,015	0,002	1,571	0,002	0	1,098
5	-1,178	-0,002	2,87	1,014	0,002	1,571	0,002	0	1,195
6	-1,275	-0,003	3,072	1,013	0,002	1,571	0,002	0	1,292
7	-1,371	-0,003	3,28	1,011	0,003	1,571	0,002	0	1,387
8	-1,467	-0,004	3,604	1,022	0,003	1,571	0,002	0	1,499
9	0,826	0,262	0,061	0,97	0,186	-1,454	0,189	0,1	-0,85
10	0,733	0,218	0,164	0,977	0,155	-1,438	0,157	0,1	-0,75
11	0,637	0,187	0,266	0,98	0,132	-1,419	0,134	0,099	-0,649
12	0,539	0,164	0,374	0,984	0,115	-1,391	0,116	0,1	-0,55
13	-1,036	0,069	2,582	1,014	0,029	1,476	0,029	0,1	1,049
14	-1,132	0,067	2,774	1,014	0,028	1,484	0,028	0,1	1,147
15	-1,229	0,065	2,973	1,013	0,027	1,491	0,027	0,099	1,244
16	-1,325	0,064	3,178	1,012	0,026	1,497	0,026	0,099	1,339
17	-1,421	0,063	3,481	1,021	0,025	1,502	0,025	0,1	1,45
18	0,157	1,28	0,11	0,272	0,943	-1,412	1,29	0,2	-1,251
19	0,779	0,602	0,039	0,887	0,429	-1,363	0,45	0,2	-0,95
20	0,732	0,496	0,12	0,923	0,352	-1,34	0,364	0,2	-0,85
21	0,663	0,421	0,212	0,943	0,297	-1,31	0,305	0,2	-0,75
22	0,582	0,363	0,306	0,955	0,255	-1,274	0,261	0,199	-0,649
23	0,495	0,321	0,409	0,966	0,223	-1,223	0,227	0,2	-0,55
24	-1,043	0,139	2,593	1,013	0,056	1,383	0,055	0,199	1,049
25	-1,139	0,136	2,785	1,013	0,054	1,399	0,053	0,199	1,147
26	-1,235	0,133	2,983	1,012	0,052	1,412	0,051	0,199	1,244
27	-1,331	0,13	3,188	1,011	0,05	1,424	0,049	0,198	1,339
28	-1,426	0,129	3,49	1,02	0,048	1,434	0,047	0,2	1,45
29	-0,031	1,309	0,256	0,206	0,959	-1,335	1,359	0,3	-1,249
30	0,378	1,149	0,136	0,533	0,826	-1,316	0,998	0,3	-1,15
31	0,56	0,957	0,114	0,711	0,68	-1,292	0,763	0,3	-1,05
32	0,615	0,802	0,146	0,808	0,565	-1,265	0,61	0,3	-0,95
33	0,606	0,683	0,207	0,864	0,478	-1,231	0,505	0,3	-0,85
34	0,564	0,591	0,285	0,899	0,411	-1,19	0,428	0,3	-0,75
35	0,502	0,52	0,371	0,923	0,358	-1,138	0,37	0,3	-0,65
36	0,43	0,463	0,464	0,94	0,315	-1,072	0,324	0,299	-0,55
37	-1,054	0,209	2,612	1,011	0,083	1,293	0,082	0,299	1,049
38	-1,15	0,205	2,803	1,011	0,079	1,316	0,078	0,298	1,147
39	-1,245	0,201	3,001	1,011	0,076	1,336	0,075	0,298	1,244
40	-1,341	0,197	3,204	1,01	0,073	1,353	0,073	0,297	1,339
41	-1,436	0,195	3,507	1,019	0,07	1,367	0,069	0,3	1,45
42	-0,347	1,343	0,444	0,044	0,979	-1,272	1,525	0,4	-1,3
43	0,023	1,288	0,326	0,327	0,925	-1,249	1,231	0,4	-1,199
44	0,288	1,155	0,259	0,55	0,816	-1,222	0,978	0,4	-1,1
45	0,419	1,01	0,254	0,688	0,704	-1,19	0,797	0,4	-1
46	0,467	0,882	0,285	0,776	0,609	-1,152	0,666	0,4	-0,9

47	0,464	0,777	0,341	0,833	0,532	-1,107	0,568	0,4	-0,8
48	0,432	0,691	0,412	0,872	0,468	-1,052	0,493	0,4	-0,7
49	0,381	0,62	0,49	0,898	0,416	-0,984	0,433	0,399	-0,6
50	-1,023	0,282	2,547	1,008	0,112	1,191	0,111	0,399	1
51	-1,118	0,276	2,733	1,009	0,107	1,223	0,106	0,398	1,098
52	-1,212	0,27	2,926	1,009	0,103	1,25	0,101	0,397	1,196
53	-1,307	0,265	3,126	1,008	0,099	1,273	0,098	0,396	1,292
54	-1,402	0,26	3,331	1,007	0,095	1,293	0,094	0,395	1,387
55	-0,415	1,358	0,549	0,069	0,978	-1,204	1,5	0,5	-1,3
56	-0,126	1,317	0,459	0,29	0,936	-1,174	1,27	0,501	-1,196
57	0,109	1,223	0,396	0,483	0,855	-1,145	1,056	0,498	-1,099
58	0,252	1,106	0,383	0,625	0,761	-1,107	0,883	0,5	-1
59	0,318	0,994	0,403	0,719	0,675	-1,064	0,754	0,5	-0,9
60	0,336	0,894	0,446	0,785	0,6	-1,012	0,653	0,5	-0,8
61	0,321	0,808	0,507	0,832	0,536	-0,951	0,573	0,5	-0,7
62	0,284	0,735	0,576	0,864	0,482	-0,877	0,509	0,498	-0,6
63	-0,95	0,36	2,404	1,004	0,145	1,065	0,144	0,499	0,901
64	-1,044	0,352	2,581	1,005	0,139	1,109	0,137	0,498	1
65	-1,137	0,344	2,766	1,006	0,132	1,146	0,131	0,497	1,099
66	-1,231	0,338	2,958	1,006	0,127	1,178	0,126	0,496	1,196
67	-1,325	0,331	3,156	1,005	0,122	1,205	0,121	0,495	1,292
68	-1,419	0,325	3,361	1,004	0,118	1,229	0,117	0,494	1,387
69	-0,357	1,367	0,614	0,187	0,963	-1,123	1,379	0,6	-1,25
70	-0,126	1,314	0,548	0,369	0,911	-1,09	1,185	0,6	-1,15
71	0,028	1,228	0,517	0,507	0,84	-1,051	1,028	0,599	-1,046
72	0,143	1,131	0,514	0,627	0,761	-1,008	0,882	0,6	-0,95
73	0,19	1,036	0,536	0,703	0,69	-0,958	0,776	0,597	-0,849
74	0,205	0,949	0,579	0,765	0,623	-0,897	0,684	0,598	-0,749
75	0,193	0,872	0,637	0,811	0,564	-0,826	0,608	0,599	-0,649
76	0,161	0,805	0,707	0,847	0,513	-0,742	0,544	0,599	-0,549
77	-0,93	0,436	2,356	0,997	0,177	0,956	0,176	0,6	0,85
78	-1,022	0,427	2,531	1	0,169	1,007	0,167	0,6	0,95
79	-1,114	0,419	2,718	1,003	0,161	1,052	0,16	0,6	1,05
80	-1,207	0,411	2,918	1,005	0,154	1,09	0,152	0,6	1,15
81	-1,299	0,404	3,132	1,008	0,148	1,123	0,146	0,6	1,25
82	-1,392	0,398	3,358	1,01	0,142	1,153	0,14	0,6	1,35
83	-0,561	1,397	0,765	0,11	0,974	-1,077	1,459	0,7	-1,3
84	-0,345	1,372	0,699	0,273	0,943	-1,043	1,289	0,7	-1,2
85	-0,168	1,315	0,654	0,418	0,89	-1,004	1,131	0,7	-1,1
86	-0,043	1,238	0,636	0,537	0,826	-0,96	0,994	0,7	-1
87	0,025	1,155	0,645	0,62	0,762	-0,909	0,888	0,697	-0,896
88	0,069	1,073	0,673	0,695	0,697	-0,851	0,787	0,699	-0,796
89	0,088	0,996	0,717	0,758	0,636	-0,785	0,698	0,7	-0,7
90	0,075	0,927	0,773	0,802	0,582	-0,709	0,628	0,7	-0,6
91	-0,916	0,513	2,322	0,99	0,21	0,852	0,209	0,7	0,8
92	-1,006	0,502	2,49	0,994	0,2	0,91	0,198	0,7	0,9
93	-1,097	0,492	2,669	0,997	0,191	0,96	0,189	0,7	1
94	-1,188	0,483	2,862	1	0,183	1,004	0,181	0,7	1,1
95	-1,279	0,475	3,069	1,003	0,175	1,043	0,173	0,7	1,2
96	-1,37	0,467	3,288	1,005	0,168	1,077	0,166	0,7	1,3

97	-0,541	1,412	0,845	0,198	0,961	-1,001	1,367	0,8	-1,25
98	-0,366	1,377	0,796	0,336	0,924	-0,963	1,222	0,8	-1,15
99	-0,227	1,321	0,767	0,455	0,873	-0,92	1,09	0,8	-1,05
100	-0,129	1,253	0,761	0,554	0,815	-0,871	0,974	0,8	-0,95
101	-0,067	1,18	0,776	0,635	0,756	-0,816	0,872	0,8	-0,85
102	-0,035	1,108	0,807	0,7	0,699	-0,753	0,785	0,8	-0,75
103	-0,028	1,04	0,851	0,751	0,645	-0,682	0,71	0,8	-0,65
104	-0,041	0,978	0,907	0,793	0,596	-0,602	0,645	0,8	-0,55
105	-0,823	0,604	2,149	0,977	0,255	0,682	0,255	0,8	0,65
106	-0,909	0,59	2,298	0,982	0,242	0,753	0,242	0,8	0,75
107	-0,997	0,578	2,459	0,986	0,231	0,816	0,23	0,8	0,85
108	-1,085	0,566	2,631	0,99	0,221	0,871	0,219	0,8	0,95
109	-1,174	0,556	2,817	0,994	0,211	0,92	0,209	0,8	1,05
110	-1,264	0,546	3,016	0,997	0,202	0,963	0,2	0,8	1,15
111	-1,354	0,537	3,228	1	0,194	1,001	0,192	0,8	1,25
112	-0,549	1,425	0,936	0,267	0,945	-0,927	1,295	0,9	-1,2
113	-0,407	1,386	0,901	0,383	0,906	-0,885	1,171	0,9	-1,1
114	-0,297	1,333	0,885	0,484	0,858	-0,838	1,057	0,9	-1
115	-0,218	1,271	0,887	0,569	0,806	-0,785	0,955	0,9	-0,9
116	-0,169	1,207	0,907	0,64	0,752	-0,727	0,866	0,9	-0,8
117	-0,145	1,143	0,94	0,699	0,701	-0,661	0,787	0,9	-0,7
118	-0,141	1,082	0,986	0,746	0,652	-0,588	0,718	0,9	-0,6
119	-0,155	1,025	1,041	0,786	0,606	-0,507	0,657	0,9	-0,5
120	-0,744	0,7	2,006	0,96	0,306	0,507	0,309	0,9	0,5
121	-0,826	0,683	2,14	0,966	0,29	0,588	0,291	0,9	0,6
122	-0,909	0,668	2,284	0,972	0,275	0,661	0,276	0,9	0,7
123	-0,994	0,654	2,438	0,977	0,263	0,727	0,262	0,9	0,8
124	-1,08	0,641	2,603	0,982	0,251	0,785	0,25	0,9	0,9
125	-1,167	0,629	2,781	0,986	0,24	0,838	0,239	0,9	1
126	-1,254	0,617	2,973	0,99	0,23	0,885	0,228	0,9	1,1
127	-1,342	0,607	3,178	0,994	0,221	0,927	0,219	0,9	1,2

Literatura

- [1]Pavlica, M., “Utjecaj rasipnog magnetskog polja u čeonom prostoru hidrogeneratora na ograničenje rada u poduzbuđenom stanju”, Doktorski rad, Fakultet elektrotehnike i računarstva, Zagreb, 2008.
- [2]Panvini, A., Yohn, T., “Field assessment of generators reactive capability”, IEEE Transactions on Power Systems, Vol. 10, No. 1, 1995, str. 288-296.
- [3]Nilsson, N., Mercurio, J., “Synchronous generator capability curve testing and evaluation”, IEEE Transactions on Power Delivery, Vol. 9, No. 1, 1994, str. 414-424.
- [4]Kon čar Generatori i motori d.d., Garantna mjerenja, generator tip: SB 3755-12, HE Vinodol, 2022.
- [5]Vražić, M., Višković, A., Hanić, Z., “User pq diagram as a part of a synchronous generator monitoring system”, Elektronika i Elektrotehnika, Vol. 20, No. 4, 2014, str. 33-38.
- [6]Vražić, M., Kovačić, M., Hanić, Z., “Design of the monitoring system for a synchronous generators in hydro power plant”, in 2012 International Conference on Renewable Energy Research and Applications (ICRERA), Nagasaki, Japan, 11-14 Nov 2012, str. 1-5.
- [7]Ilić, I., Višković, A., Vražić, M., “User p-q diagram as a tool in reactive power trade”, in 2011 8th International Conference on the European Energy Market (EEM), Zagreb, Croatia, 25-27 May 2011, str. 580-584.
- [8]Dragosavac, J., Janda, , Milanovic, J. V., “Coordinated reactive power-voltage controller for multimachine power plant”, IEEE Transactions on Power Systems, Vol. 27, No. 3, 2012, str. 1540-1549.
- [9]Bjelogrić, M., Calovic, M., “Voltage and reactive power control in transmission networks: Present practice and prospects of future developments”, in Proceedings. Joint International Power Conference Athens Power Tech, Athens, Greece, Vol. 2, 5-8 Sep 1993, str. 558-562.

- [10]Niazy, I., Ebadi, J., Sabzevari, S., Niazy, A., Mortazavi, H., Poursoltani, H., “Participation in reactive power market considering generator aging”, in 2010 Conference Proceedings IPEC, Singapore, 27-29 Oct 2010, str. 1067-1072.
- [11]Haghighat, H., Cañizares, C., Bhattacharya, K., “Dispatching reactive power considering all providers in competitive electricity markets”, in IEEE PES General Meeting, Minneapolis, Minnesota, USA, 25-29 July 2010, str. 1-7.
- [12]Ilić, I., Maljković, Z., Gašparac, I., Pavlica, M., Ilić-Zubović, D., Jarić, V., Višković, A., Belobrajčić, R., “Methodology for determining the actual pq diagram of a hydrogenerators”, *Energija*, Vol. 56, No. 2, 2007, str. 144–181.
- [13]Vuljaj, D., Hanic, Z., Vražić, M., “Labview application for visualisation of synchronous machine real-time capability diagram with variable operational limits”, in 2015 International Conference on Electrical Drives and Power Electronics (EDPE), Tatranska Lomnica, Slovakia, 21–23 Sep 2015, str. 291-295.
- [14]Kovacic, M., Hanic, Z., Vrazic, M., “Design of large synchronous turbo-generator monitoring system”, in 2012 XXth International Conference on Electrical Machines, Marseille, France, 2-5 Sep 2012, str. 1631-1636.
- [15]Jadrić, M., Despalatović, M., Terzić, B., Rajković, B., “Metodologija za identifikaciju parametara sinkronog hidrogeneratora temeljena na mjerenjima u sustavu monitoringa”, *Automatika*, Vol. 48, 2007, str. 9-19.
- [16]Despalatovic, M., Jadric, M., Terzic, B., “Modeling of saturated synchronous generator based on steady-state operating data”, *Industry Applications, IEEE Transactions on*, Vol. 48, No. 1, Jan 2012, str. 62-69.
- [17]Despalatovic, M., Jadric, M., Terzic, B., “Modeling of saturated synchronous generator based on steady-state operating data”, in 2010 XIX International Conference on Electrical Machines (ICEM), Rome, Italy, 6-8 Sep 2010, str. 1-6.
- [18]Hanić, Z., “Proračun stacionarnih stanja sinkronih strojeva primjenom strujno ovisnih funkcija ulančanih tokova”, *Doktorski rad, Fakultet elektrotehnike i računarstva, Zagreb*, 2017.
- [19]Institut za elektroprivredu i energetiku, *Proračun kratkog spoja u prijenosnoj mreži hrvatske za nazivnu 2020. godinu*, Zagreb, 2010.
- [20]Maljković, Z., Gašparać, I., “Operating limits of underexcited synchronous generator”, in 4th International Conference on Power Engineering, Energy and Electrical Drives, Istanbul, Turkey, 13-17 May 2013, str. 1374-1377.

- [21]Weili, L., Feng, Z., Yunpeng, H., Shukang, C., “The influence of end part leakage on stator temperature field”, in ICEMS’2001. Proceedings of the Fifth International Conference on Electrical Machines and Systems (IEEE Cat. No.01EX501), Shenyang, China, Vol. 1, 18-20 Aug 2001, str. 111-115 vol.1.
- [22]Richard, S., Ducreux, J.-P., Foggia, A., “A three dimensional finite element analysis of the magnetic field in the end region of a synchronous generator”, in 1997 IEEE International Electric Machines and Drives Conference Record, Milwaukee, WI, USA, 18-21 May 1997, str. WC2/4.1-WC2/4.3.
- [23]Choi, S., Jia, X., “Under excitation limiter and its role in preventing excessive synchronous generator stator end-core heating”, IEEE Transactions on Power Systems, Vol. 15, No. 1, 2000, str. 95-101.
- [24]da Costa, P., de Souza, A. N., da Silva, P. S., do Cogo Castanho, J. E., “A visual tool for building synchronous generator capability curves”, in 2012 Proceedings of IEEE Southeastcon, Orlando, FL, USA, 15-18 Mar 2012, str. 1-6.
- [25]Pavlica, M., Maljkovic, Z., Stekovic, Z., “Computer role in electrical machines courses - synchronous generator’s power chart web application”, in The IEEE Region 8 EUROCON 2003. Computer as a Tool, Ljubljana, Slovenia, Vol. 2, 22-24 Sep 2003, str. 283-286 vol.2.
- [26]Wamkeue, R., Jolette, C., Mabwe, A., Kamwa, I., “Cross-identification of synchronous generator parameters from rtldr test time-domain analytical responses”, IEEE Transactions on Energy Conversion, Vol. 26, No. 3, Sept 2011, str. 776-786.
- [27]Fard, R., Karrari, M., Malik, O., “Synchronous generator model identification for control application using volterra series”, IEEE Transactions on Energy Conversion, Vol. 20, No. 4, Dec 2005, str. 852-858.
- [28]Vakil, V., Karrari, M., Rosehart, W., Malik, O., “Synchronous generator model identification using adaptive pursuit method”, Generation, Transmission and Distribution, IEE Proceedings-, Vol. 153, No. 2, March 2006, str. 247-252.
- [29]Gong, R., Huang, Y., Wei, H., Meng, X., Xie, L., “Design of pid excitation controllers for synchronous generators based on fuzzy rbf neural network”, in International Conference on Electrical Machines and Systems, 2008. ICEMS 2008, Wuhan, China, 17-20 Oct 2008, str. 122-127.

- [30]Racewicz, S., Riu, D., Retiere, N., Chrzan, P., “Half-order modeling of saturated synchronous machine”, IEEE Transactions on Industrial Electronics, Vol. 61, No. 10, Oct 2014, str. 5241-5248.
- [31]Guha, S., Kar, N., “Saturation modeling and stability analysis of synchronous reluctance generator”, IEEE Transactions on Energy Conversion, Vol. 23, No. 3, Sept 2008, str. 814-823.
- [32]Babaei, E., Mozaffari Niapour, S., Tabarraie, M., “Design of a non-linear power system stabiliser using the concept of the feedback linearisation based on the back-stepping technique”, Generation, Transmission Distribution, IET, Vol. 5, No. 8, August 2011, str. 860-868.
- [33]Dineley, J., Mikhail, S., “The dynamic stability of a steam turbine driven synchronous generator under leading power factor load conditions”, Power Apparatus and Systems, IEEE Transactions on, Vol. 94, No. 2, Mar 1975, str. 288-298.
- [34]Wang, L., Truong, D.-N., “Dynamic stability improvement of four parallel-operated pmsg-based offshore wind turbine generators fed to a power system using a statcom”, Power Delivery, IEEE Transactions on, Vol. 28, No. 1, Jan 2013, str. 111-119.
- [35]Hamidifar, S., Kar, N., “A novel approach to saturation characteristics modeling and its impact on synchronous machine transient stability analysis”, IEEE Transactions on Energy Conversion, Vol. 27, No. 1, March 2012, str. 139-150.
- [36]Levi, E., Levi, V., “Impact of dynamic cross-saturation on accuracy of saturated synchronous machine models”, IEEE Transactions on Energy Conversion, Vol. 15, No. 2, Jun 2000, str. 224-230.
- [37]Mirosevic, M., Maljkovic, Z., Miskovic, M., “The effect of implementing of dynamic cross saturation on modeling of synchronous generator”, in Fourth International Conference on Power Engineering, Energy and Electrical Drives (POWERENG), Istanbul, Turkey, 13-17 May 2013, str. 1477-1481.
- [38]Karayaka, H., Keyhani, A., Heydt, G., Agrawal, B., Selin, D. A., “Synchronous generator model identification and parameter estimation from operating data”, IEEE Transactions on Energy Conversion, Vol. 18, No. 1, Mar 2003, str. 121-126.
- [39]Karrari, M., Malik, O., “Identification of heffron-phillips model parameters for synchronous generators using online measurements”, Generation, Transmission and Distribution, IEE Proceedings-, Vol. 151, No. 3, May 2004, str. 313-320.

- [40]Jadri ć, M., Despalatović, M., Terzić, B., “Development of synchronous generator saturation model from steady-state operating data”, *Electric Power Systems Research*, Vol. 80, No. 11, 2010, str. 1323 - 1331, dostupno na: <http://www.sciencedirect.com/science/article/pii/S0378779610001197>
- [41]Garcia-Dominguez, M., Ruiz-Vega, D., “An alternative synchronous machine model for quasi-steady-state simulations”, in *40th North American Power Symposium*, 2008. NAPS '08., Calgary, AB, Canada, 28-30 Sept 2008, str. 1-7.
- [42]Wang, L., Jatskevich, J., “A voltage-behind-reactance synchronous machine model for the emtp-type solution”, *Power Systems, IEEE Transactions on*, Vol. 21, No. 4, Nov 2006, str. 1539-1549.
- [43]Huang, Y., Chapariha, M., Therrien, F., Jatskevich, J., Marti, J., “A constant-parameter voltage-behind-reactance synchronous machine model based on shifted-frequency analysis”, *IEEE Transactions on Energy Conversion*, Vol. PP, No. 99, 2015, str. 1-11.
- [44]Cramer, A., Loop, B., Aliprantis, D., “Synchronous machine model with voltage-behind-reactance formulation of stator and field windings”, *IEEE Transactions on Energy Conversion*, Vol. 27, No. 2, June 2012, str. 391-402.
- [45]Karaagac, U., Mahseredjian, J., Kocar, I., Saad, O., “An efficient voltage-behind-reactance formulation-based synchronous machine model for electromagnetic transients”, *Power Delivery, IEEE Transactions on*, Vol. 28, No. 3, July 2013, str. 1788-1795.
- [46]Liu, S., Cheng, Y., Li, L., “A voltage-behind-reactance model and validation for six-phase synchronous machines”, in , *Beijing, China*, 31 Aug - 03 Sep 2014, str. 1-6.
- [47]Wang, L., Jatskevich, J., “Magnetically-saturable voltage-behind-reactance synchronous machine model for emtp-type solution”, *Power Systems, IEEE Transactions on*, Vol. 26, No. 4, Nov 2011, str. 2355-2363.
- [48]Aliprantis, D., Wasynczuk, O., Rodriguez Valdez, C., “A voltage-behind-reactance synchronous machine model with saturation and arbitrary rotor network representation”, *IEEE Transactions on Energy Conversion*, Vol. 23, No. 2, June 2008, str. 499-508.
- [49]Marti, J., Louie, K., “A phase-domain synchronous generator model including saturation effects”, *Power Systems, IEEE Transactions on*, Vol. 12, No. 1, Feb 1997, str. 222-229.
- [50]Pekarek, S., Walters, E., Kuhn, B., “An efficient and accurate method of representing magnetic saturation in physical-variable models of synchronous machines”, *IEEE Transactions on Energy Conversion*, Vol. 14, No. 1, Mar 1999, str. 72-79.

- [51]Walker, J., "Operating characteristics of salient-pole machines", in Proceedings of the IEE-Part II: Power Engineering, Vol. 100, No. 73, 1953, str. 13-24.
- [52]Sellschopp, F., Arjona, M., "Determination of synchronous machine parameters using standstill frequency response tests at different excitation levels", in IEEE International Electric Machines Drives Conference, 2007. IEMDC '07, Antalya, Turkey, Vol. 2, 3-5 May 2007, str. 1014-1019.
- [53]El-Serafi, A., Kar, N., "Methods for determining the q-axis saturation characteristics of salient-pole synchronous machines from the measured d-axis characteristics", IEEE Transactions on Energy Conversion, Vol. 18, No. 1, Mar 2003, str. 80-86.
- [54]MacDonald, D., Reece, A., Turner, P., "Turbine-generator steady-state reactances", Generation, Transmission and Distribution, IEE Proceedings C, Vol. 132, No. 3, May 1985, str. 101-108.
- [55]Mandić, I., Tomljenović, V., Pužar, M., "Sinkroni i asinkroni električni strojevi", textbook, Polytechnic of Zagreb, Electrical engineering department, Zagreb, 2012.
- [56]Escarela-Perez, R., Niewierowicz, T., Campero-Littlewood, E., "A study of the variation of synchronous machine parameters due to saturation: a numerical approach", Electric Power Systems Research, Vol. 72, No. 1, 2004, str. 1 - 11, dostupno na: <http://www.sciencedirect.com/science/article/pii/S0378779604000781>
- [57]Levi, E., "Saturation modelling in d-q axis models of salient pole synchronous machines", IEEE Transactions on Energy Conversion, Vol. 14, No. 1, Mar 1999, str. 44-50.
- [58]Liang, X., El-Serafi, A., Faried, S., "Application of the finite-element method for the determination of the parameters representing the cross-magnetizing in saturated synchronous machines", IEEE Transactions on Energy Conversion, Vol. 25, No. 1, March 2010, str. 70-79.
- [59]Stumberger, B., Stumberger, G., Dolinar, D., Hamler, A., Trlep, M., "Evaluation Of Saturation And Cross-Magnetization Effects In Interior Permanent-Magnet Synchronous Motor", IEEE Transactions On Industry Applications, Vol. 39, No. 5, Sept 2003, str. 1264-1271.
- [60]Bianchi, N., Bolognani, S., "Magnetic Models Of Saturated Interior Permanent Magnet Motors Based On Finite Element Analysis", in The 1998 IEEE Industry Applications Conference, 1998. 33rd IAS Annual Meeting., Vol. 1, Oct 1998, str. 27-34 Vol.1.

- [61]Tahan, S.-A., Kamwa, I., “A two-factor saturation model for synchronous machines with multiple rotor circuits”, IEEE Transactions on Energy Conversion, Vol. 10, No. 4, Dec 1995, str. 609-616.
- [62]Arjona L., M., Macdonald, D., “Saturation effects on the steady-state stability limit of turbine-generators”, IEEE Transactions on Energy Conversion, Vol. 14, No. 2, 1999, str. 133-138.
- [63]Pillutla, S., Keyhani, A., “Neural network based saturation model for round rotor synchronous generator”, IEEE Transactions on Energy Conversion, Vol. 14, No. 4, Dec 1999, str. 1019-1025.
- [64]Pillutla, S., Keyhani, A., “Neural network based modeling of round rotor synchronous generator rotor body parameters from operating data”, IEEE Transactions on Energy Conversion, Vol. 14, No. 3, Sep 1999, str. 321-327.
- [65]Abido, M., Abdel-Magid, Y., “On-line identification of synchronous machines using radial basis function neural networks”, Power Systems, IEEE Transactions on, Vol. 12, No. 4, Nov 1997, str. 1500-1506.
- [66]Wu, X., Fan, Y., “Synchronous generator model identification using half-complex wavelet nonlinear arx network”, in International Conference on Electrical Machines and Systems, 2008. ICEMS 2008, Wuhan, China, 17-20 Oct 2008, str. 20-25.
- [67]Wamkeue, R., Baetscher, F., Kamwa, I., “Hybrid-state-model-based time-domain identification of synchronous machine parameters from saturated load rejection test records”, IEEE Transactions on Energy Conversion, Vol. 23, No. 1, March 2008, str. 68-77.
- [68]Fard, R., Karrari, M., Malik, O., “Synchronous generator model identification using volterra series”, in IEEE Power Engineering Society General Meeting, 2004, Denver, CO, USA, 6-10 June 2004, str. 1344-1349 Vol.2.
- [69]Chaudhry, S., Ahmed-Zaid, S., Demerdash, N., “An artificial-neural-network method for the identification of saturated turbogenerator parameters based on a coupled finite-element/state-space computational algorithm”, IEEE Transactions on Energy Conversion, Vol. 10, No. 4, Dec 1995, str. 625-633.
- [70]Pillutla, S., Keyhani, A., Kamwa, I., “Neural network observers for on-line tracking of synchronous generator parameters”, IEEE Transactions on Energy Conversion, Vol. 14, No. 1, Mar 1999, str. 23-30.

- [71]Sobczyk, T., “Inductanceless model of salient-pole synchronous machines”, in International Symposium on Power Electronics, Electrical Drives, Automation and Motion, 2008. SPEEDAM 2008, Ischia, Italy, 11-13 June 2008, str. 620-625.
- [72]Hamidifar, S., Kar, N. C., “A state space synchronous machine model with multifunctional characterization of saturation using levenberg–marquardt optimization algorithm”, Electric Power Systems Research, Vol. 102, No. 0, 2013, str. 33 - 41, dostupno na: <http://www.sciencedirect.com/science/article/pii/S0378779613000850>
- [73]Calvo, M., Malik, O., “Synchronous machine steady-state parameter estimation using neural networks”, IEEE Transactions on Energy Conversion, Vol. 19, No. 2, June 2004, str. 237-244.
- [74]Fukami, T., Matsui, Y., Hayamizu, T., Shima, K., Hanaoka, R., Takata, S., “Steady-state analysis of a permanent-magnet-assisted salient-pole synchronous generator”, in 18th International Conference on Electrical Machines, 2008. ICEM 2008, Vilamoura, Portugal, 6-9 Sept 2008, str. 1-6.
- [75]Fukami, T., Hayamizu, T., Matsui, Y., Shima, K., Hanaoka, R., Takata, S., “Steady-state analysis of a permanent-magnet-assisted salient-pole synchronous generator”, IEEE Transactions on Energy Conversion, Vol. 25, No. 2, June 2010, str. 388-393.
- [76]Ilić, I., Maljković, Z., Gašparac, I., “An example of applying algorithm to create the actual pq diagram of a hydrogenerator”, Energija, Vol. 56, No. 4, 2007, str. 456–489.
- [77]Maljkovic, Z., Gasparac, I., Pavlica, M., “Large turbogenerator’s synchronous reactance’s load dependence determined by measurements”, in International Conference on Electrical Machines (ICEM), 2014, Berlin, Germany, 2-5 Sept 2014, str. 203-207.
- [78]Ilić, I., Maljković, Z., Gašparac, I., Pavlica, M., Ilić-Zubović, D., Jarić, V., Višković, A., “An example of applying algorithm to create the actual p-q diagram of a hydrogenerator”, Energija, Vol. 56, 2007, str. 456-489.
- [79]Hanic, Z., Vrazic, M., Maljkovic, Z., “Steady-state synchronous machine model which incorporates saturation and cross-magnetization effects”, in 4th International Conference on Power Engineering, Energy and Electrical Drives, Istanbul, Turkey, 13-17 May 2013, str. 1553-1557.
- [80]Gargiulo, G., Mangoni, V., Russo, M., “Capability charts for combined cycle power plants”, IEE Proceedings-Generation, Transmission and Distribution, Vol. 149, No. 4, 2002, str. 407–415.

- [81]Walker, J., “Operating characteristics of salient-pole machines”, Proceedings of the IEE-Part II: Power Engineering, Vol. 100, No. 73, 1953, str. 13–24.
- [82]Ehya, H., Sadeghi, I., Faiz, J., “Online condition monitoring of large synchronous generator under eccentricity fault”, in 2017 12th IEEE Conference on Industrial Electronics and Applications (ICIEA), Siem Reap, Cambodia, 18-20 June 2017, str. 19-24.
- [83]Colak, I., Garip, I., Sagiroglu, S., Bayhan, S., “Remote monitoring of the load characteristics of synchronous generators”, in 2011 International Conference on Power Engineering, Energy and Electrical Drives, Malaga, Spain, 11-13 May 2011, str. 1-4.
- [84]Glavan, B., Hanić, Z., Kovačić, M., Vražić, M., “Condition-monitoring system for identification and representation of the capability diagram limits for multiple synchronous generators in a hydro power-plant”, *Energies*, Vol. 13, No. 15, 2020, dostupno na: <https://www.mdpi.com/1996-1073/13/15/3800>
- [85]Despalatović, M., “Identifikacija parametara sinkronog hidrogeneratora na temelju mjerenja u pogonu”, Doktorski rad, Fakultet elektrotehnike, strojarstva i brodogradnje, Split, 2009.
- [86]Losi, A., Russo, M., Verde, P., Menniti, D., “Capability chart for generator-transformer units”, in Proceedings of 8th Mediterranean Electrotechnical Conference on Industrial Applications in Power Systems, Computer Science and Telecommunications (MELECON 96), Bari, Italy, Vol. 3, 13-16 May 1996, str. 1580-1583 vol.3.
- [87]Losi, A., Mangoni, V., Russo, M., “Optimal exploitation of generator-transformer units”, *IEEE Transactions on Energy Conversion*, Vol. 13, No. 1, 1998, str. 90-95.
- [88]Fleetwood, K., “An introduction to differential evolution”, in Proceedings of Mathematics and Statistics of Complex Systems (MASCOS) One Day Symposium, 26th November, Brisbane, Australia, 2004, str. 785–791.
- [89]Kim, H.-K., Chong, J.-K., Park, K.-Y., Lowther, D. A., “Differential evolution strategy for constrained global optimization and application to practical engineering problems”, *IEEE Transactions on Magnetics*, Vol. 43, No. 4, 2007, str. 1565-1568.
- [90]Oliveri, G., Rocca, P., Massa, A., “Differential evolution as applied to electromagnetics: Advances, comparisons, and applications”, in 2012 6th European Conference on Antennas and Propagation (EUCAP), 2012, str. 3058-3059.
- [91]Hoorfar, A., “Evolutionary programming in electromagnetic optimization: A review”, *IEEE Transactions on Antennas and Propagation*, Vol. 55, No. 3, 2007, str. 523-537.

- [92]Leite, J., Avila, S., Batistela, N., Carpes, W., Sadowski, N., Kuo-Peng, P., Bastos, J., “Real coded genetic algorithm for jiles-atherton model parameters identification”, IEEE Transactions on Magnetics, Vol. 40, No. 2, 2004, str. 888-891.
- [93]Donelli, M., Azaro, R., De Natale, F., Massa, A., “An innovative computational approach based on a particle swarm strategy for adaptive phased-arrays control”, IEEE Transactions on Antennas and Propagation, Vol. 54, No. 3, 2006, str. 888-898.
- [94]Rekanos, I. T., “Shape reconstruction of a perfectly conducting scatterer using differential evolution and particle swarm optimization”, IEEE Transactions on Geoscience and Remote Sensing, Vol. 46, No. 7, 2008, str. 1967-1974.
- [95]Storn, R., Price, K., “Differential evolution - a simple and efficient heuristic for global optimization over continuous spaces”, Journal of Global Optimization, Vol. 11, December 1997, str. 341-359, dostupno na: <https://doi.org/10.1023/A:1008202821328>
- [96]Holland, J. H., Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence. MIT press, 1992.
- [97]Liu, M., Li, J., Zong, T., “Parameter identification of box-jenkins systems based on the differential evolution algorithm”, in 2020 Chinese Control And Decision Conference (CCDC), Hefei, China, 2020.
- [98]Yeh, M.-F., Lu, H.-C., Leu, M.-S., Yi-Fanlee, “System identification using differential evolution with mean-best mutation”, in 2015 International Conference on Machine Learning and Cybernetics (ICMLC), Guangzhou, China, Vol. 1, 12-15 July 2015, str. 31-35.
- [99]Wang, K., Wang, X., Wang, J., Jiang, M., Lv, G., Feng, G., Xu, X., “Solving parameter identification problem of nonlinear systems using differential evolution algorithm”, in 2008 Second International Symposium on Intelligent Information Technology Application, Shanghai, China, Vol. 1, 20-22 Dec 2008, str. 687-691.
- [100]Sirotić, M. Z., Z., Sinkroni strojevi. Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, 1996.
- [101]Park, R. H., “Two-reaction theory of synchronous machines generalized method of analysis-part i”, American Institute of Electrical Engineers, Transactions of the, Vol. 48, No. 3, 1929, str. 716–727.
- [102]C. Coello, G. B. L., D. A. Van Veldhuizen, Algorithms for Solving Multi-Objective Problems, Second Edition. Springer, New York, 2007.

- [103]Rocha-Alicano, C., Covarrubias-Rosales, D., Brizuela-Rodriguez, C., “Differential evolution algorithm applied to side lobe level reduction on a planar array”, *International Journal of Electronics and Communications*, Vol. 61, No. 5, 2007, str. 286-290.
- [104]Panduro, M. A., del Rio-Bocio, C., “Beam-forming networks for scannable multi-beam antenna arrays using corbs and differential evolution”, in *Proceedings 2009 European Conference on Antennas and Propagation (EUCAP)*, Berlin, Germany, Vol. 23-27, 23-27 Mar 2009, str. 3109-3113.
- [105]Massa, A., Pastorino, M., Randazzo, A., “Reconstruction of two-dimensional buried objects by a differential evolution method”, *Inverse Problems*, Vol. 20, 2004, str. 135-150.
- [106]Qin, A. K., Huang, V. L., Suganthan, P. N., “Differential evolution algorithm with strategy adaptation for global numerical optimization”, *IEEE Transactions on Evolutionary Computation*, Vol. 13, No. 2, 2009, str. 398-417.
- [107]Kim, H.-K., Chong, J.-K., Park, K.-Y., Lowther, D. A., “Differential evolution strategy for constrained global optimization and application to practical engineering problems”, *IEEE Transactions on Magnetics*, Vol. 43, No. 4, 2007, str. 1565-1568.
- [108]Storn, R., K., P., *Differential Evolution - A Simple and Efficient Adaptive Scheme for Global Optimization Over Continuous Spaces*, Technical Report TR-95-012. International Computer Science Institute, Berkeley, CA, 1995.
- [109]Žarko, D., Maljković, Z., Pavlica, M., “Estimating magnetic properties of synchronous generator’s materials”, *Przegląd Elektrotechniczny*, Vol. 84, 01 2008, str. 267-269.

Životopis

Boris Glavan rođen je 23. travnja 1967. g. u Rijeci. Nakon srednje škole u Rijeci 1986. g. upisao je Elektrotehnički fakultet u Zagrebu. Diplomirao je 1991. g. na smjeru Elektroenergetika - Upravljanje elektroenergetskim sustavom, a nadalje je radio na Zavodu za elektrostrojarsvo kao znanstveni istraživač.

U Hrvatskoj elektroprivredi zaposlen je 1992. g. u dispečerskom centru Rijeka. Iste godine prelazi u TE Rijeka na poslove u domeni sustava vođenja elektrane (upravljanje, zaštita, signalizacija, mjerenje i regulacija). Iz TE Rijeka prelazi u HE Rijeka 2000. g. na poslove direktora pogona, a od 2006. g. do danas radi iste zadaće u HE Vinodol. Od 1992. do 1994. g. bio je asistent na Tehničkom fakultetu u Rijeci u sklopu kolegija Električni strojevi. Magistrirao je 1997. g. na Fakultetu elektrotehnike i računarstva u Zagrebu, na smjeru Elektrostrojarsvo i automatizacija.

Direktno je sudjelovao u više projekata rekonstrukcija i revitalizacija postrojenja. Na temu svojih aktivnosti koautor je u stručnim i znanstvenim radovima objavljenim u domaćim i stranim časopisima, te zbornicima savjetovanja. Pridruženi je član Studijskog odbora A1 – Rotacijski strojevi u sklopu Hrvatskog ogranka CIGRE. Domena njegova stručnog rada je vođenje, održavanje, rekonstrukcije i revitalizacije elektrana, a znanstveno-istraživački rad mu je u području modeliranja električnih sinkronih strojeva u stacionarnim i prijelaznim stanjima.

Aktivno se služi engleskim jezikom. Oženjen je i otac dvoje djece.

Popis objavljenih djela

- 1.Glavan, B.; Hanić, Z.; Kovačić, M.; Vražić, M., "Calculation methodology of common capability diagram for parallelly connected generator group", Zbornik 35. konferencije Electrical Drives and Power Electronics, Dubrovnik, 22.-24. rujan 2021.
- 2.Glavan, B.; Hanić, Z.; Kovačić, M.; Vražić, M., "Condition-Monitoring System for Identification and Representation of the Capability Diagram Limits for Multiple Synchronous Generators in a Hydro Power-Plant", Energies, Vol. 13 (2020), 15, srpanj 2020., str. 1-20
- 3.Banić, S., Pinčić, B., Glavan, B., Ilijanić, V., Vargović, E., "Analiza raspodjele struje kvara kroz uzemljivač VN postrojenja s visokim specifičnim otporom tla", Zbornik 7.

- savjetovanja HO CIGRE, Cavtat, studeni 2005., str. 736-745
4. Holjević, D., Glavan, B., Gašparović, G., "Problematika pražnjenja akumulacije Valići - HE Rijeka", Zbornik Hidroelektrane - obnovljiva energija za danas i sutra, Elektrotehničko društvo Zagreb, 2003., str. 196-202
 5. Simper, I., Glavan, B., Prpić, E., "Razvoj i eksploatacija uredskih mrežnih aplikacija za praćenje rada pogona i planiranje poslova održavanja u svrhu poslovnog i operativnog planiranja i organizacije radova u TE Rijeka 320 MW", Zbornik Energetska i procesna postrojenja, Dubrovnik, Energetika marketing, Zagreb, 2000., str. 276-282
 6. Prpić, E., Glavan, B., "Zahvati na digitalnim sustavima vođenja u TE Rijeka 320 MW u svrhu rješavanja problema 2000. godine - priprema, realizacija i završne analize", Zbornik Energetska i procesna postrojenja, Dubrovnik, Energetika marketing, Zagreb, 2000., str. 283-288
 7. Glavan, B., Bakula, M., Katić, Z., Dizdarević, N., "Analiza dinamičkog odziva TE "Rijeka" pri bliskim poremećajima u elektroenergetskoj mreži s obzirom na sustav zaštite turbogeneratorskog", Zbornik Energetska i procesna postrojenja, Dubrovnik, Energetika marketing, Zagreb, 2000., str. 179-182
 8. Glavan, B., Prpić, E., "Arhitektura središnjeg računalnog sustava vođenja turboagregata, elektroenergetskih i pomoćnih postrojenja u HEP TE Rijeka 1x320 MW - pregled izvedenog stanja", Energija, časopis Hrvatske elektroprivrede, Vol. 47, 6, 1998., str. 447-450
 9. Prpić, E., Glavan, B., Klapčić, C., Bakula, M., "Priprema zamjene sustava vođenja elektroenergetskog dijela postrojenja u HEP TE Rijeka 1x320 MW", Zbornik Energetska i procesna postrojenja, Dubrovnik, Energetika marketing, Zagreb, 1998., str. 592-597
 10. Glavan, B., Bakula, M., Prpić, E., "Arhitektura središnjeg računalnog sustava vođenja turboagregata, elektroenergetskih i pomoćnih postrojenja u HEP TE Rijeka 1x320 MW - pregled izvedenog stanja i planova za dogradnju", Zbornik Energetska i procesna postrojenja, Dubrovnik, Energetika marketing, Zagreb, 1998., str. 588-591
 11. Maljković, Z., Kuterovac, Lj., Glavan, B., "Evaluation of torsional strains in a turbine-generator shaft at network disturbances", Zbornik ELECTRIMACS, IMACS, Saint-Nazaire, 1996., str. 1039-1044
 12. Babić, S., Tešnjak, S., Dizdarević, N., Glavan, B., "Analiza prijelazne stabilnosti EES-a Istre s posebnim osvrtom na modeliranje sistema regulacije uzbude u TE Plomin 1", Zbornik 1. savjetovanje HK CIGRE - III. sekcija – Mreže, Zagreb, 1993., str. 569-578

Curriculum vitae

Boris Glavan was born on the 23rd of April 1967 in Rijeka. In 1986 he enrolled at the Faculty of Electrical Engineering in Zagreb. In 1991, he graduated from the programme of Electric Power Engineering, specializing in Management of electric power systems, and continued working at the Department of Electric Machines, Drives and Automation as a scientific researcher.

In 1992, he started working at Hrvatska Elektroprivreda at the dispatch center in Rijeka. The same year, he crossed over to the Rijeka TPP, as automation system engineer (control, protection, signalization, measuring, regulation). In 2000 he moved to HPP Rijeka as director of the plant, and in 2006 he started working as director of HPP Vinodol, where he still works today.

From 1992 to 1994, he worked as an assistant at the Faculty of Engineering in Rijeka on the Electric Machines course. He graduated master degree in 1997 from the Faculty of Electrical Engineering and Computing, programme of Electric Machines, Drives, and Automation.

The scope of his professional work includes management, maintenance, reconstruction and revitalization of power plants, and his scientific work involves modelling of electric synchronous machines in stationary and transition states. He was involved in multiple projects concerning reconstruction and revitalization of power plants. He is a co-author of multiple professional and scientific articles published in both domestic and foreign papers, and collected papers. He is an associate member of the A1 Study committee – Rotary machines within the Croatian branch of CIGRE.