Bezsenzorsko upravljanje sinkronim vjetrogeneratorom s permanentnim magnetima zasnovano na opserveru u kliznom načinu rada

Jukić, Filip

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:168:823987

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-19**

Repository / Repozitorij:

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

Sveučilište u Zagrebu

FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Filip Jukić

BEZSENZORSKO UPRAVLJANJE SINKRONIM VJETROGENERATOROM S PERMANENTNIM MAGNETIMA ZASNOVANO NA OPSERVERU U KLIZNOM NAČINU RADA

DOKTORSKI RAD

Zagreb, 2022.

Sveučilište u Zagrebu

FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Filip Jukić

BEZSENZORSKO UPRAVLJANJE SINKRONIM VJETROGENERATOROM S PERMANENTNIM MAGNETIMA ZASNOVANO NA OPSERVERU U KLIZNOM NAČINU RADA

DOKTORSKI RAD

Mentor: prof. dr. sc. Damir Sumina

Zagreb, 2022.

University of Zagreb

FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING

Filip Jukić

SENSORLESS CONTROL OF PERMANENT MAGNET WIND GENERATOR BASED ON SLIDING-MODE OBSERVER

DOCTORAL THESIS

Supervisor: Full Professor Damir Sumina, PhD

Zagreb, 2022

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

Mentor: prof. dr. sc. Damir Sumina

Doktorski rad ima: 217 stranica

Doktorski rad br.: _____

O mentoru

Damir Sumina je redoviti profesor na Sveučilištu u Zagrebu Fakultetu elektrotehnike i računarstva, na Zavodu za elektrostrojarstvo i automatizaciju. Na istom Zavodu je diplomirao 2001., magistrirao 2005. te obranio doktorsku disertaciju 2009. U razdoblju od 2001. do 2011. radio je kao asistent. Od 2011. do 2016. radio je u zvanju docenta, a od 2016. do 2020. u zvanju izvanrednog profesora na Zavodu za elektrostrojarstvo i automatizaciju, Sveučilišta u Zagrebu Fakulteta elektrotehnike i računarstva.

Znanstveni interes prof. dr. sc. Damira Sumine obuhvaća upravljanje električnim strojevima i elektromotornim pogonima, posebno upravljanje hidrogeneratorima i vjetrogeneratorima te industrijsku automatizaciju. Damir Sumina bio je voditelj znanstvenog projekta "*Razvoj naprednih energetski učinkovitih struktura upravljanja vjetrogeneratorom sa stalnim magnetima bez mjernog člana*", financiranog od Hrvatske zaklade za znanost. Tijekom svojeg radnog staža Damir Sumina bio je uključen kao istraživač u mnoge nacionalne i međunarodne projekte. Autor je brojnih radova objavljenih u međunarodnim časopisima i međunarodnim konferencijama, od toga 20 radova u časopisima A kategorije. Recenzirao je veći broj radova u visokorangiranim časopisima i na raznim konferencijama.

Bio je mentor preko sto studenata na preddiplomskom i diplomskom studiju i član je udruge HRO CIGRÉ.

About the Supervisor

Damir Sumina is a full professor at University of Zagreb Faculty of Electrical Engineering and Computing, Department of Electric Machines, Drives and Automation. He received his B.Sc. degree in 2001, his M.Sc. degree in 2005 and his Ph.D. degree in 2009 from the same Department. He worked as an assistant from 2001 to 2011, as an assistant professor from 2011 to 2016 and as an associate professor from 2016 to 2020 at University of Zagreb Faculty of Electrical Engineering and Computing, Department of Electric Machines, Drives and Automation.

The scientific interests of Full Professor Damir Sumina, Ph.D., are the control of electrical machines and drives, especially the control of hydro and wind generators and industrial automation. Damir Sumina was the leader of the scientific research project "*Development of advanced energy-efficient algorithms for sensorless control of permanent magnet generators*", funded by the Croatian Science Foundation. During his tenure, Damir Sumina was involved as a researcher in numerous national and international projects. He is the author of numerous papers published in international journals and conferences. He has published 20 papers in category A journals. He has reviewed numerous papers in high impact journals and conferences. He has also supervised more than a hundred undergraduate and graduate students.

He is a member of the HRO CIGRÉ association.

Zahvala

Prije izlaganja doktorske disertacije želio bih se zahvaliti svima onima koji su, na ovaj ili onaj način, bili dio ovog doktorskog rada.

Na prvom mjestu zahvaljujem prof. dr. sc. Damiru Sumini, svom dugogodišnjem mentoru, što je u meni prepoznao prikladnog suradnika za svoj istraživački projekt i na taj me način, već davne 2016., uveo u uzbudljiv nastavnički i istraživački svijet Fakulteta elektrotehnike i računarstva. Hvala mu za povjerenje koje mi je iskazao kao i za svu potporu koji mi je pružio tijekom mog doktorskog studija.

Osim mentoru, hvala svim kolegama i osoblju Zavoda za svaku pomoć koju su mi pružili i sve zajedničke aktivnosti u kojima smo sudjelovali. Ipak, posebna zahvala ide mojim dugogodišnjim kolegama iz sobe, Luki Pravici i Tinu Bariši. U našoj sobi posao se uvijek shvaćao ozbiljno, bilo da se radilo o istraživanjima, simulacijama, implementacijama, stručnim projektima, nastavi... Unatoč tome i uz to, ipak se svakodnevno s kraja hodnika četvrtog kata C zgrade po nekoliko puta mogao čuti gromoglasan smijeh vesele družine iz C04–15. Luka i Tin, hvala vam na svim konstruktivnim raspravama, savjetima i pomoći te što ste me svojim trudom, upornošću i dobrom voljom poticali da "guram" naprijed istim tempom. Osim toga, hvala vam i na dobrom društvu i prijateljstvu koje sam dobio u vama. Zbog ovakvih kolega na posao sam uvijek dolazio i odlazio s radošću i entuzijazmom.

Također, htio bih se zahvaliti cijeloj svojoj obitelji, užoj i široj, koja me uvijek poticala na marljivost i učila da se trud na kraju uvijek isplati. Posebno hvala mami i tati na bezgraničnom povjerenju koje su imali u mene tijekom cijelog školovanja. Hvala bratu Kristianu (i Gabrijeli), bivšem FER-ovcu, koji me uvijek razumio i poticao da idem naprijed i ne odustajem. Hvala sestri Ani koja me naučila puno toga o strpljivosti. Hvala nećacima Emanuelu, Veroniki i Pavli na iskrenoj ljubavi koju su uvijek iskazivali prema svom uji i striki.

Hvala i svim prijateljima, posebno onima iz Dogovora i Gradeca, što moj život, pa tako i ovaj doktorski studij, činite lakšim i slađim.

Ipak, od svih zahvala najveća ide mojoj supruzi Ivoni. Gotovo cijeli moj doktorski studij vremenski se poklopio s našim upoznavanjem, hodanjem i, na koncu, brakom. Sve to vrijeme ti si bila ona koja je, svojim osmijehom i entuzijazmom, izvlačila ono najbolje iz mene. Ivona, iskreno ti hvala na tome, kao i na beskrajnom strpljenju i razumijevanju za česte "prekovremene", za rad vikendom, za moju zabrinutost oko toga hoću li sve stići na vrijeme... Nadam se da će nakon ove obrane toga biti puno manje.

I zadnje, ali ne manje bitno. Oni koji me iole poznaju znaju da ne mogu, a da na kraju ne zahvalim dragom Bogu. Hvala Ti što si mi dao priliku imati i iskusiti sva dobra gore navedena, počevši od obrazovanja, kolega, prijatelja, obitelji i još toliko toga što se ne može izreći u samo jednoj rečenici.

Sažetak

U zadnjim desetljećima očigledan je porast integracije sustava za pretvorbu energije vjetra. Sinkroni stroj s permanentnim magnetima, upravljan pomoću AC-DC-AC pretvarača, jedan je od najčešće korištenih električnih generatora u takvim sustavima. U svrhu povećanja robusnosti cjelokupnog sustava, poželjno je koristiti algoritme bez mjernog člana kuta i brzine vrtnje rotora. Iz tog razloga područje istraživanja ove doktorske disertacije predstavljaju napredni algoritmi za bezsenzorsko upravljanje sinkronim generatorom s permanentnim magnetima u sustavim za pretvorbu energije vjetra. Znanstveni doprinos disertacije podijeljen je na tri dijela:

1. metoda za bezsenzorsko upravljanje sinkronim generatorom s permanentnim magnetima zasnovana na opserveru u kliznom načinu rada,
2. metoda za bezsenzorski leteći start sinkronog generatora s permanentnim magnetima zasnovana na opserveru u kliznom načinu rada i
3. metoda za smanjenje estimacijske greške opservera u kliznom načinu rada zasnovana na aproksimativnoj funkciji za adaptaciju induktiviteta u poprečnoj grani generatora.

Razvijena metoda za bezsenzorsko upravljanje temelji se na opserveru u kliznom načinu rada koji je modeliran u estimiranom rotirajućem koordinatnom sustavu koristeći model aktivnog magnetskog toka rotora. Takav opserver zahtjeva minimalno poznavanje parametara generatora te omogućava estimaciju greške između stvarnog i estimiranog rotirajućeg koordinatnog sustava iz koje se, korištenjem PI regulatora u fazno-zaključanoj petlji, estimira kut i brzina vrtnje rotora generatora.

Metoda za besenzorski leteći start također se temelji na opserveru u kliznom načinu rada čiji je matematički model prilagođen isprekidanom načinu rada pretvarača. Na taj način omogućena je estimacija kuta i brzine vrtnje rotora prije uključenja generatorskog dijela pretvarača te je osigurana minimalna struja uklopa.

Metoda za smanjenje estimacijske greške opservera u kliznom načinu rada uslijed promjene parametara generatora pri magnetskom zasićenju temelji se na adaptaciji poprečnog induktiviteta pomoću aproksimativne funkcije. Koeficijenti aproksimativne funkcije određeni su linearnom regresijom iz niza mjerenja dobivenih histereznim upravljanjem struje u poprečnoj osi prije početka rada pretvarača.

Sve razvijene metode ispitane su i eksperimentalno potvrđene u laboratoriju. Laboratorijski postav sastoji se od sinkronog generatora s permanentnom magnetima, pretvarača i opteretnog asinkronog stroja. Upravljački algoritmi za pretvarač napisani su u programskom jeziku C i implementirani u digitalni upravljački sustav temeljen na procesoru *Texas Instruments* Delfino C28343.

Ključne riječi: vjetroagregat, sinkroni generator s permanentnim magnetima, upravljanje bez mjernog člana brzine vrtnje, opserver u kliznom načinu rada, leteći start, adaptacija induktiviteta

Extended abstract

Sensorless control of permanent magnet wind generator based on sliding-mode observer

The integration of power plants based on renewable resources into power generation systems has increased significantly worldwide in recent decades. Moreover, the use of wind energy dominates compared to all other types of renewable energy sources. In the last decade, the capacity installed in wind power plants accounted for more than 50% of the total electrical energy generated in renewable energy power plants, excluding hydropower. Projections for the period between 2020 and 2025 indicate that approximately 94 GW of additional capacity will be installed in wind energy conversion systems per year, representing an increase of 469 GW of electrical power generated from wind energy by 2025. The above statistics and trends justify increased research into power generation systems based on renewable resources, particularly wind.

Two main components of wind energy conversion systems are mechanical and electrical subsystems. The main mechanical components are the rotor blades, which convert the kinetic energy of the wind into mechanical rotational energy. The electrical generators provide the further conversion into electrical energy, which is usually transmitted to the power grid through a power converter. Today, the most common electrical generator in high-power wind energy conversion systems (> 1 MW) is a doubly-fed induction generator because of its low cost and high reliability. The main competitor of the doubly-fed induction generator is the permanent magnet synchronous generator, which is characterized by its high efficiency, high power factor, and high energy density per volume. In terms of failure rates, some research indicates that the failures of wind energy conversion systems with doubly-fed induction generators are less frequent than those with permanent magnet generators. However, the higher failure rate for systems with permanent magnet generators is mainly due to failures in the converter subsystems, such as the cooling system, rather than failures of the generator itself. In contrast, generator failures are the same or even higher for systems with doubly-fed induction generators. Nevertheless, Type 4 wind energy conversion systems, which consist of a AC-DC-AC converter and a permanent magnet generator, are increasingly being used due to their advantages such as high wind energy conversion efficiency, separation between the generator and the power grid, operation at full speed, and robustness to power grid disturbances. In addition, the option of using multipole permanent magnet generators allows a direct connection between the generator shaft and the wind turbine, eliminating the need for a gearbox. This option is a great advantage, as gearbox failures are likely to be very complex and result in the wind turbine being out of service for several days.

In addition to mechanical and electrical failures, sensor failures account for 10–20% of all

system failures. However, standard control algorithms for permanent magnet generators typically require sensors that provide information about rotor angle and speed, such as encoders or resolvers. Therefore, sensorless control algorithms for a permanent magnet generator with implemented methods for estimating rotor angle and speed increase the overall robustness of the system. Accordingly, the development of sensorless control algorithms for the permanent magnet generator in wind energy conversion systems is the focus of the research in this dissertation. The research deals with a comprehensive algorithm that improves the standard control algorithms for permanent magnet generators in wind energy conversion systems. This improvement manifests itself in the use of a sensorless control algorithm based on a sliding-mode observer that enables a flying start of a permanent magnet generator, robust operation over the entire operating range, and reduced sensitivity to variations in generator parameters.

Recently, the application of sliding-mode theory to the development of sensorless control structures for electrical machines has attracted considerable interest. In sensorless applications for permanent magnet machines, most methods that use a sliding-mode observer are based on estimating the back-EMF, which means that their accuracy is higher in the medium and high speed ranges. This makes the sliding-mode observer an excellent candidate for sensorless control of the permanent magnet generator in wind energy conversion system, since these systems are characterized by the cut-in speed, which is the lowest allowable speed of the wind turbine. Thus, a generator-side converter is switched on only when the cut-in speed is reached. In contrast, the generator-side converter is switched off and no energy conversion takes place. Furthermore, since the sliding-mode observer is a model-based method, its complexity depends on the mathematical model of the permanent magnet synchronous generator. Surface permanent magnet generators are more suitable for sensorless control based on the sliding-mode observer because of their simple mathematical model, while the mathematical model of interior permanent magnet generators must be reconstructed to be suitable for the sliding-mode observer design. The most commonly used model reconstructions of the interior permanent magnet generator are the extended back-EMF model and the active flux model. The reconstructed extended back-EMF or active flux model of the interior permanent magnet generator in the stationary $\alpha\beta$ reference frame becomes equivalent to the surface permanent magnet generator model in the sense that the rotor angle information is present only in the extended back-EMF vector. Accordingly, the sliding-mode observer based on the reconstructed models can perform the estimation of the rotor angle of the interior permanent magnet generator in a similar way as for the surface permanent magnet generators. One of the differences between these two reconstructed models is the number of parameters required to develop a sliding-mode observer. The extended back-EMF model requires knowledge of stator resistance and d- and q-axis inductance, while the active flux model requires only stator resistance and q-axis inductance. Although there are many research papers on the implementation of sliding-mode observers in sensorless control systems for permanent magnet synchronous

machines, few of them deal with sliding-mode observers modeled in the estimated rotating $\gamma\delta$ reference frame. In this case, the information to be retrieved is not the rotor angle contained in the sinusoidal signal, but the estimated rotor angle error contained in the DC signal. Therefore, the low-pass filter can be tuned to a low-frequency range without the need for compensation. In addition, the phase-locked loop PI controller must be used to bring the estimated rotor angle error to zero. Due to the inherent low-pass filtering of the phase-locked loop, the estimated rotor angle and speed are additionally filtered. Therefore, a sliding-mode observer modeled in the $\gamma\delta$ reference frame can achieve better chattering attenuation than a sliding-mode observer modeled in the $\alpha\beta$ reference frame. Apart from the various mathematical models used in the design of the sliding-mode observer, different control laws can be used to enforce and maintain the error trajectory on the sliding surface. These control laws can be signum functions, sigmoid functions or some advanced methods such as a super-twisting algorithm. Finally, the methods for extracting the rotor angle and speed from the sliding-mode observer also differ depending on the reference frame and the control law used. One of the goals of this dissertation is to develop a sliding-mode observer that allows sensorless control of a permanent magnet generator while requiring fewer parameters and reducing chattering in the estimated signals.

When the permanent magnet generator is used in a wind energy conversion system, a back-EMF is induced at its terminals due to the initial rotational speed. The process by which the generator-side converter must be switched on while the permanent magnet generator is rotating is referred to as flying start of the permanent magnet generator. However, if the permanent magnet generator and the generator-side converter are not synchronized during the flying start, the induced back-EMF leads to high inrush currents and consequently a high impact torque. This phenomenon poses a particular challenge for sensorless control of permanent magnet generators, since the rotor angle, speed, and induced back-EMF should be known before the generator-side converter is switched on in order to reduce inrush current and torque impact. Most of the scientific works dealing with sensorless control of permanent magnet synchronous machines are concerned with the estimation of rotor angle and speed starting from zero speed. On the other hand, there are a few research papers that consider sensorless control algorithms together with the flying start method. The methods proposed in these works are usually based on the injection of high frequency signals, zero voltage pulses or voltage measurements. Furthermore, despite the widespread implementation of sliding-mode observers in sensorless control structures of permanent magnet generators, to the best of the authors' knowledge, there are no methods that account for the flying start of a permanent magnet generator based on sliding-mode observers. For this reason, part of this dissertation is to develop a sliding-mode observer capable of estimating rotor angle and speed during discontinuous operation of the generator-side converter to enable flying start of the permanent magnet generator and sensorless control once flying start has occurred.

Finally, sliding-mode observers are mainly developed using the constant parameters of the permanent magnet generator. Most of the works dealing with sliding-mode observers neglect the fact that parameters such as the stator resistance, d- and q-axis inductance are not found on the nameplate of the permanent magnet generator. Moreover, despite its robustness, the estimation accuracy of the sliding-mode observer is affected by the mismatches between the parameters of the permanent magnet generator and the sliding observer that occur at the heavy load operating points due to temperature changes and the magnetic saturation effect. The estimation error of the sliding observer is mainly affected by the mismatch of q-axis inductance. Except for the sliding-mode observer, the standard control structures such as the field-oriented control, which is still widely used for the generator-side converter control, require the permanent magnet generator parameters for the tuning process. The lack of familiarity with the parameters of the permanent magnet generator can be overcome by applying some methods for self-commissioning. Since there is no standard procedure, many methods of self-commissioning are proposed for the AC drives. Self-commissioning can be performed with the rotor free or locked, and the parameters are usually estimated using frequency or time response methods. The research focus of the dissertation is to apply some already known self-commissioning methods to ensure the information on the required parameters for designing the sliding-mode observer, tuning the current controller, and determining the q-axis inductance approximation function to minimize the estimation error of the sliding-mode observer at heavy load operating points.

Overall, the contribution of this dissertation is threefold:

1. The sliding-mode observer in the estimated rotating $\gamma\delta$ reference frame is modeled using the active flux model of the permanent magnet generator. Compared to the standard sliding-mode observers in the stationary $\alpha\beta$ reference frame, the proposed method is less computationally intensive and achieves better chattering attenuation.
2. The sliding-mode observer in both the stationary $\alpha\beta$ and the estimated rotating $\gamma\delta$ reference frames are adapted for the sensorless flying start purpose using the discontinuous operation mode of the generator-side converter which allows the use of the same sliding-mode observer based estimation structure for the flying start as for the continuous operation mode. The operation of the algorithm is analyzed using a general mathematical model in the discrete-time domain, regardless of the reference frame used for the implementation or the order of the sliding-mode observer. In literature the exact expressions for the computation of the gain can only be found for first-order sliding-mode observers in continuous operation. In this dissertation, exact expressions for the computation of the gain are derived for both first- and second-order sliding-mode observers for both discontinuous and continuous operation and for both stationary and estimated rotating reference frames.
3. For a full range of operation, the main cause of the error in estimating the rotor angle is correctly identified and a suitable solution is found in the form of an adjustment of the

q-axis inductance using an approximation function to minimize the error.

Thus, a total of six algorithms are presented and analyzed, modified for flying start, and a complete parameter adjustment is derived. Experimental verification is performed for all six algorithms and a comprehensive and detailed comparison is made. The laboratory setup for the verification consists of a permanent magnet generator, an inverter, and a load induction machine emulating the wind turbine. The control algorithm was written in the *C* programming language and integrated into the digital control system based on the *Texas Instruments* Delfino C28343 processor.

Finally, the dissertation is structured as follows:

Chapter 1 - ***Introduction*** - In the introductory chapter, the problems and the motivation of the scientific research of the dissertation are presented. In addition, the original scientific contributions and the structure of the dissertation are briefly presented and described.

Chapter 2 - ***Wind energy conversion*** - The second chapter describes the most commonly used types of wind energy conversion systems. Then, the mathematical model of wind turbines, the physical principles of wind energy conversion, and the basics of the control principle of wind turbines are presented. Finally, the mathematical model of a permanent magnet synchronous generator is presented and the standard control algorithms for AC-DC-AC converters are described.

Chapter 3 - ***Sliding-mode theory*** - The third chapter gives an introduction to sliding-mode theory, which is necessary for understanding the operation of sliding-mode observers, including some simulation examples.

Chapter 4 - ***Laboratory setup*** - The fourth chapter describes the experimental setup used to test the developed control algorithms. The experimental setup includes the nominal data of the tested permanent magnet synchronous generator, the converter, the induction machine, and measuring equipment. Finally, the chapter describes a digital control system in which the control algorithms are implemented and a software tool in which the algorithms are written.

Chapter 5 - ***Sensorless control of a permanent magnet generator based on a sliding-mode observer*** - The fifth chapter describes in detail the first part of the original scientific contribution. The chapter begins with a literature review on sensorless control of permanent magnet synchronous machines, focusing on sliding-mode observers. After the literature review, the mathematical model of the developed sliding-mode observer and the structure of the rotor angle and speed estimation method based on the developed observer are described. Finally, the experimental results are presented.

Chapter 6 - ***Flying start of a permanent magnet generator based on a sliding-mode observer*** - The sixth chapter describes in detail the second part of the original scientific contribution. At the beginning of the chapter, a review of the literature on the methods of flying start of a permanent magnet synchronous generator is given. A modified mathematical model is derived

for a sliding-mode observer suitable for estimating the angle and speed of the rotor in the discontinuous mode of operation of the converter. A control structure based on a modified sliding-mode observer is described that enables a flying start of a permanent magnet synchronous generator with a minimum inrush current. Finally, experimental results are presented.

Chapter 7 - ***Reducing the estimation error of a sliding-mode observer*** - The seventh chapter describes the third part of the original scientific contribution. The chapter begins with a review of the literature dealing with the determination and adjustment of the parameters of a permanent magnet synchronous generator and the reduction of the estimation error of the sliding-mode observer due to the magnetic saturation of the generator. The proposed method for adjusting the q-axis inductance based on the approximation function for reducing the estimation error of the sliding-mode observer is described. Finally, simulation and experimental results are presented.

Chapter 8 - ***Conclusion*** - The last chapter contains a short summary and conclusion of the dissertation.

Keywords: wind energy conversion system, permanent magnet generator, sensorless control, sliding-mode observer, flying start, inductance adaptation

Sadržaj

1. Uvod **1**

1.1. Opis problema i motivacija istraživanja 1
1.2. Izvorni znanstveni doprinos 5
1.3. Struktura disertacije 6

2. Pretvorba energije vjetra **9**

2.1. Sustavi za pretvorbu energije vjetra 9
2.1.1. Mehanički sustav vjetroagregata 9
2.1.2. Električni sustav vjetroagregata 10
2.1.3. Upravljački sustav vjetroagregata 11
2.2. Matematički model vjetroturbine 11
2.2.1. Fizikalne osnove energije vjetra 11
2.2.2. Dinamička jednadžba vjetroturbine 16
2.3. Upravljanje vjetroturbinom 16
2.3.1. Upravljanje vjetroturbinom ispod nazivne brzine vrtnje 18
2.3.2. Upravljanje vjetroturbinom iznad nazivne brzine vrtnje 19
2.4. Matematički model PMSG-a 21
2.4.1. Prikaz trofaznih veličina preko prostornog vektora 24
2.4.2. Transformacije koordinata 26
2.4.3. Matematički model PMSG-a u troosnom abc koordinatnom sustavu . .28
2.4.4. Matematički model PMSG-a u dvoosnom mirujućem $\alpha\beta$ koordinatnom sustavu 30
2.4.5. Matematički model PMSG-a u dvoosnom rotirajućem dq koordinatnom sustavu 31
2.4.6. Matematički model PMSG-a u estimiranom dvoosnom rotirajućem $\gamma\delta$ koordinatnom sustavu 32
2.4.7. Snaga i moment PMSG-a 33
2.4.8. Radno područje PMSG-a 35
2.5. Upravljanje AC-DC-AC energetskim pretvaračem 38

2.5.1. Upravljanje generatorskim dijelom AC-DC-AC pretvarača 39
2.5.2. Upravljanje mrežnim dijelom AC-DC-AC pretvarača 40
2.5.3. Vektorska modulacija 41

3. Teorija kliznih režima **47**
3.1. Primjeri sustava s kliznim režimom 47
3.1.1. Klizni režim u mehaničkom sustavu 47
3.1.2. Klizni režim u električnom sustavu 49
3.2. Uvjeti postojanja kliznog režima 52
3.2.1. Uvjet dohvaćanja klizne plohe 53
3.2.2. Uvjet postojanja kliznog režima 53
3.3. Dinamika i stabilnost sustava u kliznom režimu 55
3.3.1. Stabilnost sustava u kliznom režimu 56
3.4. Odabir upravljačkog zakona 58
3.4.1. Efekt zveketanja (engl. *chattering effect*) 59
3.5. Primjer upravljanja silaznim DC-DC pretvaračem temeljenog na kliznom režimu61
3.6. Opserver u kliznom načinu rada 64
3.6.1. Uvjet dohvaćanja i postojanja kliznog režima u prostoru stanja greške opservera 66
3.6.2. Stabilnost kliznog režima u prostoru stanja greške opservera 66
3.6.3. Robusnost opservera u kliznom načinu rada 67
3.6.4. Razlike između regulatora i opservera u kliznom načinu rada 68
3.6.5. Primjer opservera u kliznom načinu rada 68
3.7. Diskretni klizni režim 69

4. Opis laboratorijskog postava **71**
4.1. Energetski dio postava 71
4.2. Upravljački dio laboratorijskog postava 72
4.3. Mjerna oprema 76

5. Bezsenzorsko upravljanje PMSG-om zasnovano na opserveru u kliznom načinu rada **79**
5.1. Pregled literature 79
5.1.1. Prvi dio znanstvenog doprinosa 85
5.2. Rekonstrukcija matematičkog model PMSG-a 85
5.2.1. Model PMSG-a temeljen na aktivnom magnetskom toku rotora u dq koordinatnom sustavu 85

5.2.2. Model PMSG-a temeljen na aktivnom magnetskom toku rotora u $\alpha\beta$ koordinatnom sustavu 86
5.2.3. Model PMSG-a temeljen na aktivnom magnetskom toku rotora u $\gamma\delta$ koordinatnom sustavu 87
5.2.4. Opći zapis modela PMSG-a temeljenog na aktivnom magnetskom toku rotora 88
5.3. Matematički model SMO-a u estimiranom rotirajućem $\gamma\delta$ koordinatnom sustavu temeljen na modelu aktivnog toka PMSG-a 89
5.3.1. Opći zapis modela SMO-a 89
5.3.2. SMO u estimiranom $\gamma\delta$ koordinatnom sustavu 89
5.4. Analiza uvjeta dohvaćanja i stabilnosti kliznog režima 90
5.4.1. Klizni režim prvog reda 90
5.4.2. Klizni režim drugog reda 92
5.5. Metoda bezsenzorskog upravljanja PMSG-a temeljena na SMO-u u $\gamma\delta$ koordinatnom sustavu 94
5.6. Eksperimentalni rezultati 97
5.6.1. Verifikacija bezsenzorske metode temeljene na SMO-u $\gamma\delta$ koordinatnom sustavu 98
5.6.2. Usporedba bezsenzorske metode upravljanja temeljene na SMO-a u $\gamma\delta$ i $\alpha\beta$ koordinatnom sustavu 100

6. Leteći start PMSG-a primjenom opservera u kliznom načinu rada 107
6.1. Pregled literature 107
6.1.1. Drugi dio znanstvenog doprinosa 110
6.2. Isprekidani način rada pretvarača 110
6.2.1. Matematički model PMSG-a tijekom isprekidanog načina rada 111
6.3. Matematički model SMO-a pri isprekidanom načinu rada pretvarača 112
6.4. Analiza uvjeta dohvaćanja i stabilnosti SMO-a pri isprekidanom načinu rada pretvarača 113
6.4.1. Klizni režim prvog reda 114
6.4.2. Klizni režim drugog reda 115
6.4.3. Prelazak iz isprekidanog u trajni način rada 116
6.5. Metoda letećeg starta PMSG-a temeljena na SMO-u i isprekidanom načinu rada pretvarača 117
6.6. Eksperimentalni rezultati 121
6.6.1. Leteći start temeljen na SMO-u $\alpha\beta$ koordinatnom sustavu 122
6.6.2. Leteći start temeljen na SMO-u $\gamma\delta$ koordinatnom sustavu 127

7. Smanjenje estimacijske greške opservera u kliznom načinu rada 131
7.1. Pregled literature 131
7.1.1. Treći dio znanstvenog doprinosa 135
7.2. Utjecaj magnetskog zasićenja na induktivitete PMSG-a 136
7.3. Greška estimiranog kuta rotora uzrokovana promjenom parametara PMSG-a . .138
7.4. Određivanje parametara PMSG-a 139
7.4.1. Određivanje statorskog otpora 140
7.4.2. Određivanje nezasićenog poprečnog induktiviteta i njegove aproksimativne funkcije 140
7.4.3. Određivanje uzdužnog induktiviteta 143
7.5. Metoda za smanjenje estimacijske greške SMO-a 143
7.6. Simulacijski rezultati 143
7.6.1. Određivanje parametara aproksimativne funkcije induktiviteta 145
7.6.2. Smanjenje greške estimiranog kuta rotora primjenom aproksimativne funkcije poprečnog induktiviteta 148
7.7. Eksperimentalni rezultati 150

8. Zaključak 155

Literatura 159

Popis oznaka 173

Popis slika 181

Popis tablica 185

Prilog - Izvedba predloženih metoda u programskom jeziku C 187

Životopis 213

Curriculum vitae 217

1.Uvod

1.1.Opis problema i motivacija istraživanja

Statistički podaci o električnoj energiji dobivenoj iz obnovljivih izvora energije potvrđuju porast integracije elektrana na obnovljive energente u elektroenergetske sustave diljem svijeta. Taj porast posebno je izražen u drugom desetljeću 21. stoljeća. Na slici 1.1 prikazan je porast ukupne instalirane električne snage elektrana na obnovljive izvore, porast instalirane električne snage elektrana iz obnovljivih izvora ne uzimajući u obzir hidroelektrane te porast instalirane električne snage elektrana na vjetar u razdoblju od 2000. do 2025. godine prema [1, 2]. Osim porasta integracije elektrana na obnovljive energente u elektroenergetski sustav, može se uočiti dominacija električne energije dobivene iz vjetra u odnosu na druge obnovljive izvore. U posljednjem desetljeću instalirana električna snaga vjetroelektrana čini u prosjeku više od 50% ukupne električne snage proizvedene u elektranama na obnovljive energente (uz zanemarenje hidroelektrana). Predviđanja za period između 2020. i 2025. godine očekuju porast od otprilike 94 GW snage dobivene iz energije vjetra godišnje [3], što predstavlja dodatnih 469 GW proizvedene električne snage iz energije vjetra do 2025. Navedene statistike i trendovi opravdavaju ulaganja u istraživanja sustava za proizvodnju električne energije iz obnovljivih izvora, ponajviše iz energije vjetra.

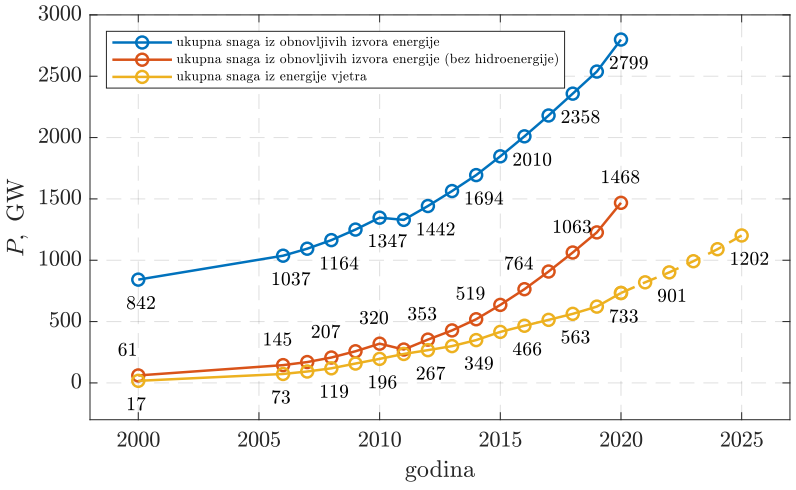

Slika 1.1: Instalirana električna snaga iz obnovljivih izvora energije u razdoblju od 2000. do 2025.

Sustavi za pretvorbu energije vjetra u električnu energiju, odnosno vjetroagregati, sastoje se od dva ključna dijela: mehaničkog i električnog. Najvažnije mehaničke komponente vjetroagregata čine rotorske lopatice koje vrše pretvorbu kinetičke energije vjetra u mehaničku rotacijsku energiju rotora. Daljnju pretvorbu mehaničke rotacijske energije rotora u električnu energiju čine električni generatori, a proizvedena električna energija najčešće se predaje električnoj mreži preko energetskog pretvarača. Prema [4–8], danas najzastupljeniji električni generatori u vjetroagregatima su dvostruko napajani asinkroni generatori. Zastupljenost dvostruko napajanih asinkronih generatora u vjetroagregatima velikih snaga ($\geq$ 1 MW) veća je od 50%, a slijede ih sinkroni generatori s permanentnim magnetima [5]. Uspoređujući sustave s navedenim generatorima, kao najveća prednost vjetroagregata s dvostruko napajanim asinkronim generatorima ističu se manji financijski troškovi i veća pouzdanost [9]. S druge strane, prednosti vjetroagregata sa sinkronim generatorima s permanentnim magnetima jesu veća korisnost, veći faktor snage i veća gustoća energije po volumenu generatora [5, 7, 10]. Govoreći o pouzdanosti, istraživanje provedeno u [9] pokazuje da vjetroagregati sa sinkronim generatorima s permanentnim magnetima imaju tri puta veću učestalost kvarova od vjetroagregata koji koriste dvostruko napajane asinkrone generatore. Međutim, uzrok veće učestalosti kvarova takvih sustava su kvarovi u energetskim AC-DC-AC pretvaračima (najčešće u sustavima za hlađenje pretvarača) [9, 11], dok su kvarovi samog generatora podjednaki [11] ili čak veći [9] kod sustava s dvostruko napajanim asinkronim generatorima, nego li u sustavima sa sinkronim generatorima s permanentnim magnetima. Unatoč spomenutim kvarovima AC-DC-AC pretvarača, vjetroagregati tipa 4 u kojima se koriste sinkroni generatori s permanentnim magnetima [5] imaju mnoge prednosti kao što su veća iskoristivost energije vjetra, odvojenost generatora od električne mreže, radno područje u punom opsegu brzine vrtnje (0 do 100%) i veća robusnost na poremećaje u električnoj mreži [5, 12]. Nadalje, mogućnost projektiranja višepolnih, odnosno sporohodnih sinkronih generatora s permanentnim magnetima omogućuje izravan spoj osovine generatora na vjetroturbinu bez potrebe za prijenosnim mehanizmom ili, pak, uz primjenu prijenosnog mehanizma s manjim prijenosnim omjerom pri većim snagama [5, 7, 10]. S obzirom na to da su kvarovi prijenosnog mehanizma često vrlo složeni i zahtijevaju zaustavljanje pogona vjetroagregata na više dana [13–15], ova mogućnost predstavlja veliku prednost vjetroagregata sa sinkronim generatorom s permanentnim magnetima u odnosu na sustave s dvostruko napajanim asinkronim generatorom.

Sinkroni generator s permanentnim magnetima se koristi u vjetroagregatima tipa 4 u kojima je generator spojen na električnu mrežu preko trofaznog AC-DC-AC pretvarača. Takva topologija također se koristi i za upravljanje električnim strojevima s permanentnim magnetima u sustavima različitih namjena kao što su električni automobili, električna vuča i ostali elektromotorni pogoni. Za navedene sustave razvijeni su razni algoritmi upravljanja među kojima su neki od najzastupljenijih: upravljanje orijentacijom toka, izravno upravljanje momentom, upravljanje orijentacijom napona i izravno upravljanje snagom. Ovi algoritmi koriste se i za upravljanje

sinkronim generatorima s permanentnim magnetima, odnosno, AC-DC-AC pretvaračima u vjetroagregatima tipa 4 [16]. AC-DC-AC pretvarač dijeli se na generatorski i mrežni dio. Glavna zadaća upravljanja mrežnim dijelom trofaznog AC-DC-AC pretvarača je upravljanje tokovima radne i jalove snage prema elektroenergetskom sustavu [17], dok se upravljanje generatorskim dijelom svodi na upravljanje momentom sinkronog generatora s permanentnim magnetima u svrhu praćenja krivulje maksimalne snage vjetroturbine čime se osigurava optimalna pretvorba energije vjetra [18, 19].

Osim mehaničkih i električnih kvarova, prema [15] kvarovi senzora čine 10–20% svih kvarova vjetroagregata. Iz tog razloga, poželjno je reducirati broj senzora u sustavu u svrhu povećanja robusnosti vjetroagregata na kvarove. S obzirom na to da standardni upravljački algoritmi za upravljanje sinkronim generatorom s permanentnim magnetima obično zahtijevaju poznavanje kuta i brzine rotora, jedan od načina za reduciranje mjernog člana kuta i brzine vrtnje rotora jest razvoj metoda za bezsenzorsko upravljanje sinkronim generatorom s permanentnim magnetima. Bezsenzorsko upravljanje podrazumijeva algoritme kojima nisu potrebni senzor kuta i brzine vrtnje rotora poput enkodera ili rezolvera.

Iz tog razloga, istraživanje doktorske disertacije temelji se na naprednim algoritmima za bezsenzorsko upravljanje sinkronim generatorom s permanentnim magnetima. U proteklim desetljećima primjena naprednih metoda za bezsenzorsko upravljanje električnim strojevima značajno je porasla, a jedna od takvih metoda je i teorija kliznih režima [20]. Posebno je uočljivo zanimanje za teoriju kliznih režima u razvoju bezsenzorskih upravljačkih struktura za sinkrone generatore s permanentnim magnetima, asinkrone strojeve i reluktantne sinkrone strojeve. Sinkroni strojevi s permanentnim magnetima dijele se u dvije skupine ovisno o položaju magneta u rotoru stroja. Ukoliko se magneti nalaze na površini rotora govori se o sinkronim strojevima s površinskim magnetima, a ako su magneti smješteni unutar rotora, radi se o sinkronim strojevima s unutarnjim magnetima. Sinkroni strojevi s površinskim magnetima prikladniji su za primjenu bezsenzorskog upravljanja temeljenog na opserveru u kliznim režimu zbog jednostavnijeg matematičkog modela koji ih opisuje, dok su sinkroni strojevi s unutarnjim magnetima, zbog magnetske nesimetrije, mnogo složeniji i zahtijevaju rekonstrukciju modela pogodnog za razvoj opservera u kliznom načinu rada [21]. Unatoč uspješnoj i širokoj primjeni opservera u kliznom načinu rada u bezsenzorskim upravljačkim strukturama za sinkrone strojeve s permanentnim magnetima, problem koji se javlja kod opservera temeljenih na modelu stroja, kao što je i opserver u kliznom načinu rada, jest potreba poznavanja parametara i utjecaj promjenjivosti parametara stroja na točnost estimacije kuta rotora. Prema tome, predmet istraživanja ove doktorskoj disertaciji je opserver u kliznom načinu rada temeljen na modelu sinkronog generatora s permanentnim magnetima koji omogućuje estimaciju kuta i brzine rotora, odnosno bezsenzorsko upravljanje, ali zahtijeva poznavanje manjeg broja parametara i postiže manju zašumljenost estimiranih signala.

Nadalje, većina znanstvenih radova o bezsenzorskom upravljanju sinkronim strojevima s permanentnim magnetima bavi se estimacijom kuta i brzine rotora iz mirovanja. S druge strane, nekolicina radova razmatra bezsenzorske algoritme upravljanja koji uključuju i metodu letećeg starta. Leteći start sinkronog generatora s permanentnim magnetima je proces koji objedinjuje sinkronizaciju generatora i pretvarača te uklop generatora na pretvarač. Sinkronizacija generatora i pretvarača podrazumijeva podudaranje estimiranog kuta rotora iz upravljačkog algoritma sa stvarnim kutom rotora sinkronog generatora s permanentnim magnetima [22, 23]. S druge strane, jedna od karakteristika rada vjetroagregata je ograničenost njegovog radnog područja uklopnom brzinom koja predstavlja najnižu dozvoljenu brzinu vjetroturbine [19]. Pri brzinama nižim od uklopne brzine pretvarač je isključen i ne postoji pretvorba energije, a uključenje pretvarača odvija se tek nakon postizanja uklopne brzine. Kada se kao generator u vjetroagregatu koristi sinkroni stroj s permanentnim magnetima, kao posljedica početne brzine vrtnje, dolazi do induciranja napona na stezaljkama generatora. Upravo zato je sinkronizacija generatora i pretvarača prije uklopa nužna jer bi pri nesinkroniziranom uklopu generatora na pretvarač inducirani napon mogao prouzročiti velike uklopne struje te posljedično veliki udarni moment što može dovesti do električnih i mehaničkih oštećenja [23]. Prema tome, sinkronizacija sinkronog generatora s permanentnim magnetima i pretvarača, osim određivanje kuta rotora, podrazumijeva i određivanje induciranog napona prije uklopa generatora na pretvarač. Iz tog razloga, predmet istraživanja doktorske disertacije predstavlja razvoj opservera u kliznom načinu rada koji omogućuje estimaciju kuta i brzine rotora prije uklopa generatora na pretvarač te tako osigurava uspješnu sinkronizaciju i leteći start sinkronog generatora s permanentnim magnetima. Nadalje, razvijeni opserver treba omogućiti estimaciju kuta i brzine rotora i pri trajnom radu sinkronog generatora s permanentnim magnetima, odnosno nakon uklopa generatora na pretvarač.

Osim toga, kao što je navedeno ranije, jedan od glavnih nedostataka opservera u kliznom načinu jest utjecaj promjenjivosti parametara sinkronog generatora s permanentnim magnetima na točnost estimacije kuta rotora. Budući da se opserver u kliznom načinu rada najčešće modelira s fiksnim parametrima stroja (otporom i induktivitetima) u različitim radnim točkama pojavit će se odstupanje modela opservera i generatora [24]. To odstupanje je najizraženije pri velikim strujama koje uzrokuju značajno smanjenje induktiviteta uzrokovano magnetskim zasićenjem sinkronog generatora s permanentnim magnetima, a najveća promjena vidljiva je u induktivitetu u poprečnoj osi čiji je utjecaj na grešku estimiranog kuta rotora prema tome i najveći. Stoga predmet istraživanja doktorske disertacije također uključuje i metodu za adaptaciju induktiviteta u poprečnoj osi u svrhu smanjenja estimacijske greške opservera u kliznom načinu rada uslijed zasićenja sinkronog generatora s permanentnim magnetima.

U nastavku du navedeni izvorni znanstveni doprinos i struktura doktorske disertacije.

1.2.Izvorni znanstveni doprinos

Izvorni znanstveni doprinos ove doktorske disertacije vezan je uz algoritme upravljanja sinkronim generatorom s unutarnjim permanentnim magnetima i dijeli se na:

1. **Metoda za bezsenzorsko upravljanje sinkronim vjetrogeneratorom s permanentnim magnetima temeljena na opserveru u kliznom načinu rada, estimiranom rotirajućem koordinatnom sustavu i modelu aktivnog magnetskog toka vjetrogeneratora**.
   Prvi dio znanstvenog doprinosa temelji se na razvoju metode za upravljanje sinkronim generatorom s permanentnim magnetima na temelju strukture koja sadrži opserver u kliznom načinu rada i regulator u fazno zatvorenoj petlji. Opserver u kliznom načinu rada modeliran je u estimiranom rotirajućem koordinatnom sustavu na temelju modela aktivnog magnetskog toka sinkronog generatora s permanentnim magnetima što smanjuje broj parametara potrebnih za modeliranje opservera te smanjuje zašumljenost estimiranih signala. Ovako modeliran opserver omogućuje estimaciju greške kuta između stvarnog i estimiranog rotirajućeg sustava na temelju koje fazno zaključana petlja određuje estimiranu brzinu i kut rotora vjetrogeneratora.
2. **Metoda za leteći start sinkronog vjetrogeneratora s permanentnim magnetima temeljena na opserveru u kliznom načinu rada prilagođenom isprekidanom radu energetskog pretvarača.**
   Drugi dio znanstvenog doprinosa koristi strukturu razvijenu u sklopu prvog doprinosa kako bi, osim estimacije brzine i kuta rotora sinkronog generatora s permanentnim magnetima u trajnom radu, omogućio estimaciju istih tijekom isprekidanog rada pretvarača. U tu svrhu, opserver u kliznom načinu radu prilagođen je matematičkom modelu vjetrogeneratora tijekom kratkotrajnih kratkih spojeva karakterističnih za isprekidani rad pretvarača. Na ovaj način, metoda temeljena na opserveru u kliznom načinu rada i fazno zatvorenoj petlji proširena je tako da, uz bezsenzorsko upravljanje u trajnom radu, omogućuje i bezsenzorski leteći start sinkronog vjetrogeneratora s permanentnim magnetima.
3. **Metoda za adaptaciju induktiviteta u poprečnoj osi rotirajućeg koordinatnog sustava primjenom aproksimativne funkcije ovisnosti induktiviteta o struji s ciljem smanjenja estimacijske greške opservera u kliznom načinu rada.**
   Treći dio znanstvenog doprinosa odnosi se za smanjenje estimacijske greške metode za bezsenzorsko upravljanje sinkronog generatora s permanentnim magnetima temeljene na opserveru u kliznom načinu rada i fazno zaključanoj petlji uzrokovane promjenom induktiviteta u poprečnoj osi uslijed magnetskog zasićenja pri velikim strujnim opterećenjima. Smanjenje estimacijske greške ostvaruje se adaptacijom iznosa poprečnog induktiviteta opservera na temelju aproksimativne funkcije određene nizom mjerenja. Mjerenja su provedena prije procesa letećeg starta sinkronog generatora s permanentnim

magnetima primjenom već poznatih metoda puštanja u pogon koje koriste isključivo energetski pretvarač, bez korištenja dodatne mjerne opreme.

1.3.Struktura disertacije

Poglavlje 1 - U uvodnom poglavlju opisana je problematika, područje i motivacija znanstvenog istraživanja doktorske disertacije. Uz to, ukratko su predstavljeni i opisani izvorni znanstveni doprinosi te struktura doktorske disertacije.

Poglavlje 2 - U drugom poglavlju opisane su najčešće korištene vrste sustava za pretvorbu energije vjetra. Nakon toga je predstavljen matematički model vjetroagregata, fizikalne osnove pretvorbe energije vjetra te osnovna načela upravljanja vjetroturbinom. Na kraju je prikazan matematički model sinkronog generatora s permanentnim magnetima te su opisani standardni algoritmi za upravljanje AC-DC-AC pretvaračem.

Poglavlje 3 - U trećem poglavlju ukratko je predstavljena teorija kliznih režima potrebna za razumijevanje načina rada opservera u kliznom načinu rada uz nekoliko simulacijskih primjera.

Poglavlje 4 - U četvrtom poglavlju opisan je eksperimentalni postav na kojem su verificirani razvijeni algoritmi upravljanja. Opis eksperimentalnog postava uključuje nazivne podatke ispitivanog sinkronog generatora s permanentnim magnetima, pretvarača, opteretnog asinkronog stroja i mjerne opreme. Nadalje, opisan je digitalni sustav upravljanja u koji su implementirani algoritmi upravljanja kao i programski alat u kojem su algoritmi napisani.

Poglavlje 5 - U petom poglavlju detaljno je opisan prvi dio izvornog znanstvenog doprinosa. Na početku poglavlja dan je pregled literature vezan uz bezsenzorsko upravljanje sinkronim strojevima s permanentnim magnetima s naglaskom na opserverima u kliznom načinu rada. Nakon pregleda literature opisan je matematički model razvijenog opservera u kliznom načinu rada te struktura estimacije kuta i brzine rotora temeljena na razvijenom opserveru. Na kraju su prikazani eksperimentalni rezultati.

Poglavlje 6 - U šestom poglavlju detaljno je opisan drugi dio izvornog znanstvenog doprinosa. Na početku poglavlja dan je pregled literature vezan uz metode letećeg starta sinkronog generatora s permanentnim magnetima. Izveden je modificirani matematički model opservera u kliznom načinu rada prilagođen za estimaciju kuta i brzine rotora pri isprekidanom radu pretvarača. Opisana je upravljačka struktura temeljena na modificiranom opserveru koja osigurava leteći start sinkronog generatora s permanentnim magnetima uz minimalnu uklopnu struju. Na kraju su prikazani eksperimentalni rezultati.

Poglavlje 7 - U sedmom poglavlju je opisan treći dio izvornog znanstvenog doprinosa. Na početku poglavlja dan je pregled literature vezan uz određivanje i adaptaciju parametara sinkronog generatora s permanentnim magnetima i smanjenja estimacijske greške opservera u kliznom načinu rada uslijed magnetskog zasićenja generatora. Opisana je predložena metoda za

adaptaciju induktiviteta u poprečnoj osi temeljena na aproksimativnoj funkciji u svrhu smanjenja estimacijske greške opservera. Na kraju su prikazani simulacijski i eksperimentalni rezultati.

Poglavlje 8 - U osmom poglavlju dan je kratki osvrt na predložene metode i njihove eksperimentalne rezultate te je iznesen zaključak doktorske disertacije.

2.Pretvorba energije vjetra

2.1.Sustavi za pretvorbu energije vjetra

Sustavi za pretvorbu energije vjetra ili, pojednostavljeno, vjetroagregati koriste se za pretvorbu energije vjetra u električnu energiju. Općenito, vjetroagregat se može podijeliti na tri podsustava: mehanički, električni i upravljački. Na slici 2.1 prikazana je općenita struktura mehaničkog i električnog dijela sustava za pretvorbu energije vjetra.

2.1.1.Mehanički sustav vjetroagregata

Osnovne mehaničke dijelove vjetroagregata čine: toranj, gondola, glavčina, rotorske lopatice, pogoni za zakretanje glavčine i rotorskih lopatica, multiplikator, mehanička kočnica i senzor brzine vjetra.

Rotorske lopatice najvažniji su dio mehaničkog sustava vjetroagregata, u smislu pretvorbe energije, jer upravo one vrše pretvorbu kinetičke energije vjetra u mehaničku energiju. Aerodinamičnost rotorskih lopatica bitno utječe na faktor iskorištenja energije vjetra pa iz tog razloga projektiranje rotorskih lopatica predstavlja jedan od ključnih dijelova razvoja vjetroagregata.

Pogoni za zakret glavčine služe za praćenje smjera vjetra te s pogonom rotorskih lopatica omogućavaju optimalno iskorištenje energije vjetra.

Turbina vjetroagregata vrti se malim brzinama pri velikim momentima, dok generator (najčešće s malim brojem polova zbog konstrukcijskih ograničenja) zahtjeva znatno veću brzinu vrtnje i manji moment. Iznimku čini sinkroni generatori koji mogu omogućiti i izravan spoj

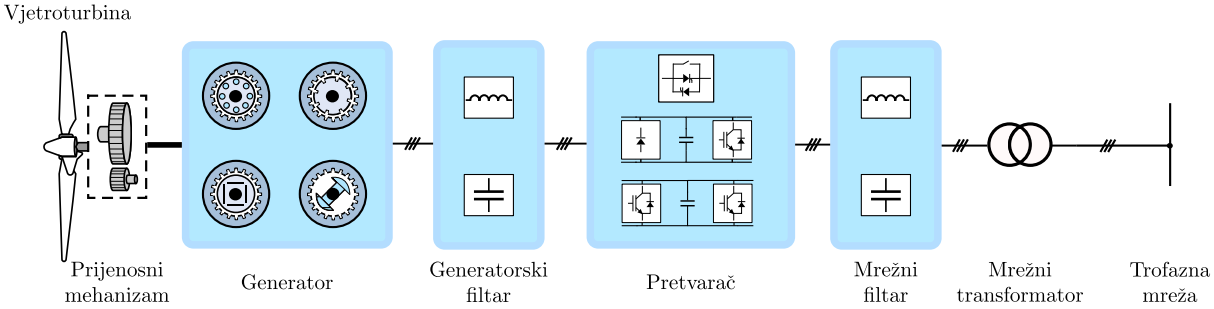

Slika 2.1: Općenita struktura sustava za pretvorbu energije vjetra

s vjetroturbinom. Zbog toga je u većinu vjetroagregata potrebno ugraditi multiplikator čiji se prijenosni omjer kreće između 1:60 i 1:120. Iako je često neophodan, kao što je rečeno u uvodu, ugradnja multiplikatora donosi i negativne posljedice poput veće cijene, povećanja buke i češćih kvarova [25]. Mehanička kočnica postavlja se na osovinu u svrhu zaustavljanja turbine tijekom kvara ili iznimno jakog vjetra, a signal senzora brzine vjetra koristi u upravljačkom sustavu.

2.1.2.Električni sustav vjetroagregata

Električni generator čini osnovni dio električnog dijela vjetroagregata, a uloga mu je pretvorba rotacijske mehaničke energije turbine u električnu energiju. Prvi vjetroagregati koristili su kavezne asinkrone generatore, dok su danas najzastupljeniji dvostruko napajani asinkroni generatori i sinkroni generatori s permanentnim magnetima. Najstariji vjetroagregati izravno su se spajali na mrežu, međutim razvojem energetske elektronike danas se vjetroagregati na električnu mrežu najčešće spajaju neizravno, putem AC-DC-AC pretvarača. Unatoč pojavi i primjeni novih topologija, osobito u području energetske elektronike (npr. višerazinski pretvarači), vjetroagregati se, s obzirom na vrstu generatora, način priključenja na električnu mrežu i radno područje brzine vrtnje, mogu podijeliti u pet konvencionalnih skupina [5] prikazanih na slici 2.2:

- **Tip 1** - konstantna brzina (±1% nazivne brzine vrtnje):
  Tip 1 je najstarija struktura vjetroagregata koja koristi kavezni asinkroni generator (engl. *Squirrel Cage Induction Generator*, SCIG) spojen na električnu mrežu preko transformatora.
- **Tip 2** - upravljanje brzinom u opsegu ±10% nazivne brzine vrtnje:
  Povećanje opsega upravljanja brzinom može se postići korištenjem klizno-kolutnog asinkronog generatora (engl. *Wounded Rotor Induction Generator*, WRIG) spojenog na mrežu preko transformatora. Upravljanje brzinom vrtnje u ovakvom sustavu postiže se promjenom iznosa rotorskog otpora čime se mijenja momentna karakteristika generatora.
- **Tip 3** - upravljanje brzinom u opsegu ±30% nazivne brzine vrtnje:
  Najzastupljenija struktura vjetroagregata koristi dvostruko napajani asinkroni generator (engl. *Doubly-Fed Induction Generator*, DFIG) čiji je stator spojen na električnu mrežu preko transformatora, a rotor preko trofaznog AC-DC-AC energetskog pretvarača i transformatora.
- **Tip 4** - upravljanje brzinom u opsegu 0 – 100% nazivne brzine vrtnje:
  Potpunu upravljivost po brzini vrtnje moguće je ostvariti spojem statora generatora na električnu mrežu putem AC-DC-AC energetskog pretvarača i transformatora. U takvim strukturama koriste se kavezni asinkroni generator te sinkroni generatori s permanentnim magnetima ili uzbudnim namotom (engl. *Permanent Magnet Synchronous Generator*, PMSG i engl. *Wounded Rotor Synchronous Generator*, WRSG).
- **Tip 5** - upravljanje brzinom u opsegu 0-100% nazivne brzine vrtnje s izravnim spojem na mrežu:

Potpuna upravljivost po brzini vrtnje može se postići i korištenjem mehaničkog pretvarača brzine i momenta. U takvim strukturama koriste se sinkroni generatori s uzbudnim namotom koji se vrti stalnom brzinom te su spojeni izravno na električnu mrežu.

Korištenje energetskih pretvarača uzrokuje pojavu viših harmonika struje i napona kao posljedicu sklapanja tranzistora (engl. *Insulated Gate Bipolar Transistor*, IGBT). U svrhu eliminacije viših harmonika koriste se različite vrste filtra, najčešće pasivnih. Filtar na generatorskoj strani pretvarača smanjuje gubitke u jezgri i namotima generatora, dok mrežni filtri osiguravaju harmonički sastav struja i napona koji zadovoljava zakonske regulative. Spoj trofazne električne mreže i energetskog pretvarača obično se izvodi preko blok transformatora.

2.1.3.Upravljački sustav vjetroagregata

U modernim vjetroagregatima (tipa 3 i 4) koji koriste energetske AC-DC-AC pretvarače, upravljački sustav može se podijeliti na generatorski i mrežni dio. Glavna zadaća generatorskog dijela upravljačkog sustava je upravljanje momentom generatora u svrhu praćenja krivulje maksimalne snage (engl. *Maximum Power Point Tracking*, MPPT), dok mrežni upravljački dio regulira tokove radne i jalove snage prema električnoj mreži. Upravljački sustavi implementirani su uz pomoć digitalnih sustava temeljenih na mikrokontrolerima, DSP-ovima (engl. *Digital Signal Processor*) ili FPGA (engl. *Field Programmable Gate Array*) čipovima.

2.2.Matematički model vjetroturbine

2.2.1.Fizikalne osnove energije vjetra

Aerodinamička pretvorba kinetičke energije vjetra u mehaničku energiju turbine i potencijalnu energiju, koja uzrokuje potisnu silu, opisuje se pomoću tri pristupa: modela aktuatorskog diska, teorije rotirajućeg diska i teorije segmenata lopatice [26, 27].

a) Model aktuatorskog diska

Modeliranje vjetroturbine kao aktuatorskog diska temelji se na promatranju rotora vjetroturbine kao homogenog diska umetnutog u struju zraka konstantne brzine kao što je prikazano na slici 2.3a. Kinetička energija stupca vjetra iznosi:

$$E_1 = \frac{1}{2} m_1 v_1^2, \tag{2.1}$$

gdje je m_1 - masa stupca vjetra, a v_1 - brzina vjetra.

Masa stupca zraka m_1 može se izraziti kao:

$$m_1 = \rho_{zr} V_1, \tag{2.2}$$

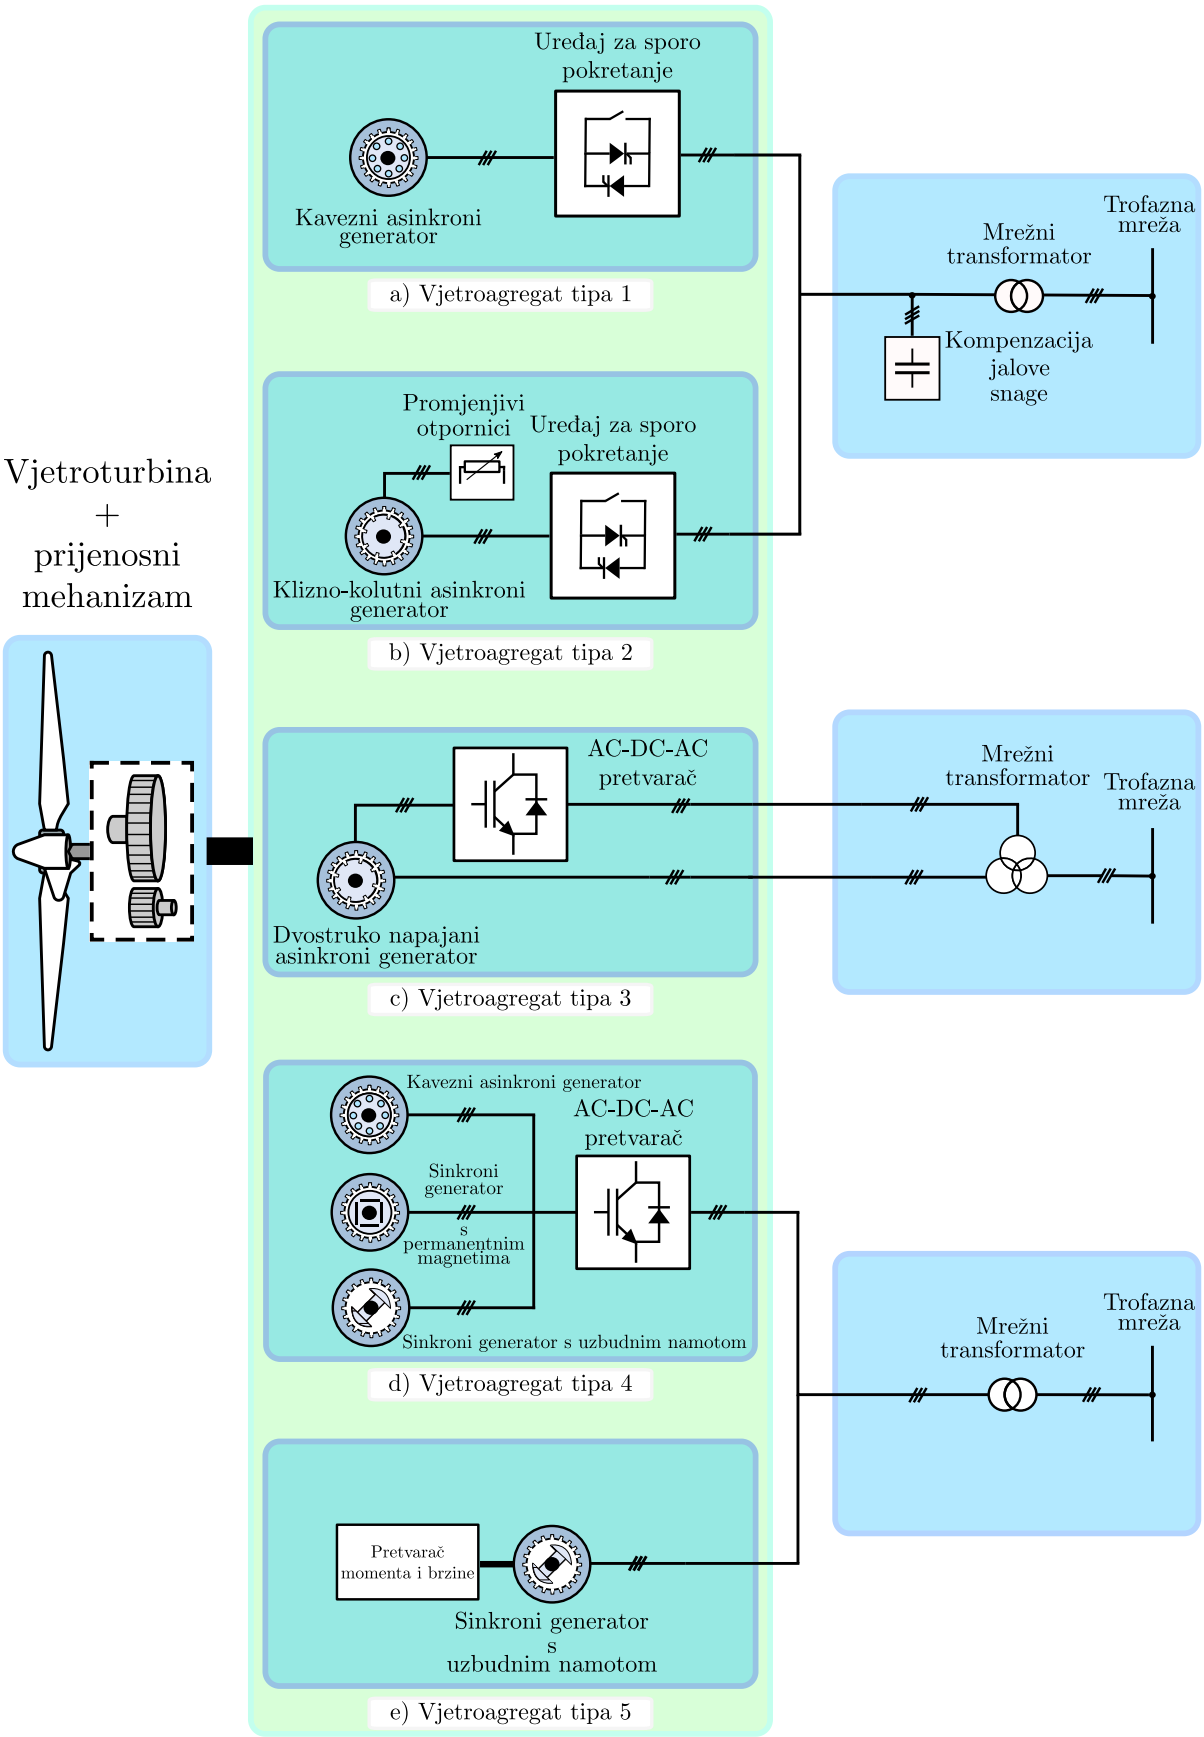

Slika 2.2: Konvencionalne vrste vjetroagregata

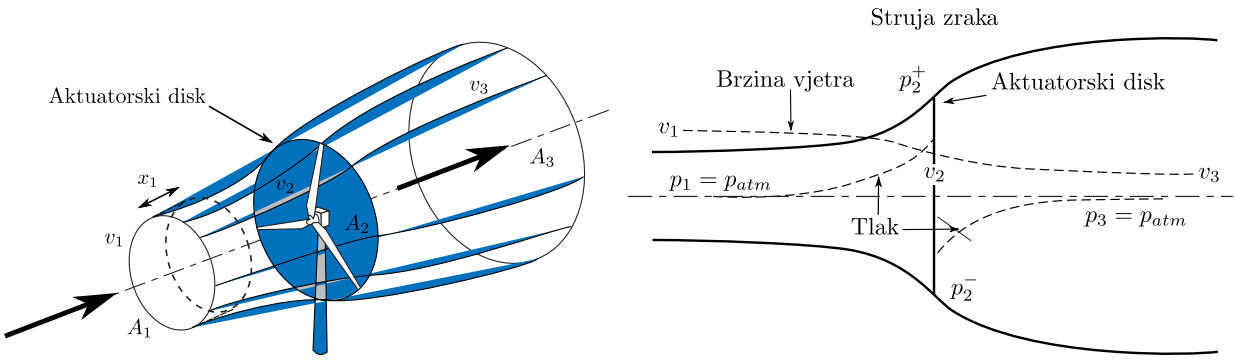

(a) Strujanje zraka preko vjetroagregata (b) Vjetroturbina kao aktuatorski disk u struji zraka

Slika 2.3: Aktuatorski disk u struji zraka [27]

gdje je ρ_{zr} - gustoća zraka, a V_1 - volumen stupca zraka.

Nadalje, volumen V_1 moguće je izraziti preko površine i visine stupca zraka kao:

$$V_1 = A_1 x_1, \tag{2.3}$$

gdje je x_1 - visina stupca zraka.

Ako se visina stupca zraka promatra kao pomak zraka unutar određenog vremena, ona se može zapisati kao:

$$x_1 = v_1 t. \tag{2.4}$$

Kombinirajući izraze (2.3) i (2.4), masa stupca zraka može se izraziti kao:

$$m_1 = \rho_{zr} A_1 v_1 t. \tag{2.5}$$

Uvrštavajući izraz za masu stupca zraka (2.5) u izraz za kinetičku energiju vjetra (2.1), uz činjenicu konstantne brzine strujanja zraka te konstantnog masenog protoka, dobiva se izraz za snagu vjetra na mjestu aktuatorskog diska [27]:

$$P_1 = \frac{1}{2} \rho_{zr} A_2 v_1^3. \tag{2.6}$$

Prema prethodnom izrazu za snagu vjetra moglo bi se zaključiti da se poznavanjem gustoće zraka, površine vjetroturbine i brzine vjetra može jednostavno odrediti i sama snaga vjetroturbine. Međutim, vjetroturbina u obliku homogenog diska preuzima samo dio kinetičke energije vjetra u vidu potencijalne energije razlike tlakova neposredno ispred i iza diska kao što je prikazano na slici 2.3b. Kao posljedica predaje dijela energije vjetroturbini dolazi do pada brzine vjetra iza homogenog diska. S obzirom na to da je masa zraka prije i poslije vjetroturbine nepromijenjena, a brzina zraka se smanjuje, dolazi i do povećanja volumena stupca zraka iza vjetroturbine.

Snaga koju vjetroturbina preuzima od vjetra može se izraziti kao:

$$P_2 = F_2 v_2, \tag{2.7}$$

gdje je F_2 - sila koja djeluje na homogeni disk, a v_2 - brzina vjetra na aktuatorskom disku.

Brzina v_2 može se definirati pomoću koeficijenta nastrujavanja koji opisuje spomenuti pad brzine vjetra zbog utjecaja aktuatorskog diska na strujanje zraka:

$$v_2 = (1 - a)v_1, \tag{2.8}$$

gdje je a - koeficijent nastrujavanja.

Izraz za silu F_2 koja djeluje na homogeni disk moguće je izraziti preko brzine vjetra ispred aktuatorskog diska koristeći zakon o očuvanju količine gibanja i Bernoullijevu jednadžbu te uz pretpostavku konstantnog volumnog protoka zraka u strujnoj cijevi te očuvanja mase zraka u strujnoj cijevi [26, 27]:

$$F_2 = \frac{1}{2}\left[1 - (1 - 2a)^2\right]\rho_{zr} A_2 v_1^2. \tag{2.9}$$

Iz (2.9) slijedi da snaga koju homogeni disk preuzima od vjetra, izražena preko brzine vjetra ispred diska, glasi:

$$P_2 = F_2 v_2 = \frac{1}{2} 4a(1 - a)^2 \rho_{zr} A_2 v_1^3. \tag{2.10}$$

Dijeljenjem (2.10) i (2.6) dobiva se izraz za koeficijent snage:

$$C_P = \frac{P_2}{P_1} = 4a(1 - a)^2. \tag{2.11}$$

Kombinacijom izraza (2.10) i (2.11) moguće je izraziti snagu vjetroturbine preko koeficijenta snage C_P kao:

$$P_2 = \frac{1}{2} C_P \rho_{zr} A_2 v_1^3. \tag{2.12}$$

Faktor snage C_P ukazuje na činjenicu da vjetroturbina ne može preuzeti cjelokupnu snagu vjetra. Maksimum funkcije (2.11) dobiva se za faktor nastrujavanja $a = 1/3$ i tada koeficijent snage iznosi $C_P = 0,593$ te se naziva Betzov limit. Betzov limit predstavlja teoretski maksimum iskorištenje energije vjetra od strane vjetroturbine.

b) Model rotirajućeg diska

Promatranjem vjetroturbine kao homogenog diska unutar struje zraka moguće je modelirati pretvorbu kinetičke energije vjetra u potencijalnu energiju koja može obaviti rad, no sam način obavljanja tog rada nije moguće opisati. Iz tog razloga, vjetroturbinu je potrebno promatrati ne samo kao statični homogeni disk, već kao rotirajući disk u struji zraka, uz pretpostavku beskonačnog broja lopatica. Glavna ideja opisa vjetroturbine kao rotirajućeg diska je promatranje

čestica zraka koje struje između lopatica koje zakreću čestice zraka u smjeru suprotnom od smjera vrtnje diska.

Na temelju očuvanja kutne količine gibanja i prema [26], iz pristupa vjetroturbini kao rotirajućem disku može se izvesti koeficijent koji predstavlja omjer obodne brzine rotirajućeg diska i brzine vjetra ispred rotirajućeg diska (engl. *Tip Speed Ratio*, TSR):

$$\lambda = \frac{\omega R}{v_1}, \tag{2.13}$$

gdje je R - radijus rotirajućeg diska.

Omjer λ vrlo je bitan faktor pri optimiranju iskorištenje energije vjetra budući da snaga vjetroturbine pri određenoj brzini vjetra može biti različita ovisno o njenoj brzini vrtnje [27].

c) Teorija segmenata lopatica

Dva prethodno spomenuta modela pretvorbe energije vjetra tretiraju rotor vjetroturbine kao homogeni disk i ne uzimaju u obzir postojanje pojedinačnih lopatica niti pojave koje se događaju na njima. Iako navedeni modeli rezultiraju nekim temeljnim relacijama koje određuju rad vjetroagregata, kao što su koeficijent snage C_P i koeficijent λ, oni nisu potpuni. Kako bi se dobila potpuna fizikalna slika pretvorbe energije vjetra u mehaničku rotacijsku energiju vjetroturbine potrebno je definirati sile koje djeluju na lopatice vjetroturbine koje se nalaze u struji zraka. Te sile zovu se potisna sila i sila otpora i pojavljuju se uslijed razlike tlakova između gornje i donje strane lopatica uzrokovane strujanjem vjetra preko lopatica karakterističnog aerodinamičnog oblika. Rastavom i analizom tih sila dobiva se izraz za zakretnu silu koja je odgovorna za razvijeni moment vjetroturbine, a koja ovisi o kutu nastrujavanja [26, 27]. Glavne komponente kuta nastrujavanja čine napadni kut vjetra α i kut zakreta lopatica vjetroturbine β.

Kombinacijom gornja tri pristupa dobiva se potpuni model vjetroturbine koji sadrži implicitne nelinearne jednadžbe koje, međutim, nisu prikladne za projektiranje upravljačkog sustava. Kako bi se izbjegao taj problem, implicitne formule mogu se koristiti u iterativnom postupku te je tako moguće izračunati ovisnosti momenta i snage vjetroturbine o koeficijentu λ i kutu zakreta lopatica β, $M_t = f(\lambda, \beta)$, odnosno $P_t = P_2 = f(\lambda, \beta)$. Dijeljenjem izraza za snagu vjetroturbine (2.12) s izrazom za snagu vjetra $P_{vj} = P_1 = f(\lambda, \beta)$ iz (2.6) mogu se dobiti krivulje ovisnosti koeficijenta snage C_P o omjeru λ uz kut zakreta lopatica β kao slobodnim parametrom kao što je prikazano na slici 2.4.

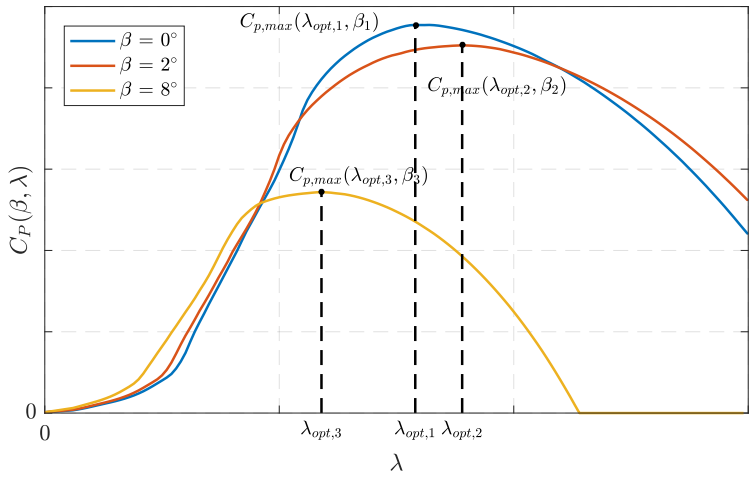

Slika 2.4: Koeficijent snage C_P u ovisnosti o koeficijentu λ i kutu zakreta lopatica β

2.2.2.Dinamička jednadžba vjetroturbine

Dinamika rotora vjetroturbine, uz zanemarenje sile trenja, može se opisati II. Newtonovim zakonom za rotacijska gibanja i glasi:

$$J_t\dot{\omega} = M_t - M_g, \tag{2.14}$$

gdje je gdje je J_t - moment inercije rotora, ω - kutna brzina rotora vjetroturbine i generatora na istoj osovini, M_t - moment vjetroturbine, a M_g - moment generatora.

Jednadžba momenta vjetroturbine izvedena je dijeljenjem izraza za snagu vjetroturbine (2.12) s kutnom brzinom vjetroturbine i glasi:

$$M_t = \frac{1}{2}\rho_{zr}R^3\pi C_Q(\lambda, \beta)v_1^2, \tag{2.15}$$

gdje je $C_Q(\lambda, \beta) = \frac{C_P(\lambda,\beta)}{\lambda}$.

2.3.Upravljanje vjetroturbinom

Kako bi se ostvarila optimalna pretvorba energije vjetra u mehaničku energiju vjetroturbine potrebno je upotrijebiti upravljački algoritam koji će omogućiti maksimalno iskorištenje energije vjetra. Budući da razvijeni moment vjetroturbine (2.15) ovisi o kutu udara vjetra na lopatice vjetroturbine, upravljački algoritmi vjetroagregata temelje se na modifikaciji napadnog kuta vjetra. S obzirom na način modifikacije napadnog kuta α, metode upravljanja vjetroagregatom mogu se podijeliti na pasivno i aktivno upravljanje.

Pasivna regulacija

Pasivno upravljanje vjetroagregatom prvi je pristup korišten za ograničenje snage vjetroagregata tipa 1 koji karakterizira stalna brzina vrtnje definirana frekvencijom električne mreže. Zbog konstantne obodne brzine vjetroturbine, povećanjem brzine vjetra dolazi do povećanja napadnog kuta i do porasta momenta vjetroturbine. Uz pretpostavljenu stalnu brzinu vrtnje ω, razvijena snaga vjetroturbine P_t ovisi o momentu vjetroturbine M_t. Razvijeni moment vjetroturbine M_t raste s brzinom vjetra do maksimalnog napadnog kuta α_{max}, a pri brzini vjetra za koju napadni kut premašuje vrijednost maksimalnog napadnog kuta α_{max}, vrijednost momenta M_t se smanjuje. Snaga P_t koju vjetroturbina razvije pri konstantnoj brzini vrtnje prati promjene momenta M_t kako je prikazano 2.5 [27].

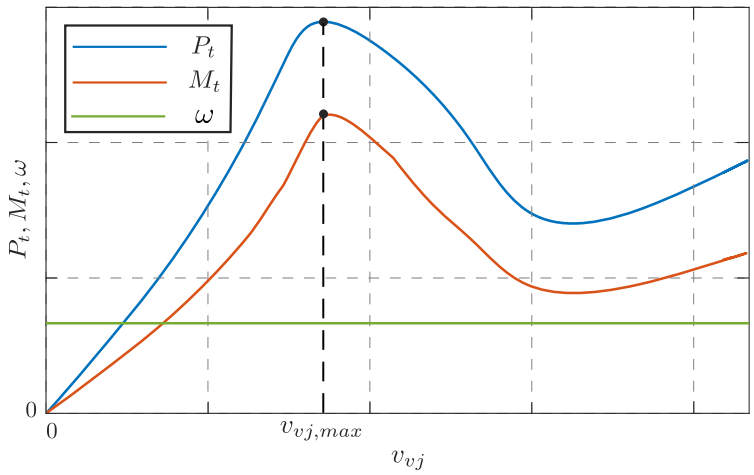

Slika 2.5: Statička karakteristika vjetroturbine pri pasivnoj regulaciji

Aktivna regulacija

U modernim vjetroagregatima aktivna regulacija standardni je postupak upravljanja. Za razliku od pasivne regulacije, u aktivnoj regulaciji modifikacija napadnog kuta vjetra izvedena je promjenom kuta zakreta lopatica β. Aktivna regulacija vjetroagregata uobičajeno se koristi u radnom području iznad nazivne brzine vjetra. Nazivna brzina vjetra $v_{vj,n}$ definira se kao najmanja brzina vjetra za koju vjetroagregat razvija nazivni moment $M_{t,n}$, odnosno nazivnu snagu $P_{t,n}$.

Budući da su vjetroagregati projektirani tako da nazivni moment $M_{t,n}$ i snagu $P_{t,n}$ postižu upravo pri nazivnoj brzini vjetra $v_{vj,n}$, pri brzinama vjetra većima od nazivne, $v_{vj} > v_{vj,n}$, potrebno je osigurati nazivnu brzinu vrtnje ω_n. Ukoliko bi pri nazivnoj brzini vrtnje ω_n brzina vjetra porasla na vrijednost $v_{vj} > v_{vj,n}$, moment i snaga vjetroturbine postigli bi vrijednost veću od nazivne. Međutim, prikladno povećanje kuta zakreta β u trenutku postizanja nazivne radne točke vjetroagregata ($P_t = P_{t,n}$, $M_t = M_{t,n}$, $\omega = \omega_n$) dovodi do smanjenja napadnog kuta α, a time i smanjenja momenta i snage vjetroturbine. Ovakav način upravljanja vjetroagregata u

području $v_{vj} > v_{vj,n}$ omogućava održavanje vjetroagregata u nazivnoj radnoj točki pri brzinama vjetra većima od nazivne [27].

S druge strane, u radnim točkama ispod nazivne brzine vjetra, $v_{vj} < v_{vj,n}$, upravljanje vjetroagregatom temelji se na optimalnom iskorištenju energije vjetra.

2.3.1.Upravljanje vjetroturbinom ispod nazivne brzine vrtnje

U radnom području vjetroagregata ispod nazivne brzine vjetra, $v_{vj} < v_{vj,n}$, energija vjetra nije dovoljna da vjetroagregat postigne nazivnu radnu točku. Iz tog razloga, cilj upravljanja vjetroagregatom u području ispod nazivne brzine vjetra je postići radnu točku u kojoj će iskorištenje energije vjetra biti maksimalno (MPPT krivulja). Kako bi se postiglo maksimalno iskorištenje energije vjetra, koeficijent snage C_P u određenoj radnoj točki mora postići maksimalnu vrijednost $C_{P,max}$. Takva radna točka naziva se optimalnom radnom točkom. Maksimum funkcije koeficijenta snage $C_P = f(\lambda, \beta)$ za neki kut zakreta lopatica β jednoznačno je određen omjerom λ. Omjer λ za koji se postiže maksimalni koeficijent snage $C_{P,max}$ naziva se optimalni omjer i označava se s λ_{opt} (slika 2.4). Iz toga slijedi da se upravljanje vjetroagregatom u području ispod nazivne brzine vjetra svodi na održavanju omjera λ na optimalnoj vrijednosti, $\lambda = \lambda_{opt}$. Budući da su moderni vjetroagregati uglavnom spojeni na mrežu preko AC-DC-AC pretvarača, moguće je postići upravljanje vjetroagregata u širokom raspona brzina ω što omogućava modifikaciju brzine vrtnje vjetroturbine na način da se optimalni koeficijent λ_{opt} održava konstantnim pri brzinama vjetra u području $v_{vj} < v_{vj,n}$.

Brzina vrtnje ω za koju će se pri određenoj brzini vjetra v_{vj1} i nekom fiksnom kutu zakreta β postići maksimalna vrijednost koeficijenta snage $C_{P,max}(\lambda, \beta)$ glasi:

$$\omega = \frac{\lambda_{opt} v_{vj1}}{R} = \omega_{opt}. \tag{2.16}$$

Uvrštavanjem (2.16) u momentnu jednadžbu vjetroturbine (2.15) dobiva se vrijednost momenta M_t koji vjetroturbina treba razvijati da bi se ostavarila optimalna brzina vrtnje ω_{opt}:

$$M_t = \underbrace{\frac{1}{2} \frac{\rho_{zr} R^5 \pi C_{P,max}(\lambda, \beta)}{\lambda_{opt}^3}}_{K_{opt}} \omega_{opt}^2 = K_{opt} \omega_{opt}^2. \tag{2.17}$$

Izraz (2.17) vrijedi za bilo koju brzinu vrtnje ω pa se može zapisati:

$$M_{t,opt} = K_{opt} \omega^2. \tag{2.18}$$

Na slici 2.6 prikazano je načelo upravljanja momentom generatora ispod nazivne brzine vjetra $v_{vj,n}$. Uz pretpostavku kuta zakreta lopatica $\beta = 0°$, optimalni omjer λ_{opt} jednoznačno je određen

kao što je prikazano na slici 2.6a. Na slikama 2.6b i 2.6c prikazani su profili aerodinamičkog momenta M_{vj} i krivulja optimalnog momenta $M_{t,opt}$. Sjecište krivulja aerodinamičkog momenta M_{vj} i krivulje optimalnog momenta vjetroturbine M_t predstavlja optimalnu radnu točku u kojoj se postiže optimalni omjer λ_{opt}, odnosno ostvaruje se maksimalni iznos koeficijenta snage $C_{P,max}$ čime se osigurava maksimalno iskorištenje energije vjetra.

Za postizanje optimalnog omjera λ_{opt} pri nekoj brzini vjetra, primjerice v_{vj6}, potrebno je ostvariti moment vjetroturbine M_t, odnosno generatora M_g iz (2.17) koji će u stacionarnom stanju osigurati optimalnu brzinu vrtnje vjetroturbine ω_{opt}. Ta radna točka označena je na slikama 2.6a, 2.6b i 2.6c s ①.

Budući da je vjetar stohastička pojava, brzina vjetra je promjenjiva. Kada u nekom trenutku brzina vjetra poraste na iznos $v_{vj7} > v_{vj6}$ porast će i aerodinamički moment $M = M_{vj7}$ te će se vjetroagregat naći u novoj radnoj točki ② kako je označeno na slici 2.6b. Porastom aerodinamičkog momenta vjetroturbina će ubrzavati do radne točke ①′ u kojoj se aerodinamički moment M_{vj7} i moment vjetroturbine M_t izjednačuju. Nova radna točka je označena s ①′ kako bi se istaknulo da se vjetroagregat nakon prijelazne pojave ponovno našao u optimalnoj radnoj točki u kojoj vrijedi $\lambda = \lambda_{opt}$ i $C_P = C_{P,max}$ kao što je bio slučaj u prethodnoj radnoj točki ①.

U slučaju smanjenja brzine vjetra na iznos $v_{vj5} < v_{vj6}$ aerodinamički moment $M = M_{vj5}$ će se smanjiti te će se vjetroagregat naći u radnoj točki ③ kako je prikazano na slici 2.6c. Budući da je u radnoj točki ③ moment vjetroturbine M_t veći od aerodinamičkog momenta M_{vj5}, vjetroturbina počinje usporavati. Usporavanje vjetroturbine traje do trenutka izjednačavanja momenata M_{vj5} i M_t. Nakon završetka prijelazne pojave i ulaska u stacionarno stanje, vjetroagregat se ponovno nalazi u optimalnoj radnoj točki ①″ u kojoj se ostvaruje maksimalno iskorištenje energije vjetra pri $\lambda = \lambda_{opt}$ i $C_P = C_{P,max}$.

Analizom promjene brzine vjetra v_{vj} u odnosu na trenutnu optimalnu radnu točku očito je da povećanje ili smanjenje brzine vjetra v_{vj} ne uzrokuje nestabilnost vjetroagregata, već se upravljanjem momentom vjetroturbine, odnosno generatora prema (2.17) u stacionarnom stanju postiže nova optimalna i stabilna radna točka.

Na slici 2.7 prikazana je struktura optimalnog upravljanja momentom vjetroagregata.

2.3.2.Upravljanje vjetroturbinom iznad nazivne brzine vrtnje

Upravljanje vjetroturbinom iznad nazivne brzine vjetra vrši se primjenom ranije opisane aktivne regulacije pomoću zakretanja lopatica. Na slici 2.8 prikazane su statičke karakteristike brzine vrtnje, momenta, snage i kuta zakreta lopatica vjetroturbine u području ispod i iznad nazivne brzine vjetra. Iz prikazanih karakteristika očito je da se do nazivne brzine vjetra kut zakreta β drži na konstantnom iznosu, u ovom slučaju 0°, te da se snagom vjetroturbine upravlja prema krivulji optimalnog momenta (Sl. 2.6). Pri prelasku nazivne brzine vjetra uključuje se sustav za zakretanje lopatica koji omogućuje razvijanje nazivne snage vjetroturbine i u radnom području

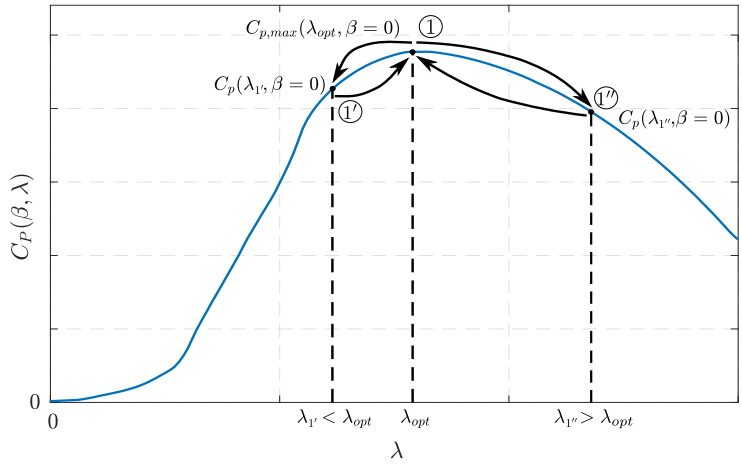

(a) Promjena koeficijenta snage C_P

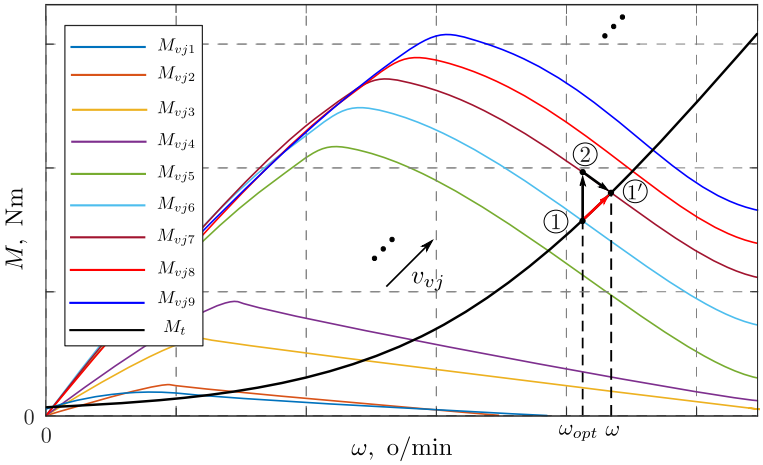

(b) Postizanje optimalnog momenta $M_{t,opt}$ pri povećanju brzine vjetra

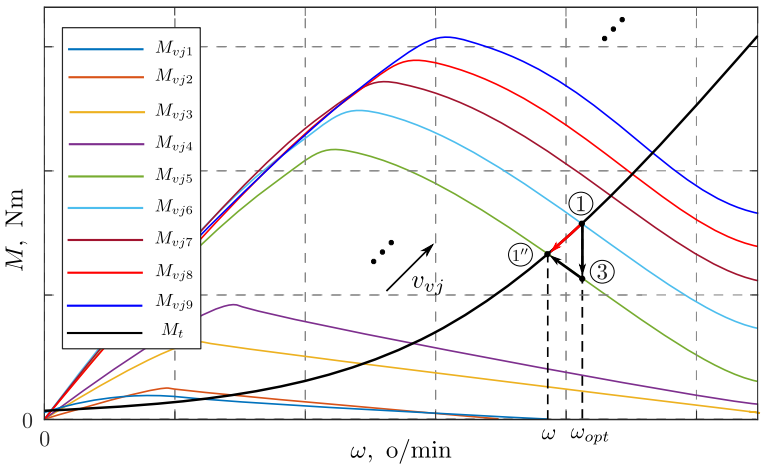

(c) Postizanje optimalnog momenta $M_{t,opt}$ pri smanjenju brzine vjetra

Slika 2.6: Optimalno upravljanje vjetroagregata ispod nazivne brzine vjetra održavanjem optimalnog iznosa koeficijenta $\lambda = \lambda_{opt}$

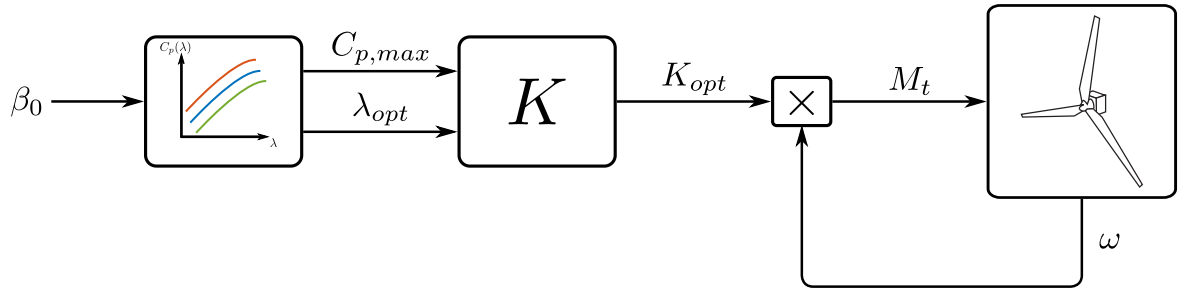

Slika 2.7: Struktura optimalnog upravljanja momentom vjetroagregata [27]

iznad nazivne brzine vjetra. Ukoliko brzina vjetra prijeđe maksimalnu dozvoljenu vrijednost $v_{vj,max}$, lopatice se postavljaju na kut 90° što uzrokuje prestanak razvijanja momenta te dovodi do zaustavljanja vjetroturbine.

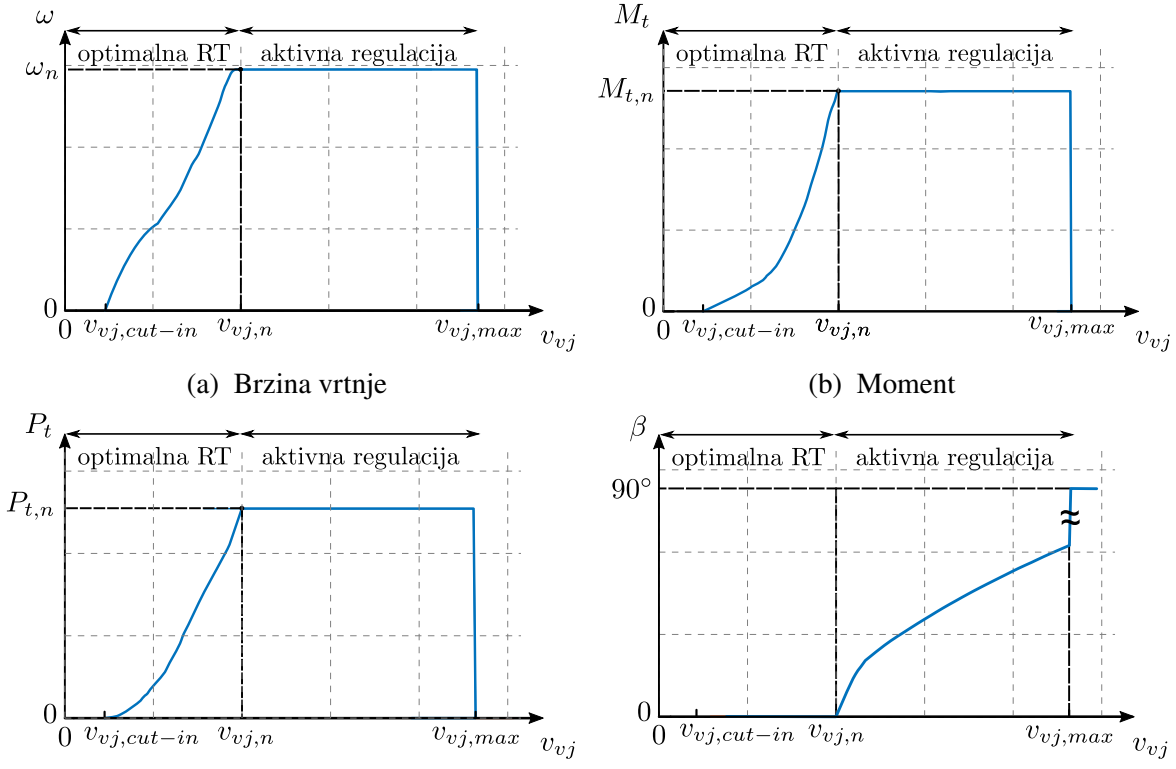

(a) Brzina vrtnje

(b) Moment

(c) Snaga

(d) Kut zakreta lopatica

Slika 2.8: Statičke karakteristike vjetroturbine

2.4.Matematički model PMSG-a

Električni strojevi su uređaji koji vrše pretvorbu električne energije u mehaničku i obrnuto. Kod pretvorbe električne energije u mehaničku govori se o električnim motorima, dok se u suprotnom

radi o električnim generatorima. Prema tome, PMSG je električni stroj koji radi u generatorskom režimu rada te pripada skupini trofaznih izmjeničnih električnih strojeva.

Specifičnost PMSG-a u odnosu na druge izmjenične električne strojeve predstavljaju permanentni magneti koji su smješteni na njegovom rotoru. Ovisno o položaju rotorskih magneta razlikuju se sinkroni generatori s površinskim permanentnim magnetima (engl. *Surface Permanent Magnet Generator*, SPMSG) i sinkroni generatori s unutarnjim permanentnim magnetima (engl. *Interior Permanent Magnet Generator*, IPMSG). Primjer presjeka rotora četveropolnog SPMSG-a i IPMSG-a prikazani su na slici 2.9. Osim presjeka, na slici je vidljiv dq koordinatni sustav koji se uobičajeno postavlja tako da mu se uzdužna, odnosno d-os, poklapa s osi magneta, dok je poprečna, odnosno q-os, pomaknuta za električni kut $\pi/2$ *. Iz prikazanih presjeka vidljiva je glavna razlika između SPMSG-a i IPMSG-a koja se očituje u tome da su kod SPMSG-a magneti jednoliko raspoređeni po obodu rotora, dok je raspodjela magneta u unutrašnjosti IPMSG-a nejednolika. Zbog jednolike raspodjele magneta, uzdužna i poprečna os SPMSG-a magnetski su simetrične, dok kod IPMSG-a to nije slučaj. Magnetska simetrija kod SPMSG-a rezultira jednakim uzdužnim i poprečnim induktivitetom, dok se kod IPMSG-a uzdužni i poprečni induktivitet razlikuju. Posljedica toga jesu različiti matematički modeli SPMSG-a i IPMSG-a. Matematički model IPMSG-a složeniji je te predstavlja poopćeni model PMSG-a budući da se iz modela IPMSG-a, uz pretpostavku jednakih induktiviteta u uzdužnoj i poprečnoj osi, lako izvodi model SPMSG-a. Iz tog se razloga u nastavku disertacije pod matematičkim modelom PMSG-a podrazumijeva matematički model IPMSG-a.

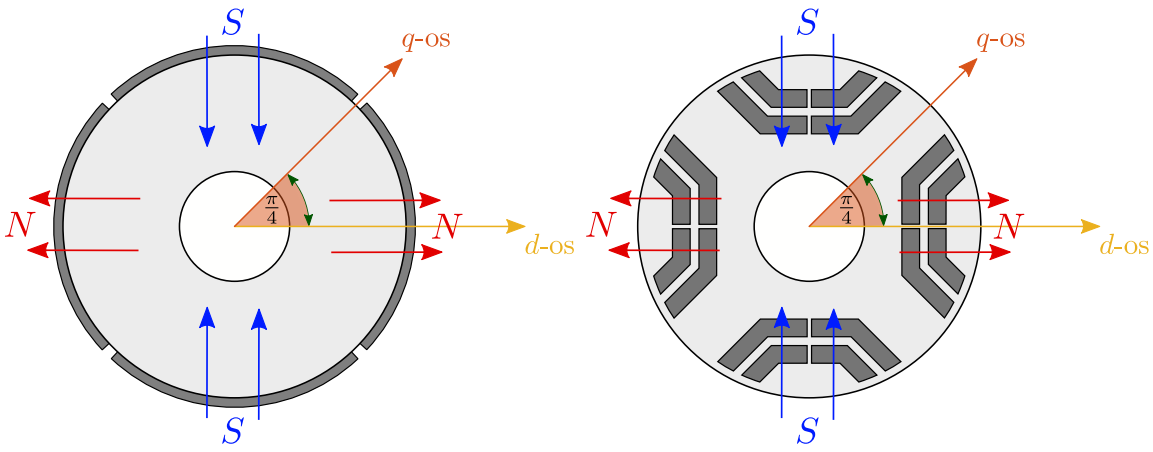

(a) Poprečni presjek rotora SPMSG-a (b) Poprečni presjek rotora IPMSG-a

Slika 2.9: Poprečni presjeci rotora četveropolnog PMSG-a

Osim specifičnog rotora, drugi ključni konstrukcijski dio PMSG-a je stator koji se bitno ne razlikuje od statora drugih trofaznih izmjeničnih strojeva poput asinkronog ili sinkronog

*Pri razmatranju matematičkih modela PMSG-a u obzir se, umjesto mehaničkog, uzima električni kut. Električni kut računa se množenjem mehaničkog kuta s brojem pari polova. U slučaju stroja s četiri pola, odnosno dva para polova, mehanički kut između uzdužne i poprečne osi iznosi $\pi/4$, a električni $\pi/2$. Kao poseban slučaj može se izdvojiti stroj s dva pola, odnosno jednim parom polova, kada su mehanički i električni kut jednaki.

reluktantnog stroja. Trofazni statorski namot raspodijeljen je po obodu statora tako da su osi pojedinih faza međusobno prostorno razmaknute za električni kut $2\pi/3$, dok je namot napajan simetričnim trofaznim izmjeničnim naponom. Na slici 2.10 prikazan je stator PMSG-a s prikazanim osima pojedinih faza zajedno s rotorom s unutarnjim magnetima.

Za razvoj i implementaciju upravljačkog algoritma nužno je poznavati prikladan i točan matematički model PMSG-a. Budući da se u vjetroagregatu tipa 4 PMSG-om upravlja tako da mu se putem AC-DC-AC pretvarača na statorski namot narine trofazni napon određene amplitude i frekvencije, model PMSG-a koji se nameće kao logičan izbor jest onaj u trofaznom abc sustavu. Međutim, s obzirom da je cilj upravljanja PMSG-om u vjetroagregatu ostvariti potreban moment kojim će se osigurati željeni tok energije prema EES-u, model PMSG-a u trofaznom abc sustavu, zbog svoje složenosti i nelinearnosti, nije prikladan za sintezu sustava upravljanja. Kako bi se ovaj problem riješio, potrebno je napone, struje i magnetske tokove statorskog namota prikazati pomoću rotirajućih prostornih vektora u mirujućem troosnom abc koordinatnom sustavu te ih zatim transformirati u rotirajući dq koordinatni sustav vezan uz rotor PMSG-a, odnosno čija se d-os poklapa s osi rotorskih magneta. U svrhu ove transformacije dodatno je definiran i mirujući dvoosni $\alpha\beta$ koordinatni sustav čija se α-os poklapa s osi faze a, dok je β-os okomita na nju. Uz to, definiran je još i estimirani rotirajući $\gamma\delta$ koordinatni sustav koji, kao i dq sustav vezan za rotor PMSG-a, no estimirana γ-os mu se ne poklapa s osi magneta. Svi navedeni koordinatni sustavi prikazani na poprečnom presjeku PMSG-a sa slike 2.10. Definirani koordinatni sustavi u nastavku se koriste za modeliranje PMSG-a, odnosno njegove upravljačke strukture.

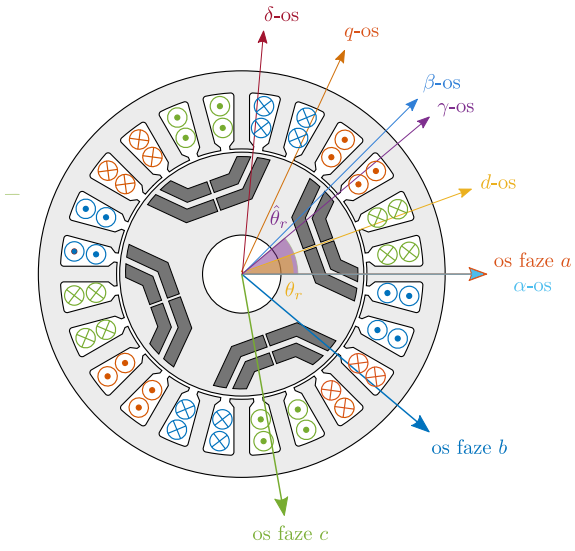

Slika 2.10: Koordinatni sustavi četveropolnog PMSG-a

Također, pri modeliranju PMSG-a u obzir je uzeto nekoliko pretpostavki, odnosno zanemarenja poput [28]:

1. pretpostavke simetričnog trofaznog napajanja (nepostojanje nul-komponente napona i struje),

2.zanemarenja viših harmonika statorskog napona uzrokovanih energetskim pretvaračem,
3. zanemarenja viših harmonika magnetskog toka, odnosno induciranog napona, uzrokovanih geometrijom statora i njegovih utora,
4. zanemarenja utjecaja magnetskog zasićenja i promjene temperature na parametre modela (induktivitete, otpor, tok rotorskih magneta) i
5.zanemarenja gubitaka u željezu PMSG-a.

2.4.1.Prikaz trofaznih veličina preko prostornog vektora

Kada se statorskim namotom čije su faze međusobno razmaknute za električni kut $2\pi/3$ narine simetričan trofazni sustav $\boldsymbol{f}_{abc}$ definiran kao:

$$\boldsymbol{f}_{abc} = \begin{bmatrix} f_a \\ f_b \\ f_c \end{bmatrix} = \begin{bmatrix} F_m \cos(\omega t) \\ F_m \cos\left(\omega t - \frac{2\pi}{3}\right) \\ F_m \cos\left(\omega t - \frac{4\pi}{3}\right) \end{bmatrix}, \tag{2.19}$$

gdje f predstavlja fazni napon, struju ili magnetski tok, u prostoru će se formirati rotirajući vektor [29]:

$$\mathbf{f} = \frac{2}{3}(f_a + \mathbf{a} f_b + \mathbf{a}^2 f_c) = F_m e^{\mathbf{j}\omega t}, \tag{2.20}$$

gdje su f_a, f_b i f_c - trenutne vrijednosti faznih veličina, $\mathbf{a} = e^{\mathbf{j}\frac{2\pi}{3}}$ - vektor u smjeru osi b, $\mathbf{a}^2 = e^{\mathbf{j}\frac{4\pi}{3}}$ - vektor u smjeru osi c, F_m - amplituda fazne veličine, $e^{\mathbf{j}\omega t} = \cos(\omega t) + \mathbf{j}\sin(\omega t)$ - Eulerov operator, a ω - kružna frekvencija.

Osim formiranja rotirajućeg prostornog vektora iz trenutnih faznih vrijednosti pojedine faze, moguć je i obrnut postupak, odnosno proračun trenutne vrijednosti faznih veličina iz projekcije prostornog vektora $\mathbf{f}$ na os odgovarajućeg namota [29]:

$$f_a = \mathrm{Re}(\mathbf{f}), \tag{2.21}$$

$$f_b = \mathrm{Re}(\mathbf{a}^2\mathbf{f}), \tag{2.22}$$

$$f_c = \mathrm{Re}(\mathbf{a}\mathbf{f}). \tag{2.23}$$

Postupak formiranja prostornog vektora $\mathbf{f}$ prikazan je na slici 2.11. Na slikama 2.11b - 2.11e prikazan je trofazni sustav čije su osi prostorno pomaknute za električni kut $2\pi/3$. Budući da su svakoj fazi namota narinuti sinusni valni oblici, u osi svake faze pojavljuje se mirujući pulsirajući vektor koji predstavlja trenutnu vrijednost pripadajućeg sinusnog valnog oblika pojedine faze sa slike 2.11a. Kako što je vidljivo iz izraza (2.19) te slike 2.11a, sinusni valni oblici narinuti svakoj fazi vremenski su pomaknuti za električni kut $2\pi/3$ što znači da se amplitude pulsirajućih vektora u osima a, b i c u svakom trenutku međusobno razlikuju. Vektorskim zbrojem ovakvih

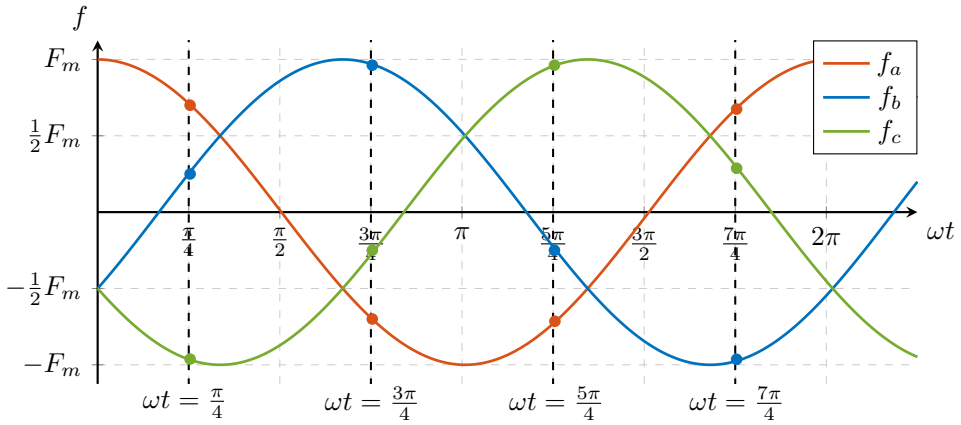

(a) Trofazni simetrični sustav

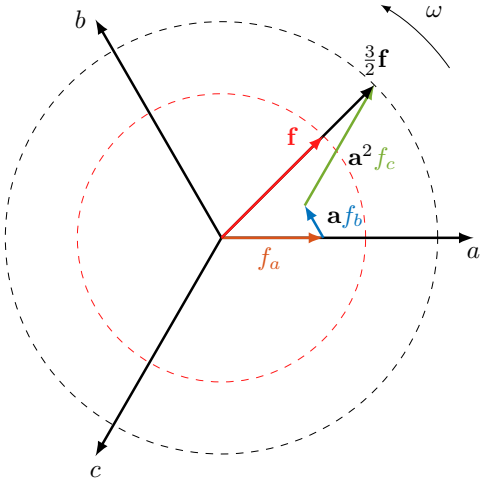

(b) $\omega t = \frac{\pi}{4}$

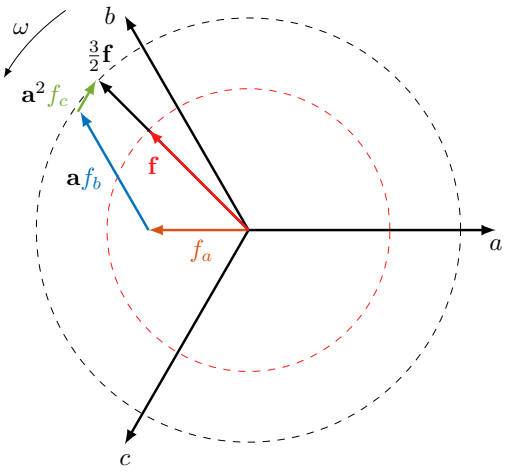

(c) $\omega t = \frac{3\pi}{4}$

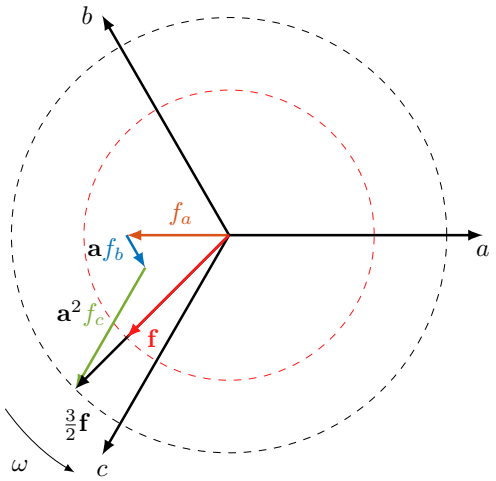

(d) $\omega t = \frac{5\pi}{4}$

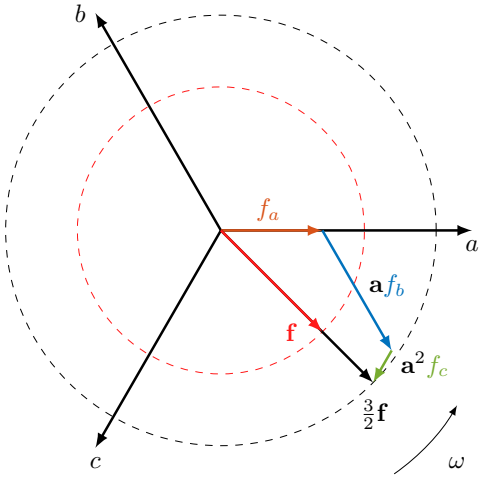

(e) $\omega t = \frac{7\pi}{4}$

Slika 2.11: Formiranje rotirajućeg prostornog vektora

prostorno razmaknutih mirujućih pulsirajućih vektora uzrokovanih vremenski razmaknutim sinusnim valnim oblicima dobiva se rezultantni prostorni vektor koji rotira u prostoru kružnom brzinom koja je jednaka kružnoj brzini narinutog sinusnog sustava (2.19). Na slikama 2.11b - 2.11e prikazan je postupak formiranja prostornog rotirajućeg vektora vektorskim zbrajanjem mirujućih pulsirajućih vektora pojedine faze za četiri odabrana trenutka. Sa slika je očito da je amplituda formiranog rezultantnog rotirajućeg vektora za 3/2 veća od amplitude pulsirajućih vektora. Prema tome, kako bi se amplituda rotirajućeg vektora odgovarala amplitudi pulsirajućih vektora potrebno je rotirajući vektor pomnožiti s faktorom 2/3 kao što je učinjeno u (2.20).

2.4.2.Transformacije koordinata

Clarkina transformacija ($abc \rightarrow \alpha\beta$)

Definiranjem dvoosnog mirujućeg $\alpha\beta$ koordinatnog sustava u kojem se realna os α poklapa s osi faze a, a imaginarna os β je okomita na nju (slika 2.12a), prostorni vektor $\mathbf{f}$ može se zapisati kao zbroj α i β komponente:

$$\mathbf{f} = f_\alpha + \mathbf{j} f_\beta. \tag{2.24}$$

Komponente f_α i f_β sinusne su veličine koje predstavljaju projekcije rotirajućeg prostornog vektora na α, odnosno β-os kao što je prikazano na slici 2.12.

Vektor trenutnih vrijednosti prostornog vektora u α i β-osi, $\boldsymbol{f}_{\alpha\beta} = [f_\alpha \; f_\beta]^{\mathrm{T}}$, može se odrediti iz trenutnih vrijednosti faznih veličina simetričnog abc sustava primjenom Clarkine transformacije koja se definira kao [30]:

$$\boldsymbol{f}_{\alpha\beta} = \mathbf{C}\boldsymbol{f}_{abc}, \tag{2.25}$$

gdje je

$$\mathbf{C} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \frac{1}{\sqrt{3}} & -\frac{1}{\sqrt{3}} \end{bmatrix} \tag{2.26}$$

matrica Clarkine transformacije.

Primjenom inverzne Clarkine transformacije, izvodi se obrnut postupak, odnosno iz trenutnih vrijednosti komponenata f_α i f_β računaju se trenutne vrijednosti faznih veličina u abc sustavu:

$$\boldsymbol{f}_{abc} = \mathbf{C}^{-1}\boldsymbol{f}_{\alpha\beta}, \tag{2.27}$$

gdje je

$$\mathbf{C}^{-1} = \begin{bmatrix} 1 & 0 \\ -\frac{1}{2} & \frac{\sqrt{3}}{2} \\ -\frac{1}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \tag{2.28}$$

matrica inverzne Clarkine transformacije.

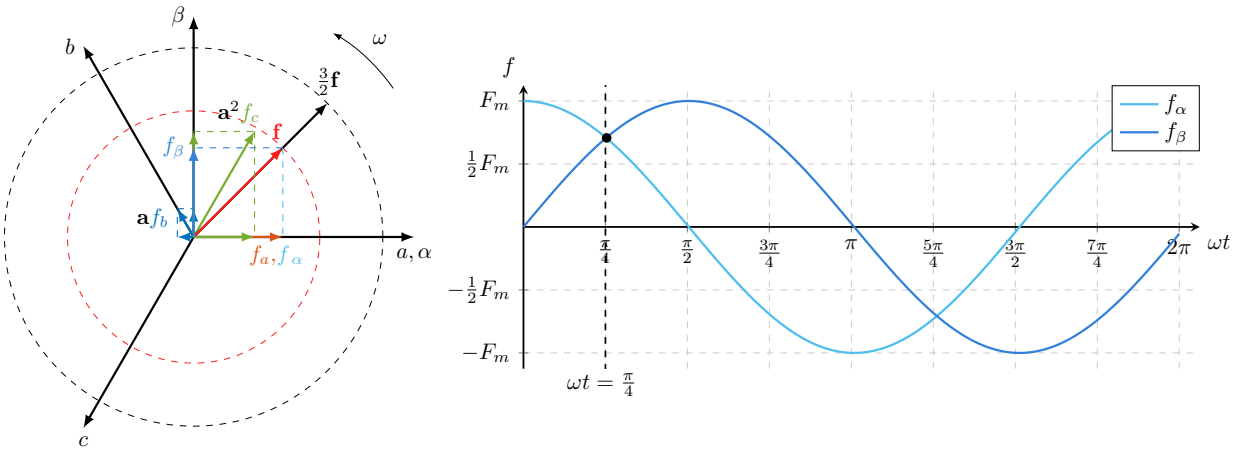

(a) Mirujući $\alpha\beta$ sustav (b) α i β komponente prostornog vektora $\mathbf{f}$

Slika 2.12: Clarkina transformacija

Parkova transformacija ($\alpha\beta \rightarrow dq$)

Postavljanjem dvoosnog rotirajućeg koordinatnog sustava čija se realna d-os poklapa s osi magneta, a imaginarna q-os je okomita na nju (slika 2.13a), prostorni vektor $\mathbf{f}$ može se zapisati kao zbroj d i q komponente:

$$\mathbf{f} = f_d + \mathbf{j} f_q. \tag{2.29}$$

Uz pretpostavku jednake kružne brzine rotirajućeg vektora i dq koordinatnog sustava, komponente f_d i f_q istosmjerne su veličine koje predstavljaju projekciju rotirajućeg prostornog vektora na osi rotirajućeg dq koordinatnog sustava.

Vektor trenutnih vrijednosti prostornog vektora u d i q-osi, $\boldsymbol{f}_{dq} = [f_d \; f_q]^T$, može se odrediti iz trenutnih vrijednosti u $\alpha\beta$ koordinatnom sustavu primjenom Parkove transformacije. Parkova transformacija definira se kao [30]:

$$\boldsymbol{f}_{dq} = \mathbf{P}(\theta)\boldsymbol{f}_{\alpha\beta}, \tag{2.30}$$

gdje je

$$\mathbf{P}(\theta) = \begin{bmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{bmatrix} \tag{2.31}$$

matrica Parkove transformacije, a θ - kut između d-osi i osi faze a, odnosno α-osi.

Primjenom inverzne Parkove transformacijom iz trenutnih vrijednosti komponenata f_{sd} i f_{sq} mogu se dobiti trenutne vrijednosti komponenata f_α i f_β:

$$\boldsymbol{f}_{\alpha\beta} = \mathbf{P}^{-1}(\theta)\boldsymbol{f}_{dq}, \tag{2.32}$$

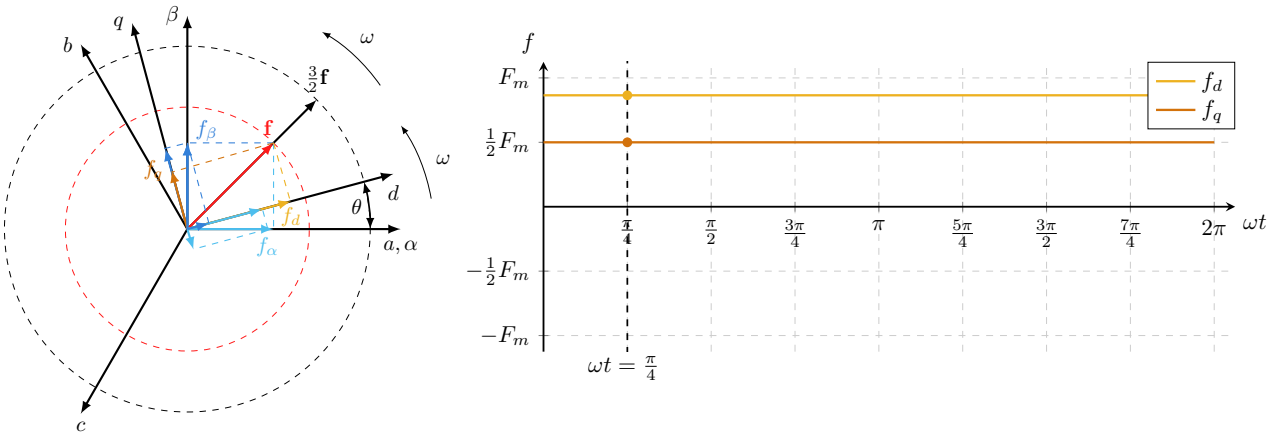

(a) Rotirajući dq sustav (b) d i q komponente prostornog vektora $\mathbf{f}$

Slika 2.13: Parkova transformacija

gdje je

$$\mathbf{P}^{-1}(\theta) = \begin{bmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{bmatrix} \tag{2.33}$$

matrica inverzne Parkove transformacije.

2.4.3. Matematički model PMSG-a u troosnom abc koordinatnom sustavu

Naponska jednadžba PMSG-a u mirujućem troosnom abc koordinatnom sustavu glasi [31]:

$$\boldsymbol{u}_{abc} = R_s \boldsymbol{i}_{abc} + \frac{d\boldsymbol{\psi}_{abc}}{dt}, \tag{2.34}$$

gdje je R_s - otpor faznih namota jednak za sve tri faze, $\boldsymbol{u}_{abc} = [u_a\ u_b\ u_c]^T$ - vektor statorskog napona, $\boldsymbol{i}_{abc} = [i_a\ i_b\ i_c]^T$ - vektor statorske struje i $\boldsymbol{\psi}_{abc} = [\psi_a\ \psi_b\ \psi_c]^T$ - vektor magnetskog toka, dok komponente prethodnih vektora predstavljaju trenutačne vrijednosti napona, struje ili magnetskog toka u pojedinoj fazi.

Magnetski tok $\boldsymbol{\psi}_{abc}$ sadrži komponentu induciranu protjecanjem statorskih struja pripadajućih faza te komponentu toka magneta smještenih u rotoru:

$$\boldsymbol{\psi}_{abc} = \boldsymbol{L}_{abc}\boldsymbol{i}_{abc} + \boldsymbol{\psi}_{r,abc}, \tag{2.35}$$

gdje je $\boldsymbol{L}_{abc}$ - matrica induktiviteta, a $\boldsymbol{\psi}_{r,abc} = [\psi_{r,a}\ \psi_{r,b}\ \psi_{r,c}]^T$ - vektor rotorskog magnetskog toka.

Uvrštavanjem izraza za statorski magnetski tok (2.35) u (2.34) dobiva se proširena naponska jednadžbu:

$$\boldsymbol{u}_{abc} = R_s \boldsymbol{i}_{abc} + \frac{d}{dt}\left(\boldsymbol{L}_{abc}\boldsymbol{i}_{abc}\right) + \boldsymbol{e}_{abc}, \tag{2.36}$$

gdje je $\boldsymbol{e}_{abc} = \dfrac{d\boldsymbol{\psi}_{r,abc}}{dt}$ - vektor napona induciranog promjenom magnetskog toka rotora.

Osim magnetskog toka induciranog protjecanjem struje u pojedinoj fazi, zbog magnetske sprege između namota faza PMSG-a, u svakoj od faza prisutni su magnetski tokovi inducirani protjecanjem struja u preostale dvije faze što je vidljivo iz matrice induktiviteta:

$$\boldsymbol{L}_{abc} = \begin{bmatrix} L_{aa} + L_\sigma & L_{ab} & L_{ac} \\ L_{ba} & L_{bb} + L_\sigma & L_{bc} \\ L_{ca} & L_{cb} & L_{cc} + L_\sigma \end{bmatrix}, \tag{2.37}$$

gdje su L_{aa}, L_{bb} i L_{cc} - samoinduktiviteti pojedinih faza, L_σ - rasipni induktivitet, L_{ab}, L_{ba}, L_{ac}, L_{ca}, L_{bc} i L_{cb} - međuinduktiviteti.

Samoinduktiviteti L_{aa}, L_{bb} i L_{cc} jednaki su:

$$L_{aa} = L_A - L_B \cos(2\theta_{re}), \tag{2.38}$$

$$L_{bb} = L_A - L_B \cos\left(2\theta_{re} + \frac{2\pi}{3}\right), \tag{2.39}$$

$$L_{cc} = L_A - L_B \cos\left(2\theta_{re} + \frac{4\pi}{3}\right), \tag{2.40}$$

a međuinduktiviteti L_{ab}, L_{ba}, L_{ac}, L_{ca}, L_{bc} i L_{cb}:

$$L_{ab} = L_{ba} = -\frac{1}{2}L_A - L_B \cos\left(2\theta_{re} - \frac{2\pi}{3}\right), \tag{2.41}$$

$$L_{bc} = L_{cb} = -\frac{1}{2}L_A - L_B \cos(2\theta_{re}), \tag{2.42}$$

$$L_{ac} = L_{ca} = -\frac{1}{2}L_A - L_B \cos\left(2\theta_{re} - \frac{4\pi}{3}\right) \tag{2.43}$$

gdje je θ_{re} - električni kut što ga os magneta (d-os) zatvara s osi faze a, L_A i L_B - pomoćni induktiviteti određeni konstrukcijom PMSG-a [31].

Električni kut rotora definiran je kao:

$$\theta_{re} = p\theta_r, \tag{2.44}$$

gdje je p - broj pari polova, a θ_r - mehanički kut između osi magneta (d-os) i osi faze a.

Očito je da su samoinduktiviteti i međuinduktiviteti PMSG-a u trofaznom abc sustavu funkcije kuta rotora θ_{re}, a osim toga, kada se pogledaju i komponente vektora magnetskog toka

rotora $\boldsymbol{\psi}_{r,abc}$ vidljivo je da i on u sebi sadrži ovisnost o kutu rotora:

$$\boldsymbol{\psi}_{r,abc} = \begin{bmatrix} \psi_r \cos\theta_{re} \\ \psi_r \cos\left(\theta_{re} - \frac{2\pi}{3}\right) \\ \psi_r \cos\left(\theta_{re} - \frac{4\pi}{3}\right) \end{bmatrix}, \tag{2.45}$$

gdje je ψ_r - tok magneta smještenih u rotoru.

Iz prethodnih izraza može se potvrditi da je matematički PMSG-a u troosnom abc sustavu izrazito složen i nelinearan te kao takav neprikladan za sintezu upravljačkog algoritma.

2.4.4.Matematički model PMSG-a u dvoosnom mirujućem $\alpha\beta$ koordinatnom sustavu

Matematički model PMSG-a u dvoosnom mirujućem $\alpha\beta$ koordinatnom sustavu izvodi se primjenom Clarkine transformacije (2.25) nad modelom u troosnom abc sustavu iz (2.34) te se može izraziti kao:

$$\boldsymbol{u}_{\alpha\beta} = R_s \boldsymbol{i}_{\alpha\beta} + \frac{d\boldsymbol{\psi}_{\alpha\beta}}{dt}, \tag{2.46}$$

gdje je $\boldsymbol{u}_{\alpha\beta} = \mathbf{C}\boldsymbol{u}_{abc} = [u_\alpha \; u_\beta]^{\mathrm{T}}$ - vektor statorskog napona, $\boldsymbol{i}_{\alpha\beta} = \mathbf{C}\boldsymbol{i}_{abc} = [i_\alpha \; i_\beta]^{\mathrm{T}}$ - vektor statorske struje i $\boldsymbol{\psi}_{\alpha\beta} = \mathbf{C}\boldsymbol{\psi}_{abc} = [\psi_\alpha \; \psi_\beta]^{\mathrm{T}}$ - vektor magnetskog toka, dok komponente prethodnih vektora predstavljaju trenutačne vrijednosti napona, struje ili magnetskog toka u realnoj α-, odnosno imaginarnoj β-osi.

Magnetski tok u $\alpha\beta$ koordinatnom sustavu također sadrži komponentu induciranu protjecanjem statorskih struja te komponentu magnetskog toka rotora:

$$\boldsymbol{\psi}_{\alpha\beta} = \boldsymbol{L}_{\alpha\beta}\boldsymbol{i}_{\alpha\beta} + \boldsymbol{\psi}_{r,\alpha\beta}, \tag{2.47}$$

gdje je vektor magnetskog toka rotora:

$$\boldsymbol{\psi}_{r,\alpha\beta} = \mathbf{C}\boldsymbol{\psi}_{r,abc} = \psi_r \begin{bmatrix} \cos\theta_{re} \\ \sin\theta_{re} \end{bmatrix}, \tag{2.48}$$

a matrica induktiviteta:

$$\boldsymbol{L}_{\alpha\beta} = \mathbf{C}\boldsymbol{L}_{abc}\mathbf{C}^{-1} = \begin{bmatrix} L_0 - L_\Delta \cos(2\theta_{re}) & -L_\Delta \sin(2\theta_{re}) \\ -L_\Delta \sin(2\theta_{re}) & L_0 + L_\Delta \cos(2\theta_{re}) \end{bmatrix}. \tag{2.49}$$

Oznaka L_0 predstavlja srednju vrijednost induktiviteta, a L_Δ amplitudu oscilacija induktiviteta:

$$L_0 = \frac{3}{2}L_A + L_\sigma, \tag{2.50}$$

$$L_\Delta = \frac{3}{2} L_B. \tag{2.51}$$

Kombinacijom jednažbi (2.46) i (2.47) naponska jednadžba u $\alpha\beta$ sustavu može se zapisati kao:

$$\boldsymbol{u}_{\alpha\beta} = R_s \boldsymbol{i}_{\alpha\beta} + \frac{d}{dt}\left(\boldsymbol{L}_{\alpha\beta}\boldsymbol{i}_{\alpha\beta}\right) + \boldsymbol{e}_{\alpha\beta}, \tag{2.52}$$

gdje je

$$\boldsymbol{e}_{\alpha\beta} = \frac{\boldsymbol{\psi}_{r,\alpha\beta}}{dt} = \omega_{re}\psi_r \begin{bmatrix} -\sin\theta_{re} \\ \cos\theta_{re} \end{bmatrix} \tag{2.53}$$

vektor napona induciranog promjenom magnetskog toka rotora, a ω_{re} - električna brzina vrtnje rotora.

Električna brzina vrtnje rotora definirana je kao:

$$\omega_{re} = p\omega_r, \tag{2.54}$$

gdje je ω_r - mehanička brzina vrtnje rotora.

2.4.5.Matematički model PMSG-a u dvoosnom rotirajućem dq koordinatnom sustavu

Matematički model PMSG-a u dvoosnom rotirajućem dq koordinatnom sustavu moguće je izvesti primjenom Parkove transformacije (2.31) s kutom θ_{re} na naponsku jednadžbu i magnetski tok u $\alpha\beta$ sustavu iz (2.46) i (2.47):

$$\boldsymbol{u}_{dq} = R_s \boldsymbol{i}_{dq} + \frac{d\boldsymbol{\psi}_{dq}}{dt} + \mathbf{J}\omega_{re}\boldsymbol{\psi}_{dq}, \tag{2.55}$$

gdje je $\boldsymbol{u}_{dq} = \mathbf{P}(\theta_{re})\boldsymbol{u}_{\alpha\beta} = [u_d\ u_q]^{\mathrm{T}}$ - vektor statorskog napona, $\boldsymbol{i}_{dq} = \mathbf{P}(\theta_{re})\boldsymbol{i}_{\alpha\beta} = [i_d\ i_q]^{\mathrm{T}}$ - vektor statorske struje i $\boldsymbol{\psi}_{dq} = \mathbf{P}(\theta_{re})\boldsymbol{\psi}_{\alpha\beta} = [\psi_d\ \psi_q]^{\mathrm{T}}$ - vektor magnetskog toka, ω_{re} - električna brzina rotora, dok komponente prethodnih vektora predstavljaju vrijednosti napona, struje ili magnetskog toka u realnoj d-, odnosno imaginarnoj q-osi.

Matrica rotacije definirana je kao:

$$\mathbf{J} = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}. \tag{2.56}$$

Magnetski tok u dq koordinatnom sustavu, kao i u prethodnim sustavima, sadrži komponentu uzrokovanu statorskim strujama te komponentu magnetskog toka rotora:

$$\boldsymbol{\psi}_{dq} = \boldsymbol{L}_{dq}\boldsymbol{i}_{dq} + \boldsymbol{\psi}_r, \tag{2.57}$$

gdje je matrica induktiviteta

$$\boldsymbol{L}_{dq} = \mathbf{P}(\theta_{re})\boldsymbol{L}_{\alpha\beta}\mathbf{P}^{-1}(\theta_{re}) = \begin{bmatrix} L_d & 0 \\ 0 & L_q \end{bmatrix}, \tag{2.58}$$

$L_d = L_0 - L_\Delta$ - induktivitet u d-osi, $L_q = L_0 + L_\Delta$ - induktivitet u q-osi, a magnetski tok:

$$\boldsymbol{\psi}_r = \mathbf{P}(\theta_{re})\boldsymbol{\psi}_{r,\alpha\beta} = \psi_r \begin{bmatrix} 1 \\ 0 \end{bmatrix}. \tag{2.59}$$

Uvrštavanjem (2.57) u (2.55) dobiva se konačni oblik naponske jednadžbe PMSG-a u dq sustavu:

$$\boldsymbol{u}_{dq} = \left(R_s\mathbf{I} + \mathbf{J}\omega_{re}\boldsymbol{L}_{dq}\right)\boldsymbol{i}_{dq} + \boldsymbol{L}_{dq}\frac{d\boldsymbol{i}_{dq}}{dt} + \boldsymbol{e}_{dq}, \tag{2.60}$$

gdje je

$$\boldsymbol{e}_{dq} = \omega_{re}\psi_r \begin{bmatrix} 0 \\ 1 \end{bmatrix} \tag{2.61}$$

vektor napona induciranog magnetskim tokom rotora, a jedinična matrica glasi:

$$\mathbf{I} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}. \tag{2.62}$$

2.4.6. Matematički model PMSG-a u estimiranom dvoosnom rotirajućem $\gamma\delta$ koordinatnom sustavu

Matematički model PMSG-a u dvoosnom estimiranom rotirajućem $\gamma\delta$ koordinatnom sustavu također se dobiva primjenom Parkove transformacije (2.31), ali na naponsku jednadžbu i magnetski tok PMSG-a u dq koordinatnom sustavu (2.60) i (2.57) uz kut $\bar{\theta}_{re}$:

$$\boldsymbol{u}_{\gamma\delta} = R_s\boldsymbol{i}_{\gamma\delta} + \frac{d\boldsymbol{\psi}_{\gamma\delta}}{dt} + \mathbf{J}\hat{\omega}_{re}\boldsymbol{\psi}_{\gamma\delta}, \tag{2.63}$$

gdje je $\boldsymbol{u}_{\gamma\delta} = \mathbf{P}(\bar{\theta}_{re})\boldsymbol{u}_{dq} = [u_\gamma\ u_\delta]^{\mathrm{T}}$ - vektor statorskog napona, $\boldsymbol{i}_{\gamma\delta} = \mathbf{P}(\bar{\theta}_{re})\boldsymbol{i}_{dq} = [i_\gamma\ i_\delta]^{\mathrm{T}}$ - vektor statorske struje i $\boldsymbol{\psi}_{\gamma\delta} = \mathbf{P}(\bar{\theta}_{re})\boldsymbol{\psi}_{dq} = [\psi_\gamma\ \psi_\delta]^{\mathrm{T}}$ - vektor magnetskog toka, $\hat{\omega}_{re}$ - estimirana brzina vrtnje rotora, a $\bar{\theta}_{re} = \hat{\theta}_{re} - \theta_{re}$ - kut između γ- i d-osi.

Magnetski tok u $\gamma\delta$ koordinatnom sustavu također sadrži komponentu uzrokovanu statorskim strujama te komponentu magnetskog toka rotora:

$$\boldsymbol{\psi}_{\gamma\delta} = \boldsymbol{L}_{\gamma\delta}\boldsymbol{i}_{\gamma\delta} + \boldsymbol{\psi}_{r,\gamma\delta}, \tag{2.64}$$

gdje je matrica induktiviteta:

$$\boldsymbol{L}_{\gamma\delta} = \mathbf{P}(\bar{\theta}_{re})\boldsymbol{L}_{dq}\mathbf{P}^{-1}(\bar{\theta}_{re}) = \begin{bmatrix} L_0 - L_\Delta\cos(2\bar{\theta}_{re}) & L_\Delta\sin(2\bar{\theta}_{re}) \\ L_\Delta\sin(2\bar{\theta}_{re}) & L_0 + L_\Delta\cos(2\bar{\theta}_{re}) \end{bmatrix}, \tag{2.65}$$

a vektor magnetskog toka:

$$\boldsymbol{\psi}_{r,\gamma\delta} = \mathbf{P}(\bar{\theta}_{re})\boldsymbol{\psi}_r = \psi_r \begin{bmatrix} \cos\bar{\theta}_{re} \\ -\sin\bar{\theta}_{re} \end{bmatrix}. \tag{2.66}$$

Uvrštavanjem (2.64) u (2.63) dobiva se konačni oblik naponske jednadžbe PMSG-a u $\gamma\delta$ sustavu:

$$\boldsymbol{u}_{\gamma\delta} = \left[R_s\mathbf{I} + \mathbf{J}\hat{\omega}_{re}\boldsymbol{L}_{\gamma\delta}\right]\boldsymbol{i}_{\gamma\delta} + \boldsymbol{L}_{\gamma\delta}\frac{d\boldsymbol{i}_{\gamma\delta}}{dt} + \boldsymbol{e}_{\gamma\delta}, \tag{2.67}$$

gdje je

$$\boldsymbol{e}_{\gamma\delta} = \omega_{re}\psi_r \begin{bmatrix} \sin\bar{\theta}_{re} \\ \cos\bar{\theta}_{re} \end{bmatrix} \tag{2.68}$$

vektor napona induciranog promjenom magnetskog toka rotora.

2.4.7.Snaga i moment PMSG-a

Trenutačna vrijednost snage PMSG-a neovisna je o referentnom koordinatnom sustavu te je jednaka realnom dijelu skalarnog umnoška vektora napona i struje:

$$p(t) = \boldsymbol{u}_{abc}\boldsymbol{i}_{abc}^{\mathrm{T}} = \frac{3}{2}\boldsymbol{u}_{\alpha\beta}\boldsymbol{i}_{\alpha\beta}^{\mathrm{T}} = \frac{3}{2}\boldsymbol{u}_{dq}\boldsymbol{i}_{dq}^{\mathrm{T}}. \tag{2.69}$$

Budući da se upravljanje momentom unutar upravljačkog sustava često izvodi u dq koordinatnom sustavu, korisno je izraziti snagu koristeći dq sustav tako da se naponska jednadžba za dq sustav iz (2.60) uvrsti u prethodni izraz iz čega se slijedi:

$$P = \underbrace{\frac{3}{2}R_s(i_d^2 + i_q^2) + \frac{3}{2}\left(L_d i_d\frac{di_d}{dt} + L_q i_q\frac{di_q}{dt}\right)}_{P_s} + \underbrace{\frac{3}{2}\omega_{re}(\psi_d i_q - \psi_q i_d)}_{P_{em}}, \tag{2.70}$$

gdje član P_s predstavlja snagu na statorskim stezaljkama, dok je član P_{em} je snaga okretnog magnetskog polja koja se preko zračnog raspora predaje rotoru.

Dijeljenjem snage okretnog magnetskog polja s brzinom vrtnje rotora dobiva se izraz za razvijeni elektromagnetski moment:

$$M_{em} = \frac{P_{em}}{\omega_r} = \frac{3}{2}p(\psi_d i_q - \psi_q i_d). \tag{2.71}$$

Osim preko izraza za snagu, elektromagnetski moment PMSG-a može se odrediti i koristeći vektorski umnožak vektora magnetskog toka i statorske struje neovisno o koordinatnom sustavu:

$$M_{em} = \frac{3}{2} p |\boldsymbol{\psi} \times \boldsymbol{i}|. \tag{2.72}$$

Elektromagnetski moment, kao i snaga, jednak je u svim koordinatnim sustavima pa se uvrštavanjem vektora magnetskog toka i struje u (2.72) dobiva izraz za elektromagnetski moment u $\alpha\beta$, dq i $\gamma\delta$ sustavima:

$$M_{em} = \frac{3}{2} p(\psi_\alpha i_\beta - \psi_\beta i_\alpha) = \frac{3}{2} p(\psi_d i_q - \psi_q i_d) = \frac{3}{2} p(\psi_\gamma i_\delta - \psi_\delta i_\gamma). \tag{2.73}$$

Nadalje, elektromagnetski moment u dq sustavu iz prethodnog izraza može se raspisati uvrštavanjem komponenti magnetskog toka iz (2.57) kao:

$$M_{em} = \frac{3}{2} p \left[\psi_r i_q + (L_d - L_q) i_d i_q\right]. \tag{2.74}$$

Elektromagnetski moment iz (2.74) sadrži dva člana gdje je prvi član dominantan i predstavlja moment razvijen međudjelovanjem toka rotorskih magneta i struje, a drugi član posljedica je magnetske nesimetrije u uzdužnoj i poprečnoj osi te se naziva reluktantni moment [†]. Uz pretpostavku pozitivnog smjera brzine vrtnje, u generatorskom režimu razvijeni elektromagnetski moment mora biti negativnog predznaka što će se postići uz struju $i_q < 0$. Ukoliko se i struja u d-osi drži negativnom, $i_d < 0$, uz činjenicu da kod PMSG-a vrijedi $L_q > L_d$, reluktantni moment će također imati negativni predznak te će doprinositi ukupno razvijenom elektromagnetskom momentu. Prema tome, radno područje PMSG-a nalazi se u III. kvadrantu[‡] dq koordinatnog sustava kao što je uočljivo na vektorskom dijagramu sa slike 2.14.

U vektorskom dijagramu PMSG-a uobičajeno je definirati i kut opterećenja γ koji predstavlja kut između vektora struje i q-osi pa se vektor struje može izraziti kao:

$$\boldsymbol{i}_{dq} = \begin{bmatrix} i_d \\ i_q \end{bmatrix} = I_m \begin{bmatrix} -\sin\gamma \\ -\cos\gamma \end{bmatrix}, \tag{2.75}$$

gdje je I_m - amplituda vektora struje.

Na kraju, elektromagnetski moment može se izraziti preko amplitude struje i kuta opterećenja uvrštavanjem (2.75) u (2.74) kao [32]:

$$M_{em} = \frac{3}{2} p \left[-\psi_r I_m \sin\gamma + \frac{1}{2}(L_d - L_q) I_m^2 \sin(2\gamma)\right]. \tag{2.76}$$

[†]Kod SPMSG-a reluktantni moment ne postoji jer zbog magnetske simetrije vrijedi $L_d = L_q$.

[‡]U slučaju rada u motorskom režimu radno područje bilo bi smješteno u II. kvadrantu.

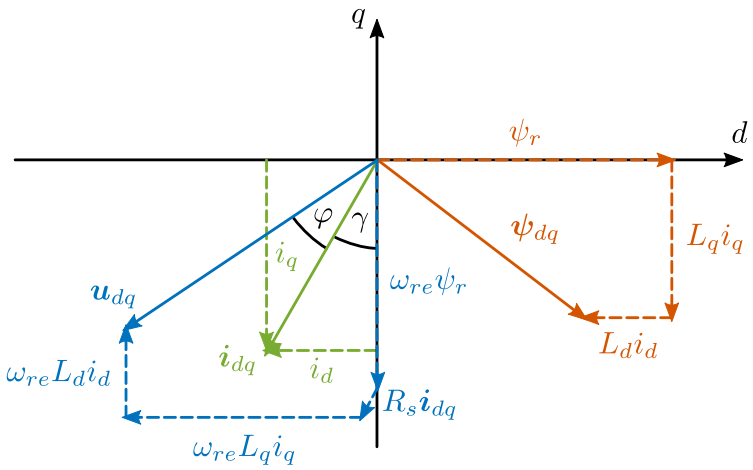

Slika 2.14: Vektorski dijagram PMSG-a

2.4.8.Radno područje PMSG-a

Naponsko ograničenje

Budući da se PMSG-om u vjetroagregatu upravlja putem AC-DC-AC pretvarača, njegovo radno područje ograničeno je najvećom amplitudom osnovnog harmonika faznog napona koju pretvarač može ostvariti na svom izlazu te se ono može zapisati kao:

$$|\boldsymbol{u}| \leq U_{max}, \tag{2.77}$$

gdje je U_{max} - najveća moguća amplituda osnovnog harmonika izlaznog napona pretvarača.

Amplituda izlaznog napona pretvarača ovisi o modulacijskoj tehnici, a danas se najčešće primjenjuju tehnike kao što je vektorska modulacija ili sinusna modulacija s injektiranjem trećeg harmonika s kojima amplituda izlaznog napona pretvarača raste do:

$$U_{max} = \frac{U_{dc}}{\sqrt{3}}, \tag{2.78}$$

gdje je U_{dc} - napon istosmjernog međukruga AC-DC-AC pretvarača.

Cilj upravljanja PMSG-om putem pretvarača je razvijanje željenog elektromagnetskog momenta, a budući da moment prema (2.76) ovisi o amplitudi i kutu opterećenja struje, upravljanje momentom svodi se upravo na upravljanje amplitudom i kutom statorske struje. Ako se promotri naponska jednadžba PMSG-a u (2.55) pri stacionarnom stanju, vektor struje glasi:

$$\boldsymbol{i}_{dq} = \frac{\boldsymbol{u}_{dq} - \mathbf{J}\omega_{re}\boldsymbol{\psi}_{dq}}{R_s}, \tag{2.79}$$

Prema tome, kako bi PMSG mogao raditi u željenoj radnoj točki definiranoj nekim referentnim momentom, pretvarač mora u svakom trenutku moći ostvariti izlazni napon koji će kroz namote

PMSG-a protjerati struju potrebnu za razvoj zadanog momenta što će biti moguće uz uvjet:

$$|\boldsymbol{u}_{dq}| \geq \omega_{re}|\boldsymbol{\psi}_{dq}|. \tag{2.80}$$

Ukoliko se u uvjet (2.80) uvrsti maksimalni izlazni napon pretvarača (2.78) te komponente vektora magnetskog toka (2.57) dobiva se jednadžba elipse koja predstavlja naponsko ograničenje radnog područja PMSG-a u dq-ravnini [32]:

$$\left(\frac{U_{max}}{\omega_{re}L_dL_q}\right)^2 \geq \left(\frac{i_d + \frac{\psi_r}{L_d}}{L_q}\right)^2 + \left(\frac{i_q}{L_d}\right)^2. \tag{2.81}$$

Strujno ograničenje

Osim naponom, radno područje PMSG-a ograničeno je i najvećom dopuštenom strujom pri kojoj neće doći do pregrijavanja PMSG-a. Budući da je PMSG projektiran tako da pri nazivnoj struji može trajno raditi bez prekoračenja termičke granice, maksimalnom dozvoljenom strujom može se smatrati amplituda nazivne struje PMSG-a:

$$|\boldsymbol{i}| \leq I_m = \sqrt{2}I_n, \tag{2.82}$$

gdje je I_n - nazivna struja PMSG-a.

Raspisom izraza (2.82) u dq sustavu dobiva se jednadžba kružnice koja predstavlja strujno ograničenje u dq-ravnini:

$$i_d^2 + i_q^2 \leq I_m^2. \tag{2.83}$$

Radno područje PMSG-a u dq ravnini

Na slici 2.15 prikazana je dq ravnina s naponskim i strujnim ograničenjima te pojedinim radnim točkama PMSG-a. Naponska ograničenja prikazana su elipsama (2.81), dok je strujno ograničenje određeno kružnicom (2.83). Budući da su prema (2.81) poluosi elipse naponskog ograničenja, uz pretpostavku konstantnih induktiviteta, obrnuto proporcionalne brzini vrtnje, prikazane su elipse za tri brzine iz čega je očito da porast brzine vrtnje uzrokuje smanjenje naponskog ograničenja. Ishodište elipsa naponskog ograničenja ovisi o odnosu magnetskog toka rotora i maksimalnog toka što ga statorska struja stvara u d-osi, a u ovom razmatranju prikazan je slučaj kada vrijedi $\psi_r/L_d < I_m$, odnosno kada se ishodište elipsa nalazi unutar kružnice strujnog ograničenja. Osim krivulja ograničenja, u dq ravnini prikazane su i dvije krivulje konstantnog momenta.

Svaka trajna radna točka PMSG-a određena nekim iznosom momenta mora se nalaziti unutar strujnog ograničenja, odnosno kružnice radijusa I_m. Budući da PMSG radi u generatorskom režimu, strujno ograničenje svodi se na dio kružnice koji obuhvaća III. kvadrant dq ravnine.

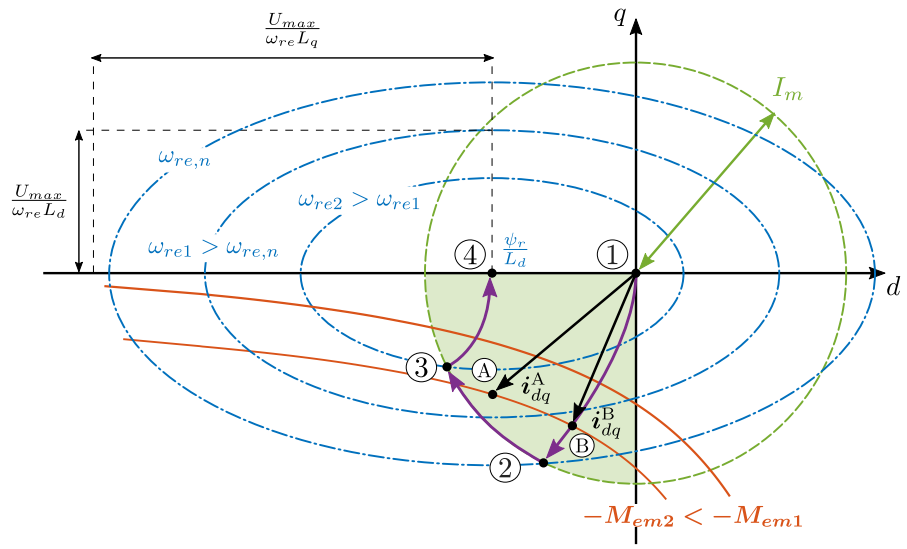

Slika 2.15: Radno područje PMSG-a

Osim strujnog ograničenja, svaka radna točka PMSG-a mora zadovoljiti i naponsko ograničenje što znači da se mora nalaziti unutar elipse određene trenutnom brzinom vrtnje. Radne točke Ⓐ i Ⓑ određene momentom $-M_{em2}$ predstavljaju ostvarive trajne radne točke zbog toga što se nalaze unutar strujnog ograničenja. Međutim, kada se u obzir uzme i naponsko ograničenje očito je da dvije radne točke određene istim momentom, ne mogu taj moment ostvariti na jednakim brzinama vrtnje. Primjerice, obje radne točke ostvarive su pri nazivnoj brzini vrtnje $\omega_{re,n}$ jer se nalaze unutar elipse određene nazivnom brzinom, no samo je radna točka Ⓐ ostvariva pri brzini vrtnje ω_{re1} budući da se nalazi unutar njene elipse, dok se radna točka Ⓑ ne može postići pri toj brzini jer se nalazi izvan iste elipse.

Osim toga, uočljivo je da su radne točke Ⓐ i Ⓑ postignute vektorom struja različitih amplituda $|\boldsymbol{i}^{A}_{dq}| > |\boldsymbol{i}^{B}_{dq}|$. Kako bi se željeni moment ostvario uz minimalnu amplitudu struje, a time i minimalne gubitke u namotima PMSG-a, često se primjenjuje MTPA (engl. *Maximum Torque Per Ampere*) algoritam koji minimizira kut opterećenja γ iz (2.76) te na taj način za svaki zadani moment određuje optimalan par struja (i_d, i_q) koji osigurava minimalne gubitke [33]. MTPA krivulja u dq ravnini predstavljena je odsječkom između točaka ① i ②, a radne točke koje prate MTPA krivulju određene su sjecištima krivulja konstantnog momenta i MTPA krivulje kao što je, na primjer, radna točka Ⓑ.

Radna točka ② predstavlja točku maksimalnog momenta budući da se nalazi na samoj granici strujnog ograničenja. Također, ta radna točka u prikazanom slučaju postignuta je pri nazivnoj brzini vrtnje. Radne točke u segmentu ② - ③ određene su sjecištem kružnice strujnog ograničenja i naponskih elipsa te su definirane brzinama većima od nazivne brzine vrtnje. Za ostvarenje tih radnih točaka potrebno je primijeniti algoritam slabljenja polja (engl. *Flux Weakening*) koji mijenja kut opterećenja čime se smanjuje ostvareni moment. Unatoč tome, smanjenje momenta nije proporcionalno povećanju brzine čime je omogućen daljnji porast razvijene snage [34].

Također, do porasta brzine vrtnje iznad nazivne može doći i unutar strujnog ograničenja te je stoga moguće primijeniti FW algoritam prije postizanja maksimalne struje, odnosno unutar kružnice ograničenja struje [35].

Na kraju, primjenom MTPV (engl. *Maximum Torque Per Voltage*) algoritma mogu se postići radne točke na segmentu ③ - ④ na kojem brzina vrtnje teoretski teži u beskonačnost.

Kada se PMSG koristi u vjetroagregatu, njegovo radno područje općenito se kreće do nazivne brzine vrtnje pa se FW i MTPV algoritmi potrebni za ostvarenje radnih točaka u segmentima ② - ③ i ③ - ④ najčešće ne implementiraju unutar upravljačkog sustava.

2.5.Upravljanje AC-DC-AC energetskim pretvaračem

Uz vjetroturbinu i generator, ključni dio vjetroagregata tipa 4 čini trofazni energetski AC-DC-AC pretvarač preko kojeg se vjetroagregat spaja na električnu mrežu. Danas se, unatoč pojavi novih topologija pretvarača, kao što su trorazinski AC-DC-AC pretvarači, u vjetroagregatima tipa 4 najčešće koristi dvorazinski pretvarač čija je topologija prikazana na slici 2.16 [36]. U vjetroagregatima većih snaga (> 3 MW) više dvorazinskih AC-DC-AC pretvarača može se spojiti paralelno kako bi se smanjili gubici i povećala instalirana snaga [36, 37]. Prikazani AC-DC-AC pretvarač može se podijeliti u dvije operacijske cjeline: generatorski pretvarač i mrežni pretvarač. Oba dijela pretvarača sastoje se od trofaznog mosnog spoja kojeg čine IGBT tranzistori s paralelno spojenim diodama. Između generatorskog i mrežnog pretvarača nalazi se istosmjerni međukrug koji služi kao spremnik energije. Prikladnim upravljanjem IGBT tranzistorima AC-DC-AC pretvarača omogućuje se upravljanje iznosom i smjerom toka energije od vjetroturbine prema EES-u. Uloga generatorskog pretvarača je upravljanjem momentom PMSG-a s ciljem osiguranja rada generatora u optimalnim radnim točkama, dok se rad mrežnog dijela pretvarača temelji na upravljanju toka radne i jalove snage od istosmjernog međukruga prema EES-u.

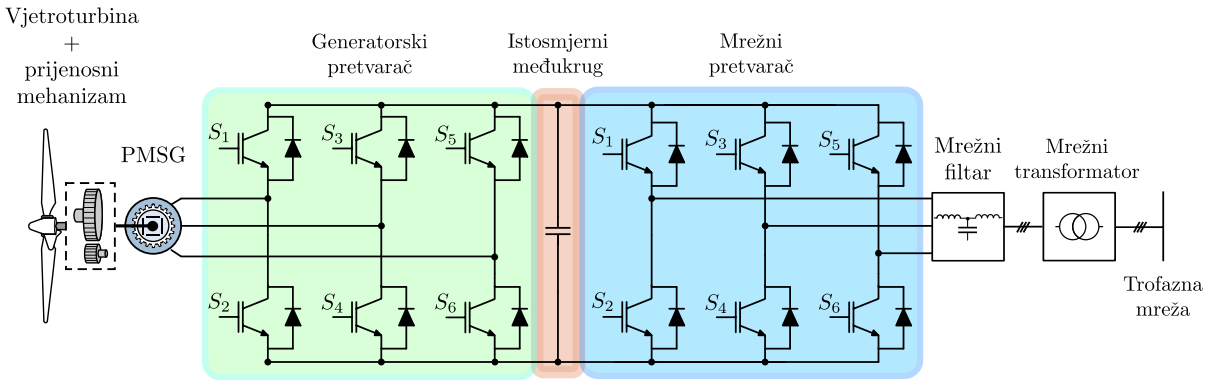

Slika 2.16: Struktura trofaznog dvorazinskog energetskog AC-DC-AC pretvarača

2.5.1.Upravljanje generatorskim dijelom AC-DC-AC pretvarača

Cilj upravljanja generatorskim pretvaračem je postizanje momenta generatora, a posljedično i vjetroturbine, koji će osigurati optimalno iskorištenje energije vjetra prema MPPT krivulji opisanoj u potpoglavlju 2.3. Kako bi se postigao optimalni moment, potrebno je primijeniti prikladan algoritam za upravljanje IGBT tranzistorima generatorskog pretvarača. Unatoč sve popularnijim algoritmima temeljenima na modelskom prediktivnom upravljanju (engl. *Model Predictive Control*, MPC) [38], najčešće korišteni algoritmi za upravljanje generatorskim pretvaračem su vektorsko upravljanje u koordinatnom sustavu magnetskog toka rotora (engl. *Rotor Field Oriented Control*, RFOC) i izravno upravljanje momentom (engl. *Direct Torque Control*, DTC) [37]. RFOC algoritam temelji se na Parkovoj transformaciji modela generatora u rotirajući koordinatni sustav magnetskog toka rotora i na taj način omogućava neovisno upravljanje tokom i momentom PMSG-a pomoću PI regulatora struja u d i q-osi i širinsko-impulsne modulacije (engl. *Pulse Width Modulation*, PWM). Za razliku od RFOC algoritma, DTC algoritam je nešto jednostavnije strukture jer ne primjenjuje Parkovu transformaciju što znači da poznavanje kuta rotora nije nužno. DTC algoritam, također, omogućuje neovisno upravljanje tokom i momentom PMSG-a, no uz korištenjem histereznih regulatora. Posljedica toga jesu brzi dinamički odzivi, ali i izražene pulzacije momenta PMSG-a. Također, s obzirom na to da DTC algoritam ne koristi PWM modulator, frekvencija sklapanja IGBT sklopki nije konstantna, već promjenjiva. Iz tog razloga razvijen je i hibridni algoritam koji unutar DTC algoritma koristi i PWM modulator [39].

U nastavku je opisana standardna struktura upravljanje generatorskim pretvaračem temeljena na RFOC algoritmu s obzirom da je taj algoritam korišten i implementiran na laboratorijskom postavu u eksperimentalnom dijelu rada. Navedena struktura upravljanja generatorskim pretvaračem prikazana je na slici 2.17. Iz referentnog iznosa momenta M^* preko MTPA algoritma, najčešće pohranjenog u preglednim tablicama (engl. *Lookup Table*, LUT), određuje se optimalni par struja (i_d, i_q) koje su potrebne za postizanje optimalnog referentnog momenta M^*. Referenti moment M^* dobiva iz nadređenog upravljačkog sustava vjetroturbine prema MPPT algoritmu. Greške između referentnog para struja (i_d^*, i_q^*) i mjerenih struja (i_a, i_b, i_c) transformiranih u dq sustav čine ulaze PI regulatora koji računaju referentne napone u_d^* i u_q^* kojim će se postići optimalni par struja. Parkova transformacija vrši se pomoću električnog kuta rotora θ_{re} koji se računa iz mjerenog kuta θ_r. Također, na izlaze PI regulatora pribrajaju se signali rasprezanja Δu_d i Δu_q. Potom se inverznom Parkovom transformacijom računaju naponske komponente (u_α^*, u_β^*) koje čine ulaze PWM modulatora. Na temelju proračunatih referentnih napona u $\alpha\beta$ sustavu, PWM modulacijom računaju se vremena vođenja IGBT tranzistora u pojedinim granama generatorskog pretvarača. Ovakvim upravljanjem IGBT tranzistorima na stezaljkama PMSG-a primjenjuje se napon koji će osigurati optimalnu struju, a time i postizanje optimalnog referentnog momenta M^*.

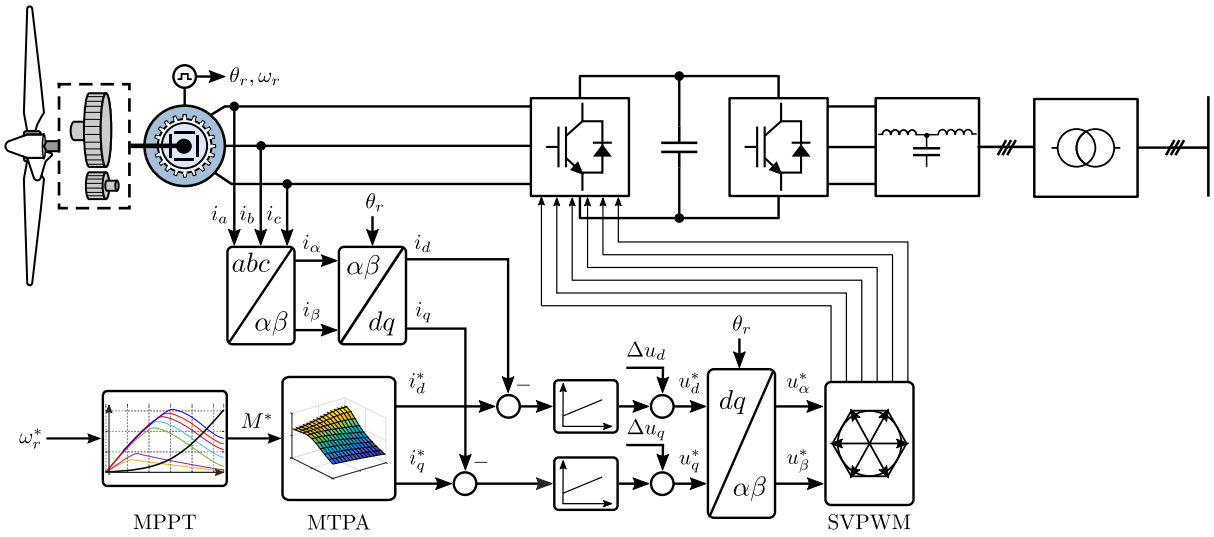

Slika 2.17: Struktura vektorskog upravljanja PMSG-om temeljena na RFOC algoritmu

2.5.2.Upravljanje mrežnim dijelom AC-DC-AC pretvarača

Električna energija proizvedena od strane PMSG-a pohranjuje se u kondenzatoru istosmjernog međukruga. Kako bi se ta energija proslijedila EES-u, potrebno je upravljati i IGBT tranzistorima mrežnog dijela pretvarača.

Za postizanje željenog toka energije prema mreži najčešće se koriste algoritam vektorskog upravljanja u koordinatnom sustavu napona mreže (engl. *Voltage Oriented Control*, VOC) ili algoritam direktnog upravljanja radnom i jalovom snagom (engl. *Direct Power Control*, DPC) [40, 41]. S obzirom na visokofrekvencijsko sklapanje IGBT sklopki, struja koja teče od mrežnog pretvarača prema mreži je harmonički izobličena te uzrokuje povećanje ukupnog harmoničkog izobličenja mrežne struje i napona (engl. *Total Harmonic Distortion*, THD). Kako bi THD mrežne struje i napona bio u dozvoljenom području propisano normom, između mrežnog pretvarača i mreže najčešće se ugrađuje LCL filtar koji prigušuje više harmoničke komponente izlazne struje pretvarača te napona. S obzirom na tu činjenicu, VOC algoritam predstavlja pogodnijeg kandidata za upravljanje mrežnim pretvaračem zbog toga što, kao i RFOC algoritam, primijenjuje konstantnu frekvenciju sklapanja IGBT-ova, za razliku od DPC algoritma, a poznavanje sklopne frekvencije nužno je za ispravno projektiranje LCL filtra [42]. Također, nužan preduvjet za korištenje VOC metode je poznavanje kuta mrežnog napona, a osnovni način određivanja tog kuta je primjenom mjerenog mrežnog napona i fazno zaključane petlje (engl. *Phase-Locked Loop*, PLL) [40, 43].

Na slici 2.18 prikazana je struktura upravljanja mrežnim pretvaračem temeljena na VOC algoritmu. Upravljanje pretvaračem je ostvareno u kaskadnoj strukturi upravljanja gdje je u nadređenoj petlji izvedeno upravljanje naponom istosmjernog međukruga U_{dc}, dok se u podređenoj petlji upravlja izlaznim strujama pretvarača i_{md} i i_{mq}. Izlaz iz regulatora napona predstavlja referentnu vrijednost struje u d-osi i_{md}^*, dok se jalova snaga najčešće održava na

vrijednosti $Q^* = 0$, što se postiže referentnom vrijednosti struje u q-osi $i^*_{mq} = 0$. Na taj je način ostvareno upravljanje radnom i jalovom snagom i to tako da se jalova snaga, općenito, održava na nuli, a radna snaga ovisi o snazi koju generator predaje istosmjernom međukrugu. Izlaz iz regulatora struje predstavlja referentne napone u^*_{md} i u^*_{mq} koji se, nakon pribrajanja signala rasprezanja Δu_{md} i Δu_{mq}, prosljeđuju bloku PWM modulatora koji generira upravljačke signale IGBT tranzistora.

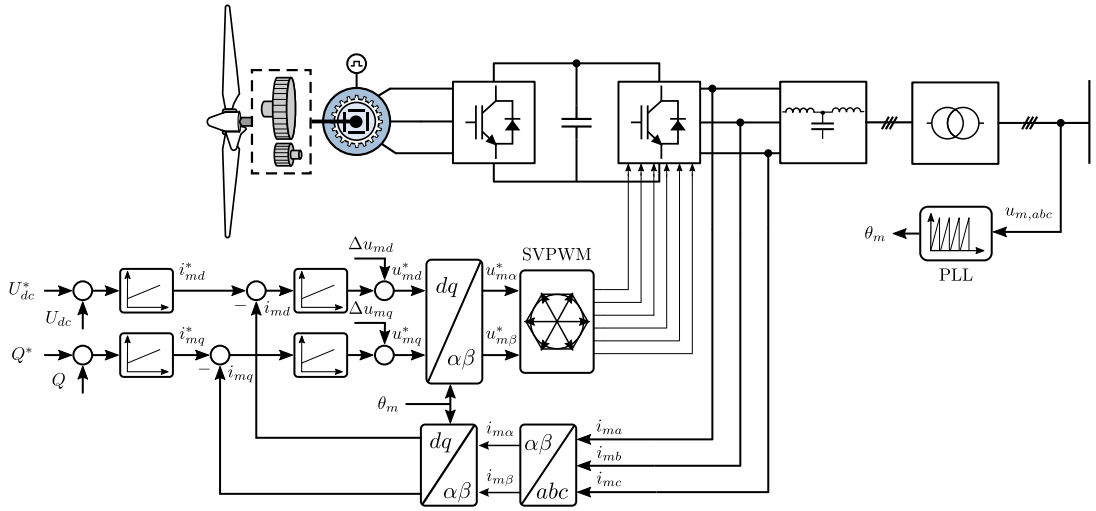

Slika 2.18: Struktura upravljanja tokom radne i jalove snage prema EES-u temeljena na VOC algoritmu

2.5.3. Vektorska modulacija

Cilj prethodno opisanih algoritama upravljanja PMSG-om putem AC-DC-AC pretvarača je postizanje trofaznih sinusnih napona i struja željene amplitude i kuta na stezaljkama generatora, odnosno mreže. Promatrajući RFOC i VOC algoritme upravljanja, očito je da su upravljačke strukture tih algoritama izvedene u rotirajućim koordinatnim sustavima magnetskog toka rotora, odnosno mrežnog napona. U tim koordinatnim sustavima naponi i struje PMSG-a i mreže su istosmjerne veličine što bitno pojednostavljuje sintezu regulatora struja. Međutim, izračunate istosmjerne referentne napone PMSG-a u^*_d i u^*_q, kao i referentne napone mreže u^*_{md} i u^*_{mq}, potrebno je primijeniti na PMSG i mrežu koji su izmjenični trofazni sustavi. Kako bi se to ostvarilo, potrebno je primijeniti tehnike kao što je PWM modulacija.

Temelj PWM modulacije jest metoda šest koraka (engl. *Six Step Method*) koja predstavlja jednostavan postupak formiranja trofaznog napona na stezaljkama električnog stroja korištenjem šest diskretnih vektora razmaknutih za kut $\pi/3$ te dva nul-vektora kao što je prikazano na slici 2.19a. Diskretni vektori $\boldsymbol{u}_1 - \boldsymbol{u}_6$ postižu se uklapanjem pojedinih IGBT tranzistora vremenski jednakog trajanja prema shemi prikazanoj na slici 2.19 na kojoj su IGBT-ovi prikazani kao sklopke $S_1 - S_6$. Budući da su vremena vođenja svih šest IGBT tranzistora jednaka, ova metoda omogućuju upravljanje frekvencijom izlaznog napona, dok se amplitudom može upravljati jedino

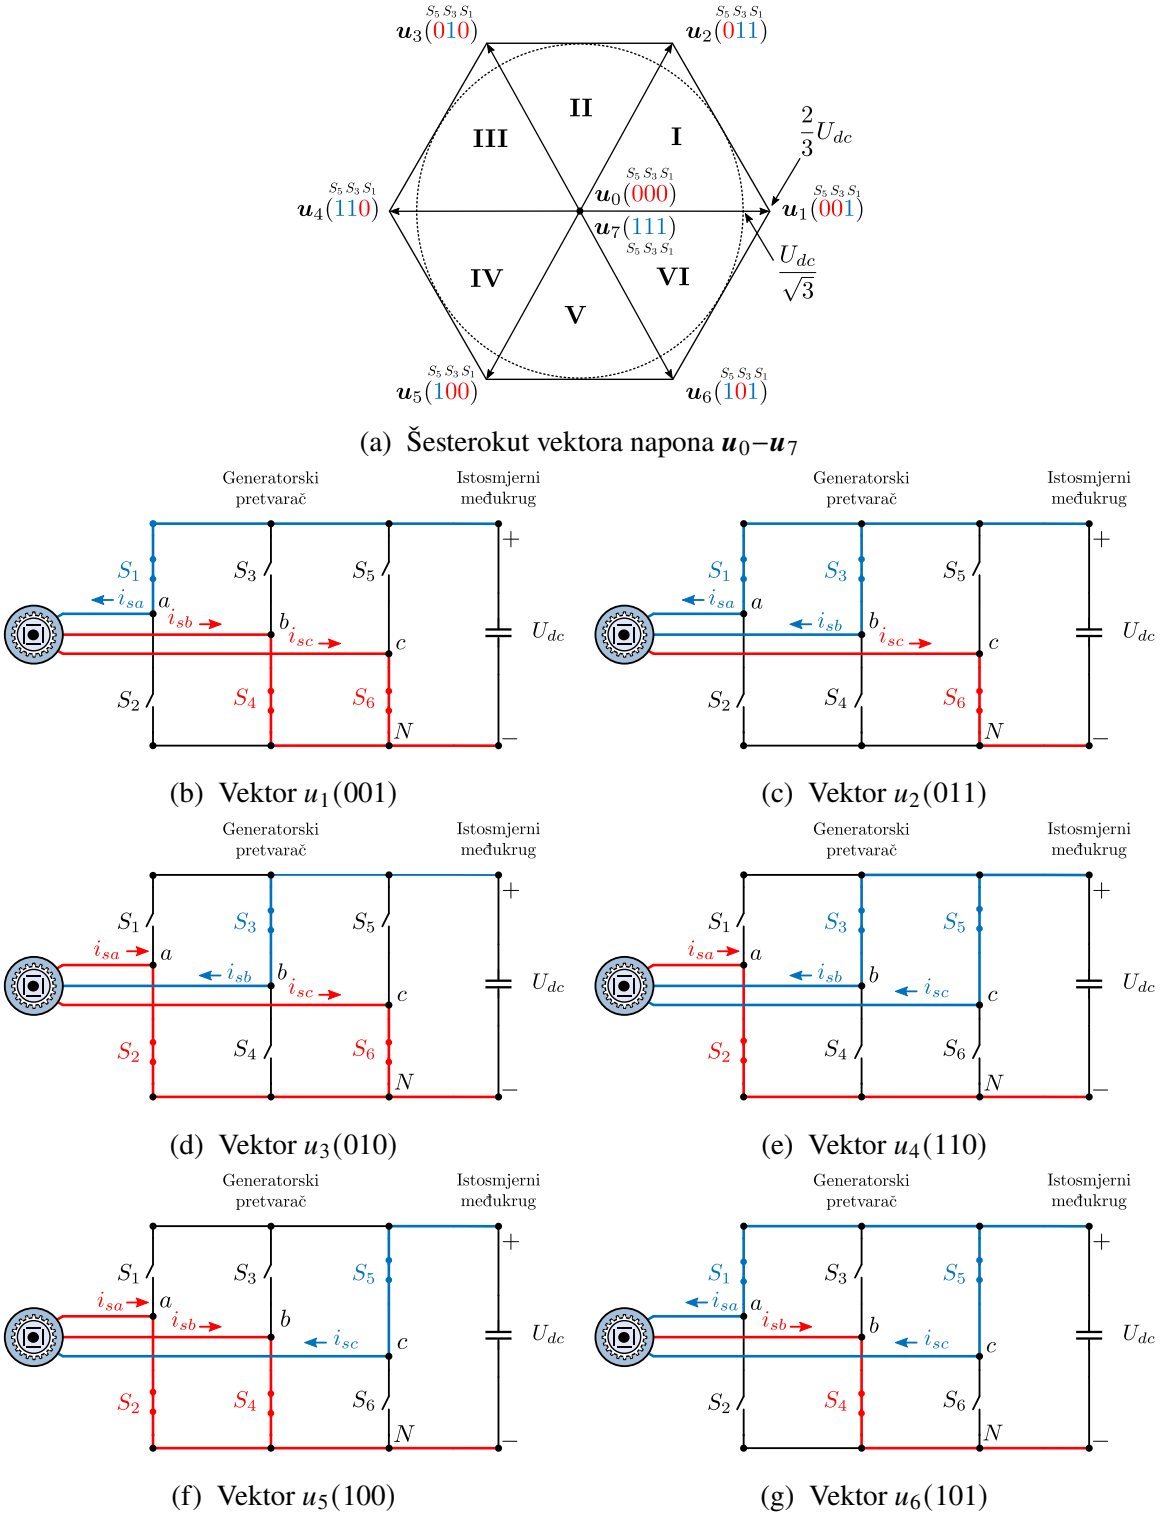

(a) Šesterokut vektora napona $\boldsymbol{u}_0$–$\boldsymbol{u}_7$

(b) Vektor $u_1(001)$

(c) Vektor $u_2(011)$

(d) Vektor $u_3(010)$

(e) Vektor $u_4(110)$

(f) Vektor $u_5(100)$

(g) Vektor $u_6(101)$

Slika 2.19: Sklopna stanja IGBT tranzistora pri metodi šest koraka

promjenom iznosa napona istosmjernog međukruga U_{dc}. Nul-vektori $\boldsymbol{u}_0$ i $\boldsymbol{u}_7$ ostvaruju se istovremenim uklapanjem svih gornjih ($S_1 - S_3 - S_5$) ili svih donjih ($S_2 - S_4 - S_6$) IGBT-ova.

Nadogradnja metode šest koraka u smislu postizanja vektora napona promjenjive amplitude i frekvencije može se ostvariti korištenjem PWM modulacije. Glavni doprinos PWM modulacije i njena razlika od metode šest koraka jest mogućnost promjene vremenskog trajanja vođenja

pojedinog IGBT tranzistora. Upravo različita vremena vođenja tranzistora omogućuju postizanje vektora napona različitih amplituda. Među nekolicinom modulacijskih metoda, jedna od najčešće korištenih je prostorno-vektorska modulacija (engl. *Space Vector Pulse Width Modulation*, SVPWM) koja je opisana u nastavku.

Kao što je već rečeno, napon željene amplitude određene izlazima PI regulatora struje iz upravljačkih struktura sa slika 2.17 i 2.18 potrebno je primijeniti na trofazni PMSG ili mrežu. Kako bi se to ostvarilo, na temelju referentnih napona (u_d^*, u_q^*), odnosno (u_{md}^*, u_{mq}^*) te mjerenog ili estimiranog kuta θ_{re}, odnosno θ, vrši se inverzna Parkova transformacija te se dobiva referentni napon u $\alpha\beta$ sustavu prema kojem se određuje koji od vektora $\boldsymbol{u}_0$–$\boldsymbol{u}_7$ i koliko dugo treba biti aktivan. Da je postizanje vektora napona željene amplitude moguće primjenom naponskih vektora $\boldsymbol{u}_0$–$\boldsymbol{u}_7$, uočljivo je na slikama 2.20b - 2.20e gdje je prikazan je vektor napona $\boldsymbol{u}$ amplitude U_m pod različitim kutovima θ_{re}. Lijeva slika prikazuje vektor napona formiran primjenom trofaznog simetričnog napajanja na stator PMSG-a kako je opisano u potpoglavlju 2.4.1. S druge strane, na desnim slikama prikazan je vektor napona iste amplitude i položaja formiran korištenjem vektora $\boldsymbol{u}_0$–$\boldsymbol{u}_7$. Budući da su naponski vektori na slikama lijevo i desno istovjetni očito je da se prikladnim uklapanjem i vremenom vođenja pojedinih IGBT sklopki može formirati naponski vektor kao što bi to bio u slučaju da je statorski namot PMSG-a napajan trofaznim simetričnim naponom.

Za određivanje potrebnog vremena vođenja IGBT tranzistora u svrhu ostvarivanja napona željene amplitude primjenom SVPWM modulacije pogodno je promotriti slučaj kada se referentni naponski vektor nalazi u sektoru **I** (slika 2.20b). Također, uz to treba pretpostaviti da vektor napona miruje budući da se promatra unutar vremena sklapanja tranzistora, T_{sw}, koje je vrlo

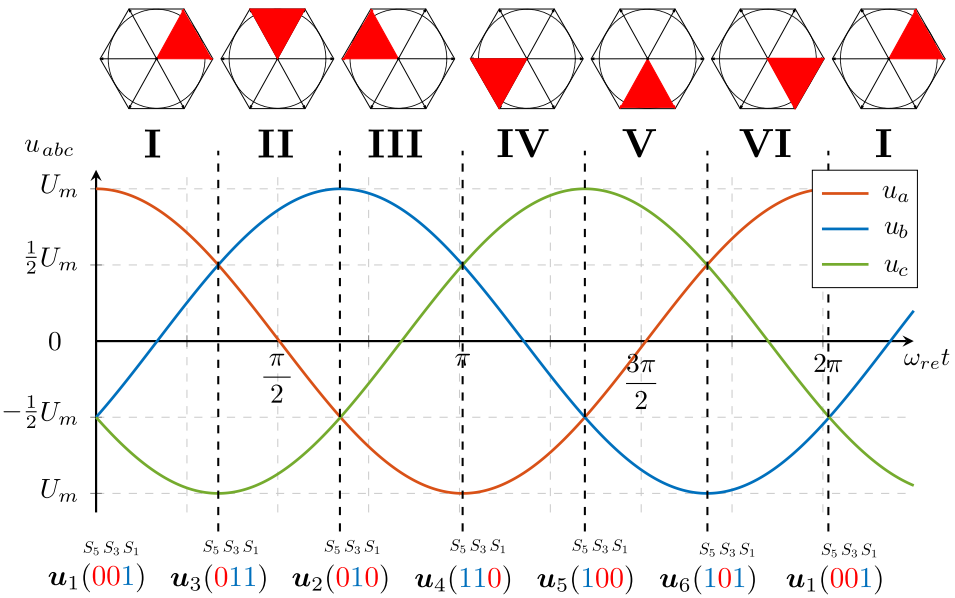

(a) Aktivni sektor ovisno o kutu referentnog napona

Slika 2.20: Formiranje naponskih vektora korištenjem SVPWM modulaciju

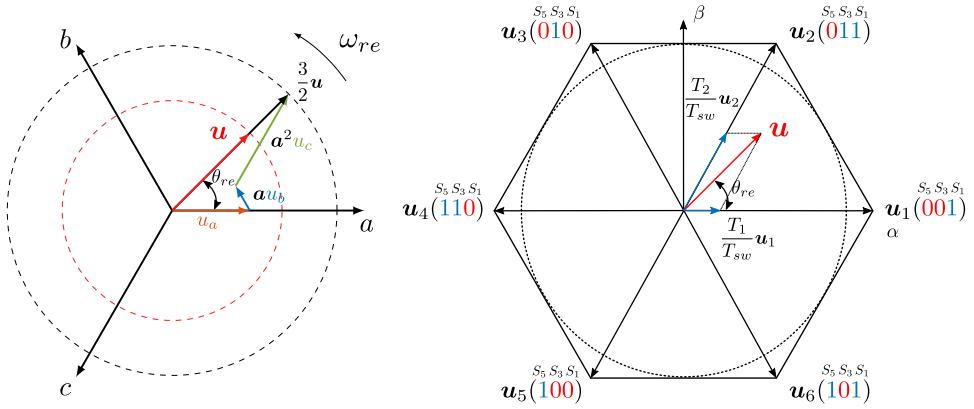

(b) Sektor **I**

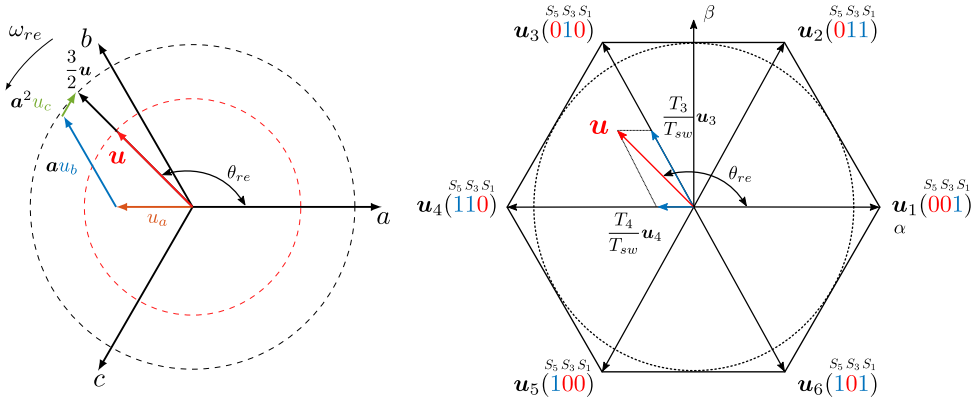

(c) Sektor **III**

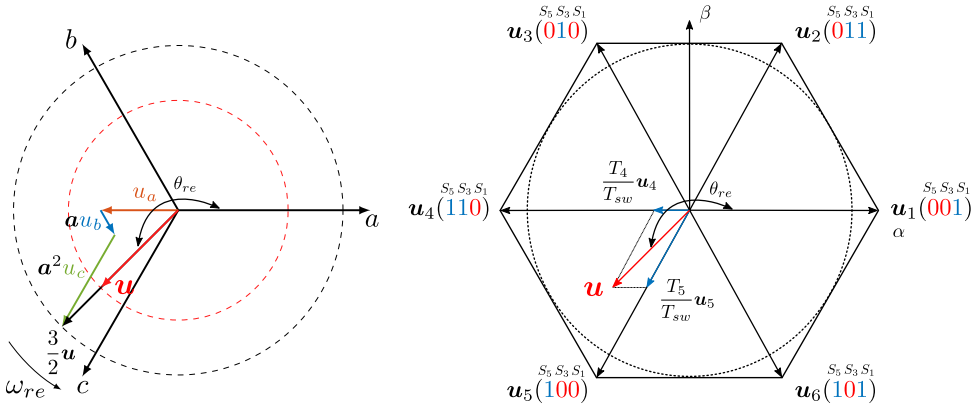

(d) Sektor **IV**

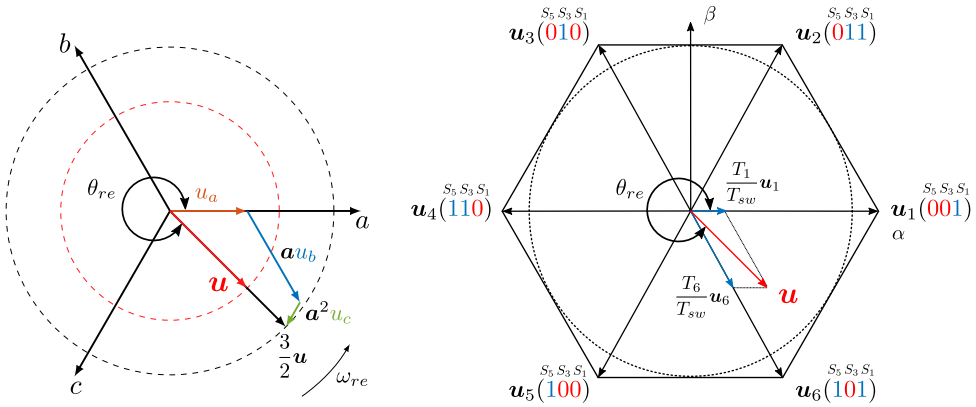

(e) Sektor **VI**

Slika 2.20: Formiranje naponskih vektora koristeći SVPWM modulaciju

kratkog trajanja.

Referentni vektor napona može se zapisati preko referentnih naponski komponenti u $\alpha\beta$ sustavu određenih od strane RFOC algoritma kao:

$$\boldsymbol{u}^* = u_\alpha^* + \mathbf{j}u_\beta^* = U_m \left(\cos\theta_{re} + \mathbf{j}\sin\theta_{re}\right), \tag{2.84}$$

gdje je U_m - amplituda vektora napona.

S obzirom da se referentni vektor napona promatra u kvadrantu **I**, moguće ga je zapisati i pomoću vektora napona $\boldsymbol{u}_1$ i $\boldsymbol{u}_2$:

$$\boldsymbol{u}^* = \frac{T_1}{T_{sw}}\boldsymbol{u}_1 + \frac{T_2}{T_{sw}}\boldsymbol{u}_2, \tag{2.85}$$

gdje je T_1 - vrijeme trajanja vektora $\boldsymbol{u}_1$, T_2 - vrijeme trajanja vektora $\boldsymbol{u}_2$, a T_{sw} - vrijeme trajanja jednog PWM ciklusa.

Nadalje, uz činjenicu da je amplituda vektora $|\boldsymbol{u}_1| = |\boldsymbol{u}_2| = 2U_{dc}/3$, vektori $\boldsymbol{u}_1$ i $\boldsymbol{u}_2$ mogu se raspisati u $\alpha\beta$ sustavu kao:

$$\boldsymbol{u}_1 = u_\alpha = \frac{2U_{dc}}{3}, \quad \boldsymbol{u}_2 = u_\alpha + \mathbf{j}u_\beta = \frac{U_{dc}}{3} + \mathbf{j}\frac{U_{dc}}{\sqrt{3}}. \tag{2.86}$$

Uvrštavanjem (2.86) u (2.85), referentni vektor napona može se zapisati u $\alpha\beta$ koordinatnom sustavu i preko komponenti vektora $\boldsymbol{u}_1$ i $\boldsymbol{u}_2$:

$$\boldsymbol{u}^* = u_\alpha^* + \mathbf{j}u_\beta^* = \frac{T_1}{T_{sw}}\frac{2U_{dc}}{3} + \frac{T_2}{T_{sw}}\frac{U_{dc}}{3} + \mathbf{j}\frac{T_2}{T_{sw}}\frac{U_{dc}}{\sqrt{3}}. \tag{2.87}$$

Izjednačavanjem α i β komponenata u izrazima (2.87) i (2.84) mogu se odrediti vremena trajanja naponskih vektora $\boldsymbol{u}_1$ i $\boldsymbol{u}_2$ kao:

$$T_1 = mT_{sw}\sin\left(\frac{\pi}{3} - \theta_{re}\right), \tag{2.88}$$

$$T_2 = mT_{sw}\sin\theta_{re}, \tag{2.89}$$

gdje je $m = U_m/(U_{dc}/\sqrt{3})$ - faktor modulacije.

Prethodna vremena trajanja aktivnih vektora za slučaj sektora **I** mogu se proširiti na ostale sektore pa općeniti izraz za proračun trajanja vektora $\boldsymbol{u}_k$ i $\boldsymbol{u}_{k+1}$ ovisno o trenutnom sektoru u kojemu se nalazi referentni vektor napona $\boldsymbol{u}^*$ glase:

$$T_k = mT_{sw}\sin\left(\frac{k\pi}{3} - \alpha\right), \tag{2.90}$$

$$T_{k+1} = mT_{sw}\sin\left(\alpha - \frac{(k-1)\pi}{3}\right), \tag{2.91}$$

gdje je k - sektor u kojem se nalazi referentni vektor napona $\boldsymbol{u}^*$, a $\alpha \in [0, \pi/3]$ - kut unutar pojedinog sektora.

Trajanja nul-vektora $\boldsymbol{u}_0$ i $\boldsymbol{u}_7$ računaju se kao ostatak perioda modulacije T_{sw} u kojem nisu aktivni neki od vektora $\boldsymbol{u}_1$–$\boldsymbol{u}_6$:

$$T_0 + T_7 = T_{sw} - T_k - T_{k+1}. \tag{2.92}$$

Kako bi se opterećenja tranzistora jednako raspodijelila najčešće se biraju jednaka vremena trajanja nul-vektora $\boldsymbol{u}_0$ i $\boldsymbol{u}_7$ pa se može pisati:

$$T_0 = T_7 = \frac{T_{sw} - T_k - T_{k+1}}{2}. \tag{2.93}$$

Prema prethodno objašnjenom principu SVPWM-a na slici 2.21 prikazan je primjer vremena vođenja tranzistora S_1, S_3 i S_5 za referentni vektor napona $\boldsymbol{u}$ koji se nalazi u sektoru **I**.

Ovako provedenom modulacijom omogućena je bolja iskoristivost napona istosmjernog međukruga budući da je maksimalni iznos faznog napona koji se može postići u slučaju SVPWM modulacije $U_{dc}/\sqrt{3}$, za razliku od također često korištene sinusne modulacije (engl. *Sine Pulse Width Modulation*, SPMW) kod koje maksimalna amplituda napona iznosi $U_{dc}/2$. Međutim, u primjeni se također susreću i modificirane SPWM modulacijske tehnike poput injektiranja signala trećeg harmonika napona (engl. *Third Harmonic Injection PWM*, THIPWM) ili injektiranja nulte komponente napona (engl. *Symmetrical PWM*, SYPWM). Primjenom ovih modifikacija SPWM tehnike, također se može osigurati postizanje maksimalnog faznog napona iznosa $U_{dc}/\sqrt{3}$.

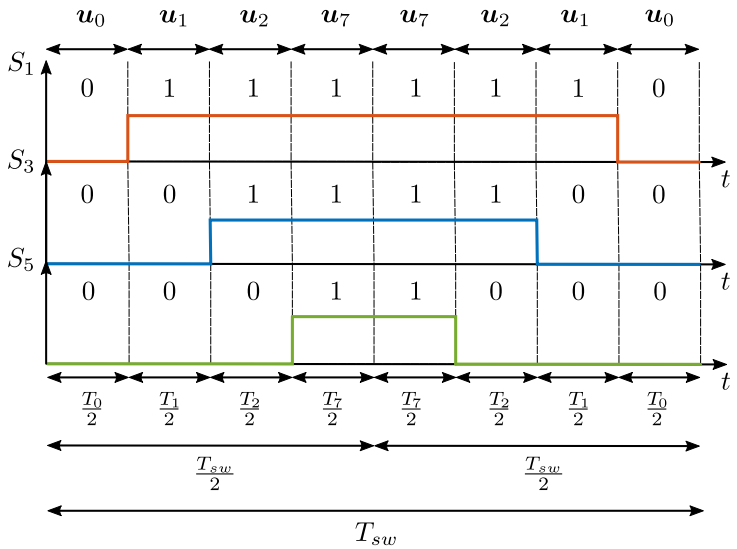

Slika 2.21: Primjer vođenja tranzistora prema SVPWM za vektor napona $\boldsymbol{u}$ u sektoru **I**

3.Teorija kliznih režima

Klizni režimi svojstveni su sustavima s promjenjivom strukturom (engl. *Variable Structure Systems*, VSS) koja je uzrokovana nelinearnom diskontinuiranom promjenom parametara sustava ili upravljačkog ulaza [20] te se kao takvi često pojavljuju i koriste u upravljačkim ili estimacijskim strukturama.

3.1.Primjeri sustava s kliznim režimom

3.1.1.Klizni režim u mehaničkom sustavu

Jedan od najjednostavnijih sustava u kojemu dolazi do pojave kliznog režima jest sustav mase i opruge s Coulombovim trenjem (slika 3.1a) čija je dinamika slobodnih oscilacija opisana nelinearnom i nehomogenom diferencijalnom jednadžbom drugog reda [44]:

$$m\ddot{x} + b\text{sign}(\dot{x}) + kx = 0, \tag{3.1}$$

gdje je $\ddot{x}$ - ubrzanje mase, $\dot{x}$ - brzina mase, x - položaj mase, b - sila trenja i k - krutost opruge.

Nelinearnost dinamičke jednadžbe (3.1) posljedica je Coulombovog trenja koje karakterizira promjenjivost smjera djelovanja sile trenja ovisno o smjeru brzine mase kao što je prikazano na slici 3.1b te je iz tog razloga drugi član dinamičke jednadžbe sustava (3.1), koji predstavlja silu

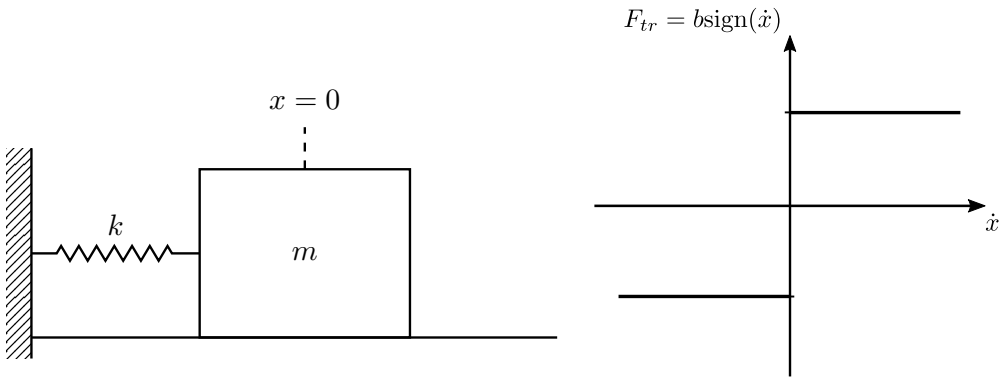

(a) Sustav mase i opruge (b) Coulombovo trenje

Slika 3.1: Dinamički sustav mase i opruge s Coulombovim trenjem

trenja opisan funkcijom signum:

$$b\text{sign}(\dot{x}) = \begin{cases} b, & \dot{x} > 0 \\ -b, & \dot{x} < 0, \end{cases} \tag{3.2}$$

gdje je $b = \mu mg$, μ - koeficijent trenja, a g - gravitacijska konstanta.

Promjenom smjera sile trenja dolazi i do promjene strukture dinamičkog sustava pa se sustav opisan diferencijalnom jednadžbom (3.1) može razdvojiti na dva podsustava:

$$\begin{cases} m\ddot{x} + b + kx = 0, & \dot{x} > 0 \\ m\ddot{x} - b + kx = 0, & \dot{x} < 0. \end{cases} \tag{3.3}$$

Iz izraza (3.3) vidljiva je promjenjivost strukture dinamičkog sustava mase i opruge s Coulombovim trenjem ovisno o smjeru brzine gibanja mase čime je ostvaren uvjet za pojavu kliznog režima.

U svrhu daljnjeg razmatranja promatrani dinamički sustav može se zapisati u prostoru stanja kao:

$$\dot{\mathbf{z}} = \begin{cases} \dot{z}_1 = \dot{x} \\ \dot{z}_2 = -\frac{b}{m}\text{sign}(\dot{z}_1) + \frac{k}{m}z_1, \end{cases} \tag{3.4}$$

gdje je $z_1 = x$, a $z_2 = \dot{x}$.

Iz zapisa sustava u prostoru stanja očito je da pravac $\dot{x} = 0$ predstavlja diskontinuitet s obzirom da funkcija signum iz (3.2) nije definirana pri brzini $\dot{x} = 0$. Taj prekid očituje se u faznom portretu tako što su tangencijalni vektori svih trajektorija sustava unutar segmenta $|x| \leq \frac{b}{k}$ usmjereni prema pravcu $\dot{x} = 0$ kao što je vidljivo na slici 3.2a. Drugim riječima, kada masa m unutar segmenta $|x| \leq \frac{b}{k}$ i u trenutku t_0 postigne brzinu $\dot{x}(t_0) = 0$, ona se trajno zadržava na zaustavljenom položaju $x(t_0) \in [-\frac{b}{k}, \frac{b}{k}]$ budući da je u tom slučaju iznos sile trenja veći od iznosa elastične sile, $b > k|x|$. Segment $|x| \leq \frac{b}{k}$ na pravcu diskontinuiteta $\dot{x} = 0$ naziva se klizna ploha (engl. *sliding surface*) ili ploha prekapčanja (engl. *switching surface*) zbog toga što sve trajektorije sustava teže k pravcu $\dot{x} = 0$, a nakon što ga dosegnu ostaju na njemu za $\forall t > t_0$ [44].

Na slici 3.2b prikazano je šest trajektorija koje opisuju prigušene oscilacije sustava (3.1) uz različite početne uvjete x_0. U skladu s ranijim opisom, vidljivo je da dinamički sustav (3.1) postiže stabilna ravnotežna stanja u različitim točkama na pravcu $\dot{x} = 0$ unutar segmenta $|x| \leq \frac{b}{k}$ ovisno o početnim uvjetima. Uvećavanjem jedne od ravnotežnih točki sustava uočava se gibanje trajektorije po kliznoj plohi sustava $\dot{x} = 0$ uzrokovano diskontinuitetom sustava na pravcu $\dot{x} = 0$ te činjenicom da je unutar segmenta $|x| \leq \frac{b}{k}$ vrijedi da je iznos sile trenja veći od elastične sile pa

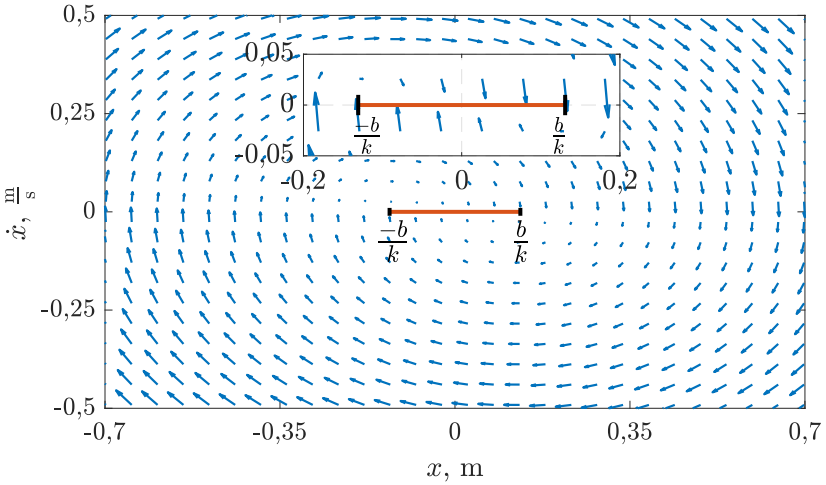

(a) Fazni portret dinamičkog sustava s Coulombovim trenjem

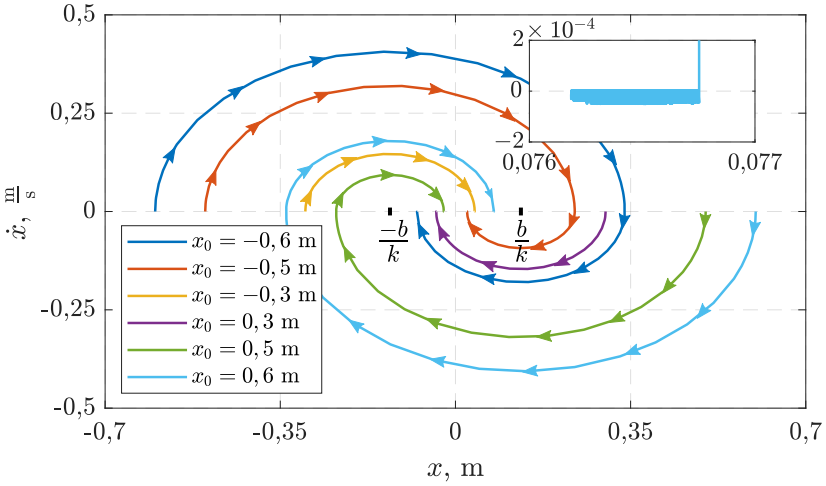

(b) Trajektorije dinamičkog sustava s Coulombovim trenjem

Slika 3.2: Fazni portret i trajektorije sustava mase i opruge s Coulombovim trenjem

su smjer gibanja mase i smjer djelovanja sile uvijek suprotnog smjera:

$$\begin{cases} m\ddot{x} < 0, & \dot{x} > 0 \\ m\ddot{x} > 0, & \dot{x} < 0. \end{cases} \tag{3.5}$$

Ovakvo gibanje trajektorija sustava po kliznoj plohi naziva se klizni režim [44].

3.1.2.Klizni režim u električnom sustavu

Električni sustavi promjenjive strukture česta su pojava, a najčešće su uzrokovani primjenom različitih vrsta energetskih pretvarača. Razlog leži u činjenici da sastavni dio energetskih pretvarača čine poluvodičke komponente poput tranzistora koji mogu poprimiti dva stanja: 0 - kada ne provode i 1 - kada provode struju.

Jednostavan primjer takvog sustava je silazni DC-DC pretvarač prikazan na slici 3.3a. S obzirom na prisutnost tranzistora T unutar električnog kruga, silazni DC-DC pretvarač može se razdvojiti na dva podsustava. Električni krug silaznog DC-DC pretvarača pri uključenom tranzistoru T prikazan je na slici 3.3b, dok je električni krug silaznog DC-DC pretvarača za vrijeme isključenog tranzistora T prikazan na slici 3.3c. Zbog ovakve promjenjive strukture, diferencijalna jednadžba koja opisuje dinamiku izlaznog napona $u_o = u_c$ rastavljena je na dva dijela:

$$\begin{cases} \ddot{u}_c + \frac{1}{RC}\dot{u}_c + \frac{1}{LC}u_c = \frac{U}{LC}, & \mathrm{T} = ON \\ \ddot{u}_c + \frac{1}{RC}\dot{u}_c + \frac{1}{LC}u_c = 0, & \mathrm{T} = OFF, \end{cases} \tag{3.6}$$

što se jednostavnije može zapisati kao:

$$\ddot{u}_c + b\dot{u}_c + au_c = aUu, \tag{3.7}$$

gdje je $a = \frac{1}{LC}$, $b = \frac{1}{RC}$, a upravljački ulaz

$$u = \begin{cases} 1, & \mathrm{T} = ON \\ 0, & \mathrm{T} = OFF. \end{cases} \tag{3.8}$$

Prethodna diferencijalna jednadžba silaznog DC-DC pretvarača (3.7) može se zapisati i u

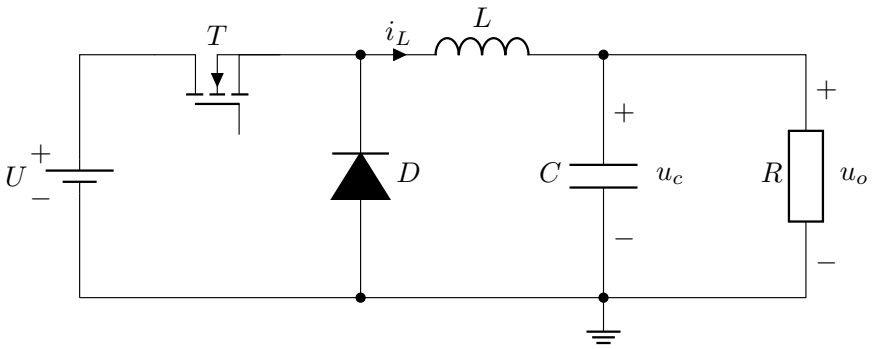

(a) Silazni DC-DC pretvarač

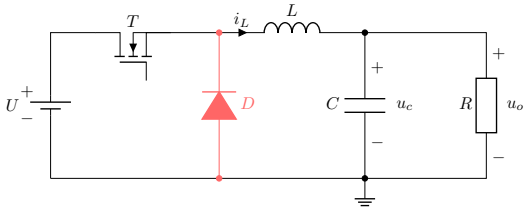

(b) Tranzistor $T = ON$ - struja ne teče kroz diodu D

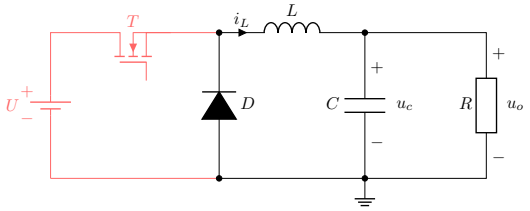

(c) Tranzistor $T = OFF$ - struja ne teče kroz izvor U i tranzistor T

Slika 3.3: Silazni DC-DC pretvarač

prostoru stanja kao:

$$\dot{\mathbf{x}} = \begin{cases} \dot{x}_1 = \dot{u}_c \\ \dot{x}_2 = -ax_1 - bx_2 + aUu, \end{cases} \tag{3.9}$$

gdje je $x_1 = u_c$, a $x_2 = \dot{u}_c$.

Očito je da dinamika sustava (3.9) ovisi o stanju upravljačkog ulaza u pa tako u slučaju kada je tranzistor T uključen ($u = 1$) trajektorije sustava teže k stabilnoj ravnotežnoj točki $(U, 0)$, dok je u slučaju isključenog tranzistora ($u = 0$) stabilna ravnotežna točka sustava $(0, 0)$ kao što je prikazano na slici 3.4. Osim trajektorija sustava ovisnih o upravljačkom ulazu u, zanimljivo je promotriti i pravac $s(\mathbf{x}) = 0$ (detaljniji opis dan je u poglavlju 3.2) koji prostor stanja $\{x_1, x_2\} = \{u_c, \dot{u}_c\}$ dijeli na dva potprostora. Za potprostor $s(\mathbf{x}) > 0$ trajektorije će biti usmjerene prema pravcu $s(\mathbf{x}) = 0$ ukoliko se upravljački ulaz sustava (3.9) postavi u $u = 0$. S druge strane, uz primjenu upravljačkog ulaza $u = 1$ trajektorije će također biti usmjerene prema pravcu $s(\mathbf{x}) = 0$ i u dijelu prostora stanja $s(\mathbf{x}) < 0$. Ukoliko se uvjet preklapanja upravljačkog ulaza u iz (3.8) postavi na prethodno opisan način, odnosno ovisno o položaju varijabli stanja u odnosu na pravac $s(\mathbf{x}) = 0$:

$$u = \begin{cases} 1, & \mathrm{s}(\mathbf{x}) < 0 \\ 0, & \mathrm{s}(\mathbf{x}) > 0, \end{cases} \tag{3.10}$$

trajektoriju sustava (3.9) moguće je, iz određenog početnog stanja, dovesti na pravac $s(\mathbf{x}) = 0$ koji predstavlja kliznu plohu ili plohu prekapčanja sustava. Dinamika trajektorije sustava iz početnog stanja $(0, 0)$ do klizne plohe, označena s ① na slici 3.4, naziva se faza dohvaćanja klizne plohe (engl. *reaching mode*). Nakon što trajektorija dostigne kliznu plohu $s(\mathbf{x}) = 0$, počinje se gibati po njoj do stabilne ravnotežne točke $(U_{ref}, 0)$ (označeno s ② na slici 3.4). S obzirom da se trajektorija sustava giba po kliznoj plohi, sustav se nalazi u kliznom režimu.

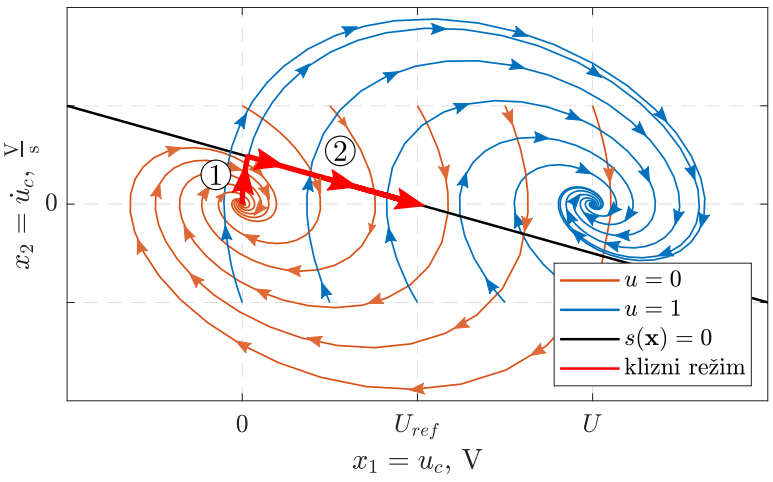

Slika 3.4: Fazni portret silaznog DC-DC pretvarača u kliznom režimu

3.2.Uvjeti postojanja kliznog režima

U potpoglavlju 3.1 pokazano je kako se klizni režimi pojavljuju isključivo u sustavima s promjenjivom strukturom, a jedan od načina za postizanje promjenjive strukture sustava je primjena diskontinuiranog upravljačkog ulaza u koji mijenja svoje stanje na temelju položaja varijabli stanja sustava u odnosu na kliznu plohu $s(\mathbf{x}) = 0$. Međutim, iako nužan, sustav s promjenjivom strukturom uzrokovanom diskontinuiranim upravljačkim ulazom u, nije i dovoljan uvjet za postizanje kliznog režima, već je, kako bi se klizni režim postigao, potrebno odabrati prikladnu funkciju prekapčanja $s(\mathbf{x})$ i upravljački ulaz u točno određenih svojstava.

Pri analizi odabira prikladne funkcije prekapčanja i upravljačkog ulaza koristi se opći zapis kontinuiranog vremenski nepromjenjivog linearnog sustava s poremećajem:

$$\dot{\mathbf{x}}(t) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t) + \mathbf{f}(t, \mathbf{x}, \mathbf{u}) \tag{3.11}$$

gdje je $\mathbf{A} \in \mathbb{R}^{n\times n}$ - matrica dinamike sustava, $\mathbf{B} \in \mathbb{R}^{n\times m}$ - ulazna matrica, $\mathbf{x} \in \mathbb{R}^n$ - vektor varijabli stanja, t - vrijeme, a $\mathbf{u}(t) \in \mathbb{R}^m$ - diskontinuirani upravljački zakon

$$\mathbf{u}(t) = \begin{cases} U^+, & s_i(\mathbf{x}) > 0, \\ U^-, & s_i(\mathbf{x}) < 0, \end{cases} \qquad i = 1, ..., m \tag{3.12}$$

Funkcija $\mathbf{f} : \mathbb{R} \times \mathbb{R}^n \times \mathbb{R}^m \mapsto \mathbb{R}^m$ predstavlja omeđeni poremećaj u sustavu koji može biti uzrokovan promjenom parametara sustava ili različitim nelinearnostima sustava.

Nadalje, neka je unutar prostora stanja $\{x_1, ..., x_n\}$ sustava (3.11) definirana linearna* funkcija $\mathbf{s}(\mathbf{x}) : \mathbb{R}^n \to \mathbb{R}^m$ kao:

$$s(\mathbf{x}) = \mathbf{S}\mathbf{x}, \tag{3.13}$$

gdje je $\mathbf{S} \in \mathbb{R}^{m\times n}$ matrica prekapčanja.

Linearna funkcija $s(\mathbf{x})$ predstavlja funkciju prekapčanja pa se klizna ploha unutar prostora stanja sustava (3.11) može definirati kao:

$$\mathcal{S} = \{\mathbf{x} \in \mathbb{R}^n \quad : \quad s(\mathbf{x}) = 0\}. \tag{3.14}$$

Kako bi se osigurao klizni režim unutar sustava (3.11) nužno je da funkcija prekapčanja $s(\mathbf{x})$ i upravljački ulaz $\mathbf{u}(t)$ osiguraju ponašanje sustava prema definiciji kliznog režima [45]:

Definicija 1. *Neka je t_s konačno vrijeme takvo da rješenje sustava* (3.11) $\mathbf{x}(t)$ *zadovoljava*

$$s(t) = \mathbf{S}\mathbf{x}(t) = 0, \quad \forall t \geq t_s.$$

*funkcija $s(\mathbf{x})$ ne mora nužno biti linearna, ali se često odabire upravo linearna funkcija zbog jednostavnosti projektiranja i implementacije sustava upravljanja

Tada kažemo da se sustav (3.11) *nalazi u kliznom režimu za* $\forall t > t_s$.

Drugim riječima, odabir funkcije prekapčanja $s(\mathbf{x})$ i upravljačkog ulaza $\mathbf{u}(t)$ treba biti takav da se osigura:

1.uvjet dohvaćanja klizne plohe,

2.uvjet postojanja kliznog režima i

3.stabilnu dinamiku sustava na kliznoj plohi tijekom kliznog režima.

Ovdje je bitno razdvojiti kliznu plohu $s(\mathbf{x}) = 0$ koja predstavlja vremenski neovisan potprostor stanja sustava od funkcije prekapčanja $s(t) = \mathbf{S}\mathbf{x}(t)$ koja je vremenski promjenjiva funkcija trenutačnog položaja trajektorije sustava u odnosu na kliznu plohu $s(\mathbf{x}) = 0$.

3.2.1.Uvjet dohvaćanja klizne plohe

Uvjet dohvaćanja klizne plohe $\mathcal{S}$ i uvjet postojanja kliznog režima na istoj kliznoj plohi usko su povezani te ih je najprikladnije razmotriti na sustavu drugog reda, odnosno za $\mathbf{x} \in \mathbb{R}^2$. Prostor stanja sustava drugog reda podijeljen je kliznom plohom $\mathcal{S}$ na dva potprostora:

$$\begin{aligned} \mathcal{R}^+ &= \{\mathbf{x} \in \mathbb{R}^2 \quad : \quad s(\mathbf{x}) > 0\}, \\ \mathcal{R}^- &= \{\mathbf{x} \in \mathbb{R}^2 \quad : \quad s(\mathbf{x}) < 0\}. \end{aligned} \tag{3.15}$$

Kako bi trajektorija sustava dohvatila kliznu plohu $\mathcal{S}$ iz nekog početnog uvjeta, gibanje trajektorije uvijek mora biti usmjereno prema okolini klizne plohe kao što je prikazano na slici 3.5a, neovisno o tome nalazi li se početni uvjet u potprostoru $\mathcal{R}^+$ ili $\mathcal{R}^-$. Okolina klizne plohe definirana je kao:

$$\Omega \subset \mathbb{R}^2 = \{\mathbf{x} \in \mathbb{R}^2 \quad : \quad 0 < |s(\mathbf{x})| < \delta\}. \tag{3.16}$$

Uz pretpostavku početnog uvjeta $\mathbf{x}_0 = \mathbf{x}(t = 0)$, udaljenog od klizne plohe $\mathcal{S}$, nužan i dovoljan uvjet da se takvo gibanje ostvari je da upravljački zakon $\mathbf{u}(t)$ osigura sljedeću nejednakost:

$$s(t)\dot{s}(t) < 0. \tag{3.17}$$

Nejednakost (3.17) naziva se globalni uvjet dohvaćanja klizne plohe (slika 3.5a).

3.2.2.Uvjet postojanja kliznog režima

Uvjet dohvaćanja (3.17) osigurava usmjerenost trajektorije sustava prema kliznoj plohi. Međutim, sama usmjerenost trajektorije prema kliznoj plohi nije dovoljna kako bi se osiguralo postojanje kliznog režima, već je nužno osigurati da trajektorija u konačnom vremenu dostigne kliznu plohu te se nastavi gibati po njoj zauvijek, odnosno do trenutka postizanja stabilne ravnotežne točke sustava. To znači da trajektorija mora i lokalno, unutar okoline Ω, također biti usmjerena prema

kliznoj plohi $\mathcal{S}$. Uvjet lokalne usmjerenosti trajektorije prema kliznoj plohi matematički se može zapisati kao [45]:

$$\begin{aligned} \lim_{s(t)\to 0^+} \dot{s}(t) < 0, \\ \lim_{s(t)\to 0^-} \dot{s}(t) > 0. \end{aligned} \tag{3.18}$$

Iz izraza (3.18) može se zaključiti da kada trajektorija prilazi kliznoj plohi $\mathcal{S}$ iz potprostora $\mathcal{R}^+$ unutar okoline Ω, gdje vrijedi $s(t) > 0$, funkcija prekapčanja $s(t)$ opada približavanjem trajektorije kliznoj plohi. S druge strane, ako trajektorija prilazi kliznoj plohi $\mathcal{S}$ iz potprostora $\mathcal{R}^-$ unutar okoline Ω, u kojem vrijedi $s(t) < 0$, funkcija prekapčanja $s(t)$ raste što je trajektorija bliže kliznoj plohi (slika 3.5b).

Pojednostavljeno, izraz (3.18) govori da funkcija prekapčanja $s(t)$ i njena derivacija $\dot{s}(t)$ unutar okoline Ω klizne plohe $\mathcal{S}$ moraju biti suprotnog predznaka. Prema tome, izraz za lokalnu usmjerenost trajektorije prema kliznoj plohi iz (3.18) može se alternativno iskazati na isti način kao i globalni uvjet dohvaćanja klizne plohe iz (3.17).

Međutim, izrazi (3.17) i (3.18) prema Ljapunovljevoj teoriji stabilnosti uz kandidata za Ljapunovljevu funkciju:

$$V(t) = \frac{1}{2}s^2(t), \tag{3.19}$$

postižu tek asimptotsko dohvaćanje klizne plohe $\mathcal{S}$ [46] s obzirom na to da vrijedi $\dot{V}(t) < 0$. Ovakvo asimptotsko ponašanje osigurava $\lim_{t\to\infty} s(t) = 0$ što nije dovoljno da se zadovolji Definicija 1 za klizni režim budući da se u ovom slučaju klizna ploha $\mathcal{S}$ ne dostiže u konačnom vremenu, već kada $t \to \infty$.

Ovaj problem može se nadići uz preinaku globalnog uvjeta dohvaćanja iz (3.17) u:

$$s(t)\dot{s}(t) \leq -\eta|s(t)|, \tag{3.20}$$

gdje je $\eta > 0$.

Integriranjem prethodnog izraza od 0 do t_s dobiva se nejednakost:

$$|s(t_s)| - |s(0)| \leq -\eta t_s, \tag{3.21}$$

iz koje je očito da funkcija prekapčanja postiže vrijednost $s(t) = 0$ u vremenu $t_s \leq \frac{|s(0)|}{\eta}$. Prema tome, izraz (3.20) naziva se uvjet postojanja kliznog režima budući da zadovoljava Definiciju 1, odnosno osigurava dostizanje klizne plohe $\mathcal{S}$ u konačnom vremenu t_s [45].

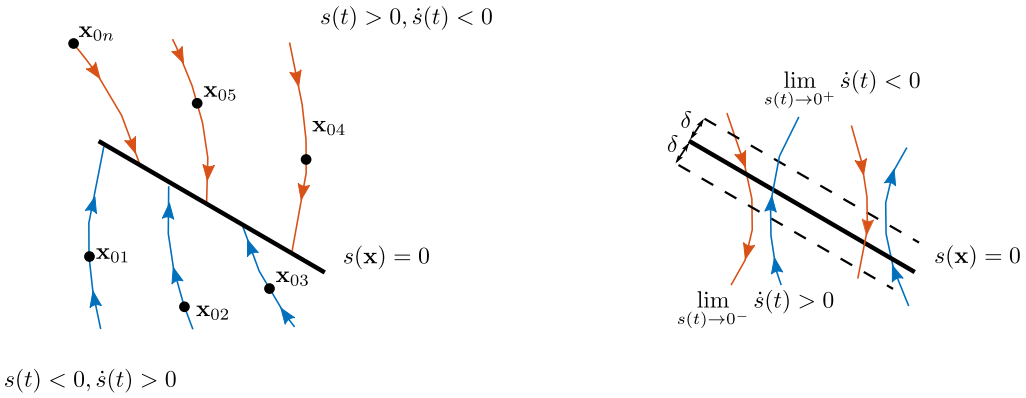

(a) Uvjet dostizanja klizne plohe (b) Uvjet postojanja kliznog režima

Slika 3.5: Uvjeti postojanja kliznog režima

3.3.Dinamika i stabilnost sustava u kliznom režimu

U svrhu jednostavnije analize sustava u kliznom režimu, prikladno je zanemariti funkciju poremećaja, $\mathbf{f}(t, \mathbf{x}, \mathbf{u}) = 0$, pa sustav (3.11) postaje:

$$\dot{\mathbf{x}}(t) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t) \tag{3.22}$$

Kada trajektorija sustava dostigne kliznu plohu, njena dinamika ne može se opisati klasičnom teorijom diferencijalnih jednadžbi zbog toga što upravljački zakon poput (3.10) nije definiran na kliznoj plohi $\mathcal{S}$, odnosno kada vrijedi $s(\mathbf{x}) = 0$, čime se u diferencijalnu jednadžbu sustava (3.22) unosi diskontinuitet te nisu zadovoljeni Lipschitzovi uvjeti koji osiguravaju postojanje jedinstvenog rješenja sustava [45]. Postoji nekoliko pristupa rješavanju ovog problema [47], no najzastupljeniji su Filipovljev pristup [48] i metoda ekvivalentnog upravljanja (engl. *equivalent control*). Filipovljeva metoda temelji se na određivanju smjera gibanja trajektorije na kliznoj plohi $\mathcal{S}$ pomoću rezultantnog vektora brzine promjene stanja u okolini klizne plohe. Takav rezultantni vektor zapravo predstavlja tangencijalni vektor klizne plohe kojim je određen smjer gibanja trajektorije [48].

S druge strane, u metodi ekvivalentnog upravljanja određuje se upravljački zakona $\mathbf{u}(t)$ koji će osigurati gibanje trajektorije sustava na kliznoj plohi $\mathcal{S}$. S obzirom na to da tijekom gibanja trajektorije na kliznoj plohi $\mathcal{S}$ vrijedi $\dot{s}(\mathbf{x}) = 0$, ekvivalentni upravljački zakon za sustav (3.22) može se odrediti kao [49]:

$$\mathbf{u}_{eq}(t) = -[\mathbf{SB}]^{-1}\mathbf{SA}\mathbf{x}(t). \tag{3.23}$$

3.3.1.Stabilnost sustava u kliznom režimu

Osim osiguravanja uvjeta dostizanja i uvjeta postojanja kliznog režima, nužno je da trajektorija sustava, jednom kada dohvati kliznu plohu $\mathcal{S}$ i uđe u klizni režim, dostigne stabilnu ravnotežnu točku. U suprotnom dinamika sustava u kliznom režimu nije stabilna. S obzirom da ekvivalentni upravljački zakon (3.23), koji definira dinamiku sustava na kliznoj plohi, ovisi o matrici prekapčanja $\mathbf{S}$, očito je da je za postizanje stabilne dinamike sustava ključan odabir prikladne klizne plohe $s(\mathbf{x})$.

Uvrštavanjem upravljačkog zakona (3.23) u jednadžbu sustava (3.22) dobiva se dinamika sustava u kliznom režimu:

$$\dot{\mathbf{x}}(t) = \mathbf{A}_{eq}\mathbf{x}(t), \tag{3.24}$$

gdje je $\mathbf{A}_{eq} = [\mathbf{I} - \mathbf{B}[\mathbf{SB}]^{-1}\mathbf{S}]\mathbf{A}$.

Dinamika sustava u kliznom režimu određena prethodnom jednadžbom bit će stabilna ukoliku su realni dijelovi svojstvenih vrijednosti matrice $\mathbf{A}_{eq}$ negativni.

Međutim, iz izraza (3.24) nije jednostavno odrediti uvjet stabilnosti. U svrhu jednostavnije analize u nastavku će se podrazumijevati da je $m = 1$, odnosno da je ulazna matrica $\mathbf{B}$ zapravo vektor stupac $\mathbf{b} \in \mathbb{R}^{n\times 1}$ (skalarni ulaz) pa sustav (3.22) postaje:

$$\dot{\mathbf{x}}(t) = \mathbf{A}\mathbf{x}(t) + \mathbf{b}u(t). \tag{3.25}$$

Također, kako bi se lakše odredila povezanost stabilnosti dinamike sustava u kliznom režimu s odabirom klizne plohe, pogodno je sustav (3.25) zapisati u regularnoj formi, koristeći transformaciju koordinata $\mathbf{x}_r(t) = \mathbf{T}\mathbf{x}(t)$, [50]:

$$\dot{\mathbf{x}}_r(t) = \mathbf{A}_r\mathbf{x}_r(t) + \mathbf{b}_r u(t), \tag{3.26}$$

gdje je $\mathbf{x}_r(t) = [\mathbf{x}_{r1}(t) \in \mathbb{R}^{n-1} \quad \mathbf{x}_{r2}(t) \in \mathbb{R}^1]^{\mathrm{T}}$, $\mathbf{A}_r = \mathbf{TAT}^{-1} = \begin{bmatrix} \mathbf{A}_{11} & \mathbf{A}_{12} \\ \mathbf{A}_{21} & \mathbf{A}_{22} \end{bmatrix}$, $\mathbf{b}_r = \mathbf{Tb} = [0 \quad \mathbf{b}_2 \in \mathbb{R}^{1\times 1}]^{\mathrm{T}}$.

Matrica prekapčanja u transformiranom koordinatnom sustavu glasi $\mathbf{S}_r = \mathbf{ST}^{-1}$ pa transformirana funkcija prekapčanja $s_r(\mathbf{x})$ postaje:

$$s_r(t) = \mathbf{S}_r\mathbf{x}_r(t) = [\mathbf{S}_1 \quad \mathbf{S}_2][\mathbf{x}_{r1}(t) \quad \mathbf{x}_{r2}(t)]^T, \tag{3.27}$$

gdje su $\mathbf{S}_1 \in \mathbb{R}^{1\times(n-1)}$ i $\mathbf{S}_2 \in \mathbb{R}^{1\times 1}$.

Tijekom kliznog režima vrijedi $s_r(t) = 0$ što rezultira izrazom:

$$\mathbf{S}_1\mathbf{x}_{r1}(t) + \mathbf{S}_2\mathbf{x}_{r2}(t) = 0, \tag{3.28}$$

iz čega slijedi

$$\mathbf{x}_{r2}(t) = -\mathbf{M}\mathbf{x}_{r1}(t), \tag{3.29}$$

gdje je $\mathbf{M} = \mathbf{S}_2^{-1}\mathbf{S}_1$.

Uvrštavanjem prethodnog izraza u regularnu jednadžbu sustava (3.26) dobiva se njegova dinamika tijekom kliznog režima:

$$\dot{\mathbf{x}}_{r1}(t) = \mathbf{A}_{r,eq}\mathbf{x}_{r1}(t), \tag{3.30}$$

gdje je $\mathbf{A}_{r,eq} = (\mathbf{A}_{11} - \mathbf{A}_{12}\mathbf{M})$.

Prema (3.30) dinamika sustava u regularnoj formi bit će stabilna ukoliko matrica $\mathbf{A}_{r,eq}$ ima stabilne svojstvene vrijednosti pa je stoga potrebno odrediti vektor $\mathbf{M}$ tako da realni dijelovi svojstvenih vrijednosti matrice $\mathbf{A}_{r,eq}$ budu negativni. Za određivanje vektora $\mathbf{M}$ (ili matrice $\mathbf{M}$ ukoliko se radi o sustavu s više ulaza, $m > 1$) najčešće se koriste [45]:

1.metoda postavljanja polova sustava,

2.QR faktorizacija,

3.LMI (engl. *Linear Matrix Inequality*) metode.

Za sustav (3.25) s jednim skalarnim ulazom pogodno je koristiti metodu postavljanja polova uz regularnu formu u obliku upravljive kanonske forme u kojoj je matrica stanja:

$$\mathbf{A} = \begin{bmatrix} 0 & 1 & 0 & \dots & 0 \\ \vdots & 0 & 1 & & \vdots \\ \vdots & & \ddots & \ddots & 0 \\ 0 & & & 0 & 1 \\ -a_1 & -a_2 & \dots & \dots & -a_n \end{bmatrix}, \tag{3.31}$$

a upravljački vektor $\mathbf{b} = [0 \quad \dots \quad \dots \quad 1]^{\mathrm{T}}$.

Za ovakav sustav, prikladna funkcija prekapčanja odabire se kao linearna funkcija oblika:

$$s(t) = \sum_{i=1}^{n-1} m_i x_i(t) + x_n(t), \tag{3.32}$$

gdje je matrica prekapčanja $\mathbf{S} = [\mathbf{M} \quad 1]$, a $\mathbf{M} = [m_1 \quad \dots \quad m_{n-1}]$.

U upravljivoj kanonskoj formi, odnos varijabli stanja i njenih derivacija može se izraziti kao:

$$\dot{x}_{n-1}(t) = x_n(t). \tag{3.33}$$

S obzirom da u kliznom režimu vrijedi $s(t) = 0$, izjednačavanjem (3.32) s nulom i uvrštava-

njem u (3.33) dobiva se dinamika sustava u kliznom režimu:

$$\dot{x}_{n-1}(t) = -m_1 x_1(t) - m_2 x_2(t) - \ldots - m_{n-1} x_{n-1}(t) \tag{3.34}$$

čija karakteristična jednadžba glasi:

$$\lambda^{n-1} + m_{n-1}\lambda^{n-2} + \ldots + m_2\lambda + m_1 = 0 \tag{3.35}$$

pa se za postizanje stabilne dinamike sustava u kliznom režimu koeficijenti $m_1, \ldots, m_{n-1}$ trebaju odabrati tako da zadovolje Hurwitzov kriterij stabilnosti [45, 46]. Ukoliko se, kao primjer, promatra sustav drugog reda ($n = 2$), karakteristična jednadžba glasi:

$$\lambda + m_1 = 0 \tag{3.36}$$

pa će sustav u kliznom režimu biti stabilan za $m_1 > 0$.

Na kraju, osim razmatranja stabilnosti sustava, iz prethodne analize, odnosno iz dinamičke jednadžbe sustava u kliznom režimu (3.34) mogu se zamijetiti dva obilježja svojstvena za klizni režim:

1. smanjene reda sustava → ukoliko je red sustava n, u kliznom režimu dinamika sustava bit će reda $n - m$ te
2. dinamika sustava u kliznom režimu ne ovisi o parametrima sustava, već isključivo o parametrima klizne plohe ($m_1, \ldots, m_{n-1}$).

3.4.Odabir upravljačkog zakona

Upravljački zakon $u(t)$ potrebno je odabrati tako da se zadovolje uvjeti dohvaćanja i postojanja kliznog režima kao i uvjet stabilnosti. Uvjet dohvaćanja i postojanja za najgori slučaj iz (3.20) može zapisati kao:

$$\dot{s}(t) = -\eta \text{sign}(s(t)). \tag{3.37}$$

Nadalje, u kliznom režimu također vrijedi:

$$\dot{s}(t) = \mathbf{S}\dot{\mathbf{x}}(t) = \mathbf{SA}\mathbf{x}(t) + \mathbf{Sb}u(t). \tag{3.38}$$

Iz prethodnog izraza očito je da, kako bi se postigao uvjet dohvaćanja i postojanja kliznog režima iz (3.37), upravljački zakon treba biti oblika [46]:

$$u(t) = \underbrace{-(\mathbf{Sb})^{-1}\mathbf{SA}\mathbf{x}(t)}_{u_l = u_{eq}} \underbrace{- \eta(\mathbf{Sb})^{-1}\text{sign}(s(t))}_{u_d}. \tag{3.39}$$

Na temelju ove analize može se zaključiti da se upravljački zakon $u(t)$ dijeli na linearni dio u_l, koji je jednak ekvivalentnom upravljačkom zakonu (3.23), i na nelinearni dio u_d, kojeg čini diskontinuirana signum funkcija kao što je prikazano na slici 3.6. Ovakav upravljački zakon $u(t)$ u skladu je s do sada predstavljenom teorijom o kliznim režimima s obzirom da je pokazano da za ostvarenje kliznog režima upravljački zakon nužno mora biti diskontinuiran, a uz to, pokazano je da je za opis dinamike sustava u kliznom režimu potrebno koristiti ekvivalentni upravljački zakon.

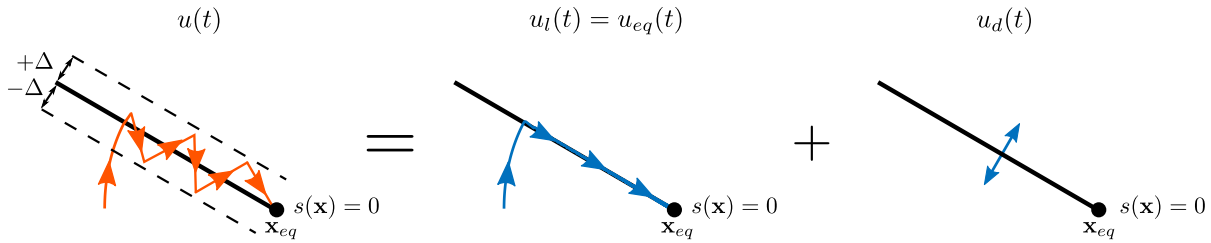

Slika 3.6: Grafički prikaz linearnog i diskontinuiranog dijela upravljačkog zakona

Ovdje treba naglasiti da linearni dio u_l, odnosno ekvivalentni upravljački zakon u_{eq}, ne predstavlja stvarni upravljački signal koji se primjenjuje na sustav. Osim toga, ukoliko se u sustavu pojavi neodređeni omeđeni poremećaj $\mathbf{f}(t, \mathbf{x}, \mathbf{u}) \neq 0$, ekvivalentni upravljački zakon ne bi bilo moguće odrediti budući da bi trebalo poznavati neodređeni poremećaj [46], što obično nije ostvarivo. Međutim, omeđeni neodređeni poremećaji u sustavu bit će kompenzirani od strane diskontinuiranog upravljačkog dijela u_d ukoliko je njegova amplituda veća od maksimalne vrijednosti poremećaja koja je u slučaju omeđenog poremećaja poznata. Iako ekvivalentni upravljački zakon ne predstavlja stvarni primijenjeni upravljački signal, on ima svoje značenje, a to je da predstavlja srednju vrijednost diskontinuiranog dijela upravljačkog zakona u_d. Objašnjenje za to leži u činjenici da je u kliznom režimu frekvencija sklapanja diskontinuiranog upravljačkog dijela u_d teoretski beskonačna, dok je širina pojasa propusnosti sustava (3.11) određena nekom konačnom frekvencijom. Drugim riječima to znači da sustav (3.11) predstavlja niskopropusni filtar za visokofrekvencijske komponente upravljačkog signala $u(t)$ pa se stoga utjecaj primijenjenog visokofrekvencijskog ulaza na sustav u kliznom režimu iskazuje preko njegove srednje vrijednosti koja predstavlja upravo ekvivalentni upravljački zakon $u_l = u_{eq}$ [45].

3.4.1.Efekt zveketanja (engl. *chattering effect*)

U dosadašnjoj analizi kliznog režima zapravo je razmatran idealni klizni režim koji podrazumijeva da se trajektorija sustava kada uđe u klizni režim giba točno po kliznoj plohi $\mathcal{S}$ (slika 3.7a). Za ostvarenje idealnog kliznog režima nužno je da upravljački zakon $u(t)$ bude beskonačne frekvencije. Međutim, u stvarnim primjenama diskontinuirani upravljački ulaz u_d je signal velike, ali ne i beskonačne frekvencije zbog pojava poput kašnjenja sklopnih uređaja. Iz tog razloga

dolazi do pojave efekta zveketanja (engl. *chattering effect*) koji se očituje u titranju trajektorije sustava oko klizne plohe $\mathcal{S}$ što je često nepoželjna pojava u primjeni na stvarnim upravljačkim sustavima zbog povećanja gubitaka, elektromagnetske interferencije i sl.

Iz tog razloga teži se smanjenju efekta zveketanja, a prvi način za to je zamjena signum funkcije unutar upravljačkog zakona $u(t)$ funkcijama kao što su:

- funkcija histereze:

$$u(t) = \begin{cases} U^+, & s(\mathbf{x}) > \Delta, \\ U^-, & s(\mathbf{x}) < \Delta, \end{cases} \tag{3.40}$$

- funkcija zasićenja:

$$u(t) = \begin{cases} U^+, & s(\mathbf{x}) > \Delta, \\ \frac{s}{\Delta}, & |s(\mathbf{x})| < \Delta, \\ U^-, & s(\mathbf{x}) < \Delta, \end{cases} \tag{3.41}$$

- funkcija oblika:

$$u(t) = \frac{s}{|s| + \Delta}. \tag{3.42}$$

Ovakve funkcije nazivaju se sigmoidne funkcije i njihovim korištenjem postavlja se omeđena granica oko klizne plohe $|s(\mathbf{x})| < \Delta$ (slika 3.7b) koja određuje maksimalnu amplitudu oscilacija trajektorija oko klizne plohe $\mathcal{S}$. Primjenom sigmoidnih funkcija sustav se nalazi u kvazi-kliznom režimu budući da se trajektorija sustava nikada ne giba po samoj kliznoj plohi već titra oko nje. Parametar Δ je proizvoljan mali broj pomoću kojeg se može upravljati amplitudom oscilacija trajektorija čime se zapravo upravlja efektom zveketanja. Međutim prilikom odabira parametra Δ treba također paziti da se ne naruši robusnost kliznog režima.

Osim primjena sigmoidnih funkcija, smanjenje efekta zveketanja može se postići i primjenom kliznih režima višeg reda [46]. U ovom poglavlju, pri osnovnoj analizi koncepta kliznih režima promatrani su isključivo klizni režimi prvog reda postignuti signum (ili sigmoidnim) upravljačkim zakonom. Klizni režim drugog reda, ostvaren korištenjem *super twisting* algoritma (STA) u upravljačkom zakonu, analiziran je u sljedećem poglavlju o bezsenzorskom upravljanju PMSG-om.

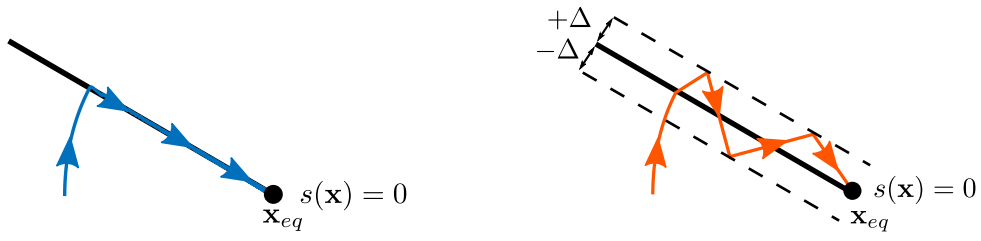

(a) Idealni klizni režim (b) Kvazi-klizni režim

Slika 3.7: Vrste kliznih režima

3.5. Primjer upravljanja silaznim DC-DC pretvaračem temeljenog na kliznom režimu

Kao što je rečeno u ranijim potpoglavljima, glavni zadatak kod upravljanja pomoću kliznog režima je odabir prikladnog upravljačkog zakona i klizne plohe. Diskontinuirani upravljački zakon za silazni DC-DC pretvarač iz (3.10) može se, pomoću funkcije signum, zapisati kao [51]:

$$u(t) = \frac{1}{2}[1 - \text{sign}(s(t)]. \tag{3.43}$$

Za funkciju prekapčanja pogodno je odabrati linearnu funkciju:

$$s(\mathbf{x}) = \mathbf{S}\mathbf{x} = [m \quad 1][x_1 \quad x_2]^{\mathrm{T}} - mU_{ref}, \tag{3.44}$$

gdje je m - upravljački parametar kliznog režima.

Primjenom uvjeta stabilnosti kliznog režima (3.18) na funkciju prekapčanja dobiva se sljedeći izraz:

$$\begin{cases} \mathbf{S}\mathbf{x} > 0, & -\delta < s(\mathbf{x}) < 0, \\ \mathbf{S}\mathbf{x} < 0, & 0 < s(\mathbf{x}) < \delta, \end{cases} \tag{3.45}$$

gdje je δ - okolina klizne plohe $s(\mathbf{x}) = 0$.

Uvrštavanjem sustava silaznog DC-DC pretvarača zapisanog u prostoru stanja iz (3.9) u prethodni uvjet postojanja kliznog režima, uz upravljački zakon iz (3.43), dobivaju se sljedeće nejednakosti:

$$\begin{cases} mx_2 - ax_1 - bx_2 + aU_{ref} > 0, & -\delta < s(\mathbf{x}) < 0, \\ mx_2 - ax_1 - bx_2 < 0, & 0 < s(\mathbf{x}) < \delta. \end{cases} \tag{3.46}$$

Ove nejednakosti predstavljaju dva pravca čija sjecišta s kliznom plohom $s(\mathbf{x}) = 0$ određuju segment AB na kliznoj plohi $s(\mathbf{x}) = 0$ u kojem se javlja klizni režim. Jednadžbe tih pravaca glase:

$$\begin{cases} p_1 = x_2 > \frac{a}{m-b}(x_1 - U_{ref}), & -\delta < s(\mathbf{x}) < 0, \\ p_2 = x_2 < \frac{a}{m-b}x_1, & 0 < s(\mathbf{x}) < \delta, \end{cases} \tag{3.47}$$

gdje je $a/(m - b)$ nagib pravaca.

Parametri a i b su konstante silaznog DC-DC pretvarača određene njegovim otporom, induktivitetom i kapacitetom pa je očito da se na područje egzistencije kliznog režima može utjecati jedino preko parametara m koji čini sastavni dio klizne plohe $s(\mathbf{x}) = 0$.

Nadalje, s obzirom da u kliznom režimu vrijedi $s(\mathbf{x}) = 0$, dinamika sustava tijekom kliznog režima glasi:

$$x_1(t) = U_{ref} + x_1(t_0)e^{-m(t-t_0)} \tag{3.48}$$

te je očito da se parametrom m, također, određuje stabilnost sustava u kliznom režimu kao i vrijeme konvergencije sustava prema stabilnoj ravnotežnoj točki. Dinamika sustava u kliznom režimu bit će stabilna za $m > 0$. Prema tome, parametar m klizne plohe $s(\mathbf{x}) = 0$ potrebno je odabrati tako da se ostvari prihvatljiva dinamika odziva napona silaznog DC-DC pretvarača, ali uz zadovoljene uvjete postojanja kliznog režima na kliznoj plohi $s(\mathbf{x}) = 0$. Budući da je $b = 1/RC$, postavljanjem $m = b$ osigurat će se najveće područje postojanja kliznog režima kao i prihvatljiva dinamika odziva. Odabirom $m < b$ smanjuje se brzina konvergencije sustava ka stabilnoj ravnotežnoj točki, ali se zadržava prilično široko područje egzistencije kliznog režima. S druge strane, uz $m > b$ povećava se brzina konvergencije nauštrb smanjenja područja egzistencije kliznog režima.

Na slici 3.8 prikazana je shema upravljanja izlaznim naponom silaznog DC-DC pretvarača. S obzirom da vrijedi $x_1 = u_c$, a $x_2 = \dot{u}_c = \frac{i_c}{C}$, odabrana funkcija prekapčanja iz (3.44) zapravo glasi:

$$s(\mathbf{x}) = m(u_c - U_{ref}) + \frac{i_c}{C}. \tag{3.49}$$

Funkcija prekapčanja $s(t)$ dovodi se na diskontinuirani upravljački zakon (3.43) koji generira upravljački signal tranzistora T.

Na slikama 3.9 i 3.10 prikazani su rezultati simulacija upravljanja izlaznim naponom silaznog DC-DC pretvarača na prethodno opisani način uz $R = 100\ \Omega$, $L = 500$ mH, $C = 100\ \mu$C te napon izvora $U = 100$ V. Referenti napon postavljen je na $U_{ref} = 50$ V.

Na slici 3.9a prikazan je prostor stanja silaznog DC-DC pretvarača s kliznom plohom iz (3.44) uz $m = 0,5b$, pravcima iz (3.47) te trajektorijom sustava. Sjecišta pravaca p_1 i p_2 s kliznom plohom $s(\mathbf{x}) = 0$ označena su s točkama A i B. Segment AB na kliznoj plohi $s(\mathbf{x}) = 0$ čini područje postojanja kliznog režima. Uz pretpostavku praznog kondenzatora, trajektorija sustava počinje iz točke $(x_1, x_2) = (u_c, \dot{u}_c) = (0, 0)$ te se giba prema kliznoj plohi $s(\mathbf{x}) = 0$. U točki C trajektorija dohvaća klizne plohu $s(\mathbf{x}) = 0$, a budući da se točka C nalazi unutar segmenta AB sustav ulazi u klizni režim te se trajektorija sustava giba po kliznoj plohi do stabilne ravnotežne točke određene referentnim naponom $U_{ref} = 50$ V. Na slici 3.9b prikazan je aperiodski vremenski odziv napona kondenzatora u_c.

Na slici 3.10 prikazana je trajektorija sustava silaznog DC-DC pretvarača, vremenski odziv napona kondenzatora u_c i upravljački signal u uz $m = 5b$. U ovom slučaju početni uvjet jednak je kao u prethodnom, $(x_1, x_2) = (u_c, \dot{u}_c) = (0, 0)$. U početnoj točki vrijedi $s(\mathbf{x}) < 0$ pa će upravljački zakon biti $u = 1$ kao što je vidljivo na slici 3.10c. Ovako postavljen upravljački zakon $u(t)$ rezultirat će gibanjem trajektorije sustava prema kliznoj plohi $s(\mathbf{x}) = 0$. Trajektorija dohvaća kliznu plohu u točki C, međutim, u ovom slučaju točka C se nalazi izvan segmenta AB te sustav ne ulazi u klizni režim budući da klizni režim postoji isključivo unutar segmenta AB klizne plohe $s(\mathbf{x}) = 0$. Iz tog razloga, trajektorija preskače kliznu plohu $s(\mathbf{x}) = 0$ što se očituje

nadvišenjem u odzivu napona kondenzatora u_c sa slike 3.10b. Nakon što je trajektorija prešla u dio prostora stanja u kojem vrijedi $s(\mathbf{x}) > 0$, upravljački zakon mijenja se u $u(t) = 0$ kako bi se trajektorija ponovno usmjerila prema kliznoj plohi. Trajektorija ponovno dohvaća kliznu plohu u točki B koja je dio segmenta AB te sustav ulazi u klizni režim u $t \approx 0,02$ s te se trajektorija giba po kliznoj plohi do ravnotežne radne točke određene referentnim naponom $U_{ref} = 50$ V.

Na slici 3.10c prikazan je upravljački signal $u(t)$ koji se dovodi na tranzistor T kao i njegova filtrirana vrijednost. U skladu s teorijom iznesenom u prethodnom potpoglavlju uočljivo je da srednja vrijednost upravljačkog signala $u(t)$ dobivena propuštanjem kroz niskopropusni filtar vremenske konstante $\tau = 0,005$ s predstavlja ekvivalentni upravljački zakon u_{eq}. S obzirom da je referentni napon koji se želi ostvariti na izlazu silaznog DC-DC pretvarača $U_{ref} = 50$ V, a ulazni napon $U = 100$ V, ekvivalentni upravljački zakon $u_{eq} = 0,5$ zapravo predstavlja vrijeme vođenja tranzistora T unutar sklopne periode potrebno da se ostvari željeni izlazni napon $u_c = U_{ref} = 0,5U$.

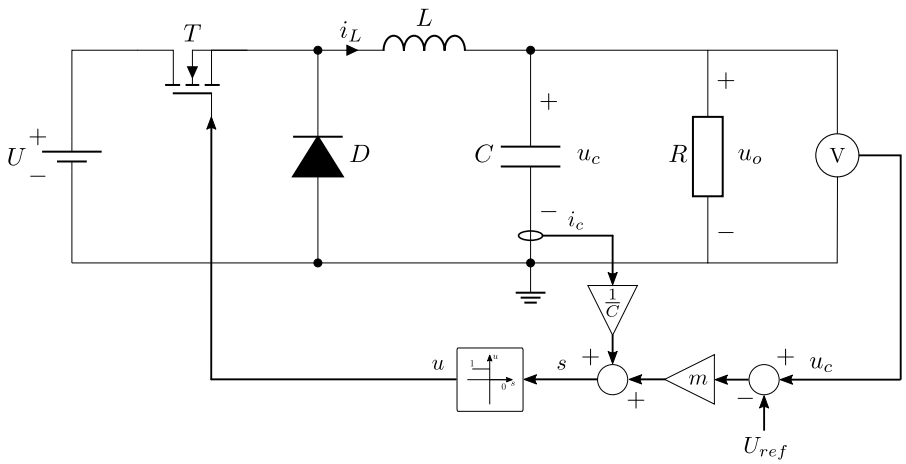

Slika 3.8: Shema upravljanja silaznim DC-DC pretvaračem temeljeno na kliznom režimu

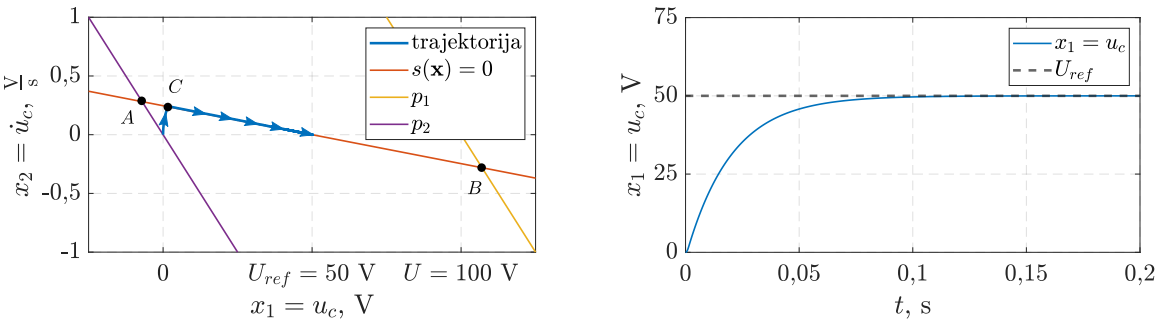

(a) Klizni režim u prostoru stanja silaznog DC-DC pretvarača

(b) Napon kondenzatora silaznog DC-DC pretvarača

Slika 3.9: Upravljanje naponom kondenzatora silaznog DC-DC pretvarača uz $m < b$

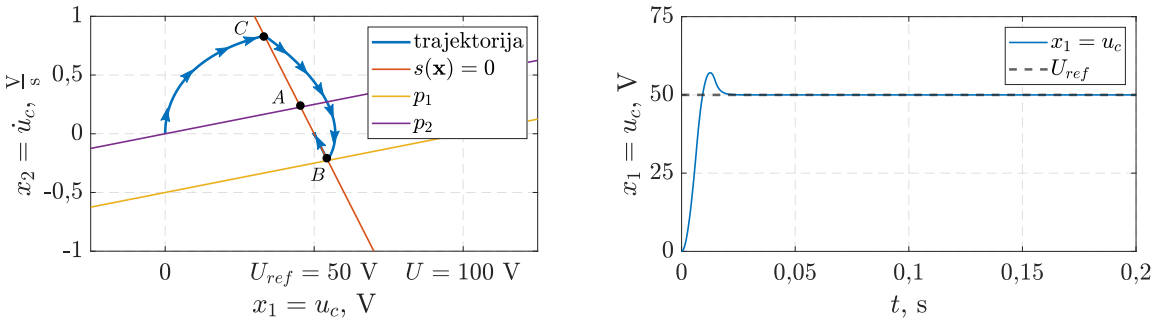

(a) Klizni režim u prostoru stanja silaznog DC-DC pretvarača

(b) Napon kondenzatora silaznog DC-DC pretvarača

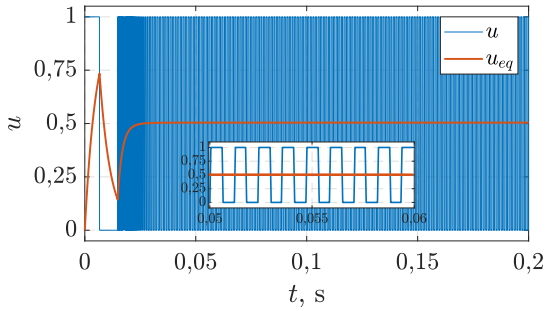

(c) Upravljački zakon

Slika 3.10: Upravljanje naponom kondenzatora silaznog DC-DC pretvarača uz $m > b$

3.6.Opserver u kliznom načinu rada

Osim u teoriji upravljanja, teorija kliznih režima primjenjuje se i u teoriji estimacije [45, 46]. Uobičajeno, varijable stanja sustava koje se ne mogu mjeriti, a potrebno ih je poznavati, mogu se estimirati pomoću opservera. Opserver je, zapravo, replika stvarnog sustava s jednakim ulazima te jednim dodatnim ulazom koji predstavlja razliku između izlaza opservera i izlaza stvarnog sustava. Ta razlika naziva se estimacijska greška opservera.

Prvi opserver koji se počeo koristiti u široj upotrebi jest Luenbergov opserver. Luenbergov opserver je linearni opserver budući da se estimacijska greška opservera množi s konstantnim pojačanjem kao što je prikazano na slici 3.11a. Međutim, nedostatak linearnog opservera je taj što, ukoliko u sustavu postoje neodređeni poremećaji, nije moguće osigurati da estimacijska greška opservera konvergira k nuli te da vrijednosti estimiranih varijabli stanja konvergiraju k vrijednostima stvarnih varijabli stanja [52].

Ovaj nedostatak moguće je izbjeći korištenjem nelinearnog opservera u kojem se estimacijska greška provodi kroz diskontinuiranu funkciju kao što je prikazano na slici 3.11b. Ukoliko je neodređenost sustava omeđena, primjenom pojačanja većeg od maksimalne vrijednosti omeđenog neodređenog poremećaja, nelinearni opserver osigurat će iščezavanje estimacijske greške opservera u konačnom vremenu kao i konvergenciju varijabli stanja opservera k varijablama stanja stvarnog sustava.

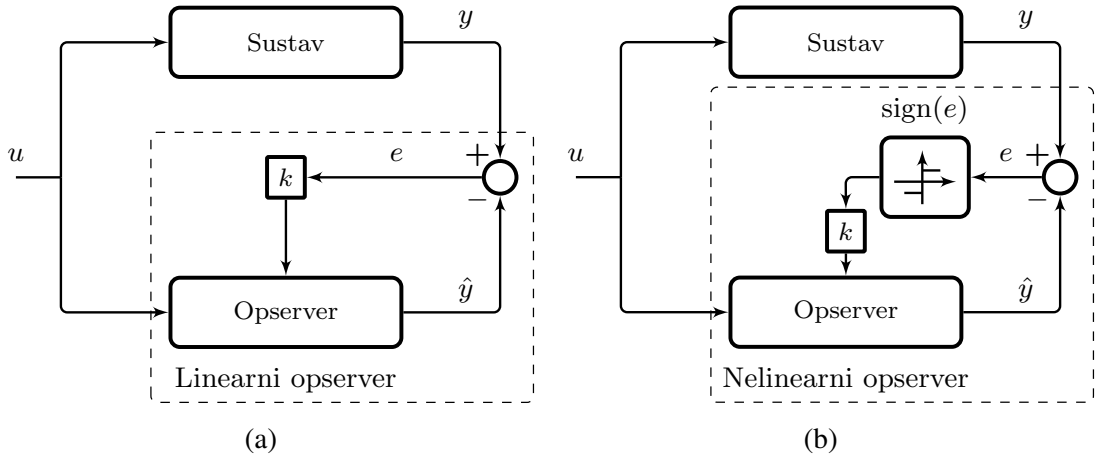

Slika 3.11: Vrste opservera

Kako bi se pokazala osnovna svojstva nelinearnog opservera može se koristiti sljedeći sustav:

$$\begin{aligned} \dot{\mathbf{x}}(t) &= \mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t) \\ \mathbf{y}(t) &= \mathbf{C}\mathbf{x}(t), \end{aligned} \tag{3.50}$$

gdje je $\mathbf{A} \in \mathbb{R}^{n\times n}$ - matrica dinamike sustava, $\mathbf{x} \in \mathbb{R}^n$ - vektor varijabli stanja, $\mathbf{B} \in \mathbb{R}^{n\times m}$ - ulazna matrica, $\mathbf{C} \in \mathbb{R}^{p\times n}$, $p \geq m$ - matrica izlaza, $\mathbf{u}(t) \in \mathbb{R}^m$ - vektor ulaza, a t - vrijeme te uz pretpostavku da su $\mathbf{B}$ i $\mathbf{C}$ punog ranga i da je par $(\mathbf{A}, \mathbf{C})$ osmotriv.

Na temelju sustava (3.50) pogodno je postaviti opserver oblika:

$$\begin{aligned} \dot{\hat{\mathbf{x}}}(t) &= \mathbf{A}\hat{\mathbf{x}}(t) + \mathbf{B}\mathbf{u}(t) + \mathbf{K}k\,\mathrm{sign}(\hat{\mathbf{y}}(t) - \mathbf{y}(t)) \\ \hat{\mathbf{y}}(t) &= \mathbf{C}\hat{\mathbf{x}}(t), \end{aligned} \tag{3.51}$$

gdje $\hat{\mathbf{x}}$ i $\hat{\mathbf{y}}$ predstavljaju estimaciju varijabli $\mathbf{x}$ i $\mathbf{y}$.

Uz definiciju estimacijske greške varijabli stanja kao $\mathbf{e}(t) = \hat{\mathbf{x}}(t) - \mathbf{x}(t)$ te estimacijske greške opservera kao $\mathbf{e}_y(t) = \hat{\mathbf{y}}(t) - \mathbf{y}(t)$ te oduzimanjem (3.51) od (3.50) dobiva se sustav koji opisuje dinamiku greške opservera:

$$\begin{aligned} \dot{\mathbf{e}}(t) &= \mathbf{A}\mathbf{e}(t) + \mathbf{K}k\,\mathrm{sign}(\mathbf{e}_y(t)) \\ \dot{\mathbf{e}}_y(t) &= \mathbf{C}\dot{\mathbf{e}}(t) = \mathbf{C}\mathbf{A}\mathbf{e}(t)) + \mathbf{C}\mathbf{K}k\,\mathrm{sign}(\mathbf{e}_y(t)), \end{aligned} \tag{3.52}$$

gdje je $\mathbf{K} = [\mathbf{K}_1 \in \mathbb{R}^{(n-p)\times p} \quad \mathbf{I}_p]^{\mathrm{T}}$.

Usporedbom prethodnog sustava koji opisuje dinamiku greške opservera sa sustavom iz (3.11) lako se uočava sličnost s obzirom da oba sustava imaju diskontinuirani ulaz definiran funkcijom signum. Iz tog razloga očito je da opserver definiran na ovakav način otvara mogućnost pojave

kliznog režima u prostoru stanja greške opservera s kliznom plohom:

$$\mathcal{S} = \{\mathbf{e} \in \mathbb{R}^n \quad : \quad \mathbf{e}_y = 0\} \tag{3.53}$$

te se stoga i naziva opserver u kliznom načinu rada (engl. *sliding-mode observer*, SMO).

Za daljnju analizu opservera u kliznom načinu rada pogodno je primijeniti transformaciju koordinata $\mathbf{x} = \mathbf{T}_c\mathbf{x}$ gdje je $\mathbf{T}_c = [\mathbf{N}_c^{\mathrm{T}} \quad \mathbf{C}]^{\mathrm{T}}$, a $\mathbf{N}_c$ predstavlja nul-prostor matrice $\mathbf{C}$. Primjenom navedene transformacije na matrice $\mathbf{A}$, $\mathbf{B}$ i $\mathbf{C}$ sustava (3.50) dobivaju se nove matrice $\mathbf{A}_c = \mathbf{T}_c\mathbf{A}\mathbf{T}_c^{-1} = \begin{bmatrix} \mathbf{A}_{11} \in \mathbb{R}^{(n-p)\times(n-p)} & \mathbf{A}_{12} \\ \mathbf{A}_{21} & \mathbf{A}_{22} \end{bmatrix}$, $\mathbf{B}_c = \mathbf{T}_c\mathbf{B} = [\mathbf{B}_1 \in \mathbb{R}^{(n-p)\times m} \quad \mathbf{B}_2]^{\mathrm{T}}$ i $\mathbf{C}_c = \mathbf{C}\mathbf{T}_c^{-1} = [0 \quad \mathbf{I}_p]$.

Uz ovakvu transformaciju koordinata, sustav (3.52) može se rastaviti na:

$$\begin{aligned} \dot{\mathbf{e}}_1(t) &= \mathbf{A}_{11}\mathbf{e}_1(t) + \mathbf{A}_{12}\mathbf{e}_y(t) + \mathbf{K}_1 v(t) \\ \dot{\mathbf{e}}_y(t) &= \mathbf{A}_{21}\mathbf{e}_1(t) + \mathbf{A}_{22}\mathbf{e}_y(t) - v(t), \end{aligned} \tag{3.54}$$

gdje je $\mathbf{e}_1 \in \mathbb{R}^{n-p}$ i $v(t) = k\,\mathrm{sign}(\mathbf{e}_{y,i}(t))$

3.6.1. Uvjet dohvaćanja i postojanja kliznog režima u prostoru stanja greške opservera

Kako bi klizni režim postojao u prostoru stanja greške opservera, potrebno je dokazati uvjet dohvaćanja i postojanja kliznog režima iz (3.20). S obzirom da je klizna ploha određena s $\mathbf{e}_y = 0$, uvjet dohvaćanja i postojanja kliznog režima glasi:

$$\mathbf{e}_y\dot{\mathbf{e}}_y = -|\mathbf{e}_y|(k - |\mathbf{A}_{21}\mathbf{e}_1 + \mathbf{A}_{22}\mathbf{e}_y|) < -\eta|\mathbf{e}_y|, \tag{3.55}$$

gdje je $\eta > 0$.

Da bi taj uvjet bio zadovoljen, potrebno je odabrati pojačanje k tako da vrijedi [46]:

$$k > |\mathbf{A}_{21}\mathbf{e}_1 + \mathbf{A}_{22}\mathbf{e}_y| + \eta. \tag{3.56}$$

3.6.2. Stabilnost kliznog režima u prostoru stanja greške opservera

Kada sustav greške opservera dostigne kliznu plohu $\mathcal{S}$, vrijedit će $\mathbf{e}_y = \dot{\mathbf{e}}_y = 0$ pa sustav greške (3.54) postaje:

$$\begin{aligned} \dot{\mathbf{e}}_1(t) &= \mathbf{A}_{11}\mathbf{e}_1(t) + \mathbf{K}_1 \overbrace{\mathrm{NPF}[v(t)]}^{u_{eq}} \\ 0 &= \mathbf{A}_{21}\mathbf{e}_1(t) - \underbrace{\mathrm{NPF}[v(t)]}_{u_{eq}}, \end{aligned} \tag{3.57}$$

gdje je u_{eq} ekvivalenti upravljački signal predstavljen u poglavlju 3.3 te predstavlja srednju vrijednost diskontinuiranog upravljačkog zakona u kliznom režimu koja se može izračunati primjenom niskopropusnog filtra (NPF).

Izražavanjem ekvivalentnog upravljačkog signala kao $u_{eq} = \mathbf{A}_{21}\mathbf{e}_1(t)$ dobiva se dinamička jednadžba greške opservera u kliznom načinu rada:

$$\dot{\mathbf{e}}_1(t) = (\mathbf{A}_{11} + \mathbf{K}_1\mathbf{A}_{21})\mathbf{e}_1(t). \tag{3.58}$$

Dinamika greške u kliznom režimu je reda $n - p$ što je u skladu s teorijom o kliznim režimima koja kaže da je jedno od glavnih svojstava kliznog režima smanjenje reda dinamike sustava.

S obzirom na pretpostavku da je par $(\mathbf{A}, \mathbf{C})$ osmotriv, tada će vrijediti i da je par $(\mathbf{A}_{11}, \mathbf{A}_{21})$ također osmotriv pa će uvijek postojati matrica $\mathbf{K}_1$ koja će osigurati stabilnu dinamiku greške opservera u kliznom režimu opisanom jednadžbom (3.58) [46].

3.6.3.Robusnost opservera u kliznom načinu rada

Uz prisutnost neodređenosti sustav (3.50) može se zapisati kao:

$$\begin{aligned} \dot{\mathbf{x}}(t) &= \mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t) + \mathbf{G}\mathbf{f}(t, \mathbf{x}, \mathbf{u}) \\ \mathbf{y}(t) &= \mathbf{C}\mathbf{x}(t), \end{aligned} \tag{3.59}$$

gdje je $\mathbf{f}(t, \mathbf{x}, \mathbf{u}) \in \mathbb{R}^h$ - poremećaj, a $\mathbf{G} \in \mathbb{R}^{n\times h}$ - matrica raspodijeljenosti poremećaja.

Uz transformaciju koordinata $\mathbf{x} = \mathbf{T}_c\mathbf{x}$ matrica raspodijeljenosti poremećaja postaje $\mathbf{G}_c = [\mathbf{K}_1\mathbf{X} \quad -\mathbf{X}]^{\mathrm{T}}$ gdje je $\mathbf{X} \in \mathbb{R}^{n\times h}$.

Primjenom istog opservera temeljenog na kliznom režimu iz (3.51) dinamika greške opservera iz (3.54) sada glasi:

$$\begin{aligned} \dot{\mathbf{e}}_1(t) &= \mathbf{A}_{11}\mathbf{e}_1(t) + \mathbf{A}_{12}\mathbf{e}_y(t) + \mathbf{K}_1 v(t) - \mathbf{K}_1\mathbf{X}\mathbf{f}(t, \mathbf{x}, \mathbf{u}) \\ \dot{\mathbf{e}}_y(t) &= \mathbf{A}_{21}\mathbf{e}_1(t) + \mathbf{A}_{22}\mathbf{e}_y(t) - v(t) + \mathbf{X}\mathbf{f}(t, \mathbf{x}, \mathbf{u}), \end{aligned} \tag{3.60}$$

Za prethodni sustav greške opservera s uključenim poremećajem uvjet dohvaćanja i postojanja kliznog režima glasi:

$$\mathbf{e}_y\dot{\mathbf{e}}_y = \mathbf{e}_y(\mathbf{A}_{21}\mathbf{e}_1 + \mathbf{A}_{22}\mathbf{e}_y + \mathbf{X}\mathbf{f}) - k|\mathbf{e}_y| < -|\mathbf{e}_y|(k - |\mathbf{A}_{21}\mathbf{e}_1 + \mathbf{A}_{22}\mathbf{e}_y + \mathbf{X}\mathbf{f}|) < -\eta|\mathbf{e}_y|, \tag{3.61}$$

što će biti zadovoljeno za $k > |\mathbf{A}_{21}\mathbf{e}_1 + \mathbf{A}_{22}\mathbf{e}_y + \mathbf{X}\mathbf{f}| + \eta$ [46].

Nadalje, kada se promotri dinamika sustava (3.60) za vrijeme kliznog režima tijekom kojeg vrijedi $\mathbf{e}_y = \dot{\mathbf{e}}_y = 0$, uočljivo je jednakost između dinamičke jednadžba greške opservera za sustav s neodređenostima i dinamičke jednadžbe greške opservera za sustav bez neodređenosti iz (3.58).

Prema tome, očito je da neodređenost u sustavu ne utječe na dinamiku greške opservera tijekom kliznog režima [46].

3.6.4.Razlike između regulatora i opservera u kliznom načinu rada

Iako je teorijska podloga regulatora i opservera temeljnih na kliznom režimima jednaka, između njih postoje dvije ključne razlike [52]:

1. Kod sustava s regulatorom u kliznom načinu rada diskontinuirani ulaz ovisi u ulaznoj matrici **B** koja je određena sustavom, dok kod opservera u kliznom načinu rada diskontinuirani ulaz ovisi o matrici pojačanja **K** koja je proizvoljna.
2. Klizna ploha kod opservera u kliznom načinu rada uvijek je ista ($\mathbf{e}_y = 0$), dok se u sustavu upravljanom regulatorom u kliznom načinu rada klizna ploha $\mathbf{s}(\mathbf{x})$ odabire na temelju željenih svojstava i dinamike upravljačkog sustava.

3.6.5.Primjer opservera u kliznom načinu rada

U nastavku je opisan primjer opservera u kliznom načinu rada s primjenom estimacije izlaznog napona DC-DC pretvarača te poremećaja u sustavu.

Matrice dinamičkog modela silaznog DC-DC pretvarača redom glase $\mathbf{A} = \begin{bmatrix} 0 & 1 \\ -a & -b \end{bmatrix}$, $\mathbf{B} = [0 \quad aU]^{\mathrm{T}}$, $\mathbf{C} = [1 \quad 0]$.

Transformacijom koordinata $\mathbf{x} = \mathbf{T}_c\mathbf{x}$, gdje je $\mathbf{T}_c = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$, matrice silaznog DC-DC pretvarača postaju $\mathbf{A} = \begin{bmatrix} -b & -a \\ 1 & 0 \end{bmatrix}$, $\mathbf{B} = [aU \quad 0]^{\mathrm{T}}$ i $\mathbf{C} = [0 \quad 1]$.

Uz pretpostavku poremećaja $f = 0,2\sin(314t)$, transformirani sustav se može zapisati u obliku (3.59), gdje je transformirana matrica raspodjele poremećaja $\mathbf{G} = \mathbf{T}_c^{-1}\mathbf{G} = [-1 \quad L]^{\mathrm{T}}$.

Prikladni opserver u kliznom načinu rada u transformiranom sustavu je oblika (3.51) gdje je matrica pojačanja $\mathbf{K} = \mathbf{G}$ ukoliko je $\mathbf{X} = 1$.

Za ovako postavljen model silaznog DC-DC pretvarača i opservera u kliznom načinu rada dinamika greške jednaka je izrazu (3.60). Cilj opservera u kliznom načinu rada je estimacija izlaznog napona silaznog DC-DC pretvarača pa je stoga u prostoru stanja greške opservera (e_y, e_1) odabrana funkcija prekapčanja $e_y(t) = \hat{u}_c(t) - u_c(t)$.

Stabilna dinamika greške u kliznom režimu iz jednadžbe (3.58) osigurat će se odabirom pojačanja $\mathbf{K}_1 < b$ jer će tada biti zadovoljen uvjet stabilnosti $A_{11} + LA_{21} < 0$.

Na slici 3.12 prikazani su odzivi simulacije opservera temeljenog na kliznom režimu za estimaciju izlaznog napona silaznog DC-DC pretvarača s parametrima iz poglavlja 3.5 te s odabranim pojačanjem $\mathbf{K}_1 = -1500$. Prema prikazanim rezultatima simulacije očito je da trajektorija greške ulazi u klizni režim u $t \approx 0,01$ s s obzirom da se od tog trenutka estimirana

vrijednost napona $\hat{u}_c$ podudara s mjernom vrijednošću u_c (slika 3.12a), odnosno dolazi do iščezavanja greške $e_y = \hat{u}_c - u_c$ (slika 3.12b). Na slici 3.12c uočljiva je jedna vrlo bitna karakteristika opservera temeljenog na kliznom režimu, a to je da ekvivalentni diskontinuirani signal v_{eq}, koji predstavlja srednju vrijednost diskontinuiranog signala v, zapravo odgovara poremećaju $f = 0,2\sin(314t)$. Iz ovog odziva, dakle, očito je da opserver u kliznom načinu rada, osim za estimaciju varijabli stanja, može služiti za estimaciju nepoznatog poremećaja u sustavu, uz uvjet da je taj poremećaj omeđen te da je pojačanje k veće od amplitude poremećaja. Na kraju, na slici 3.12d prikazana je trajektorija greške opservera u prostoru stanja (e_y, e_1) uz početne uvjete $(25, 0)$.

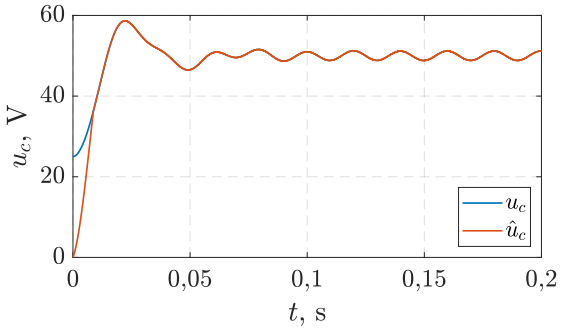

(a) Mjereni izlazni napon $u_c(t)$ i estimirani izlazni napon $\hat{u}_c(t)$

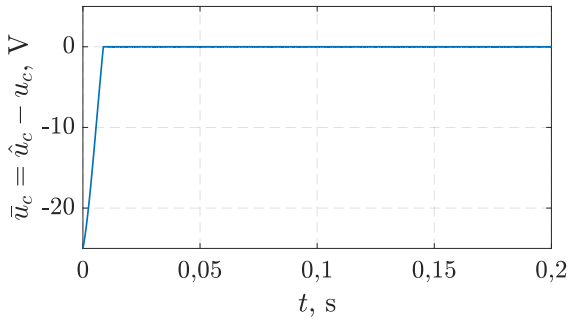

(b) Greška opservera $e_y(t) = \hat{u}_c(t) - u_c(t)$

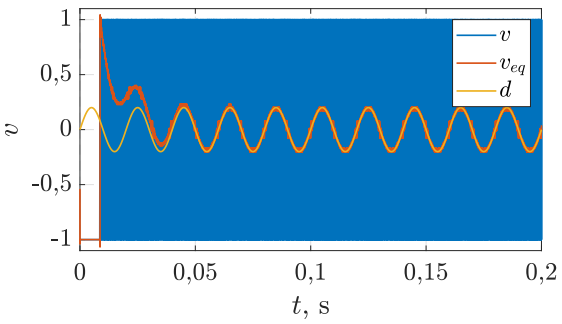

(c) Diskontinuirani signal v i ekvivalentni signal v_{eq}

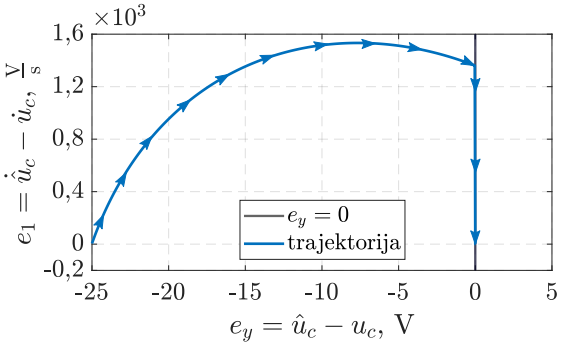

(d) Trajektorija greške u prostoru stanja (e_y, e_1)

Slika 3.12: Opserver u kliznom načinu rada za estimaciju izlaznog napona silaznog DC-DC pretvarača

3.7.Diskretni klizni režim

Za razliku od kontinuiranih sustava, u diskretnim sustavima je moguće ostvariti isključivo kvazi-klizni režim (slika 3.7b). Razlog tomu je taj što je u diskretnom sustavu upravljački zakon $u(kT_s)$ moguće primijeniti u točno određenim vremenskim trenucima čime mu je ograničena frekvencija sklapanja, a što rezultira nemogućnošću idealnog gibanja trajektorije sustava po kliznoj plohi $\mathcal{S}$.

Unatoč tome, postupak odabiranja klizne plohe vodi se istim ciljevima kao i kod odabira klizne plohe u kontinuiranom sustavu, a to je da klizna ploha $s(kT_s) = \mathbf{S}_d\mathbf{x}(kT_s)$ bude takva da

osigura stabilnu dinamiku diskretnog sustava u kliznom režimu [53].

S druge strane, postupak odabira upravljačkog zakona za diskretni kvazi-klizni režim razlikuje se od postupka odabira upravljačkog zakona za kontinuirani klizni režim. Razlog tomu leži u činjenici da diskretizirani uvjet postojanja kliznog režima za kontinuirani sustav iz (3.20):

$$\left(s_{[k+1]} - s_{[k]}\right) s_{[k]} < 0, \tag{3.62}$$

predstavlja samo dovoljan, ali ne i nužan uvjet postojanja kvazi-kliznog režima u diskretnom sustavu.

Nužan i dovoljan uvjet za dohvaćanje i postojanje kvazi-kliznog režima u diskretnom sustavu glasi [54]:

$$\left|s_{[k+1]}\right| < \left|s_{[k]}\right|. \tag{3.63}$$

Izraz (3.63) može se razdvojiti na dva dijela i zapisati kao [54]:

$$\left(s_{[k+1]} - s_{[k]}\right) \operatorname{sign}\left(s_{[k]}\right) < 0, \tag{3.64}$$

$$\left(s_{[k+1]} + s_{[k]}\right) \operatorname{sign}\left(s_{[k]}\right) \geq 0. \tag{3.65}$$

Iz prethodnog izraza vidljivo je da diskretni upravljački zakon $u(kT_s)$ određen iz uvjeta (3.63) mora:

1. osigurati usmjerenost trajektorije diskretnog sustava prema okolini kvazi-klizne plohe (uvjet (3.64)) i
2. ograničiti promjenu varijable stanja između k-tog i $k+1$ koraka tako da trajektorija stanja ne napusti okolinu kvazi-klizne plohe (uvjet (3.65)).

4.Opis laboratorijskog postava

U svrhu eksperimentalnih ispitivanja razvijenih algoritama korišten je laboratorijski postav u Laboratoriju regulacije električnih strojeva Fakulteta elektrotehnike i računarstva prikazan shemom na slici 4.1. Glavne sastavnice postava čine:

1.sinkroni generator s permanentnim magnetima *Alwin* PM-AW112M5-4-5,
2.pretvarač *Cognitio Open4Lab*,
3.asinkroni stroj *Končar* E5AZ 132M-4,
4.pretvarač *Siemens Sinamics* S120,
5.mjerni pretvornici LEM IT 205-S ULTRASTAB,
6.davač momenta na osovini HBM T12HP,
7.rezolver LTN RE-27-1-V31,
8.računala i
9.akvizicijski sustav *Dewesoft Sirius*.

Navedene sastavnice podijeljene su u energetski, upravljački i mjerni dio laboratorijskog postava te su detaljnije opisane u nastavku.

4.1.Energetski dio postava

Energetski dio laboratorijskog postava čine dva električna stroja i dva energetska pretvarača. Stroj nad kojim se ispituju razvijeni algoritmi je PMSG, dok se asinkroni stroj koristi kao pogonski. U svrhu ispitivanja, PMSG i asinkroni stroj spojeni su zajedničkom osovinom kao što je prikazano na slici 4.2, a na istu osovinu spojen je i davač momenta. Brzinom asinkronog stroja upravlja se putem industrijskog energetskog pretvarača *Sinamics* S120 (slika 4.3a) te se na taj način emulira rad vjetroturbine. Pretvarač *Sinamics* S120 sadrži aktivni ulazni stupanj (engl. *Active-Front End*, AFE) čime je omogućen povrat energije u električnu mrežu.

S druge strane, upravljanje PMSG-om vrši se putem pretvarača *Cognitio Open4Lab* prikazanog na slici 4.3b. Za razliku od pretvarača *Sinamics* S120, ovaj pretvarač je otvorenog tipa što ga čini prikladnim za implementiranje i ispitivanje novih algoritama upravljanja. Za razliku od standardnih pretvarača, *Open4Lab* pretvarač na ulazu ne sadrži trofazni diodni ispravljač niti AFE pa mu je ulazno napajanje potrebno osigurati spajanjem istosmjernog međukruga paralelno s

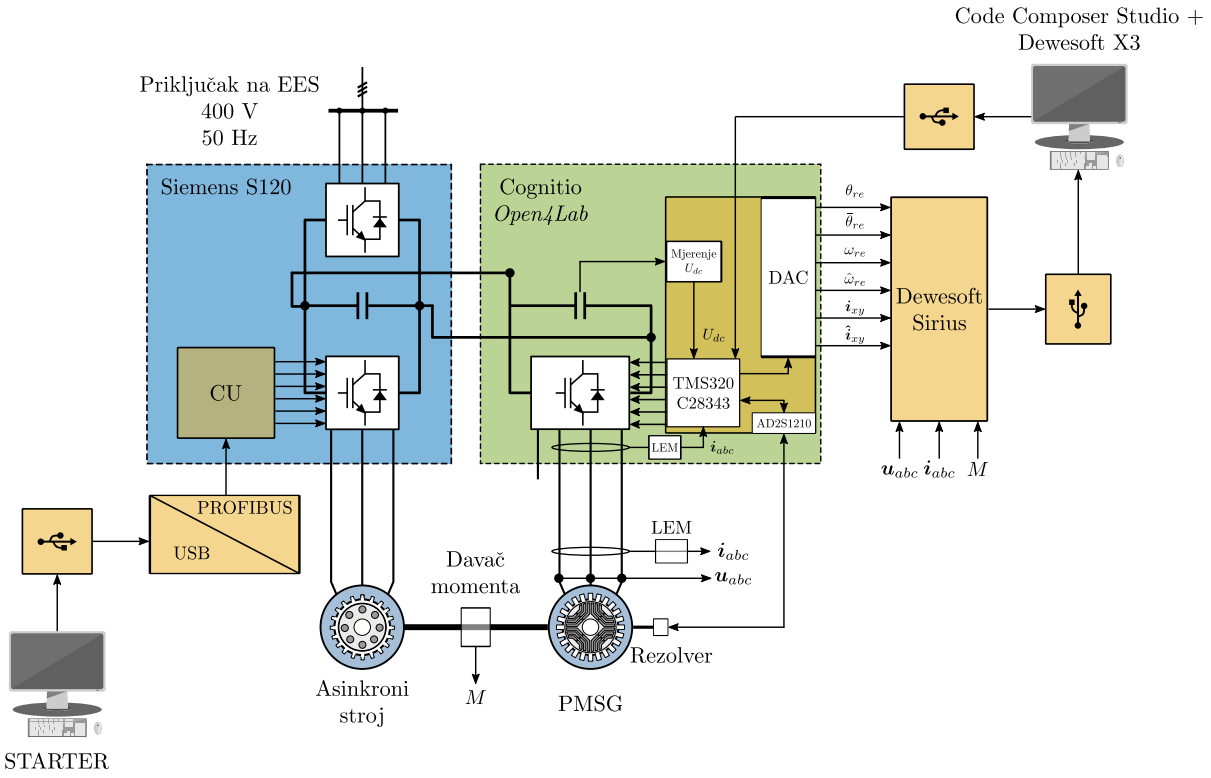

Slika 4.1: Principna shema laboratorijskog postava

istosmjernim međukrugom pretvarača *Sinamics* S120. Na ovaj način, omogućen je tok električne energije između PMSG-a i asinkronog stroja te, stoga, ulazni stupanj pretvarača *Sinamics* S120 nije potrebno koristiti za povrat energije u električnu mrežu. Nadalje, na izlazu *Open4Lab* pretvarača nalaze se četiri IGBT modula velike snage (U^{max} = 1200 V, I^{max} = 100 A) čime je omogućeno ispitivanje električnih strojeva u širokom rasponu snaga. S obzirom da je ispitivani PMSG trofazni stroj, iskorištena su tri od četiri IGBT modula pretvarača $Open4Lab$. U tablici 4.1 dani su nazivni podaci strojeva i pretvarača korištenih u eksperimentalnom ispitivanju.

4.2.Upravljački dio laboratorijskog postava

Budući da je asinkroni stroj napajan preko pretvarača *Sinamics S120* za njegovo parametriranje i upravljanje korišten je programski alat STARTER namijenjen za industrijske pretvarače tvrtke *Siemens*.

S druge strane, sastavni dio *Open4Lab* pretvarača, osim energetskog dijela, čini upravljačka ploča prikazana na slici 4.4a. Na upravljačkoj ploči nalaze se ključni dijelovi za implementaciju upravljanja PMSG-om kao što su sklopovi za okidanje IGBT-ova, elektronički krugovi za mjerenje i prilagodbu napona i struje te sučelje i elektronički sklop za napajanje i prilagodbu signala s rezolvera. Mjerenje struje vrši se pomoću mjernih pretvornika LEM LA 100-P čiji mjerni opseg iznosi 150 A. S obzirom na to da prema tablici 4.1 amplituda fazne struje PMSG-a iznosi 16,4 A, kroz pretvornik je provučeno pet zavoja po svakoj fazi kako bi se smanjio utjecaj

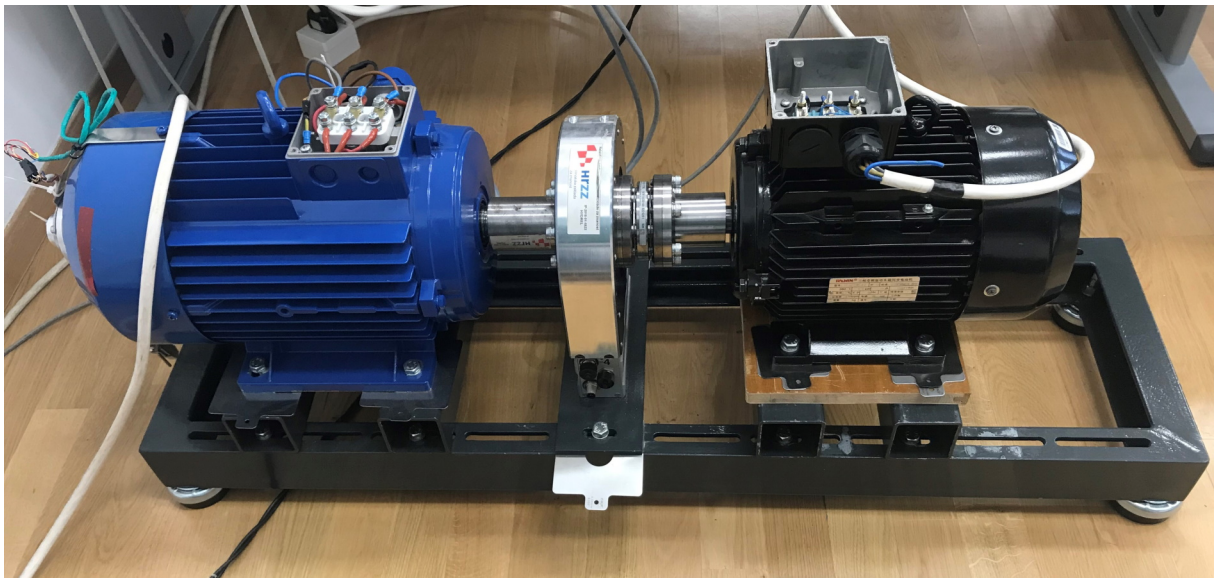

Slika 4.2: Asinkroni stroj (lijevo) i PMSG (desno)

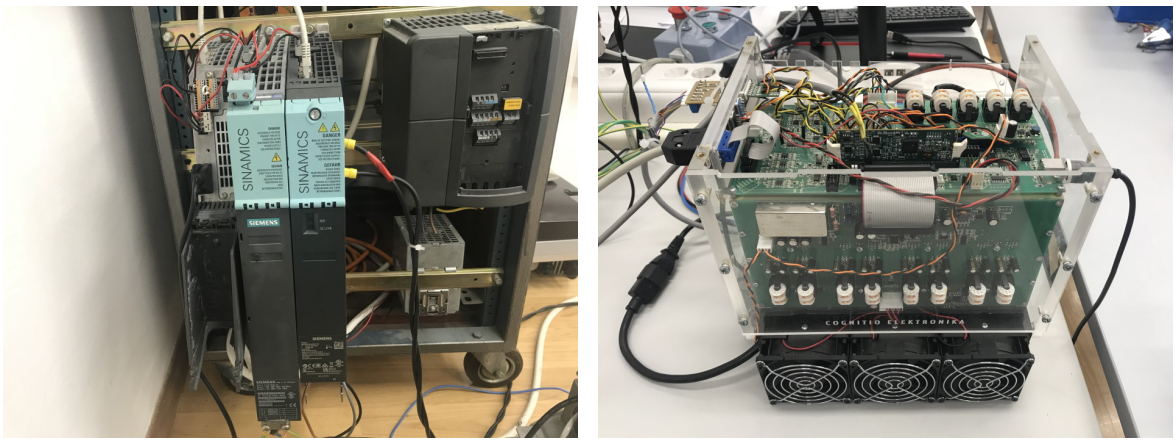

(a) *Sinamics* S120 (b) *Open4Lab*

Slika 4.3: Pretvarači za asinkroni stroj i PMSG

mjernog šuma (slika 4.4b). Osim navedenog sklopovlja, upravljačka ploča sadrži i 8-kanalni digitalno-analogni pretvornik (engl. *Digital-To-Analog Converter*, DAC). Za obradu dostupnih mjerenja te implementaciju upravljačkih algoritama, na upravljačkoj ploči nalazi se DIMM100 sabirnica u koju se dodaje upravljačka kartica. Na ovom laboratorijskom postavu korištena je *Texas Instruments* Delfino TMS320C28343 (200 MHz) upravljačka kartica s pomičnom decimalnom točkom (engl. *floating point*) prikazana na slici 4.4c.

Razvoj upravljačkih algoritama učinjen je unutar programskog okruženja *Code Composer Studio*. *Code Composer Studio* je integrirano razvojno okruženje (engl. Integrated Development Environment, IDE) temeljeno na platformi *Eclipse*, a glavna namjena mu je razvoj, prevođenje, testiranje i analiza korisničkih programa za upravljačke pločice proizvođača *Texas Instruments*. Na slici 4.5 prikazano je grafičko sučelje *Code Composer Studio*-a. Glavni dio sučelja čini uređivač namijenjen za pisanje programskog koda u programskom jeziku C. Lijevo od uređivača

Tablica 4.1: Nazivni podaci strojeva i pretvarača laboratorijskog postava

Podatak	**Ispitivani stroj, PMSG**	**Pogonski stroj, AM**
Proizvođač	Alwin	Končar
Tip	PM-AW112M5-4-5	E5AZ 132M-4
Snaga, P_n	5,5 kW	7,5 kW
Struja, I_n	11,6 A	15,2 A
Napon, U_n	220 V/ko/min	400 V
Brzina vrtnje, n_n	1500 o/min	1455 o/min
Frekvencija, f_n	50 Hz	50 Hz
Korisnost	92,1%	88,7%
Broj pari polova, p	2	2
Spoj	Y	Δ
Klasa izolacije	F	F
Faktor snage, $\cos\varphi_n$	-	0,8
	Pretvarač PMSG-a	**Pretvarač AM-a**
Proizvođač	Cognitio Elektronika	Siemens
Tip	Open4Lab	S120
Napon DC međukruga, U_{dc}	do 700 V	510-720 V
Izlazni napon, U_{out}	$0,7U_{dc}$	-
Izlazna struja, I_{out}	50 A	18 A
Izlazna snaga, P_{out}	-	9,7 kW

nalazi se projektno stablo unutar kojeg su vidljive sve mape i datoteke aktivnog projekta.

Struktura projekta unutar kojeg su razvijeni upravljački algoritmi prikazana je na slici 4.6. U mapama *targetConfigs* i *DSP2834x* nalaze se sve datoteke potrebne za ispravan rad i komunikaciju računala s upravljačkom karticom Delfino C28343 kao što su datoteke za definiranje svih registara i memorijskog prostora upravljačke kartice, datoteke s matematičkim funkcijama itd. Nadalje, mapa *HAL* sadrži datoteku s funkcijama za analogno-digitalnu pretvorbu (engl. *Analog-To-Digital Conversion*, ADC) mjerenih signala, datoteku s funkcijama za DAC pretvorbu, datoteke s postavkama PWM registara, datoteku za definiranje ulaza i izlaza opće namjene (engl. *General Purpose Input Output*, GPIO) i datoteku s funkcijama za definiranje postavki rezolvera te za čitanje i obradu signala s rezolvera. Datoteka *self_ident.c* i pripadajuća *header* datoteka sadrže funkcije za pokretanje rutine za određivanje parametara aproksimativne funkcije induktiviteta, dok datoteke *lookup.c* i *lookup.h* služe za čitanje podataka iz jedno- i dvodimenzionalnih preglednih tablica na temelju interpolacijske metode. U *header* datoteci *motor_defs.h* definirani su nazivni i bazni podaci PMSG-a, kao i različiti faktori skaliranja i

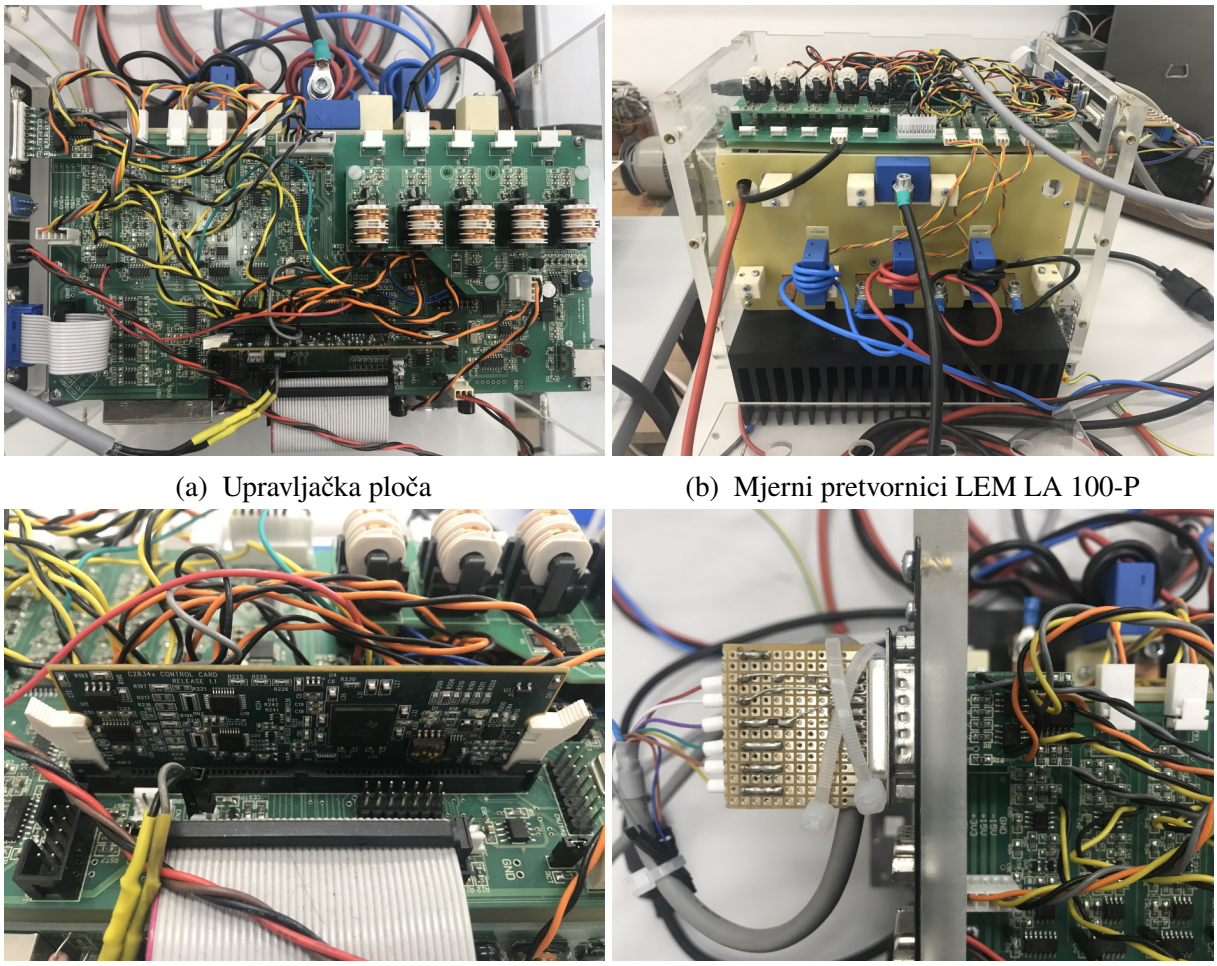

(a) Upravljačka ploča

(b) Mjerni pretvornici LEM LA 100-P

(c) Upravljačka kartica Delfino TMS320C28343

(d) Sučelje za rezolver

Slika 4.4: Upravljački dio pretvarača *Open4Lab*

ograničenja zaštitnih funkcija. U *header* datoteci *extern_variables.h* definirane su globalna upravljačka i statusna riječ preko kojih se mogu mijenjati upravljačke strukture te pratiti stanje pogona. Unutar datoteke *init.c* pozivaju se funkcije definirane u datotekama iz mapa *DSP2834x* i *HAL* pomoću kojih se inicijalizira GPIO, prekidna rutina, PWM registri i napajanje rezolvera. Prekidna rutina izvršava se frekvencijom od 5 kHz. Nadalje, u *control_lib.c* i *control_lib.h* izvedene su funkcije nužne za RFOC upravljanje PMSG-om kao što su PI regulatori, Clarkina i Parkova transformacija, određivanje vremena vođenja IGBT tranzistora (PWM modulacija), niskopropusni filtar kao i zaštitne funkcije, a u *smo_lib.c* i *smo_lib.h* nalaze se funkcije opservera u kliznom načinu rada i funkcije upravljačkih zakona. U glavnom programu *main.c* vrši se inicijalizacija upravljačkog sustava pozivom datoteke *init.c* te se upravlja ventilatorima pomoću funkcija iz datoteke *inverter_temperature_fans.c*. Unutar prekidne rutine *epwm1_isr.c* izvodi se RFOC algoritam i estimacija brzine i kuta rotora PMSG-a na temelju mjerene struje PMSG-a. Na kraju, u tablici *mtpa_lookup.tbl* pohranjena je pregledna tablica za određivanje referentnih vrijednosti struja PMSG-a na temelju zadanog momenta.

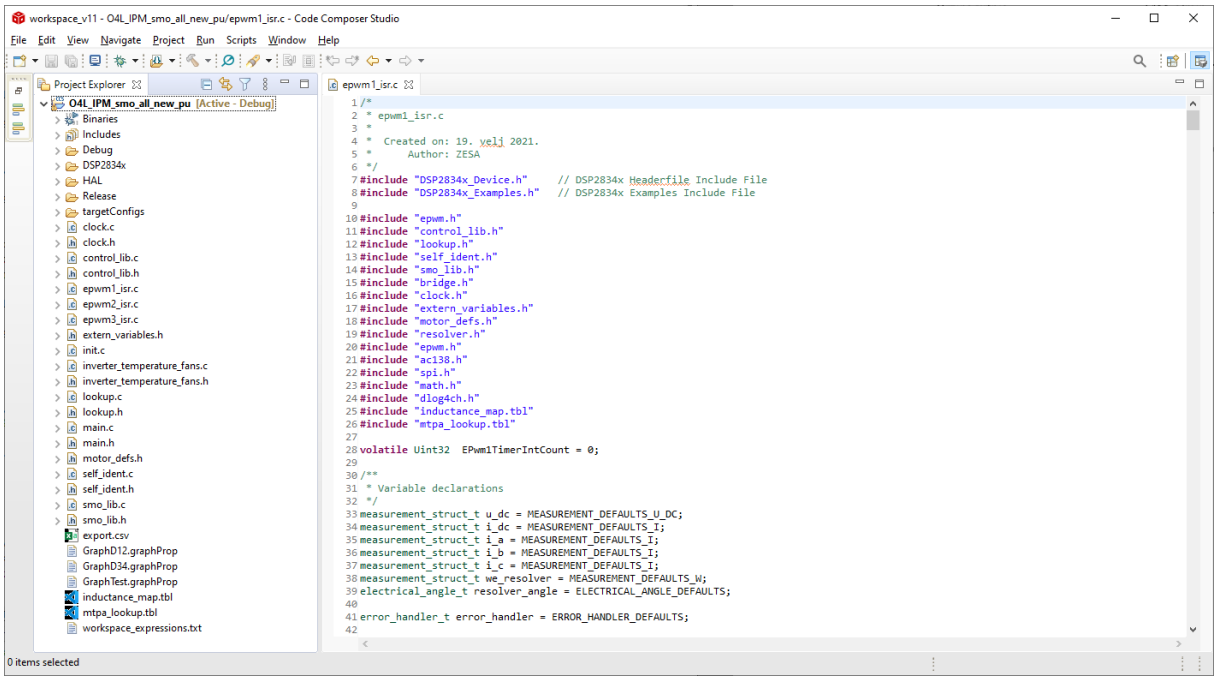

Slika 4.5: Grafičko sučelje programskog okruženja *Code Composer Studio*

<O4L_PMSG_SMO> ..... mapa projekta u *Code Composer Studio*-u
- `targetConfigs` ..... mapa s konfiguracijom upravljačke kartice *Delfino* C28343
- `DSP2834x` ..... mapa s osnovnim datotekama potrebnim za rad *Delfino*-a C28343
- `HAL` ..... mapa s datotekama za rad s perfiferijom upravljačke ploče
- `self_ident.c` .... datoteka za određivanje parametara aproksimativne funkcije induktiviteta
- `self_ident.h` ..... *header* datoteka
- `lookup.c` ..... datoteka za čitanje podataka iz pregledne tablice
- `lookup.h` ..... *header* datoteka
- `motor_defs.h` ..... *header* datoteka s nazivnim parametrima PMSG-a
- `extern_variables.h` ..... *header* datoteka s eksternim varijablama
- `init.c` ..... datoteka za inicijalizaciju
- `control_lib.c` ..... datoteka s funkcijama za upravljanje PMSG-om
- `control_lib.h` ..... *header* datoteka
- `smo_lib.c` ..... datoteka s opserverima u kliznom načinu rada
- `smo_lib.h` ..... *header* datoteka
- `main.c` ..... glavni program
- `main.h` ..... *header* datoteka
- `epwm1_isr.c` ..... prekidna rutina frekvencije 5 kHz
- `inverter_temperature_fans.c` ..... datoteka za upravljanje ventilatorima
- `inverter_temperature_fans.h` ..... *header* datoteka
- `mtpa_lookup.tbl` ..... pregledna tablica MTPA algoritma

Slika 4.6: Struktura projekta s razvijenim algoritmima u *Code Composer Studio*-u

4.3.Mjerna oprema

Uz integriranu mjernu opremu na samom pretvaraču *Open4Lab*, laboratorijski postav opremljen je i dodatnom mjernom opremom u svrhu snimanja i obrade veličina ispitivanog PMSG-a. Dodatna

mjerna oprema prikazana je na 4.7, a čine je tri mjerna pretvornika namijenjena mjerenju faznih struja PMSG-a, davač momenta, rezolver i akvizicijski sustav *Dewesoft Sirius*. Nazivni podaci dodatne mjerne opreme dani su u tablici 4.2. Iz istog razloga kao i kod pretvornika integriranih na upravljačku ploču pretvarača *Open4Lab*, kroz pretvornike LEM IT 205-S ULTRASTAB provučeno je sedam zavoja po svakoj fazi budući da je maksimalni mjerni opseg ovih pretvornika 283 A, u odnosu na maksimalnu struju PMSG-a od 16,4 A. Osim mjerene struje, na akvizicijski sustav dovodi se mjereni moment s davača momenta, dok se signali rezolvera na sustav *Sirius* ne dovode izravno, već mu se prosljeđuju nakon obrade u upravljačkom sustavu. Uz signal mjerene brzine vrtnje i kuta rotora s rezolvera, upravljački sustav preko DAC sučelja šalje i signale estimirane i uzorkovane struje, estimirane brzine vrtnje te greške između estimiranog i mjerenog kuta rotora. Svi navedeni signali dovedeni su na ulaze akvizicijskog sustav koji se sastoji od tri međusobno povezana i sinkronizirana *Sirius* modula. Signali se uzorkuju frekvencijom od 100 kHz te se prikazuju, obrađuju i pohranjuju na računalu putem programskog alata *Dewesoft X3*.

(a) Mjerni pretvornici LEM IT 205-S ULTRASTAB

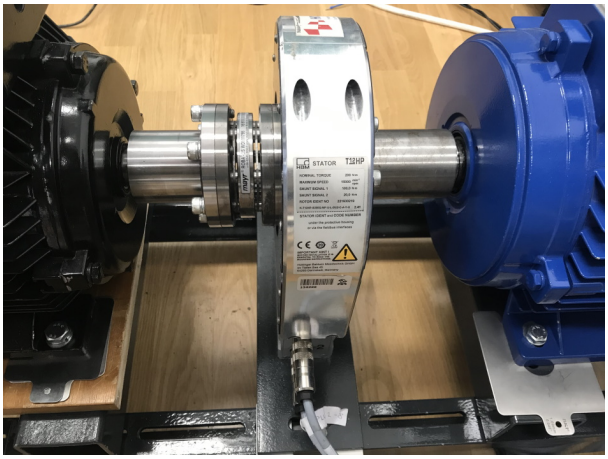

(b) Davač momenta HBT12HP

(c) Rezolver LTN RE-27-1-V31

(d) Akvizicijski sustav Sirius

Slika 4.7: Mjerna oprema

Tablica 4.2: Nazivni podaci mjerne opreme

Davač momenta	
Proizvođač	HBM
Tip	T12HP
Klasa točnosti	0,02
Frekvencijski raspon	6 kHz (-3 dB)
Nazivni moment	200 Nm
Granični moment	200 %
Moment kočenja	> 400 %
Maksimalna brzina vrtnje	15000 o/min
Rezolver	
Proizvođač	LTN
Tip	RE-27-1-V31
Broj polova	4
Omjer namota primara i sekundara	0,5 ± 10%
Napon primarnog namota	7 V
Struja primarnog namota	30 mA
Frekvencija	10 kHz
Maksimalna brzina vrtnje	16000 o/min
Mjerni pretvornik struje	
Proizvođač	LEM
Tip	IT 205-S ULTRASTAB
Omjer namota primara i sekundara	0,001
Nazivni mjerni opseg	200 A
Maksimalni mjerni opseg	283 A
Akvizicijski sustav	
Proizvođač	Dewesoft
Tip	Sirius HS
Frekvencija uzorkovanja	do 1 MHz

5. Bezsenzorsko upravljanje PMSG-om zasnovano na opserveru u kliznom načinu rada

5.1.Pregled literature

Kao što je već rečeno, upravljanje izmjeničnim električnim strojevima poput PMSG-a često se izvodi u rotirajućem dq koordinatnom sustavu kako bi se osiguralo neovisno upravljanje magnetskim tokom i momentom. Primjer takvog upravljanja je i već spomenuti RFOC algoritam iz potpoglavlja 2.5. Međutim, za upravljanje u rotirajućem dq koordinatnom sustavu nužno je poznavati kut rotora θ_{re} kako bi se, pomoću Parkove transformacije, dobio model PMSG-a u dq rotirajućem koordinatnom sustavu iz (2.60). Također, kako je vidljivo iz (2.60), za postavljanje modela PMSG-a u rotirajućem dq koordinatnom sustavu potrebno je poznavati i brzinu vrtnje rotora pa stoga algoritmi za estimaciju kuta rotora najčešće uključuju i estimaciju brzine vrtnje rotora PMSG-a.

Standardni RFOC algoritam, čija je struktura prikazana na slici 2.17, podrazumijeva dobivanje informacije o kutu rotora pomoću mjernog uređaja kao što je rezolver ili enkoder. Međutim, u upravljačkim sustavima teži se smanjenju broja mjernih uređaja s ciljem povećanja pouzdanosti i smanjenja troškova [55]. Iz tog razloga, razvijene su mnoge metode estimacije kuta rotora i brzine vrtnje PMSG-a koje se mogu podijeliti na dvije skupine [55]:

1.metode temeljene na anizotropiji * PMSG-a i

2.metode temeljene na modelu PMSG-a.

Prva istraživanja i implementacija bezsenzorskih upravljačkih algoritama za PMSG temeljili su se na modelu PMSG-a te su postizali visoku uspješnost estimacije pri srednjim i velikim brzinama vrtnje. Razlog uspješne estimacije u tom opsegu brzina vrtnje je taj što algoritmi temeljeni na modelu PMSG-a najčešće estimiraju kut i brzinu rotora neizravno, preko estimiranog induciranog napona. Budući da je vrijednost induciranog napona pri malim brzinama također mala, takvi algoritmi pri malim brzina vrtnje ne daju dobre rezultate uslijed niskog omjera signala

*anizotropija je istoznačnica magnetskoj nesimetriji

i šuma (engl. *Sound to Noise Ratio*, SNR), utjecaja nelinearnosti pretvarača i sl. [55]. Kako bi se područje estimacije proširilo i na male brzine vrtnje razvijene su metode estimacije kuta rotora temeljene na anizotropiji PMSG-a koje iskorištavaju magnetsku nesimetriju PMSG-a kako bi estimirale kut rotora pri malim brzina te čak i u mirovanju.

Na slici 5.1 prikazan je dijagram s podjelom metoda za estimaciju kuta i brzine rotora PMSG-a [55]. Kao što je vidljivo iz dijagrama, metode estimacije temeljene na anizotropiji PMSG-a dijele se na metode temeljene na injektiranju visokofrekvencijskih (VF) naponskih signala te metode temeljene na primjeni klasične PWM modulacijske tehnike (engl. *Fundamental Pulsewidth Modulation Excitation*, FPE).

Metode injektiranja VF naponskih signala mogu se podijeliti prema vrsti injektiranog signala gdje se rotirajući VF signali injektiraju u $\alpha\beta$ koordinatnom sustavu, dok se pulsirajući VF signali injektiraju u dq koordinatnom sustavu. Nakon injekcije VF naponskog signala u PMSG, potrebno je, neovisno o vrsti injektiranog signala, odrediti kut rotora PMSG-a. Kod metoda s injektiranjem rotirajućeg VF signala kut rotora najčešće se određuje iz negativne komponente VF odziva struje u $\alpha\beta$ koordinatnom sustavu koristeći metodu negativne komponente struje (engl. *Negative-Sequence Current Method*) ili, pak, iz mjerene nul-komponente napona PMSG-a (engl. *Zero Sequence Voltage Method*). Nadalje, kod metoda s injektiranjem pulsirajućeg VF signala, VF naponski signal može biti sinusni ili pravokutni. Prilikom primjene obje vrste signala, kut rotora određuje se iz ovojnice VF odziva mjerene struje PMSG-a koristeći neku od tehnika demodulacije. Glavna prednost metoda s injektiranjem rotirajućeg VF signala je ta što, za razliku od metoda s pulsirajućim VF signalom, nije potrebno poznavati početni kut rotora. S druge strane, metode s pulsirajućim VF signalom su robusnije na nelinearnosti pretvarača te, ukoliko se primjenjuje pravokutni VF signal, omogućuju injektiranje naponskih signala viših frekvencija [55].

Druga skupina metoda za estimaciju kuta rotora PMSG-a temeljena na anizotropiji jesu FPE metode čiji su glavni predstavnici INFORM metoda (engl. *Indirect Flux Detection By Online Reactance Measurement*) [56], ZVVI metoda (engl. *Zero-Voltage Vector Injection Method*) [57] i ZSCD metoda (engl. *Zero-Sequence Current Derivatives*). INFORM metoda je jednostavna metoda koja se temelji na modifikaciji PWM modulacijske tehnike tako da se tijekom trajanja nul-vektora, koje je pri malim brzinama relativno dugačko, unose dva suprotna aktivna vektora jednakog trajanja kako bi srednja vrijednost napona PMSG-a tijekom jednog perioda sklapanja ostala ista. Određivanjem derivacije induciranih struja koje su uzrokovane dodatnim aktivnim naponskim vektorima može se odrediti kut rotora PMSG-a. Za razliku od INFORM metode, ZVVI metoda ne unosi dodatne naponske vektore, već modificira PWM modulaciju na način da proširuje trajanje nul-vektora u usporedbi s klasičnom PWM tehnikom, a kut rotora određuje se na temelju matematičkog modela PMSG-a u $\alpha\beta$ koordinatnom sustavu za vrijeme trajanja nul-vektora. Glavna prednost ZVVI metode je neosjetljivost na promjenu parametara PMSG-a.

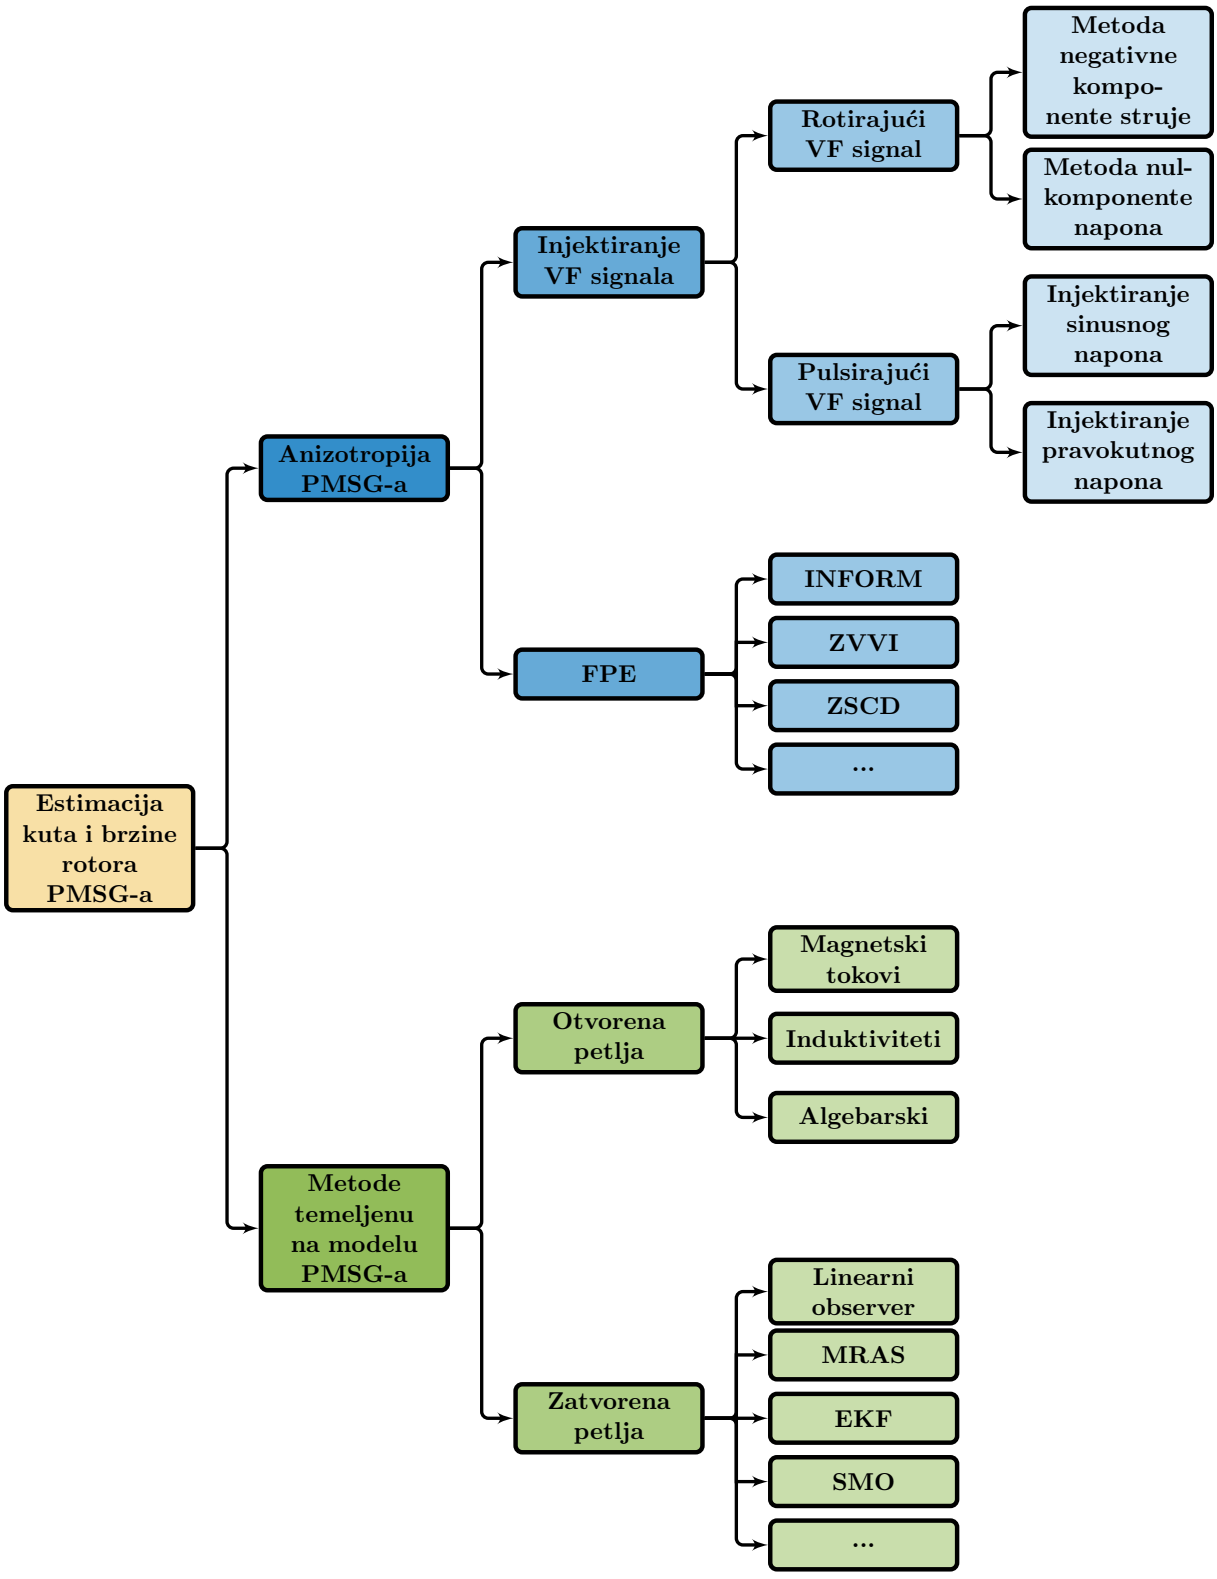

Slika 5.1: Podjela metoda za estimaciju kuta i brzine rotora PMSG-a

Na kraju, ZSCD metoda primjenjuje testne naponske nul-vektore i određuje kut rotora na temelju mjerenih derivacija tranzijentnih struja uzrokovanih testnim naponima.

Iako metode temeljene na anizotropiji pokazuju zadovoljavajuće rezultate, osobito pri malim brzina vrtnje PMSG-a, injektiranje dodatnih VF signala donosi i negativne posljedice poput povećanja gubitaka, akustične buke i oscilacije momenta. Također, pri velikim brzinama moguće je da pretvarač ne može osigurati dovoljno napona za injektiranje dodatnih naponskih signala. Iz tog razloga, pri srednjim i velikim brzinama pogodnije je koristiti metode estimacije kuta i brzine rotora PMSG-a temeljene na njegovom matematičkom modelu. Prema tome, zbog činjenice da je radno područje vjetroagregata ograničeno minimalnom dozvoljenom brzinom vjetra, odnosno vrtnje rotora, koja se naziva uklopna brzina [19], metode temeljene na modelu PMSG-a prikladne su za primjenu u vjetroagregatima.

Metode estimacije temeljene na modelu PMSG-a dijele se na metode u otvorenoj i metode u zatvorenoj petlji [19]. Glavno svojstvo metoda u otvorenoj petlji jest njihova jednostavnost u vidu implementacije u upravljački sustav. U [58] kut rotora određen je preko arkus tangens funkcije omjera rotorskog magnetskog toka u β i α-osi. Komponente rotorskih tokova u statorskom $\alpha\beta$ koordinatnom sustavu dobivene su integracijom statorskih naponskih jednadžbi u β i α-osima. S obzirom da su statorski i rotorski magnetski tokovi jednaki jedino u praznom hodu, dok se pri opterećenju razlikuju za kut opterećenja, potrebno je primijeniti metodu aktivnog toka (engl. *Active Flux*) predstavljenu u [59] kako bi se osigurala točna estimacija u cijelom radnom području PMSG-a. Također, budući da ova metoda koristi integraciju naponske jednadžbe, potrebno je poznavati početne uvjete integracije te osigurati uklanjanje istosmjerne komponente. Osim metoda estimacije kuta rotora preko magnetskih tokova, kut rotora PMSG-a moguće je odrediti estimirajući fazne induktivitete s obzirom na to da su fazni induktiviteti PMSG-a funkcije kuta rotora [60]. Nadalje, u [61] je pokazano kako se kombinacijom algebarskih jednadžbi struja i napona PMSG-a u $\alpha\beta$ i dq koordinatnom sustavu također može odrediti kut rotora PMSG-a. Međutim, unatoč jednostavnoj primjeni, glavni nedostaci metoda estimacije kuta rotora i brzine vrtnje PMSG-a u otvorenoj petlji jesu izrazita osjetljivost na točnost mjerenja napona i struja kao i na točnost poznavanja parametara PMSG-a.

S druge strane, u svrhu ostvarenja veće točnosti i robusnosti primjenjuju se metode estimacije u zatvorenoj petlji koje se najčešće temelje na nekoj vrsti opservera (slika 3.11) kao što su linearni opserveri [62–64], EKF filtri (engl. *Extended Kalman Filter*) [65–67], MRAS (engl. *Model Reference Adaptive System*) opserveri, SMO opserveri i sl. [19, 55].

Među prvim metodama estimacije u zatvorenoj petlji korišteni su linearni opserveri poremećaja [62]. Model linearnog opservera temeljen je na modelu PMSG-a te uz ulazni napon sadrži i dodatni ulaz koji predstavlja grešku između stvarnog modela i opservera gdje se greška množi s linearnim pojačanjem. Stabilnost linearnog opservera kao i točnost estimacije izrazito ovise o izboru linearnog pojačanja pa su takvi opserveri često osjetljivi na poremećaje u sustavu kao i na

promjene parametara sustava [19]. Jedan od načina kako se može povećati robusnost linearnog opservera jest adaptacijom linearnog pojačanja opservera [63, 68].

Nadalje, povećanje točnosti estimacijskog algoritma može se postići i korištenjem robusnijih metoda poput EKF filtra ili MRAS metode. EKF filtar je rekurzivni stohastički opserver čije glavne korake čine predikcija, proračun Kalmanovog pojačanja i adaptacija [66, 67]. Zbog izrazite robusnosti na poremećaje, EKF je pogodan za primjenu u estimaciji kuta i brzine rotora PMSG-a [65], međutim, primjena EKF algoritma sa sobom nosi i prilično velike nedostatke. Unatoč sve većim dostupnim mikroprocesorskim snagama u upravljačkim sustavima, EKF algoritam i dalje nosi veliko opterećenje na mikroprocesore s obzirom da pri proračunu Kalmanovog pojačanja zahtjeva obavljanje matričnih operacija [65]. Nadalje, unatoč ponekim dostupnim metodama [66], određivanja parametara kovarijantnih matrica EKF filtra i dalje predstavlja izazov te se često svodi na metodu pokušaja i pogrešaka [65].

MRAS metoda također se koristi za estimaciju kuta i brzine vrtnje PMSG-a, a temelji se na referentnom i adaptivnom modelu PMSG-a. Uz primjenu prikladnog adaptivnog mehanizma, izlaz adaptivnog modela konvergirat će k vrijednosti izlaza referentnog modela [19, 69]. Stabilnost MRAS metode određuje se preko Popovljevog kriterija apsolutne stabilnosti [69]. Osim za estimaciju brzine vrtnje, MRAS metodom mogu se estimirati i parametri PMSG-a poput magnetskog toka magneta rotora ili statorskog otpora [69]. Unatoč jednostavnoj mogućnosti implementacije u usporedbi s EKF filtrom, određivanje pojačanja i osiguravanje stabilnosti MRAS metode ponekad nisu trivijalni.

Kao metoda u zatvorenoj petlji koja zadovoljava kriterij visoke robusnosti te jednostavnosti implementacije nameće se i SMO. U proteklim desetljećima teorija kliznih režima nalazi široku primjenu u bezsenzorskim upravljačkim strukturama za različite vrste izmjeničnih strojeva pa tako i PMSG. Najčešće se metode za estimaciju kuta i brzine vrtnje PMSG-a koje koriste SMO temelje na estimaciji induciranog napona. Većina predloženih SMO-a modelirana je u $\alpha\beta$ koordinatnom sustavu, a budući da je SMO temeljen na matematičkom modelu PMSG-a njegova složenost ovisi o složenosti matematičkog modela samog PMSG-a. Sinkroni generatori s površinskim magnetima (SPMSG) najjednostavniji su za primjenu bezsenzorskog upravljanja temeljenog na SMO-u jer je informacija o kutu rotora sadržana isključivo u vektoru induciranog napona pa se kut rotora može jednostavno odrediti primjenom opservera kao što je SMO. S druge strane, matematički model sinkronog generatora s unutarnjim magnetima (IPMSG), zbog magnetske nesimetrije ($L_d \neq L_q$), mnogo je složeniji budući da informacija o kutu rotora nije sadržana samo u vektoru induciranog napona, već i u matrici induktiviteta. Iz tog razloga, za primjenu SMO-a kod IPMSG-a potrebno je napraviti rekonstrukciju modela pogodnu za dizajn SMO-a. Najčešća rekonstrukcija modela IPMSG-a temelji se na proširenom induciranom naponu (engl. *Extended Back Electromotive Force*) [64]. Rekonstruirani model u [64] ekvivalentan je modelu SPMSG-a u smislu da je informacija o kutu rotora prisutna isključivo u vektoru proširenog induciranog

napona. Druga najčešća rekonstrukcija modela IPMSG-a nalazi se pod različitim nazivima: model fiktivnog [70], aktivnog [59], djelomičnog [71] ili proširenog [21] magnetskog toka. Svrha ovog modela je također omogućiti estimaciju kuta rotora IPMSG-a primjenom SMO-a. Detaljna usporedba modela PMSG-a temeljenog na proširenom induciranom naponu i aktivnom toku može se naći u [21] gdje se među glavnim prednostima modela temeljenog na aktivnom magnetskom toku izdvaja manja ovisnost o parametrima stroja budući da model temeljen na aktivnom magnetskom toku eksplicitno ovisi o statorskom otporu i induktivitetu u poprečnoj osi, dok model temeljen na proširenom induciranom naponu dodatno ovisi i o induktivitetu u uzdužnoj osi.

Osim različitih matematičkih modela koji se koriste u izvedbi SMO-a, SMO-i mogu upotrebljavati različite upravljačke zakone kako bi signal greške doveli i zadržali na kliznoj plohi. Kod SMO-a prvog reda kao upravljački zakon koriste se signum ili sigmoidna funkcija koje uzrokuju efekt zveketanja što rezultira zašumljenošću estimiranog kuta i brzine rotora pa je za reduciranje zašumljenosti potrebno primijeniti niskopropusni filtar (NPF). Korištenje NPF-a uzrokuje fazni pomak u estimiranom induciranom naponu ovisan o brzini vrtnje PMSG-a što rezultira povećanjem estimacijske greške SMO te je stoga nužno kompenzirati kašnjenje NPF filtra [72]. Drugi način smanjenja šuma uzrokovanog SMO-om je primjena PLL (engl. *Phase-Locked Loop*) regulatora [73–75] ili SMO višeg reda kao što je kao što je STA (engl. super twisting algorithm) algoritam [76].

Unatoč mnogim istraživanjima vezanima za estimaciju kuta i brzine PMSG-a temeljenima na SMO-u, samo nekolicina znanstvenih radova razmatra SMO-e modelirane u rotirajućem dq koordinatnom sustavu [71, 77–79]. Metode predstavljene u [71, 78] estimiraju kut i brzinu vrtnje PMSG-a koristeći Ljapunovljevu funkciju, dok je u [77, 79] SMO modeliran u estimiranom rotirajućem $\gamma\delta$ koordinatnom sustavu na sličan način kao i SMO u $\alpha\beta$ koordinatnom sustavu [21] koristeći model proširenog induciranog napona PMSG-a. Međutim, prednost SMO-a prvog reda u estimiranom rotirajućem $\gamma\delta$ koordinatnom sustavu je ta što su srednje vrijednosti njegovih izlaza istosmjerne veličine, za razliku od sinusnih srednjih vrijednosti izlaza kod SMO-a u $\alpha\beta$ koordinatnom sustavu. Prema tome, korištenje NPF-a neće uzrokovati fazni pomak čime je izbjegnuta potreba za kompenzacijom. Nadalje, budući da je iz izlaza SMO-a u $\gamma\delta$ sustavu moguće estimirati grešku kuta rotora pogodno je primijeniti PLL regulator kako bi se iz estimirane greške kuta estimirao stvarni kut i brzina vrtnje rotora. S obzirom da PLL regulator inherentno posjeduje filtarska svojstva, primjena takvog rješenja omogućuje istovremenu estimaciju i dodatno filtriranje estimiranog kuta rotora i brzine vrtnje. Nadalje, korištenjem STA algoritma moguće je dodatno smanjiti šum estimiranog kuta i brzine vrtnje. U [79] predstavljena je usporedba metoda estimacije kuta i brzine vrtnje rotora PMSG-a primjenom SMO-a temeljenog na modelu proširenog induciranog napona u $\alpha\beta$ i estimiranom $\gamma\delta$ koordinatnom sustavu, dok s druge strane, u dostupnoj znanstvenoj literaturi nije pronađena metoda bezsenzorskog upravljanja PMSG-om

pomoću SMO temeljenog na aktivnom toku u estimiranom rotirajućem $\gamma\delta$ koordinatnom sustavu.

5.1.1.Prvi dio znanstvenog doprinosa

U sklopu doktorske disertacije razvijena je metoda bezsenzorskog upravljanja PMSG-a temeljena na SMO-u [80]. Metoda se sastoji od SMO-a modeliranog u estimiranom rotirajućem $\gamma\delta$ koordinatnom sustavu koji omogućuje estimaciju greške između stvarnog dq i estimiranog $\gamma\delta$ koordinatnog sustava te PLL regulatora pomoću kojeg se iz estimirane greške kuta određuju kut i brzina vrtnje rotora PMSG-a. Razvijena metoda temelji se na sličnim pretpostavkama kao i algoritam razvijen u [77], međutim SMO u razvijenom algoritmu modeliran je pomoću modela aktivnog magnetskog toka PMSG-a, za razliku od SMO iz [77] koji je modeliran koristeći model proširenog induciranog napona PMSG-a. Na ovaj način, zadržane su prednosti estimacije kuta i brzine rotora PMSG-a pomoću SMO-a modeliranog u estimiranom rotirajućem $\gamma\delta$ koordinatnom sustavu kao što je manja zašumljenost estimiranih signala, a uz to je postignuta manja ovisnost o parametrima PMSG-a. Pri razvoju SMO-a analizirani su uvjeti postajanja i stabilnosti za klizni režim prvog reda, kao i za klizni režim drugog reda postignut uz pomoć STA algoritma. Za oba slučaja izvedena su pojačanja koja osiguravaju stabilan rad sustava te je napravljena usporedba razvijenog i već postojećih SMO-a.

5.2.Rekonstrukcija matematičkog model PMSG-a

S obzirom da SMO pripada skupini metoda za estimaciju kuta i brzine vrtnje PMSG-a temeljene na njegovom modelu, potrebno je odabrati model PMSG-a prikladan za modeliranje SMO-a željenih svojstava. Prikladan model podrazumijeva postojanje informacije o kutu rotora isključivo u vektoru induciranog napona. Prema tome, standardni modeli dani u poglavlju 2.4 ne zadovoljavaju prethodni uvjet budući da model u dq koordinatnom sustavu uopće ne sadrži informaciju o kutu rotora, dok modeli u $\alpha\beta$ i $\gamma\delta$ koordinatnim sustavima informaciju o kutu rotora, uz vektor induciranog napona, sadrže i u matricama induktiviteta. Kako bi navedeni problem bio riješen, standardni modeli PMSG-a iz potpoglavlja 2.4 rekonstruirani su na temelju koncepta aktivnog magnetskog toka [59].

5.2.1. Model PMSG-a temeljen na aktivnom magnetskom toku rotora u dq koordinatnom sustavu

Aktivni magnetski tok rotora PMSG-a u dq koordinatnom sustavu može se zapisati kao:

$$\boldsymbol{\psi}_{dq}^{AF} = L_q \boldsymbol{i}_{dq} + \psi_r^{AF} \begin{bmatrix} 1 \\ 0 \end{bmatrix}, \tag{5.1}$$

gdje je:

$$\psi_r^{AF} = \psi_r + (L_d - L_q) i_d \tag{5.2}$$

- aktivni magnetski tok rotora.

Uvrštavanjem (5.1) u naponsku jednadžbu PMSG-a u dq koordinatnom sustavu (2.55) dobiva se matematički model temeljen na aktivnom magnetskom toku:

$$\boldsymbol{u}_{dq} = (R_s \mathbf{I} + \mathbf{J}\omega_{re} L_q)\boldsymbol{i}_{dq} + L_q \frac{d\boldsymbol{i}_{dq}}{dt} + \boldsymbol{e}_{dq}^{AF}, \tag{5.3}$$

gdje je:

$$\boldsymbol{e}_{dq}^{AF} = \frac{d\psi_r^{AF}}{dt} \begin{bmatrix} 1 \\ 0 \end{bmatrix} + \omega_{re} \psi_r^{AF} \begin{bmatrix} 0 \\ 1 \end{bmatrix} \tag{5.4}$$

- vektor napona induciranog aktivnim magnetskim tokom rotora.

Prvi član vektora induciranog napona predstavlja derivaciju aktivnog magnetskog toka rotora koja je proporcionalna promjeni struje u d-osi:

$$\frac{d\psi_r^{AF}}{dt} = (L_d - L_q)\frac{di_d}{dt}. \tag{5.5}$$

5.2.2. Model PMSG-a temeljen na aktivnom magnetskom toku rotora u $\alpha\beta$ koordinatnom sustavu

Inverznom Parkovom transformacijom vektora aktivnog toka iz (5.1) s kutom rotora θ_{re} dobiva se vektor aktivnog magnetskog toka u $\alpha\beta$ koordinatnom sustavu:

$$\boldsymbol{\psi}_{\alpha\beta}^{AF} = L_q \boldsymbol{i}_{\alpha\beta} + \boldsymbol{\psi}_{r,\alpha\beta}^{AF}. \tag{5.6}$$

gdje je:

$$\boldsymbol{\psi}_{r,\alpha\beta}^{AF} = \psi_r^{AF} \begin{bmatrix} \cos\theta_{re} \\ \sin\theta_{re} \end{bmatrix} \tag{5.7}$$

- vektor aktivnog magnetskog toka rotora.

Uvrštavanjem prethodnog izraza u naponsku jednadžbu PMSG-a u $\alpha\beta$ koordinatnom sustavu iz (2.46), dobiva se model PMSG-a temeljen na aktivnom magnetskom toku u $\alpha\beta$ koordinatnom sustavu:

$$\boldsymbol{u}_{\alpha\beta} = R_s \boldsymbol{i}_{\alpha\beta} + L_q \frac{d\boldsymbol{i}_{\alpha\beta}}{dt} + \boldsymbol{e}_{\alpha\beta}^{AF}. \tag{5.8}$$

Vektor napona induciran aktivnim magnetskim tokom rotora glasi:

$$\boldsymbol{e}_{\alpha\beta}^{AF} = \frac{d\psi_r^{AF}}{dt} \begin{bmatrix} \cos\theta_{re} \\ \sin\theta_{re} \end{bmatrix} + \omega_{re} \psi_r^{AF} \begin{bmatrix} -\sin\theta_{re} \\ \cos\theta_{re} \end{bmatrix}. \tag{5.9}$$

Prema (5.5), promjena aktivnog magnetskog toga ovisi o promjeni struje u d-osi. Međutim, struja u d-osi u određenoj radnoj točki u području konstantnog momenta konstantnog je iznosa, dok se njena vrijednost mijenja tek uslijed promjene momenta. Prema tome, inducirani napon uzrokovan vrtnjom rotora dominantan je u odnosu na napon induciran zbog promjene struje u d-osi $\left(\omega\psi_r^{AF} \gg \frac{d\psi_r^{AF}}{dt}\right)$ pa se vektor induciranog napona (5.9) može pojednostaviti kao:

$$\boldsymbol{e}_{\alpha\beta}^{AF} \approx \omega_{re}\psi_r^{AF}\begin{bmatrix}-\sin\theta_{re}\\ \cos\theta_{re}\end{bmatrix}. \tag{5.10}$$

5.2.3. Model PMSG-a temeljen na aktivnom magnetskom toku rotora u $\gamma\delta$ koordinatnom sustavu

Ukoliko se nad vektorom aktivnog magnetskog toka iz (5.1) izvrši inverzna Parkova transformacija s kutom greške $\bar{\theta}_{re} = \hat{\theta}_{re} - \theta_{re}$ dobiva se vektor aktivnog magnetskog toka u $\gamma\delta$ koordinatnom sustavu:

$$\boldsymbol{\psi}_{\gamma\delta}^{AF} = L_q\boldsymbol{i}_{\gamma\delta} + \boldsymbol{\psi}_{r,\gamma\delta}^{AF} \tag{5.11}$$

gdje je:

$$\boldsymbol{\psi}_{r,\gamma\delta}^{AF} = \psi_r^{AF}\begin{bmatrix}\cos\bar{\theta}_{re}\\ -\sin\bar{\theta}_{re}\end{bmatrix} \tag{5.12}$$

- vektor aktivnog magnetskog toka rotora.

Uvrštavanjem izraza (5.12) u naponsku jednadžbu PMSG-a u $\gamma\delta$ koordinatnom sustavu iz (2.63), dobiva se model PMSG-a temeljen na aktivnom magnetskom toku u $\gamma\delta$ koordinatnom sustavu:

$$\boldsymbol{u}_{\gamma\delta} = \left(R_s\mathbf{I} + \mathbf{J}\hat{\omega}L_q\right)\boldsymbol{i}_{\gamma\delta} + L_q\frac{d\boldsymbol{i}_{\gamma\delta}}{dt} + \boldsymbol{e}_{\gamma\delta}^{AF}. \tag{5.13}$$

Vektor napona induciran aktivnim magnetskim tokom rotora glasi:

$$\boldsymbol{e}_{\gamma\delta}^{AF} = \frac{d\psi_r^{AF}}{dt}\begin{bmatrix}\cos\bar{\theta}_{re}\\ -\sin\bar{\theta}_{re}\end{bmatrix} + \omega_{re}\psi_r^{AF}\begin{bmatrix}\sin\bar{\theta}_{re}\\ \cos\bar{\theta}_{re}\end{bmatrix}. \tag{5.14}$$

Zanemarenjem promjene aktivnog magnetskog toka kao i kod modela u $\alpha\beta$ koordinatnom sustavu, izraz (5.14) također se može pojednostaviti kao:

$$\boldsymbol{e}_{\gamma\delta}^{AF} \approx \omega_{re}\psi_r^{AF}\begin{bmatrix}\sin\bar{\theta}_{re}\\ \cos\bar{\theta}_{re}\end{bmatrix}. \tag{5.15}$$

5.2.4.Opći zapis modela PMSG-a temeljenog na aktivnom magnetskom toku rotora

Prethodno izvedeni matematički modeli PMSG-a temeljeni na aktivnom magnetskom toku rotora mogu se, neovisno o koordinatnom sustavu, zapisati kao:

$$\frac{d\boldsymbol{i}_x}{dt} = \mathbf{A}\boldsymbol{i}_x + \mathbf{B}\left(\boldsymbol{u}_x - \boldsymbol{e}_x^{AF}\right), \tag{5.16}$$

gdje je $_x$ - koordinatni sustav, **A** - matrica stanja, a **B** matrica ulaza.

Matrice **A** i **B** kao i vektor aktivnog napona za $\alpha\beta$ i $\gamma\delta$ koordinatni sustav prikazani su u tablici 5.1.

Tablica 5.1: Matrice stanja i ulaza te vektor aktivnog induciranog napona PMSG-a za $\alpha\beta$ i $\gamma\delta$ koordinatni sustav

Koordinatni sustav	Matrica stanja	Matrica ulaza	Aktivni inducirani napon
$\alpha\beta$	$\mathbf{A} = -\frac{R_s}{L_q}\mathbf{I}$	$\mathbf{B} = \frac{1}{L_q}\mathbf{I}$	$\boldsymbol{e}_{\alpha\beta}^{AF} = \omega_{re}\psi_r^{AF}\begin{bmatrix}-\sin\theta_{re}\\ \cos\theta_{re}\end{bmatrix}$
$\gamma\delta$	$\mathbf{A} = -\frac{R_s}{L_q}\mathbf{I} - \hat{\omega}_{re}\mathbf{J}$	$\mathbf{B} = \frac{1}{L_q}\mathbf{I}$	$\boldsymbol{e}_{\gamma\delta}^{\mathrm{AF}} = \omega_{re}\psi_r^{AF}\begin{bmatrix}\sin\bar{\theta}_{re}\\ \cos\bar{\theta}_{re}\end{bmatrix}$

S obzirom da je SMO namijenjen za primjenu u digitalni upravljački sustav, a temelji se na matematičkom modelu PMSG-a, model PMSG-a potrebno je diskretizirati kako bi se omogućilo modeliranje diskretnog SMO-a. U tu svrhu može se primijeniti unaprijedna Eulerova diskretizacija $\left(\frac{di}{dt} \approx \frac{i_{[k+1]} - i_{[k]}}{T_s}\right)$ nad općim modelom PMSG-a iz (5.16) te se dobiva:

$$\boldsymbol{i}_{x[k+1]} = \mathbf{A}_d\boldsymbol{i}_{x[k]} + \mathbf{B}_d\left(\boldsymbol{u}_{x[k]} - \boldsymbol{e}_{x[k]}^{AF}\right), \tag{5.17}$$

gdje su $\mathbf{A}_d$ i $\mathbf{B}_d$ - matrice stanja i ulaza diskretizirane s vremenom diskretizacije T_s te prikazane u tablici 5.2.

Tablica 5.2: Diskretne matrice stanja i ulaza PMSG-a za $\alpha\beta$ i $\gamma\delta$ koordinatni sustav

Koordinatni sustav	Matrica stanja	Matrica ulaza
$\alpha\beta$	$\mathbf{A}_d = \left(1 - T_s\frac{R_s}{L_q}\right)\mathbf{I}$	$\mathbf{B}_d = \frac{T_s}{L_q}\mathbf{I}$
$\gamma\delta$	$\mathbf{A}_d = \left(1 - T_s\frac{R_s}{L_q}\right)\mathbf{I} - T_s\hat{\omega}_{re}\mathbf{J}$	$\mathbf{B}_d = \frac{T_s}{L_q}\mathbf{I}$

5.3. Matematički model SMO-a u estimiranom rotirajućem $\gamma\delta$ koordinatnom sustavu temeljen na modelu aktivnog toka PMSG-a

Iz tablice 5.1 očito je da je rekonstrukcijom modela PMSG-a pomoću aktivnog magnetskog toka u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu postignut cilj rekonstrukcije, odnosno, da je informacija o kutu rotora sada sadržana isključivo u vektoru induciranog napona. Prema tome, u nastavku je na temelju rekonstruiranog modela i općeg zapisa SMO-a izveden novi SMO u $\gamma\delta$ koordinatnom sustavu.

5.3.1. Opći zapis modela SMO-a

Na temelju općeg diskretnog modela PMSG-a (5.16) moguće je modelirati i SMO u općem zapisu kao:

$$\hat{\boldsymbol{i}}_{x[k+1]} = \mathbf{A}_d \hat{\boldsymbol{i}}_{x[k]} + \mathbf{B}_d \left(\boldsymbol{u}_{x[k]} - \boldsymbol{z}_{x[k]} \right). \tag{5.18}$$

gdje je $\hat{\boldsymbol{i}}_x$ - vektor estimirane struje, $\boldsymbol{z}_x$ - vektor upravljačkog zakona

$$\boldsymbol{z}_x = f\left(\bar{\boldsymbol{i}}_x\right), \tag{5.19}$$

$f\left(\bar{\boldsymbol{i}}_x\right)$ - funkcija upravljačkog zakona i $\bar{\boldsymbol{i}}_x = \hat{\boldsymbol{i}}_x - \boldsymbol{i}_x$ - greška estimacije struje.

Dinamika greške estimirane struje dobiva se nakon oduzimanja (5.18) od (5.17) te ona glasi:

$$\bar{\boldsymbol{i}}_{x[k+1]} = \mathbf{A}_d \bar{\boldsymbol{i}}_{x[k]} + \mathbf{B}_d (\boldsymbol{e}^{AF}_{x[k]} - \boldsymbol{z}_{x[k]}). \tag{5.20}$$

Uvrštavanjem matrica stanja i ulaza iz tablice 5.2 za $\alpha\beta$ koordinatni sustav, opći model SMO-a dobiva oblik poput onog predstavljenog u [21], dok se uvrštavanjem matrica $\gamma\delta$ koordinatnog sustava dobiva novi SMO predstavljen u nastavku [80].

5.3.2. SMO u estimiranom $\gamma\delta$ koordinatnom sustavu

Korištenjem matrica stanja i ulaza iz tablice 5.1 za $\gamma\delta$ koordinatni sustav, model PMSG-a u $\gamma\delta$ koordinatnom sustavu temeljen na aktivnom magnetskom toku može se zapisati kao:

$$\frac{d\boldsymbol{i}_{\gamma\delta}}{dt} = -\left(\frac{R_s}{L_q}\mathbf{I} - \mathbf{J}\hat{\omega}_{re}\right)\boldsymbol{i}_{\gamma\delta} + \frac{1}{L_q}\boldsymbol{u}_{\gamma\delta} - \frac{1}{L_q}\boldsymbol{e}^{AF}_{\gamma\delta}. \tag{5.21}$$

Predloženi SMO modeliran je na temelju (5.21) te njegov kontinuirani oblik glasi:

$$\frac{d\hat{\boldsymbol{i}}_{\gamma\delta}}{dt} = -\left(\frac{R_s}{L_q}\mathbf{I} - \mathbf{J}\hat{\omega}_{re}\right)\hat{\boldsymbol{i}}_{\gamma\delta} + \frac{1}{L_q}\boldsymbol{u}_{\gamma\delta} - \frac{1}{L_q}\boldsymbol{z}_{\gamma\delta}. \tag{5.22}$$

Nadalje, primjenom diskretnih matrica iz tablice 5.2 na diskretni opći model PMSG-a iz

(5.18), diskretni model PMSG-a u $\gamma\delta$ koordinatnom sustavu glasi:

$$\boldsymbol{i}_{\gamma\delta[k+1]} = \left[\left(1 - \frac{T_s R_s}{L_q}\right)\mathbf{I} - \mathbf{J}T_s\hat{\omega}_{re[k]}\right]\boldsymbol{i}_{\gamma\delta[k]} + \frac{T_s}{L_q}\boldsymbol{u}_{\gamma\delta[k]} - \frac{T_s}{L_q}\boldsymbol{e}^{AF}_{\gamma\delta[k]}. \tag{5.23}$$

Diskretni oblik SMO-a u $\gamma\delta$ koordinatnom sustavu modelira se na temelju (5.23) kao:

$$\hat{\boldsymbol{i}}_{\gamma\delta[k+1]} = \left[\left(1 - \frac{T_s R_s}{L_q}\right)\mathbf{I} - \mathbf{J}T_s\hat{\omega}_{re[k]}\right]\hat{\boldsymbol{i}}_{\gamma\delta[k]} + \frac{T_s}{L_q}\boldsymbol{u}_{\gamma\delta[k]} - \frac{T_s}{L_q}\boldsymbol{z}_{\gamma\delta[k]}. \tag{5.24}$$

5.4.Analiza uvjeta dohvaćanja i stabilnosti kliznog režima

U svrhu analize uvjeta dohvaćanja i stabilnosti izvedenog SMO-a (5.24) u diskretnoj domeni, potrebno je definirati dinamiku greške struje u $\gamma\delta$ koordinatnom sustavu. S obzirom da je greška definirana kao $\bar{\boldsymbol{i}}_{\gamma\delta} = \hat{\boldsymbol{i}}_{\gamma\delta} - \boldsymbol{i}_{\gamma\delta}$, dinamika greške dobiva se oduzimanjem diskretnog modela PMSG-a iz (5.23) od diskretnog SMO-a iz (5.24):

$$\bar{\boldsymbol{i}}_{\gamma\delta[k+1]} = \left[\left(1 - \frac{T_s R_s}{L_q}\right)\mathbf{I} - \mathbf{J}T_s\hat{\omega}_{re[k]}\right]\bar{\boldsymbol{i}}_{\gamma\delta[k]} - \frac{T_s}{L_q}\boldsymbol{z}_{\gamma\delta[k]} + \frac{T_s}{L_q}\boldsymbol{e}^{AF}_{\gamma\delta[k]}. \tag{5.25}$$

Uz prikladno odabran vektor upravljačkog zakona, trajektorija greške $\bar{\boldsymbol{i}}_{\gamma\delta}$ u prostoru stanja $\left(\bar{\boldsymbol{i}}_{\gamma\delta}, \dot{\bar{\boldsymbol{i}}}_{\gamma\delta}\right)$ težit će k osi $\bar{\boldsymbol{i}}_{\gamma\delta} = 0$ koja predstavlja kvazi-kliznu plohu.

5.4.1.Klizni režim prvog reda

Odabirom signum funkcije za upravljački zakon, vektor upravljačkog zakona može se zapisati kao:

$$\boldsymbol{z}_{\gamma\delta[k]} = K_c\text{sign}(\bar{\boldsymbol{i}}_{\gamma\delta[k]}), \tag{5.26}$$

gdje je K_c - pojačanje upravljačkog zakona.

Kako bi trajektorija greške estimacije struje dostigla kvazi-kliznu plohu $\bar{\boldsymbol{i}}_{\gamma\delta} = 0$ te ostala u njenoj okolini potrebno je odabrati prikladno pojačanje upravljačkog zakona. Pojačanje K_c određuje se uvrštavanjem dinamike greške struje (5.25) u uvjete postojanja i dostizanja kvazi-kliznog režima iz (3.64) i (3.65) čime se dobivaju sljedeći uvjeti:

$$\left[\bar{\boldsymbol{i}}_{\gamma\delta[k+1]} - \bar{\boldsymbol{i}}_{\gamma\delta[k]}\right]\text{sign}(\bar{\boldsymbol{i}}_{\gamma\delta[k]}) < 0, \tag{5.27}$$

$$\left[\bar{\boldsymbol{i}}_{\gamma\delta[k+1]} + \bar{\boldsymbol{i}}_{\gamma\delta[k]}\right]\text{sign}(\bar{\boldsymbol{i}}_{\gamma\delta[k]}) \geq 0. \tag{5.28}$$

Uvjet (5.27) osigurava usmjerenost trajektorije greške estimacije struje prema kvazi-kliznoj plohi $\bar{\boldsymbol{i}}_{\gamma\delta} = 0$. Iz (5.27) očito je da član $\left[\bar{\boldsymbol{i}}_{\gamma\delta[k+1]} - \bar{\boldsymbol{i}}_{\gamma\delta[k]}\right]$ i greška estimacije moraju biti suprotnog predznaka kako bi uvjet bio zadovoljen. Raspisom prvog člana uvjeta (5.27) dobiva

se:

$$\bar{\boldsymbol{i}}_{\gamma\delta[k+1]} - \bar{\boldsymbol{i}}_{\gamma\delta[k]} = \left(-\frac{T_s R_s}{L_q}\mathbf{I} - \mathbf{J}T_s\hat{\omega}_{re[k]}\right)\bar{\boldsymbol{i}}_{\gamma\delta[k]} - \frac{T_s}{L_q}K\text{sign}(\bar{\boldsymbol{i}}_{\gamma\delta[k]}) + \frac{T_s}{L_q}\boldsymbol{e}^{AF}_{\gamma\delta[k]}. \tag{5.29}$$

Kako bi uvjet (5.27) bio zadovoljen, u slučaju pozitivne greške estimirane struje, $\bar{\boldsymbol{i}}_{\gamma\delta[k]} > 0$, izraz (5.29) mora biti negativan što rezultira pojačanjem:

$$K_c > \boldsymbol{e}^{AF}_{\gamma\delta[k]} - \left(R_s\mathbf{I} - \mathbf{J}L_q\hat{\omega}_{re[k]}\right)\bar{\boldsymbol{i}}_{\gamma\delta[k]}. \tag{5.30}$$

S druge strane, uz $\bar{\boldsymbol{i}}_{\gamma\delta[k]} < 0$, izraz (5.29) nužno je pozitivan pa u tom slučaju pojačanje koje osigurava uvjet (5.27) glasi:

$$K_c > -\boldsymbol{e}^{AF}_{\gamma\delta[k]} + \left(R_s\mathbf{I} - \mathbf{J}L_q\hat{\omega}_{re[k]}\right)\bar{\boldsymbol{i}}_{\gamma\delta[k]}. \tag{5.31}$$

S obzirom da uvjet (5.30) obuhvaća i uvjet (5.31), izračunati uvjeti mogu se sažeti kao:

$$K_c > |\boldsymbol{e}^{AF}_{\gamma\delta[k]}| - \left(R_s\mathbf{I} - \mathbf{J}L_q\hat{\omega}_{re[k]}\right)\left|\bar{\boldsymbol{i}}_{\gamma\delta[k]}\right|. \tag{5.32}$$

Nadalje, drugi uvjet dohvaćanja kvazi-klizne plohe iz (5.28) ograničava promjenu greške estimirane struje između k-tog i $k+1$ koraka kako trajektorija ne bi izašla iz okoline kvazi-plohe $\bar{\boldsymbol{i}}_{\gamma\delta[k]} = 0$. Kako bi to bilo osigurano, očito je da član $\left[\bar{\boldsymbol{i}}_{\gamma\delta[k+1]} + \bar{\boldsymbol{i}}_{\gamma\delta[k]}\right]$ i greška estimacije moraju biti istog predznaka, gdje se prvi član može se raspisati kao:

$$\bar{\boldsymbol{i}}_{\gamma\delta[k+1]} + \bar{\boldsymbol{i}}_{\gamma\delta[k]} = \left[\left(2 - \frac{T_s R_s}{L_q}\right)\mathbf{I} - \mathbf{J}T_s\hat{\omega}_{re[k]}\right]\bar{\boldsymbol{i}}_{\gamma\delta[k]} - \frac{T_s}{L_q}K\text{sign}(\bar{\boldsymbol{i}}_{\gamma\delta[k]}) + \frac{T_s}{L_q}\boldsymbol{e}^{AF}_{\gamma\delta[k]}. \tag{5.33}$$

Uz pozitivnu grešku estimacije, $\bar{\boldsymbol{i}}_{\gamma\delta[k]} > 0$, izraz (5.33) također mora biti pozitivan pa pojačanje glasi:

$$K_c \leq \boldsymbol{e}^{AF}_{\gamma\delta[k]} + \left[\left(\frac{2L_q}{T_s} - R_s\right)\mathbf{I} - \mathbf{J}L_q\hat{\omega}_{re[k]}\right]\bar{\boldsymbol{i}}_{\gamma\delta[k]}, \tag{5.34}$$

dok je za negativnu grešku estimacije, $\bar{\boldsymbol{i}}_{\gamma\delta[k]} < 0$, izraz (5.33) negativan pa je u tom slučaju pojačanje:

$$K_c \leq -\boldsymbol{e}^{AF}_{\gamma\delta[k]} - \left[\left(\frac{2L_q}{T_s} - R_s\right)\mathbf{I} - \mathbf{J}L_q\hat{\omega}_{re[k]}\right]\bar{\boldsymbol{i}}_{\gamma\delta[k]}. \tag{5.35}$$

Uvjeti (5.34) i (5.35) mogu se objediniti u izraz:

$$K_c \leq -|\boldsymbol{e}^{AF}_{\gamma\delta[k]}| + \left[\left(\frac{2L_q}{T_s} - R_s\right)\mathbf{I} - \mathbf{J}L_q\hat{\omega}_{re[k]}\right]|\bar{\boldsymbol{i}}_{\gamma\delta[k]}|. \tag{5.36}$$

Konačno, prethodnim izvodom očito je da pojačanje signum upravljačke funkcije ograničeno

s gornje i donje strane

$$|\boldsymbol{e}^{AF}_{\gamma\delta[k]}| - \left(R_s\mathbf{I} - \mathbf{J}L_q\hat{\omega}_{re[k]}\right)|\bar{\boldsymbol{i}}_{\gamma\delta[k]}| < K_c \leq -|\boldsymbol{e}^{AF}_{\gamma\delta[k]}| + \left[\left(\frac{2L_q}{T_s} - R_s\right)\mathbf{I} - \mathbf{J}L_q\hat{\omega}_{re[k]}\right]|\bar{\boldsymbol{i}}_{\gamma\delta[k]}|, \tag{5.37}$$

gdje donja granica osigurava uvjet (5.27), a gornja granica uvjet (5.28).

Navedena ograničenja na pojačanje upravljačke funkcije vrijedit će i ukoliko se za upravljački zakon odabere sigmoidna funkcija uz prikladno odabran parametar Δ [81].

U tablici 5.3 sažeti su prethodno izvedeni uvjeti dohvaćanja i stabilnosti kliznog režima prvog reda za SMO u $\gamma\delta$ koordinatnom sustavu. Uz to, iako nisu izvedeni korak po korak, u tablici su, u svrhu usporedbe, prikazani i uvjeti dohvaćanja i stabilnosti za SMO u $\alpha\beta$ koordinatnom sustavu [21] koji se mogu izvesti na isti način. S obzirom da će amplituda vektora induciranog napona biti najveća pri nazivnoj brzini vrtnje izraz $|\boldsymbol{e}^{AF}_{\gamma\delta[k]}|$ zamijenjen je s $\omega_{re,n}\psi^{AF}_r$ gdje je $\omega_{re,n}$ nazivna električna brzina vrtnje. Kao što je vidljivo iz tablice 5.3, uvjeti stabilnosti SMO-a modeliranog u $\gamma\delta$ koordinatnom sustavu, za razliku od onog modeliranog u $\alpha\beta$ sustavu, sadrže dodatni član $L_q\hat{\omega}_{re[k]}$.

Tablica 5.3: Opći uvjeti dohvaćanja i postojanja kliznog režima prvog reda u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu

Koordinatni sustav	**Uvjet**
$\alpha\beta$	$K_c > \omega_{re,n}\psi^{AF}_r - R_s\left\|\bar{\boldsymbol{i}}_{\alpha\beta[k]}\right\|$ $K_c \leq -\omega_{re,n}\psi^{AF}_r + \left(\frac{2L_q}{T_s} + R_s\right)\left\|\bar{\boldsymbol{i}}_{\alpha\beta[k]}\right\|$
$\gamma\delta$	$K_c > \omega_{re,n}\psi^{AF}_r - (R_s\mathbf{I} + L_q\hat{\omega}_{re[k]}\mathbf{J})\left\|\bar{\boldsymbol{i}}_{\gamma\delta[k]}\right\|$ $K_c \leq -\omega_{re,n}\psi^{AF}_r + \left[\left(\frac{2L_q}{T_s} - R_s\right)\mathbf{I} - \mathbf{J}L_q\hat{\omega}_{re[k]}\right]\left\|\bar{\boldsymbol{i}}_{\gamma\delta[k]}\right\|$

5.4.2.Klizni režim drugog reda

Jedan od najčešće korištenih načina postizanja kliznog režima višeg reda je korištenje STA algoritma [82, 83]. Pomoću STA algoritma moguće je ostvariti klizni režim drugog reda čije je glavno svojstvo smanjenje efekta zveketanja. Opći oblik STA algoritma može se izraziti kao:

$$\begin{aligned}\frac{d\boldsymbol{x}_1}{dt} &= -k_{1c}|\boldsymbol{x}_1|^{\frac{1}{2}}\text{sign}(\boldsymbol{x}_1) + \boldsymbol{x}_2 + \boldsymbol{\rho}_1(\boldsymbol{x}_1, t)\\ \frac{d\boldsymbol{x}_2}{dt} &= -k_{2c}\text{sign}(\boldsymbol{x}_1) + \boldsymbol{\rho}_2(\boldsymbol{x}_2, t),\end{aligned} \tag{5.38}$$

gdje su $\boldsymbol{x}_1$ i $\boldsymbol{x}_2$ - varijable stanja, a $\boldsymbol{\rho}_1(\boldsymbol{x}_1, t)$ i $\boldsymbol{\rho}_2(\boldsymbol{x}_2, t)$ - perturbacije sustava.

U [84], uz pretpostavku $\boldsymbol{\rho}_2(\boldsymbol{x}_2, t) = 0$, dokazana je konvergencija varijable $\boldsymbol{x}_1$ ka kliznoj plohi u konačnom vremenu uz uvjet da je perturbacija sustava omeđena s:

$$\boldsymbol{\rho}_1(\boldsymbol{x}_1, t) \leq \zeta|\boldsymbol{x}_1|^{\frac{1}{2}}, \tag{5.39}$$

gdje je $\zeta \geq 0$ - pozitivna konstanta.

Da bi se osigurao uvjet (5.39) pojačanja sustava (5.38) moraju zadovoljiti sljedeće uvjete [84]:

$$k_{1c} > 2\zeta, \tag{5.40}$$

$$k_{2c} > k_{1c}\frac{5\zeta k_{1c} + 4\zeta^2}{2(k_{1c} - 2\zeta)}. \tag{5.41}$$

Nadalje, sustav (5.38) diskretiziran unaprijednom Eulerovom metodom glasi:

$$\boldsymbol{x}_{1[k+1]} = -\boldsymbol{z}_{[k]} + \boldsymbol{\rho}_1(\boldsymbol{x}_{1[k]}, kT_s) \tag{5.42}$$

gdje je upravljački zakon definiran kao:

$$\begin{aligned} \boldsymbol{z}_{[k]} &= T_s k_{1c} |\boldsymbol{x}_{1[k]}|^{\frac{1}{2}} \text{sign}(\boldsymbol{x}_{1[k]}) + T_s \boldsymbol{x}_{2[k]}, \\ \boldsymbol{x}_{2[k+1]} &= \boldsymbol{x}_{2[k]} + T_s k_{2c} \text{sign}(\boldsymbol{x}_{1[k]}). \end{aligned} \tag{5.43}$$

Odabirom dovoljno malog vremena diskretizacije T_s, trajektorije diskretnog sustava (5.42) i (5.43) konvergirat će ka kvazi-kliznoj plohi gdje je širina kvazi-klizne plohe proporcionalna vremenu diskretizacije kao što je pokazano u [85].

Zamjenom varijable stanja $\boldsymbol{x}_1$ s vektorom greške estimirane struje $\bar{\boldsymbol{i}}_{\gamma\delta}$, prethodni diskretni sustav postaje:

$$\bar{\boldsymbol{i}}_{\gamma\delta[k+1]} = -\boldsymbol{z}_{\gamma\delta[k]} + \boldsymbol{\rho}_{\gamma\delta[k]}, \tag{5.44}$$

a upravljački zakon:

$$\begin{aligned} \boldsymbol{z}_{\gamma\delta[k]} &= T_s k_{1c} |\bar{\boldsymbol{i}}_{\gamma\delta[k]}|^{\frac{1}{2}} \text{sign}\left(\bar{\boldsymbol{i}}_{\gamma\delta[k]}\right) + T_s \boldsymbol{x}_{\gamma\delta[k]} \\ \boldsymbol{x}_{\gamma\delta[k+1]} &= \boldsymbol{x}_{\gamma\delta[k]} + T_s k_{2c} \text{sign}(\bar{\boldsymbol{i}}_{\gamma\delta[k]}). \end{aligned} \tag{5.45}$$

Usporedbom dinamike greške estimirane struje izvedene u (5.25) i izraza (5.44) dobivenog analizom sustava sa STA algoritmom, uočava se da vektor perturbacije za SMO izveden u (5.24) glasi:

$$\boldsymbol{\rho}_{\gamma\delta[k]} = \left[\left(1 - \frac{T_s R_s}{L_q}\right)\mathbf{I} - \mathbf{J}T_s\hat{\omega}_{re[k]}\right]\bar{\boldsymbol{i}}_{\gamma\delta[k]} + \frac{T_s}{L_q}\boldsymbol{e}^{AF}_{\gamma\delta[k]}. \tag{5.46}$$

Kako bi se osigurala maksimalna konstanta ζ potrebno je pronaći najveću perturbaciju. Budući da za bilo koja dva kompleksna broja vrijedi $|\mathbf{z_1}| + |\mathbf{z_2}| \geq |\mathbf{z_1} + \mathbf{z_2}|$, maksimalna perturbacija može se odrediti kao:

$$|\boldsymbol{\rho}_{\gamma\delta[k]}| = \left|\left(1 - \frac{T_s R_s}{L_q}\right)\mathbf{I} - \mathbf{J}T_s\hat{\omega}_{re[k]}\right||\bar{\boldsymbol{i}}_{\gamma\delta[k]}| + \frac{T_s}{L_q}|\boldsymbol{e}^{AF}_{\gamma\delta[k]}|. \tag{5.47}$$

Uvrštavanjem vektora perturbacije u uvjet (5.39) lako se može odrediti konstanta ζ:

$$\zeta \geq \frac{|\boldsymbol{\rho}_{\gamma\delta[k]}|}{|\bar{\boldsymbol{i}}_{\gamma\delta[k]}|^{\frac{1}{2}}} \tag{5.48}$$

Poznavanjem ograničenja konstante ζ moguće je, prema izrazima (5.40) i (5.41), odrediti pojačanja upravljačkog zakona temeljenog na STA algoritmu za izvedeni SMO iz (5.24) koja će osigurati konvergenciju greške estimirane struje ka kvazi-kliznoj plohi $\bar{\boldsymbol{i}}_{\gamma\delta} = 0$.

U tablici 5.4 prikazan je izraz za prethodno određen vektor perturbacije u $\gamma\delta$ koordinatnom sustavu iz (5.46). Također, u tablici se nalazi i vektor perturbacije za $\alpha\beta$ koordinatni sustav iz [76] u svrhu usporedbe. Kao i kod uvjeta za klizni režim prvog reda iz tablice 5.3, vektori perturbacija u $\gamma\delta$ i $\alpha\beta$ koordinatnom sustavu razlikuju se, također, za član $T_s\hat{\omega}_{re[k]}$. U tablici su umjesto samih vektora, dane amplitude vektora perturbacije zbog toga što, prema (5.48), konstanta ζ mora biti veća od vektora perturbacije pa je stoga potrebno poznavati amplitudu perturbacija kako bi pojačanja (5.40) i (5.41) zadovoljila uvjet (5.39). Nadalje, konstanta ζ obrnuto je proporcionalna korijenu greške estimirane struje pa je iz tog razloga potrebno odabrati minimalnu očekivanu grešku estimacije kako bi pojačanja (5.40) i (5.41) zadovoljila uvjet dohvaćanja klizne plohe.

Tablica 5.4: Opći izrazi perturbacija u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu

Koordinatni sustav	**Perturbacija**
$\alpha\beta$	$\|\boldsymbol{\rho}_{\alpha\beta[k]}\| = \left\|1 - \frac{T_s R_s}{L_q}\right\| \|\bar{\boldsymbol{i}}_{\alpha\beta[k]}\| + \frac{T_s}{L_q}\omega_{re,n}\psi_r^{AF}$
$\gamma\delta$	$\|\boldsymbol{\rho}_{\gamma\delta[k]}\| = \left\|\left(1 - \frac{T_s R_s}{L_q}\right)\mathbf{I} - \mathbf{J}T_s\hat{\omega}_{re[k]}\right\| \|\bar{\boldsymbol{i}}_{\gamma\delta[k]}\| + \frac{T_s}{L_q}\omega_{re,n}\psi_r^{AF}$

5.5. Metoda bezsenzorskog upravljanja PMSG-a temeljena na SMO-u u $\gamma\delta$ koordinatnom sustavu

U digitalni upravljački sustav PMSG-a opisan u poglavlju 4 implementiran je SMO u $\gamma\delta$ koordinatnom sustavu izveden u potpoglavlju 5.3. Na slici 5.2 prikazana je načelna shema bezsenzorskog upravljanja PMSG-om primjenom razvijenog SMO-a. Predložena struktura upravljanja temelji se na standardnoj RFOC upravljačkoj strukturi PMSG-om u vjetroagregatu prikazanoj na slici 2.17. Međutim, predložena struktura koristi estimirani kut i brzinu vrtnje rotora, dok se u standardnoj strukturi kut i brzina vrtnje dobivaju mjerenjem na osovini. Predložena metoda estimacije kuta i brzine vrtnje rotora implementirana je u bloku SMO+PLL. Izlaze bloka čine estimirani električni kut i brzina vrtnje rotora, $\hat{\theta}_{re[k]}$ i $\hat{\omega}_{re[k]}$, dok su ulazi u estimacijski blok mjerena struja i referentni napon u estimiranom $\gamma\delta$ koordinatnom sustavu. Kada estimacijska struktura SMO+PLL osigura točnu estimaciju kuta rotora, odnosno kada vrijedi $\hat{\theta}_{re} = \theta_{re}$, dolazi

do poklapanja stvarnog dq koordinatnog sustava i estimiranog $\gamma\delta$ koordinatnog sustava koji se koristi u upravljačkom algoritmu. Ulazna struja $\boldsymbol{i}_{\gamma\delta[k]}$ dobivena je Clarkinom te Parkovom transformacijom s estimiranom kutom $\hat{\theta}_{re[k]}$ nad uzorkovanom trofaznom strujom $\boldsymbol{i}_{abc[k]}$. S druge strane, referentni napon $\boldsymbol{u}^*_{\gamma\delta[k]}$ predstavlja izlaz bloka RFOC nad kojim se vrši inverzna Parkova transformacija s estimiranim kutom kako bi se dobio referentni napon u $\alpha\beta$ koordinatnom sustavu te na temelju njega proračunali faktor modulacije i vremena vođenja pojedinih IGBT-ova generatorskog pretvarača. Zbog pojednostavljenja primjene, predložena upravljačka struktura, za razliku od standardne, ne koristi MPPT krivulju za određivanje referentnog momenta, već se referentni moment zadaje izravno na ulaz MTPA bloka. MTPA krivulje strojeva korištenih u eksperimentima dobivene su obradom eksperimentalnih mjerenja. Interpolacijom pregledne tablice u kojima su pohranjene funkcije $i_d = f(M)$ i $i_q = f(M)$, za zadani referenti moment M^* dobiva se optimalni par struja (i^*_d, i^*_q) koji, uz mjerenu struju $\boldsymbol{i}_{\gamma\delta[k]}$, čini ulaz RFOC algoritma. Uloga bloka RFOC je određivanje referentnog napona $\boldsymbol{u}^*_{\gamma\delta[k]}$ primjenom PI regulatora čije ulaze čine razlika referentne i mjerene struje.

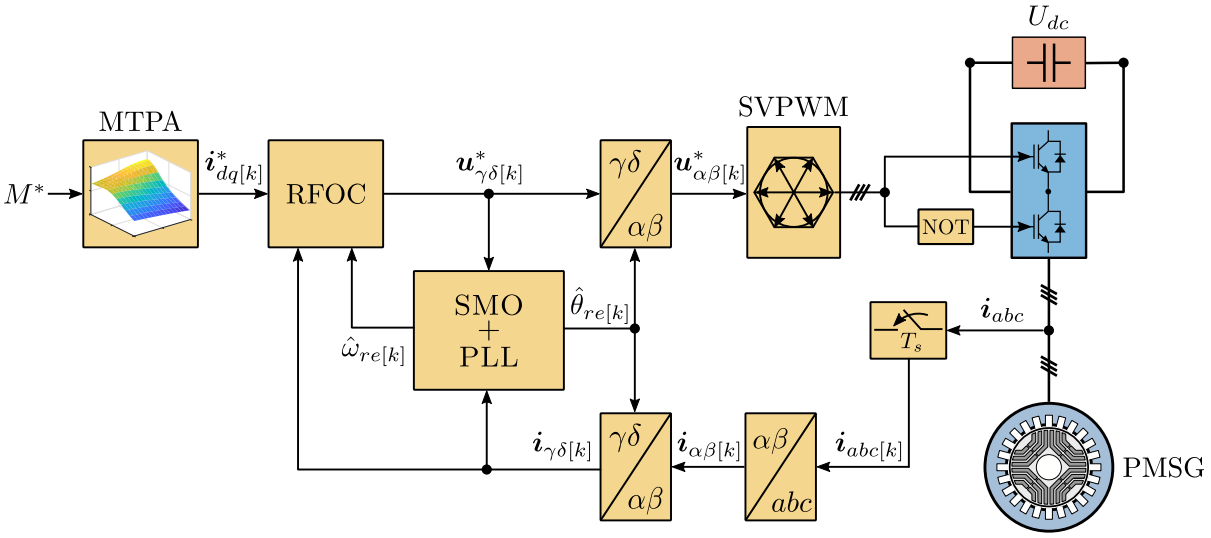

Slika 5.2: Struktura bezsenzorskog upravljanja PMSG-a temeljena na SMO-u

Detaljan prikaz estimacijskog bloka SMO+PLL unutar kojeg su implementirane predloženi SMO te PLL regulator dan je na slici 5.3. S obzirom da je rekonstrukcijom modela PMSG-a u $\gamma\delta$ koordinatnom sustavu na temelju aktivnog magnetskog toka postignuto da kut rotora postoji isključivo u vektoru induciranog napona, glavni zadatak SMO-a predstavlja upravo estimacija tog napona. Ulaz SMO-a predloženog u (5.24) čine referentni napon $\boldsymbol{u}_{\gamma\delta[k]} = \boldsymbol{u}^*_{\gamma\delta[k]}$, vektor upravljačkog zakona $\boldsymbol{z}_{\gamma\delta[k]}$ te estimirana brzina vrtnje $\hat{\omega}_{re[k]}$, dok se na izlazu nalazi estimirana struja u sljedećem diskretnom koraku $\hat{\boldsymbol{i}}_{\gamma\delta[k+1]}$. Estimiranu struja iz prethodnog koraka oduzima se od mjerene struje uzorkovane u k-tom koraku. Na taj način dobiva se greška estimirane struje $\bar{\boldsymbol{i}}_{\gamma\delta[k]}$ koja se prosljeđuje upravljačkom zakonu. U svrhu usporedbe, u upravljačkom sustavu implementirane su tri vrste upravljačkog zakona: signum funkcija, sigmoidna funkcija i STA

algoritam. Vrsta upravljačkog zakona bira se signalom CONTROL LAW TYPE, a vrstu upravljačkog zakona potrebno je odabrati prije početka rada estimacijske strukture te ju nije moguće mijenjati tijekom rada. Neovisno o vrsti, cilj upravljačkog zakona je natjerati trajektorije u prostoru stanja greške estimirane struje $\left(\bar{\boldsymbol{i}}_{\gamma\delta[k]}, \dot{\bar{\boldsymbol{i}}}_{\gamma\delta[k]}\right)$ na kliznu plohu $\bar{\boldsymbol{i}}_{\gamma\delta} = 0$ gdje će vrijediti $\hat{\boldsymbol{i}}_{\gamma\delta[k]} = \boldsymbol{i}_{\gamma\delta[k]}$. Takva dinamika trajektorije greške estimirane struje ostvarit će se primjenom prikladnih pojačanja upravljačkih zakona izvedenih u potpoglavlju 5.4 koji će osigurati uvjete postojanja i stabilnosti kliznog režima. Jednom kada sustav uđe u klizni režim vrijedit će $\bar{\boldsymbol{i}}_{\gamma\delta[k]} = 0$ te će prema (5.25), vektor induciranog napona postati jednak vektoru upravljačkog zakona:

$$\boldsymbol{e}^{AF}_{\gamma\delta[k]} = \boldsymbol{z}_{\gamma\delta[k]} = \omega_{re[k]}\psi^{AF}_{r}\begin{bmatrix}\sin\bar{\theta}_{re[k]}\\ \cos\bar{\theta}_{re[k]}\end{bmatrix}. \tag{5.49}$$

U kliznom režimu prvog reda vektor upravljačkog zakona je visokofrekvencijski signal uzrokovan prekapčanjem signum, odnosno sigmoidne funkcije pa je signal upravljačkog zakona potrebno filtrirati kako bi se dobila srednja vrijednost estimiranog induciranog napona. S druge strane, pri korištenju STA algoritma izlaz upravljačkog zakona inherentno je istosmjerni signal te ga nije nužno filtrirati. Unatoč tome, i u tom slučaju vektor upravljačkog zakona propušten je kroz NPF pa se neovisno o vrsti upravljačkog zakona može pisati:

$$\boldsymbol{e}^{AF}_{\gamma\delta[k]} = \boldsymbol{z}'_{\gamma\delta[k]} = \mathrm{NPF}(\boldsymbol{z}_{\gamma\delta[k]}). \tag{5.50}$$

Iz prethodne jednakosti i izraza za induciranu napon (5.49), očito je da se informacija o kutu rotora može odrediti kao:

$$\bar{\theta}_{re[k]} = \tan^{-1}\left(\frac{z'_{\gamma[k]}}{z'_{\delta[k]}}\right). \tag{5.51}$$

Estimirana informacija o kutu predstavlja kut greške između γ i d-osi te je iz te greške potrebno estimirati kut d-osi, $\hat{\theta}_{re[k]}$. U tu svrhu, estimirana greška kuta $\bar{\theta}_{re[k]}$ dovodi se na ulaz PLL-a koji se sastoji od PI regulatora i integratora. Greška kuta definirana je kao $\bar{\theta}_{re[k]} = \hat{\theta}_{re[k]} - \theta_{re[k]}$ što znači da će pri pozitivnoj grešci kuta estimirani $\gamma\delta$ sustav prethoditi, a u slučaju negativne greške, zaostajati za dq sustavom. Prema tome, kako bi PI regulator ubrzao $\gamma\delta$ sustav pri pozitivnoj grešci kuta, odnosno usporio ga prilikom negativne greške, na ulaz u PLL regulator potrebno je proslijediti negativnu estimiranu grešku kuta:

$$\varepsilon_{[k]} = -\tan^{-1}\left(\frac{z'_{\gamma[k]}}{z'_{\delta[k]}}\right). \tag{5.52}$$

Estimirana brzina vrtnje propušta se kroz NPF te se šalje u SMO te RFOC algoritam. Na kraju, integracijom estimirane brzine vrtnje s izlaza PI regulatora određuje estimirani kut rotora $\hat{\theta}_{re[k]}$ koji se koristi u bezsenzorskoj upravljačkoj strukturi sa slike 5.2.

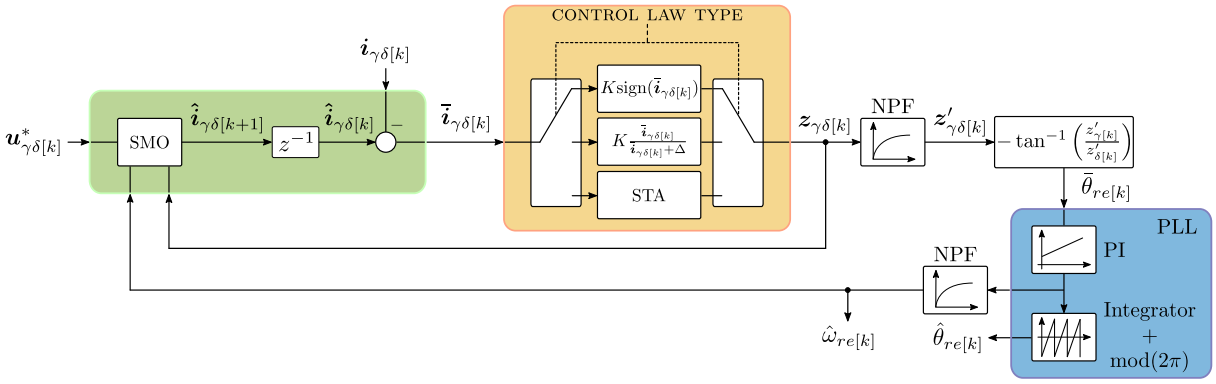

Slika 5.3: Struktura estimacije kuta i brzine vrtnje rotora PMSG-a temeljena na SMO-u i PLL regulatoru

5.6.Eksperimentalni rezultati

Prethodno predstavljena bezsenzorska upravljačka struktura temeljena na SMO-u $\gamma\delta$ koordinatnom sustavu implementirana je u upravljački sustav pretvarača *Open4Lab* i eksperimentalno je verificirana na laboratorijskom postavu iz poglavlja 4. Metoda je ispitana za tri različita upravljačka zakona: signum funkciju, sigmoidnu funkciju i STA algoritam. Također, predstavljena metoda eksperimentalno je uspoređena s bezsenzorskom metodom temeljenoj na SMO-u u $\alpha\beta$ koordinatnom sustavu.

Pri implementaciji u digitalni upravljački sustav korišteni su parametri PMSG-a u jediničnom sustavu vrijednosti proračunati pomoću baznih vrijednosti iz tablice 5.5. Također, u tablici 5.5 dani su i parametri nadomjesne sheme PMSG-a potrebni za modeliranje SMO-a te određivanje pojačanja PI regulatora struja. Metoda određivanja parametara nadomjesne sheme PMSG-a detaljno je opisana u poglavlju 7. Vrijeme diskretizacije jednako je vremenu izvođenja prekidne rutine i iznosi $T_s = 0,0002$ s, dok je napon istosmjernog međukruga $U_{dc} = 540$ V.

Tablica 5.5: Bazne vrijednosti PMSG-a i parametri nadomjesne sheme PMSG-a u sustavu jediničnih vrijednosti

Bazne vrijednosti	$U_b = 289$ V, $\psi_{r,b} = 0,92$ Wb, $\omega_{re,b} = 314,16$ rad/s, $L_b = 56,1$ mH,	$I_b = 16,4$ A $f_b = 50$ Hz $Z_b = 17,62\ \Omega$ $M_b = 35,01$ Nm
	SI	p.u.
Parametri nadomjesne sheme	$R_s = 0,894\ \Omega$, $L_d = 23,8$ mH, $L_q = 65,3$ mH, $\psi_r = 0,92$ Wb,	$R_{s,pu} = 0,051$ $L_{d,pu} = 0,4238$ $L_{q,pu} = 1,1636$ $\psi_{r,pu} = 1$

Pojačanja vektora upravljačkih zakona za klizni režim prvog reda proračunata su prema izrazima za $\gamma\delta$ koordinatni sustav iz tablice 5.3, dok su pojačanja STA algoritma proračunata

iz izraza za perturbaciju u $\gamma\delta$ sustavu iz tablice 5.4 te izraza (5.40), (5.41) i (5.48). Pri odabiru pojačanja pretpostavljena je greška estimirane struje u iznosu od $|\bar{\boldsymbol{i}}_{\alpha\beta[k]}| = |\bar{\boldsymbol{i}}_{\gamma\delta[k]}| = 0,01$ p.u. Također, prema (5.2), aktivni magnetski tok ovisi o struji u d-osi čija je maksimalna vrijednost pretpostavljena u nazivnoj radnoj točki. Uzimajući u obzir MTPA krivulju, za maksimalni kut opterećenja vrijedi $\gamma \approx 40°$ pa je odabrana maksimalna struja $i_d = -0,6$ p.u. Nadalje, donja granica uvjeta stabilnosti STA algoritma, prema (5.40) i (5.41), nije strogo određena pa je za uvjet (5.40) proizvoljno odabran faktor od 1%, a za uvjet (5.41) faktor 5%:

$$k_{1c} > 1,01 \cdot 2\zeta, \tag{5.53}$$

$$k_{2c} > 1,05 \cdot k_{1c} \frac{5\zeta k_{1c} + 4\zeta^2}{2(k_{1c} - 2\zeta)}. \tag{5.54}$$

Na temelju navedenih pretpostavki i parametara nadomjesne sheme PMSG-a u sustavu jediničnih vrijednosti iz tablice 5.5 proračunata su ograničenja pojačanja upravljačkih funkcija SMO-a te su prikazana u tablici 5.6. Sva ograničenja proračunata su za brzinu vrtnje $\omega_{re} = 1$ p.u. Na temelju izračunatih ograničenja odabrana su pojačanja prikazana u tablici 5.7.

Tablica 5.6: Ograničenja pojačanja upravljačkih funkcija SMO-a u $\gamma\delta$ koordinatnom sustavu

Signum/Sigmoid	**STA**
$K_c > 1,4438$ $K_c < 91,6365$	$\lvert\boldsymbol{\rho}_{\gamma\delta[k]}\rvert = 0,0673$, $\zeta = 0,6734$ $k_{1c} \geq 1,3602$, $k_{2c} \geq 339,0225$

Tablica 5.7: Odabrana pojačanja upravljačkih funkcija SMO-a u $\gamma\delta$ koordinatnom sustavu

Signum	**Sigmoid**	**STA**
$K_c = 1,5$	$K_c = 1,5$, $\Delta = 0,0002$	$k_{1c} = 1,3602$ $k_{2c} = 339,0225$

Parametri PI regulatora struja izračunati su pomoću metode postavljanja polova koristeći parametre nadomjesne sheme PMSG-a u sustavu jediničnih vrijednosti iz tablice 5.5, dok su pojačanja PLL regulatora određena prema simetričnom optimumu [43], uz parametar $\alpha = 25$ te su dani u tablici 5.8. U tablici su još prikazani i vremenska konstanta filtra kroz koju se propušta ulaz u PLL regulatora te vremenska konstanta filtra estimirane brzine vrtnje. Referentne vrijednosti struje čitaju se iz pregledne tablice na temelju zadanog referentnog momenta koji se mijenja prema vremenskoj rampi od 5 s.

5.6.1. Verifikacija bezsenzorske metode temeljene na SMO-u $\gamma\delta$ koordinatnom sustavu

U nastavku su prikazani odzivi bezsenzorskog upravljanja PMSG-om temeljeni na upravljačkoj i estimacijskoj strukturi sa slika 5.2 i 5.3 te parametrima određenima u tablicama 5.7 i 5.8. Na svim

Tablica 5.8: Pojačanja PI i PLL regulatora

PI regulator		**PLL regulator**	
***d*-os**	***q*-os**		
$K_{pd} = 2,2485,$	$K_{pq} = 6,1728,$	$K_p^{PLL} = 0,6366,$	$T_i^{PLL} = 125$ ms
$T_{id} = 26,6$ ms,	$T_{iq} = 73$ ms,	$T_f^{PLL} = 10$ ms,	$T_f^{\omega} = 100$ ms

slikama prikazani su odzivi mjerene i estimirane brzine vrtnje, ω_{re} i $\hat{\omega}_{re}$, mjerenog i estimiranog kuta rotora, θ_{re} i $\hat{\theta}_{re}$, greške estimacije kuta rotora $\bar{\theta}_{re}$, referentnog i razvijenog momenta, M^* i M, mjerene i estimirane struje, $\boldsymbol{i}_{\gamma\delta}$ i $\hat{\boldsymbol{i}}_{\gamma\delta}$, te referentne struje $\boldsymbol{i}_{dq}^*$ i mjerene struje $\boldsymbol{i}_{dq}$.

Navedeni odzivi snimljeni su za tri vrste upravljačkih funkcija: signum, sigmoidnu i STA algoritam te su prikazani na slikama 5.4, 5.5 i 5.6. Neovisno o korištenoj upravljačkoj funkciji, ispitano je ponašanje predložene bezsenzorske upravljačke strukture u tri radne točke: promjena brzine vrtnje pri neopterećenom PMSG-u, terećenje PMSG-a pri konstantnoj brzini vrtnje i promjena brzine vrtnje pri konstantnom teretu.

Na slikama 5.4a, 5.5a i 5.6a dani su odzivi za prvu radnu točku, odnosno promjenu brzine vrtnje rotora s $\omega_r = 0,33$ p.u. na $\omega_r = 0,83$ p.u. Analizom snimljenih odziva vidljivo je da predložena estimacijska struktura temeljena na SMO-u u $\gamma\delta$ koordinatnom sustavu uspješno estimira kut i brzinu vrtnje prilikom promjene brzine vrtnje kao i u stacionarnom stanju za sva tri vrste upravljačkih funkcija. Također, nakon završetka prijelazne pojave u sva tri odziva može se uočiti blagi porast greške estimiranog kuta. Ova greška, uzrokovana promjenom brzine vrtnje, može se reducirati kompenzacijom kašnjenja digitalnog upravljačkog sustava [86] koja trenutno nije implementirana budući da je greška unutar prihvatljivih granica, $\bar{\theta} \leq 5°$.

Druga radna točka, određena promjenom tereta PMSG-a pri konstantnoj brzini $\omega_{re} = 0,33$ p.u., prikazana je na slikama 5.4b, 5.5b i 5.6b. Zadana je referentna vrijednost momenta $M^* = -1,48$ p.u. koja odgovara amplitudi struje od 1 p.u. Kao što je vidljivo iz odziva brzine, terećenje PMSG-a ne utječe na točnost estimacije brzine vrtnje, dok se, s druge strane, u signal estimiranog kuta unosi značajna greška koja u sva tri odziva iznosi $\bar{\theta}_{re} \approx 15°$. Unatoč grešci, SMO za pojačanja odabrana prema tablici 5.7 pri zadanom teretu ostaje na kvazi-kliznoj plohi $\bar{\boldsymbol{i}}_{\gamma\delta} = 0$ što se zaključuje iz odziva estimirane struje koja prate mjerenu struju u $\gamma\delta$ sustavu, odnosno vrijedi $\boldsymbol{i}_{\gamma\delta} = \hat{\boldsymbol{i}}_{\gamma\delta}$. Prema tome, uzrok greške estimiranog kuta nije izlazak iz kvazi-kliznog režima, već razlika u stvarnim parametrima PMSG-a koji se mijenjaju zbog magnetskog zasićenja i promjene temperature u trenutnoj radnoj točki te fiksnih parametara PMSG-a korištenih pri modeliranju SMO-a. Posljedica greške estimiranog kuta rotora očituje se u nesrazmjeru između referentnog para struja (i_d^*, i_q^*) i struja koje teku PMSG-om, (i_d, i_q), do kojeg dolazi zbog primjene pogrešnog napona budući da se izlaz iz regulatora struje transformira s estimiranim kutom u koji je unesena greška. S obzirom da par struja (i_d, i_q) ne odgovara referentnom momentu prema MTPA algoritmu, razvijeni moment također odstupa od referentnog. Ova problematika i njeno

rješenje detaljnije su opisani u poglavlju 7.

U trećoj radnoj točki prikazanoj na slikama 5.4c, 5.5c i 5.6c estimacija brzine ostaje točna i pri promjeni brzine opterećenog PMSG-a. Greška estimiranog kuta se, budući da ovisi o momentu PMSG-a koji je ostao nepromijenjen, nakon kratkotrajne prijelazne pojave ustaljuje na jednakom iznosu što rezultira istim neslaganjima referentnih i mjernih struja, odnosno momenta.

5.6.2. Usporedba bezsenzorske metode upravljanja temeljene na SMO-a u $\gamma\delta$ i $\alpha\beta$ koordinatnom sustavu

U svrhu usporedbe eksperimentalnih rezultata razvijene bezsenzorske metode upravljanja iz prethodnog poglavlja, unutar upravljačke strukture sa slike 5.2 na laboratorijskom postavu je implementirana i struktura estimacije kuta i brzine rotora temeljena SMO-u u $\alpha\beta$ koordinatnom sustavu [21].

Ograničenja pojačanja za sva tri implementirana upravljačka zakona izračunate su prema izrazima za $\alpha\beta$ koordinatni sustav iz tablice 5.3, odnosno tablice 5.4 i izraza (5.40), (5.41) i (5.48) uz jednake pretpostavke kao i kod SMO-a u $\gamma\delta$ koordinatnom sustavu. Izračunata ograničenja i odabrana pojačanja SMO-a u $\alpha\beta$ koordinatnom sustavu dani su u tablicama 5.9 i 5.10.

Tablica 5.9: Ograničenja pojačanja upravljačkih funkcija SMO-a u $\alpha\beta$ koordinatnom sustavu

Signum/Sigmoid	**STA**
$K_c > 1,4438$ $K_c < 91,6365$	$\lvert\boldsymbol{\rho}_{\alpha\beta[k]}\rvert = 0,0879$, $\zeta = 0,8794$ $k_1 \geq 1,7588$, $k_2 \geq 578,1835$

Tablica 5.10: Odabrana pojačanja upravljačkih funkcija SMO-a u $\alpha\beta$ koordinatnom sustavu

Signum	**Sigmoid**	**STA**
$K_c = 1,5$	$K_c = 1,5$, $\Delta = 0,0002$	$k_1 = 1,7764$ $k_2 = 578,1835$

Upravljačka struktura koristi jednaka pojačanja PI regulatora struja iz tablice 5.8 kao i u slučaju SMO u $\gamma\delta$ sustavu. Također, struktura PLL regulatora je ostala nepromijenjena kao i filtar estimirane brzine vrtnje, međutim u slučaju SMO-a u $\alpha\beta$ sustavu ulaz u PLL regulator više se ne računa prema izrazu (5.52), već glasi:

$$\varepsilon_{[k]} = -\frac{1}{\Gamma}\left(z_{\alpha[k]}\cos\hat{\theta}_{re[k]} + z_{\beta[k]}\sin\hat{\theta}_{re[k]}\right), \tag{5.55}$$

gdje je

$$\Gamma = \sqrt{z_\alpha^2 + z_\beta^2}, \tag{5.56}$$

a $z_{\alpha[k]}$ i $z_{\beta[k]}$ - komponente upravljačkog vektora u $\alpha\beta$ koordinatnom sustavu.

Budući da je srednja vrijednost upravljačkog zakona $\boldsymbol{z}_{\alpha\beta}$ sinusna veličina, ulaz u PLL regulator se ne filtrira kako se u signal estimiranog induciranog napona te posljedično estimiranog kuta rotora ne bi unijelo kašnjenje.

Na slici 5.7 usporedno su prikazani odzivi referentnog momenta i estimiranog momenta, brzine vrtnje i estimirane brzine vrtnje te greške estimiranog kuta za strukturu bezsenzorskog upravljanja temeljenog na SMO-u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu. Odzivi su snimljeni za radnu točku određenu konstantnom brzinom vrtnje $\omega_{re} = 0,33$ p.u. i promjenom tereta s $M^* = 0$ p.u. na $M^* = -1,48$ p.u.

Slika 5.7a prikazuje navedene odzive za upravljački zakon temeljen na signum funkciji, slika 5.7b za upravljački zakon temeljen na sigmoidnoj funkciji, a slika 5.7c za upravljački zakon temeljen na STA algoritmu. Analizom prikazanih odziva mogu se uočiti slične karakteristike odziva estimacijskih struktura temeljenih na SMO-u u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu. Neovisno o vrsti upravljačkog zakona, terećenje ne unosi grešku u signal estimirane brzine vrtnje, dok greška estimiranog kuta podjednako raste s porastom tereta za oba SMO-a. Unatoč tome, prednost SMO-a modeliranog u $\gamma\delta$ koordinatnom sustavu predstavlja manja zašumljenost greške estimiranog kuta, odnosno posljedično manja zašumljenost samog signala estimiranog kuta rotora. Iako je u obje estimacijske strukture korišten PLL regulator istih karakteristika, promatrajući odzive za istu upravljačku funkciju, u $\gamma\delta$ sustavu postiže se manja zašumljenost estimiranog kuta u odnosu na $\alpha\beta$ sustav, što je posljedica dodatnog filtriranja ulaza PLL regulatora, koje se u strukturi izvedenoj u $\alpha\beta$ koordinatnom sustavu ne primjenjuje kako bi se izbjegla dodatna greška estimiranog kuta uzrokovana kašnjenjem filtra.

Nadalje, na slici 5.8 prikazano je vrijeme izvođenja algoritama na upravljačkoj pločici Delfino C28343 za estimacijske strukture u oba koordinatna sustava te za sve tri vrste implementiranih upravljačkih zakona. Vrijeme izvođenja je prikazano u postotnom odnosu prema vremenu trajanja jedne PWM periode koja za frekvenciju sklapanja $f_{sw} = 5$ kHz iznosi $T_{sw} = 0,0002$ s. Iz prikazanih podataka, očito je da, neovisno o koordinatnom sustavu SMO-a, najmanje procesorske snage zauzima algoritam temeljen na signum upravljačkoj funkciji, dok je najzahtjevniji STA algoritam. S druge strane, također se može uočiti da bezsenzorska struktura upravljanja temeljena na SMO-u u $\gamma\delta$ koordinatnom sustavu zauzima prosječno $1,4 - 2$ % manje procesorskih resursa od strukture izvedenu u $\alpha\beta$ koordinatnom sustavu. Iako estimacijske strukture izvedene u $\alpha\beta$ i $\gamma\delta$ koordinatnim sustavima relativno slične, glavna razlika očituje se usporedbom ulaza PLL regulatora u (5.52) i (5.55) iz koje je očito da proračun u $\alpha\beta$ koordinatnom sustavu složeniji u odnosu na $\gamma\delta$ sustav s obzirom da sadrži funkcije kvadriranja, korjenovanja te funkcije sinus i kosinus.

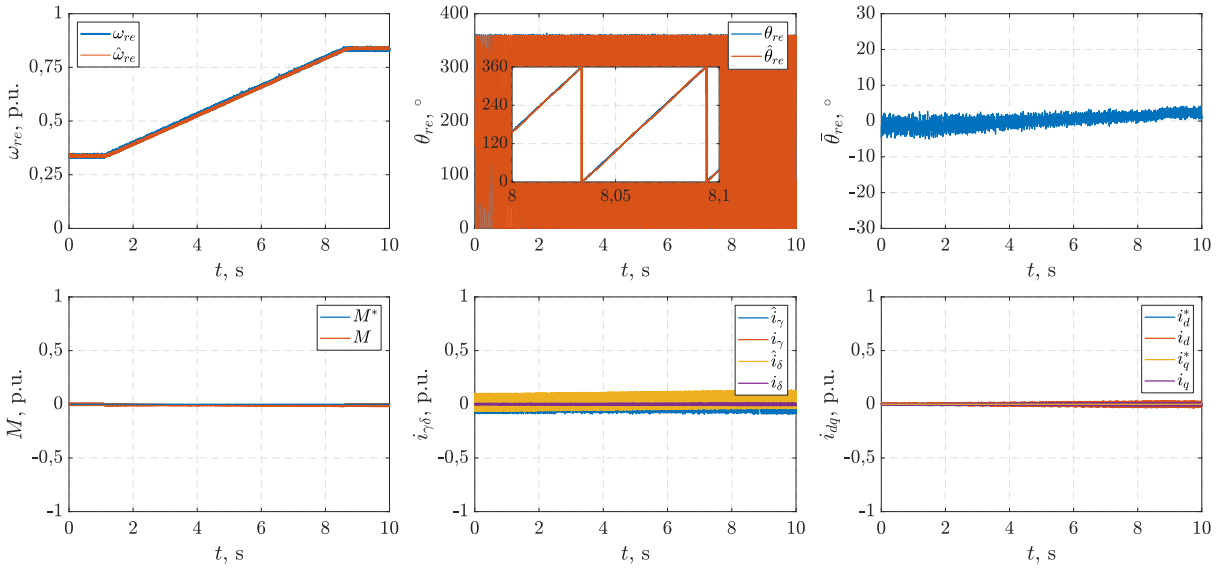

(a) Promjena brzine rotora s $\omega_r = 0,33$ p.u. na $\omega_r = 0,83$ p.u. neopterećenog PMSG-a

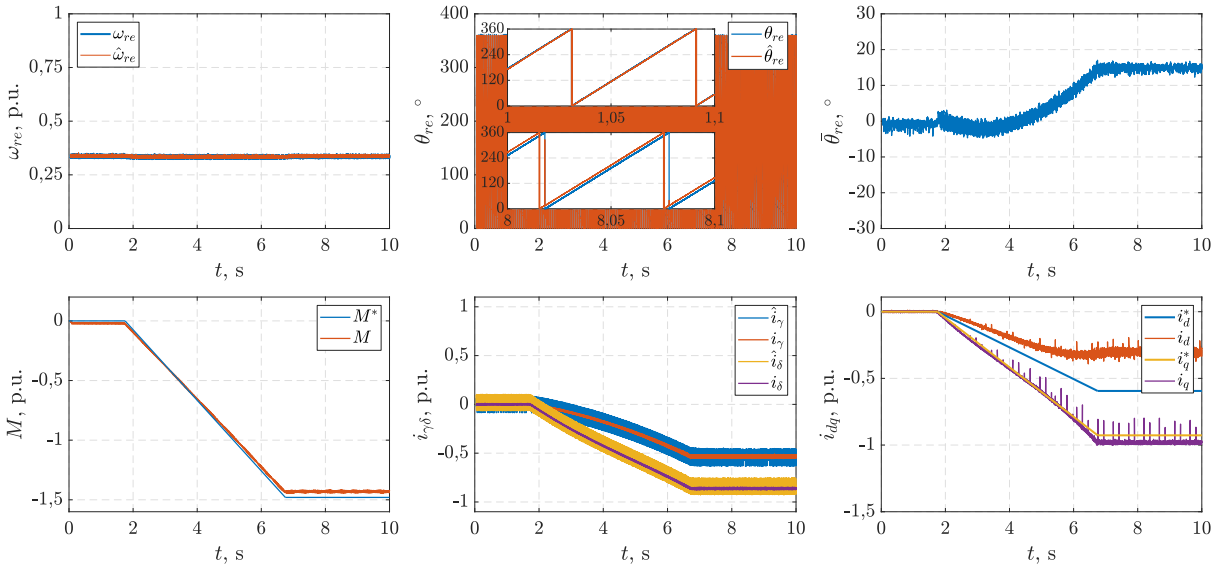

(b) Promjena tereta s $M^* = 0$ p.u. na $M^* = -1,48$ p.u. pri brzini vrtnje $\omega_r = 0,33$ p.u.

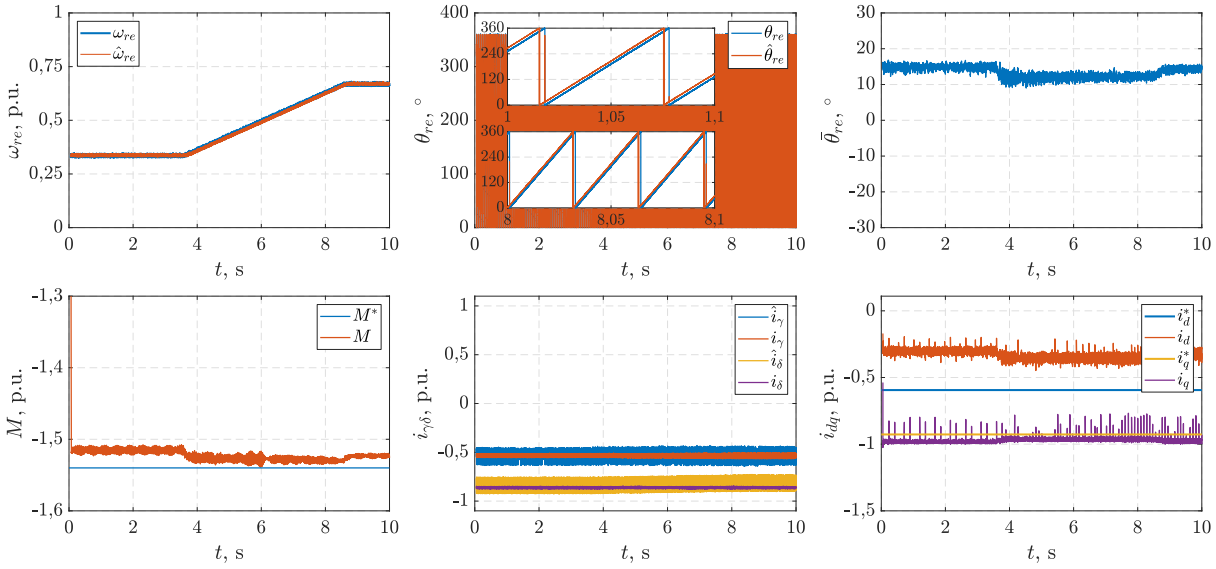

(c) Promjena brzine rotora s $\omega_r = 0,33$ p.u. na $\omega_r = 0,67$ p.u. pri teretu $M^* = -1,48$ p.u

Slika 5.4: Odzivi za estimacijsku strukturu temeljenoj na SMO-u u $\gamma\delta$ sustavu i signum funkciji

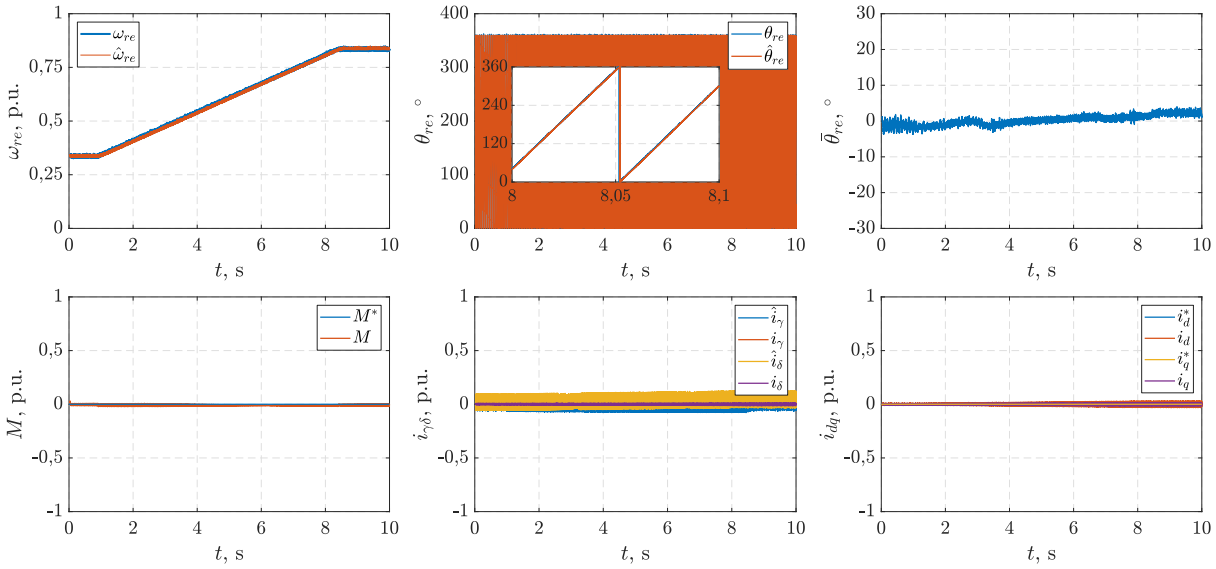

(a) Promjena brzine rotora s $\omega_r = 0,33$ p.u. na $\omega_r = 0,83$ p.u. neopterećenog PMSG-a

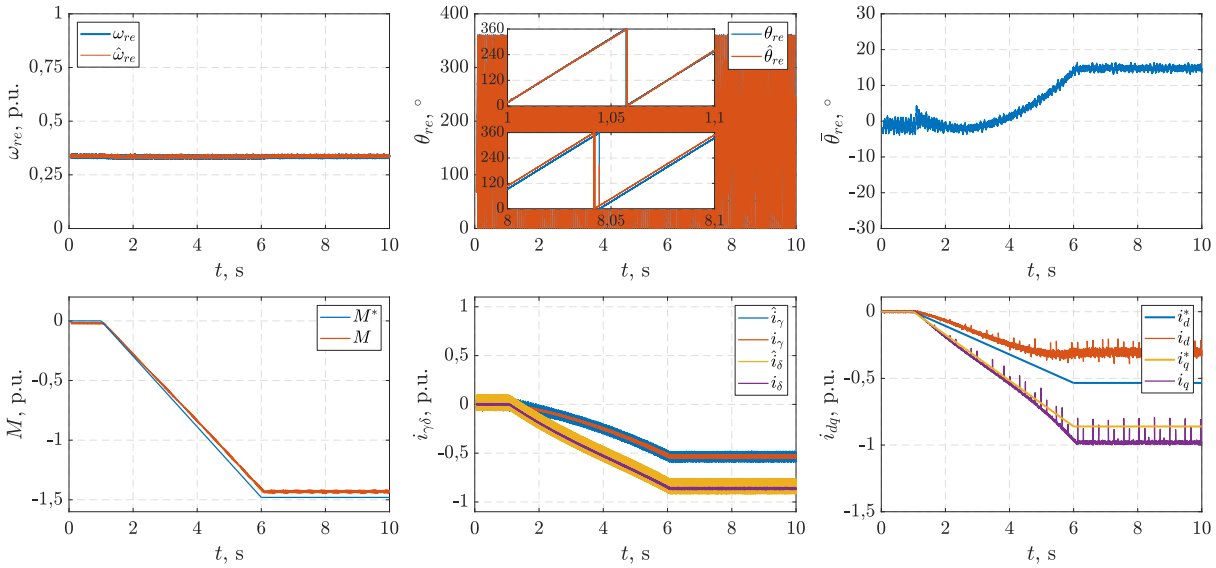

(b) Promjena tereta s $M^* = 0$ p.u. na $M^* = -1,48$ p.u. pri brzini vrtnje $\omega_r = 0,33$ p.u.

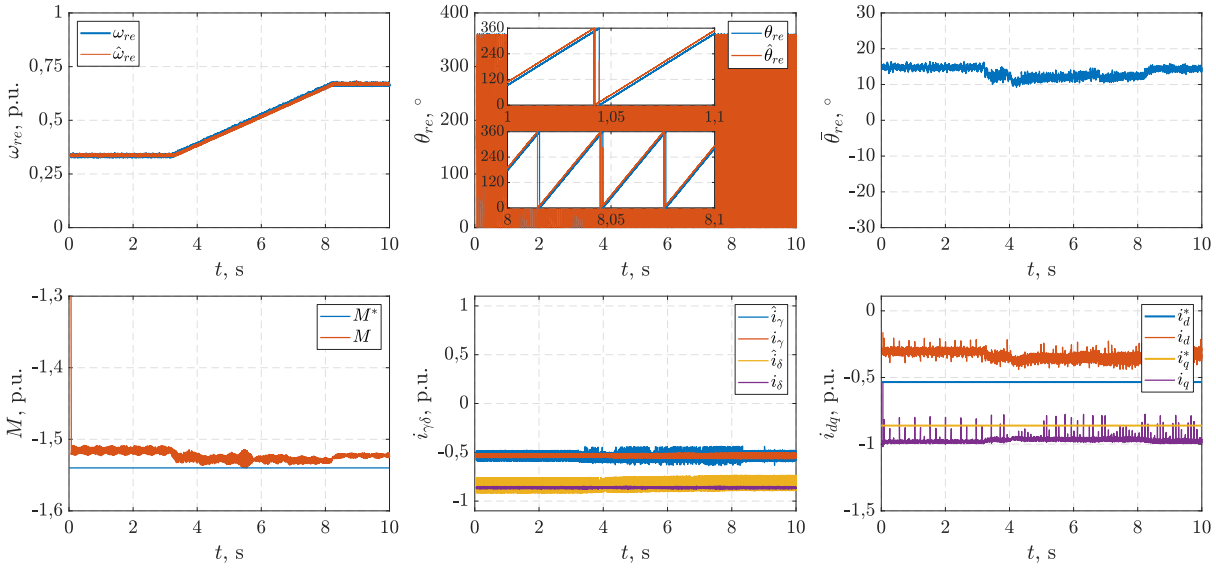

(c) Promjena brzine rotora s $\omega_r = 0,33$ p.u. na $\omega_r = 0,67$ p.u. pri teretu $M^* = -1,48$ p.u.

Slika 5.5: Odzivi za estimacijsku strukturu temeljenoj na SMO-u u $\gamma\delta$ sustavu i sigmoidnoj funkciji

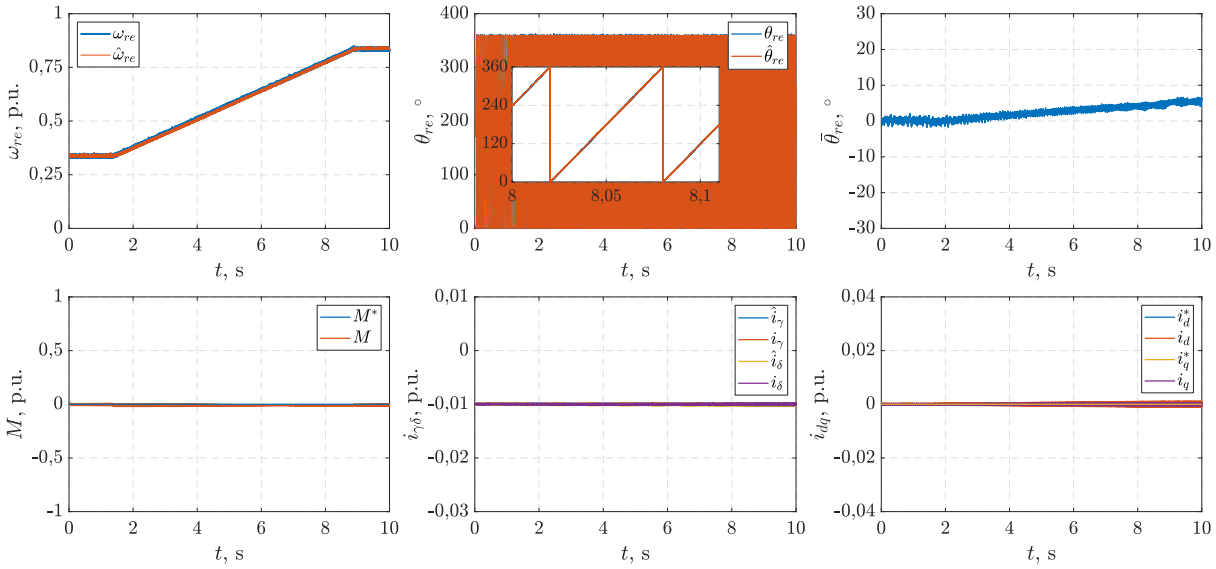

(a) Promjena brzine rotora s $\omega_r = 0,33$ p.u. na $\omega_r = 0,83$ p.u. neopterećenog PMSG-a

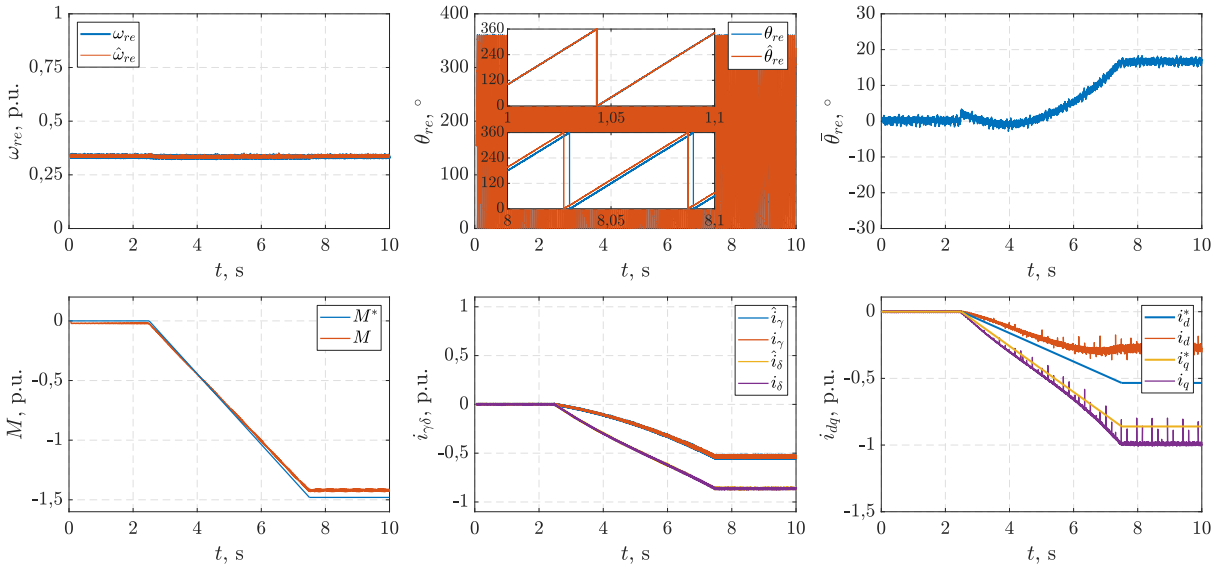

(b) Promjena tereta s $M^* = 0$ p.u. na $M^* = -1,48$ p.u. pri brzini vrtnje $\omega_r = 0,33$ p.u.

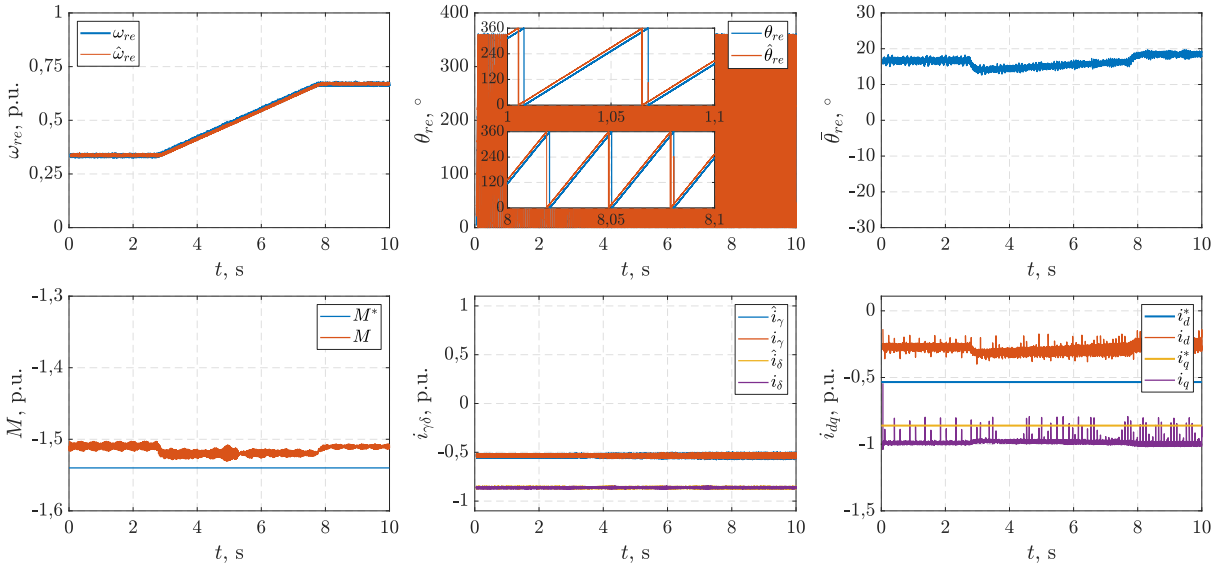

(c) Promjena brzine rotora s $\omega_r = 0,33$ p.u. na $\omega_r = 0,67$ p.u. pri teretu $M^* = -1,48$ p.u.

Slika 5.6: Odzivi za estimacijsku strukturu temeljenoj na SMO-u u $\gamma\delta$ sustavu i STA algoritmu

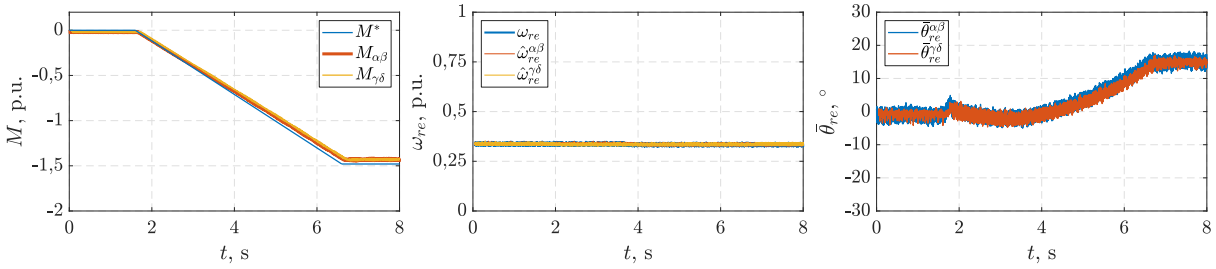

(a) Signum funkcija

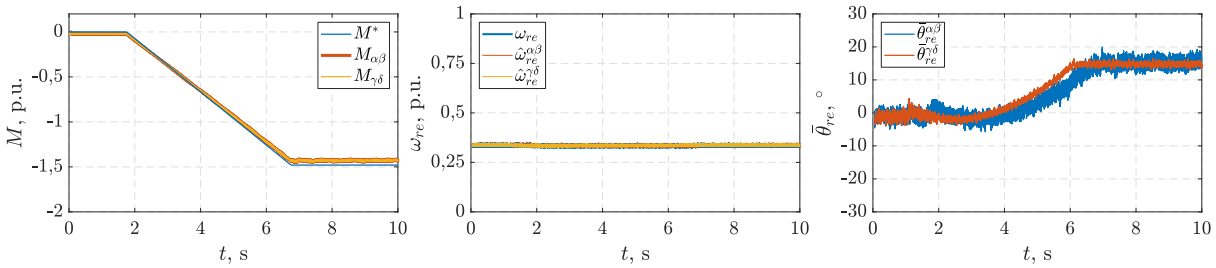

(b) Sigmoidna funkcija

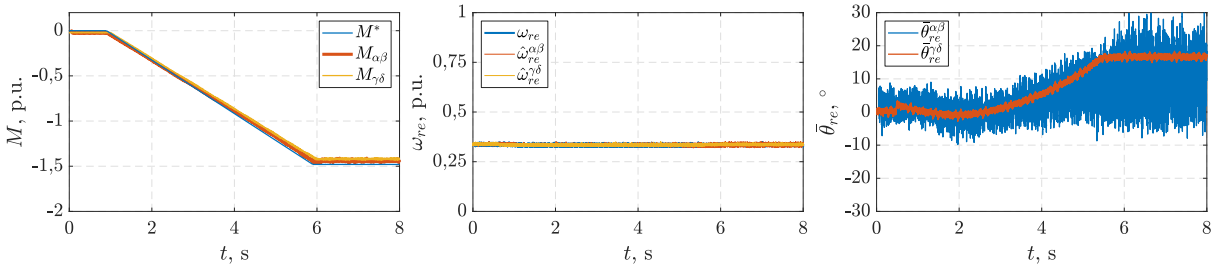

(c) STA algoritam

Slika 5.7: Usporedba odziva estimirane brzine vrtnje i kuta rotora za estimacijsku strukturu sa SMO-om u $\alpha\beta$ i $\gamma\delta$ sustavu

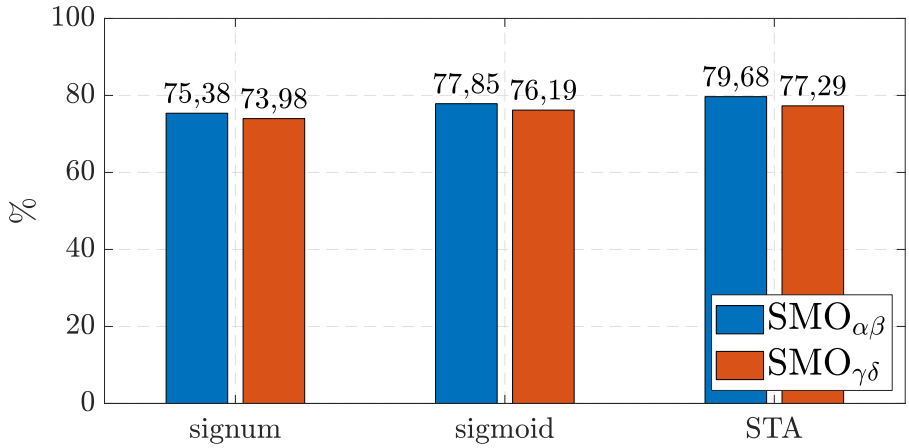

Slika 5.8: Usporedba zauzeća procesora pri korištenju različitih bezsenzorskih algoritama upravljanja temeljenih na SMO-u

6. Leteći start PMSG-a primjenom opservera u kliznom načinu rada

6.1.Pregled literature

U poglavlju 5 predstavljena je bezsenzorska metoda upravljanja PMSG-om temeljena na SMO-u u estimiranom $\gamma\delta$ rotirajućem koordinatnom sustavu modeliranom koristeći model aktivnog magnetskog toka rotora PMSG-a koja omogućava estimaciju kuta i brzine vrtnje rotora PMSG-a u svojstvenom radnom područje PMSG-a određenom srednjim i velikim brzinama vrtnje.

Nadalje, poznato je da radno područje sustava za pretvorbu energije vjetra ima donju granicu određenu minimalnom dozvoljenom brzinom vjetra, odnosno uklopnom brzinom [19]. Iz tog razloga, pri brzinama nižim od uklopne pretvarač je isključen te se ne događa pretvorba energije vjetra u električnu energiju, a uključenje pretvarača događa se tek nakon postizanja uklopne brzine. Upravo uklop generatora na pretvarač predstavlja kritičnu radnu točku sustava za pretvorbu energije vjetra, osobito ako se kao generator koriste strojevi s permanentnim magnetima na rotoru. Razlog za to leži u činjenici da se na stezaljkama PMSG-a, zbog vrtnje vjetroturbine, inducira napon koji uslijed neprikladnog uklopa PMSG-a na pretvarač može uzrokovati uklopnu struju te udarni moment [23]. Posljedično, velika uklopna struja i udarni moment potencijalno mogu izazvati električna i mehanička oštećenja PMSG-a i pretvarača. U najboljem slučaju može doći do prorade prekostrujne zaštite pretvarača koja neće dozvoliti nastavak rada. Upravo je zato, prije uklopa nužno izvršiti sinkronizaciju PMSG-a i pretvarača koja podrazumijeva određivanje kuta i brzine vrtnje rotora te induciranog napona prije samog uklopa. Budući da kut i brzina vrtnje rotora te inducirani napon trebaju biti poznati prije uklopa PMSG-a, proces sinkronizacije predstavlja poseban izazov za bezsenzorsko upravljanje PMSG-om s obzirom na to da se kut i brzina vrtnje, u tom slučaju, ne mogu mjeriti. U literaturi se proces koji objedinjuje sinkronizaciju PMSG-a i pretvarača s uklopom PMSG-a na pretvarač najčešće naziva se leteći start PMSG-a. Osim u generatorskim sustavima, metode letećeg starta imaju primjenu i u elektromotornim pogonima s motorima s permanentnim magnetima gdje je potrebno osigurati ponovno uključenje pretvarača pri vrtnji motora u slučajevima kratkotrajnog gubitka napajanja pretvarača.

Unatoč gore navedenom, većina znanstvenih radova koji proučavaju bezsenzorsko upravljanje

strojevima s permanentnim magnetima, neovisno radi li se o motorskom ili generatorskom režimu rada, bavi se estimacijom kuta i brzine rotora iz mirovanja. S druge strane, postoji nekolicina javno dostupnih radova koji razmatraju bezsenzorske algoritme upravljanja koji uključuju i metodu letećeg starta, dok je dobar dio metoda predloženih kao rješenje ove problematike zaštićen patentima i industrijskim vlasništvom. Metode koje se najčešće predlažu u javno dostupnim radovima mogu se podijeliti tri skupine:

1.injektiranje VF naponskih signala,
2.mjerenje napona i
3.injektiranje nul-naponskih impulsa (engl. *Zero-Voltage Pulse*).

Unutar navedenih skupina, metode letećeg starta koje se temelje na injektiranju VF naponskog signala najrjeđe su zastupljene, a djelovanje tih metoda temelji se na anizotropiji PMSG-a koja je opisana u prethodnom poglavlju. Primjeri metoda letećeg starta koje koriste injektiranje VF signala mogu se pronaći u [87, 88]. U obje metode koristi se injektiranje pravokutnog naponskog signala u estimiranu γ-os PMSG-a.

Sljedeća skupina metoda za leteći start temeljena je na mjerenju napona na stezaljkama PMSG-a prije uklopa na pretvarač. Neke od takvih metoda predstavljene su u [89, 90]. U [89] kut rotora estimira se pomoću nelinearnog opservera na čiji se ulaz dovodi mjereni inducirani napon PMSG-a. S druge strane, u [90], umjesto opservera, za estimaciju kuta rotora i brzine vrtnje PMSG-a koristi se PLL regulator čiji ulaz čini mjereni inducirani napon u estimiranoj γ-osi. S obzirom da inducirani napon PMSG-a prisutan isključivo u q-osi, napon u estimiranoj γ-osi zapravo predstavlja grešku estimiranog kuta rotora iz koje se uz primjenu PLL regulatora estimira stvarni kut rotora. Međutim, nakon uklopa PMSG-a na pretvarača, napon na stezaljkama PMSG-a više nije sinusnog valnog oblika već postaje visokofrekvencijski pravokutni signal uzrokovan PWM modulacijom pretvarača. Iz tog razloga predložene metode temeljene na mjerenju induciranog napona prije uključenje pretvarača nisu pogodne za estimaciju kuta i brzine vrtnje rotora u trajnom radu (nakon uklopa PMSG-a na pretvarač). Kako bi se navedeni problem nadišao, u [23] je predložena nadogradnja metode [90] na način da se na ulaz PLL regulatora, umjesto mjerenog induciranog napona dovodi estimirani magnetski tok dobiven integracijom mjerenog napona prije uklopa, dok se u trajnom radu magnetski tok estimira integracijom rekonstruiranog napona pretvarača. Navedene metode postižu uspješan leteći start PMSG-a, međutim njihov glavni nedostatak je korištenje dodatnog senzora za mjerenje napona na stezaljkama PMSG-a koji ne čini sastavni dio upravljačke opreme čime se povećava cijena te smanjuje robusnost upravljačkog sustava.

Zadnjoj skupini metoda letećeg starta PMSG-a pripadaju metode s primjenom naponskih nul-impulsa koji uzrokuju kratkotrajni kratki spoj na stezaljkama PMSG-a. Obično se predlaže primjena jednog, dva ili tri nul-naponska impulsa. U [91] primijenjen je jedan naponski nul-impuls postignut istodobnim uklapanjem IGBT tranzistora donje grane generatorskog pretvarača.

Nedostatak ove metode je ovisnost estimiranog kuta i brzine vrtnje o parametrima PMSG-a. Točnost i robusnost estimacije može se povećati dodavanjem još jednog nul-naponskog impulsa kao što je učinjeno u [92]. Uz primjenu dva naponska nul-vektora brzina vrtnje rotora računa se dijeljenjem razlike kutova između vektora inducirane struje i vremenskog intervala između primijenjenih impulsa. Kod primjene dva naponska nul-vektora, u slučaju velike vremenske konstante PMSG-a, postoji mogućnost da kratki spoj PMSG-a uzrokovan primjenom drugog nul-vektora započne prije nego li struja inducirana tijekom prvog kratkog spoja iščezne što bi znatno narušilo točnost estimacije. Iz tog su razloga u [93] primijenjena tri uzastopna naponska nul-vektora, a budući da je vremenski interval između drugog i trećeg impulsa nešto dulji u odnosu na interval između prva dva impulsa, prethodni slučaj može biti izbjegnut. Unatoč većoj točnosti i robusnosti, metoda s tri nul-naponska impulsa iz [93] također je podložna estimacijskoj grešci kuta rotora uslijed promjene induktiviteta u q-osi. Rješenje tog problema predstavljeno je u [86] gdje je estimacijska greška kuta ograničena na najviše 10° na način da se vrijeme trajanja nul-naponskog impulsa podešava na temelju estimirane brzine vrtnje rotora tijekom trajanja metode letećeg starta. Osim primjene nekolicine impulsa u literaturi se može naići i na metode letećeg starta uz primjenu niza naponskih nul-vektora [22, 94, 95]. U [95] broj primijenjenih nul-naponskih vektora kreće se između tri i deset, dok na niz nul-impulsa u [22, 94] nije postavljeno ograničenje zbog toga što je unutar algoritma također implementirano i upravljanje amplitudom struje kratkog spoja na stezaljkama PMSG-a uzrokovanog nul-naponskim vektorima. Osim neosjetljivosti na parametre PMSG-a i iznimnu robusnost na promjene brzine vrtnje, metoda [22], za razliku od većine drugih metoda za leteći start PMSG-a, ima dodatnu prednost, a to je da omogućuje korištenje iste bezsenzorske upravljačke strukture koja se koristi za leteći start i nakon uklopa PMSG-a na pretvarač, odnosno u trajnom radu, čime, na jednostavan i kompaktan način, pokriva cjelokupno radno područje PMSG-a.

Zbog prethodno navedenog, bezsenzorska metoda upravljanja PMSG-a predstavljena u [22] detaljno je proučena. Ova metoda dijeli se na isprekidani i trajni način rada. Isprekidani način rada ostvaruje se nizom nul-naponskih impulsa, a za vrijeme trajanja isprekidanog načina rada struju provode isključivo donji IGBT tranzistori u svakoj od grana pretvarača i to u ciklusu vođenja fiksnog trajanja. Vrijeme vođenja donjih IGBT tranzistora proračunava se pomoću PI regulatora na temelju srednje vrijednosti mjerene struje PMSG-a u α-osi te se na taj način osigurava amplituda inducirane struje dovoljno velika da se otkloni utjecaj mjernog šuma, a s druge strane, dovoljno mala da se osigura pad struje na nulu prije primjene sljedećeg nul-impulsa. Na ovaj način postižu se kratkotrajni kratki spojevi na stezaljkama PMSG-a. Tijekom trajanja svakog od naponskih nul-vektora dolazi do porasta struje uzrokovanog induciranim naponom, a valni oblik inducirane struje prati valni oblik induciranog napona u kojem je sadržana informacija o kutu rotora pa se primjenom opservera toka PMSG-a u otvorenoj petlji i PLL regulatora mogu odrediti kut i brzina vrtnje rotora. Nadalje, kao što je spomenuto ranije, ista se estimacijska

struktura koristi i za trajni rad nakon što je postupak letećeg starta završen.

Osim navedenih metoda, u literaturi se mogu pronaći i prijedlozi metoda za leteći start koje se ne mogu svrstati niti u jednu od navedenih najčešćih skupina pa se tako predlažu metode temeljene na virtualnom otporu PMSG-a [96, 97], modelskom prediktivnom upravljanju [98] ili metode za leteći start u području slabljenja magnetskog polja [99].

6.1.1.Drugi dio znanstvenog doprinosa

U sklopu doktorske disertacije razvijena je metoda za leteći start PMSG-a temeljena na opserveru u kliznom načinu rada i isprekidanom radu pretvarača [80]. Isprekidani rad pretvarača postignut je nizom naponskih nul-impulsa na način opisan u [22]. Model opservera u kliznom načinu rada sastoji se od dvije strukture. Prva je prilagođena modelu PMSG-a u isprekidanom radu, dok je druga temeljena na modelu PMSG-a u trajnom radu. Opserver u kliznom načinu rada modeliran na ovakav način omogućuje estimaciju kuta i brzine vrtnje PMSG-a tijekom isprekidanog rada pretvarača čime je omogućen leteći start PMSG-a. Nadalje, slično kao i kod metode [22], nakon uspješno izvedenog letećeg starta, struktura opservera prilagođava se modelu PMSG-a u trajnom radu te omogućava daljnje nesmetano bezsenzorsko upravljanje. Prednost predložene metode u odnosu na metodu iz [22] jesu veća stabilnost i robusnost s obzirom na primjenu opservera u zatvorenoj petlji, za razliku od metode iz [22] koja koristi opserver u otvorenoj petlji. Nadalje, korišteni opserver u otvorenoj petlji estimira magnetski tok PMSG-a pomoću niskopropusnog filtra kako bi osigurao uklanjanje istosmjerne komponentu iz estimiranog magnetskog toka. Međutim, estimacija preko niskopropusnog filtra unosi dodatno kašnjenje te narušava dinamiku estimacijskog algoritma. Ovaj nedostatak također je izbjegnut primjenom predložene metode temeljene na opserveru u kliznom načinu rada.

U trenutku objavljivanja znanstvenog rada [80], u kojem je iznesena metoda letećeg starta PMSG-a temeljena na opserveru u kliznom načinu rada, u literaturi nije pronađena metoda koje objedinjuju leteći start PMSG-a i opserver u kliznom načinu rada.

6.2.Isprekidani način rada pretvarača

Isprekidani način rada pretvarača predložen u [22] koristi se u procesu sinkronizacije pretvarača i PMSG-a te ne predstavlja izvorni znanstveni doprinos ove disertacije. Ovakav način rada postiže se specifičnim načinom sklapanja IGBT tranzistora koji podrazumijeva upravljanje isključivo tranzistorima donje grane pretvarača, dok su, istovremeno, gornji IGBT-ovi blokirani. Upravljanje donjim IGBT-ovima svodi se na određivanje faktora vođenja D unutar jedne periode sklapanja PWM-a, T_{sw}. Primjenom jednakog faktora vođenja na sve IGBT-ove u donjoj grani ostvaruje se kratki spoj na stezaljkama PMSG-a. U slučaju vrtnje rotora, namotima PMSG-a poteći će struja kao posljedica induciranog napona. Iz tog razloga nužno je osigurati kontrolirano

vođenje IGBT-ova donje grane pretvarača. Vrijeme vođenja donjih IGBT tranzistora proračunava se pomoću PI regulatora na temelju srednje vrijednosti mjerene struje PMSG-a u statorskoj α-osi te se na taj način postižu kratkotrajni i kontrolirani kratki spojevi na stezaljkama PMSG-a. Na ovaj način osigurava se dovoljno velika amplituda inducirane struje da se otkloni utjecaj mjernog šuma, a ipak dovoljno mala da struja padne na nulu prije primjene sljedećeg nul-impulsa.

Na slici 6.1 prikazan je inducirani napon te struja PMSG-a u α-osi tijekom isprekidanog rada pretvarača (napon i struja u β-osi jednakog su valnog oblika s faznim pomakom od $\pi/2$). Inducirani napon sinusnog je valnog oblika te tijekom vremena vođenja DT_{sw}, kada su stezaljke PMSG-a u kratkom spoju, uzrokuje protufaznu struju u namotima PMSG-a. Budući da je vrijeme DT_{sw} vrlo kratko, struja raste linearno, a nakon prestanka vođenja, unutar vremena $(1-D)T_{sw}$, pada na nulu. Iz tog je razloga inducirana struja šiljastog valnog oblika. Međutim, ovojnica ovakve struje prati sinusni valni oblik. Prema tome, uzorkovanjem šiljaste inducirane struje u sredini periode trokutastog PWM brojača, uz uvjet da je trajanje kratkog spoja simetrično u odnosu na sredinu periode, uzorkovana struja bit će sinusnog valnog oblika s upola manjom amplitudom. Ovako uzorkovana sinusna struja pogodna je za obradu u digitalnom upravljačkom sustavu.

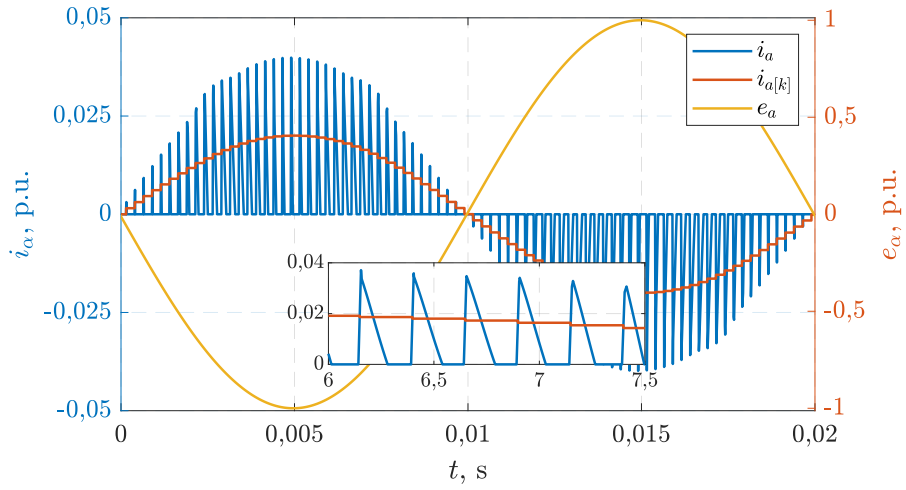

Slika 6.1: Struja i inducirani napon u α-osi PMSG-a tijekom isprekidanog načina rada pretvarača

6.2.1. Matematički model PMSG-a tijekom isprekidanog načina rada

U općenitom slučaju napon pretvarača tijekom trajnog kratkog spoja PMSG-a jednak je nuli pa model PMSG-a u $\alpha\beta$ koordinatnom sustavu temeljen na aktivnom magnetskom toku iz (5.8) postaje:

$$0 = R_s \boldsymbol{i}_{\alpha\beta} + L_q \frac{d\boldsymbol{i}_{\alpha\beta}}{dt} + \boldsymbol{e}^{AF}_{\alpha\beta}. \tag{6.1}$$

Uz zanemarenje pada napona na otporu statora struja, kratkospojna struja $\boldsymbol{i}_{\alpha\beta}$ može se lako

odrediti integriranjem (6.1) kao:

$$\boldsymbol{i}_{\alpha\beta} = -\frac{\psi_r^{AF}}{L_q}\begin{bmatrix}\cos\theta_{re}\\ \sin\theta_{re}\end{bmatrix}, \tag{6.2}$$

odnosno u $\gamma\delta$ koordinatnom sustavu, primjenom Parkove transformacije s kutom $\hat{\theta}_{re}$ nad prethodnim izrazom, kao:

$$\boldsymbol{i}_{\gamma\delta} = -\frac{\psi_r^{AF}}{L_q}\begin{bmatrix}\cos\bar{\theta}_{re}\\ -\sin\bar{\theta}_{re}\end{bmatrix}. \tag{6.3}$$

Međutim, tijekom isprekidanog rada pretvarača događa se kontrolirani kratki spoj kratkog trajanja pa se kut rotora θ_{re} tijekom trajanja kratkog spoja može smatrati konstantnim. Uz to, vremenska konstanta kruga (6.1) znatno je veća od vremena trajanja kratkog spoja, $\tau = L_q/R_s \gg DT_{sw}$. Prema tome, model (6.1) može se, tijekom trajanja k-tog kratkog spoja, promatrati kao istosmjerni krug čije je rješenje [22]:

$$\boldsymbol{i}_{\alpha\beta[k]} = -\frac{\boldsymbol{e}_{\alpha\beta[k]}^{AF}}{R_s}\left(1 - e^{-\frac{R_s}{L_q}t}\right). \tag{6.4}$$

Uz pretpostavku uzorkovanja inducirane struje u sredini PWM periode, aproksimaciju $e^{-\frac{R_s}{L_q}t} \approx 1-\frac{R_s}{L_q}t$ te vrijeme trajanja kratkog spoja DT_{sw}, izraz za kratkospojnu struju u isprekidanom načinu rada konačno se može zapisati kao:

$$\boldsymbol{i}_{\alpha\beta[k]} = -\frac{\omega_{re[k]}\psi_r^{AF}}{2L_q}DT_{sw}\begin{bmatrix}-\sin\theta_{re[k]}\\ \cos\theta_{re[k]}\end{bmatrix}. \tag{6.5}$$

Parkovom transformacijom s estimiranim kutom $\hat{\theta}_{re}$, struja (6.5) u $\gamma\delta$ koordinatnom sustavu glasi:

$$\boldsymbol{i}_{\gamma\delta[k]} = -\frac{\omega_{re[k]}\psi_r^{AF}}{2L_q}DT_{sw}\begin{bmatrix}\sin\bar{\theta}_{re[k]}\\ \cos\bar{\theta}_{re[k]}\end{bmatrix}. \tag{6.6}$$

6.3. Matematički model SMO-a pri isprekidanom načinu rada pretvarača

Iz izraza za struju PMSG-a tijekom kontroliranog kratkog spoja, (6.5) i (6.6), očito je da se kut rotora, odnosno greška kuta, mogu jednostavno odrediti primjenom arkus tangens funkcije na kvocijent α i β, odnosno γ i δ komponente struja. Međutim, ovakvo određivanje kuta rotora je manjkavo jer ne omogućava nastavak estimacije nakon uklopa pretvarača, odnosno u trajnom radu. Prema tome potrebno je razviti strukturu koja omogućava estimaciju kuta i brzine vrtnje tijekom isprekidanog rada, ali također i u trajnom radu. U tu svrhu može se iskoristiti SMO u $\gamma\delta$ koordinatnom sustavu temeljen na modelu aktivnog toka predstavljen u poglavlju 5, kao i

već postojeći SMO-i u $\alpha\beta$ koordinatnom sustavu, no prije toga potrebno je učiniti prilagodbe SMO-a kako bi mogao ostvariti estimaciju i u isprekidanom načinu rada pretvarača te tako, osim bezsenzorskog upravljanja u trajnom radu, omogućiti i leteći start PMSG-a.

Budući da za tijekom kratkog spoja vrijedi $\boldsymbol{u}_{x[k]} = 0$, korištenjem općeg zapisa iz (5.16), diskretni model PMSG-a tijekom isprekidanog načina rada može se zapisati kao:

$$\boldsymbol{i}_{x[k+1]} = \mathbf{A}_d \boldsymbol{i}_{x[k]} - \mathbf{B}_d \boldsymbol{e}^{AF}_{x[k]}. \tag{6.7}$$

Na isti način, opći oblik SMO-a za isprekidani rad može se definirati kao:

$$\hat{\boldsymbol{i}}_{x[k+1]} = \mathbf{A}_d \hat{\boldsymbol{i}}_{x[k]} - \mathbf{B}_d \boldsymbol{z}_{x[k]}, \tag{6.8}$$

gdje su matrice $\mathbf{A}_d$ i $\mathbf{B}_d$ dane u tablici 5.2.

Razlika u SMO-a pri trajnom radu PMSG-a iz (5.18) te SMO-a modeliranog za isprekidani rad pretvarača iz (6.8) očituje se u naponu pretvarač $\boldsymbol{u}_{x[k]}$ koji u isprekidanom načinu rada, s obzirom na kontrolirani kratki spoja PMSG-a, jednak nuli. Osim toga, kao što je vidljivo usporedbom tablica s matricama stanja i ulaza u trajnom i isprekidanom radu 5.2 i 6.1, tijekom isprekidanog načina rada zanemaren je statorski otpor $R_s = 0$.

Tablica 6.1: Diskretne matrice stanja i ulaza PMSG-a za $\alpha\beta$ i $\gamma\delta$ koordinatni sustav u isprekidanom načinu rada pretvarača

Koordinatni sustav	Matrica stanja	Matrica ulaza
$\alpha\beta$	$\mathbf{A}_d = \mathbf{I}$	$\mathbf{B}_d = \frac{T_s}{L_q}\mathbf{I}$
$\gamma\delta$	$\mathbf{A}_d = \mathbf{I} - T_s\hat{\omega}_{re}\mathbf{J}$	$\mathbf{B}_d = \frac{T_s}{L_q}\mathbf{I}$

6.4. Analiza uvjeta dohvaćanja i stabilnosti SMO-a pri isprekidanom načinu rada pretvarača

Jednako kao i u trajnom radu, za analizu uvjeta dohvaćanja i stabilnosti SMO-a potrebno je odrediti dinamiku greške estimirane struje. Oduzimanjem (6.7) od (6.8), dinamika greške struje tijekom isprekidanog načina rada glasi:

$$\bar{\boldsymbol{i}}_{x[k+1]} = \mathbf{A}_d \bar{\boldsymbol{i}}_{x[k]} + \mathbf{B}_d \left(\boldsymbol{e}^{AF}_{x[k]} - \boldsymbol{z}_{x[k]} \right). \tag{6.9}$$

Usporedbom (5.20) i (6.9), očito je da je dinamika greške u općem zapisu prilikom isprekidanom načina rada identična dinamici greške u trajnom radu. Prema tome, za analizu uvjeta stabilnosti i dohvaćanja kliznog režima nije potrebno raditi dodatni izvod, već je uvjete izvedene

za trajni rad nužno prilagoditi karakterističnim uvjetima pri isprekidanom načinu rada pretvarača, odnosno primijeniti matrice stanja i ulaza dane u tablici 6.1.

6.4.1.Klizni režim prvog reda

Iz izraza za uzorkovanu struju pri isprekidanom načinu rada, (6.5) i (6.6), lako je odrediti njenu amplitudu kao:

$$|\boldsymbol{i}_{\alpha\beta[k]}| = |\boldsymbol{i}_{\gamma\delta[k]}| = \frac{\omega_{re[k]}\psi_r^{AF}}{2L_q} DT_s, \tag{6.10}$$

gdje je $T_s = T_{sw}$ - vrijeme diskretizacije.

Uz pretpostavku ispravnog rada regulatora faktora vođenja D, amplituda uzorkovane isprekidane struje bit će jednaka polovici referentne amplitude na ulazu u regulator:

$$\frac{I_D^*}{2} = |\boldsymbol{i}_{\alpha\beta[k]}| = |\boldsymbol{i}_{\gamma\delta[k]}|. \tag{6.11}$$

Budući da je u početnom trenutku estimacije struja SMO-a $\hat{\mathbf{i}}_{\alpha\beta[k]} = \hat{\mathbf{i}}_{\gamma\delta[k]} = 0$, najveća početna greška estimirane struje iznosi:

$$|\bar{\boldsymbol{i}}_{\alpha\beta[k]}| = |\bar{\boldsymbol{i}}_{\gamma\delta[k]}| = \frac{I_D^*}{2}. \tag{6.12}$$

Nadalje, srednja vrijednost induciranog napona tijekom trajanja k-tog kratkog spoja glasi:

$$|\boldsymbol{e}_{\alpha\beta[k]}| = |\boldsymbol{e}_{\gamma\delta[k]}| = \omega_{re[k]}\psi_r^{AF} DT_s. \tag{6.13}$$

Iz izraza za uzorkovanu isprekidanu struju u $\gamma\delta$ koordinatnom sustavu (6.6), uz $\bar{\theta}_{re} = 0$, očito je da je sva struja smještena u q-osi, odnosno $i_d = 0$, te prema (5.2) vrijedi:

$$\psi_r^{AF} = \psi_r. \tag{6.14}$$

Uvrštavanjem (6.12) i (6.13) u uvjete za $\alpha\beta$ koordinatni sustav iz tablice 5.3, uz zanemarenje statorskog otpora, dobivaju se uvjeti dohvaćanja i stabilnosti kliznog režima prvog reda za isprekidani način rada:

$$\omega_{re[k]}\psi_r DT_s < K_d \leq -\omega_{re[k]}\psi_r DT_s + \frac{2L_q}{T_s}\frac{I_D^*}{2}. \tag{6.15}$$

Nadalje, iako su amplituda greške estimirane struje i srednja vrijednost napona prema (6.12) i (6.13) jednaki u oba koordinatna sustava, određivanje granica pojačanja u $\gamma\delta$ sustavu nešto je složenija zbog rasprezanja između γ i δ-osi. Iz tog razloga korisno je raspisati donju i gornju

granicu iz tablice 5.3 pojedinačno sa γ i δ-os iz čega slijedi:

$$K_d > \max\left\{e^{AF}_{\gamma[k]} + L_q\hat{\omega}_{re[k]}\bar{i}_{\delta[k]},\ e^{AF}_{\delta[k]} - L_q\hat{\omega}_{re[k]}\bar{i}_{\gamma[k]}\right\}, \tag{6.16}$$

$$K_d \leq \max\left\{-e^{AF}_{\gamma[k]} + \frac{2L_q}{T_s}\bar{i}_{\gamma[k]} + L_q\hat{\omega}_{re[k]}\bar{i}_{\delta[k]},\ -e^{AF}_{\delta[k]} + \frac{2L_q}{T_s}\bar{i}_{\delta[k]} - L_q\hat{\omega}_{re[k]}\bar{i}_{\gamma[k]}\right\}, \tag{6.17}$$

U prethodnim izrazima najgori slučaj koji je potrebno obuhvatiti ograničenjima pojačanja pojavljuje se kada se inducirani napon nalazi potpuno u γ ili δ-osi. Ranije je pokazano da se sva struja tijekom isprekidanog načina rada nalazi u istoj osi kao i inducirani napon, dok u suprotnoj osi struja ne teče. Prema tome vrijedi $L_q\hat{\omega}_{re[k]}\bar{i}_{\delta[k]} = 0$ i $L_q\hat{\omega}_{re[k]}\bar{i}_{\gamma[k]} = 0$. Uvrštavanjem (6.12) i (6.13) u izraze (6.16) i (6.17) dobivaju se jednaka ograničenja kao i u $\alpha\beta$ koordinatnom sustavu iz (6.15).

U tablici 6.2 sažeta su ograničenja pojačanja K_d koja će osigurati uvjet dohvaćanja i stabilnosti kliznog režima prvog reda u isprekidanom načinu rada za $\alpha\beta$ i $\gamma\delta$ koordinati sustav iz koje je očito da su ograničenja pojačanja istovjetna za oba koordinatna sustava.

Tablica 6.2: Opći uvjeti dohvaćanja i postojanja kliznog režima prvog reda u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu u isprekidanom načinu rada pretvarača

Koordinatni sustav	**Uvjet**
$\alpha\beta$	$K_d > \omega_{re[k]}\psi_r DT_s$ $K_d \leq -\omega_{re[k]}\psi_r DT_s + \frac{2L_q}{T_s}\frac{I^*_D}{2}$
$\gamma\delta$	$K_d > \omega_{re[k]}\psi_r DT_s$ $K_d \leq -\omega_{re[k]}\psi_r DT_s + \frac{2L_q}{T_s}\frac{I^*_D}{2}$

6.4.2.Klizni režim drugog reda

Prilikom isprekidanog načina rada vektor perturbacije određene za trajni rad u tablici 5.4, također je potrebno prilagoditi isprekidanom načinu rada pretvarača. S obzirom na to da je amplituda induciranog napona u isprekidanom radu poznata iz (6.13), potrebno ju je uvrstiti u vektor perturbacije. Nadalje, amplituda greške estimirane struje u početnom trenutku također je poznata iz (6.12). Međutim, kao i u trajnom radu, konstanta ζ koja uvjetuje donje ograničenje pojačanja obrnuto je proporcionalna korijenu greške estimirane struje pa je potrebno odabrati minimalnu očekivanu grešku estimacije kako bi pojačanja (5.40) i (5.41) zadovoljila uvjet dohvaćanja klizne plohe.

U tablici 6.3 nalaze se opći izrazi za perturbacije u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu za isprekidani način rada.

Tablica 6.3: Opći izrazi perturbacija u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu u isprekidanom načinu rada pretvarača

Koordinatni sustav	Perturbacija
$\alpha\beta$	$\lvert\boldsymbol{\rho}_{\alpha\beta[k]}\rvert = \lvert\bar{\boldsymbol{i}}_{\alpha\beta[k]}\rvert + \frac{T_s}{L_q}\omega_{re[k]}\psi_r DT_s$
$\gamma\delta$	$\lvert\boldsymbol{\rho}_{\gamma\delta[k]}\rvert = \lvert\mathbf{I} - \mathbf{J}T_s\hat{\omega}_{re[k]}\rvert\,\lvert\bar{\boldsymbol{i}}_{\gamma\delta[k]}\rvert + \frac{T_s}{L_q}\omega_{re[k]}\psi_r DT_s$

6.4.3.Prelazak iz isprekidanog u trajni način rada

Odabirom pojačanja prema uvjetima određenima u tablici 6.2 za klizni režim prvog reda, odnosno tablici 6.3 za klizni režim drugog reda, osigurano je da će trajektorija greške estimacije struje dostići kvazi-kliznu plohu $\bar{\boldsymbol{i}}_{x[k]} = 0$ tijekom isprekidanog načina rada pretvarača. Nakon toga, potrebno je prijeći u trajni rad gdje vrijede drugačiji uvjeti stabilnosti kliznog režima.

Analizirajući klizni režim prvog reda, širina kvazi-kliznog područja oko klizne plohe određena je izrazom [100]:

$$\Delta = K\mathbf{B}_d + \mathbf{B}_d \boldsymbol{e}^{AF}_{x[k]}. \tag{6.18}$$

Nakon što trajektorija greške estimacije uđe u klizni režim prvog reda, širina kvazi-kliznog područja zapravo predstavlja najveću moguću grešku estimacije pa vrijedi:

$$\Delta = \lvert\bar{\boldsymbol{i}}_{x[k]}\rvert. \tag{6.19}$$

Uvrštavanjem (6.19) u uvjete za klizni režim prvog reda u trajnom radu iz tablice 5.3 očito je da jedini uvjet postojanja i stabilnosti nakon prelaska u trajni rad za oba koordinatna sustava glasi:

$$K_c > \omega_{re[k]}\psi_r^{AF}. \tag{6.20}$$

Uvjet (6.20) pokazuje da nakon prelaska iz isprekidanog u trajni način rada ne postoji gornje ograničenje na pojačanje upravljačke funkcije što je u skladu s očekivanjem budući da je sustav prije prelaska u trajni rad već bio u kliznom režimu te ga je potrebno isključivo zadržati u kvazi-kliznom području u okolini klizne plohe, što je osigurano donjom granicom pojačanja K_c iz tablica 5.6 i 5.9.

Kod kliznog režima drugog reda nakon uklopa pretvarača, odnosno prelaska u trajni rad, potrebno je adaptirati pojačanja prema vektorima perturbacija za trajni rad određenima tablicom 5.4.

U tablici 6.4 sažeta su sva ograničenja na pojačanja za klizni režim prvog reda, kao i izrazi za vektor perturbacije za klizni režim drugog reda, u isprekidanom i trajnom načinu rada pretvarača. Kako bi estimacija kuta i brzine vrtnje rotora u isprekidanom načinu rada te prelazak u trajni

način rada bili osigurani, potrebno je odabrati pojačanja SMO-a prema izrazima iz ove tablice.

Tablica 6.4: Uvjeti postojanja i stabilnosti SMO-a u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu za isprekidani i trajni način rada

Koordinatni	**Isprekidani rad**	
sustav	**Klizni režim prvog reda**	**STA**
$\alpha\beta$	$K_d > \omega_{re[k]}\psi_r DT_s$ $K_d \leq -\omega_{re[k]}\psi_r DT_s + \frac{2L_q}{T_s}\frac{I_D^*}{2}$	$\lvert\boldsymbol{\rho}_{\alpha\beta[k]}\rvert = \lvert\bar{\boldsymbol{i}}_{\alpha\beta[k]}\rvert$ $+\frac{T_s}{L_q}\omega_{re[k]}\psi_r DT_s$
$\gamma\delta$	$K_d > \omega_{re[k]}\psi_r DT_s$ $K_d \leq -\omega_{re[k]}\psi_r DT_s + \frac{2L_q}{T_s}\frac{I_D^*}{2}$	$\lvert\boldsymbol{\rho}_{\gamma\delta[k]}\rvert = \left\lvert\mathbf{I} - \mathbf{J}T_s\hat{\omega}_{re[k]}\right\rvert \lvert\bar{\boldsymbol{i}}_{\gamma\delta[k]}\rvert$ $+\frac{T_s}{L_q}\omega_{re[k]}\psi_r DT_s$
	Trajni rad	
$\alpha\beta$	$K_c > \omega_{re[k]}\psi_r^{AF}$	$\lvert\boldsymbol{\rho}_{\alpha\beta[k]}\rvert = \left\lvert 1 - \frac{T_s R_s}{L_q}\right\rvert \lvert\bar{\boldsymbol{i}}_{\alpha\beta[k]}\rvert$ $+\frac{T_s}{L_q}\omega_{re,n}\psi_r^{AF}$
$\gamma\delta$	$K_c > \omega_{re[k]}\psi_r^{AF}$	$\lvert\boldsymbol{\rho}_{\gamma\delta[k]}\rvert = \left\lvert\left(1 - \frac{T_s R_s}{L_q}\right)\mathbf{I} - \mathbf{J}T_s\hat{\omega}_{re[k]}\right\rvert \lvert\bar{\boldsymbol{i}}_{\gamma\delta[k]}\rvert$ $+\frac{T_s}{L_q}\omega_{re,n}\psi_r^{AF}$

6.5. Metoda letećeg starta PMSG-a temeljena na SMO-u i isprekidanom načinu rada pretvarača

Metoda letećeg starta PMSG-a temeljena na SMO-u i isprekidanom načinu rada pretvarača implementirana je u digitalni upravljački sustav iz poglavlja 4. Na slici 6.2 prikazana je načelna shema bezsenzorskog upravljanja PMSG-om primjenom SMO-a s funkcijom letećeg starta. Budući da predložena metoda letećeg starta koristi SMO predložen u poglavlju 5, struktura upravljanja temelji se na upravljačkoj strukturi prikazanoj na slici 5.2 s prilagodbama potrebnima za omogućavanje letećeg starta. Osim toga, u upravljački sustav, uz SMO temeljen na aktivnom toku u $\gamma\delta$ koordinatnom sustavu predloženom u poglavlju 5, implementiran je i već postojeći SMO temeljen na aktivnom toku u $\alpha\beta$ koordinatnom sustavu, no prilagođen za leteći start PMSG-a. Na ovaj način omogućena je usporedba letećeg starta primjenom SMO-a modeliranih u različitim koordinatnim sustavima. Ovisno o vrsti SMO-a, prije pokretanja estimacije, putem upravljačkog signala SMO TYPE bira se SMO koji se koristi u estimacijskoj strukturi tako da se na ulaz bloka SMO+PLL prosljeđuju pripadajući napon i struja, ovisno o primijenjenom SMO-u. Nadalje, prilagodba upravljačke strukture za potrebe letećeg starta PMSG-a uključuje regulator

faktora vođenja IGBT-ova donje grane pretvarača tijekom isprekidanog načina rada te prilagodbu ulaza u blok SMO+PLL. Isprekidani način rada aktivan je kada je upravljački signal PWM ENABLE postavljen u nulu. U isprekidanom načinu rada IGBT-ovi gornje grane pretvarača su blokirani dok se svim IGBT-ovima donje grane zadaje isti faktor vođenja D. Faktor vođenja računa se regulatorom čije ulaze čine referentna amplituda isprekidane struje I_D^* te mjerena struja u α-osi. Referentna amplituda provodi se kroz generator rampe i oduzima se od srednje vrijednosti ispravljene mjerene struje, a ta razlika dovodi se na PI regulator koji na svom izlazu daje potreban faktor vođenja D. Osim toga, tijekom isprekidanog rada na ulaz bloka SMO+PLL dovodi se referentni napon $\boldsymbol{u}^*_{\gamma\delta[k]} = \boldsymbol{u}^*_{\alpha\beta[k]} = 0$ kako bi se SMO prilagodio kontroliranim kratkim spojevima na stezaljkama PMSG-a. Primjenom pojačanja SMO-a izvedenima za isprekidani način rada iz tablice 6.4 i prikladnim podešenjem PLL regulatora postiže se točna estimacije kuta rotora i brzine u konačnom vremenu što omogućuje postavljanje početnog uvjeta, $u_\delta^* = u_q^* = \hat{\omega}_{re[k]}\psi_r$, regulatoru struje u q-osi čime je postignuto da napon na izlazu iz pretvarača i napon na stezaljkama PMSG-a budu jednaki. Na ovaj način osigurana je minimalna uklopna struja prilikom uklopa PMSG-a na pretvarač čime je ostvarena glavna zadaća funkcije letećeg starta. Uklop pretvarača omogućuje se postavljenjem signala PWM ENABLE te se na taj način prelazi se u trajni rad temeljen na RFOC algoritmu i PWM modulaciji, dok se za bezsenzorsko upravljanje koristi isti estimacijski blok SMO+PLL uz prilagodbu ulaza i pojačanja za trajni rad prema tablici 6.4.

Na slici 6.3 detaljno je prikazana struktura za estimaciju kuta i brzine vrtnje PMSG-a temeljena na SMO-u i PLL-u prilagođena za isprekidani i trajni način rada pretvarača. S obzirom da se za leteći start koriste SMO-i u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu, struktura je predstavljena koristeći opći zapis. Upravljanje strukturom za estimaciju izvodi se pomoći tri upravljačka signala SMO TYPE, CONTROL LAW TYPE i PWM ENABLE kojim se odabiru koordinatni sustav SMO-a, vrsta upravljačkog zakona te vrsta rada pretvarača.

Postavljanjem signala PWM ENABLE u nulu aktiviran je isprekidani način rada pretvarača te je SMO potrebno prilagoditi tako što mu se na ulaz prosljeđuje napon $\boldsymbol{u}^*_{x[k]} = 0$ te mu se statorski otpor postavlja na $R_s = 0$. Osim toga, u isprekidanom načinu rada potrebno je odabrati pojačanja prilagođena za isprekidani rad temeljena na tablici 6.4, a to su K_d za klizni režim prvog reda ili k_{1d} i k_{2d} za STA algoritam. Odabirom prikladnih pojačanja, trajektorija u prostoru stanja greške estimirane struje $(\boldsymbol{i}_{x[k]}, \dot{\bar{\boldsymbol{i}}}_{x[k]})$ u isprekidanom radu dostići će kvazi-kliznu plohu $\bar{\boldsymbol{i}}_{x[k]} = 0$ pa će prema jednadžbi dinamike greške estimirane struje za isprekidani način rada (6.9) vrijediti:

$$\boldsymbol{e}^{AF}_{x[k]} = \mathrm{NPF}\left(\boldsymbol{z}_{x[k]}\right). \tag{6.21}$$

Osim postavljanja ispravnih pojačanja SMO-a, za točnu estimaciju kuta rotora vrlo važno je vektor upravljačkog zakona $\boldsymbol{z}_{x[k]}$ zakrenuti za kut $\pi/2$. Razlog za to leži u činjenici da je SMO za isprekidani rad modeliran na temelju modela PMSG-a u trajnom kratkom spoju koji se s

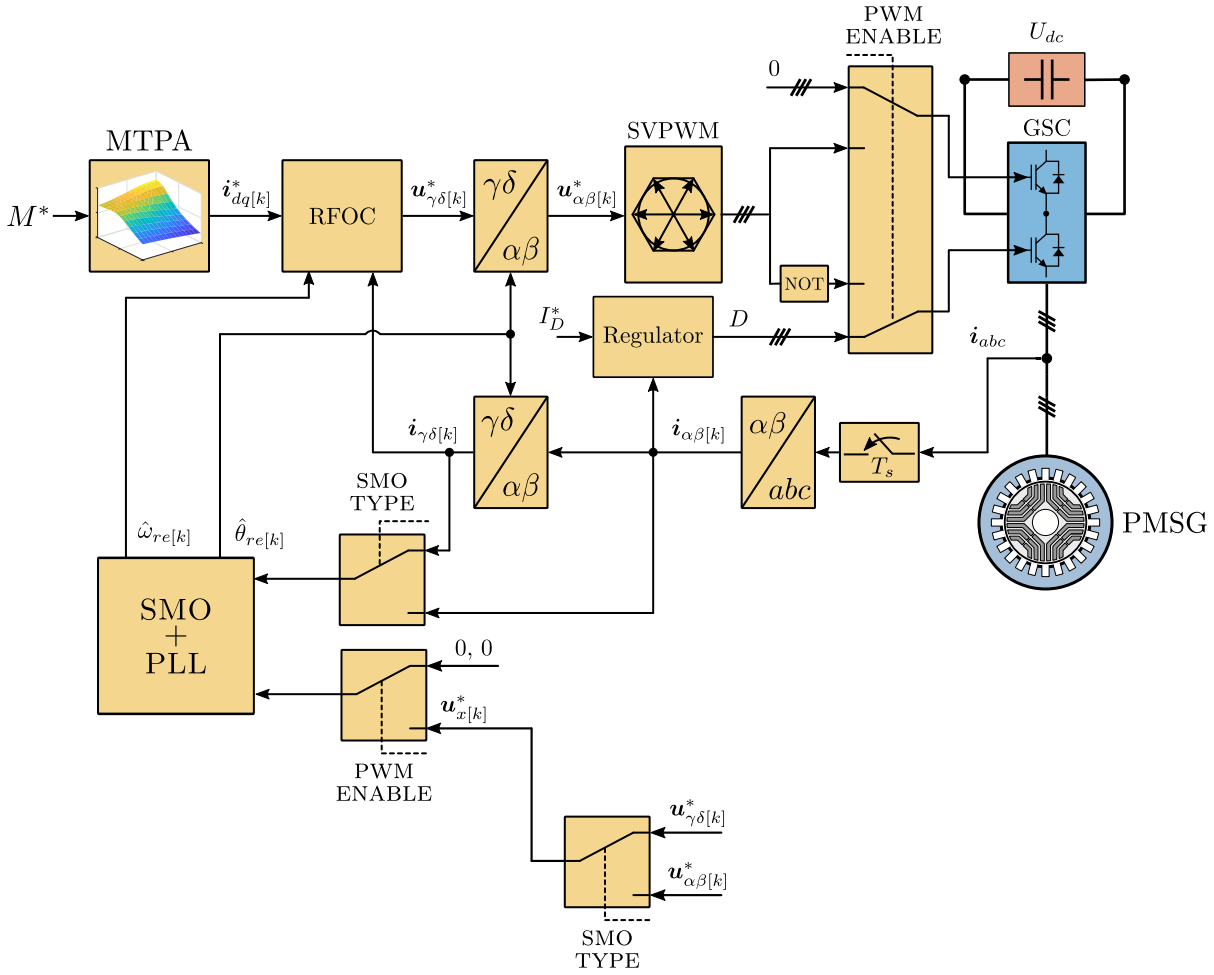

Slika 6.2: Struktura za bezsenzorski leteći start i trajni rad PMSG-a temeljena na SMO-u

modelom PMSG-a pri kontroliranom kratkotrajnom kratkom spoju uzrokovanom isprekidanom načinom rada ne slaže u potpunosti. Ovaj nesrazmjer očituje se u faznom pomaku za kut $\pi/2$ između struje dobivene iz modela za trajni kratki spoj, (6.2) i (6.3), te uzorkovane isprekidane struje tijekom kontroliranog kratkog spoja, (6.5) i (6.6). Navedeno neslaganje najlakše je uočiti promatrajući model PMSG-a i SMO-a u $\alpha\beta$ koordinatnom sustavu. Na ulaz SMO-a u tom se slučaju dovodi upravo uzorkovana struja (6.5). Uvrštavanjem derivacije uzorkovane struje (6.5) u model za trajni kratki spoj PMSG-a (6.1), uz zanemarenje statorskog otpora, očito je da između napona i uzorkovane struje postoji fazni pomak od $\pi/2$ budući da se radi o čisto induktivnom električnom krugu. Nakon dostizanja kvazi-klizne plohe takav inducirani napon bit će jednak srednjoj vrijednosti upravljačkog vektora, odnosno vrijedit će $\boldsymbol{e}^{AF}_{\alpha\beta[k]} = \mathrm{NPF}\left(\boldsymbol{z}_{\alpha\beta[k]}\right)$. Prema tome, estimirani inducirani napon $\mathrm{NPF}\left(\mathrm{z}_{\alpha\beta[\mathrm{k}]}\right)$ dobiven iz SMO-a modeliranog na temelju modela trajnog kratkog spoja, fazno je pomaknut za kut $\pi/2$ od stvarnog induciranog napona e_α na stezaljkama PMSG-a kao što je vidljivo na slici 6.4a na kojoj su prikazani valni oblici u α-osi (u β-osi događa se isti pomak u odnosu na β komponentu estimiranog induciranog napona). U estimiranom $\gamma\delta$ koordinatnom sustavu ovaj problem očituje se u pomaku za kut $\pi/2$

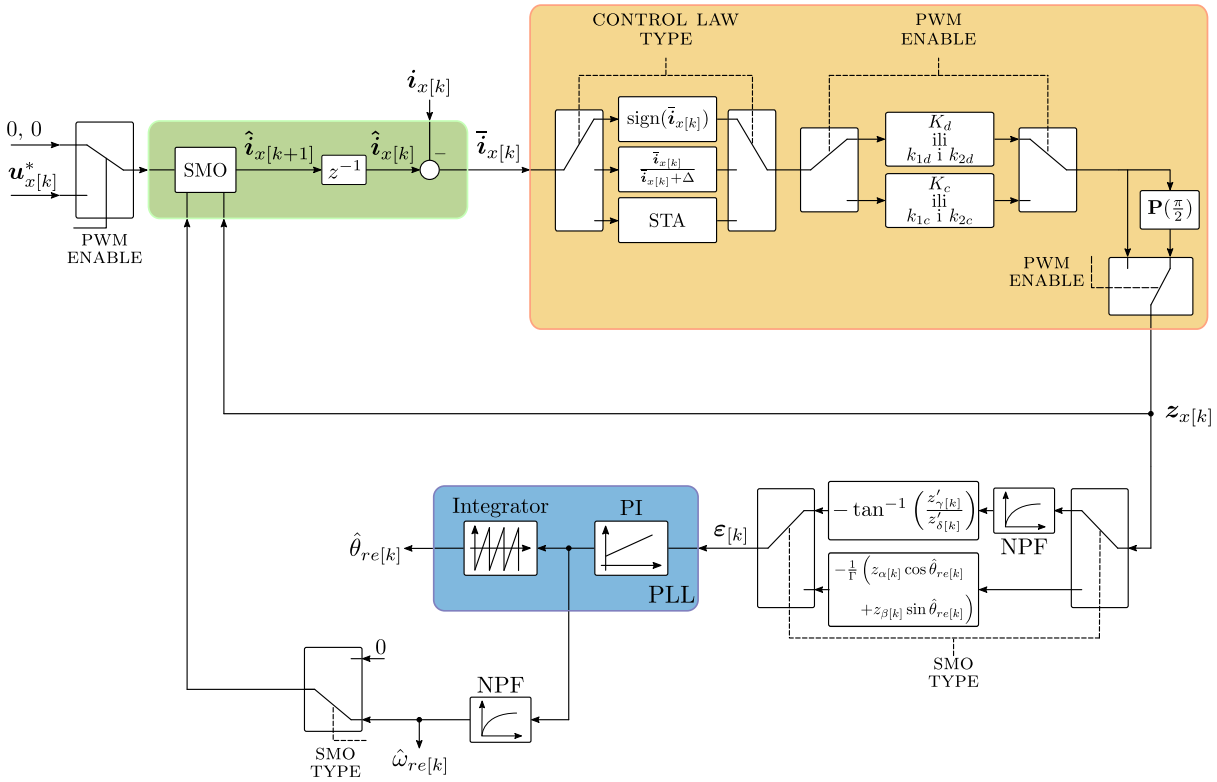

Slika 6.3: Struktura za estimacije kuta i brzine vrtnje PMSG-a temeljena na SMO-u i PLL-u prilagođena isprekidanom načinu rada

u odnosu na stvarni dq koordinatni sustav (slika 6.4b). Ovaj problem može se riješiti pomakom uzorkovane struje na ulazu u SMO ili vektora upravljačkog zakona za kut $\pi/2$. Prema tome, kako bi se osigurala točna estimacija kuta rotora u upravljačkoj strukturi izvršen je pomak vektora upravljačkog zakona za kut $\pi/2$ koristeći Parkovu transformaciju.

Nakon uklopa pretvarača, odnosno prelaska u trajni rad postavljanjem signala PWM ENABLE, vektor upravljačkog zakona više nije potrebno zakretati. Također, u trajnom radu, ovisno o signalu SMO TYPE, na ulaze SMO-a prosljeđuje se referentni napon $\boldsymbol{u}^*_{\gamma\delta[k]}$ te estimirana brzina vrtnje $\hat{\omega}_{re[k]}$ za $\gamma\delta$ koordinatni sustav, odnosno napon $\boldsymbol{u}^*_{\alpha\beta[k]}$ za $\alpha\beta$ koordinatni sustav, dok se u tom slučaju ulaz estimirane brzine vrtnje postavlja na nulu.

Također, neovisno o načinu rada pretvarača, no ovisno o odabranom koordinatnom sustavu SMO-a mijenja se i ulaz u PLL regulator. U $\gamma\delta$ koordinatom sustavu ulaz u PLL regulator glasi:

$$\varepsilon_{[k]} = -\tan^{-1}\left(\frac{z'_{\gamma[k]}}{z'_{\delta[k]}}\right) = -\tan^{-1}\left(\frac{\mathrm{NPF}(z_{\gamma[k]})}{\mathrm{NPF}(z_{\delta[k]})}\right) = -\tan^{-1}\left(\frac{\sin\bar{\theta}_{re[k]}}{\cos\bar{\theta}_{re[k]}}\right), \tag{6.22}$$

dok je u $\alpha\beta$ koordinatnom sustavu ulaz PLL-a jednak (5.55)

Na kraju, estimirani kut rotora $\hat{\theta}_{re[k]}$ te filtrirana estimirana brzina vrtnje $\hat{\omega}_{re[k]}$ dobiveni na izlazu PLL regulatora prosljeđuju se RFOC algoritmu.

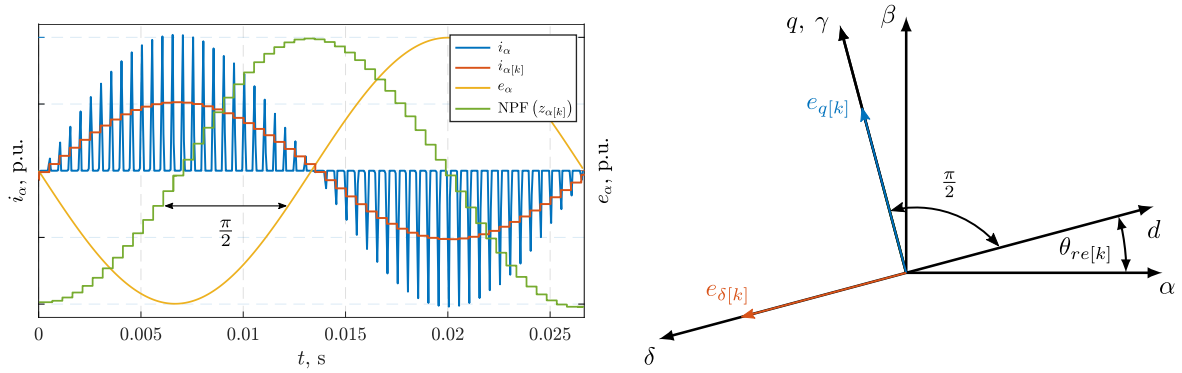

(a) Pomak između estimiranog i stvarnog induciranog napona PMSG-a u vremenskoj domeni

(b) Pomak između estimiranog $\gamma\delta$ i stvarnog dq koordinatnog sustava

Slika 6.4: Pomak između estimiranog i stvarnog induciranog napona PMSG-a uzrokovan razlikom modela SMO-a i modela stroja pri isprekidanom radu pretvarača

6.6.Eksperimentalni rezultati

Bezsenzorska metoda upravljanja temeljena na SMO-u predstavljena u poglavlju 5 nadograđena je metodom za bezsenzorski leteći start predstavljenom u potpoglavlju 6.5 te je implementirana u upravljački sustav pretvarača *Open4Lab* i eksperimentalno verificirana na laboratorijskom postavu iz poglavlja 4. Metoda je izvedena u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu te je ispitana za tri različita upravljačka zakona: signum funkciju, sigmoidnu funkciju i STA algoritam.

Pri implementaciji u digitalni upravljački sustav korišteni su parametri PMSG-a predstavljeni u poglavlju 5 u tablici 5.5. Vrijeme diskretizacije jednako je vremenu izvođenja prekidne rutine i iznosi $T_s = 0,0002$ s.

Pojačanja vektora upravljačkih zakona za klizni režim prvog reda proračunata su prema izrazima izvedenima za isprekidani rad u tablici 6.2, dok su pojačanja STA algoritma proračunata iz izraza za perturbaciju u isprekidanom načinu rada u tablici 6.3 te izraza (5.40), (5.41) i (5.48). Referentna amplituda isprekidane struje postavljena je na $I_D^* = 0,01$ p.u., a faktor vođenja koji osigurava takvu amplitude iznosi $D = 0,16$. Na temelju navedenog i parametara nadomjesne sheme PMSG-a u sustavu jediničnih vrijednosti iz tablice 5.5 proračunata su ograničenja pojačanja upravljačkih funkcija SMO-a te su prikazana u tablici 6.5. U skladu s izračunatim ograničenjima odabrana su pojačanja dana u tablici 6.6.

Pri određivanju perturbacija STA algoritma pretpostavljena je minimalna greška estimirane struje u iznosu od $|\bar{\boldsymbol{i}}_{\alpha\beta[k]}| = |\bar{\boldsymbol{i}}_{\gamma\delta[k]}| = 0,002$ p.u., dok je za donju granicu uvjeta stabilnosti STA algoritma odabran faktor sigurnosti kao i u (5.53) te (5.54).

RFOC algoritam neaktivan je tijekom isprekidanog rada pretvarača, te se uključuje nakon uklopa pretvarača pa su parametri PI regulatora struje jednaki kao u poglavlju 5, odnosno tablici 5.8.

Pojačanja regulatora faktora vođenja glase: $K_p^{disc} = 0,5$ i $T_i^{disc} = 10$ ms, a referentna

Tablica 6.5: Ograničenja pojačanja upravljačkih funkcija SMO-a u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu za isprekidani način rada pretvarača

Koordinatni sustav	Signum/Sigmoid	STA
$\alpha\beta$	$K_d > 0,0101$ $K_d < 0,1749$	$\lvert\boldsymbol{\rho}_{\alpha\beta[k]}\rvert = 0,0025$, $\zeta = 0,0569$ $k_{1d} \geq 0,1149$, $k_{2d} \geq 2,4172$
$\gamma\delta$	$K_d > 0,0101$ $K_d < 0,1749$	$\lvert\boldsymbol{\rho}_{\gamma\delta[k]}\rvert = 0,0016$, $\zeta = 0,0354$ $k_{1d} \geq 0,0715$, $k_{2d} \geq 0,9365$

Tablica 6.6: Odabrana pojačanja upravljačkih funkcija SMO-a u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu za isprekidani način rada pretvarača

Koordinatni sustav	Signum	Sigmoid	STA
$\alpha\beta$	$K_d = 0,015$	$K_d = 0,015$, $\Delta = 0,0002$	$k_{1d} = 0,1149$ $k_{2d} = 2,4172$
$\gamma\delta$	$K_d = 0,015$	$K_d = 0,015$, $\Delta = 0,0002$	$k_{1d} = 0,0715$ $k_{2d} = 0,9365$

vrijednost amplitude isprekidane struje dovodi se na ulaz regulatora preko rampe od 1 s.

6.6.1.Leteći start temeljen na SMO-u $\alpha\beta$ koordinatnom sustavu

U nastavku su prikazani odzivi bezsenzorskog letećeg starta PMSG-a temeljeni na upravljačkoj strukturi sa slike 6.2 i estimacijskoj strukturi prikazanoj na slici 6.3 izvedenoj u $\alpha\beta$ koordinatnom sustavu. Na svim slikama prikazani su odzivi mjerene i uzorkovane struje, $\boldsymbol{i}_{\alpha\beta}$ i $\boldsymbol{i}_{\alpha\beta[k]}$, mjerene i estimirane struje, $\boldsymbol{i}_{\alpha\beta}$ i $\hat{\boldsymbol{i}}_{\alpha\beta}$, mjerene struje $\boldsymbol{i}_{dq}$, mjerene i estimirane brzine vrtnje, ω_{re} i $\hat{\omega}_{re}$, mjerenog i estimiranog kuta rotora, θ_{re} i $\hat{\theta}_{re}$ i greške estimacije kuta rotora $\bar{\theta}_{re}$. Navedeni odzivi snimljeni su za tri vrste upravljačkih funkcija: signum, sigmoidnu i STA algoritam te su prikazani slikama 6.5, 6.6 i 6.7.

Pokretanjem algoritma letećeg starta PI regulator računa se faktor vođenja IGBT-ova donje grane pretvarača kojim se ostvaruje isprekidana struja zadane amplitude $I_D^* = 0,01$ p.u. Uzimanjem uzoraka isprekidane struje u sredini PWM periode, uzorkovana struja prati sinusni valni oblik ovojnice isprekidane struje kao što je teoretski objašnjeno slikom 6.1 i što se može vidjeti iz uvećanih prikaza mjerene struje $\boldsymbol{i}_{\alpha\beta}$ i uzorkovane struje upravljačkog sustava $\boldsymbol{i}_{\alpha\beta[k]}$ na slikama 6.5a, 6.6a i 6.7a. Nadalje, ovako uzorkovana struja dovodi se na ulaz SMO-a koji dohvaća kvazi-kliznu plohu $\bar{\boldsymbol{i}}_{\alpha\beta} = 0$ s obzirom da vrijedi $\hat{\boldsymbol{i}}_{\alpha\beta} = \boldsymbol{i}_{\alpha\beta}$. Također, mjerena struja $\boldsymbol{i}_{dq}$ tijekom isprekidanog rada nalazi u q-osi što je u skladu s teoretskim razmatranjem iz prethodnog

potpoglavlja. Iz odziva brzine vrtnje uočava se da estimacija ne započinje odmah, već u trenutku $t \approx 2$ s. Razlog tomu je taj što estimacijska struktura temeljena na SMO-u i PLL regulatoru kreće s radom tek nakon što amplituda isprekidane struje postigne 70% zadane referentne vrijednosti. Brzina konvergencije estimirane brzine k stvarnoj ovisi o primijenjenom upravljačkom zakonu te se za signum funkciju estimirana brzina poklapa sa stvarnom u $t \approx 6,6$ s, za sigmoidnu funkciju u $t \approx 4,5$ s, a za STA algoritam u $t \approx 2,5$ s. U trenutku kada estimirana brzina konvergira ka stvarnoj, greška estimiranog kuta iščezava što implicira točnu estimaciju kuta rotora. Na kraju, estimacijska struktura u isprekidanom načinu rada ispitana je i u radnim točkama $\omega_{re} = 0,5$ p.u. i $\omega_{re} = 0,67$ p.u. u kojima, također, pokazuje zadovoljavajuće rezultate.

Na slikama 6.5b, 6.6b i 6.7b prikazan je trenutak uklopa pretvarača pri brzini $\omega_{re} = 0,33$ p.u. Estimacije brzine i kuta rotora izvedena je na prethodno opisan način. Nakon uspješne estimacije brzine vrtnje i kuta rotora, početni uvjet PI regulatora u q-osi postavljen je na iznos $u_\delta^* = u_q^* = 0,33$ p.u te je sustav spreman za uklop. Zbog točno postavljenog početnog uvjeta PI regulatora, u trenutku uklopa dolazi do minimalne razlike napona između stezaljki pretvarača i stezaljki PMSG-a što uzrokuje uklopnu struju zanemarivog iznosa. Za sva tri upravljačka zakona uklopna struja nalazi se u granici $|\boldsymbol{i}_{\alpha\beta}| = |\boldsymbol{i}_{\gamma\delta}| < 0,02$ p.u.

Osim uklopa na brzini vrtnji $\omega_{re} = 0,33$ p.u., ispitan je i uklop pri brzini $\omega_{re} = 0,67$ p.u. Iz snimljenih odziva sa slika 6.5c, 6.6c i 6.7c vidljivo je da je leteći start pri brzini $\omega_{re} = 0,67$ p.u. uspješno izveden. Uklopna struja pri brzini vrtnje $\omega_{re} = 0,67$ p.u. nešto je veća nego u slučaju $\omega_{re} = 0,33$ p.u., međutim, također se nalazi u prihvatljivom opsegu $|\boldsymbol{i}_{\alpha\beta}| = |\boldsymbol{i}_{\gamma\delta}| < 0,03$ p.u. Također, pri većoj brzini vrtnje potrebno je dulje vrijeme za konvergenciju estimiranih veličina ka stvarnim.

Također, osim blagog porasta mjerene struje $\boldsymbol{i}_{\alpha\beta}$, na odzivima sa slika 6.5b, 6.5c, 6.6b i 6.6c očituje se i skok estimirane struje $\hat{\boldsymbol{i}}_{\alpha\beta}$ u trenutku uklopa. Razlog tomu je promjena pojačanja SMO-a pri prelasku iz isprekidanog u trajni način rad pretvarača kako bi se trajektorija greške zadržala u kvazi-klizom području unatoč promjeni modela PMSG-a. Iz izvedenih pojačanja za klizni režim prvog reda iz tablice 6.4 očito je da pojačanje K_c znatno veće od pojačanje K_d budući da vrijedi $K_c = K_d/DT_s$. Osim toga, širina kvazi-kliznog područja prema (6.18) ovisi o pojačanju pa je, zbog toga što vrijedi $K_c \gg K_d$ (usporedba tablica 5.7, 5.10 i 6.6), širina kvazi-kliznog područja u trajnom radu znatno veća u usporedbi s isprekidanim radom što uzrokuje i veće vrijednosti estimirane struje $\hat{\boldsymbol{i}}_{\alpha\beta}$ pri trajnom radu. S druge strane, porast estimirane estimirane struje $\hat{\boldsymbol{i}}_{\alpha\beta}$ u trenutku uklopa nije toliko značajan kada se u upravljačkoj funkciji koristi STA algoritam kao što je uočljivo iz odziva sa slika 6.7b i 6.7c. Ovakva pojava nije iznenađujuća s obzirom da STA algoritam inherentno smanjuje efekt zveketanja estimiranog signal koji u ovom slučaju predstavlja estimirana struja $\hat{\boldsymbol{i}}_{\alpha\beta}$. Istovjetno razmatranje primjenjivo je i na estimiranu struju u $\gamma\delta$ koordinatnom sustavu, $\hat{\boldsymbol{i}}_{\gamma\delta}$, čiji će odzivi biti prikazani u sljedećem potpoglavlju 6.6.2.

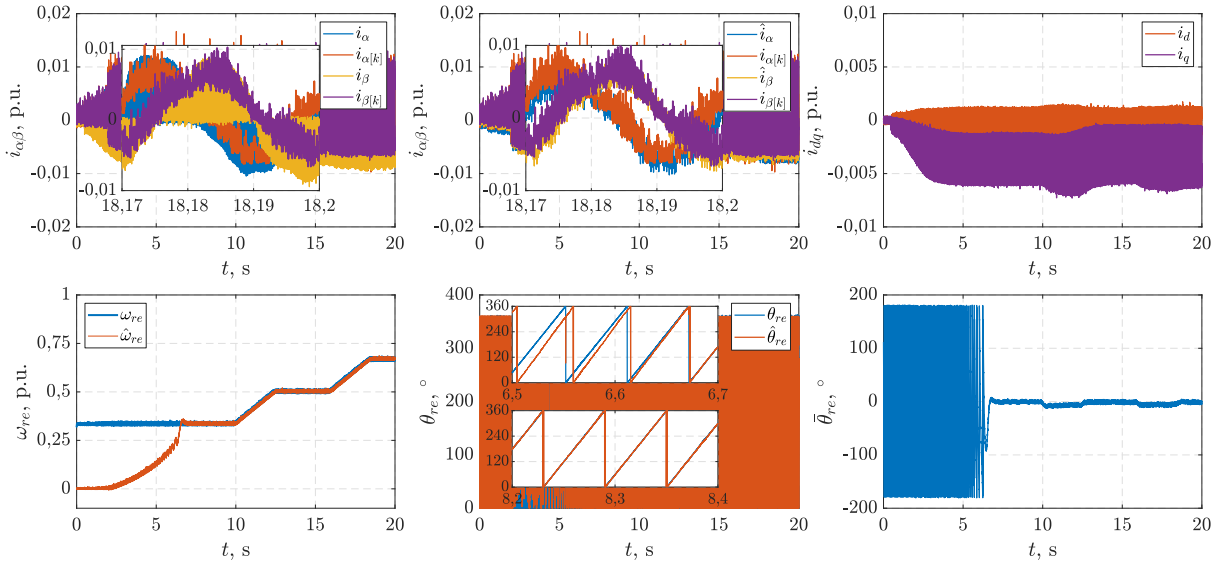

(a) Estimacija kuta i brzine vrtnje pri isprekidanom radu pretvarača i promjeni brzine vrtnje

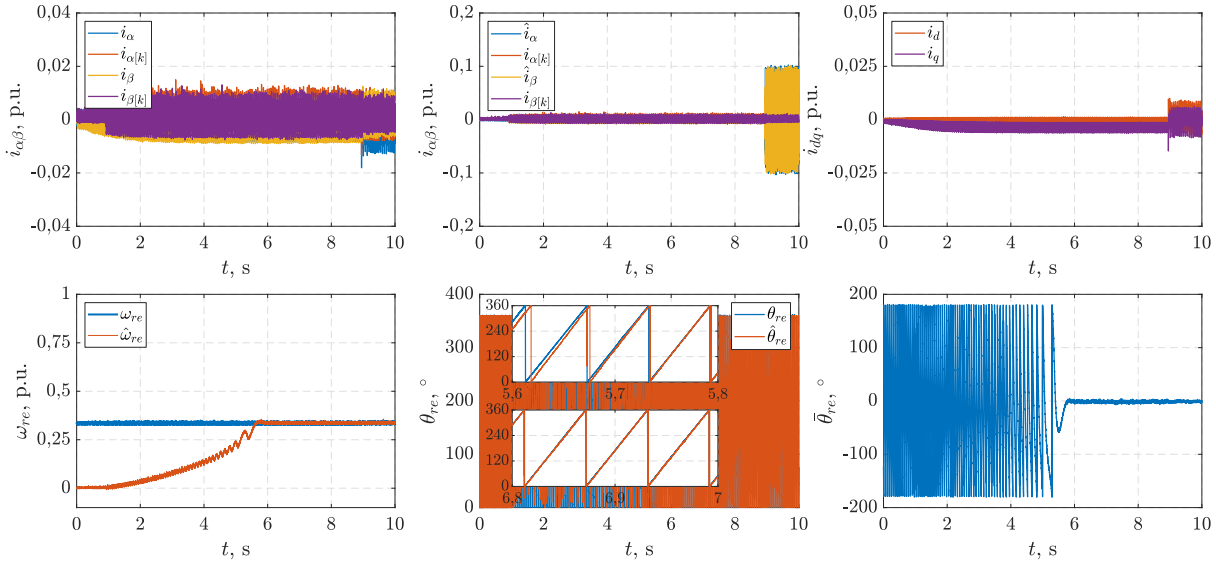

(b) Uklop pri brzini vrtnje $\omega_r = 0,33$ p.u.

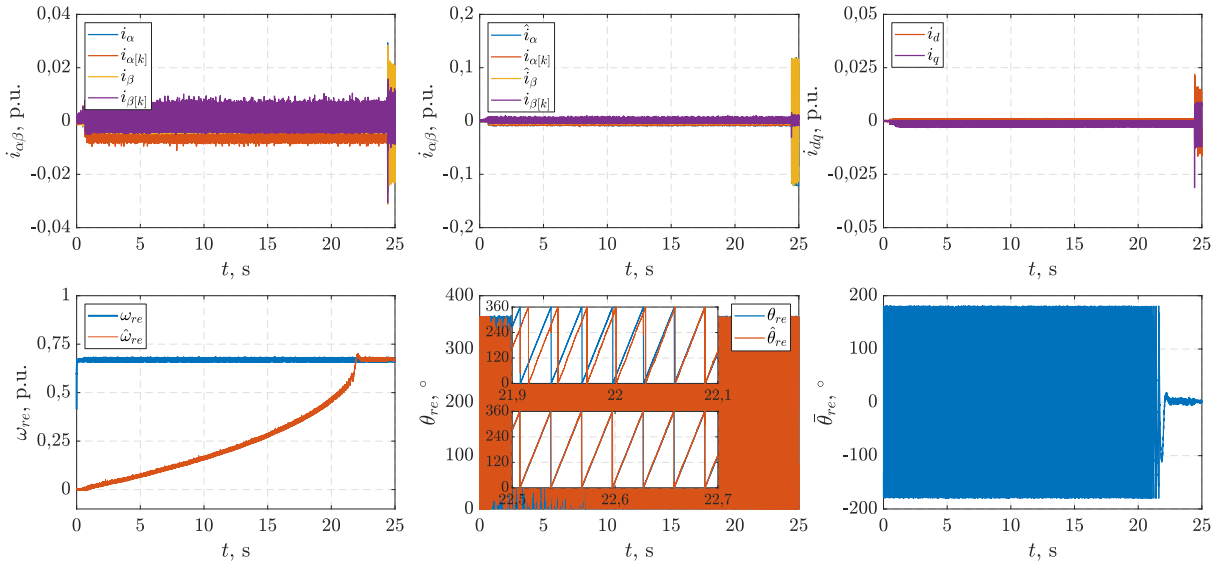

(c) Uklop pri brzini vrtnje $\omega_r = 0,67$ p.u.

Slika 6.5: Leteći start s estimacijskom strukturom temeljenoj na SMO-u u $\alpha\beta$ sustavu i signum funkciji

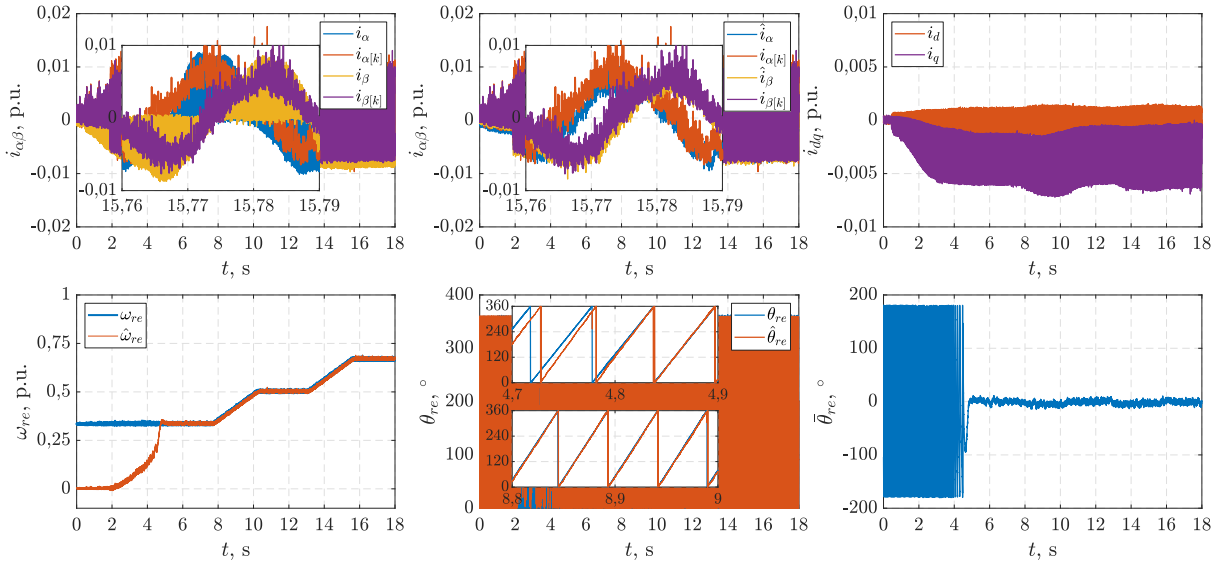

(a) Estimacija kuta i brzine vrtnje pri isprekidanom radu pretvarača i promjeni brzine vrtnje

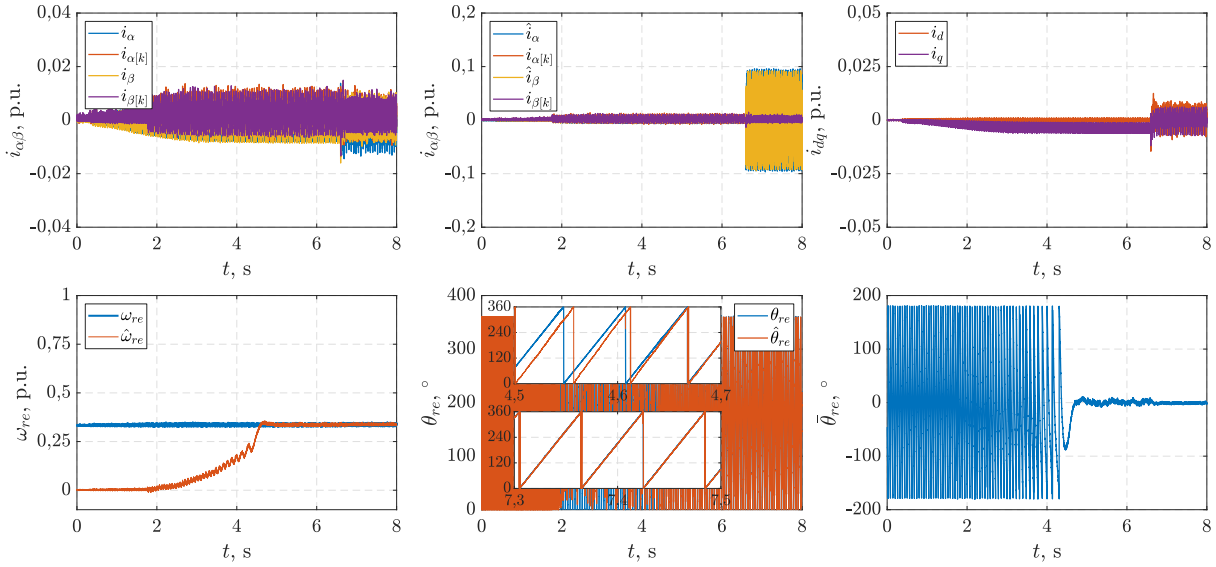

(b) Uklop pri brzini vrtnje $\omega_r = 0,33$ p.u.

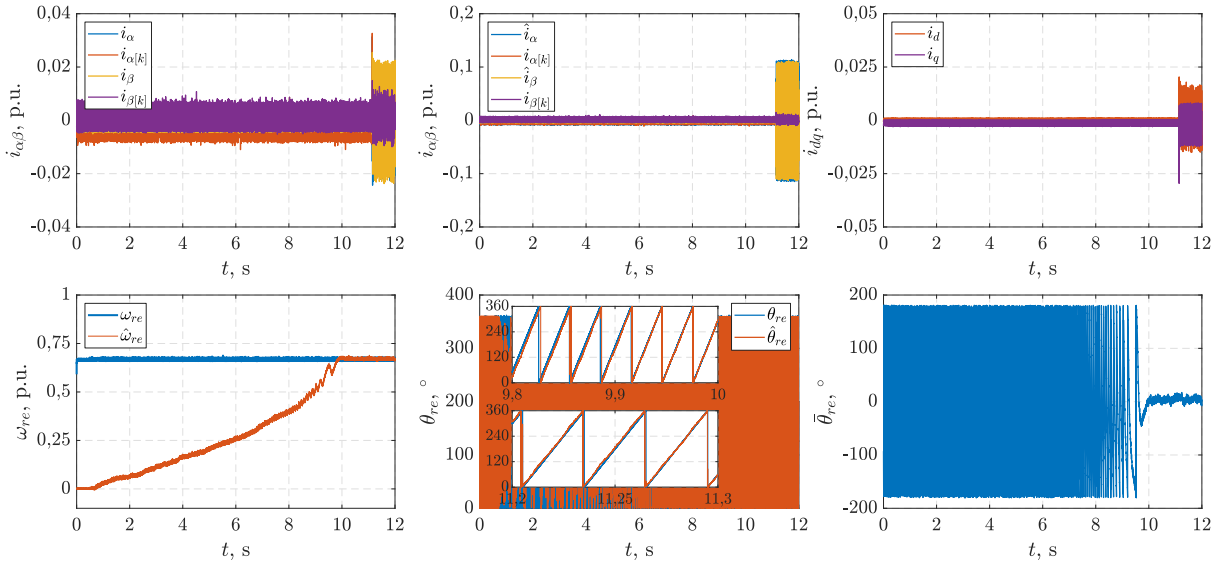

(c) Uklop pri brzini vrtnje $\omega_r = 0,67$ p.u.

Slika 6.6: Leteći start s estimacijskom strukturom temeljenoj na SMO-u u $\alpha\beta$ sustavu i sigmoidnoj funkciji

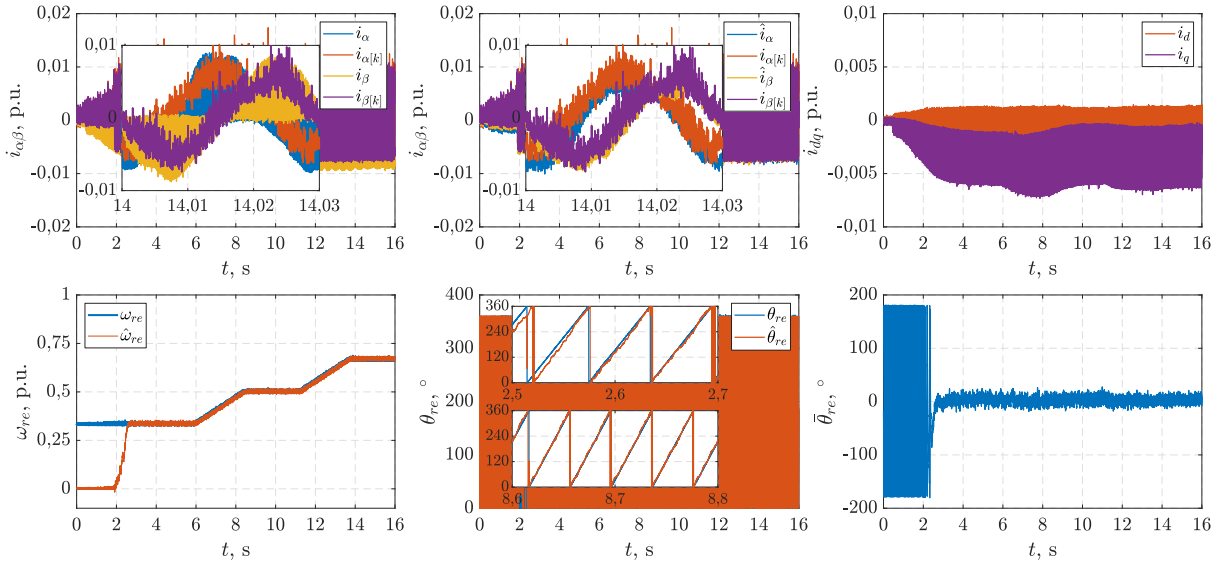

(a) Estimacija kuta i brzine vrtnje pri isprekidanom radu pretvarača i promjeni brzine vrtnje

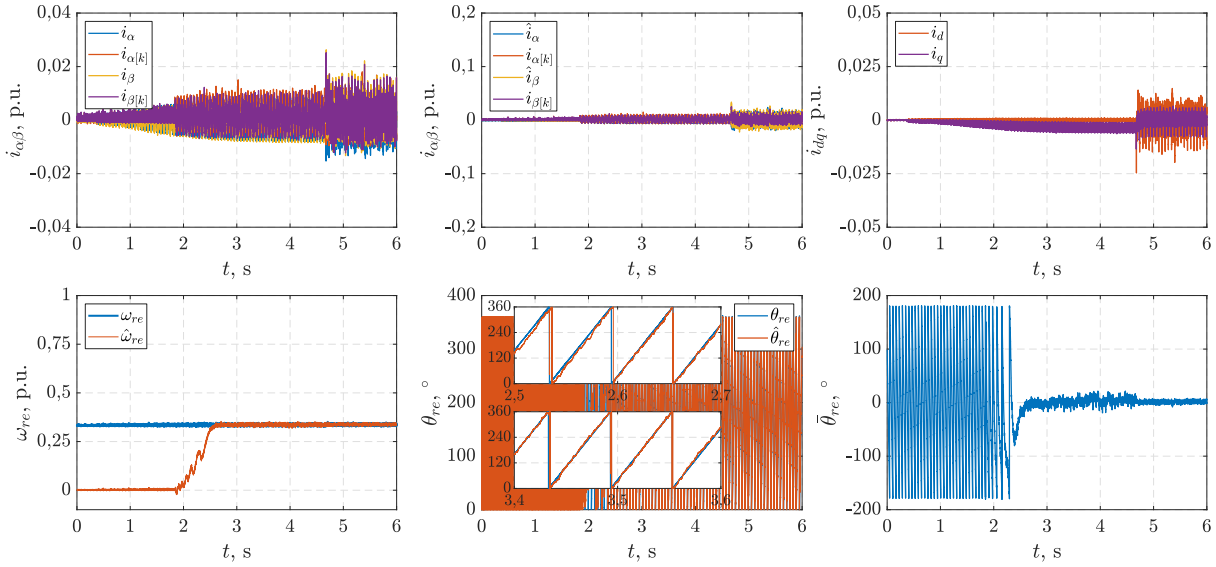

(b) Uklop pri brzini vrtnje $\omega_r = 0,33$ p.u.

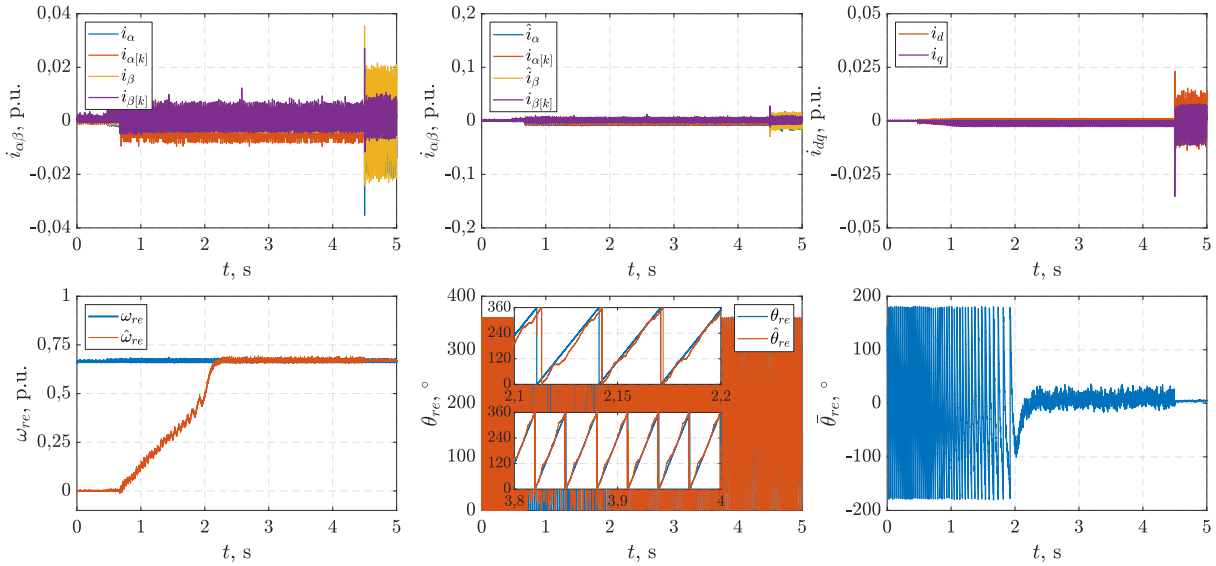

(c) Uklop pri brzini vrtnje $\omega_r = 0,67$ p.u.

Slika 6.7: Leteći start s estimacijskom strukturom temeljenoj na SMO-u u $\alpha\beta$ sustavu i STA algoritmu

6.6.2.Leteći start temeljen na SMO-u $\gamma\delta$ koordinatnom sustavu

U nastavku su prikazani odzivi bezsenzorskog letećeg starta PMSG-a temeljeni na upravljačkoj strukturi sa slike 6.2 i estimacijskoj strukturi prikazanoj na slici 6.3 izvedenoj u $\gamma\delta$ koordinatnom sustavu. Na svim slikama prikazani su odzivi mjerene struje $\boldsymbol{i}_{\gamma\delta}$, mjerene i estimirane struje, $\hat{\boldsymbol{i}}_{\gamma\delta}$ i $\boldsymbol{i}_{\gamma\delta}$, mjerene struje $\boldsymbol{i}_{dq}$, mjerene i estimirane brzine vrtnje, ω_{re} i $\hat{\omega}_{re}$, mjerenog i estimiranog kuta rotora, θ_{re} i $\hat{\theta}_{re}$ i greške estimacije kuta rotora $\bar{\theta}_{re}$. Navedeni odzivi snimljeni su za tri vrste upravljačkih funkcija: signum, sigmoidnu i STA algoritam te su prikazani slikama 6.8, 6.9 i 6.10.

Pokretanjem algoritma letećeg starta uključuju se PI regulator faktora vođenja čije je djelovanje jednako kao i za estimacijsku strukturu izvedenoj u $\alpha\beta$ koordinatnom sustavu te čime se, također, ostvaruje isprekidana struja vidljiva u uvećanom prikazu mjerene struje $\boldsymbol{i}_{\alpha\beta}$ na slikama 6.8a, 6.9a i 6.10a. Nadalje, nad ovako uzorkovanom strujom izvodi se Parkova transformacija s estimiranom kutom rotora te se struja $\boldsymbol{i}_{\gamma\delta}$ dovodi na ulaz SMO-a koji dohvaća kvazi-klinu plohu $\bar{\boldsymbol{i}}_{\gamma\delta} = 0$ s obzirom da vrijedi $\hat{\boldsymbol{i}}_{\gamma\delta} = \boldsymbol{i}_{\gamma\delta}$. Nadalje, mjerena struja $\boldsymbol{i}_{dq}$ tijekom isprekidanog rada očekivano je smještena u q-osi. Estimacija brzine vrtnje počinje tek nakon dostizanja 70% zadane referentne amplitude isprekidane struje, odnosno u trenutku $t \approx 2$ s. Konvergencije estimirane brzine vrtnje ka stvarnoj brzini vrtnje znatno je brža, nego kod primjene estimacijske strukture izvedene u $\alpha\beta$ koordinatnom sustavu iako su u obje strukture korištena ista pojačanja PLL regulatora. Također, odabir upravljačkog zakona ne utječe bitno na brzinu konvergencije za razliku od sustava izvedenog u $\alpha\beta$ koordinatnom sustavu. U trenutku kada estimirana brzina konvergira ka stvarnoj, greška estimiranog kuta iščezava što implicira točnu estimaciju kuta rotora. Na kraju, estimacijska struktura u isprekidanom načinu rada ispitana je i u radnim točkama $\omega_{re} = 0,5$ p.u. i $\omega_{re} = 0,67$ p.u. u kojima, također, pokazuje zadovoljavajuće rezultate.

Na slikama 6.8b, 6.9b i 6.10b prikazan je trenutak uklopa pretvarača pri brzini $\omega_{re} = 0,33$ p.u. Nakon uspješne estimacije brzine vrtnje i kuta rotora, početni uvjet PI regulatora u q-osi postavljen je na iznos $u^*_{\gamma\delta} = 0,33$ p.u. te je sustav spreman za uklop. Zbog točno postavljenog početnog uvjeta PI regulatora, u trenutku uklopa dolazi do minimalne razlike napona između stezaljki pretvarača i stezaljki PMSG-a što uzrokuje uklopnu struju zanemarivog iznosa. Za sva tri upravljačka zakona uklopna struja nalazi se u istim granicama kao i u slučaju primjene estimacijske strukture u $\alpha\beta$ koordinatnom sustavu, $|\boldsymbol{i}_{\alpha\beta}| = |\boldsymbol{i}_{\gamma\delta}| < 0,02$ p.u.

Također, ispitan je i uklop pri brzini $\omega_{re} = 0,67$ p.u. Odzivi sa slika 6.8c, 6.9c i 6.10c pokazuju uspješan leteći start i pri brzini $\omega_{re} = 0,67$ p.u. Uklopna struja pri brzini vrtnje $\omega_{re} = 0,67$ p.u. nešto je veća nego u slučaju $\omega_{re} = 0,33$ p.u., međutim, također se nalazi u prihvatljivom opsegu $|\boldsymbol{i}_{\alpha\beta}| = |\boldsymbol{i}_{\gamma\delta}| < 0,05$ p.u. što čini blago povećanje u odnosu na uklopnu struju pri primjeni estimacijske strukture izvedenoj u $\alpha\beta$ koordinatnim sustavu. Na kraju, veća brzina vrtnje ne utječe na produljenje vremena estimacije kao što je slučaj pri korištenju strukture izvedene u $\alpha\beta$ koordinatnim sustavu.

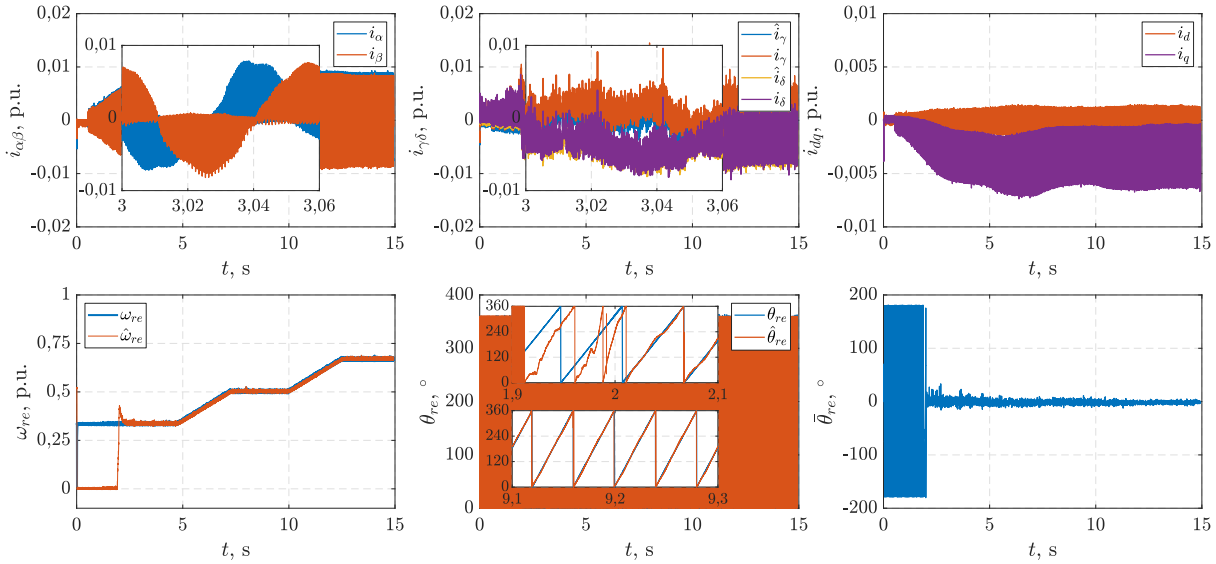

(a) Estimacija kuta i brzine vrtnje pri isprekidanom radu pretvarača i promjeni brzine vrtnje

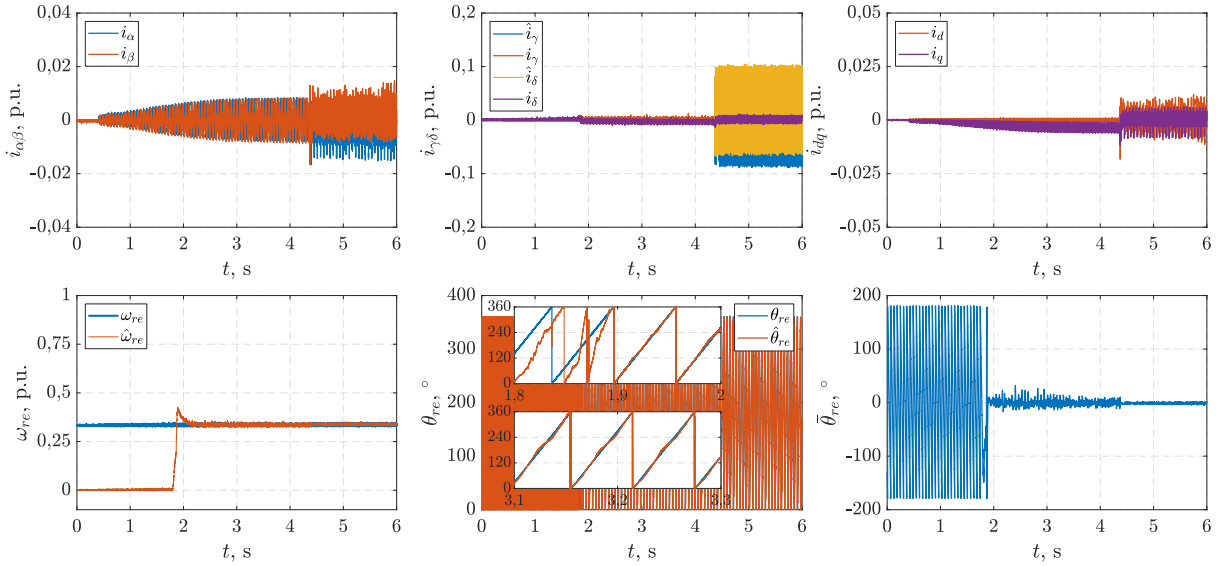

(b) Uklop pri brzini vrtnje $\omega_r = 0,33$ p.u.

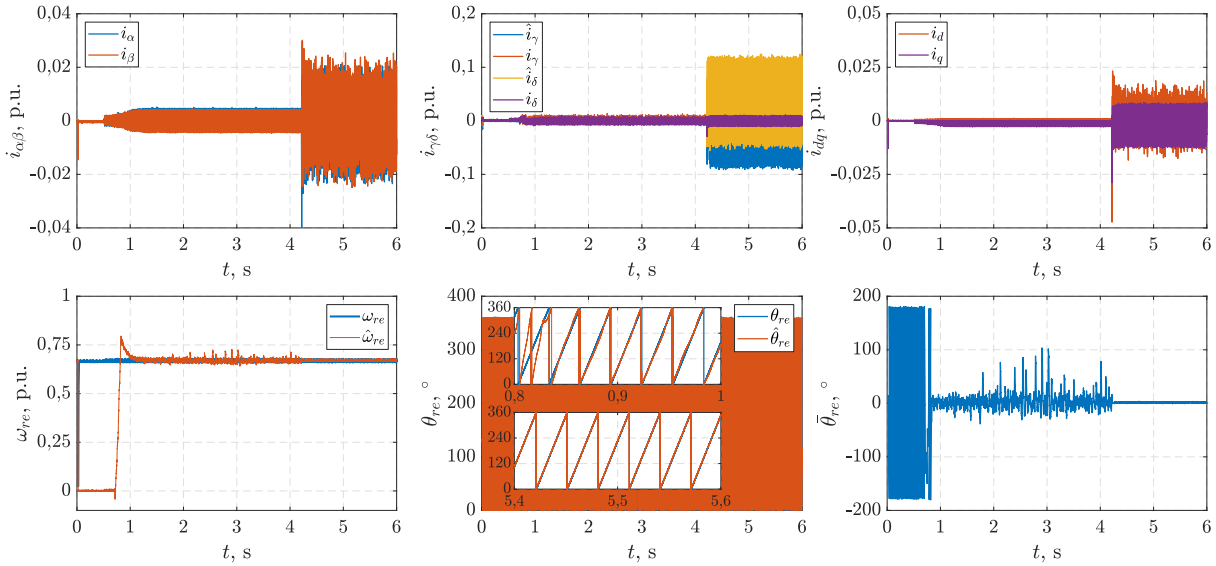

(c) Uklop pri brzini vrtnje $\omega_r = 0,67$ p.u.

Slika 6.8: Leteći start s estimacijskom strukturom temeljenoj na SMO-u u $\gamma\delta$ sustavu i signum funkciji

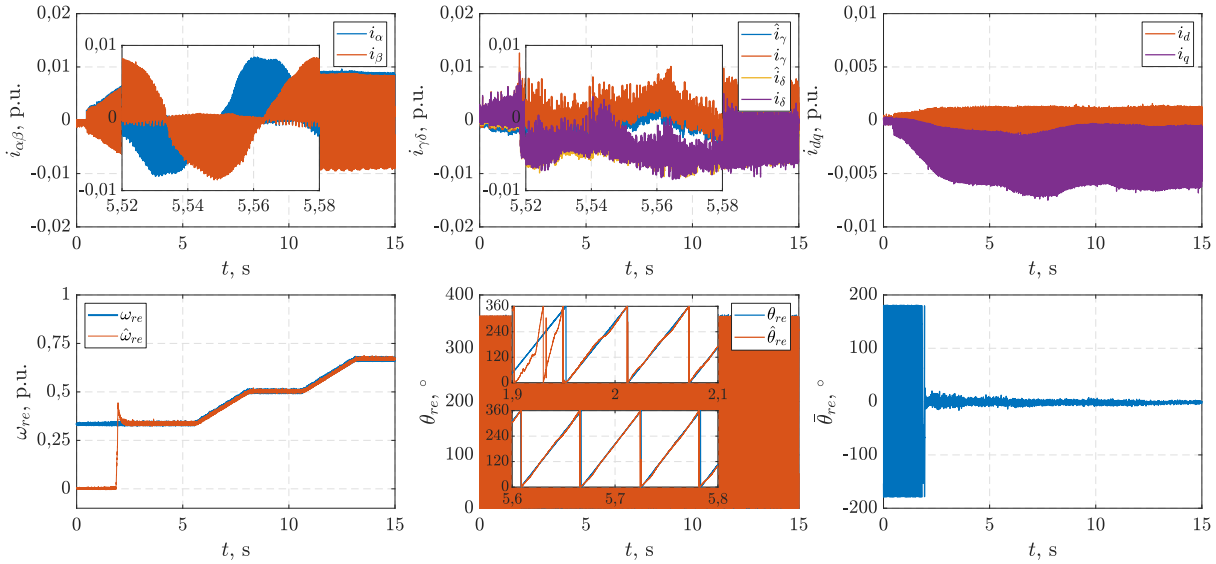

(a) Estimacija kuta i brzine vrtnje pri isprekidanom radu pretvarača i promjeni brzine vrtnje

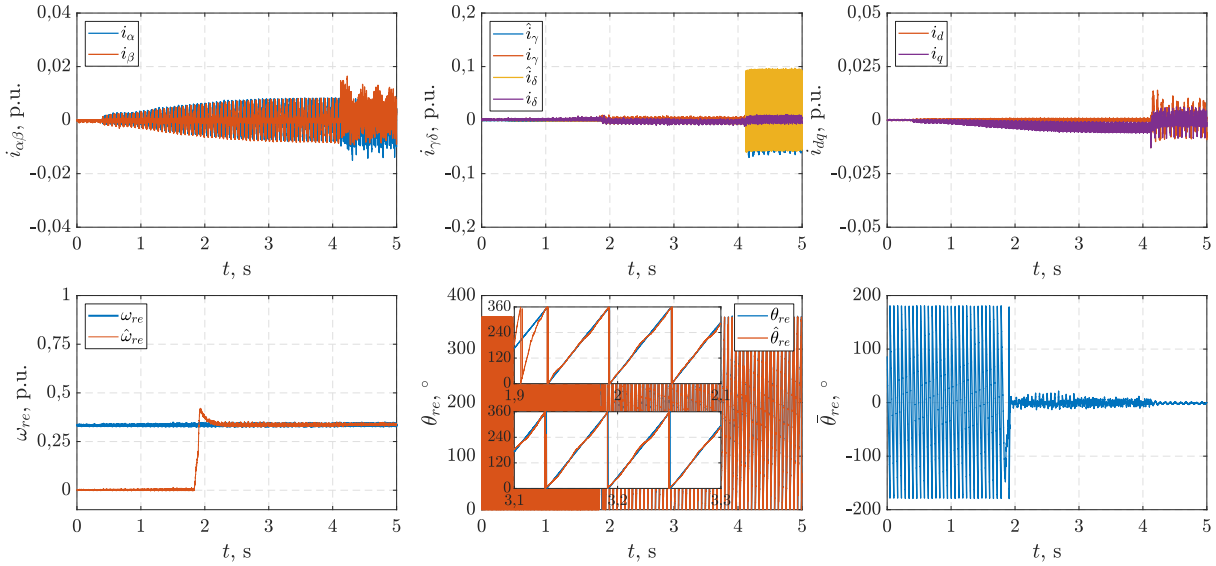

(b) Uklop pri brzini vrtnje $\omega_r = 0,33$ p.u.

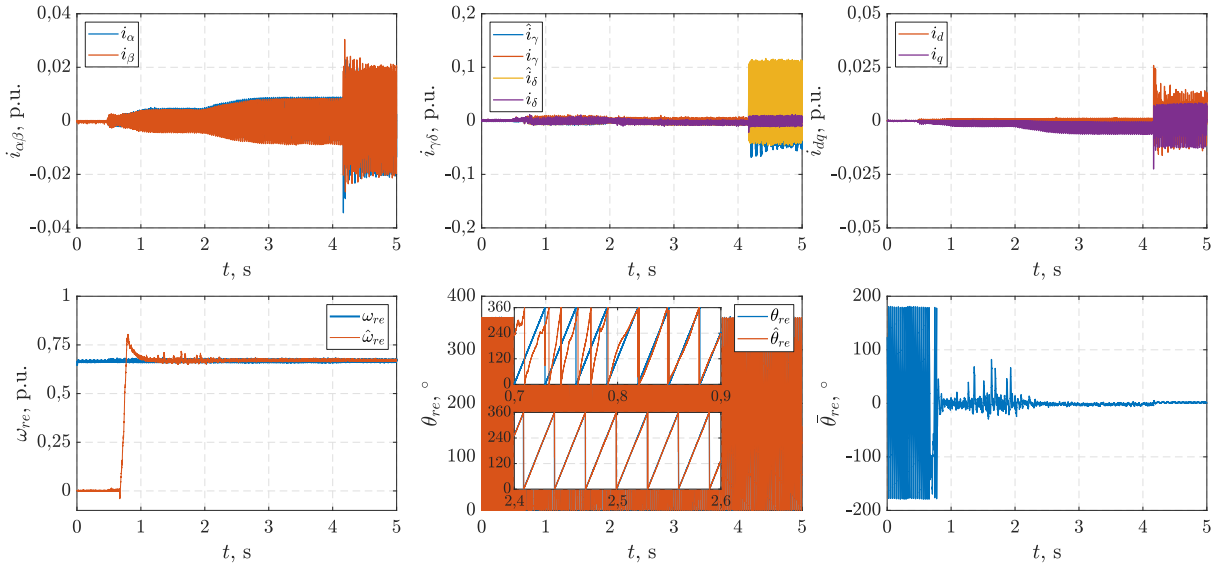

(c) Uklop pri brzini vrtnje $\omega_r = 0,67$ p.u.

Slika 6.9: Leteći start s estimacijskom strukturom temeljenoj na SMO-u u $\gamma\delta$ sustavu i sigmoidnoj funkciji

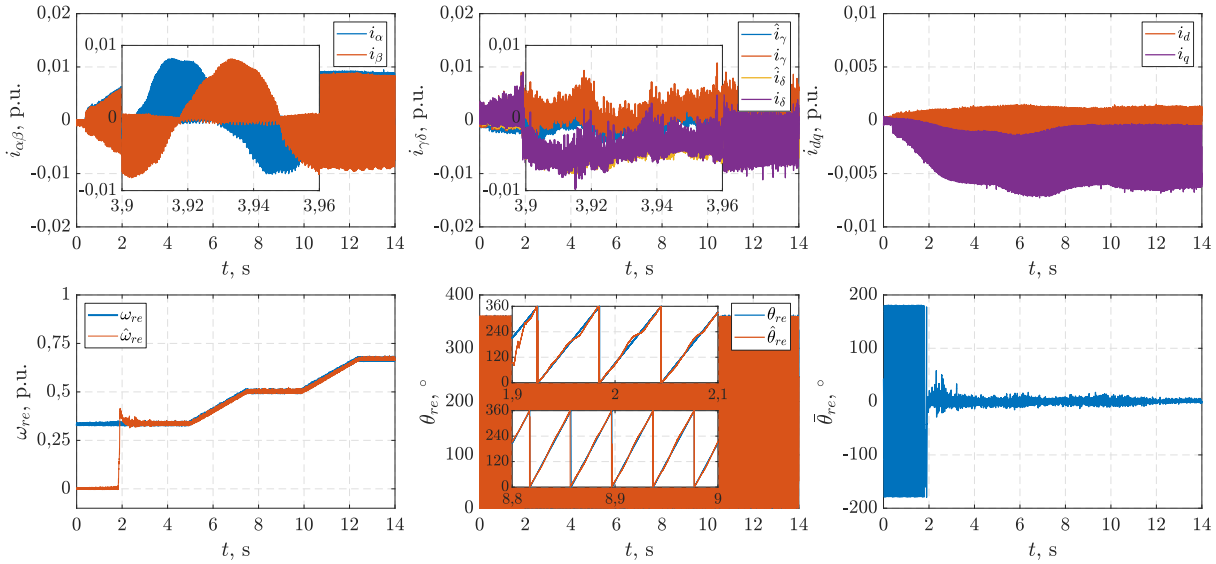

(a) Estimacija kuta i brzine vrtnje pri isprekidanom radu pretvarača i promjeni brzine vrtnje

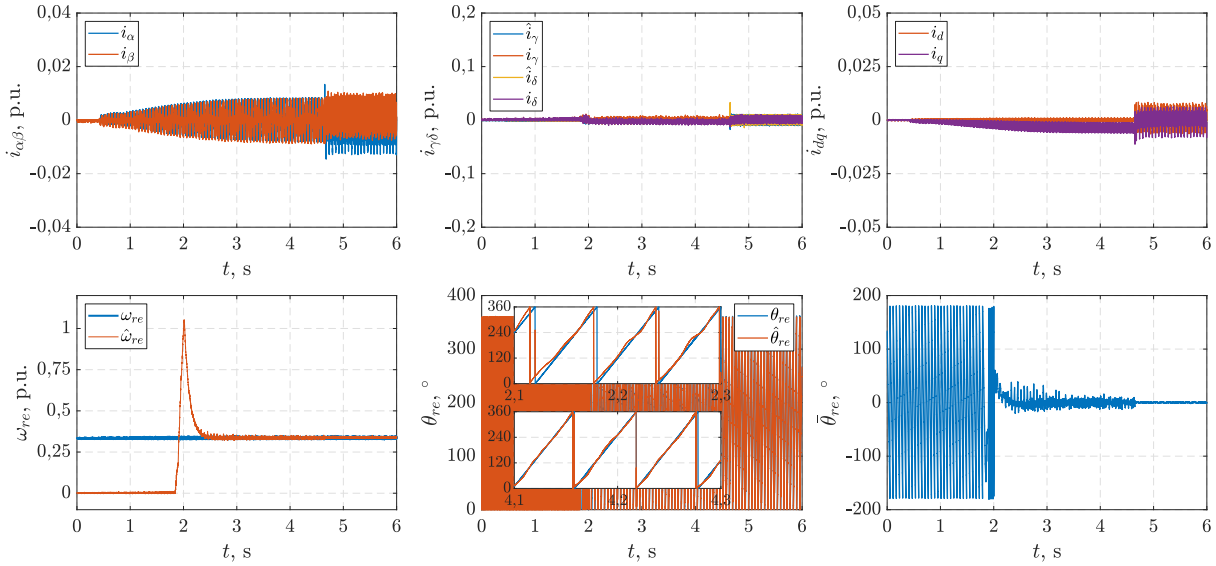

(b) Uklop pri brzini vrtnje $\omega_r = 0,33$ p.u.

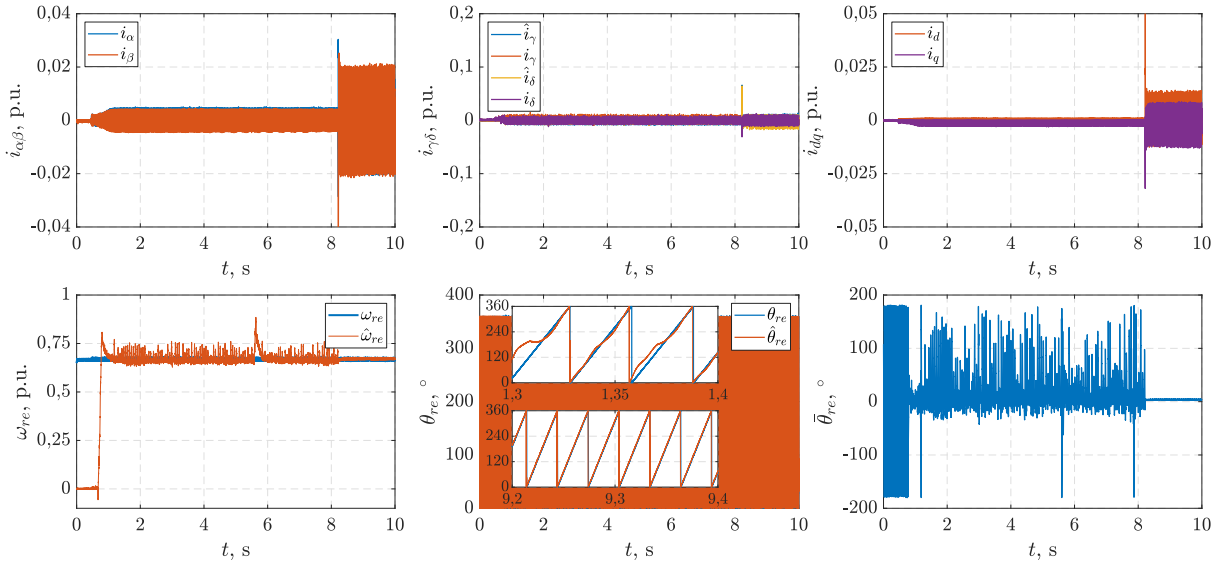

(c) Uklop pri brzini vrtnje $\omega_r = 0,67$ p.u.

Slika 6.10: Leteći start s estimacijskom strukturom temeljenoj na SMO-u u $\gamma\delta$ sustavu i STA algoritmu

7. Smanjenje estimacijske greške opservera u kliznom načinu rada

7.1.Pregled literature

Najčešće korištene metode estimacije kuta i brzine vrtnje rotora jesu metode u zatvorenoj petlji u obliku različitih vrsta observera. Ove metode estimacije kuta i brzine vrtnje PMSG-a pripadaju skupini metoda koje se temelje na modelu PMSG-a što znači da je pri modeliranju takvih estimacijskih metoda potrebno poznavati određene parametre PMSG-a poput statorskog otpora i induktiviteta u uzdužnoj i poprečnoj osi. Međutim, parametri PMSG-a poput prethodno navedenih, obično nisu dostupni među osnovnim podacima stroja koji se mogu pronaći na njegovoj natpisnoj pločici. Iz tog razloga te je parametre potrebno odrediti različitim mjerenjima, primjenom neke metode estimacije ili analitičkim i numeričkim proračunima. Nadalje, osim problema početnog poznavanja parametara PMSG-a, dodatni problem uzrokovan je činjenicom da se parametri PMSG-a mijenjaju tijekom rada u ovisnosti o radnoj točki PMSG-a pa se tako statorski otpor i magnetski tok rotora mijenjaju s temperaturom namota, odnosno rotora PMSG-a. S druge strane, promjena vrijednosti induktiviteta PMSG-a događa se uslijed magnetskog zasićenja željezne jezgre koje je uzrokovano porastom struje u radnim točkama određenima velikim elektromagnetskim momentom PMSG-a.

Na slici 7.1 prikazana je raspodjela metoda za identifikaciju parametara PMSG-a. Prva podjela određena je vremenom identifikacije parametara, odnosno vrši li se određivanje parametara izvan pogona (engl. *Offline*) ili za vrijeme rada PMSG-a (engl. *Online*). *Offline* metode najčešće se primjenjuju kada nisu dostupni nikakvi podaci o parametrima PMSG-a, dok se *online* metode većinom koriste za adaptaciju parametara pri radu PMSG-a [101].

Prva skupina *offline* metoda za određivanje parametara PMSG-a temelji se na njegovoj geometriji i dijeli se na analitičke metode [102–104] te metode temeljene na metodi konačnih elemenata (MKE) [105, 106]. Danas su, zbog dostupnosti računala velikih procesorskih snaga, MKE metode zastupljenije od onih analitičkih. MKE algoritmima može se odrediti cjelokupna magnetska slika PMSG-a uz parametre kao što su magnetski tokovi [105] i induktiviteti [105, 106] u d- i q-osima u ovisnosti o strujama. Tako određeni parametri mogu se zatim pohraniti u

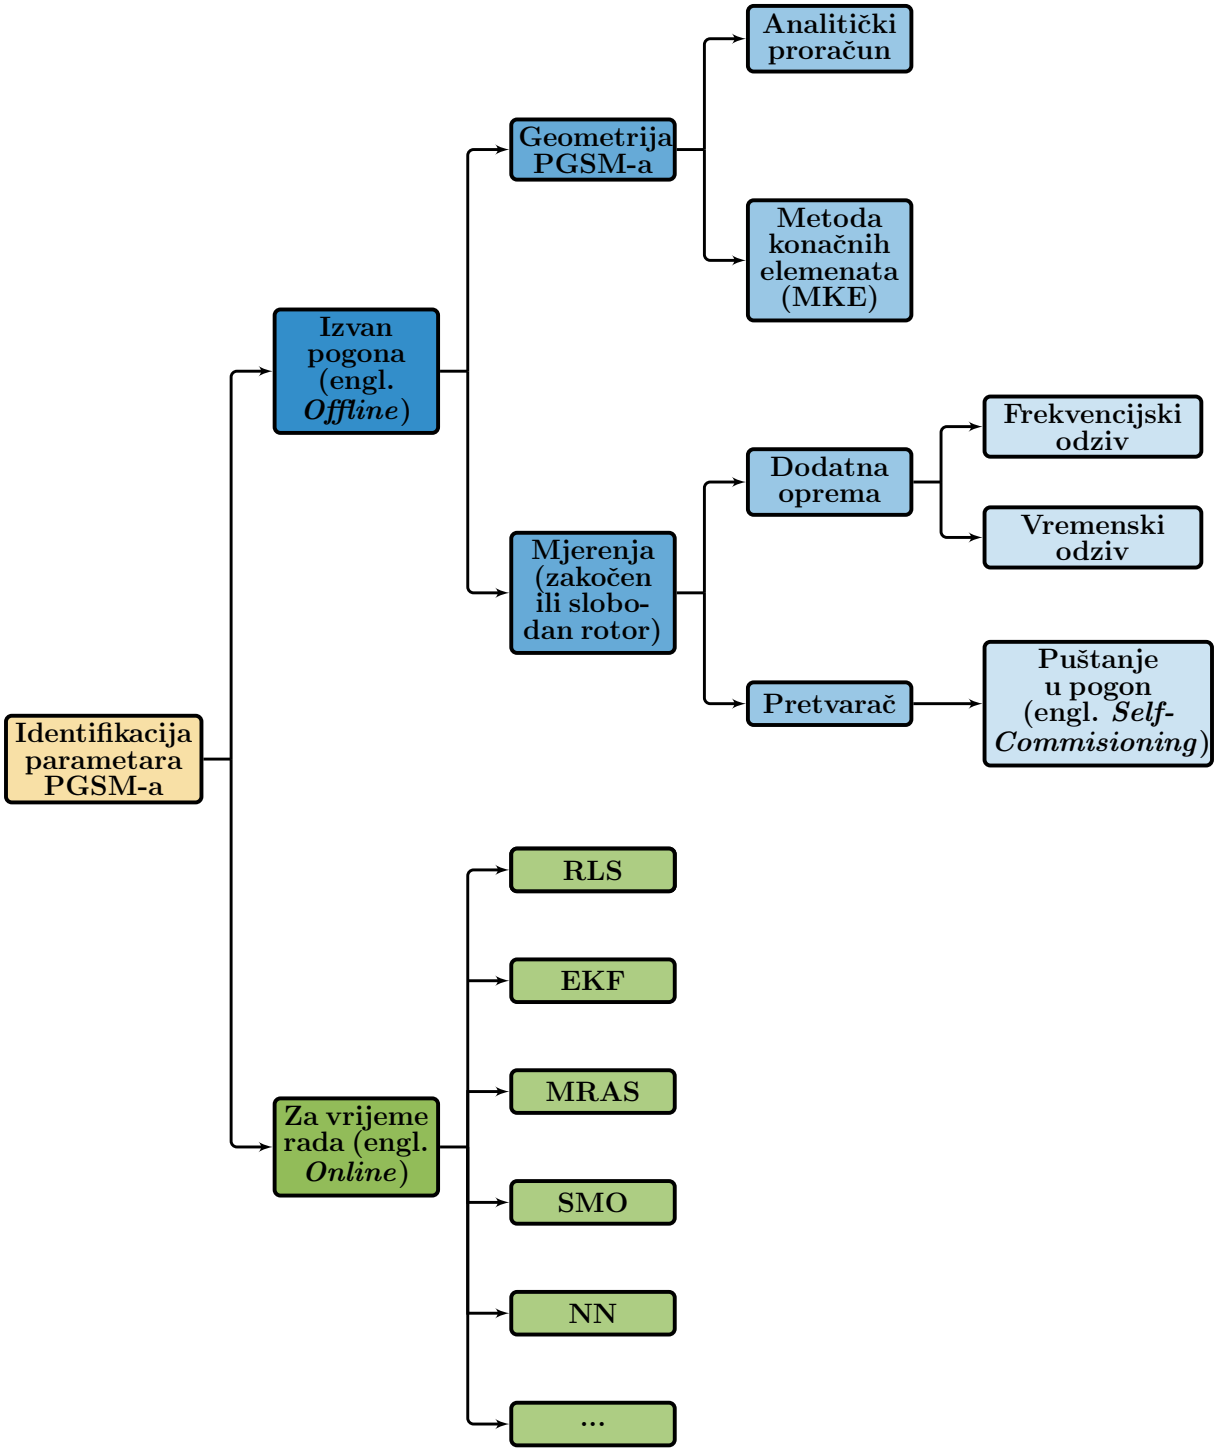

Slika 7.1: Podjela metoda za identifikaciju parametara PMSG-a

upravljački sustav koristeći pregledne tablice (engl. *Look-Up Table*, LUT). Međutim, za primjenu MKE metoda potrebno je ispuniti dva preduvjeta, a to su poznavanje geometrije PMSG-a te posjedovanje simulacijskog programa za proračun MKE što predstavlja značajan nedostatak s obzirom da detaljni opis geometrije PMSG-a obično nije dostupan krajnjem korisniku, dok su kvalitetni simulacijski programi za proračun MKE prilično skupi.

Druga skupina *offline* metoda određivanja parametara PMSG-a temelji se na različitim vrstama mjerenja pa se metode unutar nje zapravo i dijele prema tome koriste li dodatnu mjernu opremu ili samo mjerenja dostupna preko pretvarača. Nadalje, neke metode mjerenja zahtijevaju blokiranje rotora, dok je kod drugih rotor slobodan zbog toga što je mirovanje osigurano na neki drugi način ili je, pak, metoda takva da zahtjeva mjerenje pri vrtnji rotora PMSG-a. Metode koje koriste dodatnu mjernu opremu mogu se podijeliti na one koje parametre PMSG-a određuju frekvencijskom analizom mjerenih rezultata te na one koje mjerenja obrađuju u vremenskoj domeni.

Određivanje parametara PMSG-a frekvencijskom analizom (Fourierova analiza) najčešće se odvija pri mirovanju rotora (engl. *Standstill Frequency Response*, SFR), a služi za identifikaciju parametra nadomjesne sheme PMSG-a u rotirajućem *dq* koordinatnom sustavu. Uobičajeno, SFR metode temelje se na izvođenju analize odziva PMSG-a na primijenjene ispitne signale željenih frekvencija koji se generiraju primjenom pojačala velike snage [101]. Procedura za izvođenje SFR metoda je opisana IEEE normom [107]. Nadalje, osim korištenjem pojačala, SFR metode mogu se izvoditi pomoću energetskih pretvarača koji mogu osigurati generiranje potrebnih ispitnih signala [108]. Korištenje pretvarača smanjuje potrebu za dodatnom opremom, ali donosi probleme poput utjecaja nelinearnosti pretvarača na točnost mjerenja [101]. Neovisno o izvoru, testni signali mogu se podijeliti prema vrsti na periodične, tranzijentne i aperiodičke te na determinističke i stohastičke, a uobičajene frekvencije kreću se do 1 kHz [101].

U skupini određivanja parametara PMSG-a u vremenskoj domeni mogu se naći metode poput mjerenja odziva pri izmjeničnoj (engl. *Alternating Current*, AC) uzbudi, mjerenja odziva pri istosmjernoj (engl. *Direct Current*, DC) uzbudi i terećenja PMSG-a [101, 106, 109]. Primjena metode temeljena na odzivu pri izmjeničnoj uzbudi omogućuje određivanje induktiviteta u uzdužnoj i poprečnoj grani. Mjerenje se vrši tako da se jedna fazi napoji izmjeničnim naponom te se mjeri linijska struja te napon induciran u jednoj od preostalih faza PMSG-a pri različitim položajima rotora. Na ovaj način mogu se odrediti fazni samoinduktivitet i međuinduktivitet preko kojih se, zatim, određuju uzdužni i poprečni induktiviteti [110]. Isti postupak može se izvršiti i korištenjem pretvarača što smanjuje potrebu za dodatnom mjernom opremom kao što je pokazano u [110] gdje su uspoređeni rezultati dobiveni klasičnom metodom, metodom s pretvaračem te rezultati dobiveni MKE proračunom. Poboljšanje metoda temeljenih na izmjeničnoj uzbudi može se ostvariti ako se u obzir uzme zasićenje PMSG-a kao primjerice u [111]. Osim izmjenične uzbude, za određivanje induktiviteta PMSG-a može se primijeniti i istosmjerna uzbuda. U

takvim metodama, os jedne od faza PMSG-a nužno je poravnati sa d-osi, a zatim fazu napojiti istomjernim naponom nakon čega se iz tranzijenta mjerene struje računa magnetski tok u d-osi te posljedično induktivitet d-osi. Isti postupak ponavlja se i za mjerenje u q-osi [106]. Nadalje, metode terećenja temelje se na određivanju parametara PMSG-a pomoću mjerenih struja i iznosa napona pri različitim opterećenjima, a izvode se pri vrtnji rotora. Općenito se mjerenja izvode pri srednjim i velikim brzinama kako bi se smanjio utjecaj pada napona na statorskom otporu [101] te utjecaj mrtvog vremena pretvarača [112]. Opterećenje ispitnog PMSG-a vrši se preko opteretnog stroja koji je s ispitnim strojem spojen preko iste osovine [112, 113].

U prethodno opisanim metodama već su spomenute metode identifikacije parametara PMSG-a koje koriste isključivo pretvarač kao ispitnu i mjernu opremu. Ukoliko takve metode ispunjavaju još i sljedeće uvjete [109]:

1.izvršavaju se pri mirovanju rotora,
2.ne zahtijevaju blokiranje rotora,
3.koriste algoritme izvedive na klasičnim upravljačkim sustavima,
4.ne zahtijevaju terećenje PMSG-a,
5.ne zahtijevaju prethodno poznavanje parametara PMSG-a, osim onih s nazivne pločice i
6.omogućavaju brz i ponovljivi postupak,

nazivaju se metodama za određivanja parametara PMSG-a pri puštanju u pogon (engl. *Self-Commissioning*). Većina od takvih metoda koriste neku vrstu injektiranje VF naponskih signala, a razlikuju se u načinu obrade mjernih odziva pa se tako u [114] za estimaciju induktiviteta koristi diskretna Fourierova transformacija, dok se u [115] induktiviteti računaju integriranjem naponske jednadžbe nakon primjene VF naponskog signala generiranog pomoću histereznog regulatora. S druge strane, obje metode estimiraju statorski otpor primjenom metode linearne regresije. Nadalje, u [116–118] predložene su metode za puštanje u pogon sinkronih reluktantnih strojeva te sinkronih reluktantnih strojeva potpomognutih magnetima. Ove metode temelje se na primjeni VF pravokutnih signala u d- i q-osi stroja, nakon čega se iz mjernih odziva struje i magnetskog toka određenog integriranjem naponske jednadžbe određuju ovisnosti struja i tokova koristeći metodu linearne regresije. Ova metoda može se primijeniti i kod PMSG-a [119], međutim, kako bi se zadržala točnost estimacije, mora se osigurati mirovanje rotora pri injektiranju signala u q-os.

Problem promjenjivosti parametara PMSG-a tijekom rada može se riješiti spremanjem parametara dobivenih nekom od *offline* metoda u LUT tablice ili primjenom *online* metoda identifikacije parametara PMSG-a. Prva skupina *online* metoda temelji se na rekurzivnom algoritmu najmanjih kvadrata (engl. *Recursive Least Square*, RLS) čija je zadaća rekurzivno minimizirati grešku između mjerene i estimirane veličine na temelju metode najmanjih kvadrata. Pomoću RLS algoritma moguće je estimirati:

- statorski otpor [120–122],

- induktivitete u d i q-osi [120–123],
- rotorski tok [120, 121],
- više harmonike induciranog napona [124, 125]...

Nadalje, iako su EKF i MRAS algoritmi navedeni kao metode estimacije kuta i brzine vrtnje rotora PMSG-a u poglavlju 5, isti algoritmi mogu se primijeniti za estimaciju parametra PMSG-a pa se tako pomoću EKF algoritma mogu estimirati magnetski tokovi PMSG-a [126], statorski otpor [127] te induktiviteti u d- i q-osi [128]. Također, EKF algoritam može se iskoristiti za estimaciju mehaničkih parametara PMSG-a [129]. Nadalje, MRAS algoritam najčešće se koristi prilikom estimacije statorskog otpora [69, 130] i magnetskog toka rotora [130]. Primjena SMO algoritma znatno je zastupljenija u metodama estimacije kuta i brzine vrtnje rotora, međutim, ponekad se koristi i za estimaciju parametara PMSG-a kao što je statorski otpor [76, 131], devijacija induktiviteta u d- i q-osi [131] te mehaničkih parametara PMSG-a [132, 133]. Osim već poznatih algoritama, danas se sve češće koriste i algoritmi estimacije parametara PMSG-a temeljeni na algoritmima umjetne inteligencije kao što su neuronske mreže (engl. *Neural Network*, NN) [134], genetski algoritmi [135] ili optimizacija rojem čestica (engl. *Particle Swarm Optimization*, PSO) [136].

Detaljan pregled metoda određivanja parametara PMSG-a može se naći u [101, 137].

7.1.1.Treći dio znanstvenog doprinosa

U doktorskoj disertaciji predstavljena je nadogradnja metode bezsenzorskog upravljanja PMSG-a temeljnog na SMO-u koja se očituje u smanjenju greške estimacije kuta rotora. Pokazano je da greška estimacije kuta rotora ovisi o razlici poprečnog induktiviteta koji se koristi za modeliranje SMO-a te stvarnog poprečnog induktiviteta u PMSG-u. Pri modeliranju SMO-a obično se koristi poprečni induktivitet konstantnog iznosa, dok se poprečni induktivitet PMSG-a mijenja ovisno o radnoj točki uslijed pojave magnetskog zasićenja. Prema tome, prije puštanja u rad bezsenzorskog upravljačkog algoritma, primijenjena je metoda puštanja u pogon predstavljena u [116]. Iako je ova metoda predstavljena za sinkroni reluktantni stroj, pokazala se primjenjiva i na PMSG. Metoda koristi isključivo funkcije dostupne pretvaraču, bez korištenje dodatne mjerne opreme, te primjenom histereznog regulatora struja na temelju primijenjenog napona, mjerene struje i izračunatog magnetskog toka uz pomoć metode najmanjih kvadrata određuje koeficijente aproksimativne funkcije poprečnog induktiviteta. Na temelju izračunatih koeficijenata, referentnog napona i mjerene struje u estimiranom $\gamma\delta$ koordinatnom sustavu, poprečni induktivitet SMO-a adaptira se pri različitim radnim točkama u trajnom radu te se na taj način reducira greška estimiranog kuta. Osim toga, za inicijalizaciju SMO-a u trajnom radu potrebno je poznavati neki referentni iznos poprečnog induktiviteta i statorski otpor, dok je za određivanje pojačanja PI regulatora struje unutar RFOC algoritma potrebno poznavati još i referentnu vrijednosti uzdužnog induktiviteta. Ovi parametri obično nisu dostupni na natpisnoj

pločici PMSG-a pa se određuju prilikom puštanja u pogon. Iznos uzdužnog induktiviteta određuje se na isti način kao i poprečni induktiviteta, dok se statorski otpor određuje prilikom pozicioniranja rotora PMSG-a u d-os.

Na predstavljeni način omogućeno je potpuno puštanje u pogon metode bezsenzorskog upravljanja temeljena na SMO-u s funkcijom letećeg starta predstavljena u poglavljima 5 i 6, budući da su određeni parametri PMSG-a potrebi za inicijalizaciju upravljačke strukture, dok je s druge strane povećana robusnost estimacijske strukture na promjenjivost poprečnog induktiviteta.

7.2.Utjecaj magnetskog zasićenja na induktivitete PMSG-a

Magnetsko zasićenje posljedica je željeznih konstrukcijskih dijelova statora i rotora PMSG-a. Na slici 7.2 prikazana je krivulja magnetiziranja željeza iz koje se uočava linearna ovisnost magnetskog toka o struji u području malih struja. S druge strane, pri većim strujama taj odnos postaje nelinearan te se naziva magnetsko zasićenje, a mjesto razgraničenja linearnog i nelinearnog dijela krivulje magnetiziranja naziva se koljeno. Prelaskom koljena krivulje magnetiziranja, gustoća magnetskog toka, odnosno magnetske indukcije, raste što dovodi do povećanja magnetskog otpora pa silnice magnetskog polja sve teže prolaze kroz zasićene dijelove željezne konstrukcije. Iz tog razloga, daljnje povećanje struje kroz namote PMSG-a dovodi do tek neznatnog povećanja magnetskog toka. Kao posljedica opisane pojave dolazi do smanjenja induktiviteta u osima PMSG-a u kojima je došlo do zasićenja. Također, zbog velikog magnetskog otpora u zasićenoj osi magnetski tok se počinje zatvarati i kroz os u kojoj nije došlo do zasićenja, odnosno pojavljuje se međuinduktivna veza između osi PMSG-a.

Smanjenje induktiviteta lako se može uočiti analizom krivulje magnetiziranja uz definiciju induktiviteta kao nagiba krivulje magnetiziranja. Uz takvu definiciju očito je da će induktivitet u linearnom dijelu krivulje magnetiziranja biti konstantnog iznosa budući da omjer toka i struje u svakoj točki linearnog dijela odgovara nagibu krivulje:

$$L = \frac{d\psi(i)}{di} = \frac{\psi(i)}{i} = \text{konst.} \tag{7.1}$$

Međutim, prelaskom koljena krivulje, odnosno ulaskom u nelinearni dio uzrokovan zasićenjem, induktivitet se počinje smanjivati s porastom struje budući da se i nagib tangente na nelinearni dio krivulje smanjuje porastom struje kao što je vidljivo na slici 7.2.

Na slici 7.3 prikazan je primjer ovisnosti $L_d = f(i_d, i_q)$ i $L_q = f(i_d, i_q)$ dobivenih MKE metodom za dva PMSG-a. Slika 7.3a predstavlja induktivitete generatora iz laboratorijskog postava označenog s PMSG1, dok su induktiviteti sa slike 7.3b preuzeti iz [138] za generator označen s PMSG2. Ovisnosti su prikazane za negativne struje s obzirom da su strojevi namijenjeni za generatorski režim rada. Analizom prikazanih funkcija, osim smanjenja induktiviteta pojedine osi s porastom struje u pripadajućoj osi, može se primijetiti i utjecaj struje u d-osi na promjenu

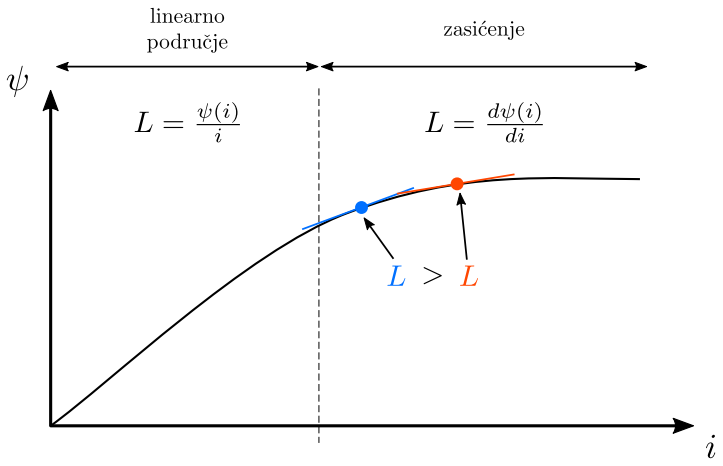

Slika 7.2: Krivulja magnetiziranja željeza

induktiviteta u q-osi i obrnuto. Također, uočljivo je da ovisnosti na slici 7.3a i ovisnosti na slici 7.3b razlikuju, iz čega se može zaključiti da karakteristike zasićenja bitno ovise o konstrukciji PMSG-a.

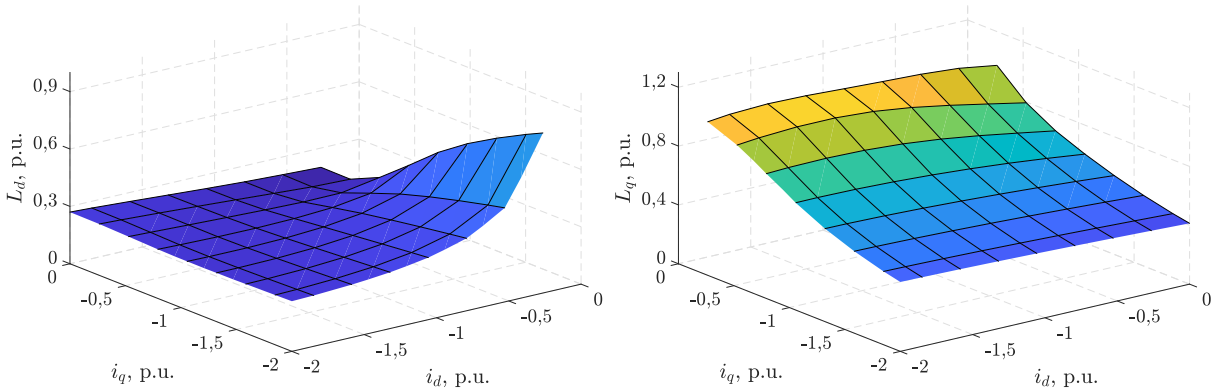

(a) PMSG1

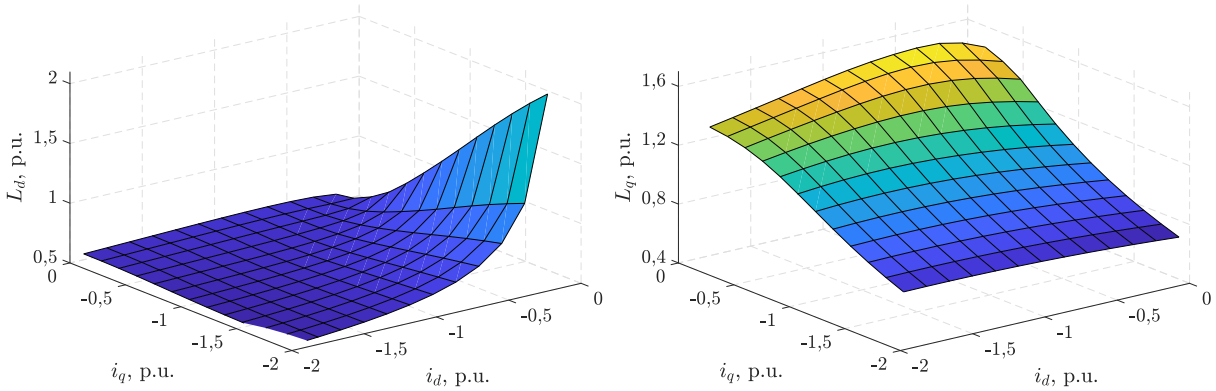

(b) PMSG2

Slika 7.3: Ovisnosti induktiviteta o strujama u d i q-osi

7.3. Greška estimiranog kuta rotora uzrokovana promjenom parametara PMSG-a

Jedno od glavnih svojstava SMO-a jest robusnost na poremećaje i promjenu parametara sustava što znači da SMO, uz prikladno odabrana pojačanja upravljačkog zakona, osigurava zadržavanje trajektorija sustava na kliznoj plohi i uslijed promjena parametara osmatrajućeg sustava. Očekivane promjene u osmatrajućem sustavu kao što je PMSG jesu promjene statorskog otpora i induktiviteta. S druge strane, SMO se općenito modelira koristeći fiksne parametre PMSG-a ne uzimajući u obzir njihovu promjenjivost u ovisnosti o radnoj točki. Zbog već navedene robusnosti SMO-a ova razlika u parametrima PMSG-a i SMO-a neće onemogućiti SMO da zadrži trajektorije greške estimirane struje na kvazi-kliznoj plohi $\bar{\boldsymbol{i}}_x = 0$. Međutim, kako bi se osigurala točna estimacija struje uslijed promjene parametara PMSG-a, doći će do faznog pomaka izlaza SMO-a, odnosno vektora upravljačkog zakona. Budući da srednja vrijednost vektora upravljačkog zakona predstavlja estimirani inducirani napon iz kojeg se estimira kut rotora, u estimiranom kutu rotora pojavit će se greška.

S obzirom da je estimacijska struktura predložena u poglavlju 5 temeljena na SMO-u modeliranom u $\gamma\delta$ koordinatnom sustavu, u svrhu analize utjecaja promjene parametara PMSG-a na točnost estimacije kuta rotora iskorišten je model PMSG-a u dq koordinatnom sustavu temeljen na aktivnom magnetskom toku iz (5.3). U modelu (5.3) pretpostavljeno je da se iznosi statorskog otpora i poprečnog induktiviteta ne mijenjaju tijekom rada PMSG-a. Međutim, kao što je objašnjeno u prethodnom potpoglavlju, induktivitet PMSG-a nije konstantnog iznosa u svim radnim točkama, već se mijenja uslijed zasićenja. Također, statorski otpor mijenja se promjenom temperature namota PMSG-a. Uzevši u obzirom promjenjivost navedenih parametara, model (5.3) može se zapisati na sljedeći način:

$$\boldsymbol{u}_{dq} = \left[(R_s + \Delta R_s)\mathbf{I} + \mathbf{J}\omega_{re}(L_q + \Delta L_q)\right] \boldsymbol{i}_{dq} + (L_q + \Delta L_q)\frac{d\boldsymbol{i}_{dq}}{dt} + \boldsymbol{e}_{dq}^{AF}, \tag{7.2}$$

gdje je ΔL_q - promjena poprečnog induktiviteta uslijed zasićenja, a ΔR_s - promjena statorskog otpora uslijed zagrijavanja namota.

Nadalje, kada model SMO-a u $\gamma\delta$ koordinatnom sustavu dostigne kliznu plohu $\bar{\boldsymbol{i}}_{\gamma\delta} = 0$ vrijedit će (5.50) pa se model SMO-a iz (5.22), uz pretpostavku $\hat{\omega}_{re} = \omega_{re}$, može zapisati kao:

$$\boldsymbol{u}_{\gamma\delta} = \left(R_s\mathbf{I} - \mathbf{J}\hat{\omega}_{re}L_q\right) \boldsymbol{i}_{\gamma\delta} + L_q\frac{d\boldsymbol{i}_{\gamma\delta}}{dt} + \boldsymbol{e}_{\gamma\delta}^{AF}. \tag{7.3}$$

Razlika modela SMO-a te stvarnog modela PMSG-a dobiva se oduzimanjem izraza (7.3) od

(7.2) i glasi:

$$\bar{\boldsymbol{u}} = (R_s\mathbf{I} + \mathbf{J}\omega_{re}L_q)\bar{\boldsymbol{i}} + (\Delta R_s\mathbf{I} + \mathbf{J}\omega_{re}\Delta L_q)\boldsymbol{i}_{dq} + L_q\frac{d\bar{\boldsymbol{i}}}{dt} + \Delta L_q\frac{d\bar{\boldsymbol{i}}_{dq}}{dt} + \boldsymbol{e}_{dq}^{AF} - \boldsymbol{e}_{\gamma\delta}^{AF}, \tag{7.4}$$

gdje je $\bar{\boldsymbol{u}} = \boldsymbol{u}_{dq} - \boldsymbol{u}_{\gamma\delta}$ - razlika vektora napona u dq i $\gamma\delta$ koordinatnom sustavu i $\bar{\boldsymbol{i}} = \boldsymbol{i}_{dq} - \boldsymbol{i}_{\gamma\delta}$ - razlika vektora struja u dq i $\gamma\delta$ koordinatnom sustavu.

U ustaljenom stanju vrijedit će $d\bar{\boldsymbol{i}}/dt = 0$, pa se raspisom uzdužne osi izraza (7.4) dobiva greška kuta rotora između dq i $\gamma\delta$ koordinatnog sustava:

$$\bar{\theta}_{re} = \arcsin\left(\frac{-(u_d - u_\gamma) + R_s(i_d - i_\gamma) + \Delta R_s i_d - \omega_{re}[\Delta L_q i_q + L_q(i_q - i_\delta)]}{\omega_{re}\psi_r^{AF}}\right). \tag{7.5}$$

U [24] analiziran je utjecaj greške napona, statorskog otpora i poprečnog induktiviteta na grešku estimiranog kuta rotora za opservere temeljene na različitim modelima PMSG-a te je pokazana dominantnost utjecaja greške poprečnog induktiviteta na točnost estimacije kuta rotora. Prema tome, prethodni izraz može se pojednostaviti kao:

$$\bar{\theta}_{re} \approx \arcsin\left(\frac{\Delta L_q i_q + L_q(i_q - i_\delta)}{\psi_r^{AF}}\right). \tag{7.6}$$

Prema izrazu (7.6) očito je da greška estimiranog kuta rotora uzrokovana neslaganjem parametara PMSG-a i SMO-a proporcionalna ΔL_q, odnosno razlici stvarne vrijednosti poprečnog induktiviteta PMSG-a i fiksnog poprečnog induktiviteta koji se koristi u modelu SMO-a, te razlici struja u q i δ-osi.

Nadalje, u [139] napravljena je slična analiza za SMO temeljen na modelu aktivnog toka u $\alpha\beta$ koordinatnom sustavu. U toj analizi pretpostavljeno je da će u svakoj radnoj točki vrijediti $i_d = 0$ te je dobiven izraz za grešku estimiranog kuta koji je, također, proporcionalan razlici poprečnog induktiviteta ΔL_q te razlici amplitude estimirane i stvarne struje.

7.4.Određivanje parametara PMSG-a

Rješenje problema pojave greške estimiranog kuta uzrokovane neslaganjem induktiviteta PMSG-a i SMO-a predstavlja adaptacija poprečnog induktiviteta SMO-a u različitim radnim točkama. Proučavanjem literature predstavljene na početku poglavlja, kao prikladna metoda odabrana je ona predstavljena u [116] te ona ne predstavlja izvorni znanstveni doprinos ove disertacije. Ova metoda obavlja se pri puštanju PMSG-a u pogon, izvodi se pri mirovanju rotora te ne zahtijeva dodatnu mjernu opremu, već se za mjerenja i obradu koristi isključivo pretvarač, odnosno njegov mjerni i upravljački dio.

Metoda za određivanje parametara aproksimativne funkcije induktiviteta prikazana je na slici 7.4 pomoću dijagrama toka. S obzirom na to da je upravljačka struktura PMSG-a bezsenzorska,

prije primjene histereznih regulatora potrebno je pozicionirati rotor u d-os što se čini primjenom napona u_d^*. Kada je pozicioniranje izvršeno, postavlja se upravljački signal POS DONE. Nadalje, ovisno o signalu SELF-COMM. TYPE aktivira se histerezni regulator struje u d-, odnosno q-osi koji osiguravaju primjenu pozitivnog napona U ukoliko struja padne ispod minimalne vrijednosti $-I_{max}$, odnosno negativni napon $-U$ kada struja prekorači maksimalnu vrijednost I_{max}. Magnetski tok računa se integracijom naponske jednadžbe na temelju primijenjenog napona i mjerenog uzorka struje. Nakon što broj primijenjenih naponskih impulsa postane jednak broju zadanom s MAX. CYCLE prekida se histerezno upravljanje strujom te se na temelju mjerene struje i izračunatog magnetskog toka metodom najmanjih kvadrata proračunavaju koeficijenti aproksimativne funkcije ovisnosti struje o magnetskom toku. U d-osi računa se parametar a_{d0} koji modelira nezasićenu vrijednost uzdužnog induktiviteta, dok se u q-osi određuje parametar nezasićenog poprečnog induktiviteta a_{q0} te parametar a_{qq} koji modelira zasićenje. Nezasićena vrijednost uzdužnog induktiviteta zajedno sa statorskim otporom koristi se za proračun pojačanja PI regulatora struje u d-osi, a nezasićeni poprečni induktivitet i statorski otpor za proračun pojačanja PI regulatora u q-osi te za inicijalizaciju SMO-a. Nadalje, koeficijenti a_{q0} i a_{qq} primjenjuju se za adaptaciju poprečnog induktiviteta SMO-a u trajnom radu kako bi se smanjila greška estimiranog kuta rotora (7.6).

7.4.1.Određivanje statorskog otpora

Budući da je prije primjene histereznih regulatora nužno pozicionirati rotor primjenom napona u_d^*, statorski otpor može se odrediti prilikom pozicioniranja kao (slika 7.4):

$$\hat{R}_s = \frac{u_d^*}{i_d}. \tag{7.7}$$

7.4.2. Određivanje nezasićenog poprečnog induktiviteta i njegove aproksimativne funkcije

U [116] predstavljena je aproksimativna funkcija ovisnosti struje o magnetskog toku:

$$i_q(\psi_q) = \left(a_{q0} + a_{qq}|\psi_q|^T\right)\psi_q, \tag{7.8}$$

gdje a_{q0} - recipročna vrijednost nezasićenog poprečnog induktiviteta, T - pozitivni eksponent, a a_{qq} - koeficijent zasićenja.

Koeficijenti a_{q0} i a_{qq} mogu se odrediti metodom najmanjih kvadrata (engl. *Linear Least Squares*, LLS) na temelju parova struja i magnetskog toka $(i_q(\psi_q), \psi_q)$ dobivenih mjerenjem, odnosno integracijom naponske jednadžbe tijekom primjene naponskih impulsa u q-osi. Integracija magnetskog toka izvodi se primjenom unaprijedne Eulerove metode:

$$\psi_{q[k+1]} = \psi_{q[k]} + T_s\left(u_{q[k]} - \hat{R}_s i_{q[k]}\right). \tag{7.9}$$

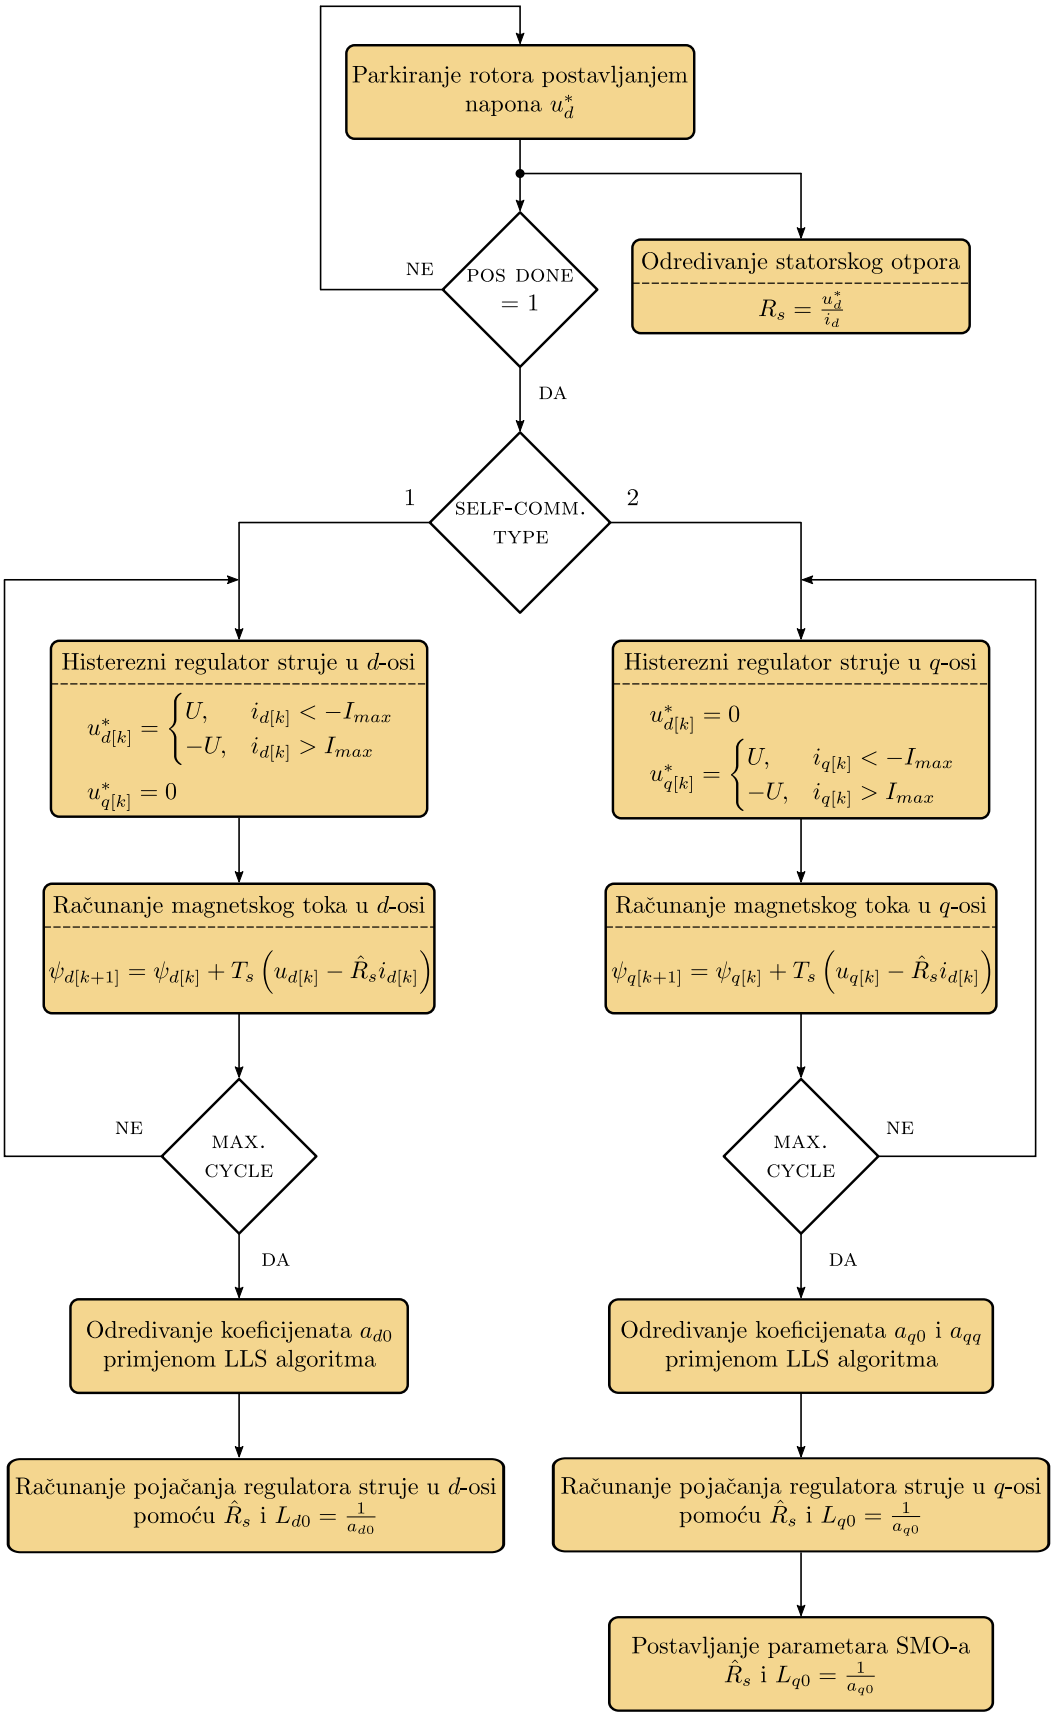

Slika 7.4: Dijagram toka za određivanje statorskog otpora i koeficijenata a_{d0}, a_{q0} i a_{qq}

Uzimanjem pozitivnih uzoraka struje i magnetskog toka, aproksimativna funkcija (7.8) može se zapisati kao:

$$i_{q[k]}(\psi_{q[k]}) = a_{q0}\psi_{q[k]} + a_{qq}\psi_{q[k]}^{T+1}. \tag{7.10}$$

Jednadžba (7.10) linearna je u odnosu na koeficijente a_{q0} i a_{qq} te se na nju može primijeniti LLS algoritam čiji opći oblik glasi:

$$\boldsymbol{y} = \boldsymbol{X}\boldsymbol{\alpha} + \boldsymbol{\epsilon}, \tag{7.11}$$

gdje je $\boldsymbol{y}$ - vektor mjerenih veličina, $\boldsymbol{X}$ - matrica regresije, $\boldsymbol{\alpha}$ - vektor koeficijenata i $\boldsymbol{\epsilon}$ - rezidualni vektor.

Primjenom (7.11) na aproksimativnu funkciju (7.10) vrijedi:

$$\boldsymbol{y} = \boldsymbol{i}_q = [i_{q[1]} \quad i_{q[2]} \quad \dots \quad i_{q[N]}]^{\mathrm{T}},$$

$$\boldsymbol{X} = \begin{bmatrix} \psi_{q[1]} & \psi_{q[1]}^{T+1} \\ \psi_{q[2]} & \psi_{q[2]}^{T+1} \\ \vdots & \vdots \\ \psi_{q[N]} & \psi_{q[N]}^{T+1} \end{bmatrix},$$

$$\boldsymbol{\alpha} = [a_{q0} \quad a_{qq}]^{\mathrm{T}},$$

$$\boldsymbol{\epsilon} = \begin{bmatrix} i_{q[1]} - \psi_{q[1]}a_{q0} - \psi_{q[1]}^{T+1}a_{qq} \\ i_{q[2]} - \psi_{q[2]}a_{q0} - \psi_{q[1]}^{T+1}a_{qq} \\ \vdots \\ i_{q[N]} - \psi_{q[N]}a_{q0} - \psi_{q[N]}^{T+1}a_{qq} \end{bmatrix},$$

gdje je N - broj uzoraka.

Prema tome, minimizirajući sumu kvadrata razlike $J(\boldsymbol{\alpha}) = \boldsymbol{\epsilon}^T\boldsymbol{\epsilon}$ vektor koeficijenata može se odrediti kao:

$$\boldsymbol{\alpha} = (\boldsymbol{X}^T\boldsymbol{X})^{-1}\boldsymbol{X}^T\boldsymbol{y}. \tag{7.12}$$

Iz vektora koeficijenata $\boldsymbol{\alpha}$, nezasićena vrijednost poprečnog induktiviteta može se odrediti kao:

$$L_{q0} = \frac{1}{a_{q0}}. \tag{7.13}$$

Nadalje, iz aproksimativne funkcije (7.8) lako se može odrediti i aproksimativna funkcija poprečnog induktiviteta kao:

$$\hat{L}_q = \frac{\psi_q}{i_q(\psi_q)} = \frac{1}{a_{q0} + a_{qq}|\psi_q|^T}. \tag{7.14}$$

Poznavanjem parametara a_{q0} i a_{qq} te integracijom magnetskog toka u pojedinoj radnoj točki

PMSG-a prema (7.9) poprečni induktivitet SMO-a može se adaptirati prema izrazu (7.14).

7.4.3.Određivanje uzdužnog induktiviteta

Iako uzdužni induktivitet, prema (7.6), ne utječe na grešku estimiranog kuta te nije potreban za inicijalizaciju SMO-a temeljenog na aktivnom magnetskom toku, nezasićenu vrijednost uzdužnog induktiviteta korisno je znati pri određivanju pojačanja PI regulatora struje u d-osi. Uzdužni induktivitet može se odrediti na identičan način kao i poprečni, odnosno primjenom histereznog regulatora struje u d-osi te linearnom regresijom nad aproksimativnom funkcijom (slika 7.4):

$$i_{d[k]}(\psi_{d[k]}) = a_{d0}\psi_{d[k]} + a_{dd}\psi_{d[k]}^{T+1}. \tag{7.15}$$

Nakon određivanja vektora koeficijenata $\boldsymbol{\alpha} = [a_{d0}\ a_{dd}]^{\mathrm{T}}$, nezasićen uzdužni induktivitet računa se kao:

$$L_{d0} = \frac{1}{a_{d0}}. \tag{7.16}$$

7.5.Metoda za smanjenje estimacijske greške SMO-a

Nakon inicijalizacije regulatora struje i SMO-a moguće je započeti leteći start i uklopiti PMSG na pretvarač, a zatim prijeći u trajni rad. Kao što je pokazano s izrazom (7.6), u trajnom radu, uslijed zasićenja PMSG-a, dolazi do pojave greške estimiranog kuta zbog razlike poprečnog induktiviteta u PMSG-u i SMO-u. Prema tome, adaptacijom induktiviteta SMO-a prema (7.14) moguće je smanjiti grešku estimacije kuta rotora prema shemi prikazanoj na slici 7.5. Predložena metoda smanjenja greške estimiranog kuta rotora predstavlja nadogradnju bezsenzorske upravljačke strukture sa slike 6.2. Na temelju referentnog napona $u^*_{\delta[k]}$ i mjerene struje $i_{\delta[k]}$ u svakoj radnoj točki računa se magnetski tok $\psi_{\delta[k]}$ koji se uvrštava u aproksimativnu funkciju poprečnog induktiviteta iz (7.14). Ovako aproksimirani induktivitet koristi se za adaptaciju poprečnog induktiviteta koji se koristi u modelu SMO-a te se tako smanjuje razlika induktiviteta PMSG-a i SMO-a te posljedično, prema (7.6), greška estimiranog kuta.

7.6.Simulacijski rezultati

Opisana problematika utjecaja promjene poprečnog induktiviteta uslijed zasićenja PMSG-a, određivanje aproksimativne funkcije induktiviteta te adaptacija poprečnog induktiviteta SMO-a u svrhu smanjenja greške estimiranog kuta analizirana je na simulacijskim modelima u programskim paketima MATLAB Simulink i PLECS. U simulacijskim modelima korišten je model generatora PMSG1 te PMSG2 čiji su nazivni i bazni podaci dani u tablici 7.1. Modeli generatora PMSG1

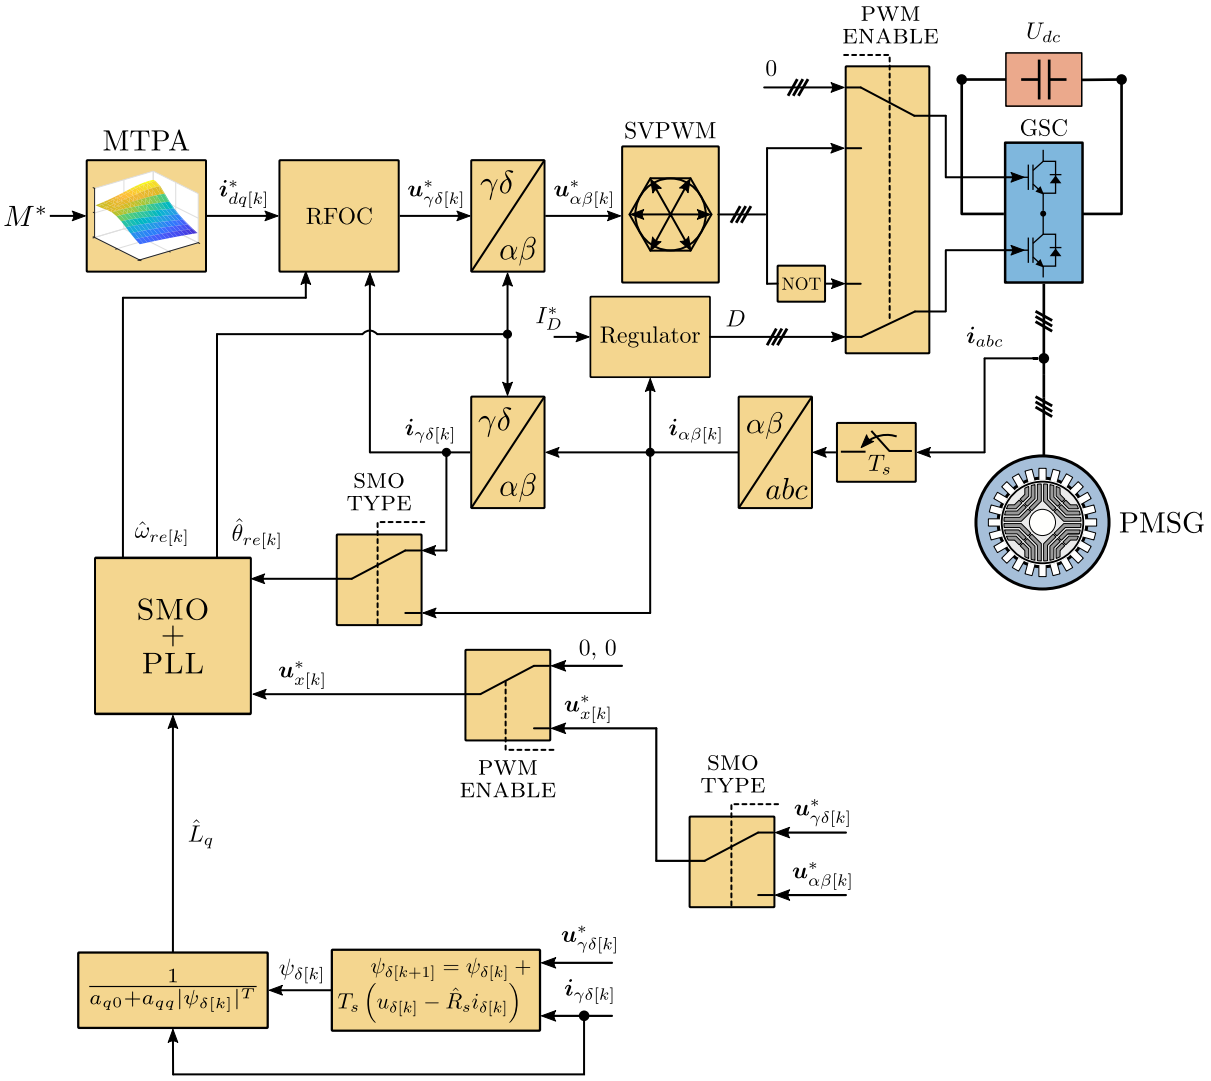

Slika 7.5: Bezsenzorska struktura upravljanja PMSG-a s implementiranom funkcijom za adaptaciju poprečnog induktiviteta u svrhu smanjenja greške estimiranog kuta rotora PMSG-a

Tablica 7.1: Nazivne i bazne vrijednosti generatora PMSG1 i PMSG2

Stroj	Nazivne vrijednosti		Bazne vrijednosti	
PMSG1	$E_n = 353$ V,	$I_n = 11,6$ A	$E_b = 289$ V,	$I_b = 16,4$ A
	$\psi_r = 0,8249$ Wb,	$f_n = 50$ Hz	$\psi_{rb} = 0,8249$ Wb,	$f_b = 50$ Hz
	$n_n = 1500$ o/min,	$M_n = 35$ Nm	$\omega_{re,b} = 314,16$ rad/s,	$M_b = 35$ Nm
PMSG2	$E_n = 311$ V,	$I_n = 223$ A	$E_b = 254$ V,	$I_b = 315,4$ A
	$\psi_r = 0,2527$ Wb,	$f_n = 160$ Hz	$\psi_{r,b} = 0,2527$ Wb,	$f_b = 160$ Hz
	$n_n = 2380$ o/min,	$M_n = 475,6$ Nm	$\omega_{re,b} = 1005,3$ rad/s,	$M_b = 475,6$ Nm
DC međukrug	$U_{dc} = 565$ V		$U_{dc,b} = 508,08$ V	

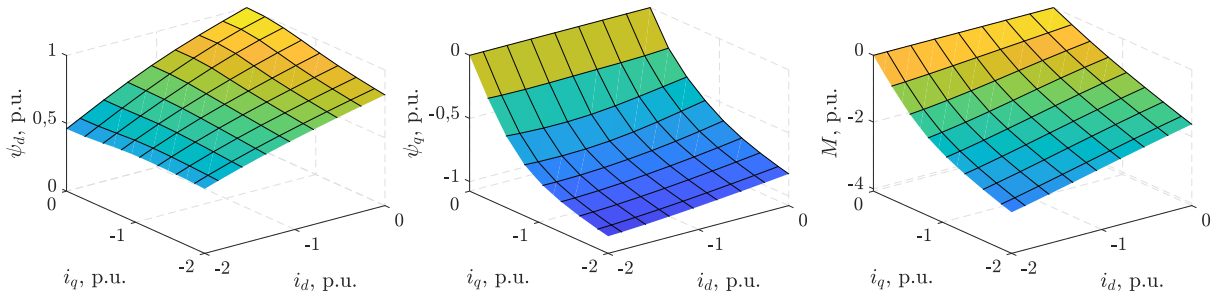

(a) PMSG1

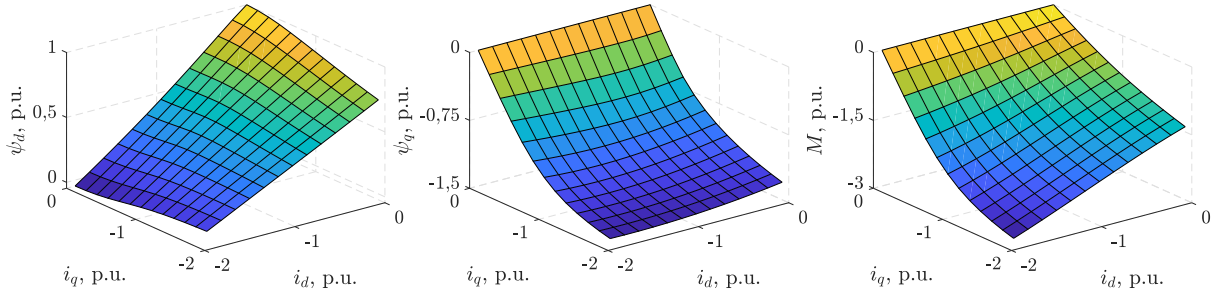

(b) PMSG2

Slika 7.6: Mape tokova i momenta proračunate MKE metodom korištene u simulacijama

i PMSG2 korišteni u simulacijama dobiveni su MKE proračunom te su pohranjeni u obliku preglednih tablica $i_d = f(\psi_d, \psi_q)$, $i_q = f(\psi_d, \psi_q)$ te $M = f(i_d, i_q)$ koje su prikazane na slici 7.6.

7.6.1. Određivanje parametara aproksimativne funkcije induktiviteta

Parametri aproksimativne funkcije induktiviteta određeni su iz simulacijskih odziva struje i magnetskog toka prikazanih na slici 7.7. Simulacije su provedene za PMSG1 i PMSG2 prema dijagramu toka sa slike 7.4. Širina histereznog regulatora postavljena je na iznos $I_{max} = 1,75$ p.u., dok je amplituda primijenjenog napona za PMSG1 postavljena je na $U = 0,77$ p.u., a za PMSG2 na $U = 0,79$ p.u. S obzirom na to da je sekvenca primijenjenog napona jednaka za oba generatora te da su odzivi struje i magnetskog toka također kvalitativno jednaki u oba slučaja, na slici 7.7 prikazani su odzivi samo jednog generatora i to PMSG1. Primjenom LLS algoritma (7.12) nad uzorcima mjerene struje i pripadajućeg uzorka magnetskog toka, uz prikladno odabran eksponent T, određeni su parametri aproksimativnih funkcija (7.10) i (7.15) te su prikazani u tablici 7.2.

Iz proračunatih parametara a_{d0} i a_{q0} nezasićeni induktiviteti određeni su uvrštavanjem u izraze (7.13) i (7.16) te za PMSG1 glase:

$$L_{d0} = 0,2113 \text{ p.u.}, \; L_{q0} = 1,0932 \text{ p.u.}, \tag{7.17}$$

a za PMSG2:

$$L_{d0} = 0,6166 \text{ p.u.}, \; L_{q0} = 1,5241 \text{ p.u.} \tag{7.18}$$

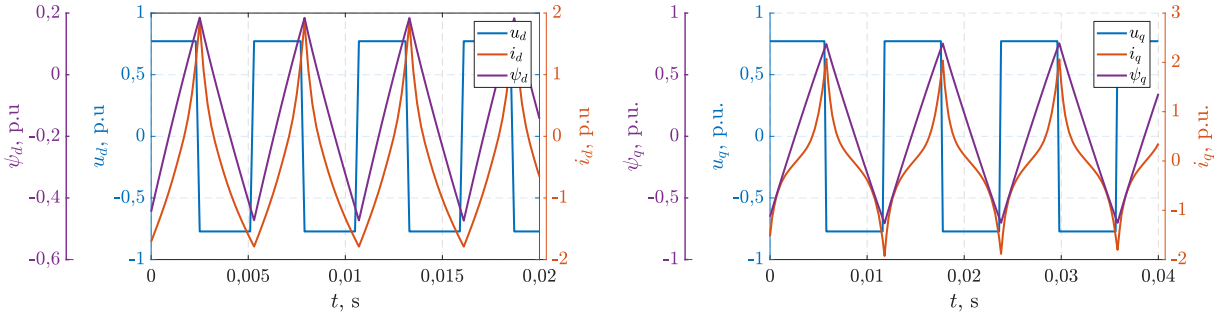

Slika 7.7: Simulacijski odzivi histereznog upravljanja strujama generatora PMSG1

Nadalje, kako bi se utvrdilo koliko dobro poprečni induktivitet aproksimiran funkcijom (7.14) i parametrima iz tablice 7.2 opisuje stvarni poprečni induktivitet generatora PMSG1 i PMSG2, na slikama 7.8 i 7.9 prikazani su aproksimirani poprečni induktiviteti te oni očitani iz preglednih tablica sa slike 7.3 u rasponu od $i_q \in [-1, 0]$ p.u. Osim poprečnog induktiviteta pri struji $i_d = 0$, očitani su i induktiviteti pri strujama $i_d = -0,3$ p.u. i $i_d = -0,6$ p.u. Usporedbom aproksimiranog induktiviteta $\hat{L}_q$ s induktivitetom L_q očitanim iz pregledne tablice pri $i_d = 0$ p.u., uočava se prilično dobro poklapanje u cijelom rasponu struje za oba generatora. Međutim, kada se u obzir uzme i međuinduktivna veza između uzdužne i poprečne osi, odnosno kada vrijedi $i_d \neq 0$ p.u., dolazi do povećanja odstupanja između aproksimiranog i stvarnog induktiviteta. Ova pojava je očekivana s obzirom na to da aproksimativna funkcija (7.14) ne modelira zasićenje uzrokovano međuinduktivnom vezom. Unatoč tome, čak i takva aproksimativna funkcija znatno smanjuje razliku između induktiviteta PMSG-a i SMO-a u odnosu na slučaj kada bi se SMO modelirao isključivo nezasićenim induktivitetom L_{q0} bez primjene adaptacije pomoću funkcije (7.14).

Također, na slikama 7.8 i 7.9 prikazani su i aproksimirani induktiviteti u uzdužnoj osi gdje se može uočiti relativno dobro slaganje s preglednim tablicama sa slike 7.3 koje je dovoljno za određivanje nezasićenog iznosa induktiviteta, dok zasićena vrijednost nije bitno budući da, prema (7.6), nesrazmjer uzdužnog induktiviteta PMSG-a i SMO-a ne utječe na povećanje estimacijske greške.

Tablica 7.2: Parametri aproksimativnih funkcija uzdužnog i poprečnog induktiviteta izračunati pomoću simulacijskih odziva

	***d*-os**		***q*-os**	
Stroj	**Eksponent**	**Koeficijent**	**Eksponent**	**Koeficijent**
PMSG1	T = 1	$a_{d0} = 4,7326$	T = 3	$a_{q0} = 0,9148$, $a_{qq} = 4,4081$
PMSG2	T = 1	$a_{d0} = 1,6217$	T = 4	$a_{q0} = 0,6561$, $a_{qq} = 0,4019$

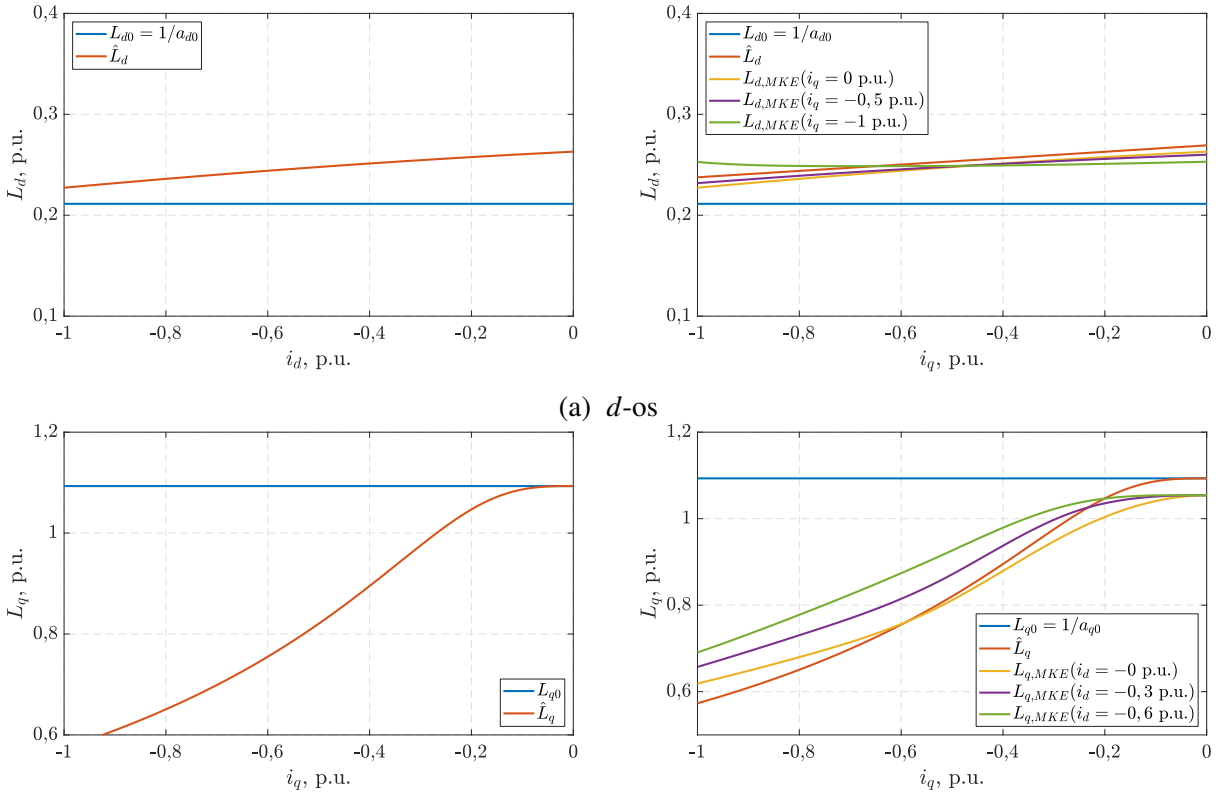

(a) d-os

(b) q-os

Slika 7.8: Usporedba aproksimiranog i stvarnog poprečnog induktiviteta za PMSG1

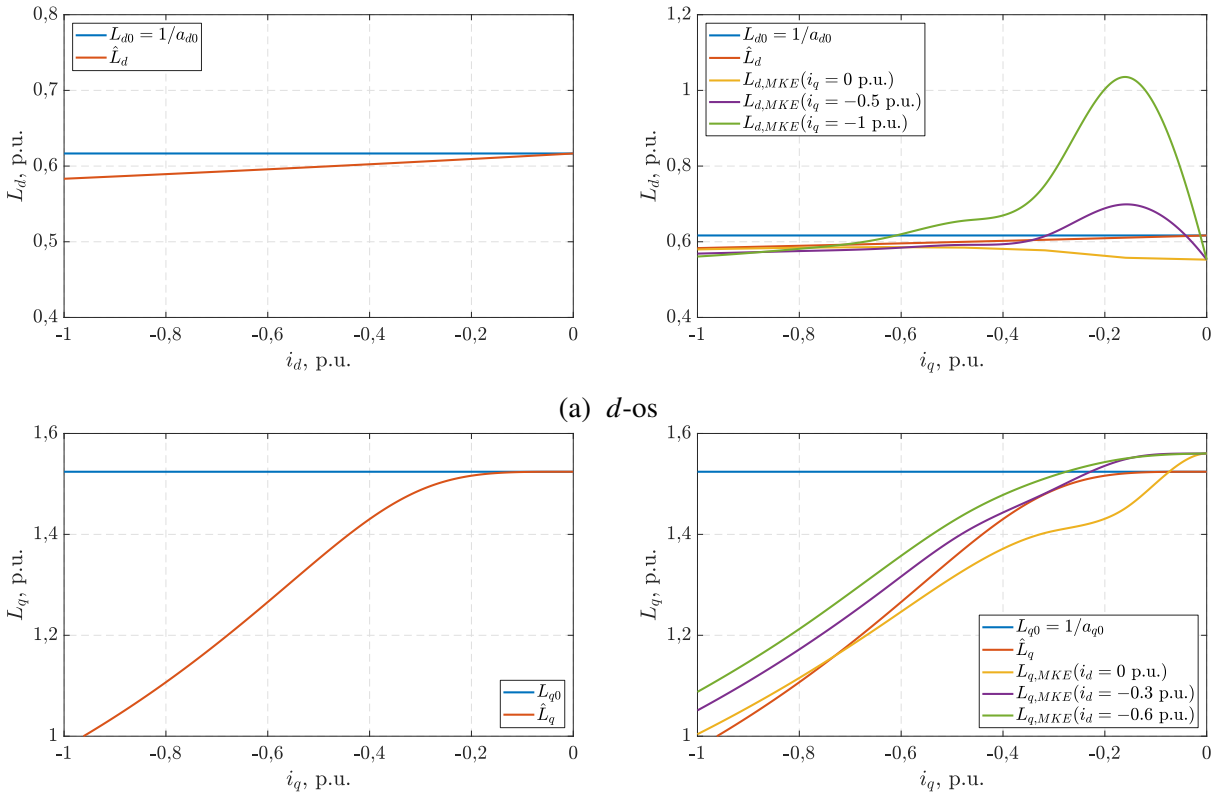

(a) d-os

(b) q-os

Slika 7.9: Usporedba aproksimiranog i stvarnog poprečnog induktiviteta za PMSG2

7.6.2. Smanjenje greške estimiranog kuta rotora primjenom aproksimativne funkcije poprečnog induktiviteta

Učinkovitost adaptiranja poprečnog induktiviteta pri smanjenju greške estimacije kuta korištenjem aproksimativna funkcije pokazana je na simulacijskom modelu bezsenzorskog upravljanja PMSG-om temeljenog na upravljačkoj strukturi sa slike 7.5. Na slici 7.10 prikazani su simulacijski odzivi referentnog i razvijenog momenta, M^* i M, referentnih i mjerenih struja u dq koordinatnom sustavu, $\boldsymbol{i}^*_{dq}$ i $\boldsymbol{i}_{dq}$, mjerene i izračunate greške estimiranog kuta, $\bar{\theta}_{re}$ i $\bar{\theta}^{calc}_{re}$, i poprečnog induktiviteta PMSG-a i adaptiranog poprečnog induktiviteta SMO-a, L_q i $\hat{L}_q$, za generatore PMSG1 i PMSG2.

Budući da je u eksperimentalnim rezultatima iz poglavlja 5 pokazano da je greška estimiranog kuta rotora približno jednaka za SMO u oba koordinatna sustava i za sve upravljačke zakone, simulacijski rezultati prikazani su samo za jednu upravljačku strukturu i to temeljenu na SMO-u $\gamma\delta$ koordinatnom sustav s upravljačkom funkcijom signum.

Odzivi na slikama prikazuju isključivo radnu točku terećenja i adaptacije poprečnog induktiviteta, uz pretpostavku da je ranije izvršen leteći start te da PMSG radi u trajnom radu koristeći bezsenzorsku strukturu upravljanja temeljenu na SMO-u u $\gamma\delta$ sustavu. Za oba generatora, PMSG1 i PMSG2, u trenutku $t = 1$ s zadaje se referentni iznos momenta M^* na temelju kojeg se određuje referentni par struja (i^*_d, i^*_q) prema MTPA krivulji. Podizanjem referentnog napona, struja $\boldsymbol{i}_{dq}$ raste te, zbog zasićenja dolazi do postupnog smanjenja poprečnog induktiviteta što uzrokuje porast greške estimiranog kuta rotora. Usporedbom stvarne greške estimiranog kuta s greškom određenom prema izrazu (7.6) očito je da izvedeni izraz prilično točno određuje očekivanu grešku estimiranog kuta u ovoj radnoj točki, iako se kod odziva za PMSG2 pojavljuje blago odstupanje koje može biti uzrokovano pretpostavljenim zanemarenjima prilikom izvoda izraza (7.6). Kao posljedica greške estimiranog kuta pojavljuje se odstupanje mjerenih struja (i_d, i_q) od zadanih referentnih vrijednosti (i^*_d, i^*_q) što također dovodi do razvijanja momenta manjeg od referentnog. U trenutku $t = 2$ s uključuje se adaptacija poprečnog induktiviteta SMO-a koristeći aproksimativnu funkciju (7.14). Iako slaganje aproksimiranog induktiviteta $\hat{L}_q$ i induktiviteta PMSG-a L_q u danoj radnoj točki nije potpuno zbog zanemarenja utjecaja međuinduktiviteta, očito je značajno smanjenje greške estimiranog kuta uslijed adaptacije poprečnog induktiviteta SMO-a. Smanjenje greške dovodi do boljeg praćenja referentnih iznosa struja, odnosno do razvijenog momenta čiji je iznos bliži referentnom.

Također, usporedbom rezultata za PMSG1 i PMSG2 uočava se da greška kuta ovisi o karakteristikama stroja, odnosno o razini zasićenja, budući da se kod oba generatora javlja približno jednaka greška $\bar{\theta}_{re} \approx 20°$, ali za različite referentne iznose momenta, $M^* = -1$ p.u. za PMSG1, odnosno $M^* = -0,8$ p.u. za PMSG2.

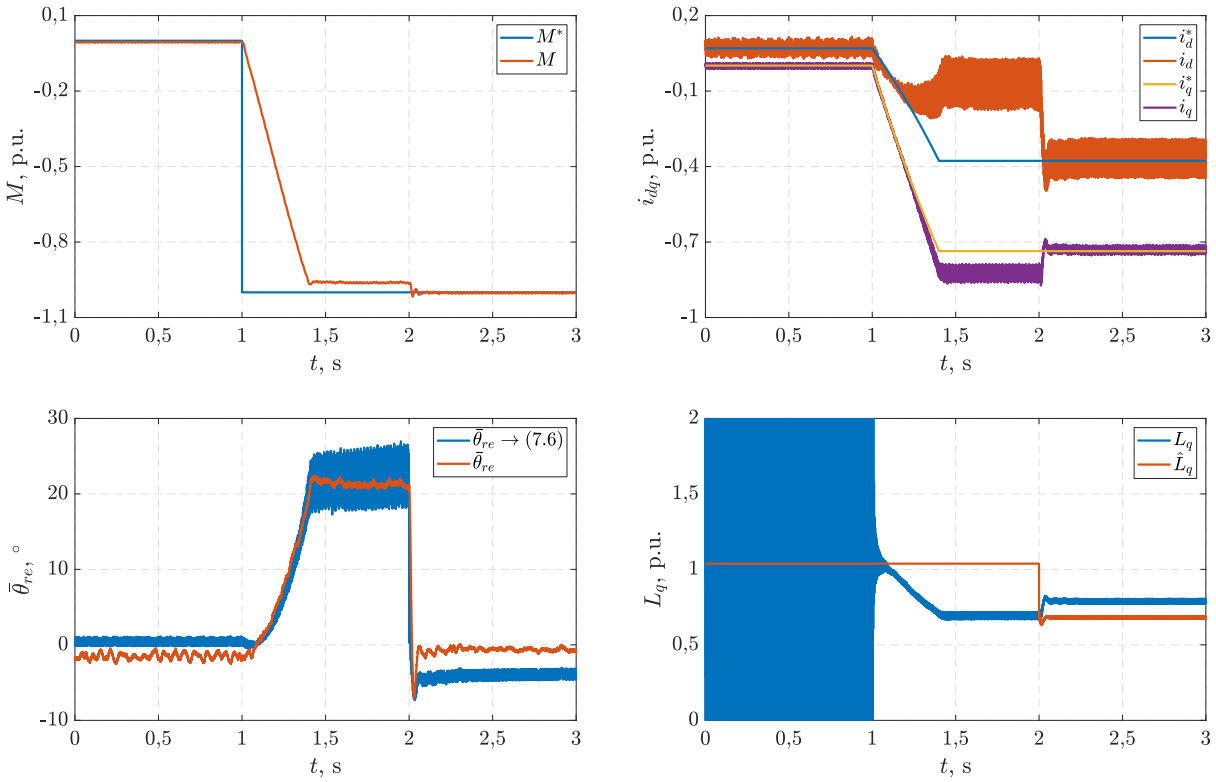

(a) PMSG1

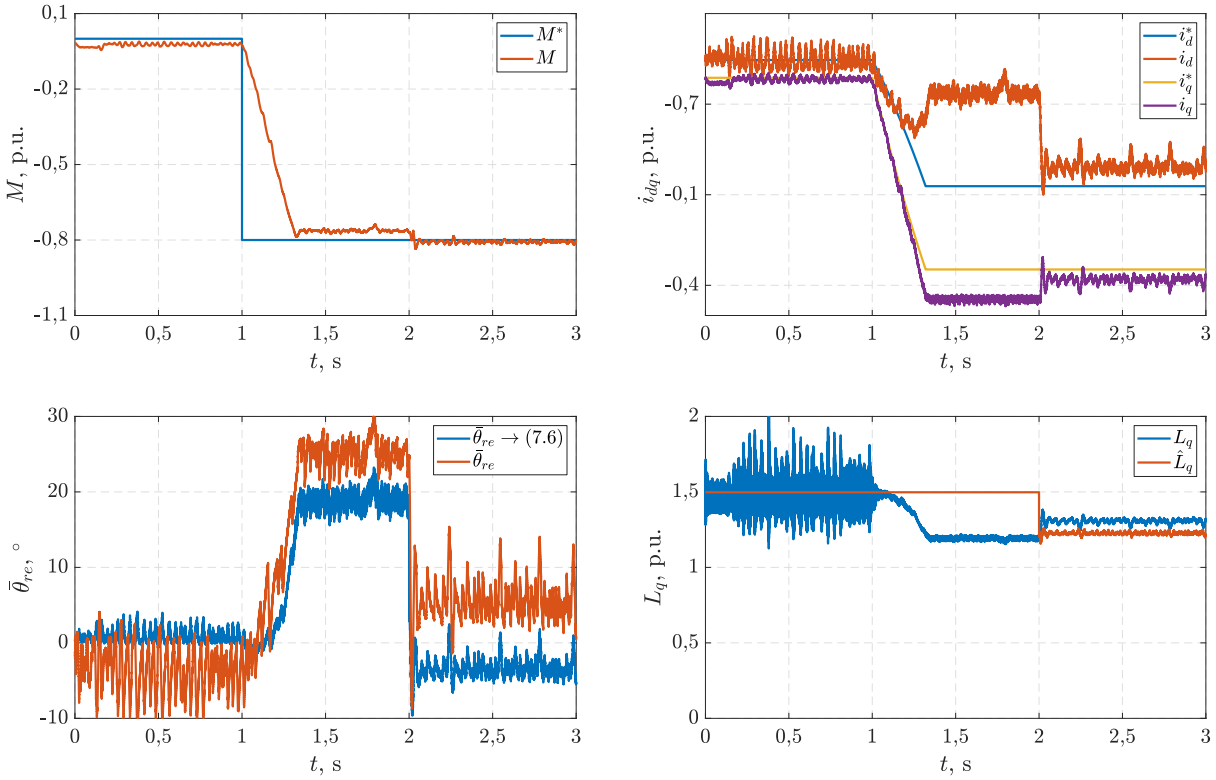

(b) PMSG2

Slika 7.10: Simulacijski odzivi bezsenzorske strukture upravljanja temeljene na SMO-u s implementiranom funkcijom za adaptaciju poprečnog induktiviteta

7.7.Eksperimentalni rezultati

Bezsenzorska metoda upravljanja temeljena na SMO-u s funkcijom letećeg starta predstavljena u poglavlju 6 nadograđena je metodom za smanjenje greške estimiranog kuta pomoću adaptacije poprečnog induktiviteta SMO-a na temelju aproksimativne funkcije. Metoda je implementirana u upravljački sustav pretvarača *Open4Lab* i eksperimentalno verificirana na laboratorijskom postavu iz poglavlja 4. Metoda smanjenja greške estimiranog kuta primijenjena je na SMO-e modelirane u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu te je ispitana za tri različita upravljačka zakona: signum funkciju, sigmoidnu funkciju i STA algoritam.

Pri implementaciji u digitalni upravljački sustav korišteni su isti parametri PMSG-a u predstavljeni u poglavlju 5 kada je pretpostavljeno da su iznosi parametara nadomjesne sheme iz tablice 5.5 poznati. Međutim, vrijednosti statorskog otpora, uzdužnog i poprečnog induktiviteta iz tablice 5.5 zapravo su određeni primjenom histereznih regulatora struje u d i q-osi prema dijagramu toka sa slike 7.4 na isti način kako je prikazano u simulacijskim odzivima (slika 7.7). Pri tome širina histereznog regulatora struje u d-osi postavljena je na $1,1$ p.u., a iznos primijenjenog napona je $\pm 0,5$ p.u. [116]. S druge strane, u q-osi korištena je širini histereze od $1,3$ p.u. s primijenjenim naponom $\pm 0,6$ p.u. [116]. Primjenom LLS algoritma na uzorke mjerene struje i izračunatog magnetskog toka tijekom histereznog upravljanja, određeni su parametri aproksimativne funkcije induktiviteta preko kojih su određene nezasićene vrijednosti uzdužnog i poprečnog induktiviteta prikazane u tablici 7.3. Također, prilikom pozicioniranja rotora u d-os određen je iznos statorskog otpora. Ovi iznosi iskorišteni su za proračun pojačanja PI regulatora struje prikazanih u tablici 5.8 i postavljanje SMO-a.

Tablica 7.3: Izračunati parametri aproksimativnih funkcija uzdužnog i poprečnog induktiviteta preko eksperimentalnih odziva

Os	Eksponent	Koeficijenti	Nezasićeni induktivitet	Statorski otpor
d	T = 0	$a_{d0} = 1,3594$	$L_{d0} = 0,4238$ p.u.	$R_s = 0,0507$ p.u.
q	T = 4	$a_{q0} = 0,8594$, $a_{qq} = 0,9639$	$L_{q0} = 1,1636$ p.u.	

Na slici 7.11 prikazani su odzivi upravljačke strukture temeljene na SMO-u u $\gamma\delta$ koordinatnim sustavu te prikazuje mjerenu i estimiranu brzinu vrtnju, ω_{re} i $\hat{\omega}_{re}$, mjereni i estimirani kut rotora, θ_{re} i $\hat{\theta}_{re}$, grešku estimiranog kuta rotora $\bar{\theta}_{re}$, referenti i razvijeni moment, M^* i M, mjerenu i estimiranu struju, $\boldsymbol{i}_{\gamma\delta}$ i $\hat{\boldsymbol{i}}_{\gamma\delta}$, te referentnu i mjerenu struju, $\boldsymbol{i}^*_{dq}$ i $\boldsymbol{i}_{dq}$. Navedeni odzivi snimljeni su za tri vrste upravljačkih funkcija: signum, sigmoidnu i STA algoritam te su prikazani na slikama 7.11a, 7.11b i 7.11c. Neovisno o korištenoj upravljačkoj funkciji, ispitano je ponašanje predložene upravljačke strukture u radnoj točki određenoj brzinom vrtnje $\omega_{re} = 0,67$ p.u. i referentnim momentom $M^* = -1,48$ p.u. uz pretpostavku ranije provedenog letećeg starta.

Referentni moment odabran je tako da PMSG-om teče nazivna struja.

Analizom odziva sa slike 7.11 potvrđeno je ponašanje estimacijske strukture temeljene na SMO-u pokazano u simulacijskim rezultatima. Kao što je već uočeno u eksperimentalnim rezultatima iz poglavlja 5, u prikazanoj radnoj točki određenoj referentnim momentom $M^* = -1,48$ p.u. dolazi do greške estimiranog kuta rotora koja iznosi $\theta_{re} \approx 15°$ neovisno o primijenjenoj upravljačkoj funkciji. Unesena greška događa se uslijed magnetskog zasićenja koje uzrokuje promjenu poprečnog induktiviteta PMSG-a što dovodi do razlike u poprečnim induktivitetima PMSG-a i SMO-a. Zbog unesene greške u estimirani kut, struje (i_d, i_q) ne prate referentni par struja (i_d^*, i_q^*) određen MTPA algoritmom za zadani referentni moment. Posljedično, ostvareni moment PMSG-a ne odgovara zadanom referentnom momentu. Kao rješenje ovog problema koristi se aproksimativna funkcija poprečnog momenta (7.14) s koeficijentima iz tablice 7.3. U trenutku $t \approx 2$ s na slici 7.11a, odnosno $t \approx 2,5$ s na slikama 7.11b i 7.11c uključuje se adaptacija poprečnog momenta SMO-a što dovodi do znatnog smanjenja greške estimiranog kuta rotora na $\bar{\theta}_{re} \approx 0°$. Uslijed smanjenja greške estimiranog kuta dolazi do boljeg praćenja mjerene i referentne struje, $\boldsymbol{i}_{dq}$ i $\boldsymbol{i}_{dq}^*$, te se smanjuje razlika između referentnog i ostvarenog momenta PMSG-a.

Na slici 7.12 prikazani su odzivi za upravljačku strukturu temeljenu na SMO-u u $\alpha\beta$ koordinatnom sustavu te prikazuje mjerenu i estimiranu brzinu vrtnje, ω_{re} i $\hat{\omega}_{re}$, mjereni i estimirani kut rotora, θ_{re} i $\hat{\theta}_{re}$, grešku estimiranog kuta rotora $\bar{\theta}_{re}$, referentni i razvijeni momenta, M^* i M, mjerenu i estimiranu struju, $\boldsymbol{i}_{\alpha\beta}$ i $\hat{\boldsymbol{i}}_{\alpha\beta}$, te referentnu i mjerenu struju, $\boldsymbol{i}_{dq}^*$ i $\boldsymbol{i}_{dq}$. Navedeni odzivi snimljeni su za tri vrste upravljačkih funkcija: signum, sigmoidnu i STA algoritam te su prikazani na slikama 7.12a, 7.12b i 7.12c za istu radnu točku kao i odzivi sa slike 7.11 uz pretpostavku ranije provedenog letećeg starta.

Analizom odziva može se uočiti jednako ponašanje kao i kod upravljačke strukture temeljene na SMO-u u $\gamma\delta$ koordinatnom sustavom budući da su izrazi za grešku estimacije kuta iz (7.6) i onaj izveden za $\alpha\beta$ sustav izveden u [79] istog oblika. Pri zadanom teretu dolazi do zasićenja, odnosno do razlike u poprečnim induktivitetima PMSG-a i SMO-a te se u estimirani kut rotora također unosi greška od $\bar{\theta}_{re} \approx 15°$. Greška estimiranog kuta uzrokuje razvoj momenta manjeg od referentnog, a uključenjem adaptacije poprečnog induktiviteta pomoću aproksimativne funkcije (7.14) i koeficijenata iz tablice 7.3 dolazi do iščezavanja greške estimiranog kuta te smanjenja odstupanja mjernih struja od referentnih, kao i mjerenog od referentnog momenta.

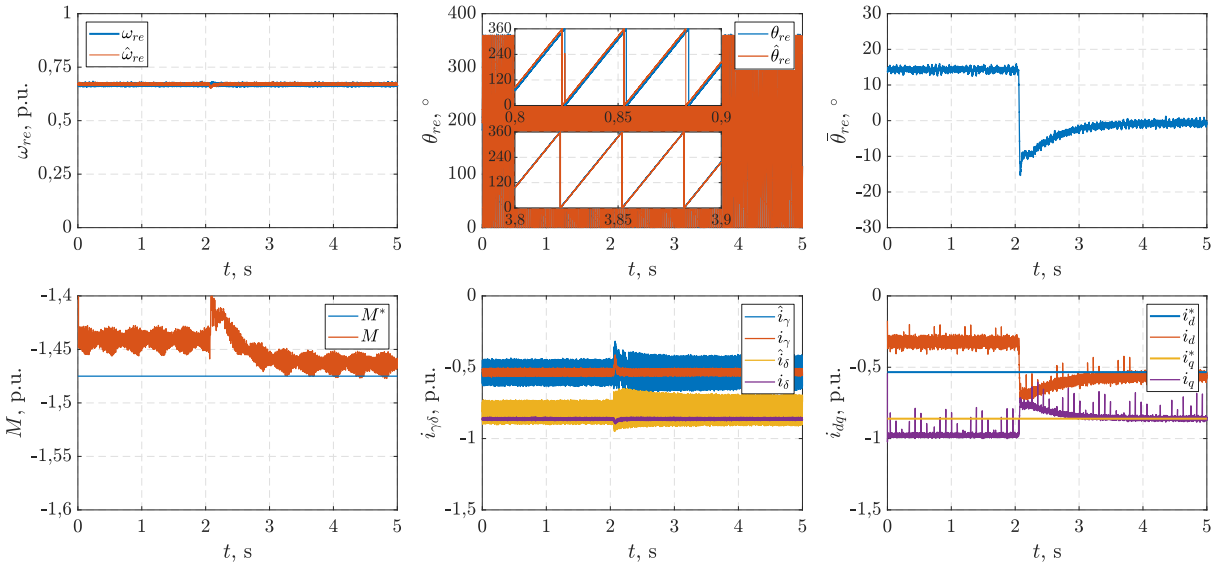

(a) Signum funkcija

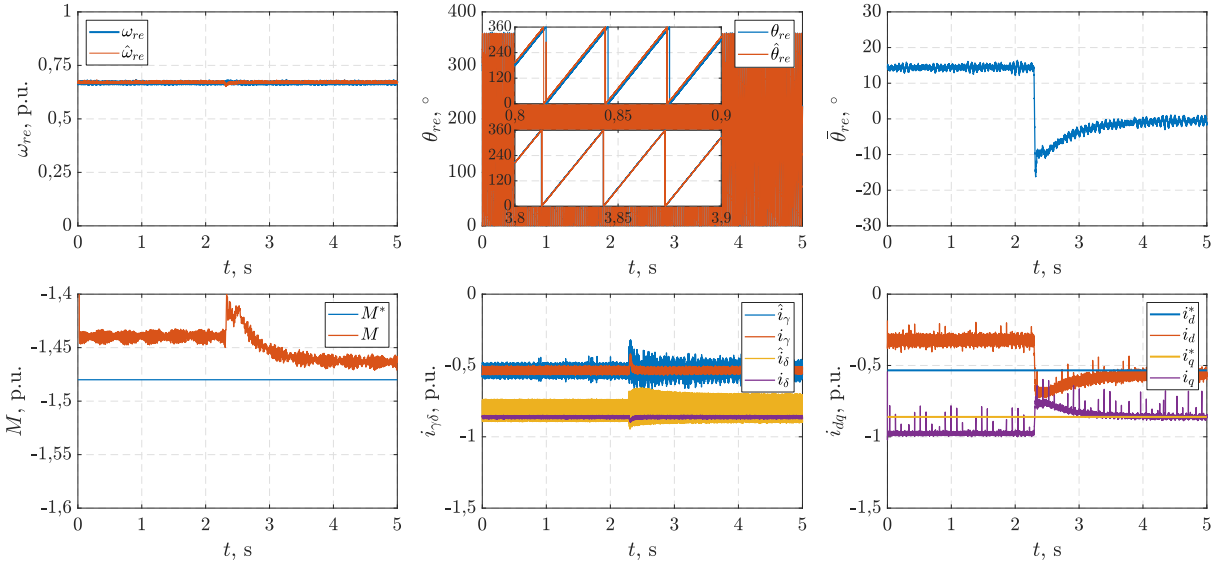

(b) Sigmoidna funkcija

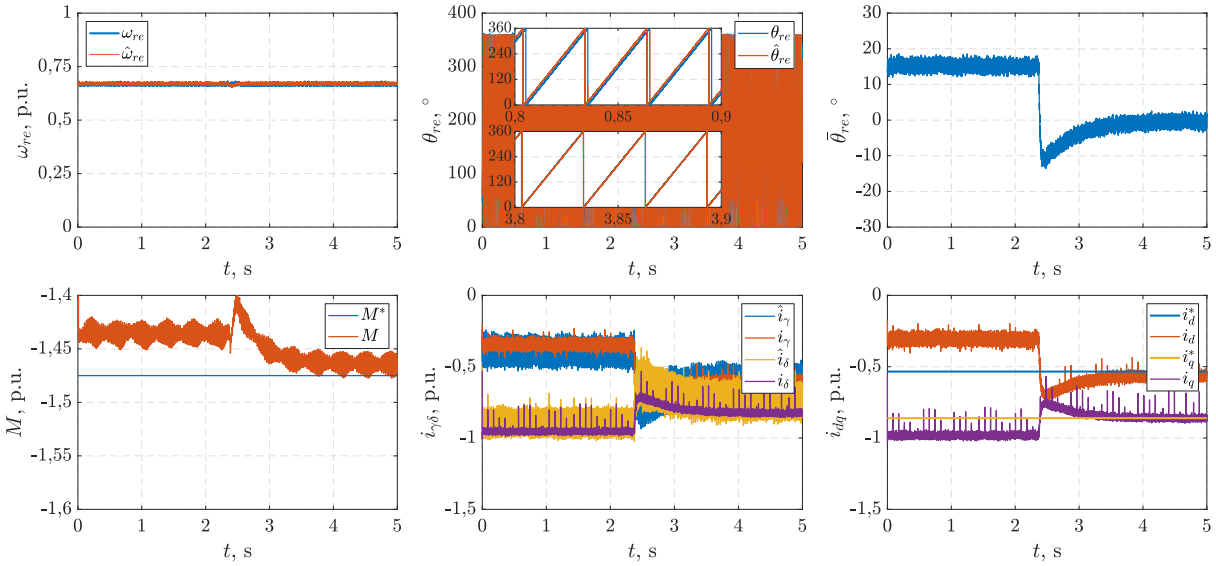

(c) STA algoritam

Slika 7.11: Smanjenje greške estimiranog kuta rotora adaptacijom induktiviteta SMO-a u $\gamma\delta$ sustavu

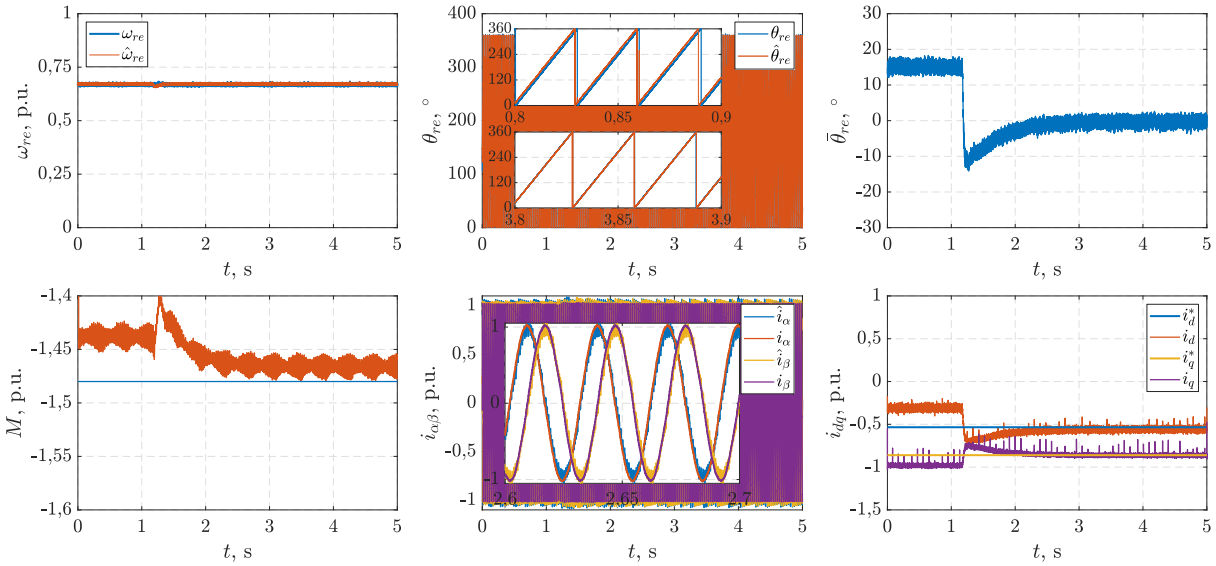

(a) Signum funkcija

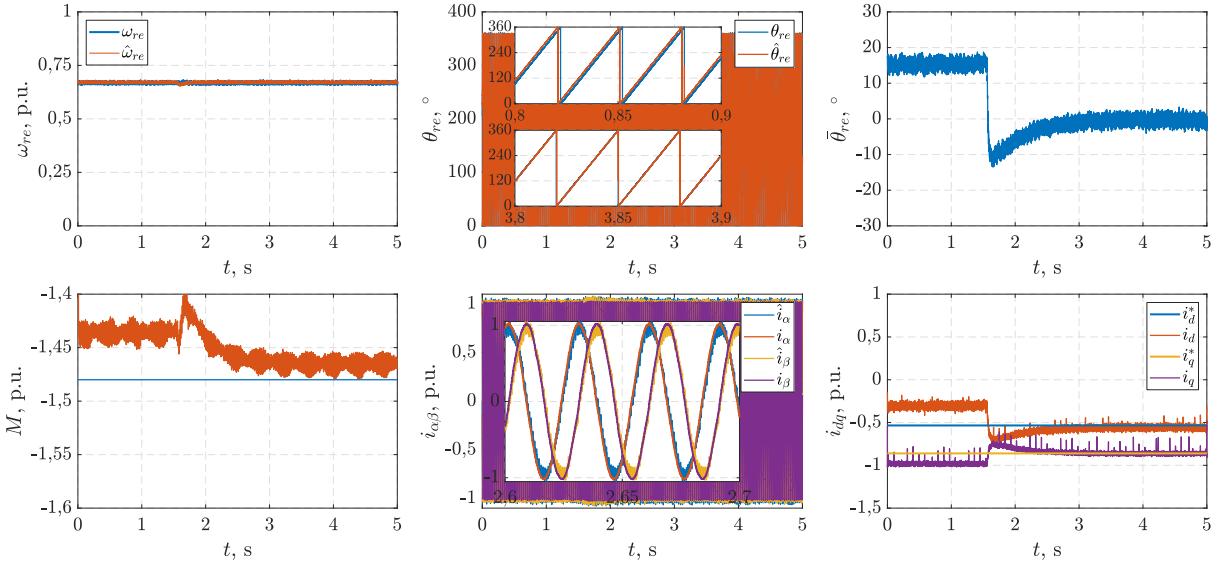

(b) Sigmoidna funkcija

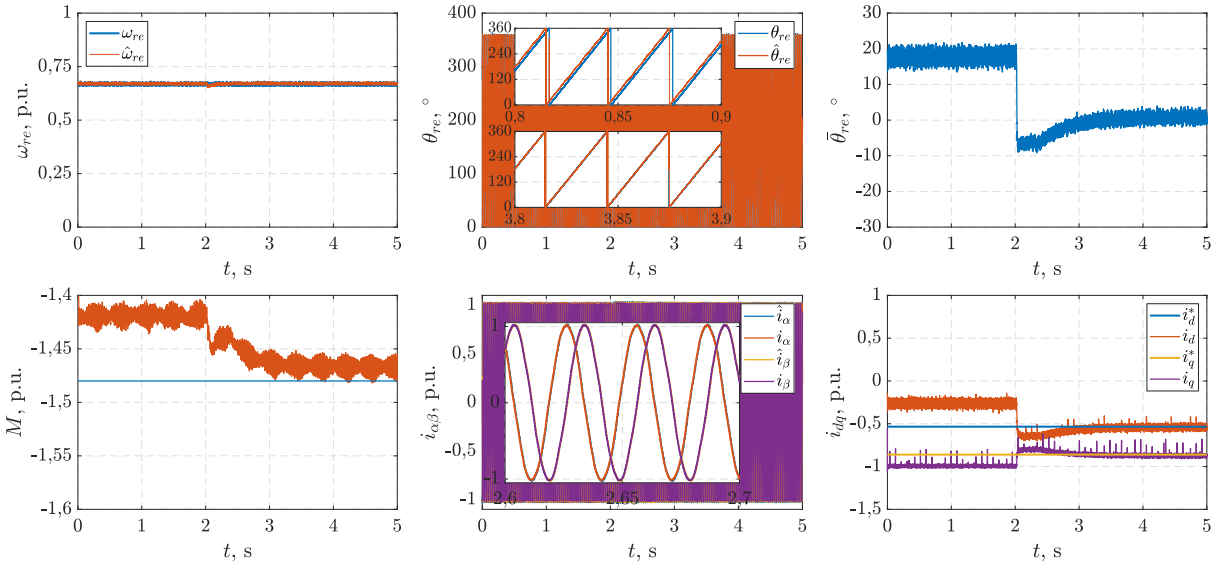

(c) STA algoritam

Slika 7.12: Smanjenje greške estimiranog kuta rotora adaptacijom induktiviteta SMO-a u $\alpha\beta$ sustavu

8.Zaključak

Porast integracije sustava za proizvodnju električne energije iz obnovljivih izvora, između kojih se ističe energija vjetra, uzrok je velikom broju znanstvenih radova vezanih za razvoj vjetroagregata. S obzirom da se u vjetroelektranama diljem svijeta sve češće koriste vjetroagregati tipa 4 čiji sastavni dio čini sinkroni generator s permanentnim magnetima te AC-DC-AC pretvarač, u doktorskoj disertaciji razmatrana je upravo takva vrsta vjetroagregata. Istraživanje vjetroagregata tipa 4 usmjereno je na bezsenzorske upravljačke strukture koje, za razliku od standardnih upravljačkih algoritama kao što je vektorsko upravljanje u koordinatnom sustavu toka rotora, ne koriste mjerni član brzine vrtnje i kuta rotora vjetrogeneratora.

U sklopu doktorske disertacije predočen je detaljan pregled znanstvene literature vezan za tri područja: bezsenzorsko upravljanje sinkronim vjetrogeneratorom s permanentnim magnetima, leteći start sinkronog vjetrogeneratora s permanentnim magnetima bez mjernog člana brzine vrtnje te smanjenje greške estimiranog kuta rotora pri korištenju estimacijske strukture temeljene na opserveru u kliznom načinu rada. Na temelju proučene literature u svakom od navedenih područja istraživanja razvijen je novi algoritam koji predstavlja nadogradnju postojećih algoritama. Svi razvijeni algoritmi ispitani su na laboratorijskom postavu koji se sastoji od generatora s permanentnim magnetima snage 5.5 kW, energetskog pretvarača te asinkronog stroja snage koji emulira rad vjetroturbine. Algoritmi su implementirani u digitalni upravljački sustav generatorskog pretvarača koji se temelji na upravljačkoj pločici Delfino C28343 proizvođača *Texas Instruments*.

Prvi dio znanstvenog doprinosa uključuje metodu estimacije brzine vrtnje i kuta rotora sinkronog generatora s permanentnim magnetima. Razvijena metoda estimacije temelji se na opserveru u kliznom načinu rada i regulatoru u fazno zaključnoj petlji. Iako u literaturi postoji velik broj estimacijskih struktura temeljenih na opserveru u kliznom načinu rada, predloženi opserver, za razliku od ostalih, modeliran je koristeći rekonstruirani matematički model sinkronog generatora s permanentnim magnetima u estimiranom $\gamma\delta$ koordinatnom sustavu. Rekonstrukcija modela generatora temelji se na konceptu aktivnog magnetskog toka rotora. Koristeći ovakvu rekonstrukciju modela generatora smanjuje se broj parametara potrebnih za inicijalizaciju opservera te se postiže manja zašumljenost estimirane brzine vrtnje i kuta rotora u odnosu na slične opservere u kliznom načinu rada modelirane u $\alpha\beta$ koordinatnom sustavu što je potvrđeno i

eksperimentalnim rezultatima. Rad predložene metode eksperimentalno je ispitan i potvrđen u tri radne točke: promjena brzine vrtnje neopterećenog generatora, terećenje generatora pri konstantnoj brzini vrtnje te promjena brzine vrtnje opterećenog generatora. Prilikom terećenja generatora uočena je pojava greške estimiranog kuta rotora koja ne utječe na stabilnost estimacijske strukture, međutim uzrokuje neslaganje razvijenog i referentnog momenta generatora. Osim toga, usporedbom predložene metode estimacije s već postojećim opserverom koji je također modeliran pomoću koncepta aktivnog magnetskog toka, ali u $\alpha\beta$ koordinatnom sustavu, pokazano je da predloženi algoritam zahtjeva manje procesorskih resursa u odnosu na postojeći.

U sklopu drugog dijela znanstvenog doprinosa razvijena je metoda letećeg starta sinkronog generatora s permanentnim magnetima bez korištenja mjernog člana brzine vrtnje. Budući da pregledom literature nije pronađena nijedna metoda koja objedinjuje leteći start i opserver u kliznom načinu rada, razvijena metoda zapravo predstavlja nadogradnju estimacijske strukture temeljene na opserveru u kliznom načinu rada i regulatoru u fazno zaključanoj petlji predstavljene u sklopu prvog doprinosa. Za leteći start iskorišten je isprekidani rad generatorskog pretvarača pa je model opservera u kliznom načinu rada prilagođen modelu sinkronog generatora s permanentnim magnetima prilikom isprekidanog rada. Na ovaj način postignuto je da se za leteći start i trajni rad sinkronog generatora s permanentnim magnetima koristi načelno ista estimacijska struktura koja zahtijeva tek nekoliko prilagodbi pri prelasku iz isprekidanog u trajni način rada pretvarača poput prilagodbe pojačanja upravljačke funkcije opservera, promjene ulaza opservera u kliznom načinu rada i prestanak zakretanja upravljačkog vektora za kut $\pi/2$. S obzirom da u znanstvenoj literaturi nisu prikazane metode letećeg starta temeljene na opserveru u kliznom načinu rada, eksperimentalno je potvrđen rad predložene strukture za leteći start temeljene na opserveru u kliznom načinu rada modeliranom u estimiranom $\gamma\delta$, kao i u $\alpha\beta$ koordinatnom sustavu. Eksperimentalni rezultati pokazuju da predložena struktura letećeg starta uspješno estimira kut i brzinu vrtnje rotora generatora tijekom isprekidanog rada pretvarača te osigurava uključenje generatorskog pretvarača uz minimalnu uklopnu struju pri različitim brzinama vrtnje.

U sklopu trećeg dijela znanstvenog doprinosa predstavljena je metoda za smanjenje greške estimiranog kuta rotora koja se pojavljuje tijekom terećenja generatora kao što je primijećeno analizom eksperimentalnih odziva metode predložene u sklopu prvog znanstvenog doprinosa. Unatoč velikom broju znanstvenih radova koji se bave estimacijskim strukturama temeljenim na opserverima u kliznom načinu rada, mali broj radova razmatra grešku estimiranog kuta koja se u takvim strukturama pojavljuje zbog toga što se opserver najčešće modelira s fiksnom vrijednošću poprečnog induktiviteta, dok se poprečni induktivitet generatora smanjuje uslijed magnetskog zasićenja u radnim točkama određenim velikim teretima, a upravo ova razlika poprečnih induktiviteta unosi grešku u signal estimiranog kuta rotora. Kako bi se navedeni problem riješio, prije početka rada upravljačke strukture predložene u sklopu prvog, odnosno drugog znanstvenog doprinosa, primijenjena je metoda za određivanje koeficijenata aproksimativne

funkcije poprečnog induktiviteta u ovisnosti o struji, odnosno magnetskom toku generatora dostupna u postojećoj znanstvenoj literaturi. Prilikom primjene ove metode određene su i nezasićene vrijednosti uzdužnog i poprečnog induktiviteta kao i statorskog otpora koje su iskorištene za inicijalizaciju opservera te proračun pojačanja PI regulatora struje. Simulacijskim i eksperimentalnim rezultatima pokazano je da se adaptacijom poprečnog induktiviteta koristeći ovako određenu aproksimativnu funkciju bitno smanjuje greška estimiranog kuta rotora te se, posljedično, osigurava da generator razvija moment bliži zadanoj referentnoj vrijednosti.

Metode iznesene u sklopu znanstvenog doprinosa doktorske disertacije predstavljaju sveobuhvatni upravljački sustav bez mjernog člana brzine vrtnje za vjetroagregat tipa 4. Razlog tomu je taj što predložene metode omogućuju stabilan i učinkovit rad u cjelokupnom radnom području vjetroagregata uključujući leteći start sinkronog generatora s permanentnim magnetima te rad upravljačkog sustava uz minimalnu grešku estimiranog kuta te posljedično minimalnu grešku ostvarenog momenta i snage. Predložene metode mogu se, osim u upravljačkim sustavima za vjetroagregate, primijeniti i u sustavima sa sinkronim strojevima s permanentnim magnetima drugačije namjene. Također, metoda letećeg starta temeljena na opserveru u kliznom načinu rada i isprekidanom radu pretvarača potencijalno je primjenjiva i na mrežni dio AC-DC-AC pretvarača [140].

Literatura

[1] IRENA (2015), "Renewable capacity statistics 2015", international Renewable Energy Agency (IRENA), Abu Dhabi.

[2] IRENA (2021), "Renewable capacity statistics 2021", international Renewable Energy Agency (IRENA), Abu Dhabi.

[3] GWEC (2021), "Global wind report 2021", global Wind Energy Council (GWEC), 25 March 2021, Brussells.

[4] Polinder, H., Ferreira, J. A., Jensen, B. B., Abrahamsen, A. B., Atallah, K., McMahon, R. A., "Trends in wind turbine generator systems", IEEE Journal of emerging and selected topics in power electronics, Vol. 1, No. 3, 2013, str. 174–185.

[5] Yaramasu, V., Wu, B., Sen, P. C., Kouro, S., Narimani, M., "High-power wind energy conversion systems: State-of-the-art and emerging technologies", Proceedings of the IEEE, Vol. 103, No. 5, 2015, str. 740–788.

[6] Camm, E., Behnke, M., Bolado, O., Bollen, M., Bradt, M., Brooks, C., Dilling, W., Edds, M., Hejdak, W., Houseman, D. *et al.*, "Characteristics of wind turbine generators for wind power plants", in 2009 IEEE Power & Energy Society General Meeting. IEEE, 2009, str. 1–5.

[7] Li, H., Chen, Z., "Overview of different wind generator systems and their comparisons", IET Renewable Power Generation, Vol. 2, No. 2, 2008, str. 123–138.

[8] Chen, H., Zuo, Y., Chau, K., Zhao, W., Lee, C. H., "Modern electric machines and drives for wind power generation: A review of opportunities and challenges", IET Renewable Power Generation, Vol. 15, No. 9, 2021, str. 1864–1887.

[9] Carroll, J., McDonald, A., McMillan, D., "Reliability comparison of wind turbines with dfig and pmg drive trains", IEEE Transactions on Energy Conversion, Vol. 30, No. 2, 2014, str. 663–670.

[10] Blaabjerg, F., Ma, K., “Future on power electronics for wind turbine systems”, IEEE Journal of emerging and selected topics in power electronics, Vol. 1, No. 3, 2013, str. 139–152.

[11] El-Naggar, M. F., Abdelhamid, A. S., Elshahed, M. A., Bekhet, M. E.-S. M., “Ranking subassemblies of wind energy conversion systems concerning their impact on the overall reliability”, IEEE Access, Vol. 9, 2021, str. 53 754–53 768.

[12] Conroy, J. F., Watson, R., “Frequency response capability of full converter wind turbine generators in comparison to conventional generation”, IEEE transactions on power systems, Vol. 23, No. 2, 2008, str. 649–656.

[13] Faulstich, S., Hahn, B., Tavner, P. J., “Wind turbine downtime and its importance for offshore deployment”, Wind energy, Vol. 14, No. 3, 2011, str. 327–337.

[14] Gu, H., Liu, W., Gao, Q., Zhang, Y., “A review on wind turbines gearbox fault diagnosis methods”, Journal of Vibroengineering, Vol. 23, No. 1, 2021, str. 26–43.

[15] Ribrant, J., Bertling, L., “Survey of failures in wind power systems with focus on swedish wind power plants during 1997-2005”, in 2007 IEEE power engineering society general meeting. IEEE, 2007, str. 1–8.

[16] Jain, B., Jain, S., Nema, R., “Control strategies of grid interfaced wind energy conversion system: An overview”, Renewable and Sustainable Energy Reviews, Vol. 47, 2015, str. 983–996.

[17] Blaabjerg, F., Teodorescu, R., Liserre, M., Timbus, A. V., “Overview of control and grid synchronization for distributed power generation systems”, IEEE Transactions on industrial electronics, Vol. 53, No. 5, 2006, str. 1398–1409.

[18] Kumar, D., Chatterjee, K., “A review of conventional and advanced mppt algorithms for wind energy systems”, Renewable and sustainable energy reviews, Vol. 55, 2016, str. 957–970.

[19] Zhao, Y., Wei, C., Zhang, Z., Qiao, W., “A review on position/speed sensorless control for permanent-magnet synchronous machine-based wind energy conversion systems”, IEEE Journal of Emerging and Selected Topics in Power Electronics, Vol. 1, No. 4, 2013, str. 203–216.

[20] Utkin, V., Guldner, J., Shi, J., Sliding mode control in electro-mechanical systems. CRC press, 2017.

[21] Zhao, Y., Zhang, Z., Qiao, W., Wu, L., "An extended flux model-based rotor position estimator for sensorless control of salient-pole permanent-magnet synchronous machines", IEEE Transactions on Power Electronics, Vol. 30, No. 8, 2014, str. 4412–4422.

[22] Pravica, L., Sumina, D., Bariša, T., Kovačić, M., Čolović, I., "Flying start of a permanent magnet wind power generator based on a discontinuous converter operation mode and a phase-locked loop", IEEE Transactions on Industrial Electronics, Vol. 65, No. 2, 2017, str. 1097–1106.

[23] Bariša, T., Sumina, D., Pravica, L., Čolović, I., "Flying start and sensorless control of permanent magnet wind power generator using induced voltage measurement and phase-locked loop", Electric power systems research, Vol. 152, 2017, str. 457–465.

[24] Lee, Y., Kwon, Y.-C., Sul, S.-K., "Comparison of rotor position estimation performance in fundamental-model-based sensorless control of pmsm", in 2015 IEEE Energy Conversion Congress and Exposition (ECCE). IEEE, 2015, str. 5624–5633.

[25] Polinder, H., Van der Pijl, F. F., De Vilder, G.-J., Tavner, P. J., "Comparison of direct-drive and geared generator concepts for wind turbines", IEEE Transactions on energy conversion, Vol. 21, No. 3, 2006, str. 725–733.

[26] Burton, T., Jenkins, N., Sharpe, D., Bossanyi, E., Wind energy handbook. John Wiley & Sons, 2011.

[27] Jelavić, M., "Upravljanje vjetroagregatom s ciljem smanjenja dinamičkih opterećenja konstrukcije", Doktorski rad, 2009.

[28] Vaez-Zadeh, S., Control of permanent magnet synchronous motors. Oxford University Press, 2018.

[29]Jadrić, M., Frančić, B., "Dinamika električnih strojeva", Graphis, Zagreb, 1997.

[30] O'Rourke, C. J., Qasim, M. M., Overlin, M. R., Kirtley, J. L., "A geometric interpretation of reference frames and transformations: dq0, clarke, and park", IEEE Transactions on Energy Conversion, Vol. 34, No. 4, 2019, str. 2070–2083.

[31] Krause, P. C., Wasynczuk, O., Sudhoff, S. D., Pekarek, S. D., Analysis of electric machinery and drive systems. John Wiley & Sons, 2013, Vol. 75.

[32] Pyrhonen, J., Hrabovcova, V., Semken, R. S., Electrical machine drives control: An introduction. John Wiley & Sons, 2016.

[33] Jung, S.-Y., Hong, J., Nam, K., "Current minimizing torque control of the ipmsm using ferrari's method", IEEE Transactions on Power Electronics, Vol. 28, No. 12, 2013, str. 5603–5617.

[34] Morimoto, S., Takeda, Y., Hirasa, T., Taniguchi, K., "Expansion of operating limits for permanent magnet motor by current vector control considering inverter capacity", IEEE Transactions on Industry Applications, Vol. 26, No. 5, 1990, str. 866-871.

[35] Pravica, L., Bariša, T., "Torque control of a wind power permanent magnet generator in a flux weakening region", in 2017 19th International Conference on Electrical Drives and Power Electronics (EDPE). IEEE, 2017, str. 273–278.

[36] Blaabjerg, F., Ma, K., "Wind energy systems", Proceedings of the IEEE, Vol. 105, No. 11, 2017, str. 2116–2131.

[37] Yaramasu, V., Dekka, A., Durán, M. J., Kouro, S., Wu, B., "Pmsg-based wind energy conversion systems: survey on power converters and controls", IET Electric Power Applications, Vol. 11, No. 6, 2017, str. 956–968.

[38] Zhang, Z., Cui, Z., Zhang, Z., Kennel, R., Rodríguez, J., "Advanced control strategies for back-to-back power converter pmsg wind turbine systems", in 2019 IEEE International Symposium on Predictive Control of Electrical Drives and Power Electronics (PRECEDE). IEEE, 2019, str. 1–6.

[39] Busca, C., Stan, A.-I., Stanciu, T., Stroe, D. I., "Control of permanent magnet synchronous generator for large wind turbines", in 2010 IEEE International Symposium on Industrial Electronics. IEEE, 2010, str. 3871–3876.

[40] Teodorescu, R., Liserre, M., Rodriguez, P., Grid converters for photovoltaic and wind power systems. John Wiley & Sons, 2011, Vol. 29.

[41] Gui, Y., Wang, X., Blaabjerg, F., Pan, D., "Control of grid-connected voltage-source converters: The relationship between direct-power control and vector-current control", IEEE Industrial Electronics Magazine, Vol. 13, No. 2, 2019, str. 31–40.

[42] Serpa, L. A., Ponnaluri, S., Barbosa, P. M., Kolar, J. W., "A modified direct power control strategy allowing the connection of three-phase inverters to the grid through lcl filters", IEEE Transactions on Industry Applications, Vol. 43, No. 5, 2007, str. 1388–1400.

[43] Kaura, V., Blasko, V., "Operation of a phase locked loop system under distorted utility conditions", IEEE Transactions on Industry applications, Vol. 33, No. 1, 1997, str. 58–63.

[44] Utkin, V. I., Sliding modes in control and optimization. Springer Science & Business Media, 2013.

[45] Edwards, C., Spurgeon, S., Sliding mode control: theory and applications. Crc Press, 1998.

[46] Shtessel, Y., Edwards, C., Fridman, L., Levant, A. *et al.*, Sliding mode control and observation. Springer, 2014, Vol. 10.

[47] Hung, J. Y., Gao, W., Hung, J. C., "Variable structure control: A survey", IEEE transactions on industrial electronics, Vol. 40, No. 1, 1993, str. 2–22.

[48] Filippov, A. F., "Differential equations with discontinuous righthand sides", in Mathematics and Its Applications, 1988.

[49] Utkin, V., "Variable structure systems with sliding modes", IEEE Transactions on Automatic control, Vol. 22, No. 2, 1977, str. 212–222.

[50] Vrdoljak, K., "Primjena kliznog režima upravljanja u sekundarnoj regulaciji frekvencije i djelatne snage razmjene elektroenergetskih sustava", Doktorski rad, 2009.

[51] Tan, S.-C., Lai, Y.-M., Tse, C.-K., Sliding mode control of switching power converters: techniques and implementation. CRC press, 2018.

[52]Alwi, H., Edwards, C., Tan, C. P., Fault detection and fault-tolerant control using sliding modes. Springer Science & Business Media, 2011.

[53] Mehta, A., Bandyopadhyay, B., Frequency-shaped and observer-based discrete-time sliding mode control. Springer, 2015.

[54] Sarpturk, S., Istefanopulos, Y., Kaynak, O., "On the stability of discrete-time sliding mode control systems", IEEE Transactions on Automatic Control, Vol. 32, No. 10, 1987, str. 930–932.

[55] Wang, G., Valla, M., Solsona, J., "Position sensorless permanent magnet synchronous machine drives—a review", IEEE Transactions on Industrial Electronics, Vol. 67, No. 7, 2019, str. 5830–5842.

[56] Schroedl, M., "Sensorless control of ac machines at low speed and standstill based on the" inform" method", in IAS'96. Conference Record of the 1996 IEEE Industry Applications Conference Thirty-First IAS Annual Meeting, Vol. 1. IEEE, 1996, str. 270–277.

[57] Wang, G., Kuang, J., Zhao, N., Zhang, G., Xu, D., "Rotor position estimation of pmsm in low-speed region and standstill using zero-voltage vector injection", IEEE Transactions on Power Electronics, Vol. 33, No. 9, 2017, str. 7948–7958.

[58] Shen, J., Zhu, Z., Howe, D., "Improved speed estimation in sensorless pm brushless ac drives", IEEE Transactions on Industry Applications, Vol. 38, No. 4, 2002, str. 1072–1080.

[59] Boldea, I., Paicu, M. C., Andreescu, G.-D., "Active flux concept for motion-sensorless unified ac drives", IEEE Transactions on Power Electronics, Vol. 23, No. 5, 2008, str. 2612–2618.

[60] Kulkarni, A. B., Ehsani, M., "A novel position sensor elimination technique for the interior permanent-magnet synchronous motor drive", IEEE Transactions on Industry Applications, Vol. 28, No. 1, 1992, str. 144–150.

[61] Hoque, M. A., Rahman, M. A., "Speed and position sensorless permanent magnet synchronous motor drives", 1994 Proceedings of Canadian Conference on Electrical and Computer Engineering, 1994, str. 689-692 vol.2.

[62] Jones, L. A., Lang, J. H., "A state observer for the permanent-magnet synchronous motor", IEEE transactions on Industrial Electronics, Vol. 36, No. 3, 1989, str. 374–382.

[63] Hinkkanen, M., Tuovinen, T., Harnefors, L., Luomi, J., "A combined position and stator-resistance observer for salient pmsm drives: Design and stability analysis", IEEE Transactions on Power Electronics, Vol. 27, No. 2, 2012, str. 601-609.

[64] Chen, Z., Tomita, M., Doki, S., Okuma, S., "An extended electromotive force model for sensorless control of interior permanent-magnet synchronous motors", IEEE transactions on Industrial Electronics, Vol. 50, No. 2, 2003, str. 288–295.

[65] Yin, Z., Gao, F., Zhang, Y., Du, C., Li, G., Sun, X., "A review of nonlinear kalman filter appling to sensorless control for ac motor drives", CES Transactions on Electrical Machines and Systems, Vol. 3, No. 4, 2019, str. 351–362.

[66] Bolognani, S., Tubiana, L., Zigliotto, M., "Extended kalman filter tuning in sensorless pmsm drives", IEEE Transactions on Industry Applications, Vol. 39, No. 6, 2003, str. 1741–1747.

[67] Xu, Z., Rahman, M., "Comparison of a sliding observer and a kalman filter for direct-torque-controlled ipm synchronous motor drives", IEEE Transactions on Industrial Electronics, Vol. 59, No. 11, 2012, str. 4179–4188.

[68] Piippo, A., Hinkkanen, M., Luomi, J., "Analysis of an adaptive observer for sensorless control of interior permanent magnet synchronous motors", IEEE Transactions on Industrial Electronics, Vol. 55, No. 2, 2008, str. 570–576.

[69] Khlaief, A., Boussak, M., Chaari, A., "A mras-based stator resistance and speed estimation for sensorless vector controlled ipmsm drive", Electric Power Systems Research, Vol. 108, 2014, str. 1–15.

[70] Koonlaboon, S., Sangwongwanich, S., "Sensorless control of interior permanent-magnet synchronous motors based on a fictitious permanent-magnet flux model", in Fourtieth IAS Annual Meeting. Conference Record of the 2005 Industry Applications Conference, 2005., Vol. 1. IEEE, 2005, str. 311–318.

[71] Ilioudis, V. C., Margaris, N. I., "Speed and position estimation technique for pmsm based on modified machine model", in 2010 12th International Conference on Optimization of Electrical and Electronic Equipment. IEEE, 2010, str. 407–415.

[72] Zhao, Y., Qiao, W., Wu, L., "Compensation algorithms for sliding mode observers in sensorless control of ipmsms", in 2012 IEEE International Electric Vehicle Conference. IEEE, 2012, str. 1–7.

[73] Wang, G., Li, Z., Zhang, G., Yu, Y., Xu, D., "Quadrature pll-based high-order sliding-mode observer for ipmsm sensorless control with online mtpa control strategy", IEEE Transactions on Energy Conversion, Vol. 28, No. 1, 2012, str. 214–224.

[74] Yuan, L., Xiao, F., Shen, J.-q., Chen, M.-l., Shi, Q.-m., Quan-feng, L., "Sensorless control of high-power interior permanent-magnet synchronous motor drives at very low speed", IET electric power applications, Vol. 7, No. 3, 2013, str. 199–206.

[75] Xu, Y., Wang, M., Zhang, W., Zou, J., "Sliding mode observer for sensorless control of surface permanent magnet synchronous motor equipped with lc filter", IET Power Electronics, Vol. 12, No. 4, 2019, str. 686–692.

[76] Liang, D., Li, J., Qu, R., "Sensorless control of permanent magnet synchronous machine based on second-order sliding-mode observer with online resistance estimation", IEEE Transactions on Industry Applications, Vol. 53, No. 4, 2017, str. 3672–3682.

[77] Jung, Y.-S., Kim, M.-G., "Sliding mode observer for sensorless control of ipmsm drives", Journal of Power Electronics, Vol. 9, No. 1, 2009, str. 117–123.

[78] Foo, G., Rahman, M., "Sensorless sliding-mode mtpa control of an ipm synchronous motor drive using a sliding-mode observer and hf signal injection", IEEE Transactions on Industrial Electronics, Vol. 57, No. 4, 2009, str. 1270–1278.

[79] He, W., Wu, X., Chen, J., Wang, Y., "Comparative study of sensorless control of permanent magnet synchronous motor realised by sliding-mode observer", IET Power Electronics, Vol. 13, No. 6, 2020, str. 1191–1199.

[80] Jukić, F., Pravica, L., Bariša, T., Sumina, D., "Flying-start and continuous operation of a permanent-magnet wind generator based on discontinuous currents, discrete second-order sliding-mode observer and phase-locked loop", IET Renewable Power Generation, Vol. 14, No. 1, 2020, str. 90–99.

[81] Zhao, Y., Qiao, W., Wu, L., "An adaptive quasi-sliding-mode rotor position observer-based sensorless control for interior permanent magnet synchronous machines", IEEE Transactions on Power Electronics, Vol. 28, No. 12, 2013, str. 5618–5629.

[82] Levant, A., "Sliding order and sliding accuracy in sliding mode control", International journal of control, Vol. 58, No. 6, 1993, str. 1247–1263.

[83] Levant, A., "Robust exact differentiation via sliding mode technique", automatica, Vol. 34, No. 3, 1998, str. 379–384.

[84] Moreno, J. A., Osorio, M., "A lyapunov approach to second-order sliding mode controllers and observers", in 2008 47th IEEE conference on decision and control. IEEE, 2008, str. 2856–2861.

[85] Davila, J., Fridman, L., Levant, A., "Second-order sliding-mode observer for mechanical systems", IEEE transactions on automatic control, Vol. 50, No. 11, 2005, str. 1785–1789.

[86] Lee, K., Ahmed, S., Lukic, S. M., "Universal restart strategy for high-inertia scalar-controlled pmsm drives", IEEE Transactions on Industry Applications, Vol. 52, No. 5, 2016, str. 4001–4009.

[87] You, Z.-C., Yang, S.-M., "A control strategy for flying-start of shaft sensorless permanent magnet synchronous machine drive", in 2018 International Power Electronics Conference (IPEC-Niigata 2018-ECCE Asia). IEEE, 2018, str. 651–656.

[88] Wu, T., Luo, D., Huang, S., Wu, X., Liu, K., Lu, K., Peng, X., "A fast estimation of initial rotor position for low-speed free-running ipmsm", IEEE Transactions on Power Electronics, Vol. 35, No. 7, 2019, str. 7664–7673.

[89] Hanamoto, T., Yamada, H., Okuyama, Y., "Position sensorless start-up method of surface permanent magnet synchronous motor using nonlinear rotor position observer", in 2014 International Power Electronics Conference (IPEC-Hiroshima 2014-ECCE ASIA). IEEE, 2014, str. 1811–1815.

[90] Orlando, N. A., Liserre, M., Mastromauro, R. A., Dell'Aquila, A., "A survey of control issues in pmsg-based small wind-turbine systems", IEEE transactions on Industrial Informatics, Vol. 9, No. 3, 2013, str. 1211–1221.

[91] Horie, T., Kondo, K., "Experimental study on a restarting procedure at coasting condition for a rotational angle sensorless pmsm", IEEJ Journal of Industry Applications, Vol. 3, No. 2, 2014, str. 131–137.

[92] Son, Y. C., Seok-Joo, J., Nasrabadi, R. D., "Permanent magnet ac motor systems and control algorithm restart methods", uS Patent 8,054,030. Nov. 8 2011.

[93] Taniguchi, S., Mochiduki, S., Yamakawa, T., Wakao, S., Kondo, K., Yoneyama, T., "Starting procedure of rotational sensorless pmsm in the rotating condition", IEEE Transactions on Industry Applications, Vol. 45, No. 1, 2009, str. 194–202.

[94] Chen, B., Shen, A., Li, P., Luo, X., Xu, S., Xu, J., "Restart strategy for sensorless pmsm drive system based on zero-voltage vector", IET Electric Power Applications, Vol. 14, No. 12, 2020, str. 2362–2369.

[95] Seo, D.-W., Bak, Y., Lee, K.-B., "An improved rotating restart method for a sensorless permanent magnet synchronous motor drive system using repetitive zero voltage vectors", IEEE Transactions on Industrial Electronics, Vol. 67, No. 5, 2019, str. 3496–3504.

[96] Choo, K.-M., Won, C.-Y., "Flying start of permanent magnet synchronous machine drives based on variable virtual resistance", IEEE Transactions on Industrial Electronics, 2020.

[97] Wang, C., Gou, L., Dong, S., Zhou, M., You, X., "Sensorless control of ipmsm based on super-twisting sliding mode observer with cvgi considering flying start", IEEE Transactions on Transportation Electrification, 2021.

[98] Liu, T., Fang, J., Xi, J., "Sensorless finite control set model predictive control with rotating restart strategy for pmsm drive system", in 2020 IEEE 9th International Power Electronics and Motion Control Conference (IPEMC2020-ECCE Asia). IEEE, 2020, str. 2239–2246.

[99] Zhou, J., Huang, K., Lei, Z., Huang, S., Wu, H., "Restart strategy of permanent magnet synchronous motor in flux-weakening filed", in 2021 IEEE 4th International Electrical and Energy Conference (CIEEC). IEEE, 2021, str. 1–6.

[100] Gao, W., Wang, Y., Homaifa, A., "Discrete-time variable structure control systems", IEEE transactions on Industrial Electronics, Vol. 42, No. 2, 1995, str. 117–122.

[101] Rafaq, M. S., Jung, J.-W., "A comprehensive review of state-of-the-art parameter estimation techniques for permanent magnet synchronous motors in wide speed range", IEEE Transactions on Industrial Informatics, Vol. 16, No. 7, 2019, str. 4747–4758.

[102] Gieras, J. F., Santini, E., Wing, M., "Calculation of synchronous reactances of small permanent-magnet alternating-current motors: comparison of analytical approach and finite element method with measurements", IEEE Transactions on Magnetics, Vol. 34, No. 5, 1998, str. 3712–3720.

[103] Hwang, C., Chang, S., Pan, C., Chang, T., "Estimation of parameters of interior permanent magnet synchronous motors", Journal of magnetism and magnetic materials, Vol. 239, No. 1-3, 2002, str. 600–603.

[104] Meessen, K. J., Thelin, P., Soulard, J., Lomonova, E., "Inductance calculations of permanent-magnet synchronous machines including flux change and self-and cross-saturations", IEEE Transactions on Magnetics, Vol. 44, No. 10, 2008, str. 2324–2331.

[105] 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, 2003, str. 1264–1271.

[106] Gao, Y., Qu, R., Chen, Y., Li, J., Xu, W., "Review of off-line synchronous inductance measurement method for permanent magnet synchronous machines", in 2014 IEEE Conference and Expo Transportation Electrification Asia-Pacific (ITEC Asia-Pacific). IEEE, 2014, str. 1–6.

[107] "Ieee standard procedures for obtaining synchronous machine parameters by standstill frequency response testing", IEEE Std 115A-1987, 1987, str. 1-28.

[108] Vandoorn, T. L., Frederik, M., Vyncke, T. J., Melkebeek, J. A., Lataire, P., "Generation of multisinusoidal test signals for the identification of synchronous-machine parameters by using a voltage-source inverter", IEEE Transactions on Industrial Electronics, Vol. 57, No. 1, 2009, str. 430–439.

[109] Odhano, S. A., Pescetto, P., Awan, H. A. A., Hinkkanen, M., Pellegrino, G., Bojoi, R., "Parameter identification and self-commissioning in ac motor drives: A technology status review", IEEE Transactions on Power Electronics, Vol. 34, No. 4, 2018, str. 3603–3614.

[110] Dutta, R., Rahman, M., "A comparative analysis of two test methods of measuring d-and q-axes inductances of interior permanent-magnet machine", IEEE Transactions on Magnetics, Vol. 42, No. 11, 2006, str. 3712–3718.

[111]Gao, Y., Qu, R., Liu, Y., “An improved ac standstill method for inductance measurement of interior permanent magnet synchronous motors”, in 2013 International Conference on Electrical Machines and Systems (ICEMS). IEEE, 2013, str. 927–931.

[112] Jukić, F., Sumina, D., Pravica, L., Kuzle, I., “Practical approach for parameter determinations of interior permanent magnet generator”, in IEEE EUROCON 2017-17th International Conference on Smart Technologies. IEEE, 2017, str. 712–719.

[113] Armando, E., Bojoi, R. I., Guglielmi, P., Pellegrino, G., Pastorelli, M., “Experimental identification of the magnetic model of synchronous machines”, IEEE Transactions on Industry Applications, Vol. 49, No. 5, 2013, str. 2116–2125.

[114] Wang, G., Qu, L., Zhan, H., Xu, J., Ding, L., Zhang, G., Xu, D., “Self-commissioning of permanent magnet synchronous machine drives at standstill considering inverter nonlinearities”, IEEE Transactions on Power Electronics, Vol. 29, No. 12, 2014, str. 6615–6627.

[115] Odhano, S. A., Giangrande, P., Bojoi, R. I., Gerada, C., “Self-commissioning of interior permanent-magnet synchronous motor drives with high-frequency current injection”, IEEE Transactions on Industry Applications, Vol. 50, No. 5, 2014, str. 3295–3303.

[116] Hinkkanen, M., Pescetto, P., Mölsä, E., Saarakkala, S. E., Pellegrino, G., Bojoi, R., “Sensorless self-commissioning of synchronous reluctance motors at standstill without rotor locking”, IEEE Transactions on Industry Applications, Vol. 53, No. 3, 2016, str. 2120–2129.

[117] Pescetto, P., Pellegrino, G., “Sensorless standstill commissioning of synchronous reluctance machines with automatic tuning”, in 2017 IEEE International Electric Machines and Drives Conference (IEMDC). IEEE, 2017, str. 1–8.

[118] Pescetto, P., Pellegrino, G., “Determination of pm flux linkage based on minimum saliency tracking for pm-syr machines without rotor movement”, IEEE Transactions on Industry Applications, Vol. 56, No. 5, 2020, str. 4924–4933.

[119] Awan, H. A. A., Song, Z., Saarakkala, S. E., Hinkkanen, M., “Optimal torque control of saturated synchronous motors: Plug-and-play method”, IEEE Transactions on Industry Applications, Vol. 54, No. 6, 2018, str. 6110–6120.

[120] Underwood, S. J., Husain, I., “Online parameter estimation and adaptive control of permanent-magnet synchronous machines”, IEEE Transactions on Industrial Electronics, Vol. 57, No. 7, 2009, str. 2435–2443.

[121] Ramakrishnan, R., Islam, R., Islam, M., Sebastian, T., "Real time estimation of parameters for controlling and monitoring permanent magnet synchronous motors", in 2009 IEEE International Electric Machines and Drives Conference. IEEE, 2009, str. 1194–1199.

[122] Ichikawa, S., Tomita, M., Doki, S., Okuma, S., "Sensorless control of permanent-magnet synchronous motors using online parameter identification based on system identification theory", IEEE Transactions on Industrial Electronics, Vol. 53, No. 2, 2006, str. 363–372.

[123] Liu, J., Nian, H., Li, J., Zeng, R., "Sensorless control of pmsg for wind turbines based on the on-line parameter identification", in Electrical Machines and Systems, 2009. ICEMS 2009. International Conference on. IEEE, 2009, str. 1–6.

[124] Abbaszadeh, A., Khaburi, D. A., Rodríguez, J., "Predictive control of permanent magnet synchronous motor with non-sinusoidal flux distribution for torque ripple minimisation using the recursive least square identification method", IET Electric Power Applications, Vol. 11, No. 5, 2017, str. 847–856.

[125] Wang, G., Li, T., Zhang, G., Gui, X., Xu, D., "Position estimation error reduction using recursive-least-square adaptive filter for model-based sensorless interior permanent-magnet synchronous motor drives", IEEE transactions on industrial electronics, Vol. 61, No. 9, 2013, str. 5115–5125.

[126] Shi, Y., Sun, K., Huang, L., Li, Y., "Online identification of permanent magnet flux based on extended kalman filter for ipmsm drive with position sensorless control", IEEE Transactions on Industrial Electronics, Vol. 59, No. 11, 2012, str. 4169–4178.

[127] Otava, L., Buchta, L., "Permanent magnet synchronous motor stator winding fault detection", in Industrial Electronics Society, IECON 2016-42nd Annual Conference of the IEEE. IEEE, 2016, str. 1536–1541.

[128] Sim, H.-W., Lee, J.-S., Lee, K.-B., "On-line parameter estimation of interior permanent magnet synchronous motor using an extended kalman filter", Journal of Electrical Engineering and Technology, Vol. 9, No. 2, 2014, str. 600–608.

[129] Salvatore, L., Stasi, S., "Application of ekf to parameter and state estimation of pmsm drive", in IEE Proceedings B (Electric Power Applications), Vol. 139, No. 3. IET, 1992, str. 155–164.

[130] Rashed, M., MacConnell, P. F., Stronach, A. F., Acarnley, P., "Sensorless indirect-rotor-field-orientation speed control of a permanent-magnet synchronous motor with stator-resistance estimation", IEEE transactions on industrial electronics, Vol. 54, No. 3, 2007, str. 1664–1675.

[131] Liu, Y., Fang, J., Tan, K., Huang, B., He, W., "Sliding mode observer with adaptive parameter estimation for sensorless control of ipmsm", Energies, Vol. 13, No. 22, 2020, str. 5991.

[132] Zhang, X., Li, Z., "Sliding-mode observer-based mechanical parameter estimation for permanent magnet synchronous motor", IEEE Transactions on Power Electronics, Vol. 31, No. 8, 2015, str. 5732–5745.

[133] Feng, Y., Yu, X., Han, F., "High-order terminal sliding-mode observer for parameter estimation of a permanent-magnet synchronous motor", IEEE Transactions on industrial electronics, Vol. 60, No. 10, 2012, str. 4272–4280.

[134] Liu, K., Zhang, Q., Chen, J., Zhu, Z.-Q., Zhang, J., "Online multiparameter estimation of nonsalient-pole pm synchronous machines with temperature variation tracking", IEEE Transactions on Industrial Electronics, Vol. 58, No. 5, 2010, str. 1776–1788.

[135] Avdeev, A., Osipov, O., "Pmsm identification using genetic algorithm", in 2019 26th International Workshop on Electric Drives: Improvement in Efficiency of Electric Drives (IWED). IEEE, 2019, str. 1–4.

[136] Liu, Z.-H., Li, X.-H., Zhang, Y.-J. *et al.*, "Cooperative particle swarm optimization with ics and its application to parameter identification of pmsm", in 2012 7th IEEE Conference on Industrial Electronics and Applications (ICIEA). IEEE, 2012, str. 1303–1308.

[137] Odhano, S. A., Bojoi, R., Armando, E., Homrich, G., Flores Filho, A. F., Popescu, M., Dorrell, D. G., "Identification of three-phase ipm machine parameters using torque tests", IEEE Transactions on Industry Applications, Vol. 53, No. 3, 2016, str. 1883–1891.

[138] Jerčić, T., Žarko, D., "A survey of permanent magnet synchronous machine models suitable for computer simulation", in 2017 19th International Conference on Electrical Drives and Power Electronics (EDPE). IEEE, 2017, str. 307–312.

[139] Zhongxiang, H., Lei, Z., Zhiqiang, J., Rui, Z., "Rotor position estimation based on modified sliding mode observer for sensorless permanent magnet synchronous motor", in 2017 IEEE Transportation Electrification Conference and Expo, Asia-Pacific (ITEC Asia-Pacific). IEEE, 2017, str. 1–6.

[140] Jukić, F., Pravica, L., Stipetić, S., "Sensorless synchronization method for a grid-side converter with an lcl filter based on a sliding mode observer and discontinuous operating mode", in 2022 International Conference on Electrical Machines (ICEM). IEEE, 2022, str. 1300–1306.

Popis oznaka

Kratice

ADCanalogno-digitalna pretvorba

AFEaktivni ulazni stupanj

DACdigitalno-analogna pretvorba

DFIGdvostruko napajani asinkroni generator

DSPdigitalni sustav temeljen na mikrokontrolerima

DTCizravno upravljanje momentom

EESelektroenergetski sustav

EKFproširenI Kalmanov filtar

IGBTbipolarni tranzistor s izoliranom vratima

IPMSGsinkroni generator s unutarnjim permanentnim magnetima

MKEmetoda konačnih elemenata

MPCmodelsko prediktivno upravljanje

MPPTkrivulja maksimalne snage vjetroagregata

MTPAkrivulja maksimalnog momenta po struji

NPFniskopropusni filtar

PLLregulator u fazno zaključanoj petlji

PMSGsinkroni generator s permanentnim magnetima

PWMširinsko-impulsna modulacija

RFOCupravljanje orijentacijom rotorskog toka

SCIGkavezni asinkroni generator

SMOopserver u kliznom načinu rada

SPMSGsinkroni generator s površinskim permanentnim magnetima

SPWMsinusna širinsko-impulsna modulacija

STA *super-twisting* algoritam

SVPWMprostorno-vektorska širinsko-impulsna modulacija

SYPWMsimetrična širinsko-impulsna modulacija

THIPWMširinsko-impulsna modulacija s injektiranjem trećeg harmonika

VFvisoko frekvencijski

VOCupravljanje orijentacijom napona

VSSsustav s promjenjivom strukturom

WRIGklizno-kolutni asinkroni generator

WRSGsinkroni generator s uzbudnim namotom

Eksponenti

* referentna vrijednost

T eksponent aproksimativne funkcije induktiviteta

Indeksi

$_\delta$ poprečna os estimiranog rotirajućeg dvoosnog koordinatnog sustava

$_\gamma$ uzdužna os estimiranog rotirajućeg dvoosnog koordinatnog sustava

$_d$ uzdužna os rotirajućeg dvoosnog koordinatnog sustava

$_k$ vrijednost veličine u vremenski diskretnom k-tom trenutku

$_q$ poprečna os rotirajućeg dvoosnog koordinatnog sustava

$_x$ proizvoljni koordinatni sustav

$_{\alpha\beta}$ mirujući dvoosni koordinatni sustav

$_\alpha$ uzdužna os mirujućeg dvoosnog koordinatnog sustava

$_\beta$ poprečna os mirujućeg dvoosnog koordinatnog sustava

$_{\gamma\delta}$ estimirani rotirajući dvoosni koordinatni sustav

$_{aa}$, $_{bb}$, $_{cc}$ samoinduktiviteti u osima a, b i c

$_{abc}$ mirujući troosni koordinatni sustav

$_{ab}$, $_{ba}$ magnetska sprega između osi a i b

$_{ac}$, $_{ca}$ magnetska sprega između osi a i c

$_a$ a-os mirujućeg troosnog koordinatnog sustava

$_{bc}$, $_{cb}$ magnetska sprega između osi b i c

$_b$	b-os mirujućeg troosnog koordinatnog sustava
$_c$	c-os mirujućeg troosnog koordinatnog sustava
$_{dq}$	rotirajući dvoosni koordinatni sustav

Matematičke veličine

$\boldsymbol{\epsilon}$	rezidualni vektor
$\boldsymbol{X}$	matrica regresije
$\boldsymbol{y}$	vektor mjerenih veličina
Δ	parametar zaobljenja signum funkcije
$\mathbf{A}$	matrica sustava
$\mathbf{a}$	vektor u smjeru osi b
$\mathbf{a}^2$	vektor u smjeru osi c
$\mathbf{A}_d$	diskretizirana matrica sustava
$\mathbf{B}$	matrica ulaza
$\mathbf{B}_d$	diskretizirana matrica ulaza
$\mathbf{C}$	Clarkina transformacija
$\mathbf{C}^{-1}$	inverzna Clarkina transformacija
$\mathbf{I}$	jedinična matrica 2x2
$\mathbf{J}$	matrica rotacije 2x2
$\mathbf{j}$	imaginarna jedinica
$\mathbf{K}_c$	pojačanje upravljačkog zakona pri trajnom radu pretvarača
$\mathbf{K}_d$	pojačanje upravljačkog zakona pri isprekidanom radu pretvarača
$\mathbf{k}_{1c}$	proporcionalno pojačanje STA algoritma pri trajnom radu pretvarača
$\mathbf{k}_{1d}$	proporcionalno pojačanje STA algoritma pri isprekidanom radu pretvarača
$\mathbf{k}_{2c}$	integralno pojačanje STA algoritma pri trajnom radu pretvarača
$\mathbf{k}_{2d}$	integralno pojačanje STA algoritma pri isprekidanom radu pretvarača
$\mathbf{P}(\theta)$	Parkova transformacija
$\mathbf{P}^{-1}(\theta)$	inverzna Parkova transformacija
$\mathbf{S}$	matrica prekapčanja
$\mathbf{u}(t)$	vektor upravljačkog zakona

$\mathbf{u}_{eq}(t)$	vektor ekvivalentnog upravljačkog zakona
$e^{\mathrm{j}\theta}$	Eulerov operator
$s(\mathbf{x})$	klizna ploha
$s(t)$	funkcija prekapčanja
$u(t)$	upravljački zakon
u_{eq}	ekvivalentni upravljački zakon
$V(t)$	Ljapunovljeva funkcija

Elektromagnetske veličine

$\bar{\theta}_{re}$	električni kut između γ- i d-osi PMSG-a
$\bar{i}$	komponenta greške estimirane struje PMSG-a u određenoj osi
$\bar{\boldsymbol{i}}$	vektor greške estimirane struje PMSG-a
$\hat{\boldsymbol{i}}$	vektor estimirane struje PMSG-a
$\boldsymbol{\psi}$	vektor magnetskog toka PMSG-a
$\boldsymbol{\psi}^{AF}$	vektor aktivnog magnetskog toka PMSG-a
$\boldsymbol{\psi}_r^{AF}$	vektor aktivnog rotorskog magnetskog toka PMSG-a
$\boldsymbol{\psi}_r$	vektor rotorskog magnetskog toka PMSG-a
$\boldsymbol{\rho}$	vektor perturbacije
$\boldsymbol{e}$	vektor induciranog napona PMSG-a
$\boldsymbol{e}^{AF}$	vektor aktivnog induciranog napona PMSG-a
$\boldsymbol{i}$	vektor struje PMSG-a
$\boldsymbol{L}$	matrica induktiviteta PMSG-a
$\boldsymbol{u}$	vektor napona PMSG-a
$\boldsymbol{u}_m$	vektor mrežnog napona
$\boldsymbol{u}_{0-7}$	naponski vektori na izlazu AC-DC-AC pretvarača
$\boldsymbol{z}$	vektor upravljačkog zakona
$\cos\varphi_n$	nazivni faktor snage PMSG-a
ΔL	promjena induktiviteta u određenoj osi PMSG-a
ΔR_s	promjena statorskog otpora PMSG-a
γ	kut opterećenja PMSG-a

$\hat{\omega}_{re}$	estimirana električna brzina vrtnje rotora PMSG-a
$\hat{\theta}_{re}$	estimirani električni kut rotora PMSG-a
$\hat{i}$	komponenta estimirane struje PMSG-a u određenoj osi
$\hat{L}$	estimirani induktivitet u određenoj osi PMSG-a
$\hat{R}_s$	estimirani statorski otpor PMSG-a
ω_{re}	električna brzina vrtnje rotora PMSG-a
ψ	komponenta magnetskog toka PMSG-a u određenoj osi
ψ^{AF}	komponenta aktivnog magnetskog toka PMSG-a u određenoj osi
ψ_r^{AF}	aktivni tok magneta rotora PMSG-a
ψ_r	tok magneta rotora PMSG-a
ρ	komponenta perturbacije u određenoj osi
θ_{re}	električni kut rotora PMSG-a
ε	ulaz u PLL regulator
a_{d0}	recipročna vrijednost nezasićenog induktiviteta u d-osi
a_{q0}	recipročna vrijednost nezasićenog induktiviteta u q-osi
a_{qq}	koeficijent zasićenja induktiviteta u q-osi
D	faktor vođenja IGBT-a
e	komponenta induciranog napona PMSG-a u određenoj osi
e^{AF}	komponenta aktivnog induciranog napona PMSG-a u određenoj osi
f	frekvencija PMSG-a
f_n	nazivna frekvencija PMSG-a
i	komponenta struje PMSG-a u određenoj osi
I_m	amplituda vektora struje PMSG-a
I_n	nazivna struja PMSG-a
K_{pd}	proporcionalno pojačanje PI regulatora struje u d-osi
K_{pq}	proporcionalno pojačanje PI regulatora struje u q-osi
L	induktivitet u određenoj osi PMSG-a
L_0	srednja vrijednost induktiviteta PMSG-a
L_Δ	amplituda oscilacija induktiviteta PMSG-a
L_A	pomoćni induktivitet određen konstrukcijom PMSG-a

L_B	pomoćni induktivitet određen konstrukcijom PMSG-a
m	faktor modulacije
M_{em}	elektromehanički moment PMSG-a
P	snaga PMSG-a
P_n	nazivna snaga PMSG-a
R_s	statorski otpor PMSG-a
T_k	vrijeme trajanje k-tog naponskog vektora na izlazu AC-DC-AC pretvarača
T_{id}	integralna vremenska konstanta PI regulatora struje u d-osi
T_{iq}	integralna vremenska konstanta PI regulatora struje u q-osi
T_{sw}	vrijeme trajanje jednog ciklusa PWM-a
T_s	vrijeme diskretizacije
u	komponenta napona PMSG-a u određenoj osi
U_m	amplituda vektora napona PMSG-a
u_m	komponenta mrežnog napona u određenoj osi
U_n	nazivni napon PMSG-a
U_{dc}	napon istosmjernog međukruga
U_{max}	maksimalni napon na izlazu AC-DC-AC pretvarača
z	komponenta upravljačkog zakona u određenoj osi

Mehaničke veličine

β	kut zakreta lopatica vjetroturbine
$\ddot{x}$	ubrzanje mase
$\dot{x}$	brzina mase
λ	omjer obodne brzine vjetroturbine i brzine vjetra ispred vjetroturbine
μ	koeficijent trenja
ω	brzina vrtnje vjetroturbine
ω_{opt}	optimalna brzina vrtnje vjetroturbine
ω_r	mehanička brzina vrtnje rotora PMSG-a
θ_r	mehanički kut rotora PMSG-a
b	sila trenja

C_P	koeficijent snage vjetroturbine
k	krutost opruge
K_{opt}	koeficijent optimalnog momenta vjetroturbine
M_t	moment vjetroturbine
$M_{t,opt}$	optimalni moment vjetroturbine
n_n	nazivna brzina PMSG-a
p	broj pari polova PMSG-a
P_t	snaga vjetroturbine
P_{vj}	snaga vjetra
R	radijus vjetroturbine
v_{vj}	brzina vjetra
x	položaj mase

Popis slika

1.1. Instalirana električna snaga iz obnovljivih izvora energije u razdoblju od 2000. do 2025. 1

2.1. Općenita struktura sustava za pretvorbu energije vjetra 9
2.2. Konvencionalne vrste vjetroagregata 12
2.3. Aktuatorski disk u struji zraka [27] 13
2.4. Koeficijent snage C_P u ovisnosti o koeficijentu λ i kutu zakreta lopatica β . . .16
2.5. Statička karakteristika vjetroturbine pri pasivnoj regulaciji 17
2.6. Optimalno upravljanje vjetroagregata ispod nazivne brzine vjetra održavanjem optimalnog iznosa koeficijenta $\lambda = \lambda_{opt}$ 20
2.7. Struktura optimalnog upravljanja momentom vjetroagregata [27] 21
2.8. Statičke karakteristike vjetroturbine 21
2.9. Poprečni presjeci rotora četveropolnog PMSG-a 22
2.10. Koordinatni sustavi četveropolnog PMSG-a 23
2.11. Formiranje rotirajućeg prostornog vektora 25
2.12. Clarkina transformacija 27
2.13. Parkova transformacija 28
2.14. Vektorski dijagram PMSG-a 35
2.15. Radno područje PMSG-a 37
2.16. Struktura trofaznog dvorazinskog energetskog AC-DC-AC pretvarača 38
2.17. Struktura vektorskog upravljanja PMSG-om temeljena na RFOC algoritmu . .40
2.18. Struktura upravljanja tokom radne i jalove snage prema EES-u temeljena na VOC algoritmu 41
2.19. Sklopna stanja IGBT tranzistora pri metodi šest koraka 42
2.20. Formiranje naponskih vektora korištenjem SVPWM modulaciju 43
2.20. Formiranje naponskih vektora koristeći SVPWM modulaciju 44
2.21. Primjer vođenja tranzistora prema SVPWM za vektor napona $\boldsymbol{u}$ u sektoru **I** . .46

3.1. Dinamički sustav mase i opruge s Coulombovim trenjem 47
3.2. Fazni portret i trajektorije sustava mase i opruge s Coulombovim trenjem . . .49

3.3. Silazni DC-DC pretvarač 50
3.4. Fazni portret silaznog DC-DC pretvarača u kliznom režimu 51
3.5. Uvjeti postojanja kliznog režima 55
3.6. Grafički prikaz linearnog i diskontinuiranog dijela upravljačkog zakona 59
3.7. Vrste kliznih režima 60
3.8. Shema upravljanja silaznim DC-DC pretvaračem temeljeno na kliznom režimu63
3.9. Upravljanje naponom kondenzatora silaznog DC-DC pretvarača uz $m < b$ . . .63
3.10. Upravljanje naponom kondenzatora silaznog DC-DC pretvarača uz $m > b$ . . .64
3.11. Vrste opservera 65
3.12. Opserver u kliznom načinu rada za estimaciju izlaznog napona silaznog DC-DC pretvarača 69

4.1. Principna shema laboratorijskog postava 72
4.2. Asinkroni stroj (lijevo) i PMSG (desno) 73
4.3. Pretvarači za asinkroni stroj i PMSG 73
4.4. Upravljački dio pretvarača *Open4Lab* 75
4.5. Grafičko sučelje programskog okruženja *Code Composer Studio* 76
4.6. Struktura projekta s razvijenim algoritmima u *Code Composer Studio*-u 76
4.7. Mjerna oprema 77

5.1. Podjela metoda za estimaciju kuta i brzine rotora PMSG-a 81
5.2. Struktura bezsenzorskog upravljanja PMSG-a temeljena na SMO-u 95
5.3. Struktura estimacije kuta i brzine vrtnje rotora PMSG-a temeljena na SMO-u i PLL regulatoru 97
5.4. Odzivi za estimacijsku strukturu temeljenoj na SMO-u u $\gamma\delta$ sustavu i signum funkciji 102
5.5. Odzivi za estimacijsku strukturu temeljenoj na SMO-u u $\gamma\delta$ sustavu i sigmoidnoj funkciji 103
5.6. Odzivi za estimacijsku strukturu temeljenoj na SMO-u u $\gamma\delta$ sustavu i STA algoritmu 104
5.7. Usporedba odziva estimirane brzine vrtnje i kuta rotora za estimacijsku strukturu sa SMO-om u $\alpha\beta$ i $\gamma\delta$ sustavu 105
5.8. Usporedba zauzeća procesora pri korištenju različitih bezsenzorskih algoritama upravljanja temeljenih na SMO-u 105

6.1. Struja i inducirani napon u α-osi PMSG-a tijekom isprekidanog načina rada pretvarača 111
6.2. Struktura za bezsenzorski leteći start i trajni rad PMSG-a temeljena na SMO-u .119

6.3. Struktura za estimacije kuta i brzine vrtnje PMSG-a temeljena na SMO-u i PLL-u prilagođena isprekidanom načinu rada 120
6.4. Pomak između estimiranog i stvarnog induciranog napona PMSG-a uzrokovan razlikom modela SMO-a i modela stroja pri isprekidanom radu pretvarača . . .121
6.5. Leteći start s estimacijskom strukturom temeljenoj na SMO-u u $\alpha\beta$ sustavu i signum funkciji 124
6.6. Leteći start s estimacijskom strukturom temeljenoj na SMO-u u $\alpha\beta$ sustavu i sigmoidnoj funkciji 125
6.7. Leteći start s estimacijskom strukturom temeljenoj na SMO-u u $\alpha\beta$ sustavu i STA algoritmu 126
6.8. Leteći start s estimacijskom strukturom temeljenoj na SMO-u u $\gamma\delta$ sustavu i signum funkciji 128
6.9. Leteći start s estimacijskom strukturom temeljenoj na SMO-u u $\gamma\delta$ sustavu i sigmoidnoj funkciji 129
6.10. Leteći start s estimacijskom strukturom temeljenoj na SMO-u u $\gamma\delta$ sustavu i STA algoritmu 130

7.1. Podjela metoda za identifikaciju parametara PMSG-a 132
7.2. Krivulja magnetiziranja željeza 137
7.3. Ovisnosti induktiviteta o strujama u d i q-osi 137
7.4. Dijagram toka za određivanje statorskog otpora i koeficijenata a_{d0}, a_{q0} i a_{qq} . .141
7.5. Bezsenzorska struktura upravljanja PMSG-a s implementiranom funkcijom za adaptaciju poprečnog induktiviteta u svrhu smanjenja greške estimiranog kuta rotora PMSG-a 144
7.6. Mape tokova i momenta proračunate MKE metodom korištene u simulacijama .145
7.7. Simulacijski odzivi histereznog upravljanja strujama generatora PMSG1 146
7.8. Usporedba aproksimiranog i stvarnog poprečnog induktiviteta za PMSG1 . . .147
7.9. Usporedba aproksimiranog i stvarnog poprečnog induktiviteta za PMSG2 . . .147
7.10. Simulacijski odzivi bezsenzorske strukture upravljanja temeljene na SMO-u s implementiranom funkcijom za adaptaciju poprečnog induktiviteta 149
7.11. Smanjenje greške estimiranog kuta rotora adaptacijom induktiviteta SMO-a u $\gamma\delta$ sustavu 152
7.12. Smanjenje greške estimiranog kuta rotora adaptacijom induktiviteta SMO-a u $\alpha\beta$ sustavu 153

Popis tablica

4.1. Nazivni podaci strojeva i pretvarača laboratorijskog postava 74
4.2. Nazivni podaci mjerne opreme 78

5.1. Matrice stanja i ulaza te vektor aktivnog induciranog napona PMSG-a za $\alpha\beta$ i $\gamma\delta$ koordinatni sustav 88
5.2. Diskretne matrice stanja i ulaza PMSG-a za $\alpha\beta$ i $\gamma\delta$ koordinatni sustav 88
5.3. Opći uvjeti dohvaćanja i postojanja kliznog režima prvog reda u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu 92
5.4. Opći izrazi perturbacija u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu 94
5.5. Bazne vrijednosti PMSG-a i parametri nadomjesne sheme PMSG-a u sustavu jediničnih vrijednosti 97
5.6. Ograničenja pojačanja upravljačkih funkcija SMO-a u $\gamma\delta$ koordinatnom sustavu98
5.7. Odabrana pojačanja upravljačkih funkcija SMO-a u $\gamma\delta$ koordinatnom sustavu .98
5.8. Pojačanja PI i PLL regulatora 99
5.9. Ograničenja pojačanja upravljačkih funkcija SMO-a u $\alpha\beta$ koordinatnom sustavu100
5.10. Odabrana pojačanja upravljačkih funkcija SMO-a u $\alpha\beta$ koordinatnom sustavu .100

6.1. Diskretne matrice stanja i ulaza PMSG-a za $\alpha\beta$ i $\gamma\delta$ koordinatni sustav u isprekidanom načinu rada pretvarača 113
6.2. Opći uvjeti dohvaćanja i postojanja kliznog režima prvog reda u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu u isprekidanom načinu rada pretvarača 115
6.3. Opći izrazi perturbacija u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu u isprekidanom načinu rada pretvarača 116
6.4. Uvjeti postojanja i stabilnosti SMO-a u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu za isprekidani i trajni način rada 117
6.5. Ograničenja pojačanja upravljačkih funkcija SMO-a u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu za isprekidani način rada pretvarača 122
6.6. Odabrana pojačanja upravljačkih funkcija SMO-a u $\alpha\beta$ i $\gamma\delta$ koordinatnom sustavu za isprekidani način rada pretvarača 122

7.1. Nazivne i bazne vrijednosti generatora PMSG1 i PMSG2 144
7.2. Parametri aproksimativnih funkcija uzdužnog i poprečnog induktiviteta izračunati pomoću simulacijskih odziva 146
7.3. Izračunati parametri aproksimativnih funkcija uzdužnog i poprečnog induktiviteta preko eksperimentalnih odziva 150

Prilog - Izvedba predloženih metoda u programskom jeziku C

Poglavlje 5 i 6 - Izvedba SMO-a u programskom jeziku C

Definicija nazivnih i baznih vrijednosti PMSG-a – *motor_defs.h*

```
.
.
.
/* Motorparameters - ratedvalues */
#define MOTOR_PP        2/              *!<Polepairs */
#define MOTOR_I         11.6f/          *!<RMScurrentinA */
#define MOTOR_FREQ      50.0f/          *!<FrequencyinHz */
#define MOTOR_PSI_R     0.92f/          *!<PermanentmagnetfluxinWb */
#define MOTOR_R         0.894f/         *!<PhaseresistanceinOhm */
#define MOTOR_LD        0.00238f/       *!<d-axisinductancefrommappinginH */
#define MOTOR_LQ        0.0653f/        *!<q-axisinductancefrommappinginH */

/* Motorparameters - basevalues */
#define MOTOR_PSI_B     0.92f/          *!<BasepermanentmagnetfluxinWb */
#define MOTOR_W_B       314.1593f/      *!<Baseangularvelocity - 2*pi * MOTOR_FREQ */
#define MOTOR_U_B       289.0265f/      *!<Basevoltage - MOTOR_PSI_B * MOTOR_W_B */
#define MOTOR_I_B       16.4049f/       *!<Basecurrent - MOTOR_I * sqrt(2) */
#define MOTOR_Z_B       17.6183f/       *!<BaseimpedanceinOhm - MOTOR_U_B/MOTOR_I_B */
#define MOTOR_L_B       0.0561f/        *!<BaseinductanceinH - MOTOR_Z_B/MOTOR_W_B */
#define MOTOR_R_B       17.6183f/       *!<BaseresistanceinOhm - MOTOR_Z_B/MOTOR_W_B
*/

/* Motorparametersp.u.values */
#define MOTOR_R_PU      0.0507f/        *!<MOTOR_R/MOTOR_R_B */
#define MOTOR_LD_PU     0.4238f/        *!<MOTOR_LD/MOTOR_L_B */
#define MOTOR_LQ_PU     1.1636f/        *!<MOTOR_LQ/MOTOR_L_B */
#define MOTOR_PSI_R_PU  1.0f/           *!<MOTOR_PSI_R/MOTOR_PSI_B */
.
.
.
```

Deklaracija struktura i funkcije SMO-a i upravljačkih funkcija – *smo_lib.h*

```
#include"DSP2834x_Device.h"//DSP2834xHeaderfileIncludeFile

#ifndefSMO_LIB_H_
#defineSMO_LIB_H_

#defineSMO_AB_SIGN    1
#defineSMO_AB_QUASI   2
#defineSMO_AB_STA     3
#defineSMO_GD_SIGN    4
#defineSMO_GD_QUASI   5
#defineSMO_GD_STA     6

#defineDISCONT        0
#defineCONT           1
.
.
.
/**
* \briefSMOestimationparametersstructure
*/
typedefstructstr_smo_param
{
   floatk_discont_ab;/      *!<\briefSMO_SIGN_ABgainindisc.mode          */
   floatk_cont_ab;/         *!<\briefSMO_SIGN_ABgainincont.mode          */
   floatk_discont_gd;/      *!<\briefSMO_SIGN_gdgainindisc.mode          */
   floatk_cont_gd;/         *!<\briefSMO_SIGN_gdgainincont.mode          */

   floatdelta;/             *!<\briefSMO_SIGN_QUASIdelta       */

   floatk1_sta_disc_ab;/    *!<\briefSMO_STA_ABsignumfunctiongainindisc.mode          */
   floatk2_sta_disc_ab;/    *!<\briefSMO_STA_ABintegratorgainindisc.mode          */
   floatk1_sta_cont_ab;/    *!<\briefSMO_STA_ABsignumfunctiongainincont.mode          */
   floatk2_sta_cont_ab;/    *!<\briefSMO_STA_ABintegratorgainincont.mode          */

   floatk1_sta_disc_gd;/    *!<\briefSMO_STA_gdsignumfunctiongainindisc.mode          */
   floatk2_sta_disc_gd;/    *!<\briefSMO_STA_gdintegratorgainindisc.mode          */
   floatk1_sta_cont_gd;/    *!<\briefSMO_STA_gdsignumfunctiongainincont.mode          */
   floatk2_sta_cont_gd;/    *!<\briefSMO_STA_gdintegratorgainincont.mode          */
} smo_param_t;

/**
* \briefSMO_abstructure
*/
typedefstructstr_smo_ab
{
   floatin_ia;/             *!<\briefAlphaaxiscomponentofcurrentsignal          */
   floatin_ib;/             *!<\briefBetaaxiscomponentofcurrentsignal          */
   floatin_ua;/             *!<\briefAlphaaxiscomponentofvoltagesignal          */
   floatin_ub;/             *!<\briefBetaaxiscomponentofvoltagesignal          */
   floatin_za;/             *!<\briefAlphaaxiscomponentofswitchingfunction          */
   floatin_zb;/             *!<\briefBetaaxiscomponentofswitchingfunction          */

   floatLq_from_map;/       *!<\briefQuadratureaxisinductancefromlookuptable          */
```

```
    float ia_est;/          *!<\brief Estimated alpha axis component of current signal */
    float ia_est_prev;/     *!<\brief Estimated alpha axis component of current signal
                            from previous step */
    float ib_est;/          *!<\brief Estimated beta axis component of current signal */
    float ib_est_prev;/     *!<\brief Estimated beta axis component of current signal
                            from previous step */

    float out_ia_err;/      *!<\brief Difference betwee nestimated and measured alpha axis
                            component of current signal */
    float out_ib_err;/      *!<\brief Difference betwee nestimated and measured beta axis
                            component of current signal */

    float t_samp;/          *!<\brief Sampling time */

    void (*init)(struct str_smo_ab*, float);/ *!<\brief Pointer to initialization function */
    void (*calc)(struct str_smo_ab*, int, int);/ *!<\brief Pointer to calculation function */
} smo_ab_t;

/**
* \brief SMO_gd structure
*/
typedef struct str_smo_gd
{
    float in_ig;/           *!<\brief Gamma axis component of current signal */
    float in_id;/           *!<\brief Delta axis component of current signal */
    float in_ug;/           *!<\brief Gamma axis component of voltage signal */
    float in_ud;/           *!<\brief Delta axis component of voltage signal */
    float in_w_est;/        *!<\brief Estimated rotational speed */
    float in_zg;/           *!<\brief Gamma axis component of switching function */
    float in_zd;/           *!<\brief Delta axis component of switching function */

    float Lq_from_map;/     *!<\brief Quadrature axis inductance from look up table */

    float ig_est;/          *!<\brief Estimated gamma axis component of current signal */
    float ig_est_prev;/     *!<\brief Estimated gamma axis component of current signal from
                            previous step */
    float id_est;/          *!<\brief Estimated delta axis component of current signal */
    float id_est_prev;/     *!<\brief Estimated delta axis component of current signal from
                            previous step */

    float out_ig_err;/      *!<\brief Difference betwee nestimated and measured gamma axis
                            component of current signal */
    float out_id_err;/      *!<\brief Difference betwee nestimated and measured delta axis
                            component of current signal */

    float t_samp;/          *!<\brief Sampling time */

    void (*init)(struct str_smo_gd*, float);/ *!<\brief Pointer to initialization function */
    void (*calc)(struct str_smo_gd*, int, int);/ *!<\brief Pointer to calculation function */
} smo_gd_t;

/**
* \brief SMO_SIGN structure
*/
typedef struct str_smo_sign
{
```

```
    float in_i1_err;/          *!<\brief Alpha or gamma axis component of current signal          */
    float in_i2_err;/          *!<\brief Beta or delta axis component of current signal          */

    float k_discont_ab;/       *!<\brief SMO_SIGN gain for SMO_AB in disc. mode          */
    float k_cont_ab;/          *!<\brief SMO_SIGN gain for SMO_AB gain in cont. mode          */

    float k_discont_gd;/       *!<\brief SMO_SIGN gain for SMO_GD in disc. mode          */
    float k_cont_gd;/          *!<\brief SMO_SIGN gain for SMO_GD in cont. mode          */

    float k;

    float out_z1;/             *!<\brief Output signal in alpha or gamma axis          */
    float out_z2;/             *!<\brief Output signal in beta or delta axis          */

    void( *init)(struct str_smo_sign *,float,float,float,float);/          *!<\brief Pointer to
    initialization function */
    void( *calc)(struct str_smo_sign *,int,int);/     *!<\brief Pointer to calculation function
    */
} smo_sign_t;

/**
* \brief SMO__QUASI_SIGN structure
*/
typedef struct str_smo_quasi_sign
{
    float in_i1_err;/          *!<\brief Alpha or gamma axis component of current signal          */
    float in_i2_err;/          *!<\brief Beta or delta axis component of current signal          */

    float k_discont_ab;/       *!<\brief SMO_SIGN gain for SMO_AB in disc. mode          */
    float k_cont_ab;/          *!<\brief SMO_SIGN gain for SMO_AB gain in cont. mode          */
    float k_discont_gd;/       *!<\brief SMO_SIGN gain for SMO_GD gain in disc. mode          */
    float k_cont_gd;/          *!<\brief SMO_SIGN gain for SMO_GD gain in cont. mode          */
    float k;
    float delta;/              *!<\brief SMO_QUASI_SIGN delta       */

    float out_z1;/             *!<\brief Output signal in alpha or gamma axis          */
    float out_z2;/             *!<\brief Output signal in beta or delta axis          */

    void( *init)(struct str_smo_quasi_sign *,float,float,float,float,float);/          *!<\brief
    Pointer to initialization function       */
    void( *calc)(struct str_smo_quasi_sign *,int,int);/       *!<\brief Pointer to calculation
    function */
} smo_quasi_sign_t;

/**
* \brief SMO_STA structure
*/
typedef struct str_smo_sta
{
    float in_i1_err;/          *!<\brief Alpha or gamma axis component of current signal          */
    float in_i2_err;/          *!<\brief Beta or delta axis component of current signal          */

    float in_i1_sign_err;/     *!<\brief Signum function output signal in alpha or gamma axis
    */
    float in_i2_sign_err;/     *!<\brief Signum function output signal in beta or delta axis
    */
```

```
  float k1_discont_ab;/        *!<\brief SMO_STA_AB signum function gain in disc. mode          */
  float k2_discont_ab;/        *!<\brief SMO_STA_AB integrator gain in disc. mode          */
  float k1_cont_ab;/           *!<\brief SMO_STA_AB signum function gain in cont. mode          */
  float k2_cont_ab;/           *!<\brief SMO_STA_AB integrator gain in cont. mode          */
  float k1_discont_gd;/        *!<\brief SMO_STA_GD signum function gain in disc. mode          */
  float k2_discont_gd;/        *!<\brief SMO_STA_GD integrator gain in disc. mode          */
  float k1_cont_gd;/           *!<\brief SMO_STA_GD signum function gain in cont. mode          */
  float k2_cont_gd;/           *!<\brief SMO_STA_GD integrator gain in cont. mode          */
  float k1;
  float k2;

  float integrator1;/          *!<\brief SMO_STA integrator 1          */
  float integrator2;/          *!<\brief SMO_STA integrator 2          */

  float out_z1;/               *!<\brief Output signal in alpha or beta axis          */
  float out_z2;/               *!<\brief Output signal in beta or gamma axis          */

  float t_samp;/               *!<\brief Sampling time          */

  void( *init)(struct str_smo_sta *,float,float,float,float,float,float,float,float,float);
  /*!<\brief Pointer to initialization function          */
  void( *calc)(struct str_smo_sta *,int,int);/     *!<\brief Pointer to calculation
  function */
} smo_sta_t;

/**
* \brief PLL structure
*/
typedef struct str_pll
{
  float in_err;/               *!<\brief Estimated rotor angle error          */

  float kp;/                   *!<\brief Proportional gain          */
  float ti;/                   *!<\brief Integral gain          */
  float tf;/                   *!<\brief Low pass filter time constant for estimated
rotational speed    */
  float t_samp;/               *!<\brief Sampling time          */

  float out_w_est;/            *!<\brief Estimated rotational speed          */
  float out_theta_est;/        *!<\brief Estimated angle          */

  void( *init)(struct str_pll *,float,float,float,float);/          *!<\brief Pointer to
  initialization function    */
  void( *calc)(struct str_pll *);/ *!<\brief Pointer to calculation function          */
} pll_t;

/* Function declarations    */
void smo_ab_init(smo_ab_t * str_smo_ab,float t_samp);
void smo_ab_calc(smo_ab_t * str_smo_ab,int discont_cont,int adapt_ind);
void smo_gd_init(smo_gd_t * str_smo_gd,float t_samp);
void smo_gd_calc(smo_gd_t * str_smo_gd,int discont_cont,int adapt_ind);
void smo_sign_init(smo_sign_t * str_smo_sign,float k_discont_ab,float k_cont_ab,float
k_discont_gd,float k_cont_gd);
void smo_sign_calc(smo_sign_t * str_smo_sign,int discont_cont,int smo_type);
void smo_quasi_sign_init(smo_quasi_sign_t * str_smo_quasi_sign,float k_discont_ab,float
```

```
k_cont_ab,floatk_discont_gd,floatk_cont_gd,floatdelta);
voidsmo_quasi_sign_calc(smo_quasi_sign_t * str_smo_quasi_sign,intdiscont_cont,int
smo_type);
voidsmo_sta_init(smo_sta_t * str_smo_sta,floatk1_discont_ab,floatk2_discont_ab,float
k1_cont_ab,floatk2_cont_ab,floatk1_discont_gd,floatk2_discont_gd,floatk1_cont_gd,float
k2_cont_gd,floatt_samp);
voidsmo_sta_calc(smo_sta_t * str_smo_sta,intdiscont_cont,intsmo_type);

#endif/ * CONTROL_LIB_H_ */
```

Definicija funkcija SMO-a i upravljačkih funkcija – *smo_lib.c*

```
#include"control_lib.h"
#include"smo_lib.h"

#include"extern_variables.h"
#include"motor_defs.h"
#include"epwm.h"
#include"math.h"

/**
* \briefInitializationfunctionforsmo_ab_paramsstructure
* \paramstr_smo_ab:SMO_abstructure
* \paramt_samp:Samplingtime
*/
voidsmo_ab_init(smo_ab_t * str_smo_ab,floatt_samp)
{
  str_smo_ab->t_samp = t_samp;
}

/**
* \briefSMOfunctioninalpha                    -betareferenceframe
* \paramstr_smo_ab:SMO_abstructure
* \paramdiscont_cont:0                 - disc.mode,1      - cont.mode
* \paramadapt_ind:0                 - constantLqused,1      - Lqadaptationon
*/
voidsmo_ab_calc(smo_ab_t * str_smo_ab,intdiscont_cont,intadapt_ind)
{
  floatmult,Lq;

  /* Setmultdependingondiscontinuous/continuousmodeofoperation              */
  if(DISCONT == discont_cont)
    mult = 0.0f;
  else
    mult = 1.0f;

  /* SetconstantLqvalueorreadLqfromlookuptable                */
  if(adapt_ind == 1)
    Lq = str_smo_ab->Lq_from_map;
  else
    Lq = MOTOR_LQ_PU;

  str_smo_ab->ia_est = (1.0f - mult * MOTOR_W_B * str_smo_ab->t_samp * MOTOR_R_PU / Lq)
                     * str_smo_ab->ia_est_prev
```

```
                    + mult * MOTOR_W_B * str_smo_ab->t_samp * str_smo_ab->in_ua / Lq
                    - MOTOR_W_B * str_smo_ab->t_samp * str_smo_ab->in_za / Lq;

  str_smo_ab->ib_est = (1.0f - mult * MOTOR_W_B * str_smo_ab->t_samp * MOTOR_R_PU / Lq)
                    * str_smo_ab->ib_est_prev
                    + mult * MOTOR_W_B * str_smo_ab->t_samp * str_smo_ab->in_ub / Lq
                    - MOTOR_W_B * str_smo_ab->t_samp * str_smo_ab->in_zb / Lq;

  str_smo_ab->out_ia_err = str_smo_ab->ia_est - str_smo_ab->in_ia;
  str_smo_ab->out_ib_err = str_smo_ab->ib_est - str_smo_ab->in_ib;

  /* Savecurrentvalues     */
  str_smo_ab->ia_est_prev = str_smo_ab->ia_est;
  str_smo_ab->ib_est_prev = str_smo_ab->ib_est;
}

/**
* \briefInitializationfunctionforsmo_gd_paramsstructure
* \paramstr_smo_gd:SMO_gdstructure
* \paramt_samp:Samplingtime
*/
voidsmo_gd_init(smo_gd_t * str_smo_gd,floatt_samp)
{
  str_smo_gd->t_samp = t_samp;
}

/**
* \briefSMOfunctioningamma                    -deltareferenceframe
* \paramstr_smo_gd:SMO_gdstructure
* \paramdiscont_cont:0                 - disc.mode,1      - cont.mode
* \paramadapt_ind:0                 - constantLqused,1       - Lqadaptationon
*/
voidsmo_gd_calc(smo_gd_t * str_smo_gd,intdiscont_cont,intadapt_ind)
{
  floatmult,Lq;

  /* Setmultdependingondiscontinuous/continuousmodeofoperation              */
  if(DISCONT == discont_cont)
    mult = 0.0f;
  else
    mult = 1.0f;

  /* SetconstantLqvalueorreadLqfromlookuptable                */
  if(adapt_ind == 1)
    Lq = str_smo_gd->Lq_from_map;
  else
    Lq = MOTOR_LQ_PU;

  str_smo_gd->ig_est = (1.0f - mult * MOTOR_W_B * str_smo_gd->t_samp * MOTOR_R_PU / Lq)
    * str_smo_gd->ig_est_prev
    + MOTOR_W_B * str_smo_gd->t_samp * str_smo_gd->in_w_est * str_smo_gd->id_est_prev
    + mult * MOTOR_W_B * str_smo_gd->t_samp * str_smo_gd->in_ug / Lq - MOTOR_W_B *
      str_smo_gd-> t_samp * str_smo_gd->in_zg / Lq;

  str_smo_gd->id_est = (1.0f - mult * MOTOR_W_B * str_smo_gd->t_samp * MOTOR_R_PU / Lq)
    *  str_smo_gd->id_est_prev
```

```
    - MOTOR_W_B * str_smo_gd->t_samp * str_smo_gd->in_w_est * str_smo_gd->ig_est_prev
    + mult * MOTOR_W_B * str_smo_gd->t_samp * str_smo_gd->in_ud / Lq - MOTOR_W_B *
      str_smo_gd-> t_samp * str_smo_gd->in_zd / Lq;

  str_smo_gd->out_ig_err = str_smo_gd->ig_est - str_smo_gd->in_ig;
  str_smo_gd->out_id_err = str_smo_gd->id_est - str_smo_gd->in_id;

  /* Savecurrentvalues     */
  str_smo_gd->ig_est_prev = str_smo_gd->ig_est;
  str_smo_gd->id_est_prev = str_smo_gd->id_est;
}

/**
* \briefInitializationfunctionforsmo_signstructure
* \paramstr_smo_sign:SMO_SIGNstructure
* \paramk_discont_ab:SMO_SIGNgaininalpha                    -betaframeanddisc.mode
* \paramk_cont_ab:SMO_SIGNgaininalpha                    -betaframeandcont.mode
* \paramk_discont_gd:SMO_SIGNgainingamma                    -deltaframeanddisc.mode
* \paramk_cont_gd:SMO_SIGNgainingamma                    -deltaframeandcont.mode
*/
voidsmo_sign_init(smo_sign_t * str_smo_sign,floatk_discont_ab,floatk_cont_ab,float
k_discont_gd,floatk_cont_gd)
{
  str_smo_sign->k_discont_ab = k_discont_ab;
  str_smo_sign->k_cont_ab = k_cont_ab;
  str_smo_sign->k_discont_gd = k_discont_gd;
  str_smo_sign->k_cont_gd = k_cont_gd;
}

/**
* \briefFunctionforcalculationswitchingvectorswithsignumfunction
* \paramstr_smo_sign:SMO_SIGNstructure
* \paramdiscont_cont:0                - disc.mode,1      - cont.mode
* \paramsmo_type:SMOtypeusedinestimation                    - 1=SMO_AB_SIGN,2=
                    SMO_AB_QUASI,3=SMO_AB_STA,4=SMO_GD_SIGN,5=SMO_GD_QUASI,6=
                    SMO_GD_STA
*/
voidsmo_sign_calc(smo_sign_t * str_smo_sign,intdiscont_cont,intsmo_type)
{
  /* Usedifferentgainsdependingondiscontinuous/continuousmodeofoperation          */
  if(DISCONT == discont_cont){
    /* Usedifferentgainsdependingonreferenceframe          */
    if((CW.smo_type == SMO_AB_SIGN) || (CW.smo_type == SMO_AB_QUASI) || (CW.smo_type ==
    SMO_AB_STA))
      str_smo_sign->k = str_smo_sign->k_discont_ab;
    else
      str_smo_sign->k = str_smo_sign->k_discont_gd;
  }
  else
  {
    /* Usedifferentgainsdependingonreferenceframe          */
    if((CW.smo_type == SMO_AB_SIGN) || (CW.smo_type == SMO_AB_QUASI) || (CW.smo_type ==
    SMO_AB_STA))
      str_smo_sign->k = str_smo_sign->k_cont_ab;
    else
      str_smo_sign->k = str_smo_sign->k_cont_gd;
```

```
    }

    str_smo_sign->out_z1 = str_smo_sign->k * ((str_smo_sign->in_i1_err > 0)
                    - (str_smo_sign->in_i1_err < 0));
    str_smo_sign->out_z2 = str_smo_sign->k * ((str_smo_sign->in_i2_err > 0)
                    - (str_smo_sign->in_i2_err < 0));
}

/**
* \briefInitializationfunctionforsmo_quasi_signstructure
* \paramstr_smo_quasi_sign:SMO_QUASI_SIGNstructure
* \paramk_discont_ab:SMO_QUASI_SIGNgaininalpha                    -betaframeanddisc.mode
* \paramk_cont_ab:SMO_QUASI_SIGNgaininalpha                    -betaframeandcont.mode
* \paramk_discont_gd:SMO_QUASI_SIGNgainingamma                    -deltaframeanddisc.mode
* \paramk_cont_gd:SMO_QUASI_SIGNgainingamma                    -deltaframeandcont.mode
* \paramdelta:SMO_QUASI_SIGNdelta
*/
voidsmo_quasi_sign_init(smo_quasi_sign_t * str_smo_quasi_sign,floatk_discont_ab,float
k_cont_ab,floatk_discont_gd,floatk_cont_gd,floatdelta)
{
    str_smo_quasi_sign->k_discont_ab = k_discont_ab;
    str_smo_quasi_sign->k_cont_ab = k_cont_ab;
    str_smo_quasi_sign->k_discont_gd = k_discont_gd;
    str_smo_quasi_sign->k_cont_gd = k_cont_gd;
    str_smo_quasi_sign->delta = delta;
}

/**
* \briefFunctionforcalculationswitchingvectorswithquasisignumfunction
* \paramstr_smo_quasi_sign:SMO_QUASI_SIGNstructure
* \paramdiscont_cont:0                - disc.mode,1      - cont.mode
* \paramsmo_type:SMOtypeusedinestimation                    - 1=SMO_AB_SIGN,2=
                    SMO_AB_QUASI,3=SMO_AB_STA,4=SMO_GD_SIGN,5=SMO_GD_QUASI,6=
                    SMO_GD_STA
*/
voidsmo_quasi_sign_calc(smo_quasi_sign_t * str_smo_quasi_sign,intdiscont_cont,int
smo_type)
{
    /* Usedifferentgainsdependingondiscontinuous/continuousmodeofoperation                */
    if(DISCONT == discont_cont){
        /* Usedifferentgainsdependingonreferenceframe            */
        if(CW.smo_type == SMO_AB_SIGN || CW.smo_type == SMO_AB_QUASI || CW.smo_type ==
        SMO_AB_STA)
            str_smo_quasi_sign->k = str_smo_quasi_sign->k_discont_ab;
        else
            str_smo_quasi_sign->k = str_smo_quasi_sign->k_discont_gd;
    }
    else
    {
        /* Usedifferentgainsdependingonreferenceframe            */
        if(CW.smo_type == SMO_AB_SIGN || CW.smo_type == SMO_AB_QUASI || CW.smo_type ==
        SMO_AB_STA)
            str_smo_quasi_sign->k = str_smo_quasi_sign->k_cont_ab;
        else
            str_smo_quasi_sign->k = str_smo_quasi_sign->k_cont_gd;
    }
```

```
  str_smo_quasi_sign->out_z1 = str_smo_quasi_sign->k * str_smo_quasi_sign->in_i1_err
       / (str_smo_quasi_sign->delta + fabsf(str_smo_quasi_sign->in_i1_err));
  str_smo_quasi_sign->out_z2 = str_smo_quasi_sign->k * str_smo_quasi_sign->in_i2_err
       / (str_smo_quasi_sign->delta + fabsf(str_smo_quasi_sign->in_i2_err));
}

/**
* \briefInitializationfunctionforsmo_stastructure
* \paramstr_smo_sta:SMO_STAstructure
* \paramk1_discont_ab:SMO_STAgaininalpha                    -betaframeanddisc.mode
* \paramk2_discont_ab:SMO_STAgaininalpha                    -betaframeanddisc.mode
* \paramk1_cont_ab:SMO_STAgaininalpha                    -betaframeandcont.mode
* \paramk2_cont_ab:SMO_STAgaininalpha                    -betaframeandcont.mode
* \paramk1_discont_gd:SMO_STAgainingamma                    -deltaframeanddisc.mode
* \paramk2_discont_gd:SMO_STAgainingamma                    -deltaframeanddisc.mode
* \paramk1_cont_gd:SMO_STAgainingamma                    -deltaframeandcont.mode
* \paramk2_cont_gd:SMO_STAgainingamma                    -deltaframeandcont.mode
* \paramt_samp:Samplingtime
*/
voidsmo_sta_init(smo_sta_t * str_smo_sta,floatk1_discont_ab,floatk2_discont_ab,
floatk1_cont_ab,floatk2_cont_ab,floatk1_discont_gd,floatk2_discont_gd,floatk1_cont_gd
,
floatk2_cont_gd,floatt_samp)
{
  str_smo_sta->k1_discont_ab = k1_discont_ab;
  str_smo_sta->k2_discont_ab = k2_discont_ab;
  str_smo_sta->k1_cont_ab = k1_cont_ab;
  str_smo_sta->k2_cont_ab = k2_cont_ab;

  str_smo_sta->k1_discont_gd = k1_discont_gd;
  str_smo_sta->k2_discont_gd = k2_discont_gd;
  str_smo_sta->k1_cont_gd = k1_cont_gd;
  str_smo_sta->k2_cont_gd = k2_cont_gd;
  str_smo_sta->t_samp = CNTRL_TS;
}

/**
* \briefFunctionforcalculationswitchingvectorswithSTAfunction
* \paramstr_smo_sta:SMO_STAstructure
* \paramdiscont_cont:0                    - disc.mode,1      - cont.mode
* \paramsmo_type:SMOtypeusedinestimation                              - 1=SMO_AB_SIGN,2=
                    SMO_AB_QUASI,3=SMO_AB_STA,4=SMO_GD_SIGN,5=SMO_GD_QUASI,6=
                    SMO_GD_STA
*/
voidsmo_sta_calc(smo_sta_t * str_smo_sta,intdiscont_cont,intsmo_type)
{
  /* Usedifferentgainsdependingondiscontinuous/continuousmodeofoperation                */
  if(DISCONT == discont_cont){
    /* Usedifferentgainsdependingonreferenceframe            */
    if(CW.smo_type == SMO_AB_SIGN || CW.smo_type == SMO_AB_QUASI || CW.smo_type ==
    SMO_AB_STA)
    {
      str_smo_sta->k1 = str_smo_sta->k1_discont_ab;
      str_smo_sta->k2 = str_smo_sta->k2_discont_ab;
    }
```

```
      else
      {
        str_smo_sta->k1 = str_smo_sta->k1_discont_gd;
        str_smo_sta->k2 = str_smo_sta->k2_discont_gd;
      }
    }
    else
    {
      /* Usedifferentgainsdependingonreferenceframe          */
      if(CW.smo_type == SMO_AB_SIGN || CW.smo_type == SMO_AB_QUASI || CW.smo_type ==
      SMO_AB_STA)
      {
        str_smo_sta->k1 = str_smo_sta->k1_cont_ab;
        str_smo_sta->k2 = str_smo_sta->k2_cont_ab;
      }
      else
      {
        str_smo_sta->k1 = str_smo_sta->k1_cont_gd;
        str_smo_sta->k2 = str_smo_sta->k2_cont_gd;
      }
    }

    str_smo_sta->integrator1 += str_smo_sta->k2 * str_smo_sta->t_samp
              * str_smo_sta->in_i1_sign_err;
    str_smo_sta->integrator2 += str_smo_sta->k2 * str_smo_sta->t_samp
              * str_smo_sta->in_i2_sign_err;

    str_smo_sta->out_z1 =  str_smo_sta->k1 * str_smo_sta->in_i1_sign_err
              * sqrtf(fabsf(str_smo_sta->in_i1_err)) + str_smo_sta->integrator1;
    str_smo_sta->out_z2 =  str_smo_sta->k1 * str_smo_sta->in_i2_sign_err
              * sqrtf(fabsf(str_smo_sta->in_i2_err)) + str_smo_sta->integrator2;
}
```

Estimacija kuta i brzine vrtnje PMSG-a pomoću SMO-a i PLL-a – *epwm_isr.c*

```
.
.
.
interruptvoidepwm1_timer_isr(void)
{
  .
  .
  .
  /* calculateSMO  */
  park_func.alpha = i_alpha_meas;
  park_func.beta = i_beta_meas;
  park_func.sin = theta_smo.sin;
  park_func.cos = theta_smo.cos;
  park_func.calc(&park_func);
  i_g_est = park_func.d;
  i_d_est = park_func.q;

  /* startSMOwhendisc.current>0.7          * ia_refandkeepworkingincont.mode          */
  if((ia_discont.out > 0.7f * ia_ref) || discontinuous_started || SW.epmw_mode)
```

```
{
  if((SMO_AB_SIGN == CW.smo_type) || (SMO_AB_QUASI == CW.smo_type) || (SMO_AB_STA ==
  CW.smo_type))
  {
    i1_meas = i_alpha_meas;
    i2_meas = i_beta_meas;
    i1_est = smo_ab.ia_est;
    i2_est = smo_ab.ib_est;
  }
  else
  {
    i1_meas = i_g_est;
    i2_meas = i_d_est;
    i1_est = smo_gd.ig_est;
    i2_est = smo_gd.id_est;
  }

  /* usingdifferentswitchingfunctions      - SIGN,QUASIorSTA      */
  switch(CW.smo_type)
  {
    caseSMO_AB_SIGN:
    smo_ab.in_ia = i_alpha_meas;
    smo_ab.in_ib = i_beta_meas;
    smo_ab.in_ua = u_alpha_est;
    smo_ab.in_ub = u_beta_est;

    smo_ab.in_za = smo_sign.out_z1;
    smo_ab.in_zb = smo_sign.out_z2;

    smo_ab_calc(&smo_ab, SW.epmw_mode, CW.adapt_ind);

    smo_sign.in_i1_err = smo_ab.out_ia_err;
    smo_sign.in_i2_err = smo_ab.out_ib_err;
    smo_sign_calc(&smo_sign, SW.epmw_mode, CW.smo_type);

    pll_ref_den = sqrtf(pow(smo_sign.out_z1,2) + pow(smo_sign.out_z2,2));
    if(pll_ref_den < 0.00000000001f)
    pll_ref_den = 0.00000000001f;

    /* shiftswitchingsignalzfor90degreesindiscontinuousmode          */
    if(SW.epmw_mode){
      park_func.d = smo_sign.out_z1;
      park_func.q = smo_sign.out_z2;
    }
    else{
      park_func.alpha = smo_sign.out_z1;
      park_func.beta = smo_sign.out_z2;
      park_func.sin = 1.0f;
      park_func.cos = 0.0f;
      park_func.calc(&park_func);
    }

    break;

    caseSMO_AB_QUASI:
    smo_ab.in_ia = i_alpha_meas;
```

```
        smo_ab.in_ib = i_beta_meas;
        smo_ab.in_ua = u_alpha_est;
        smo_ab.in_ub = u_beta_est;
        smo_ab.in_za = smo_quasi_sign.out_z1;
        smo_ab.in_zb = smo_quasi_sign.out_z2;
        smo_ab_calc(&smo_ab, SW.epmw_mode, CW.adapt_ind);

        smo_quasi_sign.in_i1_err = smo_ab.out_ia_err;
        smo_quasi_sign.in_i2_err = smo_ab.out_ib_err;
        smo_quasi_sign_calc(&smo_quasi_sign, SW.epmw_mode, CW.smo_type);

        /* QPLLforestimationofrotatinalspeedandposition            */
        /* avoiddivisionby0inline252          */
        pll_ref_den = sqrtf(pow(smo_quasi_sign.out_z1,2) + pow(smo_quasi_sign.out_z2,2));
        if(pll_ref_den < 0.00000000001f)
        pll_ref_den = 0.00000000001f;

        /* shiftswitchingsignalzfor90degreesindiscontinuousmode               */
        if(SW.epmw_mode){
          park_func.d = smo_quasi_sign.out_z1;
          park_func.q = smo_quasi_sign.out_z2;
        }
        else{
          park_func.alpha = smo_quasi_sign.out_z1;
          park_func.beta = smo_quasi_sign.out_z2;
          park_func.sin = 1.0f;
          park_func.cos = 0.0f;
          park_func.calc(&park_func);
        }

        break;

        caseSMO_AB_STA:
        smo_ab.in_ia = i_alpha_meas;
        smo_ab.in_ib = i_beta_meas;
        smo_ab.in_ua = u_alpha_est;
        smo_ab.in_ub = u_beta_est;

        smo_ab.in_za = smo_sta.out_z1;
        smo_ab.in_zb = smo_sta.out_z2;

        smo_ab_calc(&smo_ab, SW.epmw_mode, CW.adapt_ind);

        smo_sign.in_i1_err = smo_ab.out_ia_err;
        smo_sign.in_i2_err = smo_ab.out_ib_err;
        smo_sign_calc(&smo_sign, SW.epmw_mode, CW.smo_type);

        smo_sta.in_i1_err = smo_ab.out_ia_err;
        smo_sta.in_i2_err = smo_ab.out_ib_err;
        smo_sta.in_i1_sign_err = smo_sign.out_z1 / smo_sign.k;
        smo_sta.in_i2_sign_err = smo_sign.out_z2 / smo_sign.k;

        smo_sta_calc(&smo_sta, SW.epmw_mode, CW.smo_type);

        pll_ref_den = sqrtf(pow(smo_sta.out_z1,2) + pow(smo_sta.out_z2,2));
        if(pll_ref_den < 0.00000000001f)
```

```
        pll_ref_den = 0.00000000001f;

        /* shiftswitchingsignalzfor90degreesindiscontinuousmode                */
        if(SW.epmw_mode){
          park_func.d = smo_sta.out_z1;
          park_func.q = smo_sta.out_z2;
        }
        else{
          park_func.alpha = smo_sta.out_z1;
          park_func.beta = smo_sta.out_z2;
          park_func.sin = 1.0f;
          park_func.cos = 0.0f;
          park_func.calc(&park_func);
        }

        break;

        caseSMO_GD_SIGN:
        smo_gd.in_ig = i_g_est;
        smo_gd.in_id = i_d_est;
        smo_gd.in_ug = ug_ref;
        smo_gd.in_ud = ud_ref;

        smo_gd.in_zg = smo_sign.out_z1;
        smo_gd.in_zd = smo_sign.out_z2;

        smo_gd.in_w_est = we_smo.out;
        smo_gd_calc(&smo_gd, SW.epmw_mode, CW.adapt_ind);

        smo_sign.in_i1_err = smo_gd.out_ig_err;
        smo_sign.in_i2_err = smo_gd.out_id_err;
        smo_sign_calc(&smo_sign, SW.epmw_mode, CW.smo_type);

        filt_smo_sign_g.in = smo_sign.out_z1;
        filter_calc(&filt_smo_sign_g);
        filt_smo_sign_d.in = smo_sign.out_z2;
        filter_calc(&filt_smo_sign_d);

        /* shiftswitchingsignalzfor90degreesindiscontinuousmode                */
        if(SW.epmw_mode){
          park_func.d = filt_smo_sign_g.out;
          park_func.q = filt_smo_sign_d.out;
        }
        else{
          park_func.alpha = filt_smo_sign_g.out;
          park_func.beta = filt_smo_sign_d.out;
          park_func.sin = 1.0f;
          park_func.cos = 0.0f;
          park_func.calc(&park_func);
        }

        break;

        caseSMO_GD_QUASI:
        smo_gd.in_ig = i_g_est;
        smo_gd.in_id = i_d_est;
```

```
        smo_gd.in_ug = ug_ref;
        smo_gd.in_ud = ud_ref;

        smo_gd.in_zg = smo_quasi_sign.out_z1;
        smo_gd.in_zd = smo_quasi_sign.out_z2;

        smo_gd.in_w_est = we_smo.out;
        smo_gd_calc(&smo_gd, SW.epmw_mode, CW.adapt_ind);

        smo_quasi_sign.in_i1_err = smo_gd.out_ig_err;
        smo_quasi_sign.in_i2_err = smo_gd.out_id_err;
        smo_quasi_sign_calc(&smo_quasi_sign, SW.epmw_mode, CW.smo_type);

        filt_smo_sign_g.in = smo_quasi_sign.out_z1;
        filter_calc(&filt_smo_sign_g);
        filt_smo_sign_d.in = smo_quasi_sign.out_z2;
        filter_calc(&filt_smo_sign_d);

        /* shiftswitchingsignalzfor90degreesindiscontinuousmode              */
        if(SW.epmw_mode){
          park_func.d = filt_smo_sign_g.out;
          park_func.q = filt_smo_sign_d.out;
        }
        else{
          park_func.alpha = filt_smo_sign_g.out;
          park_func.beta = filt_smo_sign_d.out;
          park_func.sin = 1.0f;
          park_func.cos = 0.0f;
          park_func.calc(&park_func);
        }

        break;

        caseSMO_GD_STA:
        smo_gd.in_ig = i_g_est;
        smo_gd.in_id = i_d_est;
        smo_gd.in_ug = ug_ref;
        smo_gd.in_ud = ud_ref;

        smo_gd.in_zg = smo_sta.out_z1;
        smo_gd.in_zd = smo_sta.out_z2;

        smo_gd.in_w_est = we_smo.out;
        smo_gd_calc(&smo_gd, SW.epmw_mode, CW.adapt_ind);

        smo_sign.in_i1_err = smo_gd.out_ig_err;
        smo_sign.in_i2_err = smo_gd.out_id_err;
        smo_sign_calc(&smo_sign, SW.epmw_mode, CW.smo_type);

        smo_sta.in_i1_err = smo_gd.out_ig_err;
        smo_sta.in_i2_err = smo_gd.out_id_err;
        smo_sta.in_i1_sign_err = smo_sign.out_z1 / smo_sign.k;
        smo_sta.in_i2_sign_err = smo_sign.out_z2 / smo_sign.k;
        smo_sta_calc(&smo_sta, SW.epmw_mode, CW.smo_type);

        filt_smo_sign_g.in = smo_sta.out_z1;
```

```
        filter_calc(&filt_smo_sign_g);
        filt_smo_sign_d.in = smo_sta.out_z2;
        filter_calc(&filt_smo_sign_d);

        /* shiftswitchingsignalzfor90degreesindiscontinuousmode              */
        if(SW.epmw_mode){
          park_func.d = filt_smo_sign_g.out;
          park_func.q = filt_smo_sign_d.out;
        }
        else{
          park_func.alpha = filt_smo_sign_g.out;
          park_func.beta = filt_smo_sign_d.out;
          park_func.sin = 1.0f;
          park_func.cos = 0.0f;
          park_func.calc(&park_func);
        }

      }

      /* changePLLinputdependingonSMOtype          */
      if(CW.smo_type == SMO_AB_SIGN || CW.smo_type == SMO_AB_QUASI || CW.smo_type ==
      SMO_AB_STA)
      {
        pll_ref_den = sqrtf(pow(park_func.d,2) + pow(park_func.q,2));
        if(pll_ref_den < 0.00000000001f)
        pll_ref_den = 0.00000000001f;

        pi_pll.ref = (-park_func.d * theta_smo.cos - park_func.q * theta_smo.sin) /
  pll_ref_den;
      }
      /* forSMO_GDusedinestimation       */
      else
      {
        pi_pll.ref = -atan2(park_func.d,park_func.q);
      }
      pi_pll.fbk = 0.0f;

      /* estimaterotorspeedusingPLLPIcontroller          */
      pi_pll.calc(&pi_pll);
      discontinous_started = 1;
      we_smo.in = pi_pll.u_out;
      filter_calc(&we_smo);
    }

    elseif(ia_discont.out < 0.3f  *ia_ref) {
      pi_pll.reset(&pi_pll);
      discontinous_started = 0;
    }


    /* integrateestimatedspeedfromPLLtocalculateestimatedtheta              */
    theta_smo_unmod += MOTOR_W_B * pi_pll.u_out * CNTRL_TS;
    theta_smo.deg_value = theta_smo_unmod + 0.0f * we_smo.out * CNTRL_TS;
    theta_smo.deg_value = fmod(theta_smo.deg_value,TWO_PI);
    theta_smo.deg_value = fmod((theta_smo.deg_value + TWO_PI),TWO_PI) * 180.0f * ONE_OVER_PI
    ;
```

```
    theta_smo.raw_value = (Uint16)(theta_smo.deg_value * 1.42222222f);
    theta_smo.sin = (float)( *(sintab + theta_smo.raw_value));
    theta_smo.cos = (float)( *(sintab + theta_smo.raw_value + 128));

    theta_diff = fmod((theta_smo.deg_value - resolver_angle.deg_value + 360.0f),360.0f);

    theta_diff_filt.in = theta_diff;
    if(theta_diff > 180.0f)
    theta_diff_filt.in = theta_diff - 360.0f;
    filter_calc(&theta_diff_filt);
    .
    .
    .
    }
.
.
.
}
```

Izvedba isprekidanog načina rada pretvarača u programskom jeziku C

Postavljanje EPWM registra – *epwm1_isr.c*

```
.
.
.
interruptvoidepwm1_timer_isr(void)
{
    .
    .
    .
    /* handlecontinuous/discontinuousmode      */
    if(CW.enable_cont)
      CW.enable_discont = 0;

    /* continuousmode  - EPwm1RegsregisterissettocontrolbothIGBTs,theupperand
    thelowerone     */
    if(CW.enable_cont & !SW.epmw_mode){
      SW.epmw_mode = 1;
      EALLOW;
      EPwm1Regs.AQCTLA.bit.CAD = AQ_SET;
      EPwm1Regs.DBCTL.bit.OUT_MODE = DB_FULL_ENABLE;
      EPwm2Regs.AQCTLA.bit.CAD = AQ_SET;
      EPwm2Regs.DBCTL.bit.OUT_MODE = DB_FULL_ENABLE;
      EPwm3Regs.AQCTLA.bit.CAD = AQ_SET;
      EPwm3Regs.DBCTL.bit.OUT_MODE = DB_FULL_ENABLE;
      EPwm4Regs.AQCTLA.bit.CAD = AQ_SET;
      EPwm4Regs.DBCTL.bit.OUT_MODE = DB_FULL_ENABLE;
      EDIS;
      pwm_func.init(&pwm_func, DUTY_MIN, DUTY_MAX);

    }
```

```
    /* discontinuousmode  - EPwm1Regsregisterissettoblocktheupper IGBTsand
    tocontrolthelowerones          */
    if(CW.enable_discont & SW.epmw_mode){
      SW.epmw_mode = 0;
      EALLOW;
      EPwm1Regs.AQCTLA.bit.CAD = AQ_CLEAR;
      EPwm1Regs.DBCTL.bit.OUT_MODE = DB_DISABLE;
      EPwm2Regs.AQCTLA.bit.CAD = AQ_CLEAR;
      EPwm2Regs.DBCTL.bit.OUT_MODE = DB_DISABLE;
      EPwm3Regs.AQCTLA.bit.CAD = AQ_CLEAR;
      EPwm3Regs.DBCTL.bit.OUT_MODE = DB_DISABLE;
      EPwm4Regs.AQCTLA.bit.CAD = AQ_CLEAR;
      EPwm4Regs.DBCTL.bit.OUT_MODE = DB_DISABLE;
      EDIS;
      pwm_func.init(&pwm_func, -1.0f, 1.0f);
    .
    .
    .
}
. . .
```

Računanje fiksnog vremena vođenja IGBT-ova donje grane pretvarača – *epwm1_isr.c*

```
    .
    .
    .
    interruptvoidepwm1_timer_isr(void)
    {
      .
      .
      .
      /* FOCincontinuousmode       */
      if(SW.epmw_mode)
      {
        .
        .
        .
      }
      /* controlindiscontinuousmode       */
      else{
        /* low-passfilterformeasuredcurrentinphasea              */
        ia_discont.in = fabsf(i_a.scaled_value_pu * PI);
        filter_calc(&ia_discont);

        /* rampgeneratorforreferencevalueofdiscontinuouscurrentamplitude              */
        rtlim_discont.in = ia_ref;
        rtlim_discont.calc(&rtlim_discont);

        /* PIcontrollerfordiscontinuouscurrentamplitude(currentpeaks)              */
        pi_discont.ref = rtlim_discont.out;
        pi_discont.fbk = ia_discont.out;
        pi_discont.feed = 0.0f;
        pi_discont.calc(&pi_discont);
```

```
        /* calculatefixeddutycycleforlowerIGBTsindiscontinuousmode              */
        pwm_func.m_a = (1.0f - 2.0f * pi_discont.u_out);
        pwm_func.m_b = (1.0f - 2.0f * pi_discont.u_out);
        pwm_func.m_c = (1.0f - 2.0f * pi_discont.u_out);
        pwm_func.type = SPWM;

        dt_corr_func.corr_a = 0.0f;
        dt_corr_func.corr_b = 0.0f;
        dt_corr_func.corr_c = 0.0f;

        /* setinitialconditionforq      -axiscurrentcontroller     */
        pi_iq.feed = we_control_used * MOTOR_PSI_R_PU;

        /* inverseParktransformation     */
        ipark_func.d = 0.0f;
        ipark_func.q = we_control_used * MOTOR_PSI_R_PU;
        ipark_func.sin = theta_control_used.sin;
        ipark_func.cos = theta_control_used.cos;
        ipark_func.calc(&ipark_func);

        u_alpha_est = ipark_func.alpha;
        u_beta_est = ipark_func.beta;
    }
.
.
.
}
```

Izvedba određivanja parametara aproksimativne funkcije induktiviteta PMSG-a u programskom jeziku C

Deklaracija struktura za histerezno upravljanje strujama i određivanje parametara aproksimativne funkcije induktiviteta PMSG-a – *self_ident.h*

```
#ifndefSELF_IDENT_H_
#defineSELF_IDENT_H_

#include"DSP2834x_Device.h"//DSP2834xExamplesIncludeFile.h"
#include"epwm.h"
#include"motor_defs.h"
#include"extern_variables.h"
#include"math.h"

/* self-identificationvariables   */
#defineHYST_CURRENT_D        1.1f
#defineHYST_CURRENT_Q        1.3f
#defineHYST_VOLTAGE_D        0.5f
#defineHYST_VOLTAGE_Q        0.6f
#defineHYST_CYCLE_NUM        2
#defineHYST_D                1
```

```
#defineHYST_Q                2
#defineHYST_DQ               3
.
.
.
/** Structureformachineself_identification        */
typedefstruct
{
  floatpsid;/          *!<\briefCurrentvalueofd        -axisfluxinself      -ident.process    */
  floatpsiq;/          *!<\briefCurrentvalueofq        -axisfluxinself      -ident.process    */
  floatid_old;/        *!<\briefPreviousvalueofd        -axiscurrentinself      -ident.process    */
  floatiq_old;/        *!<\briefPreviousvalueofq        -axiscurrentinself      -ident.process    */
  floatXXd[2][2];
  floatXYd[2];
  floatXXq[2][2];
  floatXYq[2];
  floatad0;
  floatadd;
  floataq0;
  floataqq;
  floatres;
  Int16 S;
  Int16 T;
} self_ident_t;

/** Structureforhysteresiscontrolduringself_identification          */
typedefstruct
{
  floatud;/            *!<\briefCurrentvalueofd        -axiscurrentinself      -ident.process    */
  floatuq;/            *!<\briefCurrentvalueofq        -axiscurrentinself      -ident.process    */
  floatid;/            *!<\briefCurrentvalueofd        -axiscurrentinself      -ident.process    */
  floatiq;/            *!<\briefCurrentvalueofq        -axiscurrentinself      -ident.process    */
  floathyst_d_ref;
  floathyst_d_value;
  floathyst_q_ref;
  floathyst_q_value;
  Int16 hyst_counter_d;
  Int16 hyst_counter_q;
  Int16 hyst_cycle_num;
} hyst_ctrl_t;

voidself_ident_func(self_ident_t   *values, hyst_ctrl_t *control);/ *!<\briefPointerto
hyst.controlandself      -identificationfunction    */

#endif/ * SELF_IDENT_H_ */
```

Definicija funckije za histerezno upravljanje strujama i određivanje parametara aproksimativne funkcije induktiviteta PMSG-a – *self_ident.c*

```
  #include"self_ident.h"

  voidself_ident_func(self_ident_t   *values, hyst_ctrl_t *control){
    floatdet = 0.000001f;
```

```
Int16 max_cycle = 2*control->hyst_cycle_num + 1;

/* hyst.controlandself      -identificationind   -axis */
if(CW.enable_hyst == HYST_D){
  values->psid +=  MOTOR_W_B * CNTRL_TS * (control->ud - control->id * MOTOR_R_PU);
  values->res  += pow(control->id - values->ad0 * values->psid - values->add
        * pow(values->psid,(values->S+1)),2);

  if(values->S > 0){
    values->XXd[0][0] += pow(values->psid,2);
    values->XXd[0][1] += pow(fabsf(values->psid),(values->S+2));
    values->XXd[1][0] = values->XXd[0][1];
    values->XXd[1][1] += pow(values->psid,(2*(values->S+1)));

    values-> XYd[0] += fabsf(values->psid) * fabsf(control->id);
    values-> XYd[1] += pow(fabsf(values->psid),(values->S+1)) * fabsf(control->id);
  }
  else{
    values->XXd[0][0] += fabsf(values->psid);
    values-> XYd[0] += fabsf(control->id);
  }

  if(control->hyst_counter_d % 2)
  {
    control->ud = control->hyst_d_ref;
  }
  else
  {
    control->ud = -1.0f*control->hyst_d_ref;
  }

  if((control->id > control->hyst_d_value) && (control->ud > 0)){
    control->hyst_counter_d++;
  }

  if((control->id < (-1.0f * control->hyst_d_value)) && (control->ud < 0)){
    control->hyst_counter_d++;
  }

  if(control->hyst_counter_d == max_cycle){
    if(control->id > 0 && values->id_old < 0){
      if(values->S > 0){
        det = values->XXd[0][0] * values->XXd[1][1] - values->XXd[0][1]
            * values->XXd[1][0];
        values->ad0 = (values->XXd[1][1] * values->XYd[0] - values->XXd[0][1]
                  * values->XYd[1]) / det;
        values->add = (-values->XXd[1][0] * values->XYd[0] + values->XXd[0][0]
                  * values->XYd[1]) / det;
      }
      else{
        values->ad0 = 0.5f * (values->XYd[0] / values->XXd[0][0]);
        values->add = 0.5f * (values->XYd[0] / values->XXd[0][0]);
      }

      values->XXd[0][0] = 0.0f;
      values->XXd[0][1] = 0.0f;
```

```
            values->XXd[1][0] = 0.0f;
            values->XXd[1][1] = 0.0f;
            values->XYd[0] = 0.0f;
            values->XYd[1] = 0.0f;
            values->psid = 0.0f;
            values->id_old = 0.0f;
            values->res  = 0.0f;
          }
        }

        if(control->hyst_counter_d == max_cycle + 2){
          if(control->id > 0 && values->id_old < 0){
            CW.enable_hyst = 0;
            control->ud = 0.0f;
            control->hyst_counter_d = 1;

            values->XXd[0][0] = 0.0f;
            values->XXd[0][1] = 0.0f;
            values->XXd[1][0] = 0.0f;
            values->XXd[1][1] = 0.0f;
            values->XYd[0] = 0.0f;
            values->XYd[1] = 0.0f;
            values->psid = 0.0f;
            values->id_old = 0.0f;

            return;
          }
        }
        values->id_old = control->id;
      }

      /* hyst.controlandself     -identificationinq   -axis */
      elseif(CW.enable_hyst == HYST_Q){
        values->psiq += MOTOR_W_B * CNTRL_TS * (control->uq - control->iq * MOTOR_R_PU);
        values->res  += pow(control->iq - values->aq0*values->psiq - values->aqq
              * pow(values->psiq,(values->T+1)),2);

        if(values->T > 0){
          values->XXq[0][0] += pow(values->psiq,2);
          values->XXq[0][1] += pow(fabsf(values->psiq),(values->T+2));
          values->XXq[1][0] = values->XXq[0][1];
          values->XXq[1][1] += pow(values->psiq,(2*(values->T+1)));

          values-> XYq[0] += fabsf(values->psiq) * fabsf(control->iq);
          values-> XYq[1] += pow(fabsf(values->psiq),(values->T+1)) * fabsf(control->iq);
        }
        else{
          values->XXq[0][0] += fabsf(values->psiq);
          values-> XYq[0]   += fabsf(control->iq);
        }

        if(control->hyst_counter_q % 2)
        {
          control->uq = control->hyst_q_ref;
        }
        else
```

```
        {
          control->uq = -1.0f * control->hyst_q_ref;
        }

        if((control ->iq > control->hyst_q_value) && (control->uq > 0)){
          control->hyst_counter_q++;
        }

        if((control ->iq < (-1.0f * control->hyst_q_value)) && (control->uq < 0)){
          control->hyst_counter_q++;
        }

        if(control ->hyst_counter_q == max_cycle){
          if(control ->iq > 0 && values->iq_old < 0){
            if(values ->T > 0){
              det = values->XXq[0][0] * values->XXq[1][1] - values->XXq[0][1]
                    * values->XXq[1][0];
              values->aq0 = (values->XXq[1][1] * values->XYq[0] - values->XXq[0][1]
                          * values->XYq[1]) / det;
              values->aqq = (-values->XXq[1][0] * values->XYq[0] + values->XXq[0][0]
                          * values->XYq[1]) / det;
            }
            else{
              values->aq0 = 0.5f * (values->XYq[0]/values->XXq[0][0]);
              values->aqq = 0.5f * (values->XYq[0]/values->XXq[0][0]);
            }

            values->XXq[0][0] = 0.0f;
            values->XXq[0][1] = 0.0f;
            values->XXq[1][0] = 0.0f;
            values->XXq[1][1] = 0.0f;
            values->XYq[0] = 0.0f;
            values->XYq[1] = 0.0f;
            values->psiq = 0.0f;
            values->iq_old = 0.0f;
            values->res  = 0.0f;
          }
        }

        if(control ->hyst_counter_q == max_cycle + 2){
          if(control ->iq > 0 && values->iq_old < 0){
            CW.enable_hyst = 0;
            control->uq = 0.0f;
            control->hyst_counter_q = 1;

            values->XXq[0][0] = 0.0f;
            values->XXq[0][1] = 0.0f;
            values->XXq[1][0] = 0.0f;
            values->XXq[1][1] = 0.0f;
            values->XYq[0] = 0.0f;
            values->XYq[1] = 0.0f;
            values->psiq = 0.0f;
            values->iq_old = 0.0f;

            return;
          }
```

```
        }

        values->iq_old = control->iq;
      }
    }
```

Proračun i adaptacija induktiviteta PMSG-a pomoću parametara aproksimativne funckije – *epwm_isr.c*

```
    .
    .
    .
    interruptvoidepwm1_timer_isr(void)
    {
    .
    .
    .
      /* Fluxestimationinalpha     -betareferenceframe     */
      psi_alpha.in = MOTOR_W_B * psi_integral_tfilt * (u_alpha_est - i_alpha_meas *
      MOTOR_R_PU);
      psi_beta.in = MOTOR_W_B * psi_integral_tfilt * (u_beta_est - i_beta_meas *
      MOTOR_R_PU);
      filter_calc(&psi_alpha);
      filter_calc(&psi_beta);

      /* Parktransformation   */
      park_func.alpha = psi_alpha.out;
      park_func.beta = psi_beta.out;
      park_func.sin = theta_control_used.sin;
      park_func.cos = theta_control_used.cos;
      park_func.calc(&park_func);

      /* Fluxestimationingamma     -deltareferenceframe     */
      psi_g.in=park_func.d;
      psi_d.in=park_func.q;
      filter_calc(&psi_g);
      filter_calc(&psi_d);

      /* calculatedandq     -axisinductanceusingdeterminedapproximationfunction
  parametersad0,add,aq0andaqq          */
      if(!CW.enable_hyst){
        est_values.Ld = 1/(self_ident.ad0 + self_ident.add*pow(fabsf(psi_g.out),self_ident.S
        ));
        est_values.Lq = 1/(self_ident.aq0 + self_ident.aqq*pow(fabsf(psi_d.out),self_ident.T
        ));

        if(est_values.Lq > MOTOR_LQ_PU)
          est_values.Lq = MOTOR_LQ_PU;

        if(est_values.Lq < 0.6f*MOTOR_LQ_PU)
          est_values.Lq = 0.6f*MOTOR_LQ_PU;
      }
```

```
        /* writeapproximatedq   -axisinductanceinSMOstructures        */
        if(SW.epmw_mode){
          smo_ab.Lq_from_map = est_values.Lq;
          smo_gd.Lq_from_map = est_values.Lq;
        }
        else{
          smo_ab.Lq_from_map = 1/self_ident.aq0;
          smo_gd.Lq_from_map = 1/self_ident.aq0;
        }
      .
      .
      .
      }
```

Životopis

Filip Jukić rođen je 1993. godine u Zagrebu gdje završava osnovnu školu i I. gimnaziju. Fakultet elektrotehnike i računarstva Sveučilišta u Zagrebu upisuje 2011. godine. Diplomirao je 2016. godine na Zavodu za elektrostrojarstvo i automatizaciju. Od listopada 2016. godine do studenog 2018. godine radio je kao istraživač na Zavodu za elektrostrojarstvo i automatizaciju u sklopu projekta "Razvoj naprednih energetski učinkovitih struktura upravljanja generatorom s permanentnim magnetima bez mjernog člana brzine vrtnje" financiranog od Hrvatske zaklade za znanost. Od studenog 2018. radi na Zavodu za elektrostrojarstvo i automatizaciju kao asistent te sudjeluje u izvođenju laboratorijskih vježbi iz nekoliko predmeta na Fakultetu elektrotehnike i računarstva.

Poslijediplomski studij na Fakultetu elektrotehnike i računarstva u Zagrebu upisao je 2016. godine. Objavio je jedan znanstveni rad u časopisima indeksiranim u CC bazi te četiri rada u zbornicima s međunarodnom recenzijom. Područje njegovog znanstvenog istraživanja je upravljanje sinkronim strojevima s permanentnim magnetima bez mjernog člana brzine vrtnje.

Aktivno govori i piše engleski jezik, a služi se i njemačkim jezikom. Oženjen je.

Popis objavljenih djela

Rad u časopisima

1. Jukić, F., Pravica, L., Bariša, T., Sumina, D., "Flying-start and continuous operation of a permanent-magnet wind generator based on discontinuous currents, discrete second-order sliding-mode observer and phase-locked loop", *IET Renewable Power Generation*, Vol. 14, Iss. 1, 2020., str. 90-99.

Radovi u zbornicima skupova

1. Jukić, F., Pravica L., Stipetić S., "Sensorless Synchronization Method For a Grid-Side Converter With an LCL Filter Based On a Sliding Mode Observer and Discontinuous Operating Mode", *XXV International Conference on Electrical Machines (ICEM 2022)*, Valencia, Španjolska, 2022. str. 1300-1306

2. Makar M., Kutija M.,Pravica L., Jukić F., "DC/DC Converter Topologies for Elevator Energy Storage Systems Based on Supercapacitors", *2021 International Conference on Electrical Drives and Power Electronics (EDPE)*, Dubrovnik, 2021. str. 220-227
3. Pravica L., Jukić F., Bariša T., Stipetić S., "Interior Permanent Magnet Wind Generator Torque Estimation Considering Low-Pass Filter Phase Shift Compensation", *2018 International Symposium on Industrial Electronics (INDEL)*, Banja Luka, Bosna i Hercegovina, 2018., str. 1-5
4. Jukić F., Sumina D., Erceg I., "Comparison Of Torque Estimation Methods For Interior Permanent Magnet Wind Power Generator", *2017 19th International Conference on Electrical Drives and Power Electronics (EDPE)*, Dubrovnik, 2017., str. 291-296
5. Jukić F., Sumina D., Pravica L., Kuzle I., "Practical Approach for Parameter Determinations of Interior Permanent Magnet Generator," *IEEE EUROCON 2017 -17th International Conference on Smart Technologies*, Ohrid, Republika Sjeverna Makedonija, 2017., str. 712-719

Biography

Filip Jukić was born in 1993 in Zagreb, Croatia where he finished elementary school and graduated from I Gymnasium. In 2011 he enrolled at the Faculty of Electrical Engineering and Computing, University of Zagreb and graduated at the Department of Electric Machines, Drives and Automation in 2016. Since October 2016 until November 2018, he has worked as a research assistant at the Department of Electric Machines, Drives and Automation on the projected "Development of advanced energy efficient algorithms for sensorless control of permanent magnet generators" financed by Croatian science foundation. Since November 2018 he is working at the Department of Electric Machines, Drives and Automation as a junior researcher and he is participating in several laboratory courses in Faculty of Electrical Engineering and Computing.

In 2016, he started his PhD studies at the Faculty of Electrical Engineering and Computing. He co-authored one paper published in journal indexed in Current Content database and four papers in proceedings of international conferences. His scientific interests include sensorless control of permanent magnet synchronous machines.

He has an excellent knowledge of English and basic knowledge of German language. He is married.