Bezsenzorsko modelsko prediktivno izravno upravljanje strujom sinkronoga vjetrogeneratora sa stalnim magnetima

Bariša, Tin

Doctoral thesis / Disertacija

2019

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:168:330976

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-20**

Repository / Repozitorij:

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

Sveučilište u Zagrebu
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Tin Bariša

BEZSENZORSKO MODELSKO PREDIKTIVNO IZRAVNO UPRAVLJANJE STRUJAMA SINKRONOGA VJETROGENERATORA SA STALNIM MAGNETIMA

DOKTORSKI RAD

Zagreb, 2019.

Sveučilište u Zagrebu
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Tin Bariša

BEZSENZORSKO MODELSKO PREDIKTIVNO IZRAVNO UPRAVLJANJE STRUJAMA SINKRONOGA VJETROGENERATORA SA STALNIM MAGNETIMA

DOKTORSKI RAD

Mentor: Izv. prof. dr. sc. Damir Sumina

Zagreb, 2019.

University of Zagreb

FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING

Tin Bariša

SENSORLESS MODEL PREDICTIVE DIRECT CONTROL OF CURRENTS IN PERMANENT MAGNET SYNCHRONOUS WIND GENERATOR

DOCTORAL THESIS

Supervisor: Associate Professor Damir Sumina, PhD

Zagreb, 2019

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

Mentor: izv. prof. dr. sc. Damir Sumina

Doktorski rad ima 144 stranice

Doktorski rad br.: _____

O mentoru

Damir Sumina je izvanredni profesor 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 na Zavodu za elektrostrojarstvo i automatizaciju, Sveučilišta u Zagrebu Fakulteta elektrotehnike i računarstva.

Znanstveni interes izv.prof.dr.sc. Damira Sumine obuhvaća upravljanje električnim strojevima i elektromotornim pogonima, posebno upravljanje hidrogeneratorima i vjetrogeneratorima te industrijsku automatizaciju.

Damir Sumina je bio 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 je bio 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.

Član je udruga IEEE i HRO CIGRÉ.

About the Supervisor

Damir Sumina is associate 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, M.Sc. degree in 2005 and PhD degree in 2011 from the same Department. He worked as assistent from 2001 to 2011 and as assistant professor from 2011 to 2016 at University of Zagreb Faculty of Electrical Engineering and Computing, Department of Electric Machines, Drives and Automation.

Scientific interests of associate professor Damir Sumina, PhD are control of electrical machines and drives, especially control of hydro generators and wind generators and industrial automation.

Damir Sumina was leader of scientific research project "Development of advanced energy efficient algorithms for sensorless control of permanent magnet generators" financed by Croatian science foundation. During his tenure Damir Sumina was involved in numerous national and international projects as a researcher.

He is author of many papers published in international journals and conferences. He has 20 papers in A category journals. He has reviewed numerous papers in high ranked journals

and conferences. He was also supervisor of more than hundred undergraduate and graduate students.

He is member of IEEE and HRO CIGRÉ associations.

Zahvala

Prije svega bih se zahvalio svom mentoru i voditelju znanstvenog projekta na kojem sam bio zaposlen, izv. prof. dr. sc. Damiru Sumini. Hvala mu na brojnim korisnim savjetima tijekom doktorskog istraživanja, pomoći u pisanju i objavljivanju znanstvenih članaka u časopisima te na velikoj pomoći tijekom eksperimentalnih ispitivanja. Bila mi je iznimna čast i zadovoljstvo surađivati s Damirom tijekom mog rada na Zavodu za elektrostrojarstvo i automatizaciju.

Također bih se zahvalio i svojim kolegama iz sobe C04-15, Filipu Jukiću i Luki Pravici, kolegi Šandoru Ilešu te kolegici Martini Kutiji na lijepoj suradnji, druženju te općenito ugodno provedene četiri godine na Zavodu i Fakultetu. Bez obzira da li se radilo o znanstvenom istraživanju, radu u nastavi ili stručnim projektima, uvijek sam mogao računati na njihovu pomoć i korisne sugestije. Posebno bih se zahvalio Šandoru na pomoći prilikom istraživanja u području modelskog prediktivnog upravljanja.

Zahvalio bih se i kolegi Igoru Čoloviću iz tvrtke Končar INEM d.o.o. na pomoći tijekom provođenja eksperimentalnih ispitivanja vezanih uz upravljanje bez mjernog člana brzine rotora te kolegi Tomislavu Idžotiću iz tvrtke Rješenje plus d.o.o. na pomoći tijekom provođenja eksperimentalnih ispitivanja vezanih uz modelsko prediktivno upravljanje.

Naposljetku, najviše bih se zahvalio svojim roditeljima Jasminki i Mladenu te baki Matildi na podršci i strpljenju tijekom mog istraživanja i pisanja doktorske disertacije. Ovaj rad bih posvetio svom pokojnom djedu Mihajlu.

Sažetak

Ova doktorska disertacija rezultat je istraživanja u području naprednih algoritama upravljanja sinkronim generatorom sa stalnim magnetima s primjenom u sustavima za pretvorbu energije vjetra. Sustav za pretvorbu energije vjetra sastoji se od vjetroturbine, prijenosnog mehanizma (postoji ovisno o tipu generatora), generatora, AC-DC-AC pretvarača i filtra. Brojna istraživanja pokazuju da upravo izvedba sa sinkronim generatorom sa stalnim magnetima i AC-DC-AC pretvaračem preuzima dominaciju na tržištu.

U disertaciji je dan pregled različitih tipova sustava za pretvorbu energije vjetra, principa matematičkog modeliranja sinkronog generatora sa stalnim magnetima te standardnih algoritama upravljanja vjetroturbinom i AC-DC-AC pretvaračem. Također je dan pregled literature iz naprednih algoritama upravljanja sinkronim generatorom sa stalnim magnetima poput upravljanja bez mjernog člana brzine rotora, modelskog prediktivnog upravljanja te upravljanja u području slabljenja magnetskog toka. Znanstveni doprinos disertacije čine tri razvijena algoritma upravljanja sinkronim generatorom sa stalnim magnetima iz navedenih područja istraživanja.

Razvijena metoda letećeg starta i upravljanja bez mjernog člana brzine rotora temeljena je na mjerenju induciranog napona generatora u praznom hodu i fazno zatvorenoj petlji. Prije uključenja generatorskog pretvarača estimiraju se kut i brzina rotora čime je porast struje prilikom uključenja generatorskog pretvarača zanemariv. Ista struktura estimacije brzine i kuta rotora osigurava rad bez mjernog člana brzine rotora u čitavom radnom području generatora.

Razvijeni algoritam izravnog modelskog prediktivnog upravljanja strujama uzima u obzir diskretnu prirodu generatorskog pretvarača te odabirom vrijednosti parametara za penalizaciju kriterijske funkcije omogućava ostvarivanje kompromisa između smanjenih sklopnih gubitaka generatorskog pretvarača i prihvatljivog harmoničkog izobličenja struje. Stabilnost i uzastopna dopustivost algoritma osigurana je fleksibilnom upravljačkom Ljapunovljevom funkcijom.

Razvijena metoda upravljanja u području slabljenja magnetskog toka temelji se na koordiniranom radu PI regulatora napona i momenta. PI regulator napona osigurava rad na ograničenju napona, dok PI regulator momenta osigurava ispravno praćenje referentne vrijednosti momenta, tj. korekciju porasta momenta uslijed povećanja reluktantnog momenta.

Razvijeni algoritmi su provjereni na simulacijskim modelima u programskim okruženjima MATLAB/Simulink i PLECS te eksperimentalno potvrđeni na laboratorijskom postavu koji se sastoji od sinkronog generatora sa stalnim magnetima, AC-DC-AC pretvarača i asinkronog motora koji emulira rad vjetroturbine.

Ključne riječi: sinkroni generator sa stalnim magnetima, sustav za pretvorbu energije vjetra, leteći start, upravljanje bez mjernog člana brzine rotora, modelsko prediktivno upravljanje, upravljanje u području slabljenja magnetskog toka

Extended Abstract

Lately, wind energy conversion systems are one of the main renewable energy sources in the world. By 2017 total installed power in wind energy systems was 487 GW, with estimate that this number will reach 760 GW by 2020. Due to this fact, there are numerous scientific research projects with focus on improving wind energy conversion systems.

Wind energy conversion system consists of a wind turbine, gearbox (can be omitted in some configurations), electric generator, (partial or full scale) back-to-back converter and a filter between the converter and the electrical grid. Due to low cost and simplicity, the leading solution includes doubly-fed induction generator with a partial scale (around 30% of generator nominal power) back-to-back converter. However, many scientific papers indicate that solution with a permanent magnet generator and full scale back-to-back converter will take over market in the near future. This configuration allows full range speed control of the wind turbine which results in maximum power extraction from the wind.

The main advantages of permanent magnet generators are high efficiency coefficient, high power density, high power factor (magnetic flux is produced by permanent magnets on the rotor) and wide speed range. Depending on the construction, there are surface and interior permanent magnet generators. In a case of surface permanent magnet generator there is magnetic symmetry in direct and quadrature axis which results in fewer generator parameters and simpler control algorithms. On the other hand, if permanent magnets are placed inside rotor, there is magnetic asymmetry in direct and quadrature axis which results in additional, reluctance torque. This type of generator also has wider speed range compared to surface permanent magnet generators but more complex control algorithms are required.

Scientific focus of this PhD thesis are advanced control algorithms of interior permanent magnet generators for application in wind energy conversion systems. Narrow focus of research is generator, generator-side converter and its digital signal processor in which developed control algorithms were implemented. Advanced control algorithms include control structures which provide various advantages and improvements over standard control structures such as rotor field oriented control or direct torque control. The main guidelines for research are sensorless control structures for high power generators including flying start, model predictive control of two-level converter and flux weakening control structures. In those specified areas new control structures and algorithms were developed which represent scientific contribution of this PhD thesis.

According to some researchers 14% of wind system failures are related to sensor faults. The main motive for developing sensorless control techniques is elimination of sensors and improvement of robustness of the overall wind system. However, most scientific papers are focused on developing rotor speed and angle estimators, with assumption that machine is started

from standstill which is not a case of a wind generator. In a case of a wind generator, the generator-side converter is started when wind speed reaches cut-in speed. In such a case, prior to starting a generator-side converter, the control structure should have already determined rotor speed, rotor angle and induced voltage of the generator. Otherwise, significant inrush current occurs which causes mechanical stroke which could be fatal for the whole wind system. Only a few scientific papers and patents analyse switching on a converter during rotation of a permanent magnet machine. Also, control structures developed in those papers are often verified on small power machines with a high value of stator resistance which prevents significant inrush current. In this PhD thesis focus is on developing control structure which incorporates flying start in sensorless control structure for the whole operating range of the high power wind generator.

With development of digital signal processors model predictive control has become a promising alternative to standard control structures based on PI or hysteresis controllers. This control principle is based on prediction of future system states using mathematical model of the system. Using predicted future states and taking system and control input constraints into account, the minimum of the defined cost function is found and optimal control input is applied to the system. Model predictive control algorithms applied to power converters are distinguished whether pulse-width modulation is used (continuous control set) or not (finite control set). Finite control set model predictive control algorithms are analysed in this PhD thesis. The main advantage of this algorithm group is better dynamic performance compared to algorithms which are based on pulse-width modulation. In wind systems high dynamic performance is not crucial due to high inertia of wind turbine. However, finite control set algorithms also enable minimizing switching losses of the power converter with proper definition of the cost function. This aspect, along with ensuring stability and recursive feasibility of the algorithm, is the main focus of research in the PhD thesis.

One of the requirements in wind generator control system is ensuring operation on the voltage limit, i.e. flux weakening. Rotor speed increases due to increase in wind speed which results in increased induced voltage at generator terminals. If generator voltage exceeds maximum permissible value defined by DC link voltage and used pulse-width modulation technique, the control system becomes unstable. Additional control structure, usually based on generation of negative direct axis current which reduces generator voltage below maximum permissible value, is required. In most scientific papers control systems with PI speed controller and operating point on intersection of current and voltage limit are analysed. However, in case of wind system analysed in this PhD thesis, the controlled variable is torque, so modifications to existing control structures are required. Additionally, in a case of interior permanent magnet generator, standard flux weakening structures cause increase of reluctance torque which results in suboptimal operating point. The research focus in the PhD thesis is robust flux weakening structure which is compatible with standard torque control of wind generator but also enables operation

on voltage limit with successful torque reference tracking. The PhD thesis contains following chapters:

Chapter 1. - Introduction. In this chapter scientific problem is defined and motivation behind it is given. Also, scientific contributions of the PhD thesis are emphasized and structure of the thesis is outlined.

Chapter 2. - Wind energy conversion systems. In this chapter operating principle of a wind energy conversion system is described. Depending on the type of electric generator and power electronic components, four main types of wind energy conversion systems are distinguished. The emphasis is given to the fourth type, specifically a configuration with permanent magnet generator and a back-to-back converter. The mathematical model of permanent magnet machine in different coordinate systems is derived. Standard control structures for generator-side converter (rotor field oriented control with MTPA algorithm) and grid-side converter (voltage oriented control) are explained.

Chapter 3. - Laboratory setup. In this chapter experimental setup used for verification of developed algorithms is described. The setup consists of a permanent magnet generator, back-to-back converter and an induction motor which emulates wind turbine operation. Rated data for all aforementioned components along with description of measuring equipment (e.g. torque and current measurement) is given. Digital signal processor of generator- and grid-side converters is described as well. Also, main principles of graphical programming tool (*AlgoCad*) and supervisory tool (*r_parnad*) are explained.

Chapter 4. - Sensorless control. This chapter is related to development of control structure without rotor position measuring device (position sensor). The proposed control structure consists of flying start and synchronisation phase. During flying start induced voltage at generator terminals is measured and phase locked loop is employed to estimate rotor speed, rotor angle and induced voltage. Once the estimation is complete, generator-side converter is switched on and synchronisation phase is started. During continuous operation estimation of rotor speed and angle is carried out by estimation of magnetic flux and phase locked loop. Simulation and experimental results are given for switching on generator-side converter without flying start process (comparison to standard algorithms applied to motors), flying start and synchronisation phase of the developed sensorless structure along with change of torque reference and rotor speed.

Chapter 5. - Model predictive control of currents. In this chapter different model predictive control algorithms applied to electric machines and power converters are analysed, with emphasis on finite control set model predictive control. Basic principles of model predictive control are given. Mathematical model of permanent magnet generator and generator-side converter with and without considering dead time was derived. The developed model predictive direct current control algorithm consists of two modes, namely transient and steady state. By choosing parameters for penalizing current control error and switching state change, trade-off between

current ripple and reduced switching losses can be achieved. The stability and recursive feasibility are guaranteed by adding flexible control Lyapunov function constraint. Adding flexibility to standard control Lyapunov function provides less conservative optimal control action which enables penalizing switching losses even during transient state. Simulation results are given for different sizes of control invariant set, comparison of standard and flexible control Lyapunov function, analysis of different values in penalisation matrices, analysis of converter dead time impact and analysis of generator parameters variation impact. Experimental results were given for switching on the generator-side converter with developed algorithm at different rotor speed values. Analysis of different values in penalisation matrices and analysis of compensation of digital system computational delay were given.

Chapter 6. - Torque control in flux weakening region. This chapter is related to development of flux weakening structure for permanent magnet generators. Current and voltage constraints of a permanent magnet generator are explained. The developed flux weakening structure is based on coordinated operation of voltage and torque PI controllers. While the voltage PI controller keeps voltage on maximum permissible value, the torque PI controller prevents increase of reluctance torque and ensures correct tracking of torque reference. Trajectory of current in flux weakening region is also described. Experimental results are given for entering and exiting flux weakening operation with and without torque PI controller at different torque reference and rotor speed values.

Chapter 7. - Conclusion. This chapter contains conclusion of the research and emphasizes scientific contributions of the PhD thesis.

Simulation and experimental results show that the developed control structures for sensorless control with flying start, model predictive direct current control and flux weakening achieve improvement over existing algorithms which can be found in scientific literature. Flying start concept ensures switching on power converter with negligible inrush current while sensorless control structure enables operation within entire operating area of the generator without rotor position and speed sensor. Model predictive direct current control algorithm provides possibility to achieve trade-off between acceptable current ripple and reduction in generator-side converter switching losses. Flux weakening structure ensures operation on voltage limit while simultaneously tracking torque reference value. Low computation burden of the developed algorithms indicates possibility of their utilisation in industry applications.

Keywords: permanent magnet generator, wind energy conversion system, flying start, sensorless control, model predictive control, flux weakening

Sadržaj

1. Uvod 1
1.1. Opis problema i motivacija 1
1.2. Izvorni znanstveni doprinosi 4
1.3. Struktura disertacije 5

2. Sustavi za pretvorbu energije vjetra 6
2.1. Tipovi sustava za pretvorbu energije vjetra 7
2.2. Matematički model sinkronog stroja sa stalnim magnetima 10
2.2.1. Vektorski prikaz trofaznih izmjeničnih veličina 11
2.2.2. Clarkina i Parkova transformacija 12
2.2.3. Matematički model generatora u $\alpha\beta$ koordinatnom sustavu 13
2.2.4. Matematički model generatora u sinkronom dq koordinatnom sustavu . 13
2.3. Strukture upravljanja AC-DC-AC pretvaračem 15
2.3.1. Struktura upravljanja generatorskim dijelom AC-DC-AC pretvarača . . 16
2.3.2. Struktura upravljanja mrežnim dijelom AC-DC-AC pretvarača 17

3. Laboratorijski postav 20

4. Upravljanje bez mjernog člana brzine rotora 26
4.1. Pregled literature 26
4.1.1. Prvi znanstveni doprinos 30
4.2. Upravljanje bez mjernog člana brzine rotora temeljeno na mjerenju induciranog napona generatora i fazno zatvorenoj petlji 31
4.2.1. Struktura upravljanja bez mjernog člana brzine rotora 31
4.2.2. Faza predsinkronizacije 32
4.2.3. Struktura estimacije brzine i kuta rotora 33
4.2.4. Faza sinkronizacije 35
4.3. Simulacijski rezultati 37
4.3.1. Uključenje generatorskog pretvarača bez algoritma letećeg starta 37
4.3.2. Faza predsinkronizacije 39

4.3.3. Faza sinkronizacije . . . 40
4.3.4. Promjena referentne vrijednosti momenta . . . 40
4.3.5. Promjena brzine rotora . . . 41
4.4. Eksperimentalni rezultati . . . 42
4.4.1. Uključenje generatorskog pretvarača bez algoritma letećeg starta . . . 43
4.4.2. Faza predsinkronizacije . . . 44
4.4.3. Faza sinkronizacije . . . 45
4.4.4. Promjena referentne vrijednosti momenta . . . 45
4.4.5. Promjena brzine rotora . . . 46

5. Modelsko prediktivno upravljanje strujama . . . 48
5.1. Pregled literature . . . 48
5.1.1. Modelsko prediktivno upravljanje s kontinuiranim skupom upravljačkih akcija (CCS-MPC) . . . 49
5.1.2. Modelsko prediktivno upravljanje s konačnim skupom upravljačkih akcija (FCS-MPC) . . . 50
5.1.3. Drugi znanstveni doprinos . . . 54
5.2. Teorijske osnove modelskog prediktivnog upravljanja . . . 55
5.2.1. Koncept modelskog prediktivnog upravljanja . . . 55
5.2.2. Diskretni matematički model sustava . . . 56
5.2.3. Kriterijska funkcija . . . 58
5.2.4. Ograničenja . . . 59
5.2.5. Optimizacijski problem . . . 60
5.2.6. Prednosti i izazovi modelskog prediktivnog upravljanja . . . 60
5.3. Modelsko prediktivno izravno upravljanje strujama (MP-DCC) s dva režima rada 62
5.3.1. Diskretni matematički model sinkronog stroja sa stalnim magnetima i generatorskog pretvarača . . . 63
5.3.2. Metodologija razvijenog MP-DCC algoritma upravljanja . . . 69
5.4. Simulacijski rezultati . . . 77
5.4.1. MP-DCC algoritam bez upravljačke Ljapunovljeve funkcije . . . 78
5.4.2. Različite veličine upravljačkog invarijantnog skupa . . . 79
5.4.3. Usporedba standardne i fleksibilne upravljačke Ljapunovljeve funkcije . 81
5.4.4. Analiza utjecaja parametara za penalizaciju na upravljačke performanse 83
5.4.5. Analiza utjecaja mrtvog vremena generatorskog pretvarača . . . 88
5.4.6. Analiza utjecaja promjene vrijednosti parametara generatora . . . 91
5.5. Eskperimentalni rezultati . . . 95
5.5.1. Kompenzacija kašnjenja ciklusa digitalnog sustava . . . 96
5.5.2. Uključenje generatorskog pretvarača uz razvijeni MP-DCC algoritam . 97

5.5.3. Usporedba odziva s i bez kompenzacije kašnjenja ciklusa digitalnog sustava . . . 98
5.5.4. Analiza utjecaja parametara za penalizaciju na upravljačke performanse 99

6. Upravljanje momentom u području slabljenja magnetskog toka . . . 101
6.1. Pregled literature . . . 101
6.1.1. Treći znanstveni doprinos . . . 103
6.2. Metoda slabljenja magnetskog toka temeljena na PI regulatorima napona i momenta . . . 104
6.2.1. Ograničenja napona i struje generatora . . . 104
6.2.2. Razvijena struktura upravljanja u području slabljenja magnetskog toka . 105
6.2.3. Trajektorija struje u području slabljenja magnetskog toka . . . 108
6.3. Eksperimentalni rezultati . . . 109
6.3.1. Ulazak u područje slabljenja magnetskog toka bez regulatora momenta 110
6.3.2. Izlazak iz područja slabljenja magnetskog toka bez regulatora momenta 111
6.3.3. Ulazak u područje slabljenja magnetskog toka s regulatorom momenta . 112
6.3.4. Izlazak iz područja slabljenja magnetskog toka s regulatorom momenta 113

7. Zaključak . . . 115

Literatura . . . 117

Popis oznaka i kratica . . . 131

Popis slika . . . 136

Popis tablica . . . 140

Životopis . . . 141

Curriculum vitae . . . 144

1. Uvod

1.1. Opis problema i motivacija

Posljednjih godina sustavi za pretvorbu energije vjetra predstavljaju jedan od vodećih obnovljivih izvora električne energije. Iz navedenog razloga povećana je integracija vjetroelektrana u elektroenergetski sustav. Do 2017. godine ukupna instalirana snaga vjetroelektrana u svijetu iznosila je 487 GW, uz procjenu da će ta vrijednost narasti na 760 GW do 2020. godine [1, 2]. Samo u Europskoj Uniji instalirana snaga u vjetroelektranama iznosi 154 GW, uz procjenu da će do 2030. godine vjetroelektrane opskrbljivati 25% potreba za električnom energijom [3, 4].

Sustav za pretvorbu energije vjetra sastoji se od vjetroturbine, prijenosnog mehanizma (može ili ne mora postojati, ovisno o tipu generatora), generatora, AC-DC-AC pretvarača (djelomične ili pune snage s obzirom na snagu generatora što ovisi o izvedbi sustava) te filtra koji se nalazi između pretvarača i električne mreže [5, 6]. Zbog isplativosti trenutno je najzastupljenija izvedba s dvostrukom napajanim asinkronim generatorom i AC-DC-AC pretvaračem djelomične snage (uobičajeno oko 30% snage generatora). No, brojna istraživanja pokazuju da izvedba koja uključuje sinkroni generator sa stalnim magnetima i AC-DC-AC pretvarač pune snage preuzima dominaciju na tržištu. U navedenoj izvedbi moguće je maksimalno iskoristiti snagu vjetra ostvarenjem optimalne brzine vjetroturbine [7].

Prednosti sinkronih generatora sa stalnim magnetima pred drugim tipovima generatora uključuju visok stupanj korisnosti pri svim brzinama, veliku gustoću snage, visok faktor snage budući da je magnetski tok u stroju posljedica stalnih magneta na rotoru te širok raspon ostvarivih brzina rotora [8]. Ovisno o izvedbi, sinkroni generator ovog tipa može imati stalne magnete na površini ili u unutrašnjosti rotora. Posljedica smještanja magneta na površinu rotora je magnetska simetrija u uzdužnoj i poprečnoj osi što rezultira manjim brojem parametara prilikom identifikacije te jednostavnijim algoritmima upravljanja generatorom. S druge strane, ako su stalni magneti smješteni u unutrašnjosti rotora postoji magnetska asimetrija u uzdužnoj i poprečnoj osi što rezultira dodatnim, reluktantnim momentom. Ovaj tip generatora ima veći raspon brzine rotora uslijed većih mogućnosti slabljenja magnetskog toka, no algoritmi upravljanja su složeniji.

Predmet istraživanja doktorske disertacije čine napredni algoritmi upravljanja sinkronim generatorom sa stalnim magnetima u unutrašnjosti rotora za primjenu u sustavima pretvorbe energije vjetra. Uže područje razmatranja u sustavu je generator i generatorski pretvarač u čijem digitalnom sustavu su implementirani navedeni algoritmi upravljanja. Pod pojmom napredni algoritmi upravljanja podrazumijevaju se različite strukture upravljanja kojima se nadilaze ograničenja ili ostvaruju bolje performanse u usporedbi sa standardnim strukturama upravljanja poput vektorskog upravljanja u koordinatnom sustavu magnetskog toka rotora s mjernim članom brzine rotora ili izravnog upravljanja momentom. Glavne smjernice u istraživanju čine strukture upravljanja bez mjernog člana brzine rotora prilagođene za generatore velikih snaga, algoritmi modelskog prediktivnog upravljanja dvorazinskim pretvaračem i sinkronim generatorom sa stalnim magnetima te strukture upravljanja u području slabljenja magnetskog toka. U sklopu istraživanja razvijeni su novi algoritmi iz navedenih područja koji čine izvorne znanstvene doprinose doktorske disertacije.

Prema [9] 14% kvarova u vjetroelektranama uzrokovano je kvarovima senzora. S ciljem povećanja robusnosti i otpornosti na kvar čitavog sustava, tendencija je smanjenja broj senzora u sustavima upravljanja. Iz navedenog razloga postoji velik broj radova u znanstvenoj literaturi koji se bavi problematikom upravljanja bez mjernog člana brzine rotora. No, većina navedenih radova usmjerena je na sintezu estimatora brzine i kuta rotora, uz pretpostavku da se stroj pokreće iz mirovanja, što nije slučaj kod vjetrogeneratora. U slučaju vjetrogeneratora, signal za uključenje generatorskog pretvarača postaje aktivan kada brzina turbine dosegne minimalnu vrijednost za uključenje (engl. *cut-in speed*). Stoga je prije uključenja generatorskog pretvarača potrebno poznavati brzinu i kut rotora te inducirani napon generatora. U suprotnom dolazi do značajnog porasta struje i udarca momenta koji može biti poguban za čitav sustav. Mali broj znanstvenih radova i patenata analizira uključenje pretvarača tijekom vrtnje sinkronog stroja sa stalnim magnetima. Također, navedeni radovi su često eksperimentalno verificirani na strojevima malih snaga gdje porast struje nije toliko izražen zbog velike vrijednosti otpora statora koja je svojstvena upravo strojevima malih snaga. Predmet istraživanja u doktorskoj disertaciji je struktura koja omogućava estimaciju potrebnih veličina prije uključenja generatorskog pretvarača te prelazak u trajni rad bez mjernog člana brzine rotora.

Razvojem digitalnih sustava upravljanja modelsko prediktivno upravljanje postaje alternativa standardnim strukturama upravljanja pretvaračima napona i frekvencije i električnim strojevima temeljenim na PI ili histereznim regulatorima. Navedeni tip upravljanja karakterizira predikcija budućih vrijednosti varijabli stanja na temelju matematičkog modela sustava te pronalazak minimuma definirane kriterijske funkcije na predikcijskom horizontu uzimajući u obzir ograničenja sustava. Budući da navedeni algoritam proračunava optimalnu upravljačku akciju postižu se bolje performanse upravljanja u usporedbi sa standardnim strukturama upravljanja. Algoritmi modelskog prediktivnog upravljanja pretvaračima napona i frekvencije uobičajeno se

dijele na one s kontinuiranim skupom upravljačkih akcija (koristi se pulsno-širinska modulacija) i one s konačnim skupom upravljačkih akcija (izravno upravljanje sklopkama pretvarača). Upravo posljednja grupa algoritama je predmet istraživanja velikog broja radova u znanstvenoj literaturi kao i istraživanja u doktorskoj disertaciji. Prednost navedene skupine je veća dinamika odziva u usporedbi s algoritmima koji koriste pulsno-širinsku modulaciju budući da se sklopkama izravno upravlja. No, u sustavima za pretvorbu energije vjetra visoke dinamičke performanse nisu primarni zahtjev budući da se radi o sustavu s velikim momentom tromosti. Međutim, skupina algoritama modelskog prediktivnog upravljanja s konačnim skupom upravljačkih akcija omogućuje i smanjenje sklopnih gubitaka pretvarača odgovarajućim odabirom kriterijske funkcije. Upravo je navedeni aspekt, uz osiguranje stabilnosti i uzastopne dopustivosti algoritma, predmet istraživanja u doktorskoj disertaciji.

U strukturi upravljanja vjetrogeneratorom potrebno je osigurati i rad na naponskom ograničenju, tj. u području slabljenja magnetskog toka. Uslijed porasta brzine vjetra dolazi i do povećanja brzine rotora što uzrokuje porast vrijednosti induciranog napona generatora. Ako napon generatora postane veći od maksimalnog ostvarivog napona na izlazu generatorskog pretvarača (definiran naponom istosmjernog međukruga i korištenim tipom modulacije) provedu poredne diode generatorskog pretvarača te dolazi do gubitka upravljivosti generatorom. Dodatna struktura upravljanja, koja se uobičajeno temelji na generiranju dodatne negativne vrijednosti struje u uzdužnoj osi (slabljenje magnetskog toka stalnih magneta), osigurava smanjenje napona ispod dopuštene razine. Velik broj znanstvenih radova podrazumijeva upravljanje brzinom rotora putem PI regulatora, kao i istovremen rad na ograničenju struje i napona (maksimalna snaga). U slučaju sustava koji je razmatran u doktorskoj disertaciji referentna veličina u sustavu upravljanja je moment, a ne brzina rotora, stoga je potrebna modifikacija postojećih struktura. Također, u slučaju sinkronog generatora sa stalnim magnetima u unutrašnjosti rotora standardne strukture uzrokuju dodatno povećanje momenta iznad referentne vrijednosti što vodi k radu u suboptimalnom području. Predmet istraživanja doktorske disertacije je robusna struktura upravljanja koja je kompatibilna sa standardnom strukturom upravljanja momentom generatora te osigurava rad na naponskom ograničenju uz ispravnu vrijednost razvijenog momenta.

U nastavku su izneseni i ukratko opisani izvorni znanstveni doprinosi doktorske disertacije, a potom je opisana i struktura disertacije.

1.2. Izvorni znanstveni doprinosi

Izvorni znanstveni doprinosi ove doktorske disertacije vezani su uz algoritme upravljanja sinkronim generatorom s unutrašnjim stalnim magnetima:

1. **Metoda estimacije kuta rotora sinkronog vjetrogeneratora sa stalnim magnetima temeljena na mjerenju induciranog napona generatora i fazno zatvorenoj petlji.**
   Prvi doprinos odnosi se na metodu uključenja generatorskog pretvarača tijekom vrtnje generatora (leteći start) i trajni rad bez mjernog člana brzine rotora. Struktura estimacije kuta rotora prije i nakon uključenja je ista te se temelji na fazno zatvorenoj petlji. Razvijena metoda osigurava uključenje generatorskog pretvarača uz mali porast struje i zanemarivi udarac momenta te rad bez mjernog člana brzine rotora u čitavom radnom području generatora.
2. **Algoritam modelskog prediktivnog izravnog upravljanja strujama sinkronog vjetrogeneratora sa stalnim magnetima temeljen na fleksibilnoj Ljapunovljevoj funkciji s ciljem smanjenja sklopnih gubitaka pretvarača.**
   Drugi doprinos uključuje algoritam modelskog prediktivnog upravljanja s dva režima rada kojeg karakterizira izravno upravljanje sklopkama generatorskog pretvarača s ciljem smanjenja sklopnih gubitaka. Korištenjem fleksibilne upravljačke Ljapunovljeve funkcije omogućeno je smanjenje sklopnih gubitaka i u prijelaznoj pojavi. Analiziran je utjecaj mrtvog vremena pretvarača na algoritam. Odgovarajućim odabirom vrijednosti parametara kriterijske funkcije može se postići kompromis između prihvatljivog harmoničkog izobličenja struje i manjih sklopnih gubitaka pretvarača.
3. **Metoda upravljanja naponom i momentom sinkronog vjetrogeneratora sa stalnim magnetima u području slabljenja magnetskog toka.**
   Treći doprinos odnosi se na metodu upravljanja momentom generatora uz rad na ograničenju napona. PI regulatorom napona održava se napon na maksimalnoj dopuštenoj vrijednosti, a PI regulatorom momenta se osigurava održavanje momenta na referentnoj vrijednosti. Metoda osigurava praćenje sjecišta krivulje konstantnog momenta koja odgovara referentnoj vrijednosti i ograničenja napona što je optimalna radna točka u području slabljenja magnetskog toka.

1.3. Struktura disertacije

Poglavlje 1 - U ovom poglavlju prikazana je problematika i područje znanstvenog istraživanja doktorske disertacije. Također su izloženi i ukratko opisani izvorni znanstveni doprinosi te je dana struktura disertacije.

Poglavlje 2 - U ovom poglavlju opisani su različiti tipovi sustava za pretvorbu energije vjetra, s naglaskom na sustav koji uključuje sinkroni generator sa stalnim magnetima i AC-DC-AC pretvarač. Opisan je matematički model sinkronog generatora sa stalnim magnetima u različitim koordinatnim sustavima. Također su opisani standardni algoritmi upravljanja generatorskim i mrežnim dijelom AC-DC-AC pretvarača.

Poglavlje 3 - U ovom poglavlju detaljno je opisan eksperimentalni postav na kojem su verificirani razvijeni algoritmi upravljanja. Priloženi su nazivni podaci sinkronog generatora sa stalnim magnetima, AC-DC-AC pretvarača i asinkronog motora, kao i podaci o mjernoj opremi, poput mjernog člana momenta i mjernih članova struje. Opisan je digitalni sustav upravljanja u kojem su implementirani razvijeni algoritmi, kao i programski alati za grafičko programiranje te nadzor i dijagnostiku.

Poglavlje 4 - Ovo poglavlje vezano je uz prvi znanstveni doprinos. U ovom poglavlju dan je pregled literature vezan uz upravljanje sinkronim strojem sa stalnim magnetima bez mjernog člana brzine rotora. Opisano je mjerenje induciranog napona generatora, faza predsinkronizacije i sinkronizacije razvijene metode te struktura estimacije kuta rotora temeljena na fazno zatvorenoj petlji. Prikazani su simulacijski i eksperimentalni rezultati razvijene metode.

Poglavlje 5 - Ovo poglavlje vezano je uz drugi znanstveni doprinos. U ovom poglavlju dan je pregled literature vezan uz algoritme modelskog prediktivnog upravljanja dvorazinskim pretvaračem i sinkronim strojem sa stalnim magnetima. Izneseni su temeljni principi i terminologija modelskog prediktivnog upravljanja. Izveden je matematički model sustava koji uzima u obzir mrtvo vrijeme pretvarača. Opisan je razvijeni algoritam s dva režima rada koji pripada grupi algoritama s konačnim skupom upravljačkih akcija, s naglaskom na fleksibilnu upravljačku Ljapunovljevu funkciju. Analiziran je utjecaj mrtvog vremena na algoritam upravljanja. Prikazani su simulacijski i eksperimentalni rezultati razvijenog algoritma.

Poglavlje 6 - Ovo poglavlje vezano je uz treći znanstveni doprinos. U ovom poglavlju dan je pregled literature vezan uz slabljenje magnetskog toka sinkronog stroja sa stalnim magnetima. Opisana su ograničenja napona i struje te je razložena razvijena metoda upravljanja momentom u području slabljenja magnetskog toka koja se temelji na PI regulatorima napona i momenta. Prikazana je i trajektorija struje u području slabljenja magnetskog toka. Prikazani su eksperimentalni rezultati razvijene metode.

Poglavlje 7 - U ovom poglavlju komentirani su dobiveni rezultati te je dan zaključak doktorske disertacije.

2. Sustavi za pretvorbu energije vjetra

Sustavi za pretvorbu energije vjetra (engl. *wind energy conversion systems*, WECS) sastoje se od komponenata koji pretvaraju kinetičku energiju vjetra u električnu energiju koja se predaje u elektroenergetski sustav. Načelna struktura sustava za pretvorbu energije vjetra prikazana je na slici 2.1. Navedeni sustav se može podijeliti na mehanički i električni dio [10].

Mehanički dio sustava uključuje toranj, glavčinu, rotorske lopatice, gondolu, mjerni član brzine vjetra (anemometar), pogone za zakretanje gondole i rotorskih lopatica, mehaničku kočnicu te prijenosni mehanizam.

Ulazna kinetička energija vjetra najprije se pretvara u rotacijsku kinetičku energiju lopatica rotora. Efikasnost pretvorbe energije ovisi o različitim faktorima poput brzine vjetra, gustoće zraka, oblika lopatica rotora, kuta lopatica rotora i sl. Pogonima za zakretanje gondole osigurava se zakretanje u smjeru maksimalnog iskorištenja energije vjetra. Kada brzina vjetra postane veća od nazivne vrijednosti pogonom za zakretanje rotorskih lopatica ograničava se izlazna električna snaga na nazivnu vrijednost [10].

Kod standardnih vjetroagregata brzina rotorskih lopatica odnosno turbine je malog iznosa (6-20 okr/min) dok je moment velikog iznosa. S druge strane, većina generatora (uobičajeno su izvedeni s malim brojem pari polova radi jednostavnije konstrukcije i manjih troškova) zahtijeva veću brzinu rotora i manji moment u usporedbi s turbinom. Iz navedenog razloga u većini slučajeva ugrađuje se i prijenosni mehanizam između turbine i generatora kojim se povećava brzina vrtnje uz istovremeno smanjenje momenta. No, ugradnja prijenosnog mehanizma uzrokuje i niz negativnih posljedica poput povećanja cijene čitavog sustava, povećanja buke, češćih kvarova, povećanja troškova održavanja, smanjenja ukupnog stupnja korisnosti i sl. [11].

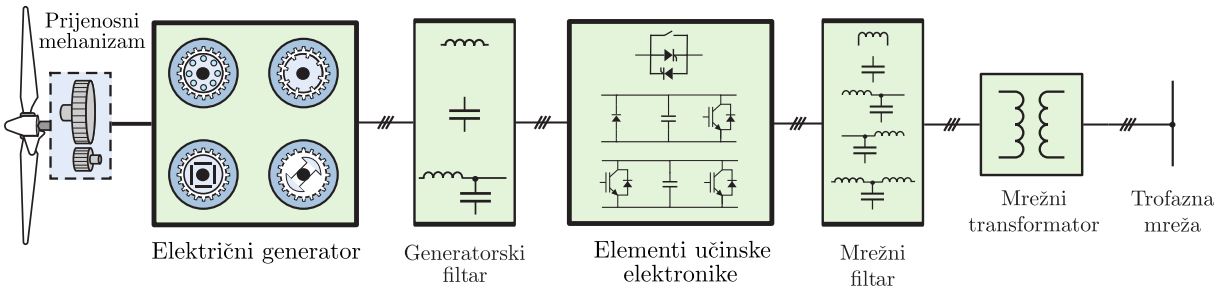

Slika 2.1: Struktura sustava za pretvorbu energije vjetra [11]

S ciljem uklanjanja prijenosnog mehanizma iz sustava, proizvođači turbina nastoje razviti sustave izravnog spoja (engl. *direct drive*) turbine i generatora, osobito za primjenu u sustavima za pretvorbu energije vjetra koji nisu smješteni na kopnu (engl. *offshore*). U navedenom slučaju brzina rotora generatora odgovara brzini rotorskih lopatica turbine pa je prijenosni mehanizam nepotreban. No, da bi se postigla mala brzina rotora generatora potrebno je povećati broj pari polova generatora što predstavlja izazov prilikom projektiranja i konstrukcije električnog stroja. Također, navedeno rješenje moguće je samo za sinkrone generatore sa stalnim magnetima i sinkrone generatore s uzbudnim namotom, dok se u slučaju asinkronih generatora ne može ukloniti prijenosni mehanizam jer se u pravilu radi o brzohodnim strojevima. Posljedica povećanja broja pari polova sinkronog generatora je značajno povećanje promjera i mase, a time i cijene generatora [5, 10].

Temeljni dio električnog dijela sustava je električni generator koji pretvara kinetičku rotacijsku energiju u električnu energiju koja se naposljetku predaje u elektroenergetski sustav. Kao vjetrogeneratori koriste se asinkroni kavezni generatori (engl. *squirrel cage induction generator*, SCIG), klizno-kolutni asinkroni generatori (engl. *wound rotor induction generator*, WRIG), dvostruko napajani asinkroni generatori (engl. *doubly fed induction generator*, DFIG), sinkroni generatori s uzbudnim namotom (engl. *wound rotor synchronous generator*, WRSG) te sinkroni generatori sa stalnim magnetima (engl. *permanent magnet generator*, PMG). U prvim razvijenim sustavima za pretvorbu energije vjetra asinkroni generator je bio spojen izravno spojen na električnu mrežu, no razvojem sklopova učinske elektronike sve veći broj vjetrogeneratora spojen je na električnu mrežu preko AC-DC-AC pretvarača. Uslijed sklapanja IGBT-ova (engl. *insulate gate bipolar transistor*) pretvarača dolazi do harmoničkog izobličenja struje i napona stoga je potrebna ugradnja filtra, osobito na mrežnoj strani s ciljem ostvarivanja kvalitete električne energije prema mrežnim pravilima na mjestu priključka na elektroenergetski sustav.

2.1. Tipovi sustava za pretvorbu energije vjetra

Na slici 2.2 prikazana su četiri različita tipa sustava za pretvorbu energije vjetra koja se razlikuju s obzirom na tip korištenog generatora i sklopove učinske elektronike te opseg upravljivosti brzinom rotora vjetrogeneratora:

- **Tip 1**: konstantna brzina rotora ($\pm 1\%$ sinkrone brzine)
- **Tip 2**: poluupravljiva brzina rotora ($\pm 10\%$ sinkrone brzine)
- **Tip 3**: poluupravljiva brzina rotora ($\pm 30\%$ sinkrone brzine)
- **Tip 4**: punoupravljiva brzina rotora ($0 - 100\%$ sinkrone brzine)

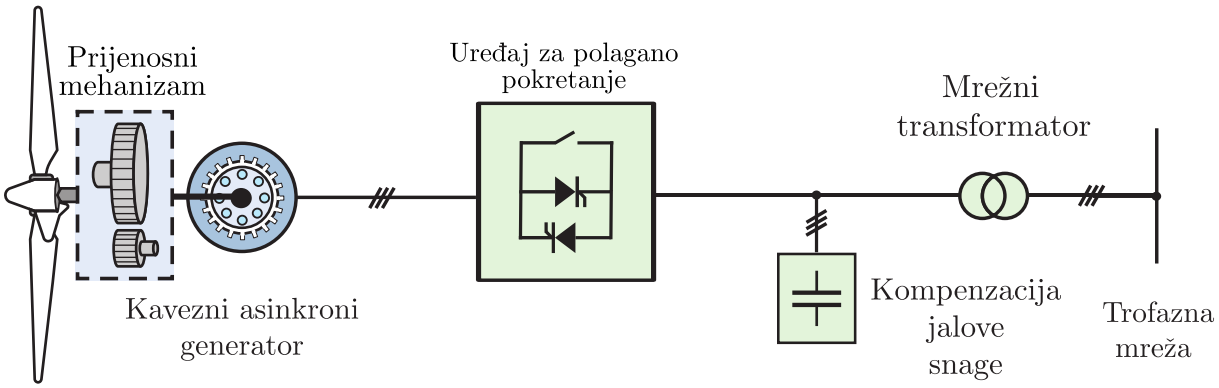

(a) Tip 1

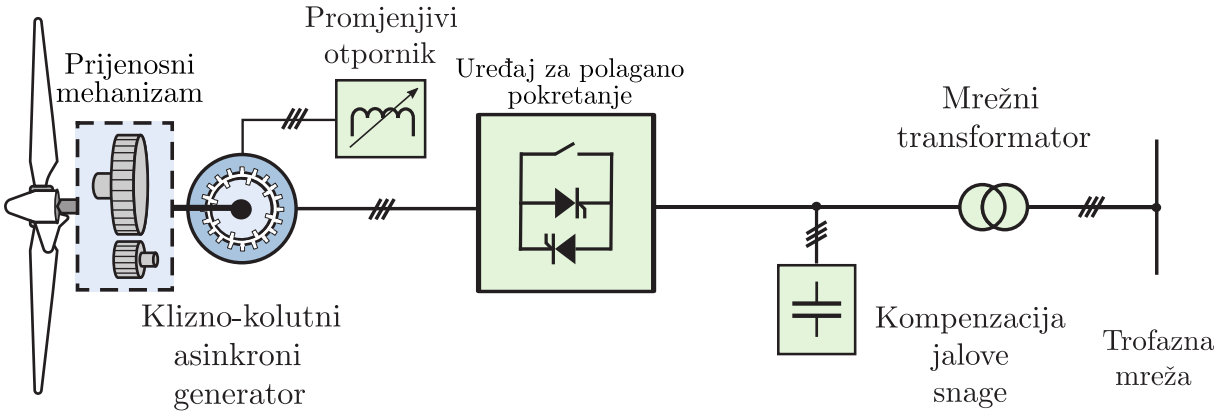

(b) Tip 2

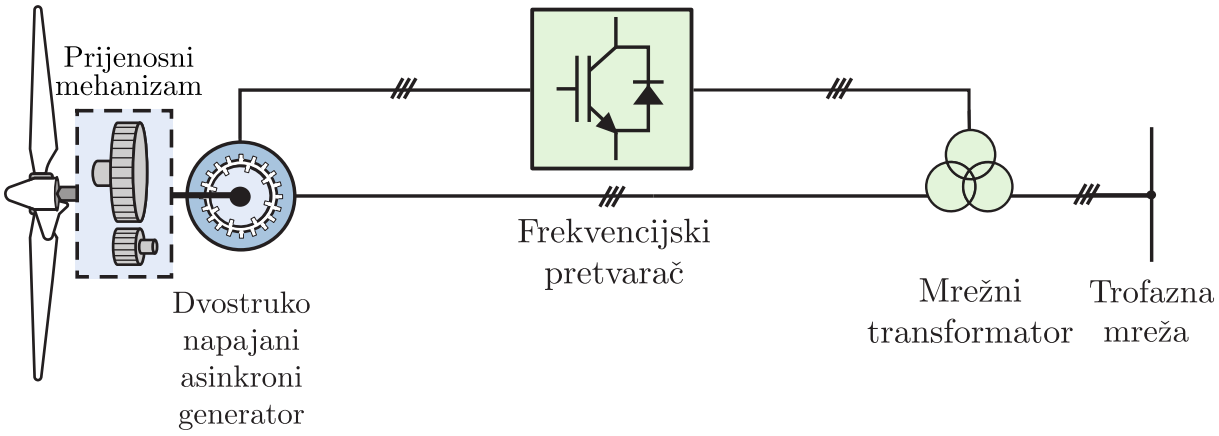

(c) Tip 3

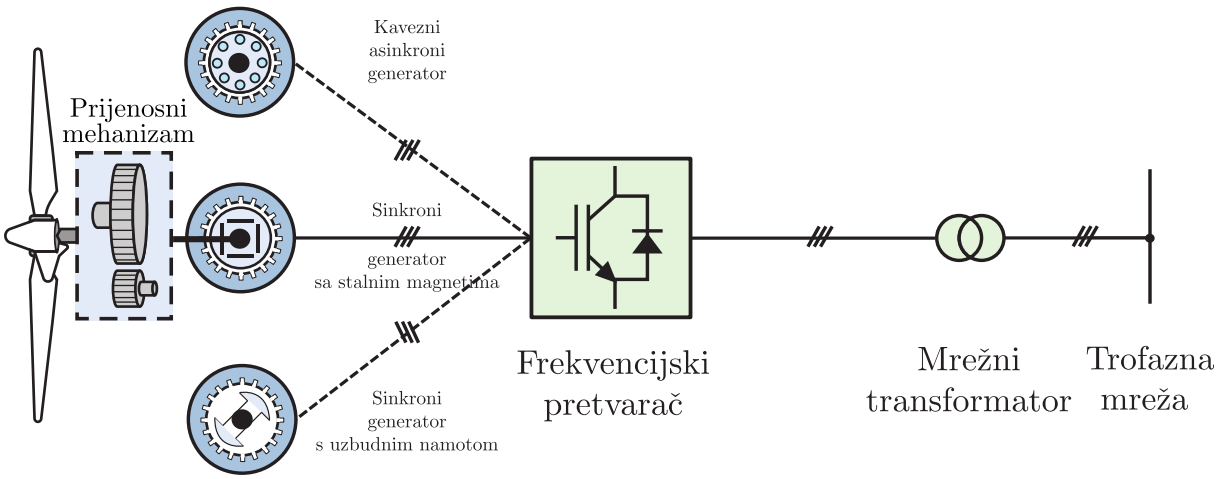

(d) Tip 4

Slika 2.2: Tipovi sustava za pretvorbu energije vjetra [11]

Prvi tip sustava za pretvorbu energije vjetra karakterizira vrlo usko područje brzine rotora ($\pm 1\%$ sinkrone brzine). U navedenoj strukturi asinkroni kavezni generator je povezan s turbinom preko prijenosnog mehanizma s više razina prijenosa (engl. *multiple stage gearbox*) te je istovremeno spojen na električnu mrežu preko transformatora. Uređaj za polagano pokretanje (engl. *soft starter*) koristi se prilikom pokretanja, dok je generator izravno spojen na električnu mrežu u normalnom režimu rada. Radi se o konvencionalnom rješenju aktualnom 1980-ih i 1990-ih godina, prvenstveno korištenom od strane danskih proizvođača (iz tog razloga se navedeni koncept često naziva i *danski koncept*). Budući da je za magnetiziranje asinkronog stroja potrebna jalova energija, u strukturu je uvedena i kompenzacija jalove snage putem kondenzatora. Prednosti ovog tipa sustava su robusnost, jednostavnost i niska cijena. S druge strane, nedostaci ovog tipa sustava su manji stupanj korisnosti sustava uslijed konstantne brzine rotora, izravno prenošenje fluktuacija ulazne snage vjetra u električnu mrežu, negativan električni i mehanički učinak propada napona na strani električne mreže na cjelokupni sustav [10, 12, 13].

Drugi tip sustava za pretvorbu energije vjetra karakterizira usko područje brzine rotora ($\pm 10\%$ sinkrone brzine). Slično kao u prethodno opisanoj strukturi, asinkroni klizno-kolutni generator je povezan s turbinom preko prijenosnog mehanizma s više razina prijenosa te je stator generatora spojen na električnu mrežu preko transformatora. Promjena brzine rotora ostvaruje se dodatnim otpornicima spojenim u seriju s otporom rotorskog kruga. U ovoj strukturi višak energije koju preuzima rotor se disipira na dodatnim otpornicima čime se povećavaju gubici u sustavu te smanjuje stupanj korisnost. Dodavanje otpora u rotorski krug ostvareno je putem sklopa učinske elektronike koji se sastoji od diodnog ispravljača i čopera. Kao i u prethodno opisanom tipu sustava, potreban je uređaj za polagano pokretanje te kompenzacija jalove snage [10, 12].

Treći tip sustava za pretvorbu energije vjetra karakterizira nešto šire područje brzine rotora ($\pm 30\%$ sinkrone brzine) u usporedbi s prethodno opisana dva tipa sustava. U navedenoj strukturi dvostruko napajani asinkroni generator je povezan s turbinom preko prijenosnog mehanizma s više razina prijenosa, stator generatora je preko transformatora spojen na električnu mrežu, dok je rotorski krug preko AC-DC-AC pretvarača djelomične snage (30% nazivne snage generatora) i transformatora spojen na električnu mrežu. Za razliku od drugog tipa gdje se energija disipira na dodatnom otporu, u trećem tipu sustava energija se iz rotorskog kruga preko pretvarača predaje u električnu mrežu što čini povećava stupanj korisnosti. Također, za razliku od prethodno opisana dva tipa sustava, nije potreban uređaj za polagano pokretanje niti kompenzacija jalove snage [10, 12].

Četvrti tip sustava za pretvorbu energije vjetra karakterizira potpuna upravljivost brzinom rotora u čitavom radnom području ($0 - 100\%$ sinkrone brzine). Navedeni tip sustava može biti ostvaren s asinkronim kaveznim generatorom (s prijenosnim mehanizmom), sinkronim generatorom s uzbudnim namotom ili sinkronim generatorom sa stalnim magnetima (s ili bez

prijenosnog mehanizma). Generator je preko AC-DC-AC pretvarača pune snage (snaga odgovara nazivnoj snazi generatora) spojen na električnu mrežu. Sinkroni generatori s uzbudnim namotom ili stalnim magnetima na rotoru mogu biti projektirani za niske brzine koje odgovaraju brzini lopatica rotora te u tom slučaju nije potreban prijenosni mehanizam. No, glavni nedostatak ovog rješenja je znatno veći promjer kao i masa generatora. Sustavi za pretvorbu energije koji uključuju AC-DC-AC pretvarač pune snage nude brojne prednosti poput upravljivosti brzinom rotora u čitavom radnom području čime je moguće upravljanje brzinom tako da je iskorištenje ulazne snage vjetra optimalno u svakoj radnoj točki. Također, generator je putem pretvarača odvojen od mreže te je odgovarajućim algoritmima upravljanja moguće osigurati zaštitu sustava u slučaju propada napona električne mreže, kao i upravljanje jalovom snagom koja se predaje u električnu mrežu [10, 12].

Zbog brojnih opisanih prednosti četvrti tip sustava za pretvorbu energije vjetra, osobito rješenje sa sinkronim generatorom sa stalnim magnetima i dvorazinskim AC-DC-AC pretvaračem, preuzima dominaciju na tržištu te postaje predmet brojnih znanstvenih istraživanja. U nastavku doktorske disertacije navedeni tip sustava je detaljnije analiziran.

2.2. Matematički model sinkronog stroja sa stalnim magnetima

Matematički model sinkronog stroja sa stalnim magnetima se može prikazati u trofaznom mirujućem *abc* sustavu sljedećim naponskim izrazima:

$$\begin{bmatrix} u_a \\ u_b \\ u_c \end{bmatrix} = \begin{bmatrix} R_{sa} & 0 & 0 \\ 0 & R_{sb} & 0 \\ 0 & 0 & R_{sc} \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} + \frac{\mathrm{d}}{\mathrm{d}t} \begin{bmatrix} \psi_a \\ \psi_b \\ \psi_c \end{bmatrix}, \tag{2.1}$$

gdje je $\boldsymbol{u}_{abc}$ napon statora, $\boldsymbol{i}_{abc}$ struja statora, $\boldsymbol{\psi}_{abc}$ magnetski tok, a R_{sa}, R_{sb} i R_{sc} otpor statora pojedine faze. Pretpostavka je da je otpor statora jednak u sve tri faze, tj. da vrijedi $R_{sa} = R_{sb} = R_{sc} = R_s$. Magnetski tok u *abc* sustavu se može prikazati kao:

$$\begin{bmatrix} \psi_a \\ \psi_b \\ \psi_c \end{bmatrix} = \begin{bmatrix} L_{aa} + L_{a\sigma} & L_{ab} & L_{ac} \\ L_{ba} & L_{bb} + L_{b\sigma} & L_{bc} \\ L_{ca} & L_{cb} & L_{cc} + L_{c\sigma} \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} + \psi_{md} \begin{bmatrix} \cos(\theta_{re}) \\ \cos(\theta_{re} - 2\pi/3) \\ \cos(\theta_{re} - 4\pi/3) \end{bmatrix}, \tag{2.2}$$

gdje je ψ_{md} magnetski tok stalnih magneta poravnat s uzdužnom (d) osi, θ_{re} električni kut rotora (kut između osi stalnih magneta na rotoru i osi faze a), L_{aa}, L_{bb} i L_{cc} samoinduktiviteti pojedinih faza, L_{ab}, L_{ba}, L_{bc}, L_{cb}, L_{ac} i L_{ca} međuinduktiviteti između faza, a $L_{a\sigma}$, $L_{b\sigma}$ i $L_{c\sigma}$ rasipni induktiviteti pojedinih faza. Pretpostavka je da su rasipni induktiviteti jednaki u sve tri faze, kao i da su međuinduktiviteti između pojedinih faza jednaki, tj. da vrijedi $L_{a\sigma} = L_{b\sigma} = L_{c\sigma} = L_\sigma$ te $L_{ab} = L_{ba}$, $L_{bc} = L_{cb}$ i $L_{ac} = L_{ca}$.

Samoinduktiviteti L_{aa}, L_{bb} i L_{cc} mogu se prikazati sljedećim izrazima:

$$\begin{aligned} L_{aa} &= L_0 + L_2 \cos(2\theta_{re}), \\ L_{bb} &= L_0 + L_2 \cos(2\theta_{re} + 2\pi/3), \\ L_{cc} &= L_0 + L_2 \cos(2\theta_{re} + 4\pi/3). \end{aligned} \tag{2.3}$$

Međuinduktiviteti L_{ab}, L_{bc} i L_{ac} se mogu prikazati sljedećim izrazima:

$$\begin{aligned} L_{ab} = L_{ba} &= -\frac{1}{2}L_0 + L_2 \cos(2\theta_{re} - 2\pi/3), \\ L_{bc} = L_{cb} &= -\frac{1}{2}L_0 + L_2 \cos(2\theta_{re} - 4\pi/3), \\ L_{ac} = L_{ca} &= -\frac{1}{2}L_0 + L_2 \cos(2\theta_{re}), \end{aligned} \tag{2.4}$$

gdje je $L_0 = \frac{L_d + L_q}{2}$ srednja vrijednost induktiviteta, dok je $L_2 = \frac{L_d - L_q}{2}$ amplituda oscilacija induktiviteta. Iz priloženih izraza može se uočiti da je matematički model sinkronog stroja u *abc* koordinatnom sustavu složen jer vrijednosti induktiviteta ovise o poziciji rotora. Iz navedenog razloga ovakav matematički zapis se vrlo rijetko koristi prilikom sinteze struktura upravljanja.

2.2.1. Vektorski prikaz trofaznih izmjeničnih veličina

Uobičajeno je korištenje vektorskog prikaza električnih veličina stroja poput napona, struje ili magnetskog toka. U slučaju sinkronog generatora sa stalnim magnetima statorski namoti faza su prostorno pomaknuti za 120° te su napajani trofaznim izmjeničnim naponom čije su faze vremenski također pomaknute za 120° prema sljedećem izrazu:

$$\begin{aligned} f_a(t) &= F_m \cos(\omega t), \\ f_b(t) &= F_m \cos(\omega t - 2\pi/3), \\ f_c(t) &= F_m \cos(\omega t - 4\pi/3), \end{aligned} \tag{2.5}$$

gdje je F_m amplituda, a ω kružna frekvencija izmjeničnih veličina. Uzimajući u obzir prostorni razmak statorskog namota i vremenski razmak izmjeničnih veličina formira se sljedeći prostorni vektor:

$$\boldsymbol{f} = \frac{2}{3}(f_a + \boldsymbol{a} f_b + \boldsymbol{a^2} f_c) = F_m e^{j\omega t}, \tag{2.6}$$

gdje su f_a, f_b i f_c trenutne vrijednosti faznih veličina, $\boldsymbol{a} = e^{j\frac{2\pi}{3}} = -\frac{1}{2} + j\frac{\sqrt{3}}{2}$ je zakret za 120° (os faze *b*), dok je $\boldsymbol{a}^2 = e^{j\frac{4\pi}{3}} = -\frac{1}{2} - j\frac{\sqrt{3}}{2}$ zakret za 240° (os faze *c*).

2.2.2. Clarkina i Parkova transformacija

Alternativa trofaznom mirujućem *abc* koordinatnom sustavu je dvofazni mirujući $\alpha\beta$ sustav gdje se os faze α poklapa s osi faze *a*, dok je os faze β okomita na nju. Prethodno uvedeni prostorni vektor (2.6) može se prikazati kao:

$$\boldsymbol{f} = f_\alpha + jf_\beta. \tag{2.7}$$

Transformacija iz trofaznog *abc* u dvofazni $\alpha\beta$ koordinatni sustav, tj. Clarkina transformacija može se ostvariti sljedećom izrazom:

$$\begin{aligned} \boldsymbol{f} = f_\alpha + jf_\beta &= \left[f_a - \frac{1}{2}f_b + j\frac{\sqrt{3}}{2}f_b - \frac{1}{2}f_c - j\frac{\sqrt{3}}{2}f_c\right] \\ f_\alpha &= \frac{2}{3}\left[f_a - \frac{1}{2}(f_b + f_c)\right], \\ f_\beta &= \frac{1}{\sqrt{3}}\left[f_b - f_c\right]. \end{aligned} \tag{2.8}$$

Budući da se radi o vremenski pomaknutim veličinama za 120°, vrijedi sljedeći izraz:

$$f_a + f_b + f_c = 0. \tag{2.9}$$

Uzimajući u obzir izraz (2.9), slijedi matrica Clarkine transformacije iz trofaznog *abc* u dvofazni $\alpha\beta$ sustav:

$$\begin{bmatrix} f_\alpha \\ f_\beta \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \frac{1}{\sqrt{3}} & -\frac{1}{\sqrt{3}} \end{bmatrix} \begin{bmatrix} f_a \\ f_b \\ f_c \end{bmatrix}. \tag{2.10}$$

Transformacija iz dvofaznog $\alpha\beta$ u trofazni *abc* sustav, tj. inverzna Clarkina transformacija se može prikazati sljedećim izrazom:

$$\begin{bmatrix} f_a \\ f_b \\ f_c \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ -\frac{1}{2} & \frac{\sqrt{3}}{2} \\ -\frac{1}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} f_\alpha \\ f_\beta \end{bmatrix}. \tag{2.11}$$

Navedene veličine moguće je transformirati i u rotirajući koordinatni sustav. Ako kutna brzina koordinatnog sustava u kojeg se transformiraju veličine odgovara kutnoj brzini signala nad kojim se vrši transformacija, tada izmjenični signal postaje istosmjeran u rotirajućem koordinatnom sustavu. Navedeno svojstvo od osobite je važnosti u području upravljanja izmjeničnim električnim strojevima budući da je tako moguće izmjenične veličine pretvoriti u istosmjerne te ostvariti analogiju upravljanja istosmjernim strojem.

Ako se definira rotirajući koordinatni sustav s uzdužnom osi *d* (odgovara osi stalnih magneta

na rotoru) i poprečnom osi q, ranije uvedeni prostorni vektor (2.6) se može zapisati sljedećim izrazom:

$$\boldsymbol{f} = f_d + jf_q. \tag{2.12}$$

Vrijednosti komponenata f_d i f_q se mogu odrediti iz komponenata f_α i f_β, uz poznavanje kuta θ kojeg zatvara uzdužna d os rotirajućeg koordinatnog sustava s osi α mirujućeg koordinatnog sustava. Transformacija iz dvofaznog mirujućeg $\alpha\beta$ u dvofazni rotirajući dq koordinatni sustav, tj. Parkova transformacija se može prikazati sljedećim izrazom:

$$\begin{bmatrix} f_d \\ f_q \end{bmatrix} = \begin{bmatrix} \cos(\theta) & \sin(\theta) \\ -\sin(\theta) & \cos(\theta) \end{bmatrix} \begin{bmatrix} f_\alpha \\ f_\beta \end{bmatrix}. \tag{2.13}$$

Transformacija iz dvofaznog rotirajućeg dq u dvofazni mirujući $\alpha\beta$ koordinatni sustav, tj. inverzna Parkova transformacija se može prikazati sljedećim izrazom:

$$\begin{bmatrix} f_\alpha \\ f_\beta \end{bmatrix} = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \begin{bmatrix} f_d \\ f_q \end{bmatrix}. \tag{2.14}$$

2.2.3. Matematički model generatora u $\alpha\beta$ koordinatnom sustavu

Primjenom Clarkine transformacije na matematički model generatora u trofaznom *abc* koordinatnom sustavu (2.1) slijedi matematički model u dvofaznom mirujućem $\alpha\beta$ koordinatnom sustavu:

$$\begin{bmatrix} u_\alpha \\ u_\beta \end{bmatrix} = \begin{bmatrix} R_s & 0 \\ 0 & R_s \end{bmatrix} \begin{bmatrix} i_\alpha \\ i_\beta \end{bmatrix} + \frac{\mathrm{d}}{\mathrm{d}t} \begin{bmatrix} \psi_\alpha \\ \psi_\beta \end{bmatrix}, \tag{2.15}$$

gdje je $\boldsymbol{u}_{\alpha\beta}$ napon statora, $\boldsymbol{i}_{\alpha\beta}$ struja statora, a $\boldsymbol{\psi}_{\alpha\beta}$ magnetski tok. Magnetski tok se može prikazati sljedećim izrazom:

$$\begin{bmatrix} \psi_\alpha \\ \psi_\beta \end{bmatrix} = \begin{bmatrix} L_0 + L_2\cos(2\theta_{re}) & L_2\sin(2\theta_{re}) \\ L_2\sin(2\theta_{re}) & L_0 - L_2\cos(2\theta_{re}) \end{bmatrix} \begin{bmatrix} i_\alpha \\ i_\beta \end{bmatrix} + \psi_{md} \begin{bmatrix} \cos(\theta_{re}) \\ \sin(\theta_{re}) \end{bmatrix}. \tag{2.16}$$

Može se uočiti da i u $\alpha\beta$ koordinatnom sustavu induktiviteti ovise o položaju rotora, što čini ovakav matematički zapis često neprikladnim za sintezu sustava upravljanja. Ipak, u slučaju sinkronog stroja sa stalnim magnetima na površini rotora ($L_d = L_q$), član L_2 iščezava budući da ovisi o razlici navedenih veličina stoga u tom slučaju ovakav zapis postaje jednostavniji.

2.2.4. Matematički model generatora u sinkronom dq koordinatnom sustavu

Primjenom Parkove transformacije s električnim kutem rotora θ_{re} na matematički model generatora u dvofaznom mirujućem $\alpha\beta$ koordinatnom sustavu (2.15) i (2.16) slijedi matematički

model u sinkronom dq koordinatnom sustavu koji rotira električnom kutnom brzinom rotora:

$$\begin{bmatrix} u_d \\ u_q \end{bmatrix} = \begin{bmatrix} R_s + \frac{\mathrm{d}}{\mathrm{d}t}L_d & -\omega_{re}L_q \\ \omega_{re}L_d & R_s + \frac{\mathrm{d}}{\mathrm{d}t}L_q \end{bmatrix} \begin{bmatrix} i_d \\ i_q \end{bmatrix} + \begin{bmatrix} 0 \\ \omega_{re}\psi_{md} \end{bmatrix}, \tag{2.17}$$

gdje je $\boldsymbol{u}_{dq}$ napon statora, $\boldsymbol{i}_{dq}$ struja statora, ω_{re} električna kutna brzina rotora, L_d i L_q induktiviteti u uzdužnoj (d) i poprečnoj (q) osi. Magnetski tok se može zapisati sljedećim izrazom:

$$\begin{bmatrix} \psi_d \\ \psi_q \end{bmatrix} = \begin{bmatrix} L_d & 0 \\ 0 & L_q \end{bmatrix} \begin{bmatrix} i_d \\ i_q \end{bmatrix} + \begin{bmatrix} \psi_{md} \\ 0 \end{bmatrix}. \tag{2.18}$$

Elektromagnetski moment se može izraziti vektorskim umnoškom vektora struje i vektora magnetskog toka, neovisno o koordinatnom sustavu, tj. vrijedi:

$$M_{em} = \frac{3}{2}p|\boldsymbol{\psi} \times \boldsymbol{i}|. \tag{2.19}$$

Razlaganjem vektora struje i magnetskog toka u mirujućem $\alpha\beta$ i rotirajućem dq koordinatnom sustavu na komponente slijedi:

$$\begin{aligned} M_{em,\alpha\beta} &= \frac{3}{2}p(\psi_\alpha i_\beta - \psi_\beta i_\alpha), \\ M_{em,dq} &= \frac{3}{2}p(\psi_d i_q - \psi_q i_d). \end{aligned} \tag{2.20}$$

Ako se u izraz (2.20) za elektromagnetski moment $M_{em,dq}$ uvrsti izraz (2.18), slijedi poznati izraz za elektromagnetski moment sinkronog stroja sa stalnim magnetima:

$$M_{em} = \frac{3}{2}p\big(\psi_{md}i_q + (L_d - L_q)i_d i_q\big). \tag{2.21}$$

2.3. Strukture upravljanja AC-DC-AC pretvaračem

Na slici 2.3 prikazan je sustav za pretvorbu energije vjetra četvrtog tipa koji se sastoji od vjetroturbine, prijenosnog mehanizma, sinkronog generatora sa stalnim magnetima, AC-DC-AC pretvarača, LCL filtra te transformatora. AC-DC-AC pretvarač se može podijeliti na generatorski i mrežni dio te istosmjerni međukrug koji ih povezuje. Topologija oba dijela pretvarača je istovjetna, tj. u slučaju dvorazinskog pretvarača radi se o trofaznom mosnom spoju gdje su sklopke IGBT-ovi s poprednim diodama.

Glavna funkcija generatorskog dijela pretvarača je upravljanje momentom generatora s ciljem rada u optimalnoj radnoj točki vjetroturbine. Referentna vrijednost momenta generatora prosljeđuje se iz nadređenog sustava turbinske regulacije. Nadređeni sustav prati točku maksimalnog iskorištenja snage vjetra (engl. *maximum power point tracking*, MPPT) te prosljeđuje referentnu vrijednost momenta upravljačkom sustavu generatorskog dijela AC-DC-AC pretvarača koji osigurava razvijanje potrebnog momenta [7]. Budući da se radi o konfiguraciji sustava s punom upravljivošću, moguće je pri svakoj brzini vjetra postići maksimalno iskorištenje energije vjetra. Također postoje izvedbe gdje je upravljačka veličina brzina rotora umjesto momenta generatora [7].

Uobičajene strukture upravljanja 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). Glavna svojstva vektorskog upravljanja su raspregnuto upravljanje strujama stroja u uzdužnoj i poprečnoj osi u sinkronom *dq* koordinatnom sustavu, uz korištenje pulsno-širinske modulacije (engl. *pulse-width modulation*, PWM) za generiranje napona željene amplitude i faze na izlazu generatorskog pretvarača. Budući da se koristi pulsno-širinska modulacija s predefiniranim brojem promjena sklopnih stanja tijekom jedne periode, sklopna frekvencija je u ovom slučaju konstantna. S druge strane,

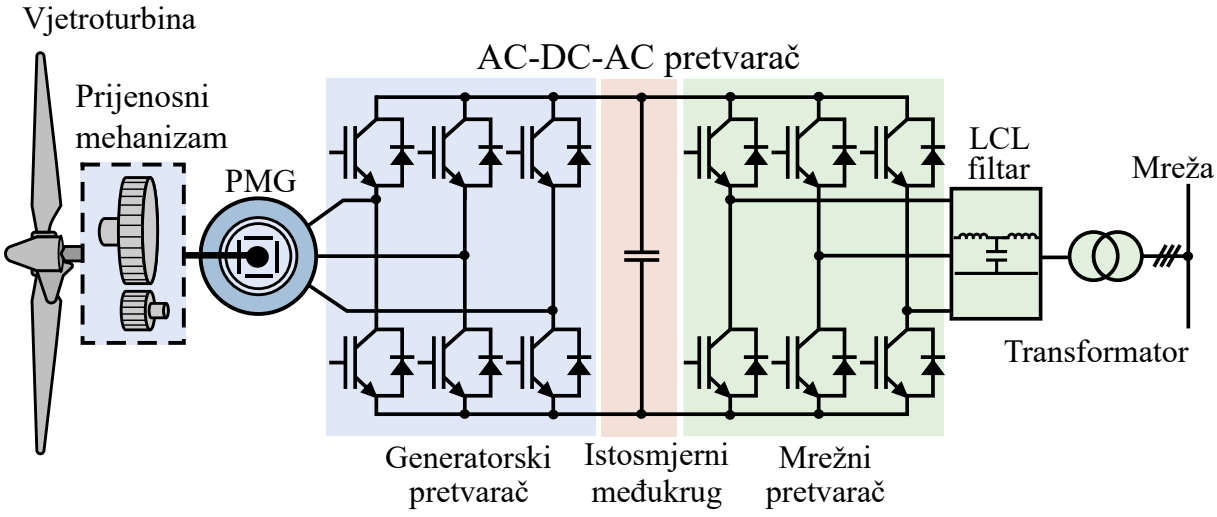

Slika 2.3: Struktura razmatranog sustava za pretvorbu energije vjetra

izravno upravljanje momentom karakterizira izravno upravljanje magnetskim tokom i elektromagnetskim momentom putem histereznih regulatora bez korištenja modulacije što uzrokuje značajno harmoničko izobličenje struje i oscilacije momenta, promjenjivu sklopnu frekvenciju, ali i visoke dinamičke performanse [14].

Glavna funkcija mrežnog dijela pretvarača je upravljanje radnom i jalovom snagom koja se predaje u električnu mrežu. Osim upravljanjem tokom snage, mrežni pretvarač treba osigurati i sinkronizaciju s električnom mrežom putem fazno zatvorene petlje, kao i osigurati zaštitu sustava u slučaju propada napona mreže (engl. *low voltage ride through*, LVRT).

Uobičajene strukture upravljanja mrežnim pretvaračem su vektorsko upravljanje u koordinatnom sustavu napona mreže (engl. *voltage oriented control*, VOC) te izravno upravljanje snagom (engl. *direct power control*, DPC). Prva navedena struktura, tj. vektorsko upravljanje, analogna je strukturi vektorskog upravljanja generatorskim pretvaračem, tj. radi se o raspregnutom upravljanju radnom i jalovom snagom temeljenom na PI regulatorima struja mreže i PWM-u. S druge strane, izravno upravljanje snagom je analogno izravnom upravljanju momentom kod generatorskog pretvarača, tj. temelji se na histereznim regulatorima radne i jalove snage te izravnom upravljanju IGBT-ovima mrežnog dijela pretvarača [15].

Budući da se razvijene strukture upravljanja u doktorskoj disertaciji temelje na vektorskom upravljanju u koordinatnom sustavu magnetskog toka rotora na generatorskom dijelu pretvarača, navedena struktura će biti detaljnije opisana u nastavku.

2.3.1. Struktura upravljanja generatorskim dijelom AC-DC-AC pretvarača

Na slici 2.4 prikazana je standardna struktura vektorskog upravljanja u koordinatnom sustavu magnetskog toka rotora (RFOC). Mjerene veličine su struja $\boldsymbol{i}_{abc}$ te mehanička brzina $\boldsymbol{\omega}_r$

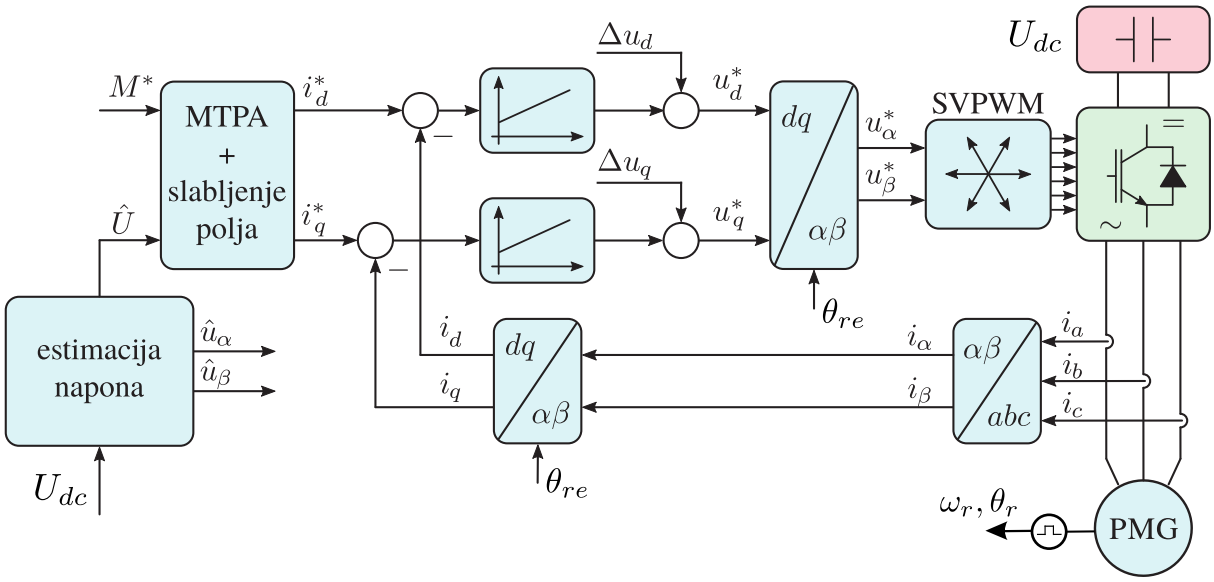

Slika 2.4: Standardna struktura upravljanja generatorskim dijelom AC-DC-AC pretvarača

i mehanički kut θ_r rotora. Mehaničke veličine se množenjem s brojem pari polova pretvaraju u električne veličine, tj. vrijedi $\omega_{re} = p\omega_r$ i $\theta_{re} = p\theta_r$. Nakon provođenja Clarkine transformacije nad mjerenim strujama provodi se i Parkova transformacija s električnim kutem rotora θ_{re} te slijede struje $\boldsymbol{i}_{dq}$. Razlika referentnih vrijednosti struja $\boldsymbol{i}^*_{dq}$ i mjerenih vrijednosti struja $\boldsymbol{i}_{dq}$ predstavlja regulacijsko odstupanje koje je ulaz u PI regulatore struja u uzdužnoj (d) i poprečnoj (q) osi. Izlaznim veličinama PI regulatora dodaju se signali rasprezanja Δu_d i Δu_q koji se proračunavaju na temelju modela sinkronog stroja sa stalnim magnetima u sinkronom dq koordinatnom sustavu (2.17):

$$\begin{aligned} \Delta u_d &= -\omega_{re} L_q i_q, \\ \Delta u_q &= \omega_{re}(L_d i_d + \psi_{md}). \end{aligned} \tag{2.22}$$

Zbroj izlaza PI regulatora i signala rasprezanja čini referentnu vrijednost napona $\boldsymbol{u}^*_{dq}$. Primjenom inverzne Parkove transformacije s električnim kutem rotora θ_{re} slijede referentne vrijednosti napona $\boldsymbol{u}^*_{\alpha\beta}$ koje se prosljeđuju prema pulsno-širinskoj modulaciji. U primjeru na slici je prikazana vektorska modulacija širine impulsa (engl. *space vector pulse width modulation*, SVPWM). Navedeni tip modulacije čest je u industrijskoj primjeni, jer nudi veću mogućnost iskorištenja napona istosmjernog međukruga u usporedbi sa sinusnom pulsno-širinskom modulacijom. PI regulatori struje se obično podešavaju prema tehničkom optimumu [16].

Kao što je navedeno ranije u tekstu, referentna vrijednost momenta M^* slijedi iz nadređenog sustava turbinske regulacije. Kod sinkronih strojeva sa stalnim magnetima uobičajen algoritam određivanja referentnih vrijednosti struja $\boldsymbol{i}^*_{dq}$ na temelju referentne vrijednosti elektromagnetskog momenta M^* je MTPA (engl. *maximum torque per ampere*). Navedeni algoritam određuje par referentnih vrijednosti struja (i^*_d, i^*_q) kojim se ostvaruje zadani moment uz minimalnu amplitudu struje čime se minimiziraju gubici u namotu statora [17–19].

Također, uobičajeno je da uz standardnu strukturu vektorskog upravljanja postoji i algoritam slabljenja magnetskog polja kojim se osigurava rad iznad nazivne brzine rotora. Standardna struktura kojom se osigurava rad u području slabljenja polja je dodatni regulator napona kojim se povećava negativna struja u d osi i time održava napon na dozvoljenoj granici. Kao signal povratne veze pritom se koristi napon $\hat{U}$ koji se rekonstruira na temelju mjerenog napona istosmjernog međukruga U_{dc} i sklopnih stanja IGBT-ova.

2.3.2. Struktura upravljanja mrežnim dijelom AC-DC-AC pretvarača

Na slici 2.5 prikazana je standardna struktura vektorskog upravljanja u koordinatnom sustavu napona mreže (VOC). Kut napona mreže određuje se korištenjem fazno zatvorene petlje

na temelju mjerenog napona $\boldsymbol{u}_{mabc}$ te se time mjereni napon smješta u d os, tj. vrijedi:

$$\begin{aligned} u_{md} &= U_m, \\ u_{mq} &= 0. \end{aligned} \tag{2.23}$$

gdje je U_m amplituda napona mreže. Radna i jalova snaga koja se predaju u mrežu mogu se proračunati prema sljedećim izrazima:

$$\begin{aligned} P_m &= \frac{3}{2}(u_{md}i_{md} + u_{mq}i_{mq}), \\ Q_m &= \frac{3}{2}(u_{mq}i_{md} - u_{md}i_{mq}). \end{aligned} \tag{2.24}$$

U standardnoj strukturi upravljanja mrežnim pretvaračem mjerene veličine su struje mreže $\boldsymbol{i}_{mabc}$ koje se Clarkinom i potom Parkovom transformacijom s kutem napona mreže θ_m transformiraju u sinkroni dq koordinatni sustav, tj. u veličine $\boldsymbol{i}_{mdq}$. U strukturi su nadređeni regulacijski krugovi napona istosmjernog međukruga i jalove snage koja se predaje u električnu mrežu. Izlaz iz PI regulatora napona istosmjernog međukruga je referentna vrijednost radne komponente struje i^*_{md}, dok je izlaz PI regulatora jalove snage referentna vrijednost jalove komponente struje i^*_{mq}. Od navedenih referentnih vrijednosti oduzimaju se odgovarajuće mjerene komponente struje te slijede regulacijska odstupanja koja su ulazi PI regulatora podređenog re-

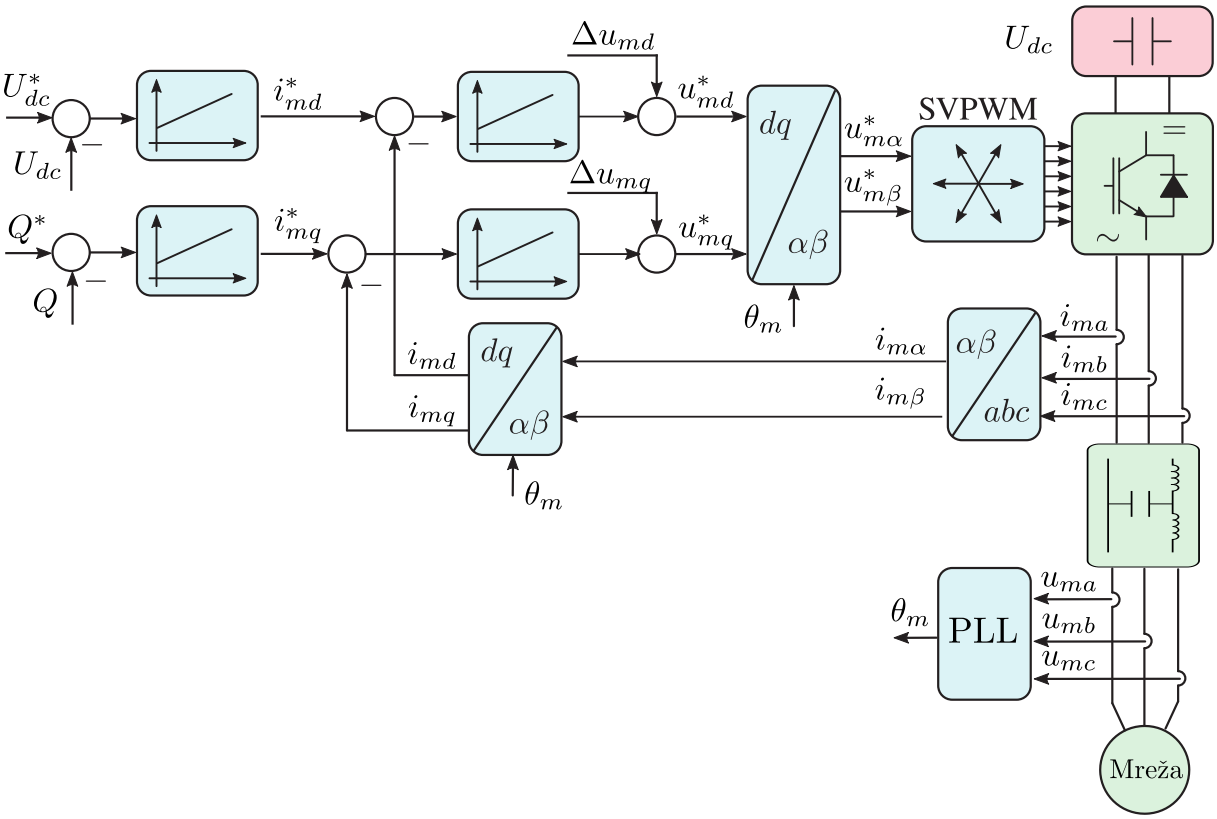

Slika 2.5: Standardna struktura upravljanja mrežnim dijelom AC-DC-AC pretvarača

gulacijskog kruga. Izlaznim veličinama regulatora struja dodaju se signali rasprezanja Δu_{md} i Δu_{mq} koji se proračunavaju na temelju modela sustava između mrežnog pretvarača i električne mreže što uključuje LCL filtar. Signali rasprezanja jednaki su sljedećim izrazima:

$$\begin{aligned} \Delta u_{md} &= u_{md} - \omega_m L_f i_{mq}, \\ \Delta u_{mq} &= u_{mq} + \omega_m L_f i_{md}. \end{aligned} \tag{2.25}$$

gdje su $\boldsymbol{u}_{mdq}$ i $\boldsymbol{i}_{mdq}$ napon i struja mreže, ω_m kružna frekvencija mreže, L_f ukupni induktivitet LCL filtra. Primjenom inverzne Parkove transformacije na referentne vrijednosti napona $\boldsymbol{u}^*_{mdq}$ slijede referentne vrijednosti $\boldsymbol{u}^*_{m\alpha\beta}$ koje se prosljeđuju pulsno-širinskoj modulaciji. Regulatori struja podređene regulacijske petlje obično se podešavaju prema tehničkom optimumu, a regulatori nadređene regulacijske petlje prema simetričnom optimumu [16]. LCL filtar koji se smješta između mrežnog dijela pretvarača i električne mreže služi za uklanjanje harmonika uzrokovanih PWM-om te poboljšanja kvalitete električne energije da bi se ispunili zahtjevi koje propisuju mrežna pravila [20].

3. Laboratorijski postav

Na slici 3.1 prikazan je laboratorijski postav na kojem su eksperimentalno verificirani implementirani algoritmi upravljanja. Postav se sastoji od sinkronog generatora sa stalnim magnetima, AC-DC-AC pretvarača i asinkronog motora koji emulira rad vjetroturbine. Asinkroni motor je napajan iz industrijskog pretvarača napona i frekvencije ABB ACS800. Navedeni pretvarač na ulaznom dijelu ima diodni most te nema mogućnost vraćanja energije u mrežu. Sinkroni generator sa stalnim magnetima povezan je na elektroenergetski sustav putem AC-DC-AC pretvarača Končar KONvert W1500 prikazanog na slici 3.2 koji se sastoji od generatorskog i mrežnog pretvarača te istosmjernog međukruga koji ih povezuje. Spoj sinkronog generatora sa stalnim magnetima i asinkronog motora, uz mjerni član momenta na osovini, prikazan je na slici 3.3. Na temelju algoritma izravnog upravljanja momentom implementiranog u industrijskom pretvaraču se regulira brzina vrtnje asinkronog motora, dok se na temelju razvijenih algoritama implementiranih u digitalnom sustavu generatorskog dijela AC-DC-AC pretvarača upravlja elektromagnetskim momentom sinkronog generatora sa stalnim magnetima. U nastavku su dane nazivne vrijednosti navedenih strojeva i pretvarača napona i frekvencije:

PMG: Tema LPMR-450, $P_n = 375$ kW, $E_n = 400$ V, $I_n = 596$ A, $f_n = 75$ Hz, $n_n = 1500$ rpm.
AC-DC-AC pretvarač: Končar KONvert W $P_n = 520$ kW, $U_n = 400$ V, $I_n = 750$ V, $f_{sw} = 2$ kHz, $T_{dt} = 4\ \mu$s, $U_{dc} = 650$ V.
AM: Končar 8AZJ 405-04, $P_n = 560$ kW, $U_n = 400$ V, $I_n = 967$ A, $f_n = 50$ Hz, $n_n = 1490$ rpm, $\cos\varphi_n = 0.87$.
Industrijski pretvarač: ABB ACS800, $P_n = 1.25$ MW, $U_n = 500$ V, $I_n = 1596$ A, $U_{dc} = 560$ V.

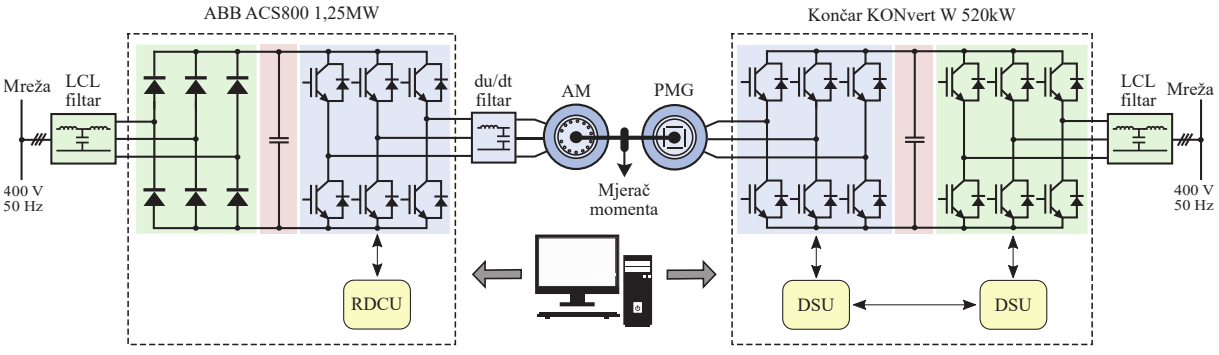

Slika 3.1: Shema laboratorijskog postava

Slika 3.2: AC-DC-AC pretvarač

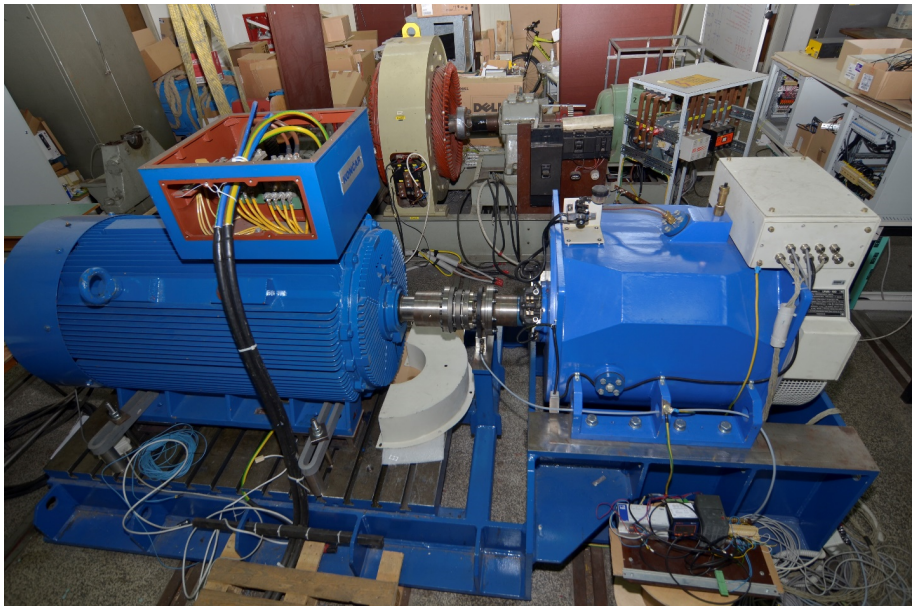

Slika 3.3: Sinkroni generator sa stalnim magnetima i asinkroni motor

Generatorski i mrežni dio AC-DC-AC pretvarača sadrže IGBT module sljedećih specifikacija:

IGBT modul: SEMIKUBE IGD-4-424-P1F7-BL-FA, $I^{max} = 750$ A, $U^{max} = 500$ V, $U_{dc}^{max} = 900$ V , $f^{max} = 500$ Hz, $f_{sw}^{max} = 20$ kHz.

Struja na izlazu generatorskog pretvarača, tj. struja koja prolazi statorskim namotom generatora, mjerena je korištenjem mjernih pretvornika integriranih u IGBT modulima (analogni izlazni signal ± 10 V, 6 mV/A) koji se temelje na Hallovom efektu u otvorenoj petlji. Napon istosmjernog međukruga mjeren je korištenjem mjernog člana DVL 1000. Podaci spojke i mjernog člana momenta na osovini dani su u nastavku:

Oprema za mjerenje momenta: spojka ROBA-DS 300/951.661, mjerni član HBM T40B, pretvornik signala HBM TIM40.

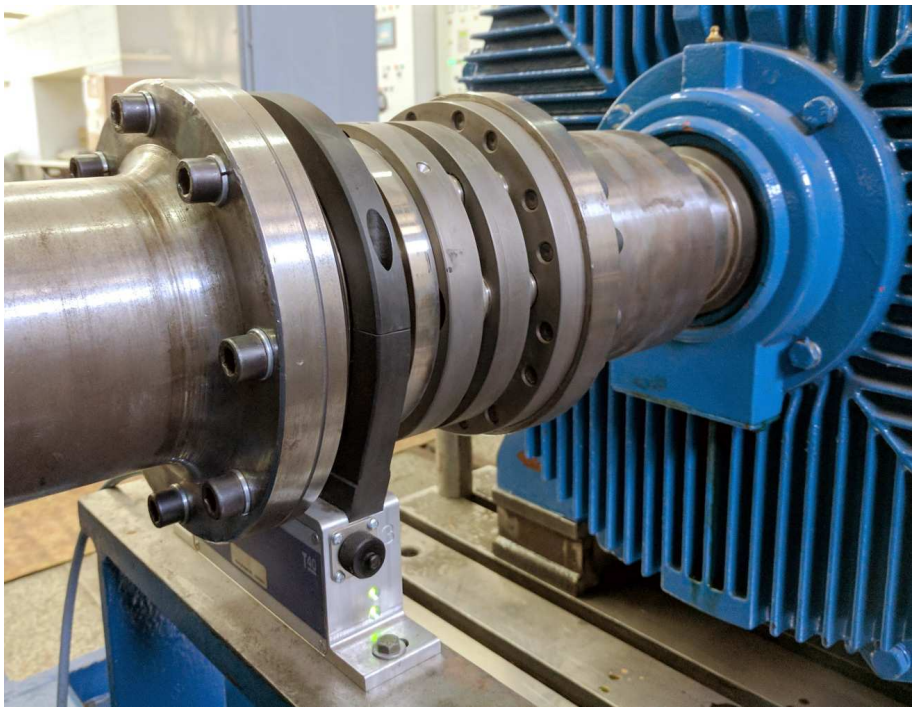

Slika 3.4: Spojka i mjerni član momenta HBM T40B

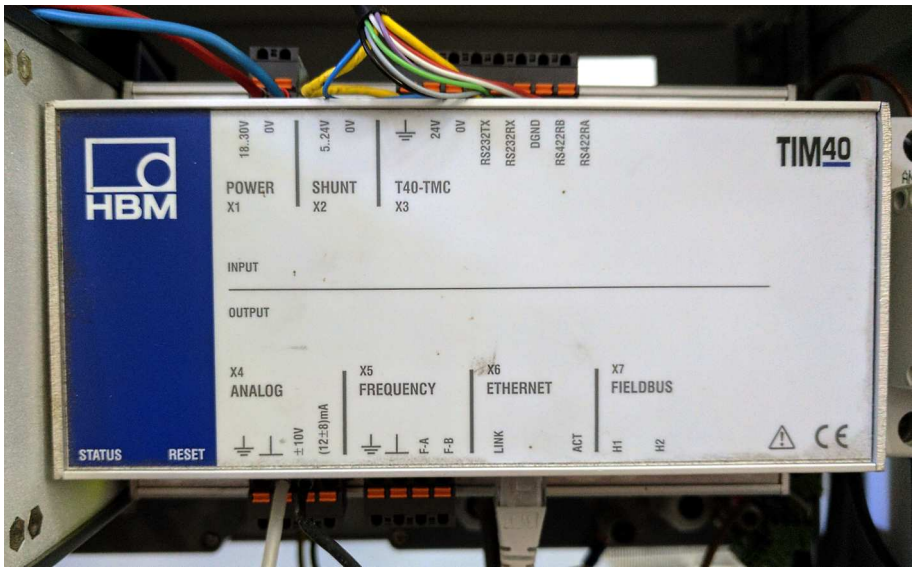

Slika 3.5: Pretvornik signala HBM TIM40

Budući da razvijeni algoritmi upravljanja, osobito algoritam modelskog prediktivnog upravljanja, zahtijevaju što točnije poznavanje parametara nadomjesne sheme sinkronog generatora sa stalnim magnetima, provedena je identifikacija navedenih parametara. Otpor statora R_s identificiran je napajanjem statorskog namota istosmjernim naponom u mirovanju, uz kompenzaciju mrtvog vremena pretvarača i pada napona na IGBT-ovima. Induktiviteti L_d i L_q identificirani su zadavanjem različitih referentnih vrijednosti struje u jednoj osi (prilikom identifikacije induktiviteta L_d zadaju se različite negativne referentne vrijednosti i_q^* dok se prilikom identifikacije induktiviteta L_q zadaju različite negativne referentne vrijednosti i_d^*) te korištenjem naponskih

jednadžbi sinkronog generatora sa stalnim magnetima u sinkronom dq koordinatnom sustavu. Budući da uslijed magnetskog zasićenja dolazi do promjena vrijednosti induktiviteta (osobito L_q) prilikom promjene opterećenja, snimljene su krivulje $L_d = f(i_d)$ i $L_q = f(i_q)$ te spremljene u pregledne (engl. *look-up*) tablice. Magnetski tok ψ_{md} stalnih magneta identificiran je u praznom hodu generatora pri različitim brzinama, na temelju mjerenog induciranog napona i mjerene brzine rotora. U nastavku su dane identificirane vrijednosti parametara nadomjesne sheme generatora (vrijednosti induktiviteta se odnose na nezasićene vrijednosti):

Parametri nadomjesne sheme: $R_s = 7$ mΩ, $L_d = 0.8$ mH, $L_q = 2.7$ mH, $\psi_{md} = 0.69$ Wb.

Implementacija algoritama upravljanja u digitalni sustav upravljanja izvedena je u jediničnom sustavu vrijednosti (engl. *per unit*). Bazne vrijednosti su definirane na temelju nazivnih vrijednosti generatora prema sljedećim iznosima:

Bazne vrijednosti: $U_b = 326$ V, $I_b = 843$ A, $f_b = 75$ Hz, $n_{rb} = 1500$ okr/min, $\omega_{rb} = 471$ rad/s, $M_b = 2389$ Nm, $Z_b = 0.39$ Ω, $L_b = 0.83$ mH, $\psi_b = 0.69$ Wb.

Na slici 3.6 je prikazan digitalni sustav upravljanja generatorskim i mrežnim dijelom AC-DC-AC pretvarača, dok su na slikama 3.7 i 3.8 prikazani osnovni prozori programskih alata *AlgoCAD* i *r_parnad*. Digitalni sustav upravljanja se temelji na ADSP-21992 16-bitnom mikroprocesoru s nepomičnom decimalnom točkom (engl. *fixed point*) (160 MHz). U digitalnom sustavu generatorskog pretvarača implementirane su zaštitne funkcije pretvarača i generatora (prekostrujna zaštita, prenaponska i podnaponska zaštita, termička zaštita i sl.) te obrada mjernih signala. Također su implementirani algoritam upravljanja momentom generatora temeljen

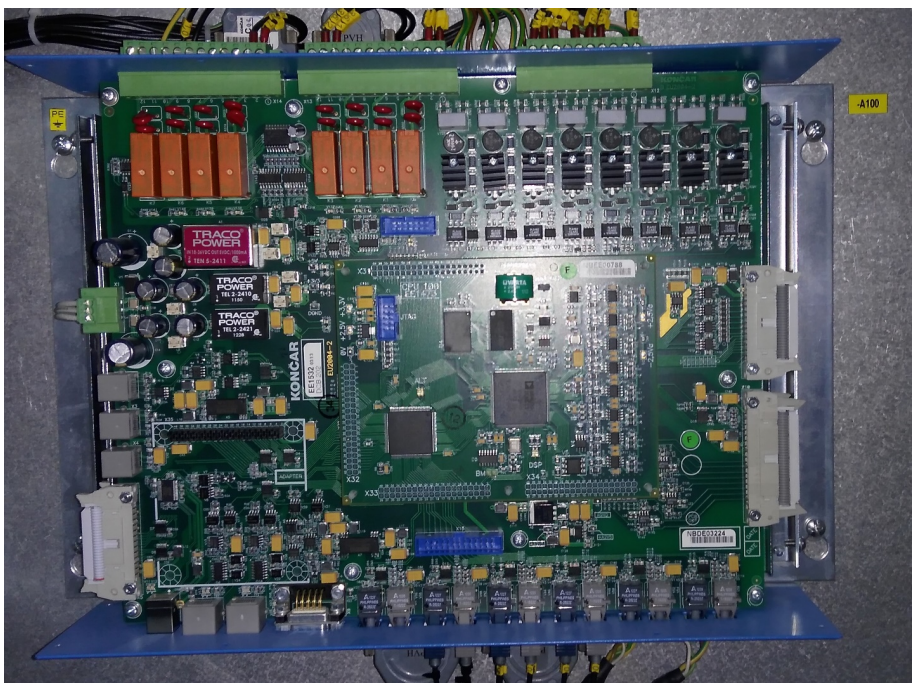

Slika 3.6: Digitalni sustav upravljanja

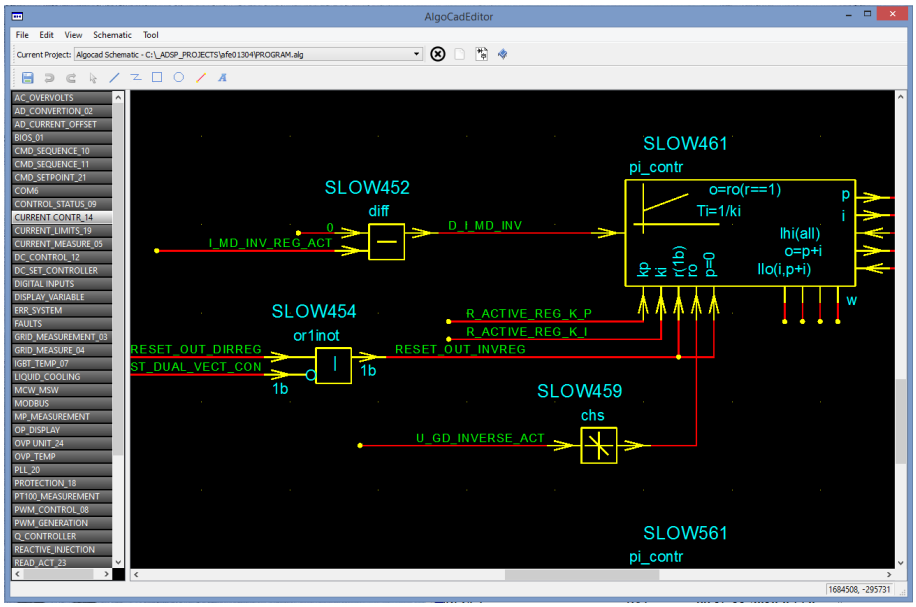

Slika 3.7: Programski alat *AlgoCad*

na MTPA algoritmu za proračun referentnih vrijednosti struje i standardnom algoritmu vektorskog upravljanja u koordinatnom sustavu magnetskog toka rotora uz vektorsku modulaciju širine impulsa kao i napredni algoritmi poput letećeg starta i upravljanja bez mjernog člana brzine rotora, modelskog prediktivnog upravljanja te rada na naponskom ograničenju tj. u području slabljenja magnetskog toka.

Opisani algoritmi implementirani su u programskom alatu *AlgoCAD*. Navedeni alat podržava grafičko programiranje putem gotovih blokova iz biblioteke. Svaki blok izvršava određenu

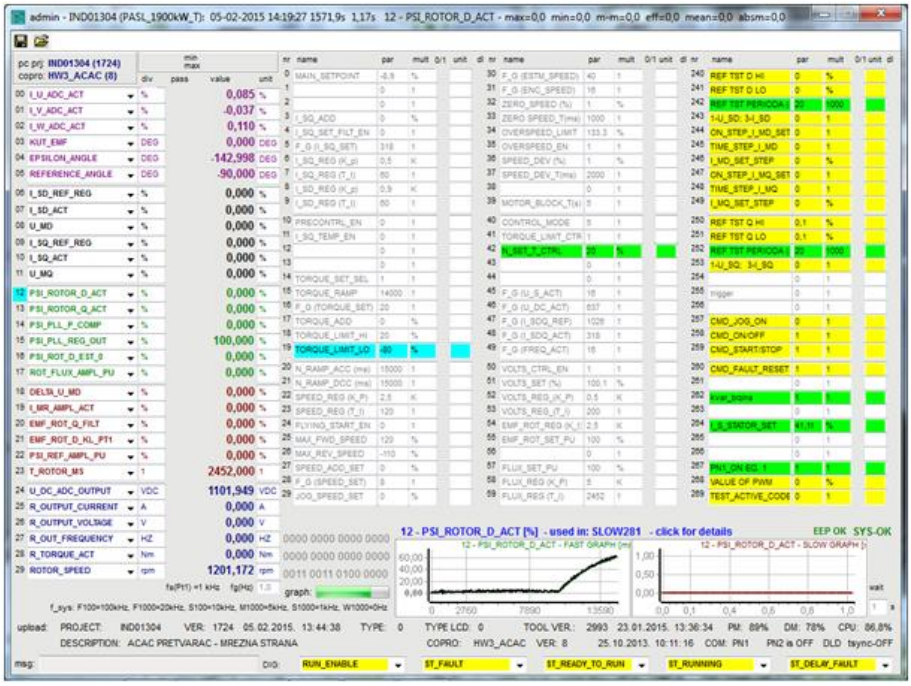

Slika 3.8: Programski alat *r_parnad*

funkciju, od računalno jednostavnijih (npr. zbrajanje - ADD, oduzimanje - DIFF, apolutna vrijednost - ABS) do računalno složenijih (npr. Parkova transformacija - PARK, PID regulator - PIDCONTR i sl.). Također, svaki od blokova se izvršava na određenoj prekidnoj rutini koja je definirana u njegovom imenu. U standardnim postavkama digitalnog sustava, prilagođenim strukturi vektorskog upravljanja uz PWM, definirane su sljedeće prekidne rutine (u zagradi su navedene frekvencije izvođenja): WAIT1000 (25 Hz), SLOW1000 (1 kHz), MID1000 (5 kHz), SLOW100 (10 kHz), FAST1000 (20 kHz) i FAST100 (100 kHz). Zaštitne funkcije su izvedene na najbržim prekidnim rutinama (FAST100 i FAST1000), najveći dio algoritama upravljanja na prekidnoj rutini SLOW100, uz dijelove s manjom dinamikom promjene na prekidnim rutinama MID1000 i SLOW1000, dok su parametri promjenjivih vrijednosti definirani na prekidnoj rutini WAIT1000.

Prilikom implementacije algoritma modelskog prediktivnog upravljanja korištene su alternativne postavke digitalnog sustava budući da je potrebna veća frekvencija izvođenja u usporedbi sa standardnim algoritmima što će biti detaljnije objašnjeno kasnije u tekstu. U navedenom slučaju definirane su sljedeće prekidne rutine: WAIT1000 (25 Hz), SLOW1000 (1 kHz), MID1000 (16 kHz) i FAST100 (32 kHz). U ovom slučaju zaštitne funkcije su izvedene na najbržoj prekidnoj rutini (FAST100), a algoritam upravljanja na prekidnoj rutini MID1000.

Programski alat *r_parnad* koristi se za upravljanje, nadzor i dijagnostiku AC-DC-AC pretvarača i generatora. Navedeni alat omogućava praćenje različitih varijabli digitalnog sustava upravljanja (prilikom grafičkog programiranja u programskom alatu *AlgoCAD* definiraju se relevantne varijable) u stvarnom vremenu (engl. *real time*). Također, moguće je zadavati željenu vrijednost različitih parametara sustava. Primjerice, iz programskog alata *r_parnad* daje se naredba za uključenje mrežnog, a potom i generatorskog pretvarača (postavljanje odgovarajućeg parametra u stanje logičke jedinice) te se također zadaje referentna vrijednost momenta generatora. Osim zadavanja vrijednosti parametara, unutar ovog programskog alata mogu se pratiti aktivni alarmi i greške, kao i snimati signali željenih veličina (npr. mjerena struja, estimirana brzina i kut rotora i sl.) unutar definiranog vremenskog intervala.

4. Upravljanje bez mjernog člana brzine rotora

4.1. Pregled literature

U usporedbi s upravljanjem sinkronim motorom sa stalnim magnetima, specifičnost upravljanja sinkronim generatorom sa stalnim magnetima je uključenje generatorskog pretvarača tijekom vrtnje generatora. Zbog djelovanja magnetskog toka stalnih magneta smještenih na rotoru, u vrtnji se inducira napon proporcionalan brzini rotora. Stoga je prije uključenja generatorskog pretvarača potrebno odrediti položaj uzdužne d osi sinkronog koordinatnog sustava, tj. kut rotora, brzinu rotora te iznos induciranog napona na stezaljkama generatora. Navedeni postupak naziva se sinkronizacija generatorskog pretvarača s generatorom. Slična problematika postoji i u elektromotornim pogonima sa sinkronim motorima sa stalnim magnetima kada je potrebno osigurati uključenje pretvarača u vrtnji motora, npr. nakon kratkotrajnog gubitka napajanja pretvarača. Navedena funkcija implementirana u komercijalnim pretvaračima napona i frekvencije naziva se leteći start (engl. *flying start*).

Ako neka od navedenih veličina (kut rotora, brzina rotora i inducirani napon) nije određena prije uključenja generatorskog pretvarača, dolazi do značajnog porasta struje prilikom uključenja, a time i do značajnog udarca momenta što može uzrokovati mehanički i električni kvar vjetroagregata. Porast struje tijekom uključenja generatorskog pretvarača određen je prvenstveno parametrima nadomjesne sheme generatora, točnije otporom statora te induktivitetom. U slučaju generatora malih snaga (nekoliko kW) s velikim otporom statora porast struje te udarac momenta prilikom uključenja generatorskog pretvarača su prihvatljivi. No, generatore velikih snaga karakterizira mali otpor statora što rezultira značajnim porastom struje, a time i udarcem momenta prilikom uključenja generatorskog pretvarača. Bez implementiranog algoritma koji određuje kut i brzinu rotora te inducirani napon prije uključenja generatorskog pretvarača može doći do oštećenja generatora ili prorade prekostrujne zaštite generatorskog pretvarača. Stoga je za generatore velikih snaga koji se uobičajeno koriste u vjetroelektranama potrebno implementirati algoritme koji osiguravaju sinkronizaciju generatorskog pretvarača i generatora.

U slučaju da se koristi mjerni član brzine rotora (npr. enkoder ili rezolver), moguće je prije

uključenja generatorskog pretvarača odrediti položaj *d* osi sinkronog koordinatnog sustava odnosno upotrebom mjerenja odrediti kut i brzinu rotora te na temelju mjerene brzine rotora i magnetskog toka stalnih magneta proračunati iznos induciranog napona. No, bez korištenja mjernog člana brzine rotora, navedene veličine potrebno je estimirati prije uključenja generatorskog pretvarača što predstavlja istraživački izazov. Također, s ciljem povećanja pouzdanosti i robusnosti sustava upravljanja, poželjno je ostvariti upravljanje sinkronim generatorom sa stalnim magnetima bez mjernog člana brzine rotora (engl. *sensorless control*) nakon uključenja generatorskog pretvarača u normalnom režimu rada te čitavom radnom području generatora.

Većina znanstvenih radova koja se bavi tematikom upravljanja bez mjernog člana brzine rotora usmjerena je na razvoj struktura estimacije kuta ili brzine rotora za sinkrone motore sa stalnim magnetima, uz pretpostavku da se motor pokreće iz mirovanja, uz zanemarenje slučaja letećeg starta, tj. uključenja pretvarača u vrtnji motora. Detaljan pregled različitih struktura estimacije kuta i brzine rotora sinkronih strojeva sa stalnim magnetima dan je u [21, 22]. Strukture estimacije kuta rotora mogu biti temeljene na:

a) matematičkom modelu sinkronog stroja sa stalnim magnetima (adaptivne i neadaptivne),
b) anizotropiji stroja (injektiranje signala visoke frekvencije),
c) algoritmima umjetne inteligencije (neuronske mreže, neizrazita logika i sl.).

Strukture estimacije temeljene na modelu stroja mogu se dodatno podijeliti na adaptivne (s povratnom vezom) i neadaptivne (bez povratne veze) strukture. Neadaptivne strukture estimiraju kut rotora na temelju estimiranog magnetskog toka ili induciranog napona koji slijedi iz samog modela stroja [23–25] bez korištenja povratne veze. S druge strane, adaptivne strukture temelje se na otklanjanju odstupanja mjerene i estimirane veličine stroja (u većini adaptivnih struktura estimacije navedena veličina je struja) čime se adaptiraju parametri modela stroja korištenog u strukturi estimacije. Ovaj tip strukture estimacije uključuje sljedeće estimatore: modelski referentni adaptivni sustav (engl. *model reference adaptive system*, MRAS) [26, 27], *observer* temeljen na kliznom režimu (engl. *sliding mode observer*, SMO) [28–30], Luenbergerov *observer* [31, 32], prošireni Kalmanov filtar (engl. *extended Kalman filter*, EKF) [33–35]. Nakon primjene ranije navedenih estimatora magnetskog toka ili induciranog napona, kut te brzina rotora se u većem broju znanstvenih radova estimiraju primjenom fazno zatvorene petlje (engl. *phase locked loop*, PLL). Neke od primjena fazno zatvorene petlje u sustavima upravljanja su magnetiziranje kaveznog asinkronog vjetrogeneratora u vrtnji bez mjernog člana brzine rotora [36], estimacija frekvencije statora asinkronog stroja [37], estimacija brzine rotora dvostruko napajanog asinkronog generatora [38], upravljanje mrežnim pretvaračem [39–41], *observer* magnetskog toka sinkronog motora sa stalnim magnetima na površini rotora [42], itd. Velik broj estimatora magnetskog toka temelji se na principu tzv. aktivnog magnetskog toka (engl. *active flux*) [43] kojim se strojevi s magnetskom nesimetrijom matematičkim transformacijama prikazuju u sličnom obliku kao strojevi s magnetskom simetrijom što smanjuje kompleksnost

algoritama estimacije i upravljanja. Sličan princip vrijedi i za inducirani napon, tj. uvodi se pojam proširenog induciranog napona (engl. *extended electromotive force*, EEF) [44]. Analiza osjetljivosti struktura estimacije temeljenih na matematičkom modelu stroja na promjene parametara stroja i greške mjerenja provedena je u [45].

Strukture estimacije temeljene na anizotropiji zasnivaju se na magnetskoj nesimetriji stroja. Kod sinkronih strojeva sa stalnim magnetima na površini dolazi do anizotropije uslijed zasićenja magnetskih puteva u dijelovima jezgre stroja, dok je anizotropija posebice izražena u slučaju sinkronih strojeva sa stalnim magnetima u unutrašnjosti rotora uslijed magnetske nesimetrije u uzdužnoj (d) i poprečnoj (q) osi. Anizotropija stroja se može iskoristiti za dobivanje informacije o kutu rotora injektiranjem signala visoke frekvencije (engl. *high frequency*, HF) u signal napona ili struje statora. Demodulacijom signala te analizom visokofrekvencijskih komponenata napona ili struje može se estimirati kut rotora, čak i pri malim brzinama rotora te u mirovanju. Ispitni signal može biti dodan u modulirani napon ili se signal visoke frekvencije injektira u signal referentne vrijednosti napona ili struje. Dodavanje ispitnog signala u modulirani napon primjenjuje se u INFORM (engl. *indirect flux detection by on-line reactance measurement*) metodi [46]. Prednosti navedene metode su estimacija kuta rotora unutar nekoliko ciklusa PWM-a, a injektirani signal nema utjecaj na upravljačku strukturu budući da je frekvencija ispitnih signala jednaka ili veća frekvenciji PWM-a. S druge strane, nedostaci su buka i vibracije koji nastaju kao posljedica ispitnih signala, potreba za korištenjem brzih i preciznih di/dt mjerača te modifikacija standardnog PWM-a. Ispitni sinusni signali visoke frekvencije mogu se dodati i na referentnu vrijednost napona u mirujućem $\alpha\beta$ [47] ili sinkronom dq [48] koordinatnom sustavu. Ako se signal dodaje u obje osi, tada se radi o injektiranju rotirajućeg vektora. U suprotnom, ako se ispitni signal injektira samo u jednu os, tada se radi o injektiranju pulsirajućeg vektora [49]. Kod navedenih metoda nema potrebe za modifikacijom PWM-a, no frekvencija injektiranog signala treba biti oko deset puta manja od frekvencije PWM-a čime injektirani signali utječu na regulacijsku strukturu struje pa ih je potrebno filtrirati što uzrokuje smanjenje dinamike regulacijske petlje struje. Također jedan od nedostataka opisanih metoda temeljenih na injektiranju visokofrekvencijskih signala je modeliranje primarne anizotropije stroja, dok je sekundarna anizotropija zanemarena što u konačnici dovodi do trajnog odstupanja estimirane i stvarne vrijednosti kuta rotora.

Strukture estimacije temeljene na metodama umjetne inteligencije (engl. *artificial intelligence*, AI) poput neuronskih mreža (engl. *neural network*, NN) [50–52] i neizrazite logike (engl. *fuzzy logic*) [53] odlikuje robusnost na promjenu parametara stroja. No, glavni nedostatak navedenih struktura je velika računalna složenost što ih čini nepovoljnima s aspekta implementacije u digitalni sustav.

Mali broj znanstvenih radova razmatra problem uključenja pretvarača u vrtnji sinkronog stroja sa stalnim magnetima (leteći start). Razvijeni algoritmi kojima se rješava navedena pro-

blematika mogu biti temeljeni na:

a) nul-impulsima napona pretvarača (engl. *zero-voltage pulse*),

b) mjerenju induciranog napona generatora.

Navedena je problematika najčešće opisana u prijavljenim patentima, a rješenja predstavljaju industrijsko vlasništvo. U [54] prikazano je određivanje kuta rotora reguliranjem iznosa ukupne struje na iznos nula. Pretpostavka je da će prilikom uključenja pretvarača izlazni napon vrlo brzo porasti ako je struja regulirana na iznos nula. Premda je navedeno rješenje primjenjivo na strojeve male snage (u radu je razmatran stroj snage 100 W), u slučaju stroja velike snage s malim otporom statora dolazi do značajnog udarca struje što je neprihvatljivo.

Algoritmi temeljeni na nul-impulsima napona pretvarača uobičajeno određuju kut rotora na temelju jednog, dva ili tri nul-impulsa. Nul-impuls napona pretvarača ostvaren je kratkotrajnim vođenjem sva tri IGBT-a u donjoj grani pretvarača čime je napon sa strane pretvarača jednak nuli odnosno dolazi do kratkog spoja generatora. U [55] predloženo je uključenje jednog od IGBT-ova u nekoj od donjih grana pretvarača u trajanju od 200 μs. Navedenim trajanjem osigurava se da struja ne prijeđe maksimalni dozvoljeni iznos. Navedeno rješenje uključuje i mjerenje struje u istosmjernom međukrugu. Na temelju kratkotrajnog uključenja jednog IGBT-a te mjerene struje u istosmjernom međukrugu može se odrediti struja jedne faze te odrediti brzina rotora odnosno frekvencija stroja. No, preostaje problem određivanja početnog kuta rotora koji se može odrediti iz trenutka kada je inducirani napon jednak nuli. Budući da je jedina mjerena veličina struja koja zbog induktivnog svojstva samog stroja nije jednaka nuli kada je inducirani napon jednak nuli, može doći do pogreške određivanja kuta rotora. U [56] predloženo je sklapanje sva tri IGBT-a u donjim granama pretvarača što uzrokuje impulse struje. U svakoj fazi pretvarača, kada vodi IGBT u donjoj grani, dolazi do porasta struje uslijed induciranog napona. Kada IGBT-ovi prestanu voditi struja pada na nulu kroz odgovarajuće diode. Navedeni postupak uključivanja/isključivanja IGBT-ova u donjim granama pretvarača se ponavlja. Na temelju procijenjene vrijednosti kuta rotora te vremenskih trenutaka maksimalne vrijednosti struje u periodu kada vode IGBT-ovi može se odrediti brzina rotora. No, navedena metoda zahtijeva visoku preciznost mjerenja struje, a i dijeljenje s malim vremenskim intervalom između dva impulsa struje što može uzrokovati značajnu grešku u određivanju brzine rotora. U [57] razvijena je metoda za leteći start skalarno upravljanog sinkronog motora sa stalnim magnetima velikog momenta inercije. Razvijena metoda temelji se na tri nul-impulsa napona kojima se određuje brzina rotora te smjer vrtnje. No, nul-impuls napona može uzrokovati čak nazivnu struju stroja što može dovesti do neželjenih vibracija. Poboljšanje algoritama koji se temelje na jednom, dva ili tri nul-impulsa napona ostvareno je algoritmom u [58]. Razvijeni algoritam temelji se na nizu nul-impulsa napona uz regulirani faktor vođenja donjeg IGBT-a u svakoj grani čime se osigurava da struja ne prelazi neželjeni iznos tijekom letećeg starta. Uzorkovanjem struje u sredini ciklusa pulsno-širinske modulacije osigurava se da je struja u digitalnom sustavu upravljanja

sinusnog oblika. Koristeći činjenicu da je vektor struje tijekom nul-impulsa napona približno u poprečnoj q osi sinkronog koordinatnog sustava, primjenom fazno zatvorene petlje ostvarena je estimacija brzine i kuta rotora. Prednost navedene metode pred ranije opisanim je ostvarenje letećeg starta s relativno malim iznosom struje (tipično 1% nazivne vrijednosti) te robusnost na pogrešne vrijednosti parametara generatora.

Neki industrijski pretvarači imaju mogućnost uključenja pretvarača u vrtnji (leteći start) sinkronog stroja sa stalnim magnetima samo uz korištenje mjernog člana napona (npr. Siemens Sinamics). U navedenom slučaju algoritam kojim se ostvaruje leteći start je implementiran u pretvaraču te predstavlja industrijsko vlasništvo. U pravilu, algoritmi temeljeni na mjerenju induciranog napona koriste mjerni član napona na stezaljkama generatora prije uključenja pretvarača. U [59] se na temelju mjerenog induciranog napona određuje frekvencija i brzina rotora kao i smjer brzine vrtnje. U [60] razvijen je algoritam pokretanja sinkronog motora sa stalnim magnetima koji koristi mjereni inducirani napon kao jedan od ulaza u nelinearni *observer* za estimaciju kuta rotora. Različita problematika (upravljanje momentom generatora, estimacija brzine i kuta rotora, upravljanje mrežnim pretvaračem i sl.) vezana uz algoritme upravljanja vjetroelektranama malih snaga sa sinkronim generatorima sa stalnim magnetima opisana je u [61]. Kao rješenje sinkronizacije generatorskog pretvarača i generatora predložena je struktura fazno zatvorene petlje uz korištenje mjerene vrijednosti induciranog napona. Budući da je inducirani napon generatora u poprečnoj q osi sinkronog koordinatnog sustava, signal u uzdužnoj d osi predstavlja grešku estimiranog kuta (razlika između mjerenog i estimiranog kuta) koja se dovodi na ulaz PLL strukture. No, predloženi algoritam ne rješava problem trajnog rada bez mjernog člana brzine vrtnje budući da dolazi do promjene amplitude i kuta mjerenog napona generatora pod opterećenjem. Također, signal s mjernog člana napona nije iskoristiv nakon uključenja generatorskog pretvarača uslijed deformacije uzrokovane PWM-om.

4.1.1. Prvi znanstveni doprinos

U doktorskoj disertaciji je razvijena metoda uključenja generatorskog pretvarača tijekom vrtnje sinkronog generatora sa stalnim magnetima (leteći start) te upravljanja bez mjernog člana brzine vrtnje temeljena na fazno zatvorenoj petlji i mjerenju induciranog napona generatora [62]. Razvijeni algoritam se temelji na sličnim pretpostavkama (mjerenje induciranog napona generatora i korištenje strukture fazno zatvorene petlje) kao i algoritam razvijen u [61]. No, za razliku od algoritma iz [61], razvijeni algoritam uključuje i estimaciju magnetskog toka prije (korištenjem mjerenog napona generatora) i nakon (korištenjem rekonstruiranog napona na izlazu pretvarača) uključenja generatorskog pretvarača. Time se osigurava uključenje generatorskog pretvarača s neznatnim porastom struje i zanemarivim udarcem momenta kao i rad bez mjernog člana brzine vrtnje u čitavom radnom području generatora što ga čini pogodnim za upravljanje vjetrogeneratorima velikih snaga.

4.2. Upravljanje bez mjernog člana brzine rotora temeljeno na mjerenju induciranog napona generatora i fazno zatvorenoj petlji

4.2.1. Struktura upravljanja bez mjernog člana brzine rotora

Načelna shema upravljanja bez mjernog člana brzine rotora uz mjerenje induciranog napona generatora je prikazana na slici 4.1. Umjesto mehaničke brzine rotora ω_r koja se mjeri putem enkodera te potom preračunava u električnu brzinu rotora ω_{re} množenjem s brojem pari polova p ($\omega_{re} = p\omega_r$), koristi se estimirana mehanička brzina rotora $\hat{\omega}_r$ odnosno estimirana električna brzina rotora $\hat{\omega}_{re}$. Važno je napomenuti da su u sustavu jediničnih vrijednosti koji se koristi prilikom sinteze sustava upravljanja mehanička i električna brzina rotora jednakog iznosa. U nastavku teksta se izrazi estimirana brzina i estimirani kut rotora odnose na električne veličine. Brzina $\hat{\omega}_{re}$ i kut $\hat{\theta}_{re}$ rotora estimiraju se na temelju mjerenog napona generatora $\boldsymbol{u}_{\alpha\beta}$, rekonstruiranog napona na izlazu generatorskog pretvarača $\hat{\boldsymbol{u}}_{\alpha\beta}$ i mjerene struje $\boldsymbol{i}_{\alpha\beta}$. Estimirana brzina rotora koristi se za signale rasprezanja u strukturi vektorskog upravljanja, dok se estimirani kut rotora koristi za Parkovu transformaciju mjerenih struja te inverznu Parkovu transformaciju referentnih vrijednosti napona na izlazu PI regulatora struja. U daljnjem tekstu oznaka $\hat{}$ upućuje da se radi o estimiranoj veličini, dok oznaka $\hat{dq}$ (uobičajeno u indeksu promatrane veličine) upućuje da se radi o veličini u estimiranom sinkronom dq koordinatnom sustavu.

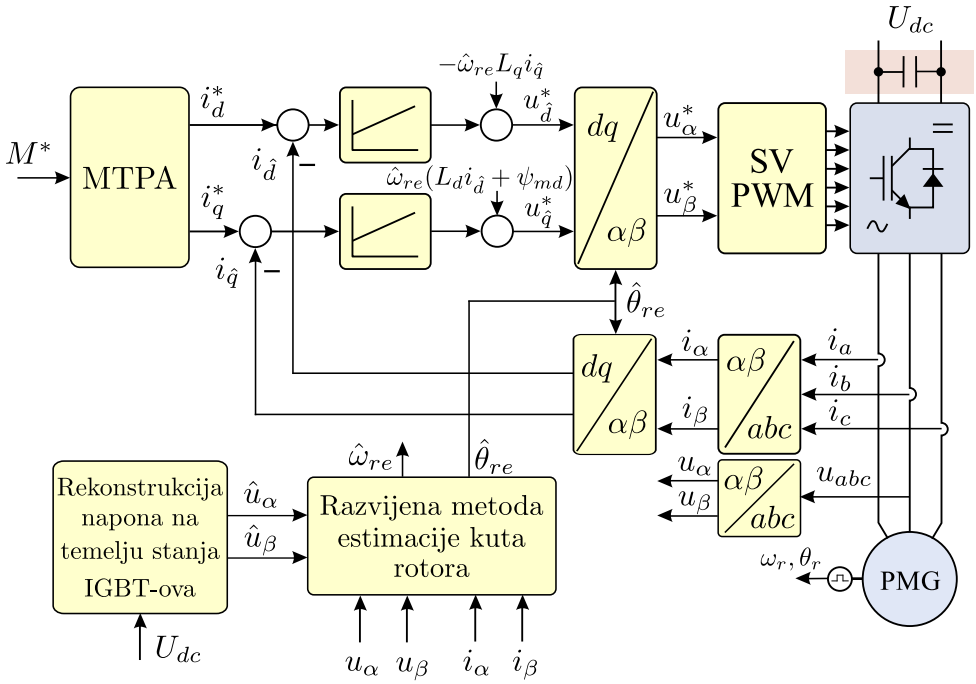

Slika 4.1: Struktura upravljanja bez mjernog člana brzine rotora

Mjerenje izlaznog napona generatorskog pretvarača, tj. napona na stezaljkama generatora najčešće nije izvedeno kod standardnih pretvarača napona i frekvencije. Napon na izlazu generatorskog pretvarača uobičajeno se rekonstruira na temelju mjerenog napona istosmjernog međukruga i sklopnih stanja IGBT-ova. Razvijena metoda uključenja generatorskog pretvarača u vrtnji sinkronog generatora sa stalnim magnetima te upravljanja bez mjernog člana brzine vrtnje zahtijeva mjerenje induciranog napona generatora prije uključenja generatorskog pretvarača. Metoda se može podijeliti na fazu predsinkronizacije i fazu sinkronizacije. Prije uključenja generatorskog pretvarača, tj. u fazi predsinkronizacije, razvijena metoda estimira brzinu i kut rotora na temelju mjerenog induciranog napona generatora i fazno zatvorene petlje. Nakon uspješne estimacije brzine i kuta rotora prelazi se u fazu sinkronizacije čime je omogućeno uključenje pulsno-širinske modulacije te potom trajni rad s estimiranim vrijednostima brzine i kuta rotora.

4.2.2. Faza predsinkronizacije

Struktura za određivanje kuta rotora u fazi predsinkronizacije prikazana je na slici 4.2. Koristeći Clarkinu transformaciju mjereni napon generatora može se transformirati u mirujući $\alpha\beta$ koordinatni sustav. Primjenom arkus tangens (*arctan*) funkcije na kvocijent komponenata mjerenog napona $\boldsymbol{u}_{\alpha\beta}$ slijedi kut induciranog napona θ_u odnosno kut poprečne q osi sinkronog dq koordinatnog sustava:

$$\theta_u = \arctan\frac{u_\beta}{u_\alpha}. \tag{4.1}$$

Budući da je inducirani napon posljedica magnetskog toka stalnih magneta na rotoru, kut vektora induciranog napona θ_u prethodi kutu stalnih magneta odnosno kutu rotora θ_{rph} za 90°. Oduzimanjem 90° od kuta induciranog napona θ_u slijedi kut rotora θ_{rph} u fazi predsinkronizacije:

$$\theta_{rph} = \theta_u - 90^\circ. \tag{4.2}$$

Tako dobiveni kut rotora θ_{rph} može se koristiti u algoritmu upravljanja te estimacije kuta i brzine rotora prije uključenja PWM-a. Međutim, nakon uključenja PWM-a, kada započne sklapanje IGBT-ova, napon na stezaljkama generatora nije sinusnog valnog oblika te je kut rotora θ_{rph} dobiven na temelju mjerenja napona izobličen što ga čini neiskoristivim za estimaciju brzine i

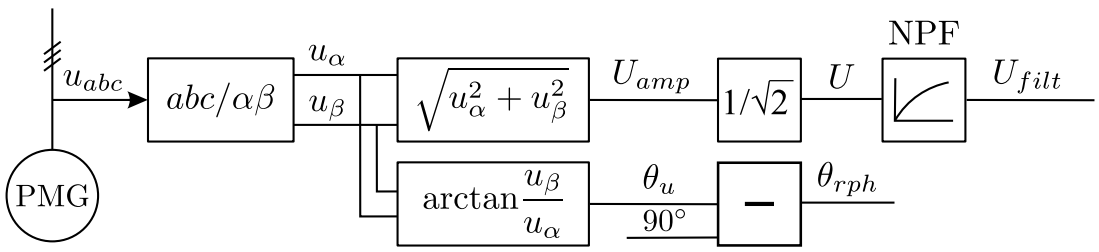

Slika 4.2: Struktura određivanja kuta rotora u fazi predsinkronizacije

kuta rotora. Iz vrijednosti komponenata mjerenog napona $u_{\alpha\beta}$ može se odrediti vrijednost amplitude napona U_{amp} koju je potrebno, prije uključenja generatorskog pretvarača, postaviti kao početni uvjet izlaza PI regulatora struje u q osi u_q^*. Time se sa strane generatorskog pretvarača stvara ravnoteža induciranom naponu generatora u q osi e_q te se izbjegava porast struje prilikom uključenja generatorskog pretvarača.

4.2.3. Struktura estimacije brzine i kuta rotora

Estimacija kuta rotora uz mjereni kut rotora u praznom hodu θ_{rph} treba biti implementirana tako da istovremeno osigurava uključenje generatorskog pretvarača, ali i trajni rad bez mjernog člana brzine rotora nakon uključenja. Kao što je navedeno ranije u tekstu, kut rotora θ_{rph} nije primjenjiv nakon uključenja PWM-a. Stoga je potrebno osigurati alternativnu strukturu estimacije koja osigurava trajni rad bez mjernog člana brzine rotora. Uključenje generatorskog pretvarača potrebno je ostvariti bez naglog prijelaza u estimiranom kutu i brzini rotora, jer u protivnom dolazi do značajnog porasta struje te prorade prekostrujne zaštite generatorskog pretvarača. Struktura estimacije brzine i kuta rotora, koja koristi kut rotora θ_{rph} određen pomoću mjerenja induciranog napona generatora u fazi predsinkronizacije te omogućava uključenje generatorskog pretvarača uz minimalni porast struje i trajni rad bez mjernog člana brzine vrtnje, prikazana je na slici 4.3.

Navedena struktura estimacije temelji se na fazno zatvorenoj petlji (PI regulator) i estimiranom magnetskom toku. Primjenom Parkove transformacije na magnetski tok u mirujućem $\alpha\beta$ koordinatnom sustavu slijedi magnetski tok u sinkronom dq koordinatnom sustavu. Navedena Parkova transformacija provodi se koristeći estimirani kut rotora $\hat{\theta}_{re}$ koji slijedi integracijom estimirane brzine rotora $\hat{\omega}_{re}$ koja je izlaz PI regulatora fazno zatvorene petlje. Na kraju faze predsinkronizacije, tj. neposredno prije uključenja generatorskog pretvarača, estimirani kut rotora $\hat{\theta}_{re}$ i kut rotora θ_{rph} dobiven na temelju mjerenja induciranog napona u praznom hodu moraju biti jednaki, odnosno treba vrijediti $\hat{\theta}_{re} = \theta_{rph}$.

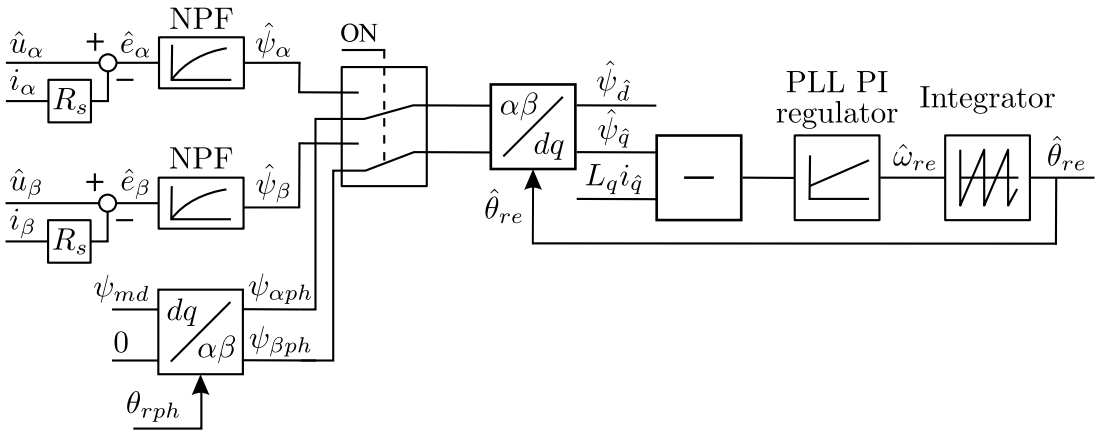

Slika 4.3: Struktura estimacije brzine i kuta rotora

Magnetski tok u q osi u sinkronom dq koordinatnom sustavu je jednak:

$$\psi_q = L_q i_q. \tag{4.3}$$

PI regulator fazno zatvorene petlje nastoji ukloniti grešku estimiranog magnetskog toka u poprečnoj q osi te time estimirati kut rotora odnosno položaj uzdužne d osi sinkronog dq koordinatnog sustava. Ulaz PI regulatora definiran je sljedećim izrazom:

$$\hat{\psi}_{\hat{q}} - L_q i_{\hat{q}} = 0. \tag{4.4}$$

PI regulator nastoji svesti ulaz definiran izrazom (4.4) na iznos nula čime estimira brzinu rotora na svom izlazu odnosno kut rotora dodatnom integracijom estimirane brzine.

Prije uključenja generatorskog pretvarača, tj. u fazi predsinkronizacije signal ON prikazan na slici 4.3 jednak je logičkoj nuli. Komponente magnetskog toka u mirujućem $\alpha\beta$ koordinatnom sustavu $\psi_{\alpha\beta ph}$ u fazi predsinkronizacije dobivaju se putem inverzne Parkove transformacije uz primjenu kuta rotora θ_{rph}:

$$\begin{bmatrix} \psi_{\alpha ph} \\ \psi_{\beta ph} \end{bmatrix} = \begin{bmatrix} \cos(\theta_{rph}) & -\sin(\theta_{rph}) \\ \sin(\theta_{rph}) & \cos(\theta_{rph}) \end{bmatrix} \begin{bmatrix} \psi_{md} \\ 0 \end{bmatrix}. \tag{4.5}$$

Pritom je magnetski tok stalnih magneta ψ_{md} postavljen kao d komponenta magnetskog toka u sinkronom dq koordinatnom sustavu dok je q komponenta magnetskog toka postavljena na iznos nula što odgovara praznom hodu generatora. Nadalje, na dobivene komponente magnetskog toka $\psi_{\alpha\beta ph}$ primijenjena je Parkova transformacija s estimiranim kutem rotora $\hat{\theta}_{re}$ koji slijedi na izlazu PLL strukture:

$$\begin{bmatrix} \hat{\psi}_{\hat{d}} \\ \hat{\psi}_{\hat{q}} \end{bmatrix} = \begin{bmatrix} \cos(\hat{\theta}_{re}) & \sin(\hat{\theta}_{re}) \\ -\sin(\hat{\theta}_{re}) & \cos(\hat{\theta}_{re}) \end{bmatrix} \begin{bmatrix} \psi_{\alpha ph} \\ \psi_{\beta ph} \end{bmatrix}. \tag{4.6}$$

U fazi predsinkronizacije PI regulator fazno zatvorene petlje promjenom izlazne veličine, tj. estimirane brzine rotora $\hat{\omega}_{re}$, osigurava da je estimirani kut rotora $\hat{\theta}_{re}$ jednak kutu rotora θ_{rph} koji je određen putem mjerenog induciranog napona generatora. Budući da je prije uključenja struja $i_{\hat{q}}$ jednaka nuli, ulaz u PI regulator je jednak $\hat{\psi}_{\hat{q}}$ što predstavlja signal greške budući da je magnetski tok u praznom hodu u d osi, tj. nakon uspješne estimacije brzine $\hat{\omega}_{re}$ i kuta $\hat{\theta}_{re}$ rotora u stacionarnom stanju vrijedi $\hat{\psi}_{\hat{d}} = \psi_{md}$. Alternativno korištenju mjerene amplitude napona U_{amp}, početni uvjet PI regulatora struje u q osi može se postaviti i na temelju estimirane brzine i magnetskog toka stalnih magneta: $u^*_{\hat{q}} = \psi_{md}\hat{\omega}_{re}$, no u tom slučaju potrebno je točno poznavanje vrijednosti magnetskog toka stalnih magneta ψ_{md}. Nakon što su ispunjeni navedeni preduvjeti počinje faza sinkronizacije generatorskog pretvarača i generatora.

4.2.4. Faza sinkronizacije

Nakon što su određeni brzina i kut rotora te početni uvjet PI regulatora struje u q osi, ispunjeni su uvjeti za fazu sinkronizacije, tj. uključenje generatorskog pretvarača. Kada dolazi do uključenja PWM-a, signal ON postaje jednak logičkoj jedinici te ulaz u PLL strukturu postaje jednak komponentama estimiranog magnetskog toka $\hat{\psi}_{\alpha\beta}$ umjesto komponentama u praznom hodu $\psi_{\alpha\beta ph}$. Estimirani magnetski tok $\hat{\psi}_{\alpha\beta}$ izračunava se u mirujućem $\alpha\beta$ koordinatnom sustavu integracijom estimiranog induciranog napona $\hat{e}_{\alpha\beta}$:

$$\hat{\psi}_{\alpha\beta} = \int \hat{e}_{\alpha\beta}\ \mathrm{d}t = \int \left(\hat{u}_{\alpha\beta} - i_{\alpha\beta} \cdot R_s\right)\ \mathrm{d}t. \tag{4.7}$$

Napon statora $\hat{u}_{\alpha\beta}$ rekonstruiran je na temelju napona istosmjernog međukruga U_{dc} i sklopnih stanja IGBT-ova generatorskog pretvarača. Alternativno, umjesto rekonstruiranog napona može se koristiti i referentna vrijednost napona na izlazu PI regulatora struje u strukturi vektorskog upravljanja $u^*_{\alpha\beta}$, no u tom slučaju potrebno je uzeti u obzir i kašnjenje koje unosi modulacija. Rekostrukcija napona s obzirom na masu istosmjernog međukruga može se prikazati sljedećim izrazom [63]:

$$\hat{u}_{xN} = \frac{t^x_{ON}}{T_{PWM}} U_{dc}, \tag{4.8}$$

gdje je $\hat{u}_{xN}$ razlika potencijala pojedine faze s obzirom na masu istosmjernog međukruga, t^x_{ON} je vrijeme vođenja gornje sklopke u pojedinoj grani, T_{PWM} je vremenski period pulsno-širinske modulacije, a oznaka faze je $x = a,b,c$. Rekonstrukcija faznih vrijednosti napona generatora $\hat{u}_{abc}$ slijedi iz faznih vrijednosti napona pretvarača $\hat{u}_{abcN}$:

$$\begin{aligned}
\hat{u}_a &= \frac{2}{3}\hat{u}_{aN} - \frac{1}{3}(\hat{u}_{bN} + \hat{u}_{cN}),\\
\hat{u}_b &= \frac{2}{3}\hat{u}_{bN} - \frac{1}{3}(\hat{u}_{aN} + \hat{u}_{cN}),\\
\hat{u}_c &= \frac{2}{3}\hat{u}_{cN} - \frac{1}{3}(\hat{u}_{aN} + \hat{u}_{bN}).
\end{aligned} \tag{4.9}$$

Standardna integracija sinusnog signala u digitalnom sustavu može dovesti do pomaka (*drifta*) signala na izlazu integratora, čak i u slučaju malog iznosa istosmjerne komponente sinusnog signala [64, 65]. Da bi se izbjegao navedeni problem, umjesto standardnog integratora korišten je niskopropusni filtar prvog reda (engl. *low-pass filter*, LPF). Estimirani magnetski tok $\hat{\psi}_{\alpha\beta}$ transformira se iz mirujućeg $\alpha\beta$ koordinatnog sustava u sinkroni dq koordinatni sustav putem Parkove transformacije s estimiranim kutem rotora $\hat{\theta}_{re}$:

$$\begin{bmatrix} \hat{\psi}_{\hat{d}} \\ \hat{\psi}_{\hat{q}} \end{bmatrix} = \begin{bmatrix} \cos(\hat{\theta}_{re}) & \sin(\hat{\theta}_{re}) \\ -\sin(\hat{\theta}_{re}) & \cos(\hat{\theta}_{re}) \end{bmatrix} \begin{bmatrix} \hat{\psi}_{\alpha} \\ \hat{\psi}_{\beta} \end{bmatrix}. \tag{4.10}$$

Prelazak iz faze predsinkronizacije u fazu sinkronizacije, tj. promjena ulaznih veličina u PLL strukturu s $\psi_{\alpha\beta ph}$ na $\hat{\psi}_{\alpha\beta}$ ne uzrokuje značajan porast struje niti udarac momenta budući da je kut rotora $\hat{\theta}_{re}$ uspješno estimiran u fazi predsinkronizacije te je izlaz PI regulatora u q osi $u^*_{\hat{q}}$ postavljen na vrijednost induciranog napona. Ipak, zbog kašnjenja samog digitalnog sustava, mjerne nesigurnosti induciranog napona te eventualne pogrešne vrijednosti magnetskog toka stalnih magneta ψ_{md} dolazi do zanemarivog porasta struje prilikom uključenja generatorskog pretvarača. Da je ulaz u PLL strukturu uvijek estimirani magnetski tok $\hat{\psi}_{\alpha\beta}$, tj. da ne postoji faza predsinkronizacije tijekom koje je ulaz u PLL strukturu magnetski tok praznog hoda $\psi_{\alpha\beta ph}$, u početnom trenutku PI regulator PLL strukture ne bi imao ispravnu vrijednost estimirane brzine rotora na svom izlazu, već bi započinjao od iznosa nula. U tom slučaju zbog neispravne vrijednosti estimirane brzine i kuta rotora dolazi do značajnog porasta struje i prorade prekostrujne zaštite generatorskog pretvarača što je neprihvatljivo u slučaju vjetrogeneratora velikih snaga. Dakle, mjerenje induciranog napona u fazi predsinkronizacije i korištenje pripadnog magnetskog toka $\psi_{\alpha\beta ph}$ je ključno za određivanje kuta i brzine rotora prije uključenja generatorskog pretvarača čime se osigurava leteći start.

Razvijena struktura estimacije kuta i brzine rotora prikazana na slici 4.3 ovisi o točnim iznosima otpora statora R_s i induktiviteta u q osi L_q. Naime, estimacija magnetskog toka u mirujućem $\alpha\beta$ koordinatom sustavu ovisi o iznosu otpora statora R_s, a ulaz u PLL strukturu predstavlja greška magnetskog toka u q osi koji sadrži član $L_q i_{\hat{q}}$, tj. ovisi o induktivitetu u q osi. U slučaju pogrešnih vrijednosti navedenih parametara, osobito induktiviteta L_q, estimirani kut d osi sinkronog dq koordinatnog sustava ne odgovara stvarnom kutu d osi odnosno osi stalnih magneta u rotoru stroja. U tom slučaju mjerene struje koje se transformiraju u estimirani sinkroni $\hat{dq}$ koordinatni sustav ne odgovaraju stvarnim strujama u stroju, a time i ostvareni moment ne odgovara referentnoj vrijednosti momenta što je ključno kod vjetrogeneratora gdje je moment upravljačka veličina. Također, veće greške u estimiranom kutu rotora mogu dovesti do nestabilnog vladanja strukture vektorskog upravljanja te naglog porasta struje i prorade prekostrujne zaštite. Da bi se osiguralo efikasno i precizno upravljanje, potrebno je navedene parametre adaptirati ovisno o radnoj točki generatora.

U slučaju razvijene strukture otpor statora nije adaptiran već je u strukturi korištena konstantna vrijednost određena prilikom identifikacije parametara generatora. Navedeni pristup se može opravdati činjenicom da se radi o generatoru velike snage ($P_n > 100$ kW) kojeg karakterizira mala vrijednost otpora statora što rezultira zanemarivim padom napona na otporu statora, čak i pri nazivnoj vrijednosti struje. S druge strane, vrijednost induktiviteta u poprečnoj q osi adaptirana je korištenjem pregledne tablice koja sadrži identificirane vrijednosti induktiviteta u ovisnosti o struji u poprečnoj q osi ($L_q = f(i_q)$).

Budući da struktura fazno zatvorene petlje sadrži astatizam prvog reda, parametri PI regulatora PLL strukture su podešeni prema simetričnom optimumu [41].

4.3. Simulacijski rezultati

Opisana metoda letećeg starta generatorskog pretvarača i upravljanja bez mjernog člana brzine rotora temeljena na mjerenju induciranog napona generatora i fazno zatvorenoj petlji potvrđena je na simulacijskom modelu u programskom paketu PLECS. U simulacijskom modelu korišteni su parametri sinkronog generatora sa stalnim magnetima i AC-DC-AC pretvarača laboratorijskog modela opisanog u poglavlju 3:

PMG: $P_n = 375$ kW, $E_n = 400$ V, $I_n = 596$ A, $f_n = 75$ Hz, $n_n = 1500$ rpm.
Parametri nadomjesne sheme: $R_s = 7$ mΩ, $L_d = 0.8$ mH, $L_q = 2.7$ mH, $\psi_{md} = 0.69$ Wb.
AC-DC-AC pretvarač: $P_n = 520$ kW, $U_n = 400$ V, $I_n = 750$ V, $f_{sw} = 2$ kHz, $U_{dc} = 650$ V.
Bazne vrijednosti: $U_b = 326$ V, $I_b = 843$ A, $f_b = 75$ Hz, $n_{rb} = 1500$ okr/min, $\omega_{rb} = 471$ rad/s, $M_b = 2389$ Nm, $Z_b = 0.39$ Ω, $L_b = 0.83$ mH, $\psi_b = 0.69$ Wb.

Upravljačka struktura simulacijskog modela sastoji se od proračuna referentnih vrijednosti struja $\boldsymbol{i}_{dq}^*$ na temelju referentne vrijednosti momenta M^* prema MTPA algoritmu. Proračunate referentne vrijednosti struja se prosljeđuju prema strukturi vektorskog upravljanja u koordinatnom sustavu magnetskog toka rotora. Estimirana brzina $\hat{\omega}_{re}$ i kut $\hat{\theta}_{re}$ rotora slijede iz ranije opisane metode temeljene na mjerenju induciranog napona generatora, estimatoru magnetskog toka i fazno zatvorenoj petlji. Vrijednosti parametara PI regulatora struja su izračunati prema tehničkom optimumu: $K_{pd} = 0.6$, $T_{id} = 90$ ms, $K_{pq} = 1.2$, $T_{iq} = 90$ ms. Frekvencija diskretnog niskopropusnog filtra za integraciju induciranog napona postavljena je na vrijednost $f_g = 1$ Hz. Vrijednosti parametara PI regulatora PLL strukture izračunate su prema simetričnom optimumu: $K_p^{\mathrm{PLL}} = 0.5$, $T_i^{\mathrm{PLL}} = 50$ ms.

U nastavku je prikazana motivacija za upotrebu metode letećeg starta (simulacijski odzivi prilikom uključenja generatorskog pretvarača bez faze predsinkronizacije), simulacijski odzivi u fazi predsinkronizacije i sinkronizacije (uključenje generatorskog pretvarača), te simulacijski odzivi prilikom promjene referentne vrijednosti momenta i promjene brzine rotora.

4.3.1. Uključenje generatorskog pretvarača bez algoritma letećeg starta

Ako se u strukturi estimacije prikazanoj na slici 4.3 zanemare dijelovi vezani uz fazu predsinkronizacije i sinkronizacije, tj. određivanje brzine i kuta rotora prije uključenja generatorskog pretvarača, slijedi struktura estimacije prikazana na slici 4.4 svojstvena sinkronim motorima sa stalnim magnetima gdje se podrazumijeva da je brzina jednaka nuli prije uključenja pretvarača.

Na slici 4.5 prikazano je uključenje generatorskog pretvarača pri brzini rotora $\omega_r = 0.33$ p.u. ($n_r = 500$ okr/min) u trenutku $t = 0.2$ s uz strukturu estimacije bez algoritma letećeg starta. Prikazani su odzivi mjerene struje $\boldsymbol{i}_{abc}$, referentne M^* i proračunate vrijednosti M elektromagnetskog momenta, mjerene ω_{re} i estimirane $\hat{\omega}_{re}$ brzine rotora, ulaznog signala PI regulatora PLL

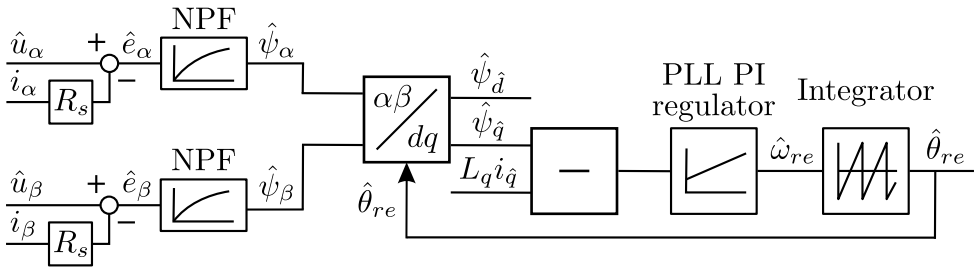

Slika 4.4: Struktura estimacije brzine i kuta rotora bez algoritma letećeg starta

strukture $\hat{\psi}_{\hat{q}} - L_q i_{\hat{q}}$, estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$ te mjerenog θ_{re} i estimiranog $\hat{\theta}_{re}$ kuta rotora.

Struktura estimacije bez algoritma letećeg starta uzrokuje značajan porast struje ($\boldsymbol{i}_{abc} \approx 0.5$ p.u.) i udarac momenta ($M \approx -0.4$ p.u.) prilikom uključenja generatorskog pretvarača što može biti pogubno za generatorski pretvarač i sam generator s električnog aspekta, a osobito za generator i vjetroturbinu s mehaničkog aspekta. Navedena pojava posljedica je nepoznate brzine i kuta rotora te induciranog napona generatora prije trenutka uključenja generatorskog pretvarača. U tom slučaju, početna vrijednost estimirane brzine rotora je jednaka nuli u trenutku uključenja. Tijekom prijelazne pojave, koju karakteriziraju značajne oscilacije u estimiranoj brzini rotora, dolazi do značajnog porasta struje budući da estimirani kut rotora, koji je ključan za ispravan rad strukture vektorskog upravljanja, nije ispravan. Ipak, nakon završetka prijelazne pojave estimirani kut rotora postaje jednak stvarnom kutu rotora te su struja i moment uspješno regulirani na vrijednost jednaku nuli.

Uključenje generatorskog pretvarača pri brzini većoj od simulirane izazvao bi veći porast struje i udarac momenta uslijed proporcionalno većeg induciranog napona generatora. Iz pri-

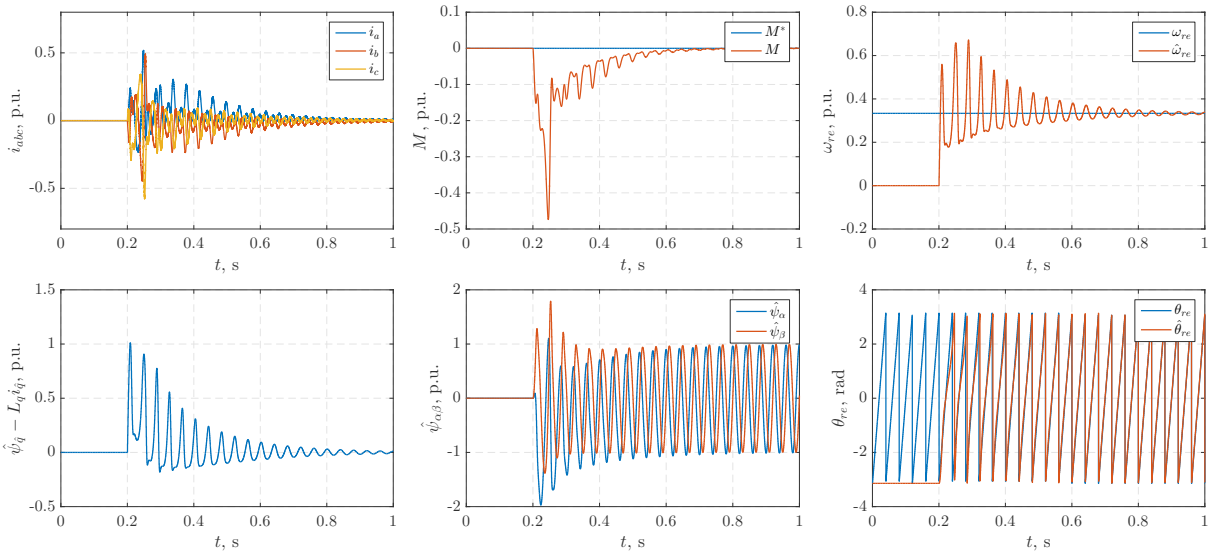

Slika 4.5: Uključenje generatorskog pretvarača uz strukturu estimacije bez algoritma letećeg starta pri brzini rotora $\omega_r = 0.33$ p.u.

loženog je očito da je navedeni algoritam neprihvatljiv za vjetrogeneratore velikih snaga zbog pogubnog električnog, a posebice mehaničkog djelovanja na čitav sustav.

4.3.2. Faza predsinkronizacije

Na slici 4.6 prikazana je faza predsinkronizacije pri brzini rotora $\omega_r = 0.33$ p.u. ($n_r = 500$ okr/min) koja započinje u trenutku $t = 0$ s uz strukturu estimacije koja uključuje algoritam letećeg starta. Prikazani su odzivi mjerene ω_{re} i estimirane $\hat{\omega}_{re}$ brzine rotora, mjerenog θ_{re} i estimiranog $\hat{\theta}_{re}$ kuta rotora, kuta rotora θ_{rph} dobivenog iz mjerenog induciranog napona generatora, referentne vrijednosti napona $\boldsymbol{u}^*_{\hat{d}q}$, magnetskog toka u fazi predsinkronizacije $\boldsymbol{\psi}_{\alpha\beta ph}$ te estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$.

Iz mjerene vrijednosti induciranog napona generatora slijedi kut rotora θ_{rph} putem kojeg se inverznom Parkovom transformacijom dobiva magnetski tok $\boldsymbol{\psi}_{\alpha\beta ph}$. Kao što je navedeno ranije u tekstu, navedeni magnetski tok se koristi kao ulaz u PLL strukturu da bi se prije uključenja generatorskog pretvarača estimirali brzina i kut rotora. U trenutku $t = 0$ s započinje faza predsinkronizacije, tj. postaje aktivan PI regulator PLL strukture. Na temelju mjerene vrijednosti induciranog napona postavlja se početni uvjet regulatora struje u q osi $u^*_{\hat{q}} = 0.33$ p.u. U fazi predsinkronizacije generatorski pretvarač još nije uključen pa je vrijednost struje jednaka nuli. Budući da estimirani magnetski tok $\hat{\boldsymbol{\psi}}_{\alpha\beta}$ slijedi propuštanjem estimiranog induciranog napona (prije uključenja jednak referentnoj vrijednosti napona $u^*_{\hat{q}}$) kroz niskopropusni filtar, postoji prijelazna pojava u odzivu. Nakon završetka prijelazne pojave, tj. nastupanja stacionarnog stanja estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$ (postaje jednak magnetskom toku $\boldsymbol{\psi}_{\alpha\beta ph}$) te uspješne estimacije brzine i kuta rotora generatorski pretvarač je spreman za uključenje, tj. fazu sinkronizacije.

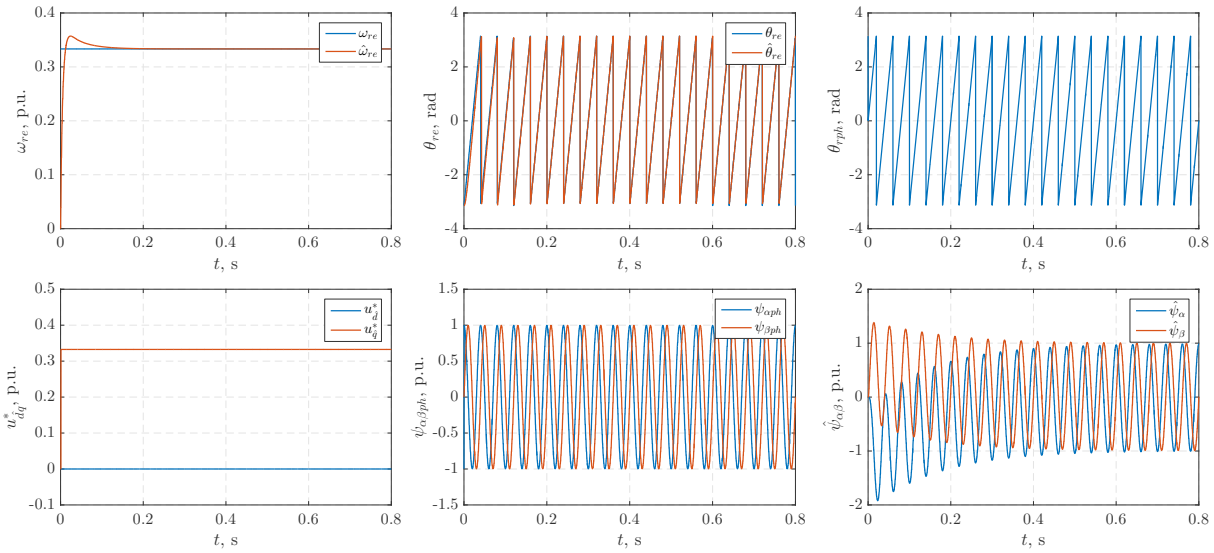

Slika 4.6: Faza predsinkronizacije uz strukturu estimacije s algoritmom letećeg starta pri brzini rotora $\omega_r = 0.33$ p.u.

4.3.3. Faza sinkronizacije

Na slici 4.7 prikazana je faza sinkronizacije pri brzini rotora $\omega_r = 0.33$ p.u. ($n_r = 500$ okr/min) koja započinje u trenutku $t = 1$ s uz strukturu estimacije koja uključuje algoritam letećeg starta. Prikazani su odzivi mjerene ω_{re} i estimirane $\hat{\omega}_{re}$ brzine rotora, mjerenog θ_{re} i estimiranog $\hat{\theta}_{re}$ kuta rotora, kuta rotora θ_{rph} dobivenog iz mjerenog induciranog napona generatora, mjerene struje $\boldsymbol{i}_{abc}$, ulaznog signala PI regulatora PLL strukture $\hat{\psi}_{\hat{q}} - L_q i_{\hat{q}}$, te estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$.

U trenutku uključenja generatorskog pretvarača ($t = 1$ s) dolazi do neznatnog porasta struje ($\boldsymbol{i}_{abc} \approx 0.02$ p.u.) što je prihvatljivo budući da uslijed malog iznosa struje ne dolazi do značajnog udarca momenta. Kut rotora θ_{rph} dobiven iz mjerenog napona generatora više nije moguće koristiti budući da napon generatora više nije sinusnog valnog oblika već je definiran pulsno-širinskom modulacijom generatorskog pretvarača što uzrokuje izobličenje navedenog kuta. Iz navedenog razloga se nakon faze sinkronizacije ne može koristiti niti magnetski tok $\boldsymbol{\psi}_{\alpha\beta\,ph}$ već se kao ulaz u strukturu estimacije kuta i brzine rotora koristi estimirani magnetski tok $\hat{\boldsymbol{\psi}}_{\alpha\beta}$. Nakon prijelazne pojave estimirane brzine i kuta rotora generatorski pretvarač spreman je za trajni rad bez mjernog člana brzine rotora.

4.3.4. Promjena referentne vrijednosti momenta

Na slici 4.8 prikazana je promjena referentne vrijednosti momenta s $M^* = 0$ p.u. na $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.33$ p.u. ($n_r = 500$ okr/min) koja započinje u trenutku $t = 2$ s uz strukturu estimacije koja uključuje algoritam letećeg starta. Prikazani su odzivi referentne M^* i proračunate M vrijednosti elektromagnetskog momenta, mjerene ω_{re} i estimirane $\hat{\omega}_{re}$ brzine

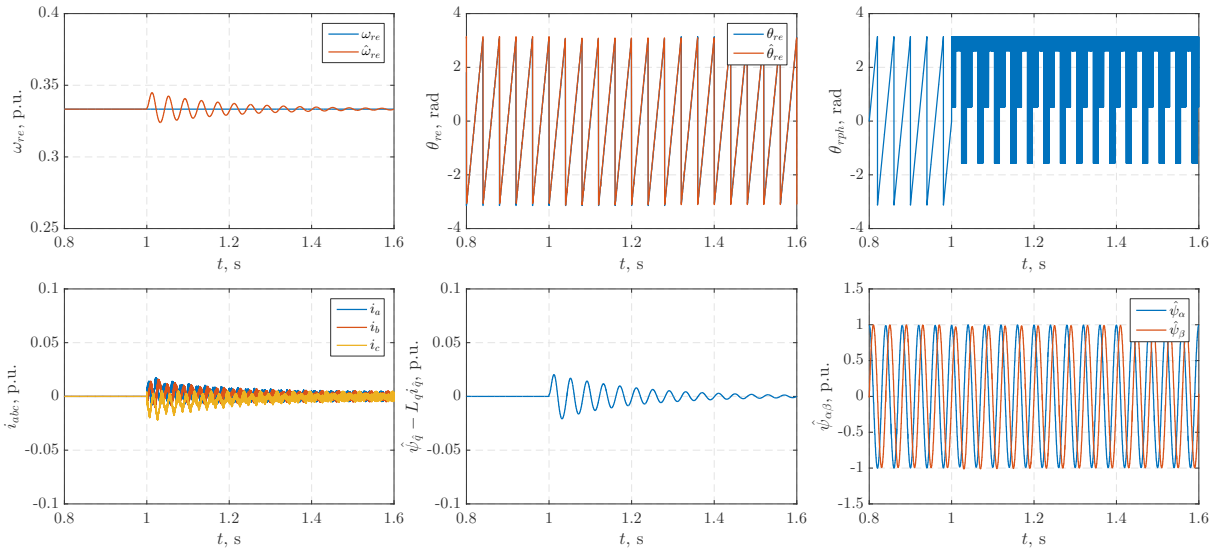

Slika 4.7: Faza sinkronizacije uz strukturu estimacije s algoritmom letećeg starta pri brzini rotora $\omega_r = 0.33$ p.u.

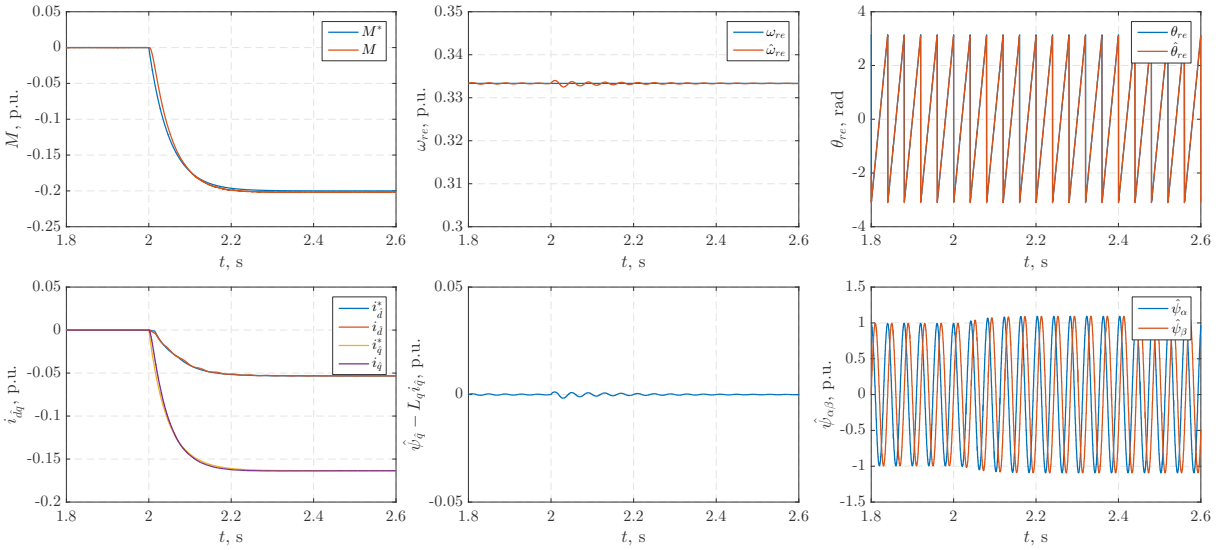

Slika 4.8: Promjena referentne vrijednosti momenta s $M^* = 0$ p.u. na $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.33$ p.u.

rotora, mjerenog θ_{re} i estimiranog $\hat{\theta}_{re}$ kuta rotora, referentne $\boldsymbol{i}^*_{\hat{d}\hat{q}}$ i mjerene $\boldsymbol{i}_{\hat{d}\hat{q}}$ vrijednosti struje, ulaznog signala PI regulatora PLL strukture $\hat{\psi}_{\hat{q}} - L_q i_{\hat{q}}$, te estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$.

U trenutku promjene referentne vrijednosti momenta M^*, a time i referentnih vrijednosti struja $\boldsymbol{i}^*_{\hat{d}\hat{q}}$ dolazi do kratkotrajnih oscilacija u ulaznom signalu PI regulatora PLL strukture $\hat{\psi}_{\hat{q}} - L_q i_{\hat{q}}$ što je posljedica promjene magnetskog toka i struje. Oscilacije u ulaznom signalu uzrokuju oscilacije i u estimiranoj brzini rotora $\hat{\omega}_{re}$. Nakon završetka prijelazne pojave brzina i kut rotora su uspješno estimirani, mjerena struja $\boldsymbol{i}_{\hat{d}\hat{q}}$ prati referentnu struju $\boldsymbol{i}^*_{dq}$. Također dolazi i do porasta vrijednosti estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$ što je posljedica porasta vrijednosti struje.

4.3.5. Promjena brzine rotora

Na slici 4.9 prikazana je promjena brzine rotora s $\omega_r = 0.33$ p.u. na $\omega_r = 0.4$ p.u. pri referentnoj vrijednosti momenta $M^* = -0.2$ p.u. koja započinje u trenutku $t = 3$ s uz strukturu estimacije koja uključuje algoritam letećeg starta. Prikazani su odzivi referentne M^* i proračunate M vrijednosti elektromagnetskog momenta, mjerene ω_{re} i estimirane $\hat{\omega}_{re}$ brzine rotora, mjerenog θ_{re} i estimiranog $\hat{\theta}_{re}$ kuta rotora, referentne $\boldsymbol{i}^*_{\hat{d}\hat{q}}$ i mjerene $\boldsymbol{i}_{\hat{d}\hat{q}}$ vrijednosti struje, ulaznog signala PI regulatora PLL strukture $\hat{\psi}_{\hat{q}} - L_q i_{\hat{q}}$, te estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$.

U trenucima promjene brzine rotora ω_r dolazi do odstupanja proračunate M i referentne vrijednosti M^* momenta što je posljedica odstupanja mjerene $\boldsymbol{i}_{\hat{d}\hat{q}}$ i referentne $\boldsymbol{i}^*_{\hat{d}\hat{q}}$ vrijednosti struje. Tijekom prijelazne pojave estimirana brzina rotora prati porast mjerene brzine rotora, no ulazni signal PI regulatora PLL strukture nije jednak nuli. No, završetkom prijelazne pojave estimirana brzina postaje jednaka mjerenoj, kao što i estimirani kut postaje jednak mjerenom kutu što osigurava ispravnu vrijednost struja $\boldsymbol{i}_{\hat{d}\hat{q}}$ odnosno momenta M.

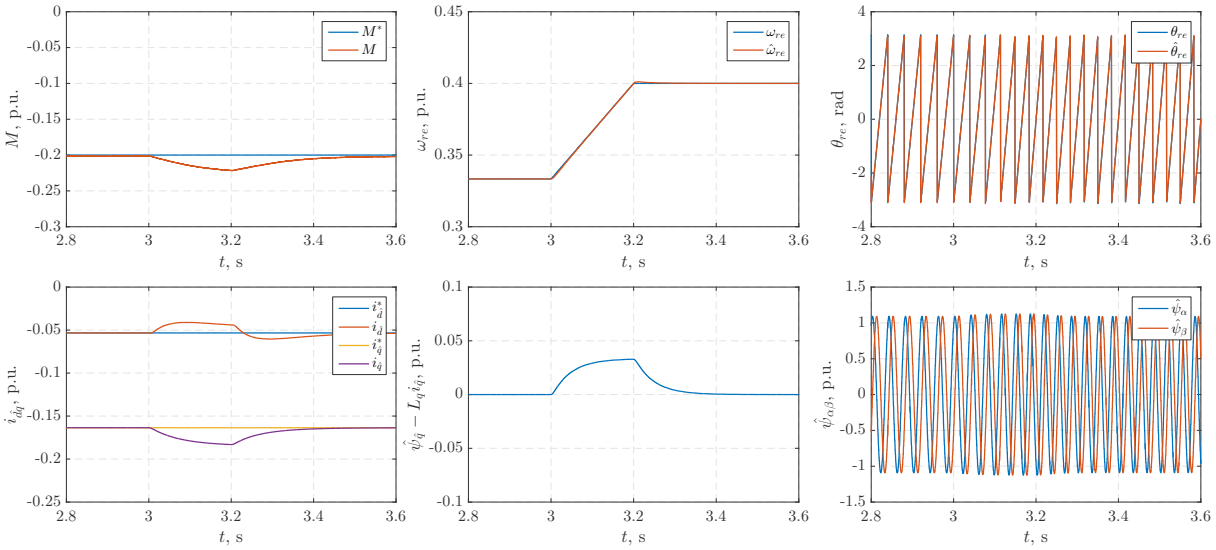

Slika 4.9: Promjena brzine rotora s $\omega_r = 0.33$ p.u. na $\omega_r = 0.4$ p.u. pri referentnoj vrijednosti momenta $M^* = -0.2$ p.u.

4.4. Eksperimentalni rezultati

Opisana metoda letećeg starta generatorskog pretvarača i upravljanja bez mjernog člana brzine rotora temeljena na mjerenju induciranog napona generatora i fazno zatvorenoj petlji implementirana je u digitalni sustav temeljen na ADSP-21992 mikroprocesoru korištenjem programskog alata *AlgoCAD* te potom provjerena na laboratorijskom postavu koji je opisan u poglavlju 3. Najvažniji podaci laboratorijskog postava koji se sastoji od sinkronog generatora sa stalnim magnetima, AC-DC-AC pretvarača i asinkronog motora koji emulira rad vjetroturbine ponovljeni su u nastavku:

PMG: Tema LPMR-450, $P_n = 375$ kW, $E_n = 400$ V, $I_n = 596$ A, $f_n = 75$ Hz, $n_n = 1500$ rpm.
AC-DC-AC pretvarač: Končar KONvert W1500, $P_n = 520$ kW, $U_n = 400$ V, $I_n = 750$ A, $f_{sw} = 2$ kHz, $U_{dc} = 650$ V.
AM: Končar 8AZJ 405-04, $P_n = 560$ kW, $U_n = 400$ V, $I_n = 967$ A, $f_n = 50$ Hz, $n_n = 1490$ rpm, $\cos\varphi_n = 0.87$.
Bazne vrijednosti: $U_b = 326$ V, $I_b = 843$ A, $f_b = 75$ Hz, $n_{rb} = 1500$ okr/min, $\omega_{rb} = 471$ rad/s, $M_b = 2389$ Nm, $Z_b = 0.39\ \Omega$, $L_b = 0.83$ mH, $\psi_b = 0.69$ Wb.

U nastavku je prikazana motivacija za upotrebu metode letećeg starta (eksperimentalni odzivi prilikom uključenja generatorskog pretvarača bez faze predsinkronizacije), eksperimentalni odzivi u fazi predsinkronizacije i sinkronizacije (uključenje generatorskog pretvarača), te eksperimentalni odzivi prilikom promjene referentne vrijednosti momenta i promjene brzine rotora. Eksperiment uključenja generatorskog pretvarača bez algoritma letećeg starta proveden je u trajanju 0.1 s, dok su preostali eksperimenti provedeni u trajanju 1 s. U programskom alatu *r_parnad* definirano je snimanje varijabli digitalnog sustava u 500 točaka unutar definiranog

vremenskog okvira koji odgovara trajanju eksperimenta.

4.4.1. Uključenje generatorskog pretvarača bez algoritma letećeg starta

Na slici 4.10 prikazano je uključenje generatorskog pretvarača pri brzini rotora $\omega_r = 0.33$ p.u. u trenutku $t = 0.03$ s uz strukturu estimacije bez algoritma letećeg starta prema slici 4.4. Prikazani su odzivi mjerene struje $\boldsymbol{i}_{abc}$, referentne M^* i proračunate M vrijednosti elektromagnetskog momenta, mjerene ω_{re} i estimirane $\hat{\omega}_{re}$ brzine rotora, ulaznog signala PI regulatora PLL strukture $\hat{\psi}_{\hat{q}} - L_q i_{\hat{q}}$, estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$ te mjerenog θ_{re} i estimiranog $\hat{\theta}_{re}$ kuta rotora.

U ovom eksperimentu prekostrujna zaštita je podešena na iznos 50% bazne vrijednosti radi zaštite pretvarača i generatora budući da je prema simulacijskim rezultatima očekivan značajan porast struje i udarac momenta. Kao što je očekivano, u trenutku uključenja generatorskog pretvarača dolazi do značajnog porasta struje i udarca momenta. Uslijed porasta struje dolazi do prorade prekostrujne zaštite i isključenja generatorskog pretvarača. Značajan porast struje u trenutku uključenja posljedica je nepoznavanja brzine i kuta rotora u trenutku uključenja. Budući da je kut rotora nepoznat, Parkova transformacija mjerene struje je neispravna te nije moguće regulirati struju na iznos nula. Također, prijelazna pojava estimiranog magnetskog toka na ulazu u PLL strukturu još nije završena u trenutku uključenja. Iz priloženog odziva može se utvrditi slaganje sa simulacijskim rezultatima te potvrditi da struktura estimacije bez određivanja brzine i kuta rotora prije uključenja generatorskog pretvarača nije primjenjiva na vjetrogeneratore velikih snaga.

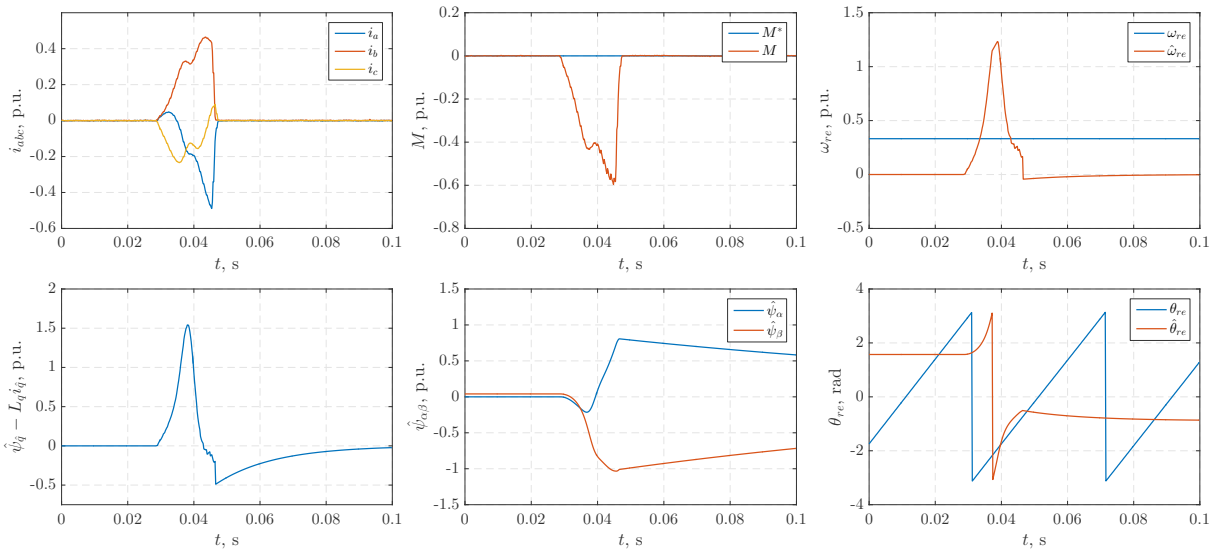

Slika 4.10: Uključenje generatorskog pretvarača uz strukturu estimacije bez algoritma letećeg starta pri brzini rotora $\omega_r = 0.33$ p.u.

4.4.2. Faza predsinkronizacije

Na slici 4.11 prikazana je faza predsinkronizacije pri brzini rotora $\omega_r = 0.33$ p.u. koja započinje u trenutku $t = 0.1$ s uz strukturu estimacije koja uključuje algoritam letećeg starta. Prikazani su odzivi mjerene ω_{re} i estimirane $\hat{\omega}_{re}$ brzine rotora, mjerenog θ_{re} i estimiranog $\hat{\theta}_{re}$ kuta rotora, kuta rotora θ_{rph} dobivenog iz mjerenog induciranog napona generatora, referentne vrijednosti napona $\boldsymbol{u}^*_{\hat{d}q}$, magnetskog toka u fazi predsinkronizacije $\boldsymbol{\psi}_{\alpha\beta ph}$ te estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$.

Kutem θ_{rph} koji se dobiva iz induciranog napona generatora izvršava se inverzna Parkova transformacija kojom se magnetski tok stalnih magneta smješta u d te se kao rezultat transformacije dobiva magnetski tok $\boldsymbol{\psi}_{\alpha\beta ph}$ koji se koristi kao ulaz u PLL strukturu u fazi predsinkronizacije. Faza predsinkronizacije započinje u trenutku $t = 0.1$ s uključenjem PI regulatora PLL strukture. U navedenom trenutku dolazi do značajnog nadvišenja estimirane brzine rotora ($\hat{\omega}_{re} \approx 0.6$ p.u.). Početno nadvišenje ovisi o trenutku uključenja PI regulatora PLL strukture odnosno o iznosu razlike mjerenog θ_{re} i estimiranog $\hat{\theta}_{re}$ u trenutku uključenja. No, nadvišenje estimirane brzine rotora $\hat{\omega}_{re}$ nema utjecaj na sustav budući da generatorski pretvarač još nije uključen, tj. radi se o fazi predsinkronizacije. Nakon završetka prijelazne pojave, estimirane vrijednosti brzine i kuta rotora slažu se s mjerenim vrijednostima. Početni uvjet PI regulatora struje u q osi je postavljen na iznos mjerenog induciranog napona $u^*_{\hat{q}} = 0.33$ p.u. Nakon završetka prijelazne pojave estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$ sustav je spreman za uključenje generatorskog pretvarača, tj. fazu sinkronizacije.

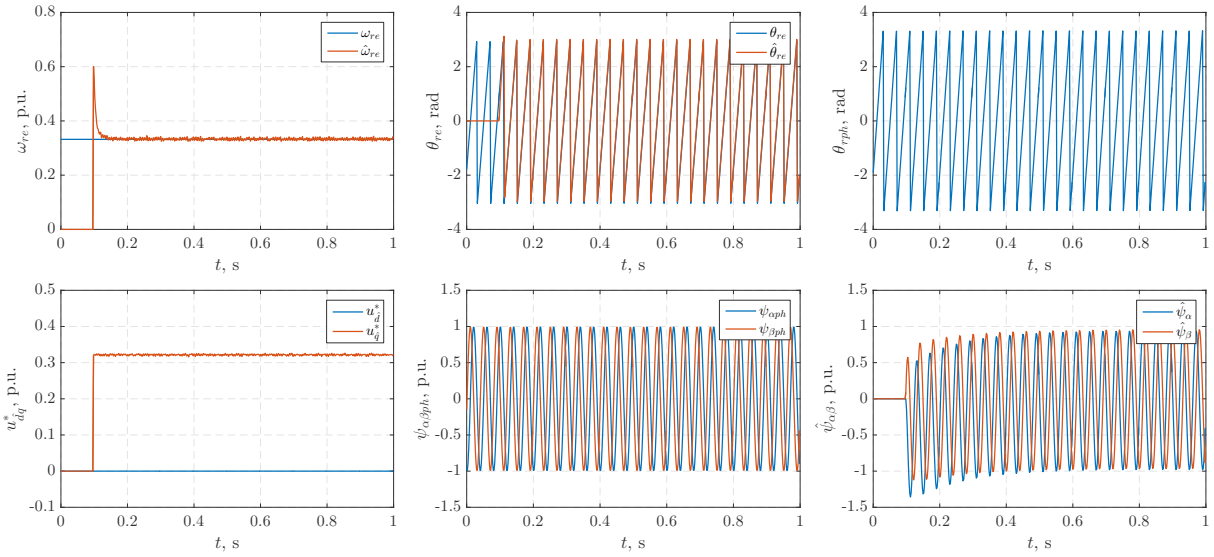

Slika 4.11: Faza predsinkronizacije u trenutku uz strukturu estimacije s algoritmom letećeg starta pri brzini rotora $\omega_r = 0.33$ p.u.

4.4.3. Faza sinkronizacije

Na slici 4.12 prikazana je faza sinkronizacije pri brzini rotora $\omega_r = 0.33$ p.u. koja započinje u trenutku $t = 0.1$ s uz strukturu estimacije koja uključuje algoritam letećeg starta. Prikazani su odzivi mjerene ω_{re} i estimirane $\hat{\omega}_{re}$ brzine rotora, mjerenog θ_{re} i estimiranog $\hat{\theta}_{re}$ kuta rotora, kuta rotora θ_{rph} dobivenog iz mjerenog induciranog napona generatora, mjerene struje $\boldsymbol{i}_{abc}$, ulaznog signala PLL PI regulatora $\hat{\psi}_{\hat{q}} - L_q i_{\hat{q}}$, te estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$.

U trenutku uključenja generatorskog pretvarača ($t = 0.1$ s) dolazi do neznatnog porasta struje ($\boldsymbol{i}_{abc} \approx 0.06$ p.u.) što je prihvatljivo budući da navedeni iznos struje ne uzrokuje značajan udarac momenta. Ipak, vrijednost struje prilikom uključenja generatorskog pretvarača je nešto većeg iznosa u usporedbi s vrijednosti struje u simulacijskom odzivu ($\boldsymbol{i}_{abc} \approx 0.02$ p.u.). Nešto veći iznos struje prilikom uključenja posljedica je kašnjenja digitalnog sustava, mjerne nesigurnosti induciranog napona i eventualne greške u vrijednosti magnetskog toka stalnih magneta koja se koristi u strukturi estimacije. Nakon uključenja generatorskog pretvarača kut rotora θ_{rph} dobiven na temelju mjerenja induciranog napona je izobličen uslijed djelovanja PWM-a te se ne može koristiti u strukturi estimacije brzine i kuta rotora. Nakon završetka prijelazne pojave estimirane brzine i kuta rotora generatorski pretvarač je spreman za trajni rad bez mjernog člana brzine rotora.

4.4.4. Promjena referentne vrijednosti momenta

Na slici 4.13 prikazana je promjena referentne vrijednosti momenta s $M^* = 0$ p.u. na $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.33$ p.u. koja započinje u trenutku $t = 0.1$ s uz strukturu estimacije koja uključuje algoritam letećeg starta. Prikazani su odzivi referentne M^* i proračunate

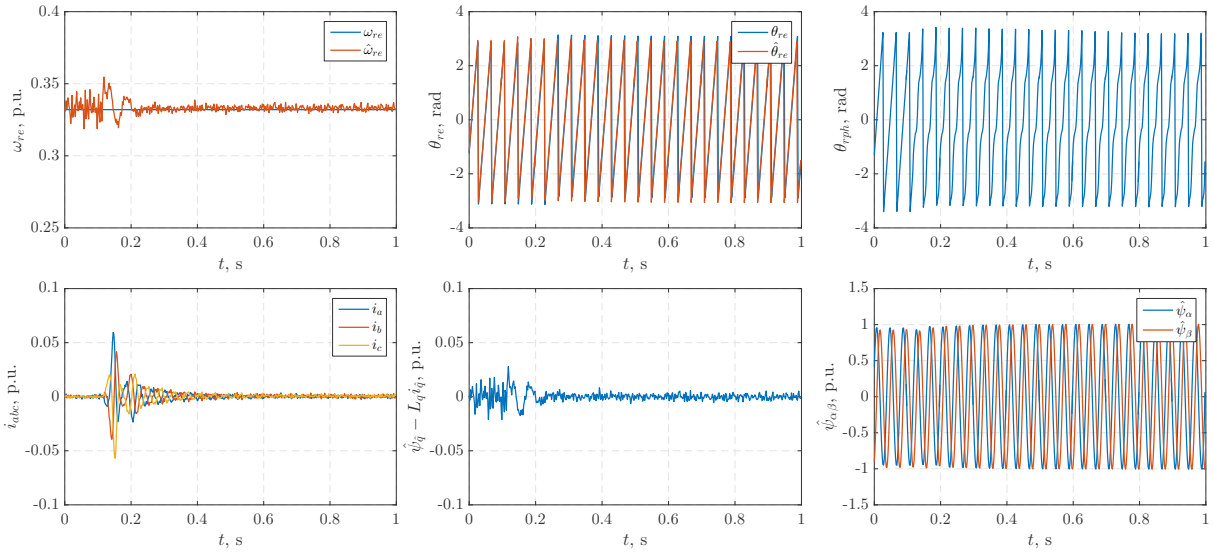

Slika 4.12: Faza sinkronizacije uz strukturu estimacije s algoritmom letećeg starta pri brzini rotora $\omega_r = 0.33$ p.u.

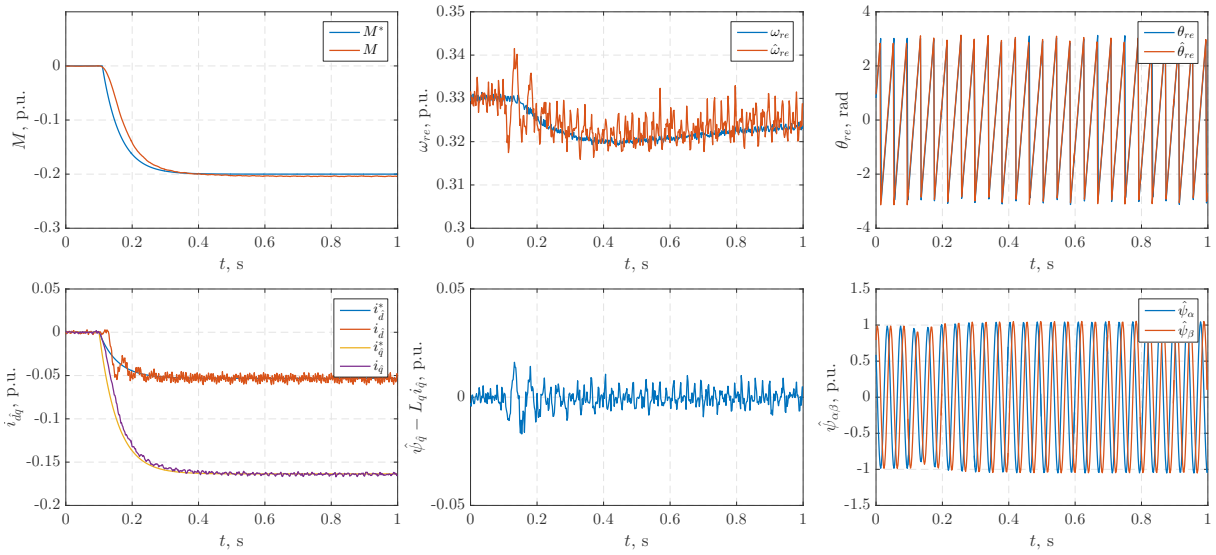

Slika 4.13: Promjena referentne vrijednosti momenta s $M^* = 0$ p.u. na $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.33$ p.u.

M vrijednosti elektromagnetskog momenta, mjerene ω_{re} i estimirane $\hat{\omega}_{re}$ brzine rotora, mjerenog θ_{re} i estimiranog $\hat{\theta}_{re}$ kuta rotora, referentne $\boldsymbol{i}^*_{dq}$ i mjerene $\boldsymbol{i}_{\hat{d}q}$ vrijednosti struje, ulaznog signala PI regulatora PLL strukture $\hat{\psi}_{\hat{q}} - L_q i_{\hat{q}}$, te estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$.

U trenutku promjene referentne vrijednosti momenta M^*, a time i referentnih vrijednosti struja $\boldsymbol{i}^*_{\hat{d}q}$ dolazi do kratkotrajnog propada brzine rotora te oscilacija u ulaznom signalu PI regulatora PLL strukture $\hat{\psi}_{\hat{q}} - L_q i_{\hat{q}}$ kao i estimiranoj brzini rotora $\hat{\omega}_{re}$. Do propada brzine rotora dolazi uslijed promjene momenta generatora, tj. potreban je određeni period da asinkroni motor koji emulira rad vjetroturbine te radi u regulaciji brzine vrtnje stvori moment suprotnog smjera čime brzina rotora ostaje jednaka referentnoj vrijednosti. Nakon završetka prijelazne pojave ulazni signal PI regulatora je jednak nuli, estimirana brzina rotora prati mjerenu vrijednost te dolazi do porasta amplitude magnetskog toka što je posljedica porasta struje.

4.4.5. Promjena brzine rotora

Na slici 4.14 prikazana je promjena brzine rotora s $\omega_r = 0.33$ p.u. na $\omega_r = 0.4$ p.u. pri referentnoj vrijednosti momenta $M^* = -0.2$ p.u. koja započinje u trenutku $t = 0.2$ s uz strukturu estimacije koja uključuje algoritam letećeg starta. Kao i u prethodnom eksperimentu, prikazani su odzivi referentne M^* i proračunate M vrijednosti elektromagnetskog momenta, mjerene ω_{re} i estimirane $\hat{\omega}_{re}$ brzine rotora, mjerenog θ_{re} i estimiranog $\hat{\theta}_{re}$ kuta rotora, referentne $\boldsymbol{i}^*_{dq}$ i mjerene $\boldsymbol{i}_{\hat{d}q}$ vrijednosti struje, ulaznog signala PI regulatora PLL strukture $\hat{\psi}_{\hat{q}} - L_q i_{\hat{q}}$, te estimiranog magnetskog toka $\hat{\boldsymbol{\psi}}_{\alpha\beta}$.

U trenucima promjene brzine rotora ω_r dolazi do odstupanja proračunate M i referentne vrijednosti M^* uslijed odstupanja mjerene vrijednosti struje $\boldsymbol{i}_{\hat{d}q}$ i referentne vrijednosti struje $\boldsymbol{i}^*_{dq}$. Tijekom prijelazne pojave estimirana brzina rotora prati porast mjerene brzine rotora, no

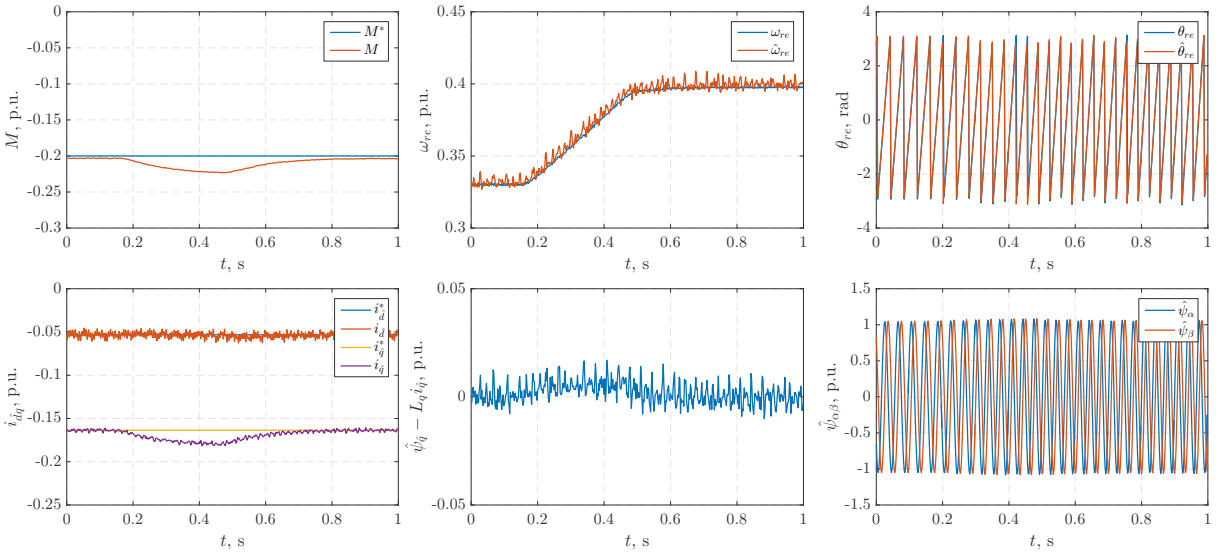

Slika 4.14: Promjena brzine rotora s $\omega_r = 0.33$ p.u. na $\omega_r = 0.4$ p.u. pri referentnoj vrijednosti momenta $M^* = -0.2$ p.u.

ulazni signal PI regulatora PLL strukture nije jednak nuli. No, završetkom prijelazne pojave estimirana brzina postaje jednaka mjerenoj, kao što i estimirani kut postaje jednak mjerenom kutu što osigurava ispravnu vrijednost struja $\boldsymbol{i}_{\hat{d}q}$ odnosno proračunatog momenta M.

5. Modelsko prediktivno upravljanje strujama

5.1. Pregled literature

Razvojem računalne moći digitalnih sustava upravljanja algoritmi modelskog prediktivnog upravljanja (engl. *model predictive control*, MPC) dobivaju značajniju primjenu u upravljanju pretvaračima napona i frekvencije te električnim strojevima. Glavne značajke MPC algoritama su fleksibilnost prilikom definiranja kriterijske funkcije, upravljanje sustavima s više ulaza i izlaza (engl. *multiple input multiple output*, MIMO) te uzimanje u obzir ograničenja varijabli stanja sustava (npr. struja pretvarača ili električnog stroja) i upravljačkih veličina (npr. izlazni napon pretvarača) prilikom sinteze samog regulatora. Zbog navedenih svojstava, u znanstvenoj literaturi se često standardni načini upravljanja poput vektorskog upravljanja u koordinatnom sustavu magnetskog toka rotora (RFOC) temeljenog na PI regulatorima i izravnog upravljanja momentom (DTC) temeljenog na histereznim regulatorima zamjenjuju upravo različitim upravljačkim strukturama temeljenim na MPC regulatoru [66].

Kao jedna od glavnih prednosti upravljačke strukture za pretvarače napona i frekvencije odnosno električne strojeve temeljene na MPC regulatoru ističe se fleksibilnost prilikom definiranja kriterijske funkcije te sustavno uzimanje u obzir ograničenja varijabli stanja i upravljačkih veličina. Prilikom odabira kriterijske funkcije moguće je definirati kojim veličinama se upravlja (npr. struja, moment, magnetski tok, brzina, pozicija i sl.) kao i težinske faktore kojima se množe pojedina odstupanja (npr. u slučaju upravljanja momentom i magnetskim tokom moguće je odgovarajućim odabirom vrijednosti težinskih faktora dati veći prioritet penalizaciji odstupanja momenta). Također je moguće uključiti i dodatne zahtjeve na sustav upravljanja u kriterijsku funkciju poput eliminacije pojedinih harmonika signala, smanjenja sklopne frekvencije i sl. Sustavnim definiranjem ograničenja varijabli stanja sustava kojima se upravlja (npr. struja, moment, magnetski tok, brzina, pozicija i sl.) te upravljačke veličine (npr. izlazni napon, sklopno stanje pretvarača i sl.) prilikom sinteze samog regulatora moguće je onemogućiti rad sustava u neželjenoj radnoj točki (npr. struja veća od nazivne vrijednosti) kao i osigurati rad blizu ograničenja ili na samom ograničenju.

Uobičajeno se MPC algoritmi upravljanja pretvaračima napona i frekvencije te električnim strojevima mogu podijeliti u dvije skupine, ovisno koristi li se modulacija širine impulsa. U primjenama s PWM-om radi se o modelskom prediktivnom upravljanju s kontinuiranim skupom upravljačkih akcija (engl. *continuous control set model predictive control*, CCS-MPC) dok se u primjenama bez PWM-a radi o modelskom prediktivnom upravljanju s konačnim skupom upravljačkih akcija (engl. *finite control set model predictive control*, FCS-MPC) [66].

5.1.1. Modelsko prediktivno upravljanje s kontinuiranim skupom upravljačkih akcija (CCS-MPC)

Glavno svojstvo CCS-MPC algoritama je fiksna sklopna frekvencija budući da se koristi neki od dostupnih tipova PWM-a [67]. Najčešće korišteni CCS-MPC algoritama primijenjeni na pretvarače napona i frekvencije temelje se na standardnom MPC regulatoru u prostoru stanja uz *online* (u svakom koraku prekidne rutine u kojoj se izvršava algoritam) rješavanje optimizacijskog problema, poopćenom prediktivnom upravljanju (engl. *generalized predictive control*, GPC) ili eksplicitnom modelskom prediktivnom upravljanju (engl. *explicit model predictive control*, EMPC).

U literaturi je opisan veći broj standardnih MPC regulatora u prostoru stanja uz *online* rješavanje optimizacijskog problema primijenjenih na pretvarače napona i frekvencije te električne strojeve. Ovisno o složenosti optimizacijskog problema pronalazak optimalnog rješenja može trajati dulje od vremena uzorkovanja što dovodi do neprimjenjivosti algoritma. Stoga je potrebno prilikom sinteze MPC regulatora osigurati da je pronalazak optimalnog rješenja moguć unutar perioda uzorkovanja. U [68] razvijen je MPC regulator momenta i struje u d osi gdje je optimizacijski problem riješen korištenjem gradijentne metode brzog spusta (engl. *fast gradient method*). Ista metoda rješavanja optimizacijskog problema korištena je u [69] gdje je MPC algoritam primijenjen na upravljanje strujama mrežnog dvorazinskog pretvarača. U navedenu podgrupu MPC algoritama spadaju i struktura upravljanja momentom sinkronog motora sa stalnim magnetima temeljena na MPC regulatoru [70] te MPC regulator koji osigurava rad u području slabljenja polja sinkronog motora sa stalnim magnetima [71].

Poopćeno prediktivno upravljanje (engl. *generalized predictive control*, GPC) se temelji na prijenosnoj funkciji sustava uz dodatak bijelog šuma, tj. na CARIMA (engl. *controlled auto-regressive integrated moving average model*) modelu i kvadratnoj kriterijskoj funkciji. U slučaju da ne postoje ograničenja optimizacijski problem se analitička rješava u svakom koraku uzorkovanja te se kao rješenje dobiva vektor promjena upravljačkih veličina na predikcijskom horizontu [72]. U [73] je primijenjen GPC regulator struje mrežnog pretvarača koji osigurava brz odziv na promjenu referentne vrijednosti, robusnost na promjenu parametara te malo harmoničko izobličenje izlazne struje. U [74] i [75] razvijen je GPC regulator primijenjen na trofazni neprekidni izvor napajanja (engl. *uninterruptible power supply*, UPS).

Temeljno svojstvo EMPC algoritama je *offline* proračun optimalne upravljačke akcije u obliku eksplicitne funkcije dok se prilikom implementacije osigurava primjena optimalne upravljačke akcije ovisno o stanju sustava u svakom koraku uzorkovanja. Iako je u navedenom slučaju veći dio kompleksnog proračuna izvršen *offline*, u slučaju većih sustava eksplicitno rješenje može postati vrlo složeno što navedeni pristup ne čini prikladnim u nekim aplikacijama [72]. Čitav proces sinteze i implementacije eksplicitnog MPC regulatora brzine rotora i struje sinkronog motora sa stalnim magnetima opisan je u [76]. U [77] razvijena je kaskadna struktura upravljanja koja se sastoji od eksplicitnog MPC regulatora brzine i momenta. Razvijena upravljačka struktura osigurava visoku dinamiku sustava uz estimaciju brzine i kuta rotora putem observera čime se izbjegava korištenje mjernog člana brzine rotora. U [78] razvijen je eksplicitni GPC algoritam upravljanja brzinom i pozicijom sinkronog motora sa stalnim magnetima.

5.1.2. Modelsko prediktivno upravljanje s konačnim skupom upravljačkih akcija (FCS-MPC)

Specifičnost FCS-MPC algoritama je konačni skup upravljačkih akcija koji je definiran brojem dozvoljenih sklopnih stanja pretvarača napona i frekvencije. Primjerice, u slučaju dvorazinskog pretvarača postoji osam dozvoljenih sklopnih stanja, tj. vektora napona (šest aktivnih i dva nul-vektora napona). U tom slučaju upravljačka veličina nije kontinuirana varijabla kao u slučaju CCS-MPC algoritama, već jedan od vektora napona čime se u potpunosti izbjegava korištenje PWM-a. Budući da se sklopkama pretvarača izravno upravlja, FCS-MPC algoritmi pripadaju sličnoj grupi upravljačkih algoritama kao i DTC algoritmi [66]. U usporedbi s CCS-MPC algoritmima, glavna svojstva FCS-MPC algoritama su promjenjiva sklopna frekvencija (osim u iznimnim slučajevima kada je kriterijskom funkcijom osigurana fiksna sklopna frekvencija), bolje dinamičke performanse tijekom prijelazne pojave budući da ne postoji kašnjenje koje unosi PWM te manji računalni zahtjevi za rješavanje optimizacijskog problema u slučaju kratkog predikcijskog horizonta. Upravo zbog smanjenja složenosti optimizacijskog problema velik broj radova razmatra FCS-MPC algoritme s predikcijskim horizontom duljine jednog koraka (jedan period uzorkovanja). U slučaju produljenja predikcijskog horizonta dolazi do eksponencijalnog porasta složenosti optimizacijskog problema. S druge strane, glavna prednost CCS-MPC algoritama pred FCS-MPC algoritmima je u pravilu manje harmoničko izobličenje veličine kojom se upravlja (npr. struje) u stacionarnom stanju, osobito u slučaju manje vrijednosti frekvencije izvođenja FCS-MPC algoritma.

FCS-MPC algoritmi se načelno mogu podijeliti u dvije skupine: MPC optimalnog sklopnog stanja (engl. *optimal switching vector model predictive control*, OSV-MPC) i MPC optimalne sekvence sklopnih stanja (engl. *optimal switching sequence model predictive control*, OSS-MPC) [79]. U slučaju OSV-MPC algoritama optimalno sklopno stanje primijenjeno je tijekom cijelog perioda uzorkovanja, dok u slučaju OSS-MPC algoritama primijenjena su dva ili više

vektora napona tijekom perioda uzorkovanja. U posljednjem slučaju kao dio optimizacijskog problema pojavljuje se i faktor vođenja pojedine sklopke čime se ta grupa algoritama približava algoritmima koji uključuju i PWM. Zbog jednostavnosti te intuitivnosti optimizacijskog problema trenutno u literaturi prevladavaju OSV-MPC algoritmi. No, glavni nedostatak navedene grupe algoritama je značajno harmoničko izobličenje veličine kojom se upravlja (uobičajeno struje) budući da je samo jedan vektor napona primijenjen tijekom cijelog perioda uzorkovanja.

Modelsko prediktivno upravljanje optimalnim sklopnim stanjem (OSV-MPC)

U znanstvenoj literaturi su opisane brojne inačice OSV-MPC algoritama. Ovisno o varijabli stanja sustava kojom se upravlja algoritmi navedene skupine mogu se podijeliti na modelsko prediktivno izravno upravljanje brzinom (engl. *model predictive direct speed control*, MP-DSC), momentom (engl. *model predictive direct torque control*, MP-DTC), strujom (engl. *model predictive direct current control*, MP-DCC) i snagom (engl. *model predictive direct power control*, MP-DPC). Atribut *izravno* upućuje na činjenicu da se sklopkama pretvarača izravno upravljanja, tj. ne koristi se PWM. Uobičajeno se posljednje navedeni tip algoritama (MP-DPC) koristi za upravljanje mrežnim pretvaračem, dok se preostali tipovi (MP-DSC, MP-DTC i MP-DCC) koriste za upravljanje generatorskim pretvaračem ili izmjenjivačem.

U pogledu primjene navedene skupine algoritama na mrežne pretvarače, u [80] je opisan OSV-MPC algoritam upravljanja strujama mrežnog pretvarača uz dinamičko generiranje referentne vrijednosti. Estimacija induktiviteta putem MP-DPC algoritma primijenjenog na mrežni pretvarač opisana je u [81]. Primjena OSV-MPC algoritama na mrežni pretvarač uzimanjem u obzir LCL filtra opisana je u radovima [82, 83]. U [84] razvijen je OSV-MPC algoritam upravljanja naponom LC filtra primijenjen na dvorazinske pretvarače u izmjeničnoj mikromreži.

U pogledu primjene navedene skupine algoritama na generatorske pretvarače i električne generatore, specifično sinkrone generatore sa stalnim magnetima s primjenom u vjetroelektranama, postoji mali broj znanstvenih radova koji su ukratko opisani u nastavku. U [85] razvijeni su algoritmi MP-DPC upravljanja mrežnim pretvaračem te CCS-MPC upravljanja strujom odnosno momentom generatorskog pretvarača bez korištenja mjernog člana brzine rotora. Također su različite inačice OSV-MPC algoritama primijenjene na upravljanje mrežnim strujama i balansiranje napona kapaciteta u istosmjernom međukrugu četverorazinskog pretvarača [86] i trorazinskog NPC (engl. *neutral point clamped*) pretvarača [11, 87]. Od preostalih tipova generatora, inačica OSV-MPC algoritma primijenjena je i na pretvarač za rotorsku stranu dvostruko napajanog asinkronog generatora [88].

U pogledu primjene navedene skupine algoritama na izmjenjivače i električne motore, specifično sinkrone motore sa stalnim magnetima, postoji velik broj znanstvenih radova koji su opisani u nastavku. U [89, 90] razvijeni su MP-DSC algoritmi koji u kriterijskoj funkciji osim greške brzine rotora uključuju i članove koji osiguravaju praćenje MTPA krivulje. MP-DSC al-

goritam s proširenim Kalmanovim filtrom za estimaciju momenta tereta opisan je u [91]. U [92] je dana usporedba standardnog MP-DCC algoritma gdje se primjenjuje jedan vektor napona tijekom cijelog perioda uzorkovanja te dvije inačice MP-DCC algoritma gdje se primjenjuju dva vektora napona i modulacija širine impulsa. U [93], [94] razvijeni su MP-DCC algoritmi koji u kriterijskoj funkciji greške struje uključuju i praćenje MTPA krivulje te rad u području slabljenja magnetskog polja. U [95] razvijen je MP-DCC algoritam uz strukturu estimacije brzine i kuta rotora temeljenu na fazno zatvorenoj petlji. U [96] razvijen je MP-DTC algoritam koji pronalazi optimalan vektor napona putem *deadbeat* rješenja, dok je u [97] dana usporedba standardnog i pojednostavljenog MP-DTC algoritma te metode koja uključuje više od jednog vektora napona tijekom perioda uzorkovanja, tj. proračun faktora vođenja pojedine sklopke.

Također u literaturi postoji i veći broj radova gdje su različite inačice MP-DTC algoritama primijenjene na asinkrone motore. Modifikacijom modela korištenog u predikciji veći broj navedenih algoritama može se primijeniti na sinkrone strojeve sa stalnim magnetima. Osobito značajnu skupinu radova u kojima je MP-DTC algoritam primijenjen na asinkroni stroj čine [98–103]. U navedenoj skupini radova razvijeni algoritam je primijenjen na trorazinski izmjenjivač i asinkroni motor. Razvijeni algoritam osigurava zadržavanje momenta, magnetskog toka te potencijala neutralne točke izmjenjivača unutar definiranih ograničenja, uz značajno smanjenje sklopne frekvencije u usporedbi sa standardnim DTC algoritmom. Navedeni algoritam omogućava znatno produljenje predikcijskog horizonta razmatranjem isključivo sklopnih stanja koja ne krše ograničenja. U navedenim radovima opisana je i implementacija razvijenog algoritma u digitalnom sustavu pretvarača snage 2 MVA kao i eksperimentalna verifikacija. Eksperimentalni rezultati potvrđuju da razvijeni algoritam u usporedbi sa standardnim DTC algoritmom postiže značajno smanjenje sklopne frekvencije pretvarača, uz ista ograničenja momenta i magnetskog toka.

Modelsko prediktivno upravljanje optimalnom sekvencom sklopnih stanja (OSS-MPC)

U slučaju OSS-MPC algoritama primjenjuju se dva ili više vektora napona odnosno sklopna stanja tijekom perioda uzorkovanja. U usporedbi s OSV-MPC algoritmima moguće je postići bolje praćenje referentne vrijednosti veličine kojom se upravlja (npr. struja pretvarača ili električnog stroja), no optimizacijski problem postaje složeniji. U [104] razvijen je MP-DPC algoritam za mrežni pretvarač u kojem se proračunava faktor vođenja za jedan aktivan i jedan nul-vektor napona koji se potom primjenjuju tijekom perioda uzorkovanja. Alternativni način primjene dva vektora napona tijekom perioda uzorkovanja je opisan u [105]. U navedenom radu omogućena je primjena dva proizvoljna vektora napona (drugi vektor napona ne mora nužno biti nul-vektor) tijekom perioda uzorkovanja čime dolazi do poboljšanja performansi upravljanja. U [106] razvijen je hibridni algoritam koji osim postojećih osam vektora napona uzima u obzir i virtualne vektore koji se mogu ostvariti odgovarajućom kombinacijom faktora vođenja posto-

jećih vektora napona. Slični algoritmi razvijeni su u [107, 108] za upravljanje momentom s ciljem smanjenja oscilacija. Univerzalni algoritam koji primjenjuje višestruke vektore napona na temelju *deadbeat* upravljanja i SVPWM-a za asinkrone strojeve opisan je u [109]. U [110] primijenjen je OSS-MPC algoritam na mrežni pretvarač kojim se proračunavaju optimalne vrijednosti faktora vođenja pojedine sklopke.

Stabilnost i uzastopna dopustivost FCS-MPC algoritama

Poseban istraživački izazov predstavlja dokaz stabilnosti (engl. *stability*) i uzastopne dopustivosti (engl. *recursive feasibility*) FCS-MPC algoritama. Tek nedavno objavljeni radovi se bave navedenom problematikom. U tim radovima ograničenje definirano upravljačkom Ljapunovljevom funkcijom (engl. *control Lyapunov function*, CLF) obično se dodaje u optimizacijski problem da bi se osigurala stabilnost i uzastopna dopustivost algoritma upravljanja.

U [111, 112] razvijen je FCS-MPC algoritam temeljen na kvadratnoj Ljapunovljevoj funkciji. Navedeni algoritam simulacijski i eksperimentalno je provjeren na DC-DC pretvaraču i dvorazinskom DC-AC pretvaraču. Algoritam garantira stabilnost i uzastopnu dopustivost tretirajući diskretnu prirodu pretvarača kao ograničenu kvantizacijsku grešku upravljačkog signala. Budući da se razmatra najgori mogući slučaj kvantizacijske greške, ovaj pristup je pretjerano konzervativan. U [113] razvijen je FCS-MPC algoritam upravljanja strujama dvorazinskog pretvarača koji je povezan s trošilom koje se sastoji od otpora, induktiviteta i protuelektromotorne sile (RLE trošilo). Ljapunovljeva funkcija se koristi za određivanje referentne vrijednosti napona koji osigurava da struja bude unutar okoline referentne vrijednosti čime se jamči stabilnost. Također se ostvaruje i veća brzina izvođenja algoritma u usporedbi sa standardnim FCS-MPC algoritmom upravljanja strujom budući da se izbjegava predikcija vrijednosti struje u idućem koraku za svaki od vektora napona. Algoritmi slični opisanom razvijeni su u [114] za primjenu na dvosmjernom AC-DC pretvarač u sustavima za pohranu energije te u [115] za primjenu na dvorazinskom mrežnom pretvaraču s L filtrom uz korištenje diskretnog SVPWM-a. U [116] razvijen je FCS-MPC algoritam upravljanja brzinom i strujom u d osi sinkronog motora sa stalnim magnetima na površini rotora s predikcijskim horizontom od jednog koraka, uz dodavanje ograničenja u kriterijsku funkciju kojima se osigurava asimptotska stabilnost. Ista istraživačka grupa u [117] je razvila algoritam u kojem se stabilnost algoritma upravljanja na istoj vrsti stroja jamči ograničenjima koja se uvode upravljačkom Ljapunovljevom funkcijom. U [118] razvijen je FCS-MPC algoritam upravljanja momentom sinkronog motora sa stalnim magnetima koji osigurava praćenje MTPA krivulje te smanjenje oscilacija momenta. Specifičnost algoritma je korištenje Ljapunovljeve funkcije za proračun faktora vođenja pojedine sklopke čime se ujedno osigurava i stabilnost sustava upravljanja.

U [119] je razvijen algoritam upravljanja magnetskim tokom sinkronog motora sa stalnim magnetima uz dodatno ograničenje koje sadrži upravljačku Ljapunovljevu funkciju čime se

osigurava stabilnost sustava upravljanja. Također je izveden i upravljački invarijantni skup u normiranom prostoru magnetskog toka. Navedena svojstva stabilnosti i uzastopne dopustivosti su izvedena i za CCS-MPC i FCS-MPC inačice algoritma te su neovisna o kriterijskoj funkciji te duljini predikcijskog horizonta. No, zbog dodatnog ograničenja koje predstavlja upravljačka Ljapunovljeva funkcija ovaj pristup također može biti konzervativan, posebice tijekom prijelazne pojave struje.

5.1.3. Drugi znanstveni doprinos

U doktorskoj disertaciji je razvijen algoritam modelskog prediktivnog izravnog upravljanja strujama (MP-DCC) sinkronog vjetrogeneratora sa stalnim magnetima temeljen na fleksibilnoj upravljačkoj Ljapunovljevoj funkciji s ciljem smanjenja sklopnih gubitaka pretvarača [120]. U osnovi je stabilnost i uzastopna dopustivost sustava upravljanja osigurana korištenjem upravljačke Ljapunovljeve funkcije izvedene u [119]. No, unaprjeđenje postojećeg algoritma razvijenog u [119] čini dodavanje fleksibilnosti upravljačkoj Ljapunovljevoj funkciji čime je omogućeno smanjenje sklopnih gubitaka i tijekom prijelazne pojave te uzimanje u obzir mrtvog vremena generatorskog pretvarača prilikom predikcije budućih varijabli stanja i izračuna upravljačkog invarijantnog skupa. Također su definirana dva režima rada algoritma što zadavanjem odgovarajućih vrijednosti parametara za penalizaciju omogućuje potpunu slobodu u odabiru zahtjeva na upravljačku strukturu kao što su brzina odziva i nadvišenje tijekom prijelazne pojave, te harmoničko izobličenje struje i sklopna frekvencija generatorskog pretvarača u stacionarnom stanju. Time je moguće postići smanjenje sklopne frekvencije, a time i sklopnih gubitaka generatorskog pretvarača uz prihvatljivo harmoničko izobličenje struje.

5.2. Teorijske osnove modelskog prediktivnog upravljanja

Modelsko prediktivno upravljanje predstavlja skupinu algoritama optimalnog upravljanja gdje se upravljačka veličina proračunava rješavanjem optimizacijskog problema temeljenog prema željenom kriteriju, predviđanju budućih stanja sustava te ograničenjima sustava. Upravo predviđanje budućih stanja sustava te uzimanje u obzir ograničenja sustava prilikom sinteze MPC regulatora čine prednosti ovog tipa upravljanja pred standardnim PID regulatorom koji ima široku primjenu u industriji. Ovisno o složenosti i ograničenjima sustava kojim se upravlja, optimizacijski problem može biti veće ili manje složenosti. U slučaju složenih optimizacijskih problema potrebni su značajni računalni resursi za rješavanje optimizacijskog problema što može predstavljati problem u slučaju malog perioda uzorkovanja. Iz tog razloga, do značajnijeg razvoja digitalnih sustava upravljanja temeljenih na mikroprocesorima, industrijska primjena MPC algoritama je bila ograničena na sporo promjenjive procese (npr. kemijska industrija). No, razvojem modernih digitalnih sustava većih računalnih resursa, MPC algoritmi se počinju značajnije primjenjivati i u drugim granama industrije poput robotike, avioindustrije, učinske elektronike i sl.

5.2.1. Koncept modelskog prediktivnog upravljanja

Temeljno svojstvo ove skupine algoritama upravljanja je proračun optimalne vrijednosti upravljačke veličine rješavanjem definiranog optimizacijskog problema (engl. *optimization problem*) pritom koristeći matematički model procesa kojim se upravlja. Koncept modelskog prediktivnog upravljanja prikazan je na slici 5.1. Diskretni matematički model procesa koristi se za predikciju budućih vrijednosti varijabli stanja na temelju mjerenih vrijednosti u trenutnom periodu uzorkovanja. Predikcija se izvršava na predikcijskom horizontu (engl. *prediction horizon*) koji predstavlja broj budućih perioda uzorkovanja na kojima se računa predikcija varijabli stanja sustava. U pravilu, duži predikcijski horizont rezultira boljim performansama upravljanja sustava, ali i većom računalnom složenosti algoritma. Optimizacijski problem je određen kriterijskom funkcijom (engl. *cost function*) te ograničenjima (engl. *constraints*) varijabli stanja sustava i upravljačke veličine. Kriterijskom funkcijom se definiraju zahtjevi na upravljačku strukturu, npr. penalizacija regulacijskog odstupanja, promjene upravljačke veličine i sl. Ograničenja varijabli stanja sustava i upravljačke veličine moguće je već prilikom sinteze MPC regulatora uzeti u obzir te time osigurati rad sustava unutar dopustivih granica (npr. u slučaju pretvarača i električnih strojeva se može osigurati rad unutar strujnog i naponskog ograničenja). U svakom koraku uzorkovanja rješenje optimizacijskog problema predstavlja vektor optimalnih upravljačkih veličina na čitavom predikcijskom horizontu. No, na kraju proračuna primjenjuje se samo optimalna upravljačka veličina proračunata za trenutni period uzorkovanja te se čitav postupak ponavlja u idućem koraku uzorkovanja. Navedeni princip naziva se upravljanje s

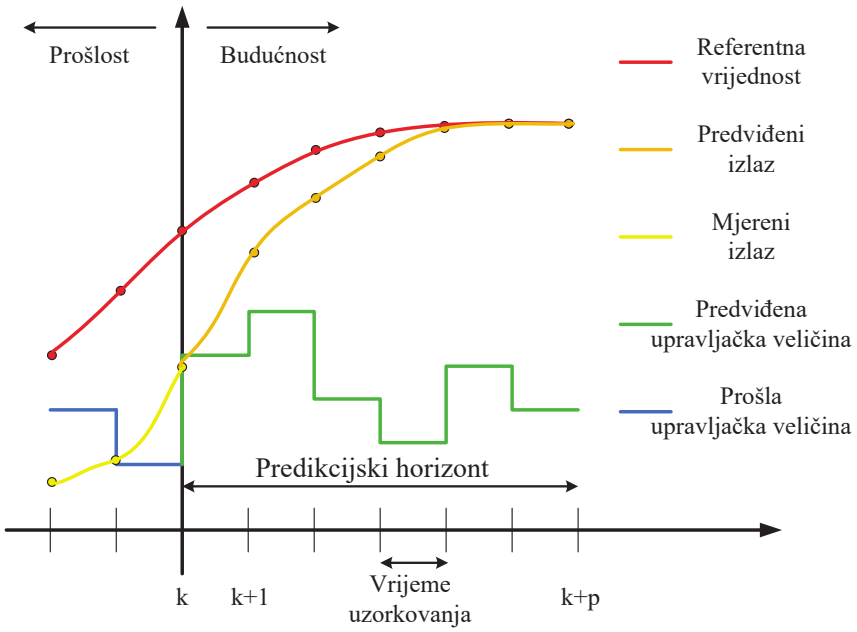

Slika 5.1: Koncept modelskog prediktivnog upravljanja

pomičnim horizontom (engl. *receding horizon control*) [121].
Iz priloženog se metodologija MPC algoritama može podijeliti u sljedeće cjeline:

1. diskretni matematički model sustava,
2. kriterijska funkcija,
3. ograničenja,
4. optimizacijski problem.

5.2.2. Diskretni matematički model sustava

Predikcija budućih vrijednosti varijabli stanja temelji se na matematičkom modelu sustava kojim se upravlja. Točnost matematičkog modela sustava je iznimno važna, jer u protivnom dolazi do pogrešne predikcije budućih varijabli stanja te narušenih performansi upravljanja kao i neželjenog vladanja sustava. Uobičajen zapis matematičkog modela sustava je matrični zapis u prostoru stanja. Dinamika općenitog sustava može se zapisati sljedećim izrazima [122]:

$$\begin{aligned} \frac{\mathrm{d}\boldsymbol{x}(t)}{\mathrm{d}t} &= f(\boldsymbol{x}(t), \boldsymbol{u}(t)), \\ \boldsymbol{y}(t) &= h(\boldsymbol{x}(t), \boldsymbol{u}(t)), \end{aligned} \tag{5.1}$$

gdje je f funkcija koja opisuje dinamiku sustava, a h funkcija koja definira izlazne veličine $\boldsymbol{y}(t) \in \mathbb{R}^{n_y}$ na temelju varijabli stanja $\boldsymbol{x}(t) \in \mathbb{R}^{n_x}$ i upravljačkih veličina $\boldsymbol{u}(t) \in \mathbb{R}^{n_u}$. U ranije navedenim izrazima n_x, n_u i n_y su redom dimenzije vektora varijabli stanja, upravljačke veličine

i izlaza sustava. U slučaju linearnih sustava zapis postaje jednak sljedećem:

$$\begin{aligned} \frac{\mathrm{d}\boldsymbol{x}(t)}{\mathrm{d}t} &= \boldsymbol{A_c}\boldsymbol{x}(t) + \boldsymbol{B_c}\boldsymbol{u}(t), \\ \boldsymbol{y}(t) &= \boldsymbol{C_c}\boldsymbol{x}(t), \end{aligned} \tag{5.2}$$

gdje su $\boldsymbol{A_c}$, $\boldsymbol{B_c}$ i $\boldsymbol{C_c}$ redom matrica dinamike sustava, ulazna te izlazna matrica u kontinuiranoj vremenskoj domeni. No, sinteza MPC regulatora podrazumijeva diskretni matematički model sustava stoga je potrebno provesti diskretizaciju kontinuiranog modela sustava. Integracijom između vremenskih trenutaka $t = kT_s$ i $t = (k+1)T_s$, gdje je T_s vrijeme uzorkovanja, te uzimanjem u obzir da je upravljačka veličina $\boldsymbol{u}(t)$ konstantna između dva trenutka uzorkovanja i jednaka $\boldsymbol{u}(k)$, slijedi diskretni matematički model u prostoru stanja:

$$\begin{aligned} \boldsymbol{x}(k+1) &= \boldsymbol{A_d}\boldsymbol{x}(k) + \boldsymbol{B_d}\boldsymbol{u}(k), \\ \boldsymbol{y}(k) &= \boldsymbol{C_d}\boldsymbol{x}(k), \end{aligned} \tag{5.3}$$

gdje su $\boldsymbol{A_d}$, $\boldsymbol{B_d}$ i $\boldsymbol{C_d}$ redom matrica dinamike sustava, ulazna te izlazna matrica u diskretnoj vremenskoj domeni. Matrice $\boldsymbol{A_d}$ i $\boldsymbol{B_d}$ mogu se izračunati iz odgovarajućih matrica u kontinuiranoj vremenskoj domeni sljedećim izrazima [122]:

$$\begin{aligned} \boldsymbol{A_d} &= e^{\boldsymbol{A_c}T_s}, \\ \boldsymbol{B_d} &= \int_0^{T_s} e^{\boldsymbol{A_c}(T_s-\tau)}\boldsymbol{B_c}\mathrm{d}\tau. \end{aligned} \tag{5.4}$$

Ako postoji inverz matrice $\boldsymbol{A_c}$, tada vrijedi:

$$\boldsymbol{B_d} = (\boldsymbol{A_c})^{-1}(\boldsymbol{A_d} - \boldsymbol{I})\boldsymbol{B_c}, \tag{5.5}$$

gdje je e matrična eksponencijalna funkcija, a $\boldsymbol{I}$ jedinična matrica odgovarajućih dimenzija. Alternativan pristup diskretizaciji predstavlja unaprijedna Eulerova diskretizacija koja je pogodna u slučaju malog vremena uzorkovanja i kratkog predikcijskog horizonta, jer se izbjegava korištenje eksponencijalne funkcije koja povećava računalnu složenost. Matrice sustava u diskretnoj domeni izvedene putem unaprijedne Eulerove diskretizacije mogu se zapisati sljedećim izrazima [122]:

$$\begin{aligned} \boldsymbol{A_d} &= \boldsymbol{I} + \boldsymbol{A_c}T_s, \\ \boldsymbol{B_d} &= \boldsymbol{B_c}T_s. \end{aligned} \tag{5.6}$$

Upravo navedena vrsta diskretizacije se uobičajeno primjenjuje prilikom diskretizacije matematičkih modela pretvarača i električnih strojeva.

5.2.3. Kriterijska funkcija

Kriterijskom funkcijom se definiraju zahtjevi na upravljačku strukturu. Uobičajeni zahtjevi na sustav upravljanja su penalizacija regulacijskog odstupanja veličine kojom se upravlja kao i penalizacija promjene upravljačke veličine. Općenit oblik kriterijske funkcije dan je sljedećim izrazom:

$$J(\boldsymbol{x}(k),\vec{\boldsymbol{u}}(k)) = F(\boldsymbol{x}(k+N)) + \sum_{j=0}^{N-1} l(\boldsymbol{x}(k+j),\boldsymbol{u}(k+j)), \tag{5.7}$$

gdje je $l(\boldsymbol{x}(k+j),\boldsymbol{u}(k+j))$ kriterijska funkcija u trenutnom koraku, $F(\boldsymbol{x}(k+N))$ kriterijska funkcija u posljednjem koraku, N predikcijski horizont, a $J(\boldsymbol{x}(k),\vec{\boldsymbol{u}}(k))$ ukupna kriterijska funkcija koju čini suma kriterijskih funkcija u trenutnim koracima $l(\boldsymbol{x}(k+j),\boldsymbol{u}(k+j))$ na predikcijskom horizontu (u svim koracima predikcije osim posljednjeg) te kriterijske funkcije u posljednjem koraku $F(\boldsymbol{x}(k+N))$. Kriterijska funkcija u trenutnom i posljednjem koraku može biti proizvoljno definirana ovisno o zahtjevu na sustav upravljanja. Uobičajen zapis navedenih kriterijskih funkcija je:

$$\begin{aligned} l(\boldsymbol{x}(k),\boldsymbol{u}(k)) &= \|\boldsymbol{Q}\boldsymbol{x}(k)\|_p + \|\boldsymbol{R}\Delta\boldsymbol{u}(k)\|_p, \\ F(\boldsymbol{x}(k)) &= \|\boldsymbol{P}\boldsymbol{x}(k)\|_p, \end{aligned} \tag{5.8}$$

gdje je oznakom p definirana norma, matricom $\boldsymbol{Q}$ se penalizira odstupanje varijabli stanja od referentne vrijednosti u svakom koraku uzorkovanja na predikcijskom horizontu osim posljednjeg (kriterijska funkcija u trenutnom koraku), matricom $\boldsymbol{P}$ se penalizira odstupanje varijabli stanja od referentne vrijednosti u posljednjem koraku uzorkovanja, dok matricom $\boldsymbol{R}$ promjena upravljačke veličine. Ovisno o relativnom odnosu vrijednosti elemenata matrica $\boldsymbol{Q}$, $\boldsymbol{P}$ i $\boldsymbol{R}$ može se postići željena brzina odziva uz prihvatljivu brzinu promjene upravljačke veličine. Uz navedene elemente u kriterijsku funkciju mogu se uključiti i dodatni zahtjevi na strukturu upravljanja specifični za konkretnu primjenu. Sljedeći izrazi vrijede za $p = 1,2,\infty$, tj. 1-normu, 2-normu i ∞-normu vektora $\boldsymbol{x} = (x_1, x_2, ..., x_n)$ koji se sastoji od n elemenata:

$$\begin{aligned} \|\boldsymbol{x}\|_1 &= \sum_{i=1}^{n} |\boldsymbol{x}_i|, \\ \|\boldsymbol{x}\|_2 &= \sqrt{\sum_{i=1}^{n} |\boldsymbol{x}_i|^2}, \\ \|\boldsymbol{x}\|_\infty &= \max_{i=1,\ldots,n} |\boldsymbol{x}_i|. \end{aligned} \tag{5.9}$$

U literaturi koja se bavi problematikom MPC algoritama često se koristi 2-norma koja se još naziva i Euklidska norma budući da se u tom slučaju i mali iznosi grešaka značajno penaliziraju.

S druge strane, prednost 1-norme je manja računalna složenost u usporedbi s 2-normom što ju čini pogodnijom za implementaciju u digitalni sustav.

5.2.4. Ograničenja

Čak i u slučaju da se sustav kojim se upravlja može opisati kao linearan sustav u prostoru stanja, kao što je prikazano izrazima (5.2) i (5.3), najčešće postoje ograničenja samog sustava kao i aktuatora koja je potrebno uzeti u obzir prilikom sinteze MPC regulatora što u konačnici čini sustav nelinearnim. Navedena ograničenja definiraju se kao ograničenja varijabli stanja odnosno ograničenja upravljačke veličine. Primjerice, u slučaju MPC algoritma za pretvarače i električne strojeve uz korištenje PWM-a, uz standardnu definiciju struja kao varijabli stanja te napona kao upravljačke veličine, ograničenja varijabli stanja definiraju skup unutar kojeg upravljački algoritam mora zadržati vrijednosti struje (uobičajeno definirano nazivnom strujom pretvarača ili električnog stroja), dok ograničenje upravljačke veličine definira skup unutar kojeg se nalazi dostupni napon (uobičajeno definirano iznosom napona istosmjernog međukruga i korištenim tipom PWM-a).

U općenitom obliku se ograničenja varijabli stanja i upravljačke veličine mogu zapisati sljedećim izrazima [122]:

$$\begin{aligned} \boldsymbol{x}(k) &\in \mathscr{X} \subseteq \mathbb{R}^{n_x}, \\ \boldsymbol{u}(k) &\in \mathscr{U} \subseteq \mathbb{R}^{n_u}, \end{aligned} \tag{5.10}$$

gdje je $\mathscr{X}$ dopušteni skup varijabli stanja $\boldsymbol{x}(k)$ dimenzija n_x, a $\mathscr{U}$ dopušteni skup upravljačke veličine $\boldsymbol{u}(k)$ dimenzija n_u. Ograničenja upravljačke veličine definiraju dopušteni skup koji može biti kontinuiran ili diskretan. U slučaju da se koristi PWM, dopušteni skup upravljačke veličine je kontinuiran te može poprimiti proizvoljnu vrijednost između 0 i 1 (navedeni skup se može smatrati faktorom vođenja određene sklopke):

$$\mathscr{U} = [0,1]^{n_u}. \tag{5.11}$$

S druge strane, kod algoritama koji ne koriste PWM već uzimaju u obzir diskretnu prirodu pretvarača, dopušteni skup upravljačke veličine je diskretan te može poprimiti vrijednost 0 ili 1 (određena sklopka vodi ili ne vodi tijekom perioda uzorkovanja):

$$\mathscr{U} = \{0,1\}^{n_u}. \tag{5.12}$$

Ograničenja opisana izrazima (5.11) i (5.12) su posljedica same strukture odnosno topologije pretvarača te predstavljaju stroga ograničenja (engl. *hard constraints*). S druge strane, postoje i ograničenja koja su dio kriterijske funkcije s velikim faktorom penalizacije (engl. *soft*

constraints). Navedeni tip ograničenja uobičajeno se koristi kao osiguranje da struja ne prelazi maksimalnu dopuštenu vrijednost. Pritom se maksimalna dopuštena vrijednost struje u algoritmu uobičajeno postavlja na nešto manji iznos od vrijednosti prorade prekostrujne zaštite, uz veliku penalizaciju kršenja tog ograničenja. Ovakvim tipom ograničenja se izbjegavaju i numerički problemi u slučaju da u nekom koraku uzorkovanja ne postoji upravljačka veličina koja zadovoljava sva ograničenja sustava [122].

5.2.5. Optimizacijski problem

Rješenje optimizacijskog problema je vektor upravljačkih veličina koji osigurava minimum kriterijske funkcije na predikcijskom horizontu uz predikciju budućih varijabli stanja korištenjem diskretnog matematičkog modela sustava uzimajući u obzir ograničenja varijabli stanja i upravljačke veličine. Standardna formulacija optimizacijskog problema dana je sljedećim izrazom:

$$\begin{aligned} \min_{\vec{\boldsymbol{u}}(k)} J(\boldsymbol{x}(k),\vec{\boldsymbol{u}}(k)) = \min_{\vec{\boldsymbol{u}}(k)} \left(F(\boldsymbol{x}(k+N)) + \sum_{j=0}^{N-1} l(\boldsymbol{x}(k+j),\boldsymbol{u}(k+j)) \right) \\ \text{tako da}: \boldsymbol{x}(k+j+1) = f(\boldsymbol{x}(k+j),\boldsymbol{u}(k+j)), \\ \boldsymbol{x}(k+j) \in \mathscr{X}, j = 0,\ldots,N-1, \\ \boldsymbol{x}(k+N) \in \mathscr{X}_N, j = N, \\ \boldsymbol{u}(k+j) \in \mathscr{U}, j = 0,\ldots,N-1. \end{aligned} \tag{5.13}$$

Vektor optimalnih upravljačkih veličina na predikcijskom horizontu jednak je:

$$\vec{\boldsymbol{u}}^*(k) = \left[\boldsymbol{u}^*(k)\, \boldsymbol{u}^*(k+1)\, \ldots,\, \boldsymbol{u}^*(k+N-1)\right]. \tag{5.14}$$

Premda je u svakom koraku izračunat vektor upravljačkih veličina na cijelom predikcijskom horizontu, primjenjuje se samo optimalna upravljačka veličina u trenutnom periodu uzorkovanja $\boldsymbol{u}^*(k)$, te se cijeli postupak ponavlja u narednom periodu uzorkovanja (upravljanje s pomičnim horizontom).

5.2.6. Prednosti i izazovi modelskog prediktivnog upravljanja

Prednosti modelskog prediktivnog upravljanja su:

- sistematično uzimanje u obzir ograničenja varijabli stanja i upravljačkih veličina,
- upravljanje sustavima s više ulaza/izlaza,
- ostvarivanje visokih performansi upravljanja.

Uzimanjem u obzir ograničenja varijabli stanja i upravljačkih veličina prilikom sinteze MPC regulatora postižu se bolje performanse upravljanja u usporedbi s klasičnim upravljačkim struk-

turama temeljenim na PID regulatorima. Time je omogućen rad blizu ili čak na samim ograničenjima sustava. Također je moguće rješavanjem jednog optimizacijskog problema istodobno upravljati s više varijabli stanja istog sustava. Odgovarajućim definiranjem kriterijske funkcije moguće je ostvariti bolje performanse upravljanja u usporedbi sa standardnim upravljačkim strukturama.

Izazovi modelskog prediktivnog upravljanja su:

- implementacija,
- stabilnost,
- robusnost,
- dopustivost.

Većina MPC algoritama podrazumijeva rješavanje optimizacijskog problema u realnom vremenu, tj. unutar perioda uzorkovanja sustava digitalnog sustava što može predstavljati izazov u slučaju složenijih optimizacijskih problema. Stabilnost sustava upravljanja temeljenim na MPC regulatoru također nije inherentno zajamčena. Jedan od izazova predstavlja i robusnost sustava na nesigurnosti modela i poremećaje. Također je potrebno razmatrati i problem dopustivosti MPC algoritma, tj. postoji mogućnost da u određenom periodu uzorkovanja nije moguće pronaći upravljačku veličinu koja zadovoljava ograničenja varijabli stanja i upravljačke veličine.

5.3. Modelsko prediktivno izravno upravljanje strujama (MP-DCC) s dva režima rada

U strukturi upravljanja momentom sinkronog vjetrogeneratora sa stalnim magnetima razvijeni algoritam modelskog prediktivnog izravnog upravljanja strujama (MP-DCC) zamjenjuje standardnu strukturu upravljanja temeljenu na PI regulatorima struja u sinkronom dq koordinatnom sustavu. Motivacija za razvoj MP-DCC algoritma je ostvarivanje kompromisa između praćenja referentne vrijednosti struje i minimizacije sklopnih gubitaka generatorskog pretvarača. Razvijeni algoritam pripada grupi FCS-MPC algoritama budući da se izravno upravlja sklopkama generatorskog pretvarača te se sastoji od dva režima rada: prijelazne pojave i stacionarnog stanja. Na slici 5.2 je prikazana predložena struktura upravljanja temeljena na razvijenom MP-DCC algoritmu.

Na temelju referentne vrijednosti elektromagnetskog momenta M^* proračunavaju se referentne vrijednosti struje $\boldsymbol{i}^*_{dq}$ na temelju MTPA algoritma. U svakom periodu uzorkovanja mjeri se trofazna struja $\boldsymbol{i}_{abc}$ te se primjenom Parkove transformacije dobiva struja $\boldsymbol{i}_{dq}$ u sinkronom dq koordinatnom sustavu. Također, u svakom periodu uzorkovanja mjere se i mehanička brzina ω_r te kut rotora θ_r koji se potom pretvaraju u električne vrijednosti ω_{re} i θ_{re} te prosljeđuju MP-DCC algoritmu. Osim navedenih veličina MP-DCC algoritmu se prosljeđuje i mjerena vrijednost napona istosmjernog međukruga U_{dc} da bi se proračunale ispravne vrijednosti vektora napona generatorskog pretvarača. Za svaki od osam vektora napona (šest aktivnih i dva nul-vektora), tj. sklopnih stanja generatorskog pretvarača, proračunava se predikcija varijabli stanja za određen broj budućih perioda uzorkovanja koji odgovara duljini predikcijskog horizonta. Vektori napona koji krše ograničenja se automatski odbacuju iz daljnjeg razmatranja

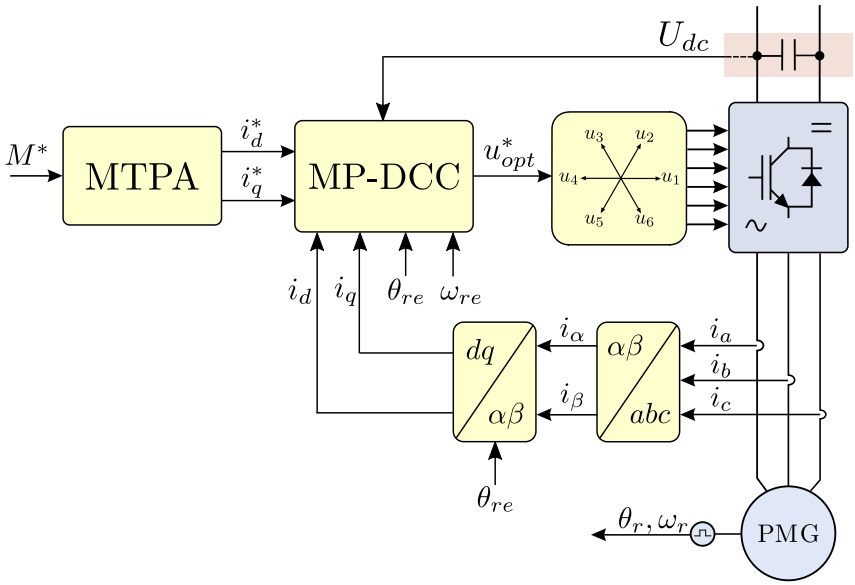

Slika 5.2: Struktura upravljanja temeljena na razvijenom MP-DCC algoritmu

dok se preostali vektori napona uspoređuju prema kriterijskoj funkciji. Vektor napona odnosno sklopno stanje koje osigurava minimalni iznos kriterijske funkcije se smatra optimalnim te se primjenjuje u idućem periodu uzrokovanja na generatorski pretvarač. Navedeni postupak se ponavlja u narednom periodu uzrokovanja. Predikcija budućih varijabli stanja sustava se temelji na diskretnom matematičkom modelu sinkronog stroja sa stalnim magnetima i generatorskog pretvarača.

5.3.1. Diskretni matematički model sinkronog stroja sa stalnim magnetima i generatorskog pretvarača

Da bi se razvio predikcijski model potreban za modelsko prediktivno upravljanje potrebno je zapisati matematički model sinkronog stroja sa stalnim magnetima u matričnom obliku. Matematički model u sinkronom dq koordinatnom sustavu zapisan u kontinuiranoj vremenskoj domeni zapisan jednak je:

$$\begin{aligned}\frac{\mathrm{d}i_d(t)}{\mathrm{d}t} &= -\frac{R_s}{L_d}i_d(t) + \frac{L_q}{L_d}\omega_{re}(t)i_q(t) + \frac{1}{L_d}u_d(t),\\ \frac{\mathrm{d}i_q(t)}{\mathrm{d}t} &= -\frac{R_s}{L_q}i_q(t) - \left(\frac{L_d}{L_q}i_d(t) + \frac{\psi_{md}}{L_q}\right)\omega_{re}(t) + \frac{1}{L_q}u_q(t).\end{aligned} \tag{5.15}$$

Ako se kao vektor varijabli stanja $\boldsymbol{x}(t)$ odabere vektor struje $\boldsymbol{i}_{dq}(t)$, kao vektor upravljačke veličine $\boldsymbol{u}(t)$ vektor napona $\boldsymbol{u}_{dq}(t)$, a električna brzina rotora $\omega_{re}(t)$ se smatra mjerenom poremećajnom veličinom, matematički model sinkronog stroja sa stalnim magnetima se može u općenitom obliku zapisati sljedećim izrazima:

$$\begin{aligned}\frac{\mathrm{d}\boldsymbol{x}(t)}{\mathrm{d}t} &= f(\boldsymbol{x}(t), \boldsymbol{u}(t), \omega_{re}(t)),\\ &= \boldsymbol{A_c}(t)\boldsymbol{x}(t) + \boldsymbol{B_c}\boldsymbol{u}(t) + \boldsymbol{G_c}\omega_{re}(t).\end{aligned} \tag{5.16}$$

Matrice sustava u kontinuiranoj domeni $\boldsymbol{A_c}(t)$, $\boldsymbol{B_c}$ i $\boldsymbol{G_c}$ su jednake:

$$\boldsymbol{A_c}(t) = \begin{bmatrix} -\frac{R_s}{L_d} & \omega_{re}(t)\frac{L_q}{L_d} \\ -\omega_{re}(t)\frac{L_d}{L_q} & -\frac{R_s}{L_q} \end{bmatrix}, \boldsymbol{B_c} = \begin{bmatrix} \frac{1}{L_d} & 0 \\ 0 & \frac{1}{L_q} \end{bmatrix}, \boldsymbol{G_c} = \begin{bmatrix} 0 \\ -\frac{\psi_{md}}{L_q} \end{bmatrix}. \tag{5.17}$$

Budući da je u matrici $\boldsymbol{A_c}(t)$ sadržana električna brzina rotora koja je funkcija vremena, radi se o vremenski promjenjivom sustavu čime sinteza MPC regulatora postaje značajno kompleksnija. No, u slučaju vjetrogeneratora mehanička vremenska konstanta je zbog velikog momenta tromosti vjetroturbine znatno veća od električne vremenske konstante te se električna brzina rotora može smatrati konstantnom tijekom perioda uzorkovanja. U tom slučaju vremenski ovisna električna brzina rotora $\omega_{re}(t)$ se može zamijeniti s konstantnom vrijednosti ω_{re0} koja odgovara određenoj brzini rotora vjetrogeneratora ili s vrijednosti ω_{re} koja se mjeri u svakom periodu

uzorkovanja te smatra nepromjenjivom do idućeg perioda uzrokovanja. Time matrica $\boldsymbol{A_c}$ više nije vremenski ovisna jer se električna brzina rotora može smatrati jednim od parametara generatora:

$$\boldsymbol{A_c} = \begin{bmatrix} -\frac{R_s}{L_d} & \omega_{re}\frac{L_q}{L_d} \\ -\omega_{re}\frac{L_d}{L_q} & -\frac{R_s}{L_q} \end{bmatrix}. \tag{5.18}$$

Budući da je za sintezu MPC regulatora potreban matematički model sustava u diskretnoj vremenskoj domeni, provedena je unaprijedna Eulerova diskretizacija nad kontinuiranim modelom sustava. Diskretni matematički model sustava može se općenito prikazati sljedećim izrazom:

$$\begin{aligned} \boldsymbol{x}(k+1) &= f(\boldsymbol{x}(k), \boldsymbol{u}(k), \theta_{re}(k), \omega_{re}), \\ &= \boldsymbol{A_d}\boldsymbol{x}(k) + \boldsymbol{B_d}(\theta_{re}(k))\boldsymbol{u}(k) + \boldsymbol{G_d}\omega_{re}. \end{aligned} \tag{5.19}$$

Pritom je diskretna matrica $\boldsymbol{B_d}(\theta_{re}(k))$ raspisana kao funkcija kuta rotora $\theta_{re}(k)$, jer je napon definiran u mirujućem $\alpha\beta$ koordinatnom sustavu. Matrice sustava u diskretnoj domeni $\boldsymbol{A_d}$, $\boldsymbol{B_d}$ i $\boldsymbol{G_d}$ s vremenom uzorkovanja T_s jednake su:

$$\boldsymbol{A_d} = \begin{bmatrix} 1-\frac{R_s T_s}{L_d} & \omega_{re}\frac{L_q T_s}{L_d} \\ -\omega_{re}\frac{L_d T_s}{L_q} & 1-\frac{R_s T_s}{L_q} \end{bmatrix}, \boldsymbol{B_d}(\theta_{re}(k)) = \begin{bmatrix} \frac{T_s}{L_d}\cos(\theta_{re}(k)) & \frac{T_s}{L_d}\sin(\theta_{re}(k)) \\ -\frac{T_s}{L_q}\sin(\theta_{re}(k)) & \frac{T_s}{L_q}\cos(\theta_{re}(k)) \end{bmatrix}, \tag{5.20}$$

$$\boldsymbol{G_d} = \begin{bmatrix} 0 \\ -\frac{\psi_{md} T_s}{L_q} \end{bmatrix}. \tag{5.21}$$

Na slici 5.3 prikazana je struktura dvorazinskog generatorskog pretvarača te pripadnih osam (šest aktivnih i dva nul-vektora) vektora napona. U tablici 5.1 prikazane su vrijednosti komponenata vektora napona u mirujućem $\alpha\beta$ koordinatnom sustavu. Navedeni vektori napona pred-

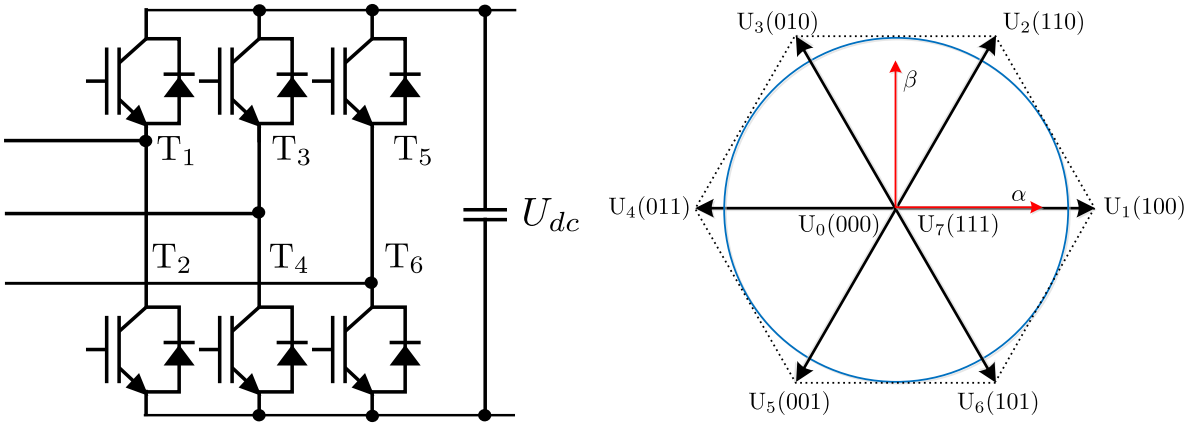

(a) Generatorski pretvarač

(b) Vektori napona

Slika 5.3: Topologija generatorskog pretvarača i vektori napona

Tablica 5.1: Vektori napona dvorazinskog generatorskog pretvarača u mirujućem $\alpha\beta$ koordinatnom sustavu

Vektor napona	u_α	u_β
U_0 (000)	0	0
U_1 (100)	$\frac{2}{3}U_{dc}$	0
U_2 (110)	$\frac{1}{3}U_{dc}$	$\frac{1}{\sqrt{3}}U_{dc}$
U_3 (010)	$-\frac{1}{3}U_{dc}$	$\frac{1}{\sqrt{3}}U_{dc}$
U_4 (011)	$-\frac{2}{3}U_{dc}$	0
U_5 (001)	$-\frac{1}{3}U_{dc}$	$-\frac{1}{\sqrt{3}}U_{dc}$
U_6 (101)	$\frac{1}{3}U_{dc}$	$-\frac{1}{\sqrt{3}}U_{dc}$
U_7 (111)	0	0

stavljaju skup upravljačkih akcija razvijenog MP-DCC algoritma te je iz tog razloga matrica $\boldsymbol{B_d}(\theta_{re}(k))$ zapisana u $\alpha\beta$ koordinatnom sustavu.

Električni kut rotora smatra se nepromjenjivim tijekom perioda uzorkovanja. Promjena električnog kuta rotora između dva perioda uzorkovanja može se prikazati sljedećim izrazom:

$$\theta_{re}(k+1) = \theta_{re}(k) + \omega_{re}T_s. \tag{5.22}$$

Uz zanemarenje magnetskog zasićenja, magnetski tok se u sinkronom dq koordinatnom sustavu može prikazati sljedećim izrazom:

$$\boldsymbol{\psi}_{dq}(k) = \boldsymbol{L}\boldsymbol{i}_{dq}(k) + \boldsymbol{\Psi}, \tag{5.23}$$

gdje su $\boldsymbol{\psi}_{dq}(k)$ vektor magnetskog toka, $\boldsymbol{L}$ dijagonalna matrica induktiviteta, a $\boldsymbol{\Psi}$ vektor koji sadržava magnetski tok stalnih magneta jednaki:

$$\boldsymbol{\psi}_{dq}(k) = \begin{bmatrix} \psi_d(k) \\ \psi_q(k) \end{bmatrix}, \boldsymbol{L} = \begin{bmatrix} L_d & 0 \\ 0 & L_q \end{bmatrix}, \boldsymbol{\Psi} = \begin{bmatrix} 0 \\ \psi_{md} \end{bmatrix}. \tag{5.24}$$

Budući da nisu uvedena stroga ograničenja na varijable stanja sustava, tj. struje $\boldsymbol{i}_{dq}(t)$, uvodi se ograničenje referentne vrijednosti struje $\boldsymbol{i}^*_{dq}(t)$. Apsolutan iznos referentne vrijednosti struje treba zadovoljavati ograničenje definirano maksimalnom dozvoljenom strujom generatorskog pretvarača i generatora I_{max}:

$$\left\| i^*_d(k)\, i^*_q(k) \right\|_2 \leq I_{max}. \tag{5.25}$$

Diskretni matematički model s uključenim mrtvim vremenom generatorskog pretvarača

S ciljem izbjegavanja kratkog spoja istosmjernog međukruga u trenutku promjene sklopnog stanja, dodaje se mrtvo vrijeme (engl. *dead time*) u upravljački program (engl. *driver*) IGBT-a kao i u algoritam modulacije širine impulsa [123, 124]. Mrtvo vrijeme pretvarača definira period između isklapanja gornjeg IGBT-a i uklapanja donjeg IGBT-a u jednoj fazi te obrnuto. Premda mrtvo vrijeme osigurava siguran rad pretvarača, dolazi do izobličenja izlaznog napona. Tijekom mrtvog vremena dolazi do gubitka upravljivosti nad izlaznim naponom pretvarača koji odstupa od referentne vrijednosti. Ako se koristi neka od inačica PWM-a, postoje različiti algoritmi kompenzacije mrtvog vremena [125–127]. S druge strane, u slučaju FCS-MPC algoritama kojima je svojstveno izravno upravljanje sklopkama, potrebno je mrtvo vrijeme pretvarača uključiti u matematički model koji se koristi za predikciju budućih varijabli stanja sustava.

Kao što je prikazano na slici 5.4, struja pozitivnog predznaka prolazi kroz tranzistor T1 ili kroz povratnu diodu D2, dok struja negativnog predznaka prolazi kroz tranzistor T2 ili kroz povratnu diodu D1. Efekt koji uzrokuje mrtvo vrijeme prikazan je na slici 5.5. Ako pozitivna struja prolazi kroz diodu D2 te dođe do uklapanja tranzistora T1, struja nastavi prolaziti kroz diodu tijekom mrtvog vremena te izlazni napon postaje ispravan tek po završetku mrtvog vremena. Međutim, ako pozitivna struja prolazi kroz tranzistor T1 te dođe do uklapanja tranzistora T2, struja trenutno počne prolaziti kroz diodu D2 te je izlazni napon ispravan. S druge strane, ako negativna struja prolazi kroz diodu D1 te dođe do uklapanja tranzistora T2, struja nastavi prolaziti kroz diodu tijekom mrtvog vremena te izlazni napon postaje ispravan tek po završetku mrtvog vremena. Međutim, ako negativna struja prolazi kroz tranzistor T2 te dođe do uklapanja

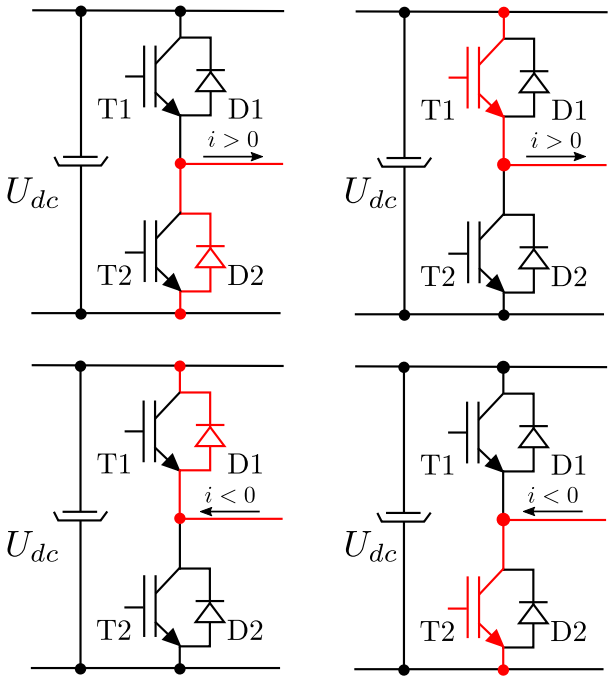

Slika 5.4: Smjer struje u jednoj fazi pretvarača

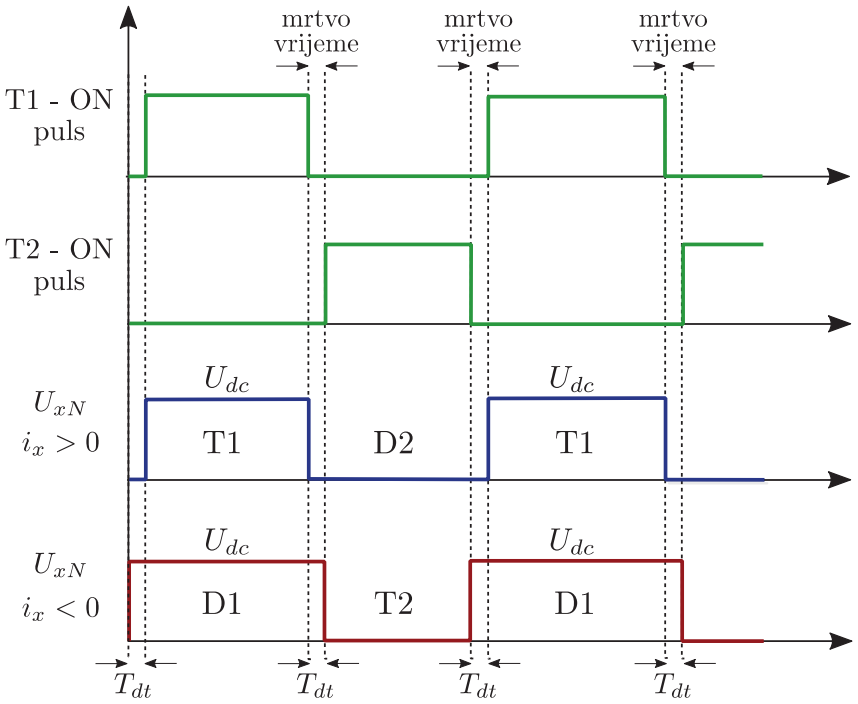

Slika 5.5: Mrtvo vrijeme pretvarača

tranzistora T1, struja trenutno počne prolaziti kroz diodu D1 te je izlazni napon ispravan.

Navedeno objašnjenje vrijedi za promjenu sklopnog stanja u jednoj fazi pretvarača. No, u slučaju razvijenog MP-DCC algoritma može doći do promjene sklopnog stanja u jednoj ($[000] \rightarrow [100]$), dvije ($[000] \rightarrow [110]$) ili tri ($[000] \rightarrow [111]$) faze pretvarača. U ranije navedenim primjerima promjene sklopnih stanja, oznake 1 (aktivno) i 0 (neaktivno) predstavljaju stanje gornje sklopke (IGBT i povratna dioda) u svakoj fazi pretvarača. Za svaku fazu pretvarača u kojoj dolazi do promjene sklopnog stanja, aktivno sklopno stanje tijekom mrtvog vremena je određeno predznakom struje u toj fazi prema sljedećem izrazu:

$$S_x^+ = \begin{cases} 1, \text{ako vrijedi } i_x < 0, \\ 0, \text{ako vrijedi } i_x > 0, \end{cases} \quad S_x^- = \begin{cases} 0, \text{ako vrijedi } i_x < 0, \\ 1, \text{ako vrijedi } i_x > 0, \end{cases} \tag{5.26}$$

gdje $x = a,b,c$ označava fazu pretvarača, S_x^+ je sklopno stanje gornje sklopke, a S_x^- sklopno stanje donje sklopke u pojedinoj fazi, dok je i_x fazna struja. Primjerice, ako dolazi do promjene sklopnog stanja u samo jednoj fazi (npr. $[000] \rightarrow [100]$), uz negativnu vrijednost struje u toj fazi ($i_a < 0$), prema (5.26) aktivno sklopno stanje tijekom mrtvog vremena je $[100]$ što prema tablici 5.1 odgovara vektoru napona U_1.

Da bi se mrtvo vrijeme generatorskog pretvarača uzelo u obzir prilikom predikcije varijabli stanja, potrebno je vrijeme uzorkovanja T_s podijeliti na dva dijela: mrtvo vrijeme T_{dt} i preostali dio vremena uzorkovanja $T_s - T_{dt}$. Tijekom mrtvog vremena, $kT_s \leq t < kT_s + T_{dt}$, $\forall k \in \mathbb{Z}_+$,

dinamika sustava se može prikazati sljedećim izrazom:

$$\boldsymbol{x}_{dt}(kT_s + T_{dt}) = \boldsymbol{A}_{dt}\boldsymbol{x}(kT_s) + \boldsymbol{B}_{dt}(\theta_{re}(kT_s))\boldsymbol{u}_{dt}(kT_s) + \boldsymbol{G}_{dt}\omega_{re}, \tag{5.27}$$

gdje je $\boldsymbol{x}_{dt}(kT_s + T_{dt})$ vektor varijabli stanja na kraju mrtvog vremena, $\boldsymbol{u}_{dt}(kT_s)$ vektor napona aktivan tijekom mrtvog vremena (može se definirati prema izrazu (5.26)), dok su $\boldsymbol{A}_{dt}$ i $\boldsymbol{B}_{dt}$ diskretne matrice sustava s vremenom uzorkovanja jednakim mrtvom vremenu T_{dt}. Navedenim izrazom moguće je odrediti iznos varijabli stanja na kraju mrtvog vremena. U preostalom vremenu uzorkovanja $kT_s + T_{dt} \leq t < (k+1)T_s$ dinamika sustava se može prikazati sljedećim izrazom:

$$\boldsymbol{x}(kT_s + T_s) = \boldsymbol{A}_{sys}\boldsymbol{x}_{dt}(kT_s + T_{dt}) + \boldsymbol{B}_{sys}(\theta_{re}(kT_s) + \omega_{re}T_{dt})\boldsymbol{u}_{sys}(kT_s) + \boldsymbol{G}_{sys}\omega_{re}, \tag{5.28}$$

gdje je $\boldsymbol{x}(kT_s + T_s)$ vektor varijabli stanja na kraju perioda uzorkovanja, $\boldsymbol{u}_{sys}(kT_s)$ vektor napona aktivan u preostalom dijelu perioda uzorkovanja (optimalni vektor napona prema MP-DCC algoritmu), dok su $\boldsymbol{A}_{sys}$ i $\boldsymbol{B}_{sys}$ diskretne matrice sustava s vremenom uzorkovanja $T_s - T_{dt}$. Navedenim izrazom moguće je odrediti iznos varijabli stanja na kraju perioda uzorkovanja. Uzimajući u obzir mrtvo vrijeme, matrice sustava u diskretnoj domeni mogu se općenito zapisati sljedećim izrazima:

$$\boldsymbol{A_l} = \begin{bmatrix} 1 - \frac{R_s T_l}{L_d} & \omega_{re}\frac{L_q T_l}{L_d} \\ -\omega_{re}\frac{L_d T_l}{L_q} & 1 - \frac{R_s T_l}{L_q} \end{bmatrix}, \boldsymbol{B_l}(\theta_{re}(\cdot)) = \begin{bmatrix} \frac{T_l}{L_d}\cos(\theta_{re}(\cdot)) & \frac{T_l}{L_d}\sin(\theta_{re}(\cdot)) \\ -\frac{T_l}{L_q}\sin(\theta_{re}(\cdot)) & \frac{T_l}{L_q}\cos(\theta_{re}(\cdot)) \end{bmatrix}, \tag{5.29}$$

$$\boldsymbol{G_l} = \begin{bmatrix} 0 \\ -\frac{\psi_m T_l}{L_q} \end{bmatrix}. \tag{5.30}$$

Simbol l označava koji je diskretni matematički model korišten (dt za mrtvo vrijeme, tj. $kT_s \leq t < kT_s + T_{dt}$ i sys za preostali dio vremena uzorkovanja, tj. $kT_s + T_{dt} \leq t < (k+1)T_s$), dok je T_l vrijeme diskretizacije koje je jednako T_{dt} ili $T_s - T_{dt}$, ovisno o diskretnom matematičkom modelu. Kombinacijom oba diskretna modela te izbacivanjem oznake T_s radi jednostavnosti zapisa slijedi diskretni matematički model sinkronog stroja sa stalnim magnetima s uključenim mrtvim vremenom T_{dt} generatorskog pretvarača:

$$\begin{aligned} \boldsymbol{x}(k+1) = {} & \boldsymbol{A}_{sys}\boldsymbol{A}_{dt}\boldsymbol{x}(k) + \boldsymbol{A}_{sys}\boldsymbol{B}_{dt}(\theta_{re}(k))\boldsymbol{u}_{dt}(k) + \\ & + \boldsymbol{B}_{sys}(\theta_{re}(k) + \omega_{re}T_{dt})\boldsymbol{u}_{sys}(k) + (\boldsymbol{A}_{sys}\boldsymbol{G}_{dt} + \boldsymbol{G}_{sys})\omega_{re}. \end{aligned} \tag{5.31}$$

5.3.2. Metodologija razvijenog MP-DCC algoritma upravljanja

Kao što je navedeno ranije u tekstu, glavna motivacija za razvoj MP-DCC algoritma je smanjenje sklopnih gubitaka generatorskog pretvarača, uz prihvatljivo harmoničko izobličenje struje te prihvatljive oscilacije momenta. Razvijeni MP-DCC algoritam se sastoji od dva režima rada: prijelazne pojave tijekom koje se varijable stanja, tj. struje usmjeravaju u upravljački invarijantni skup (engl. *control invariant set*, CIS) i stacionarnog stanja koje nastupa kada se struja nalazi unutar upravljačkog invarijantnog skupa. Upravljački invarijantni skup jest onaj unutar kojeg uvijek postoji upravljačka veličina (u slučaju razvijenog algoritma radi se o jednom od osam vektora napona odnosno sklopnih stanja) koja zadržava varijable stanja sustava unutar navedenog skupa. Upravljački invarijantni skup sadrži ravnotežnu točku koja je definirana s referentnom vrijednosti struje te kada se jednom struje nađu unutar navedenog skupa postaje aktivan drugi režim rada, tj. stacionarno stanje.

Stabilnost i uzastopna dopustivost algoritma osigurana je dodatnim ograničenjem koje je definirano fleksibilnom upravljačkom Ljapunovljevom funkcijom. Time se osigurava da se vektori napona koji vode k nestabilnom radu izuzmu iz daljnjeg razmatranja. U slučaju dvorazinskog generatorskog pretvarača postoji osam dopuštenih vektora napona (šest aktivnih i dva nul-vektora) odnosno sklopnih stanja te zbog diskretnih svojstava samog pretvarača nije moguće postići savršeno praćenje referentne vrijednosti. Posljedica navedene pojave je značajno harmoničko izobličenje struje, osobito u slučaju većeg vremena uzorkovanja, što rezultira i konstantnim oscilacijama elektromagnetskog momenta. Povećanjem sklopne frekvencije generatorskog pretvarača smanjuje se harmoničko izobličenje struje, no ujedno se povećavaju i sklopni gubici pretvarača. Također vrijedi i obrnut slučaj, tj. smanjenje sklopne frekvencije uzrokuje povećanje harmoničkog izobličenja struje.

U stacionarnom stanju je struja ograničena unutar skupa $\mathscr{B}$ koji sadrži njezinu referentnu vrijednost. Da bi se razlikovala dva režima rada uvodi se varijabla m kako slijedi:

$$m = \begin{cases} 0, \boldsymbol{x} \notin \mathscr{B}, \\ 1, \boldsymbol{x} \in \mathscr{B}, \end{cases} \tag{5.32}$$

gdje je prijelazna pojava definirana s $m = 0$, a stacionarno stanje s $m = 1$. Općenita kriterijska funkcija koja uzima u obzir režim rada putem varijable m definirana je sljedećim izrazom:

$$J(\boldsymbol{x}(k), \vec{\boldsymbol{u}}(k), m) = F(\boldsymbol{x}(k+N), m) + \sum_{j=0}^{N-1} l(\boldsymbol{x}(k+j), \boldsymbol{u}(k+j), m), \tag{5.33}$$

gdje je $\boldsymbol{x}(k+j)$ vektor varijabli stanja (struja u sinkronom dq koordinatnom sustavu), $\boldsymbol{u}(k+j)$ vektor upravljačke veličine (vektori napona generatorskog pretvarača), $\vec{\boldsymbol{u}}(k)$ vektor upravljačke veličine na predikcijskom horizontu, N predikcijski horizont, $l(\boldsymbol{x}(k+j), \boldsymbol{u}(k+j))$ kri-

terijska funkcija u trenutnom koraku, $F(\boldsymbol{x}(k+N))$ kriterijska funkcija u posljednjem koraku, $J(\boldsymbol{x}(k),\vec{\boldsymbol{u}}(k))$ ukupna kriterijska funkcija, a m varijabla kojom se definira koji režim rada je aktivan. Da bi se postigao kompromis između praćenja referentne vrijednosti struje i smanjenja sklopnih gubitaka generatorskog pretvarača odabrana je kvadratna kriterijska funkcija (2-norma, tj. Euklidska norma). Zbog jednostavnosti zapisa, oznaka 2 u indeksu norme je izostavljena u izrazima koji slijede te se podrazumijeva da se radi o Euklidskoj normi. Odabirom Euklidske norme kriterijska funkcija u trenutnom koraku $l(\boldsymbol{x}(k+j),\boldsymbol{u}(k+j))$ i kriterijska funkcija u posljednjem koraku $F(\boldsymbol{x}(k+N))$ postaju jednake:

$$\begin{aligned} l(\boldsymbol{x}(k),\boldsymbol{u}(k),m) &= \begin{cases} \|\boldsymbol{x}(k)\|^2_{Q_0} + \|\Delta\boldsymbol{u}(k)\|^2_{R_0}, \text{ ako je } m=0, \\ \|\boldsymbol{x}(k)\|^2_{Q_1} + \|\Delta\boldsymbol{u}(k)\|^2_{R_1}, \text{ ako je } m=1, \end{cases} \\ F(\boldsymbol{x}(k),\boldsymbol{u}(k),m) &= \begin{cases} \|\boldsymbol{x}(k)\|^2_{P_0}, \text{ ako je } m=0, \\ \|\boldsymbol{x}(k)\|^2_{P_1}, \text{ ako je } m=1, \end{cases} \end{aligned} \tag{5.34}$$

gdje $\|z\|_X = \sqrt{z^T X z}$ označava težinsku Euklidsku normu s matricom X. Matrice Q_0, R_0, P_0, Q_1, R_1 i P_1 su definirane sljedećim izrazima: $Q_0 = q_0 I$, $R_0 = r_0 I$, $P_0 = p_0 I$, $Q_1 = q_1 I$, $R_1 = r_1 I$, $P_1 = p_1 I$, gdje je I jedinična matrica (2×2). Uz navedeni izbor kriterijske funkcije, parametri za penalizaciju regulacijskog odstupanja struje i promjene sklopnog stanja u prijelaznoj pojavi i u stacionarnom stanju su: q_0, p_0, r_0, q_1, p_1 i r_1. Optimalni upravljački problem može se zapisati sljedećim izrazom:

$$\begin{aligned} \min_{\vec{\boldsymbol{u}}(k)} J(\boldsymbol{x}(k),\vec{\boldsymbol{u}}(k),m) = \min_{\vec{\boldsymbol{u}}(k)} &\left(F(\boldsymbol{x}(k+N),m) + \sum_{j=0}^{N-1} l(\boldsymbol{x}(k+j),\boldsymbol{u}(k+j),m) \right), \\ \text{tako da : } &\boldsymbol{x}(k+j+1) = f(\boldsymbol{x}(k+j),\boldsymbol{u}(k+j),\theta_{re}(k+j),\omega_{re}(k)), \\ &\boldsymbol{x}(k+j) \in \mathscr{X}, j=0,\ldots,N-1, \\ &\boldsymbol{x}(k+N) \in \mathscr{X}_N, j=N, \\ &\boldsymbol{u}(k+j) \in \mathscr{U}, j=0,\ldots,N-1, \\ &V(\boldsymbol{x}(k+j+1)) \le (1-m)\cdot\big(V(\boldsymbol{x}(k+j)) + \lambda(k+j) - b(k)\big) + m\cdot\gamma. \end{aligned} \tag{5.35}$$

gdje je $\vec{\boldsymbol{u}}(k) = [\boldsymbol{u}^*(k)\,\boldsymbol{u}^*(k+1)\,\ldots,\,\boldsymbol{u}^*(k+N-1)]$ vektor optimalnih upravljačkih veličina (vektori napona) na predikcijskom horizontu, funkcija $f(\boldsymbol{x}(k+j),\boldsymbol{u}(k+j),\theta_{re}(k+j),\omega_{re}(k))$ definira dinamiku sustava prema izrazu (5.19) ili izrazu (5.31) ako se u obzir uzima i mrtvo vrijeme, $\mathscr{X}$ i $\mathscr{X}_N$ su dopušteni skupovi varijabli stanja, tj. struje (budući da se radi pojednostavljenja algoritma ograničava referentna vrijednost struje, a ne varijabla stanja, navedeni skupovi nisu ograničeni, tj. vrijedi $\mathscr{X} = \mathscr{X}_N = \mathbb{R}^2$), dok je $\mathscr{U}$ upravljački skup s konačnim brojem

upravljačkih akcija (strogo ograničenje definirano topologijom generatorskog pretvarača) koji je definiran vektorima napona prema slici 5.3b:

$$\mathscr{U} = U_{dc}\left\{ \underbrace{\begin{bmatrix}0\\0\end{bmatrix}}_{u_0}, \underbrace{\begin{bmatrix}\frac{2}{3}\\0\end{bmatrix}}_{u_1}, \underbrace{\begin{bmatrix}\frac{1}{3}\\\frac{\sqrt{3}}{3}\end{bmatrix}}_{u_2}, \underbrace{\begin{bmatrix}-\frac{1}{3}\\\frac{\sqrt{3}}{3}\end{bmatrix}}_{u_3}, \underbrace{\begin{bmatrix}-\frac{2}{3}\\0\end{bmatrix}}_{u_4}, \underbrace{\begin{bmatrix}-\frac{1}{3}\\-\frac{\sqrt{3}}{3}\end{bmatrix}}_{u_5}, \underbrace{\begin{bmatrix}\frac{1}{3}\\-\frac{\sqrt{3}}{3}\end{bmatrix}}_{u_6}, \underbrace{\begin{bmatrix}0\\0\end{bmatrix}}_{u_7} \right\}. \tag{5.36}$$

Posljednje ograničenje optimizacijskog problema definiranog izrazom (5.35) uvjetovano je fleksibilnom upravljačkom Ljapunovljevom funkcijom kojom se garantira stabilnost i uzastopna dopustivost algoritma. Uvedeno ograničenje osigurava dostizanje okoline referentne vrijednosti $\mathscr{B}$ u konačnom vremenskom intervalu. U slučaju zanemarenja utjecaja mrtvog vremena generatorskog pretvarača, u radu [119] pokazano je da za $\boldsymbol{x} \in \mathscr{X} \setminus \mathscr{B}, \mathscr{X} = \mathbb{R}^2$ postoji takva upravljačka Ljapunovljeva funkcija $V(\boldsymbol{x}) \geq 0$, $u \in \mathscr{U}$, $\gamma > 0$, $b(k) > 0$ da vrijedi (radi jednostavnosti zapisa izbačena je ovisnost varijabli stanja, brzine i kuta rotora o trenutku uzorkovanja k):

$$V(f(\boldsymbol{x}, \boldsymbol{u}, \boldsymbol{\omega}_{re}, \boldsymbol{\theta}_{re})) \leq \max(V(\boldsymbol{x}) - b(k), \gamma), \tag{5.37}$$

gdje varijabla $b(k)$ definira brzinu opadanja upravljačke Ljapunovljeve funkcije. Uz zanemarenje mrtvog vremena pretvarača te definiranjem skupa ograničenja varijabli stanja $\mathscr{X} = \mathbb{R}^2$, vrijednost varijable $b(k)$ može biti odabrana iz sljedećeg skupa [119]:

$$b(k) \in (0, 1/\sqrt{3} - V(\boldsymbol{y}(k))\big], \tag{5.38}$$

gdje $\boldsymbol{y}(k)$ definira odstupanje referentne vrijednosti magnetskog toka između dva koraka uzorkovanja prema izrazu:

$$\boldsymbol{y}(k) = -(\bar{\psi}^*_{\alpha\beta}(k) - \bar{\psi}^*_{\alpha\beta}(k+1)). \tag{5.39}$$

Okolina referentne vrijednosti $\mathscr{B}$ definirana je kao podrazinski skup upravljačke Ljapunovljeve funkcije. Za vrijednosti varijabli stanja iz podrazinskog skupa vrijedi da je vrijednost upravljačke Ljapunovljeve funkcije manja od vrijednosti označene s γ kako slijedi:

$$\mathscr{B} = \{\boldsymbol{x} : V(\boldsymbol{x}) \leq \gamma\} \subset \mathscr{X}. \tag{5.40}$$

Odabrana je upravljačka Ljapunovljeva funkcija koja je definirana u normiranom prostoru magnetskog toka u mirujućem $\alpha\beta$ koordinatnom sustavu [119] sljedećim izrazom:

$$V(\Delta\bar{\psi}_{\alpha\beta}) = \left\| \boldsymbol{H}\Delta\bar{\psi}_{\alpha\beta} \right\|_{\infty}, \tag{5.41}$$

gdje su matrica $\boldsymbol{H}$ i regulacijsko odstupanje normiranog magnetskog toka $\Delta\bar{\psi}_{\alpha\beta}$ jednaki:

$$\boldsymbol{H} = \begin{bmatrix} 0 & 1 \\ \sqrt{3}/2 & 1/2 \\ \sqrt{3}/2 & -1/2 \\ 0 & -1 \\ -\sqrt{3}/2 & -1/2 \\ -\sqrt{3}/2 & 1/2 \end{bmatrix}, \tag{5.42}$$

$$\Delta\bar{\psi}_{\alpha\beta} = (\bar{\psi}_{\alpha\beta} - \bar{\psi}^*_{\alpha\beta}) = (\psi_{\alpha\beta} - \psi^*_{\alpha\beta})(T_s U_{dc})^{-1}. \tag{5.43}$$

U izrazu (5.43) $\psi_{\alpha\beta}$ je magnetski tok, dok je $\psi^*_{\alpha\beta}$ referentna vrijednost magnetskog toka, T_s je period uzorkovanja, a U_{dc} je napon istosmjernog međukruga. Uz zanemarenje mrtvog vremena pretvarača i skup ograničenja $\mathscr{X} = \mathbb{R}^2$, u [119] pokazano je da upravljačka Ljapunovljeva funkcija definirana izrazom (5.41) sadrži podrazinske skupove u obliku šesterokuta:

$$\Omega(\gamma) = \{\Delta\bar{\psi}_{\alpha\beta} : \boldsymbol{H}\Delta\bar{\psi}_{\alpha\beta} \leq \gamma\}. \tag{5.44}$$

U [119] je pokazano da je za vrijednosti $\gamma \geq 1/\sqrt{3}$ izračunati predskup (engl. *preset*) podrazinskog skupa definiran s (5.44) konveksni skup koji sadrži originalni podrazinski skup što znači da je svaki skup za kojeg vrijedi $\gamma \geq 1/\sqrt{3}$ ujedno i upravljački invarijantni skup za nominalni sustav uz zanemarenje mrtvog vremena pretvarača. Budući da je svaki skup za kojeg vrijedi $\gamma \geq 1/\sqrt{3}$ invarijantan, podešavanjem vrijednosti parametra γ mijenja se veličina skupa unutar kojeg se nastoji zadržati vrijednost varijable stanja, u ovom slučaju struje. Time se može ostvariti kompromis između prihvatljivog harmoničkog izobličenja struja i niske sklopne frekvencije generatorskog pretvarača u drugom režimu rada, tj. stacionarnom stanju. Također, parametar γ određuje kada je aktivan pojedini režim rada razvijenog algoritma prema izrazima (5.32) i (5.40).

U predikcijskom modelu te prilikom definiranja upravljačkog problema korišten je standardni model sinkronog generatora sa stalnim magnetima u sinkronom dq koordinatnom sustavu, dok je upravljačka Ljapunovljeva funkcija definirana u mirujućem $\alpha\beta$ koordinatnom sustavu. Budući da se, uz poznate vrijednosti parametara generatora, magnetski tok izravno proračunava putem izraza (5.23), prije proračuna upravljačke Ljapunovljeve funkcije izvršava se inverzna Parkova transformacija magnetskog toka:

$$\begin{bmatrix} \psi_\alpha \\ \psi_\beta \end{bmatrix} = \begin{bmatrix} \cos(\theta_{re}) & -\sin(\theta_{re}) \\ \sin(\theta_{re}) & \cos(\theta_{re}) \end{bmatrix} \begin{bmatrix} \psi_d \\ \psi_q \end{bmatrix}. \tag{5.45}$$

S ciljem smanjenja konzervativnosti rješenja optimizacijskog problema, umjesto standardne upravljačke Ljapunovljeve funkcije definirane s (5.41), uvodi se fleksibilna upravljačka Ljapunovljeva funkcija sljedećeg oblika:

$$V(f(\boldsymbol{x},\boldsymbol{u},\omega_{re},\theta_{re})) \leq \max(V(\boldsymbol{x})+\lambda(k)-b(k),\gamma), \tag{5.46}$$

gdje je $\lambda(k) \geq 0$ vremenski promjenjiva funkcija sljedećih svojstava:

$$\lambda(k+j) = 0, \forall j \geq k_1, k_1 \in \mathbb{Z}_+, \tag{5.47}$$

gdje je k_1 trenutak u kojem funkcija $\lambda(k)$ postaje jednaka nuli te ograničenje definirano fleksibilnom upravljačkom Ljapunovljevom funkcijom postaje istovjetno ograničenju definiranom standardnom upravljačkom Ljapunovljevom funkcijom. Koncept fleksibilne upravljačke Ljapunovljeve funkcije uveden je u [128]. Primjena navedene funkcije omogućava u određenim uvjetima i porast iznosa upravljačke Ljapunovljeve funkcije što može voditi k manje konzervativnom rješenju u usporedbi sa standardnom upravljačkom Ljapunovljevom funkcijom, a time i boljim performansama upravljanja. Primjenom fleksibilne upravljačke Ljapunovljeve funkcije očuvana je uzastopna dopustivost i stabilnost razvijenog algoritma, a ograničenje definirano izrazom (5.37) je relaksirano čime je omogućena minimizacija sklopnih gubitaka i tijekom prijelazne pojave.

Kao što je navedeno ranije u tekstu, parametri algoritma koji se odnose na kriterijsku funkciju (parametri za penalizaciju) su (q_0, p_0, r_0) u prijelaznoj pojavi i (q_1, p_1, r_1) u stacionarnom stanju. U prvom režimu rada, tj. prijelaznoj pojavi parametrima q_0 i r_0 penalizira se regulacijsko odstupanje struje i promjena sklopnog stanja na predikcijskom horizontu, dok se parametrom p_0 penalizira regulacijsko odstupanje struje na kraju predikcijskog horizonta. Vrijednosti navedenih parametara za prijelaznu pojavu mogu se definirati prema sljedećim smjernicama. Najveća dinamika odziva struje dobiva se samo penalizacijom regulacijskog odstupanja struje, tj. postavljanjem pozitivne vrijednosti parametara q_0 i p_0 te postavljanjem vrijednosti parametra r_0 na nulu. Međutim, ako je poželjno penalizirati promjenu sklopnog stanja tijekom prijelazne pojave vrijednost parametra r_0 se postavlja na pozitivnu vrijednost. Relativni odnos vrijednost parametra r_0 te parametara q_0 i p_0 definira daje li se prioritet penalizaciji sklopnih gubitaka ili penalizaciji regulacijskog odstupanja struje. Neovisno o vrijednosti parametra r_0 koji u slučaju velikog iznosa može uzrokovati nestabilnost bez dodatnih ograničenja, stabilnost je osigurana fleksibilnom upravljačkom Ljapunovljevom funkcijom.

U drugom režimu rada, tj. stacionarnom stanju odabirom vrijednosti parametra γ koji definira veličinu upravljačkog invarijantnog skupa u intervalu $\gamma = \left[\frac{1}{\sqrt{3}}, \infty\right)$ može se definirati najveće dopušteno harmoničko izobličenje struje. Također se parametrima q_1 i r_1 penalizira regulacijsko odstupanje struje i promjena sklopnog stanja na predikcijskom horizontu, dok se parame-

trom p_1 penalizira regulacijsko odstupanje struje na kraju predikcijskog horizonta. Vrijednosti navedenih parametara za stacionarno stanje mogu se definirati prema sljedećim smjernicama. Ako je poželjno isključivo penalizirati promjenu sklopnog stanja tada se vrijednosti parametara q_1 i p_1 postavljaju na nulu, a vrijednost parametra r_1 na neki pozitivan iznos. S druge strane, ako je poželjno ostvariti što točnije praćenje referentne vrijednosti struje, tada se vrijednosti parametara q_1 i p_1 postavljaju na neku pozitivnu vrijednost, a vrijednost parametra r_1 na nulu. Navedeni su granični slučajevi razvijenog algoritma. U svim drugim slučajevima kompromis između smanjenja sklopne frekvencije i prihvatljivog harmoničkog izobličenja struje se ostvaruje relativnim podešavanjem vrijednosti parametara q_1 i p_1 u odnosu na vrijednost parametra r_1.

Redoslijed izvođenja razvijenog MP-DCC algoritma prikazan je na slici 5.6. Prije početka rada algoritma inicijaliziraju se parametri kriterijske funkcije te upravljačke Ljapunovljeve funkcije. Na početku perioda uzorkovanja prikupljaju se mjerenja struje, napona istosmjernog međukruga, brzine i kuta rotora, a potom se na temelju izmjerenih vrijednosti struje te parametara generatora proračunava iznos Ljapunovljeve funkcije u trenutnom koraku uzorkovanja. Ovisno o iznosu upravljačke Ljapunovljeve funkcije aktivna je prijelazna pojava ($m = 0$) ili stacionarno stanje ($m = 1$). Potom se proračunava iznos opadanja upravljačke Ljapunovljeve funkcije $b(k)$ te predikcija struja na predikcijskom horizontu za svih osam vektora napona generatorskog pretvarača. Za svaki od vektora napona provjerava se zadovoljava li ograničenje definirano fleksibilnom upravljačkom Ljapunovljevom funkcijom te se potom putem kriterijske

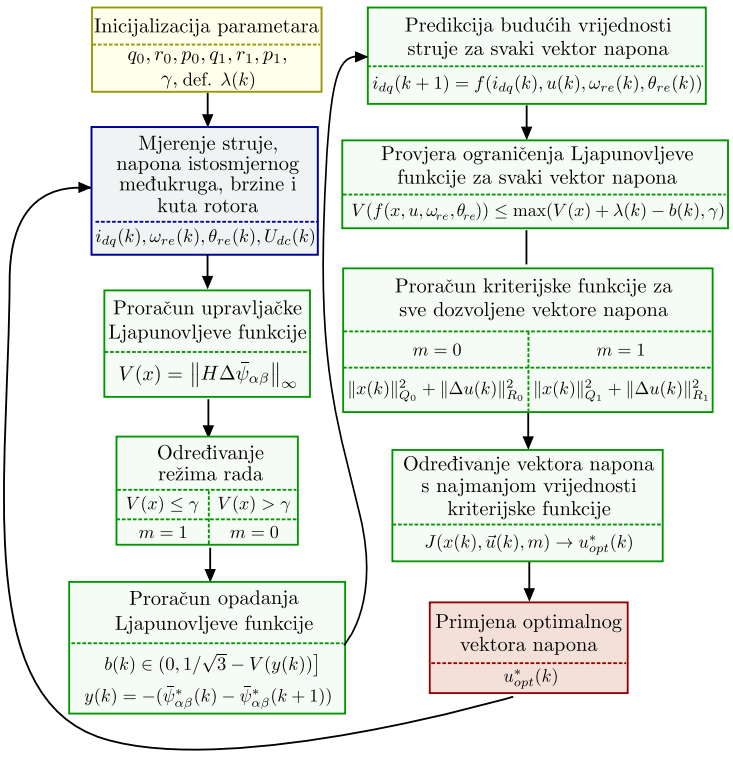

Slika 5.6: Dijagram toka razvijenog MP-DCC algoritma

funkcije određuje optimalni vektor napona koji se primjenjuje na pretvarač u idućem periodu uzorkovanja.

Utjecaj mrtvog vremena pretvarača na upravljačke performanse

U slučaju zanemarenja mrtvog vremena pretvarača, $\Omega(\gamma)$ je upravljački invarijantni skup za $\forall\gamma \geq \frac{1}{\sqrt{3}}$. Navedeni skup može se izračunati koristeći normirani magnetski tok u $\alpha\beta$ koordinatnom sustavu kao što je opisano u [119]. No, tijekom mrtvog vremena, aktivan je vektor napona definiran strujom u trenutku k što može dovesti do gubitka svojstva upravljačke invarijantnosti skupova $\Omega(\gamma)$ za $\forall\gamma \geq \frac{1}{\sqrt{3}}$. Iz tog razloga potrebno je mrtvo vrijeme pretvarača uvrstiti u matematički model za predikciju budućih varijabli stanja.

U ovom potpoglavlju izračunat je upravljački invarijantni skup uzimajući u obzir mrtvo vrijeme generatorskog pretvarača. Koristeći isti postupak kao u potpoglavlju 5.3.1, diskretan matematički model koji opisuje magnetski tok u $\alpha\beta$ koordinatnom sustavu se može zapisati kao:

$$\bar{\boldsymbol{\psi}}_{\alpha\beta}(k+1) = \bar{\boldsymbol{\psi}}_{\alpha\beta}(k) + \frac{T_{dt}}{T_s}\bar{\boldsymbol{u}}_{dt,\alpha\beta}(k) + \frac{T_s - T_{dt}}{T_s}\bar{\boldsymbol{u}}_{\alpha\beta}(k), \tag{5.48}$$

gdje su $\bar{\boldsymbol{u}}_{\alpha\beta}$ i $\bar{\boldsymbol{u}}_{dt,\alpha\beta}$ normirani kompenzirani vektor napona definiran upravljačkim algoritmom te vektor napona aktivan tijekom mrtvog vremena: $\bar{\boldsymbol{u}}_{\alpha\beta} = \frac{\boldsymbol{u}_{\alpha\beta} - \boldsymbol{i}_{\alpha\beta}R_s}{U_{dc}}$, $\bar{\boldsymbol{u}}_{dt,\alpha\beta} = \frac{\boldsymbol{u}_{dt,\alpha\beta} - \boldsymbol{i}_{\alpha\beta}R_s}{U_{dc}}$. Dinamika normirane greške magnetskog toka se može zapisati kao:

$$\begin{aligned}\Delta\bar{\boldsymbol{\psi}}_{\alpha\beta}(k+1) &= \Delta\bar{\boldsymbol{\psi}}_{\alpha\beta}(k) + \frac{T_{dt}}{T_s}\bar{\boldsymbol{u}}_{dt,\alpha\beta}(k) + \frac{T_s - T_{dt}}{T_s}\bar{\boldsymbol{u}}_{\alpha\beta}(k) - \boldsymbol{y}(k) \\ &= \Delta\bar{\boldsymbol{\psi}}_{\alpha\beta}(k) + \frac{T_{dt}}{T_s}\bar{\boldsymbol{u}}_{dt,\alpha\beta}(k) + \boldsymbol{u}(k),\end{aligned} \tag{5.49}$$

gdje je $\boldsymbol{u}(k) = \frac{T_s - T_{dt}}{T_s}\bar{\boldsymbol{u}}_{\alpha,\beta}(k) - \boldsymbol{y}(k)$, dok $\boldsymbol{y}(k)$ predstavlja odstupanje referentne vrijednosti magnetskog toka između dva koraka uzorkovanja prema izrazu (5.39).

Uz zanemarenje otpora statora, vektor napona tijekom mrtvog vremena pretvarača te vektor napona u preostalom dijelu vremena uzorkovanja pripadaju upravljačkom skupu s konačnim brojem elemenata, odnosno $\boldsymbol{u}_{\alpha\beta} \in \mathscr{U}$ i $\boldsymbol{u}_{dt,\alpha\beta} \in \mathscr{U}$. Time i normirani vektori napona $\bar{\boldsymbol{u}}_{\alpha\beta}$ i $\bar{\boldsymbol{u}}_{dt,\alpha\beta}$ pripadaju normiranom skupu $\bar{\mathscr{U}}$. Skup $\bar{\mathscr{U}}$ nije konveksan skup, već je definiran vrhovima šesterokuta $\Omega(\frac{1}{\sqrt{3}})$ označenih s $\mathscr{V}(\Omega\big(\frac{1}{\sqrt{3}}\big))$.

Prema definiciji ranije uvedene veličine $\boldsymbol{u}$, uz zanemarenje ovisnosti o trenutku uzorkovanja k radi jednostavnosti zapisa, $\bar{\boldsymbol{u}}_{\alpha\beta} \in \bar{\mathscr{U}}$ implicira $\boldsymbol{u} + \boldsymbol{y} \in \frac{T_s - T_{dt}}{T_s}\bar{\mathscr{U}}$. Ako vrijedi $\boldsymbol{y} \in int(hull(\frac{T_s - T_{dt}}{T_s}\mathscr{U}))$, tada $\bar{\mathscr{U}} + \boldsymbol{y}$ sadrži ishodište u svojoj unutrašnjosti.

Uvodi se pretpostavka da se greška normiranog magnetskog toka nalazi u šesterokutu odnosno da vrijedi $\Delta\bar{\boldsymbol{\psi}}_{\alpha,\beta} \in \Omega(\gamma)$. Skup svih stanja koja vode u skup $\Omega(\gamma)$ u jednom koraku uzorkovanja koristeći konačni skup upravljačkih akcija (vektori napona) uzimajući u obzir mrtvo vrijeme pretvarača naziva se predskup skupa $\Omega(\gamma)$ te se označava $\mathscr{O}(\Omega(\gamma))$. Skup koji je

uvijek sadržan u predskupu $\Gamma(\gamma) \subseteq \mathscr{O}(\Omega(\gamma))$ je izračunat korištenjem Minkowski sume i razlike kao što je definirano u nastavku.

Za dva skupa $\mathscr{A}$ and $\mathscr{B}$, Minkowski suma definira se sljedećim izrazom: $\mathscr{A} \oplus \mathscr{B} = \{a+b : a \in \mathscr{A}, b \in \mathscr{B}\}$, dok se Minkowski razlika definira kao $\mathscr{A} \ominus \mathscr{B} = \{x \in \mathbb{R}^n : x+b \in \mathscr{A}, \forall b \in \mathscr{B}\}$. Koristeći ranije navedene definicije $\Gamma(\gamma)$ se može izračunati kao:

$$\begin{aligned}\Gamma(\gamma) = \bigcap_{\boldsymbol{y} \in \mathscr{Y}} \Big(\Omega(\gamma) \ominus \frac{T_{dt}}{T_s} \mathscr{V}(\Omega(\frac{1}{\sqrt{3}}))\Big) \oplus \\ \oplus \mathscr{V}\Big(\frac{T_s - T_{dt}}{T_s} \Omega(\frac{1}{\sqrt{3}})\Big) \oplus y,\end{aligned} \tag{5.50}$$

gdje je $\mathscr{Y} = int\left(\Omega(\frac{T_s-T_{dt}}{T_s}\frac{1}{\sqrt{3}})\right) = \Omega(\frac{T_s-T_{dt}}{T_s}\frac{1}{\sqrt{3}} - b)$, gdje je $b > 0$ pozitivan broj. Ako vrijedi sljedeća pretpostavka $\gamma \geq \frac{T_d}{T_s}\frac{1}{\sqrt{3}}$, tada vrijedi $\Omega(\gamma) \ominus \frac{T_{dt}}{T_s}\mathscr{V}(\Omega(\frac{1}{\sqrt{3}})) = \Omega(\gamma - \frac{T_{dt}}{T_s}\frac{1}{\sqrt{3}})$.

Ako vrijedi pretpostavka $\gamma - \frac{T_{dt}}{T_s}\frac{1}{\sqrt{3}} \geq \frac{T_s-T_{dt}}{T_s}\frac{1}{\sqrt{3}}$ tada vrijedi $\Omega(\gamma - \frac{T_{dt}}{T_s}\frac{1}{\sqrt{3}}) \oplus \mathscr{V}\left(\frac{T_s-T_{dt}}{T_s}\Omega(\frac{1}{\sqrt{3}})\right) = \Omega(\gamma + \frac{T_s-2T_{dt}}{T_s})$. Dakle, ako vrijedi $\gamma \geq \frac{1}{\sqrt{3}}$, skup $\Gamma(\gamma)$ se može izračunati kako slijedi:

$$\Gamma(\gamma) = \Omega\Big(\gamma - \frac{T_{dt}}{T_s}\frac{1}{\sqrt{3}} + b\Big). \tag{5.51}$$

Ako vrijedi $\mathscr{O}(\Omega(\gamma)) \subseteq \Omega(\gamma)$, tada je $\Omega(\gamma)$ upravljački invarijantni skup. Navedena tvrdnja vrijedi za $\gamma \geq \frac{1}{\sqrt{3}}$ i $b \geq \frac{T_{dt}}{T_s}\frac{1}{\sqrt{3}}$ te budući da vrijedi $T_s > T_{dt}$, dolazi se do sljedećeg uvjeta za naponsko ograničenje:

$$|\omega_{re}|\|\psi^*_{dq}\| \leq \frac{1}{\sqrt{3}}\Big(\frac{T_s - 2T_{dt}}{T_s} - \varepsilon\Big)U_{dc}. \tag{5.52}$$

Budući da vrijedi $b > \frac{T_{dt}}{T_s}\frac{1}{\sqrt{3}}$, varijable stanja sustava su sadržane u originalnom upravljačkom invarijantnom skupu izračunatom za nominalni sustav, no radna točka treba biti udaljenija od naponskog ograničenja.

Upravljačka Ljapunovljeva funkcija može se tijekom mrtvog vremena pretvarača povećati za iznos $\frac{T_{dt}}{T_s}\frac{1}{\sqrt{3}}$, stoga je nužno osigurati smanjenje upravljačke Ljapunovljeve funkcije za vrijednost nešto veću od navedenog iznosa, tj. $\frac{T_{dt}}{T_s}\frac{1}{\sqrt{3}} + \varepsilon$. Navedeno svojstvo vodi k novom izrazu za varijablu $b(k)$ kojom se definira brzina opadanja upravljačke Ljapunovljeve funkcije, prethodno definiranu izrazom (5.38). Uzimajući u obzir mrtvo vrijeme pretvarača upravljački invarijantni skup ostaje jednak izvornom, no vrijednost varijable $b(k)$ je iz sljedećeg intervala:

$$b(k) \in \Big(\frac{T_{dt}}{T_s\sqrt{3}}, \frac{T_s - 2T_{dt}}{T_s\sqrt{3}} - V(\boldsymbol{y}(k))\Big]. \tag{5.53}$$

5.4. Simulacijski rezultati

Opisani algoritam modelskog prediktivnog izravnog upravljanja strujama sinkronog generatora sa stalnim magnetima temeljen na fleksibilnoj upravljačkoj Ljapunovljevoj funkciji provjeren je na simulacijskom modelu u programskom paketu MATLAB. U simulacijskom modelu korišteni su parametri sinkronog generatora sa stalnim magnetima i AC-DC-AC pretvarača laboratorijskog modela koji su ponovljeni u nastavku:

PMG: $P_n = 375$ kW, $E_n = 400$ V, $I_n = 596$ A, $f_n = 75$ Hz, $n_n = 1500$ rpm.
Parametri nadomjesne sheme: $R_s = 7$ mΩ, $L_d = 0.8$ mH, $L_q = 2.7$ mH, $\psi_{md} = 0.69$ Wb.
AC-DC-AC pretvarač: $P_n = 520$ kW, $U_n = 400$ V, $I_n = 750$ A, $T_s = 62.5$ μs, $T_{dt} = 4$ μs, $U_{dc} = 650$ V.
Bazne vrijednosti: $U_b = 326$ V, $I_b = 843$ A, $f_b = 75$ Hz, $n_{rb} = 1500$ okr/min, $\omega_{rb} = 471$ rad/s, $M_b = 2389$ Nm, $Z_b = 0.39$ Ω, $L_b = 0.83$ mH, $\psi_b = 0.69$ Wb.

Upravljačka struktura simulacijskog modela sastoji se od proračuna referentnih struja $\boldsymbol{i}^*_{dq}$ na temelju referentnog momenta M^* prema MTPA algoritmu. Proračunate referentne vrijednosti struja se prosljeđuju razvijenoj strukturi MP-DCC upravljanja kojom se prema ranije opisanom algoritmu određuje optimalni vektor napona odnosno sklopno stanje koje se primjenjuje na generatorski pretvarač u svakom trenutku uzorkovanja. S obzirom na složenost razvijenog algoritma upravljanja i ograničenja procesorske moći digitalnog sustava laboratorijskog modela, odabrana frekvencija izvođenja algoritma (frekvencija uzorkovanja) jednaka je $f_s = 16$ kHz. Mrtvo vrijeme generatorskog pretvarača jednako je $T_{dt} = 4$ μs što odgovara stvarnoj vrijednosti na laboratorijskom modelu te je uzeto u obzir prilikom modeliranja generatorskog pretvarača u simulacijskom modelu. Simulacijski rezultati su prikazani za predikcijski horizont $N = 1$.

U nastavku je prikazana motivacija za uvođenje ograničenja definiranog upravljačkom Ljapunovljevom funkcijom, odzivi za različite vrijednosti parametra koji definira veličinu upravljačkog invarijantnog skupa, usporedba fleksibilne i standardne upravljačke Ljapunovljeve funkcije, učinak parametara za penalizaciju regulacijskog odstupanja struje i promjene vektora napona na sklopnu frekvenciju i harmoničko izobličenje struje u čitavom radnom području generatora, usporedba odziva kada se mrtvo vrijeme generatorskog pretvarača uzima u obzir prilikom sinteze regulatora te kada se zanemaruje, kao i robusnost algoritma na promjene parametara generatora. Prikazane su referentne $\boldsymbol{i}^*_{dq}$ i mjerene $\boldsymbol{i}_{dq}$ vrijednosti struje u sinkronom dq koordinatnom sustavu, mjerene vrijednosti struje $\boldsymbol{i}_{abc}$ u mirujućem *abc* koordinatnom sustavu, optimalni vektora napona $\boldsymbol{u}^*_{\alpha\beta}$ u mirujućem $\alpha\beta$ koordinatnom sustavu te optimalno sklopno stanje s^*_{opt}, upravljačka Ljapunovljeva funkcija V, parametar kojim se definira veličina upravljačkog invarijantnog skupa γ i funkcija λ kojom se dodaje fleksibilnost upravljačkoj Ljapunovljevoj funkciji te referentni M^* i proračunati M moment generatora.

5.4.1. MP-DCC algoritam bez upravljačke Ljapunovljeve funkcije

Na slici 5.7 prikazana je usporedba MP-DCC algoritma bez ograničenja definiranog upravljačkom Ljapunovljevom funkcijom za vrijednosti parametara penalizacije ($q = 1, r = 0, p = 1$) (penalizira se isključivo regulacijsko odstupanje struje) i ($q = 1, r = 100, p = 1$) (osim regulacijskog odstupanja struje penalizira se i promjena vektora napona) u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. Simulacija je provedena za 2000 koraka uzorkovanja što je ekvivalentno vremenu $t = 0.125$ s. Simulirana struktura upravljanja temeljena je na standardnoj inačici MP-DCC algoritma s kvadratnom kriterijskom funkcijom kojom se penalizira odstupanje mjerene i referentne vrijednosti struje te promjena vektora napona. Budući da u navedenoj inačici algoritma ne postoje dva režima rada, koriste se jedinstveni parametri za penalizaciju regulacijskog odstupanja (q i p) i promjene vektora napona (r).

Ako se penalizira samo regulacijsko odstupanje struje ($q = 1$, $r = 0$, $p = 1$) tada je ostvareno stabilno vladanje sustava budući da je u svakom trenutku uzorkovanja optimalan vektor napona onaj koji osigurava minimalnu grešku struje. S druge strane, kada se penalizira i regulacijsko odstupanje i promjena vektora napona ($q = 1$, $r = 100$, $p = 1$) može doći do nestabilnog vladanja sustava kao što je prikazano na slici 5.7b. Navedena pojava posljedica je vrijednosti parametra za penalizaciju promjene vektora napona ($r = 100$) te radne točke.

Naime, uz odabrane parametre i navedenu radnu točku, u većini trenutaka uzorkovanja optimalno je zadržati postojeći vektor napona što u konačnici dovodi do gubitka upravljivosti

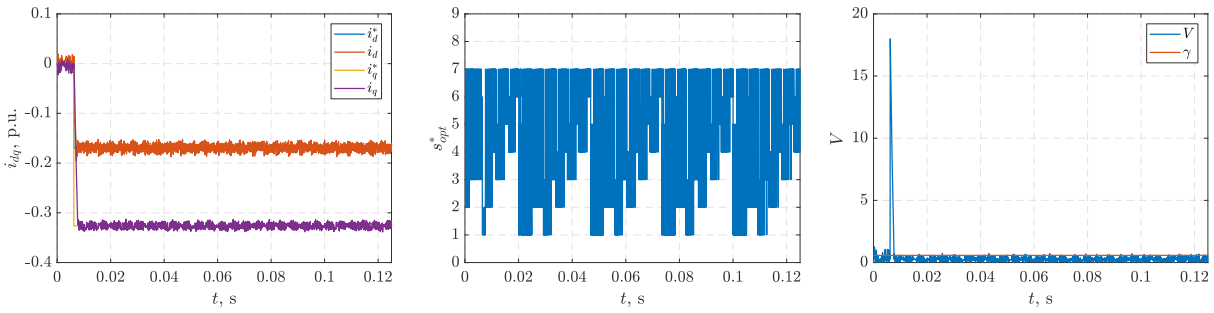

(a) MP-DCC algoritam s parametrima ($q = 1$, $r = 0$, $p = 1$)

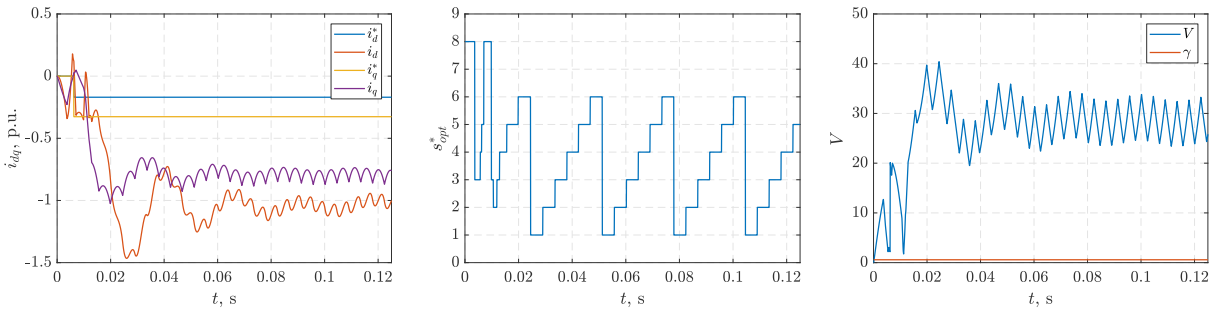

(b) MP-DCC algoritam s parametrima ($q = 1$, $r = 100$, $p = 1$)

Slika 5.7: MP-DCC algoritam bez ograničenja definiranog upravljačkom Ljapunovljevom funkcijom za $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u.

strujama i nestabilnog rada. Budući da je odabir parametara penalizacije proizvoljan te ovisi o željenim upravljačkim performansama sustava, a ovisno o brzini vjetra mijenja se i radna točka generatora, ovakvo vladanje sustava nije prihvatljivo u slučaju generatora velikih snaga koji se koriste u vjetroelektranama. Iz navedenog razloga uvedeno je ograničenje definirano upravljačkom Ljapunovljevom funkcijom.

5.4.2. Različite veličine upravljačkog invarijantnog skupa

Kao što je opisano u potpoglavlju 5.3.2, parametrom γ definirana je veličina upravljačkog invarijantnog skupa u prostoru normiranog magnetskog toka. Za vrijednosti $\gamma \geq 1/\sqrt{3}$ upravljački skup je invarijantan što upućuje da je iz navedenog intervala moguće odabrati proizvoljnu vrijednost parametra γ. Na slici 5.8 prikazani su odzivi razvijenog MP-DCC algoritma uz parametre za penalizaciju u stacionarnom stanju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) za različite veličine upravljačkog invarijantnog skupa: $\gamma = \frac{1}{\sqrt{3}}$, $\gamma = \frac{2}{\sqrt{3}}$ i $\gamma = \frac{3}{\sqrt{3}}$ u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. Simulacija je provedena za 2000 koraka uzorkovanja što je ekvivalentno vremenu $t = 0.125$ s. Navedena kombinacija parametara za penalizaciju u stacionarnom stanju osigurava da se unutar invarijantnog skupa ($V(x) \leq \gamma$) isključivo penalizira promjena vektora napona uz zadržavanje unutar upravljačkog invarijantnog skupa čime se minimizira sklopna frekvencija, a time i sklopni gubici. Sklopna frekvencija f_{sw} i ukupno harmoničko izobličenje (engl. *total harmonic distortion*, THD) THD_i mogu se izračunati sljedećim izrazima [129]:

$$\begin{aligned} f_{sw} &= \frac{\sum_{k=1}^{N} \Delta s(k)}{6NT_s} \\ \text{THD}_\text{i} &= \frac{\sqrt{i_2^2 + i_3^2 + ... + i_n^2}}{i_1} \end{aligned} \tag{5.54}$$

gdje je Δs broj sklapanja između dva uzastopna perioda uzorkovanja, N je broj perioda uzorkovanja nad kojim se računa sklopna frekvencija, T_s je period uzorkovanja, i_1 je osnovni harmonik struje, dok su $(i_2, ..., i_n)$ viši harmonici struje.

Kao što je prikazano na slici 5.8 povećanjem vrijednosti parametra γ se povećava upravljački invarijantni skup unutar kojeg se nastoji zadržati struju što dovodi do manjeg broja promjena vektora napona, a time i većeg harmoničkog izobličenja struje. Za različite vrijednosti parametra γ izračunate su sljedeće vrijednosti sklopne frekvencije i ukupnog harmoničkog izobličenja:

- $\gamma = 1/\sqrt{3} \rightarrow f_{sw} = 1549$ Hz, $\text{THD}_\text{i} = 4.55\%$,
- $\gamma = 2/\sqrt{3} \rightarrow f_{sw} = 702$ Hz, $\text{THD}_\text{i} = 9.71\%$,
- $\gamma = 3/\sqrt{3} \rightarrow f_{sw} = 462$ Hz, $\text{THD}_\text{i} = 14.34\%$.

Kao što se može uočiti iz priloženih vrijednosti, povećanjem parametra γ dolazi do značajnog povećanja harmoničkog izobličenja struje, stoga je u narednim simulacijskim rezultatima vrijednost parametra γ postavljena na minimalnu vrijednost, tj. $\gamma = \frac{1}{\sqrt{3}}$.

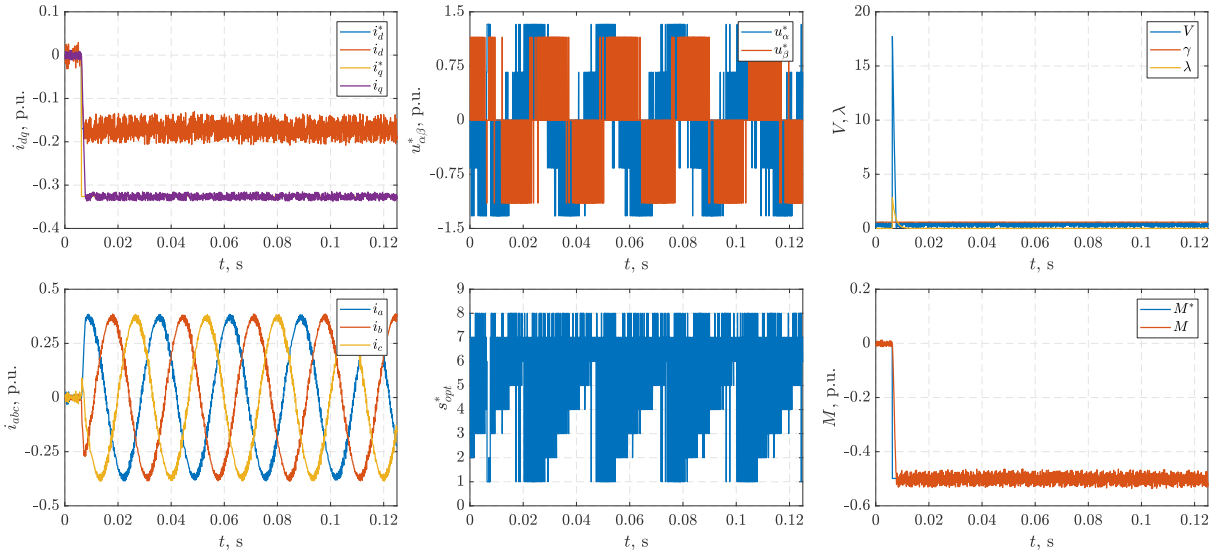

(a) MP-DCC algoritam uz veličinu upravljačkog invarijantnog skupa $\gamma = \frac{1}{\sqrt{3}}$

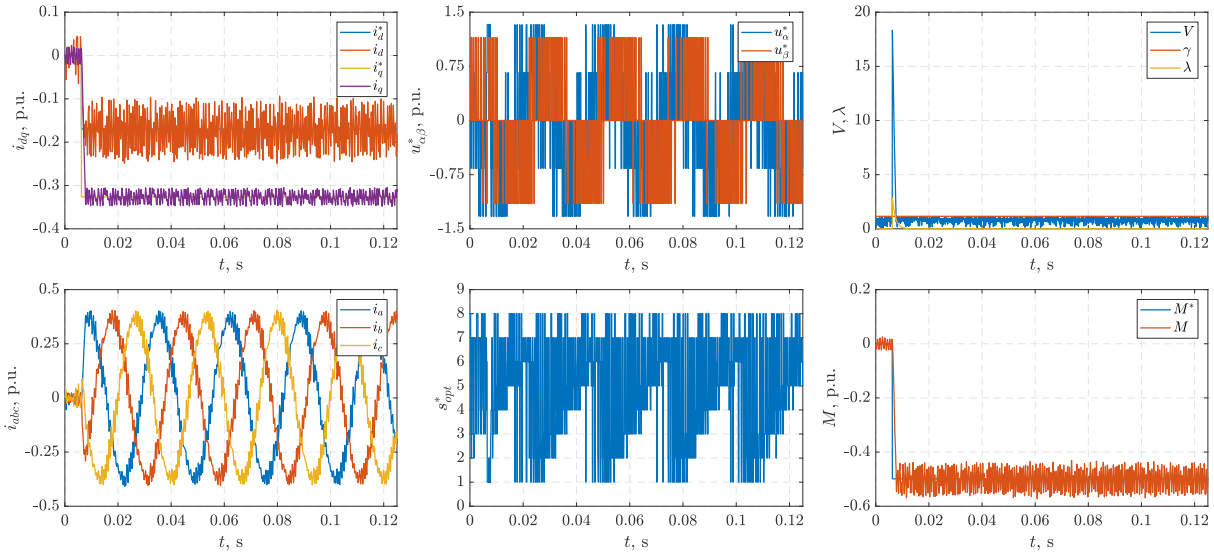

(b) MP-DCC algoritam uz veličinu upravljačkog invarijantnog skupa $\gamma = \frac{2}{\sqrt{3}}$

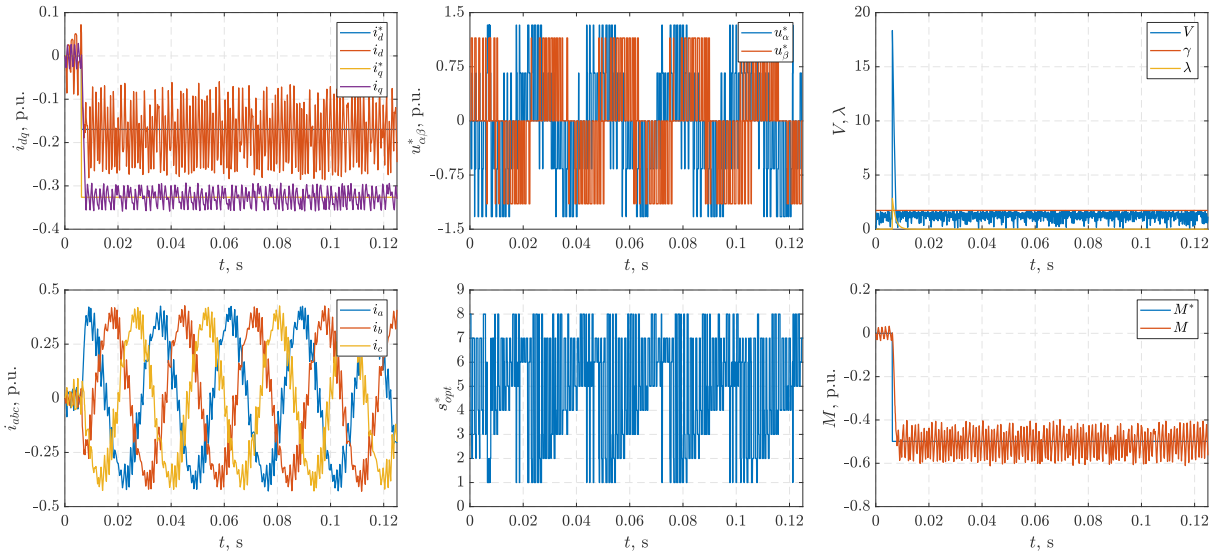

(c) MP-DCC algoritam uz veličinu upravljačkog invarijantnog skupa $\gamma = \frac{3}{\sqrt{3}}$

Slika 5.8: MP-DCC algoritam uz različite vrijednosti veličine upravljačkog invarijantnog skupa γ za $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u.

5.4.3. Usporedba standardne i fleksibilne upravljačke Ljapunovljeve funkcije

Na slici 5.9 prikazana je usporedba MP-DCC algoritma sa standardnom i fleksibilnom upravljačkom Ljapunovljevom funkcijom s parametrima za penalizaciju ($q_0 = 1$, $r_0 = 0$, $p_0 = 1$) za $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. Simulacija je provedena za 500 koraka uzorkovanja što je ekvivalentno vremenu $t = 0.0313$ s. Funkcija $\lambda(k)$ kojom se dodaje fleksibilnost standardnoj upravljačkoj Ljapunovljevoj funkciji je definirana kao: $\lambda(k+1) = \max(0, \rho\lambda(k) - \varepsilon)$, uz početni uvjet $\lambda(0) = 3$ te vrijednosti $\rho = 0.95$ i $\varepsilon = 10^{-10}$.

Budući da se u prvom režimu rada, tj. u prijelaznoj pojavi, penalizira samo regulacijsko od-

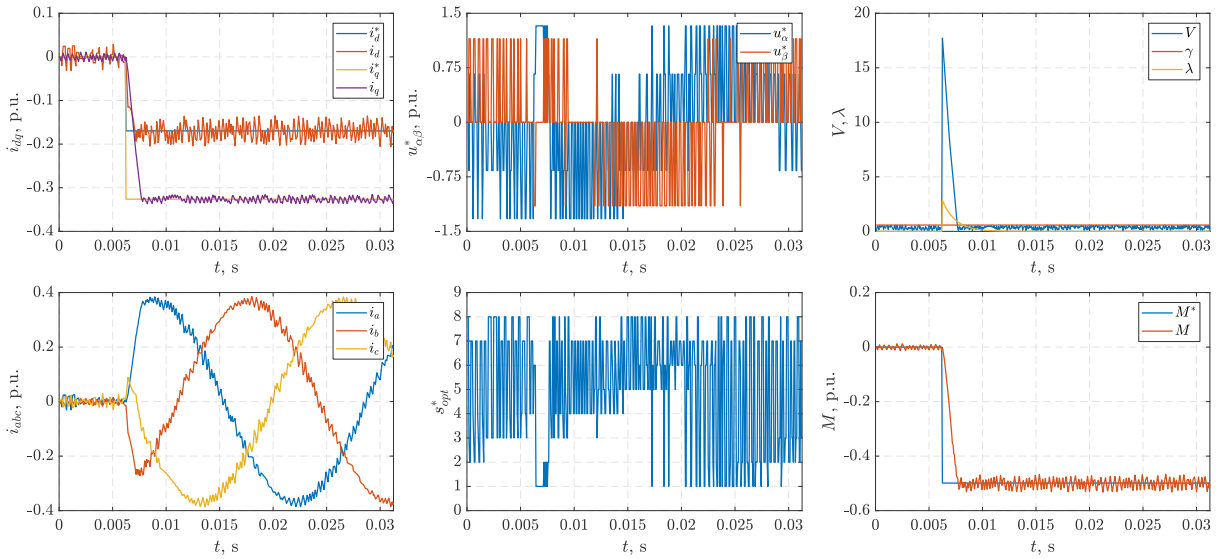

(a) MP-DCC algoritam sa standardnom upravljačkom Ljapunovljevom funkcijom

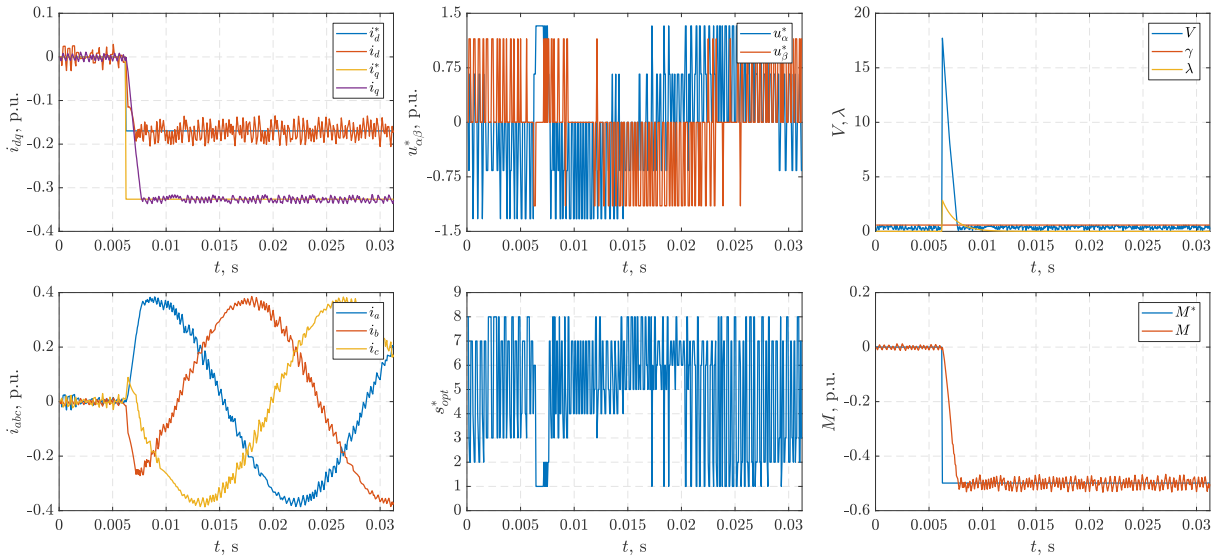

(b) MP-DCC algoritam s fleksibilnom upravljačkom Ljapunovljevom funkcijom

Slika 5.9: Usporedba MP-DCC algoritma sa standardnom i fleksibilnom upravljačkom Ljapunovljevom funkcijom s parametrima za penalizaciju ($q_0 = 1$, $r_0 = 0$, $p_0 = 1$) za $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u.

stupanje struje ($r_0 = 0$), optimalan vektor napona će uvijek djelovati u smjeru opadanja upravljačke Ljapunovljeve funkcije stoga slijedi identičan odziv sa standardnom i fleksibilnom upravljačkom Ljapunovljevom funkcijom. U simuliranom vremenskom intervalu je postignuta ista vrijednost sklopne frekvencije $f_{sw} = 1520$ Hz (broj sklapanja je $N_{sw} = 285$).

Na slici 5.10 prikazana je ista radna točka uz vrijednosti parametara za penalizaciju jednake ($q_0 = 1$, $r_0 = 50$, $p_0 = 1$). Budući da se u ovom slučaju penalizira i promjena vektora napona ($r_0 = 50$), u određenim trenucima uzorkovanja je optimalno zadržati vektor napona iz prošlog trenutka uzorkovanja što može dovesti do rasta upravljačke Ljapunovljeve funkcije.

U slučaju da je ograničenje definirano standardnom upravljačkom Ljapunovljevom funk-

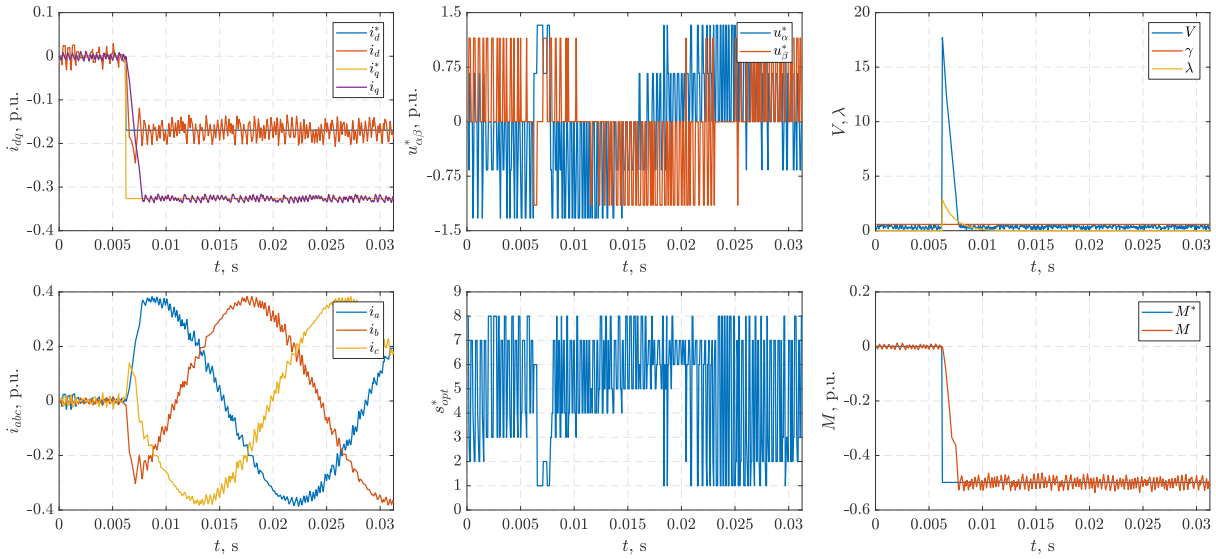

(a) MP-DCC algoritam sa standardnom upravljačkom Ljapunovljevom funkcijom

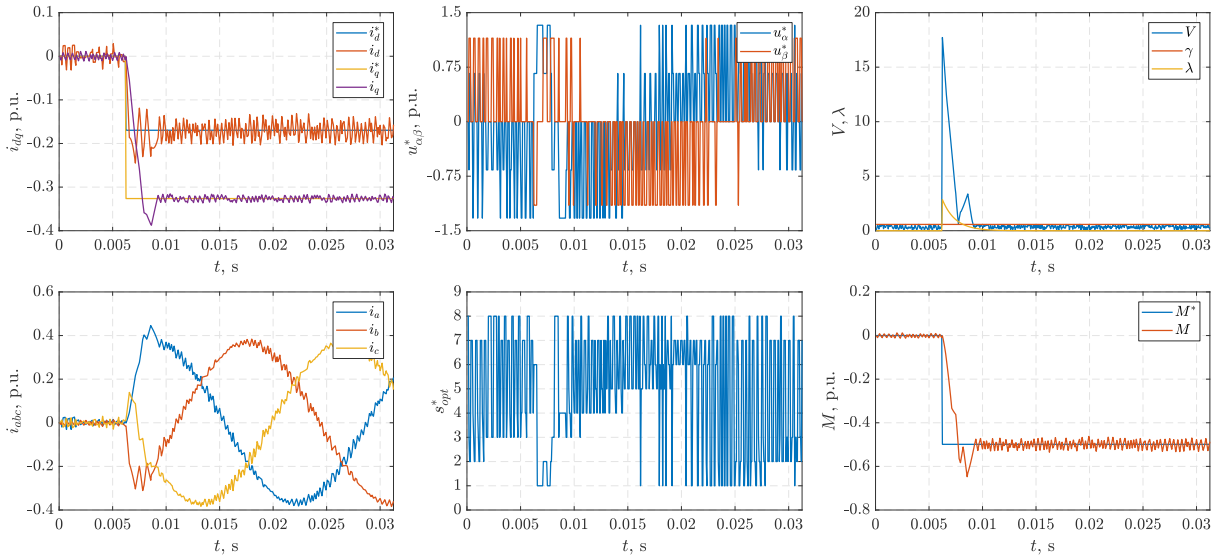

(b) MP-DCC algoritam s fleksibilnom upravljačkom Ljapunovljevom funkcijom

Slika 5.10: Usporedba MP-DCC algoritma sa standardnom i fleksibilnom upravljačkom Ljapunovljevom funkcijom s parametrima za penalizaciju ($q_0 = 1$, $r_0 = 50$, $p_0 = 1$) za $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u.

cijom navedeni slučajevi nisu dopustivi što vodi do konzervativnog rješenja. S druge strane, dodavanjem fleksibilnosti upravljačkoj Ljapunovljevoj funkciji omogućen je kratkotrajan rast upravljačke Ljapunovljeve funkcije tijekom prijelazne pojave što omogućava optimalno rješenje sukladno funkciji troška te je time moguće ostvariti dodatnu penalizaciju sklopnih gubitaka i tijekom prijelazne pojave. U slučaju sa standardnom upravljačkom Ljapunovljevom funkcijom postignuta je sklopna frekvencija $f_{sw} = 1472$ Hz (broj sklapanja je $N_{sw} = 276$), dok u slučaju s fleksibilnom upravljačkom Ljapunovljevom funkcijom $f_{sw} = 1413$ Hz (broj sklapanja je $N_{sw} = 265$).

5.4.4. Analiza utjecaja parametara za penalizaciju na upravljačke performanse

Na slici 5.11 prikazana je usporedba MP-DCC algoritma s fleksibilnom upravljačkom Ljapunovljevom funkcijom te parametrima za penalizaciju ($q_1 = 1,\ r_1 = 0,\ p_0 = 1$) i ($q_1 = 1,\ r_1 = 100,\ p_1 = 1$) za $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u. Budući da je razmatran učinak parametara za penalizaciju u drugom režimu rada, tj. u stacionarnom stanju (q_1, r_1, p_1), parametri za penalizaciju u prvom režimu rada, tj. u prijelaznoj pojavi, u svim su slučajevima postavljeni na jednake iznose ($q_0 = 1$, $r_0 = 0$, $p_1 = 1$). Simulacija je provedena za 2000 koraka uzorkovanja što je ekvivalentno vremenu $t = 0.125$ s.

U slučaju da su vrijednosti parametara za penalizaciju postavljene na ($q_1 = 1,\ r_1 = 0,\ p_1 = 1$), penalizira se isključivo regulacijsko odstupanje struje u stacionarnom stanju čime se osigurava smanjenje harmoničkog izobličenja struje, ali i značajno povećanje sklopne frekvencije. S druge strane, postavljanjem parametara za penalizaciju na ($q_1 = 1,\ r_1 = 100,\ p_1 = 1$), osigurava se minimizacija sklopnih gubitaka u stacionarnom stanju, uz povećanje harmoničkog izobličenja struje. U tom slučaju optimalan vektor napona je onaj kojim se osigurava minimalan broj sklapanja u odnosu na primijenjeni vektor napona iz prethodnog trenutka uzorkovanja (u idealnom slučaju zadržava se vektor napona iz prethodnog koraka) bez kršenja dodatnog ograničenja koje se uvodi fleksibilnom upravljačkom Ljapunovljevom funkcijom. Vrijednostima parametara za penalizaciju ($q_1 = 0,\ r_1 = 1,\ p_1 = 0$) postižu se slične performanse upravljanja kao i za simulirane vrijednosti ($q_1 = 1,\ r_1 = 100,\ p_1 = 1$). No, ključna razlika je u odabiru optimalnog vektora u slučaju da više od jednog vektora napona zadovoljava ograničenje fleksibilne upravljačke Ljapunovljeve funkcije te ima jednak broj sklapanja u odnosu na vektor napona iz prethodnog koraka. U navedenom slučaju, vrijednosti parametara ($q_1 = 1,\ r_1 = 100,\ p_1 = 1$) osiguravaju odabir onog vektora napona koji ujedno osigurava i najmanje regulacijsko odstupanje struje što vodi k manjem harmoničkom izobličenju.

Proračunom sklopne frekvencije i ukupnog harmoničkog izobličenja dobivene su sljedeće vrijednosti za simulirane slučajeve:

- $(q_1 = 1, r_1 = 0, p_1 = 1) \rightarrow f_{sw} = 2023$ Hz, $\mathrm{THD_i} = 5.02\%$,
- $(q_1 = 1, r_1 = 100, p_1 = 1) \rightarrow f_{sw} = 937$ Hz, $\mathrm{THD_i} = 8.97\%$.

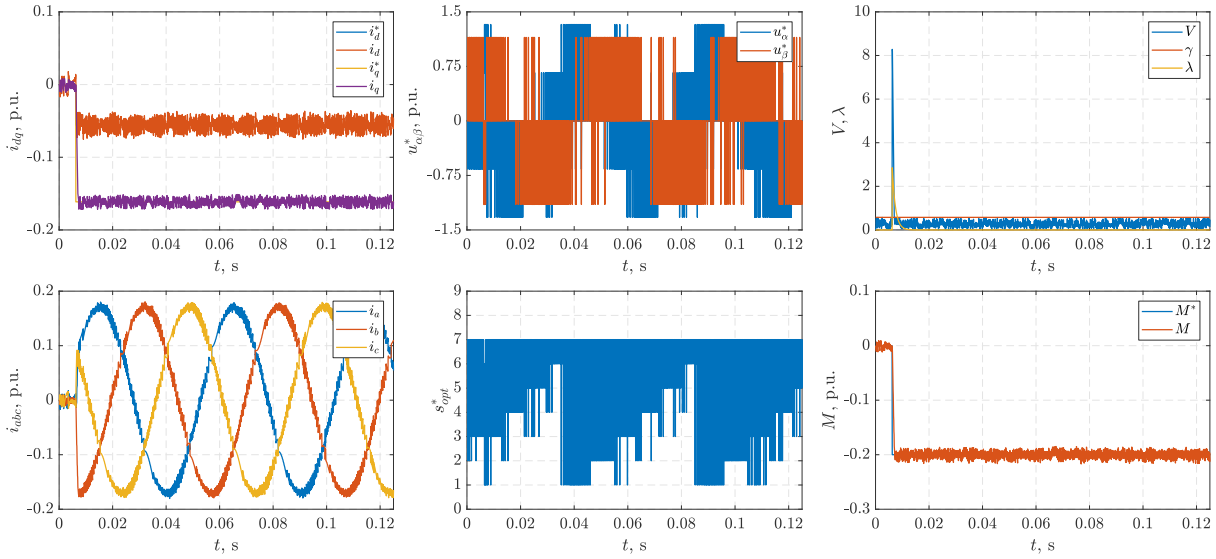

(a) MP-DCC algoritam s parametrima za penalizaciju u stacionarnom stanju ($q_1 = 1$, $r_1 = 0$, $p_1 = 1$)

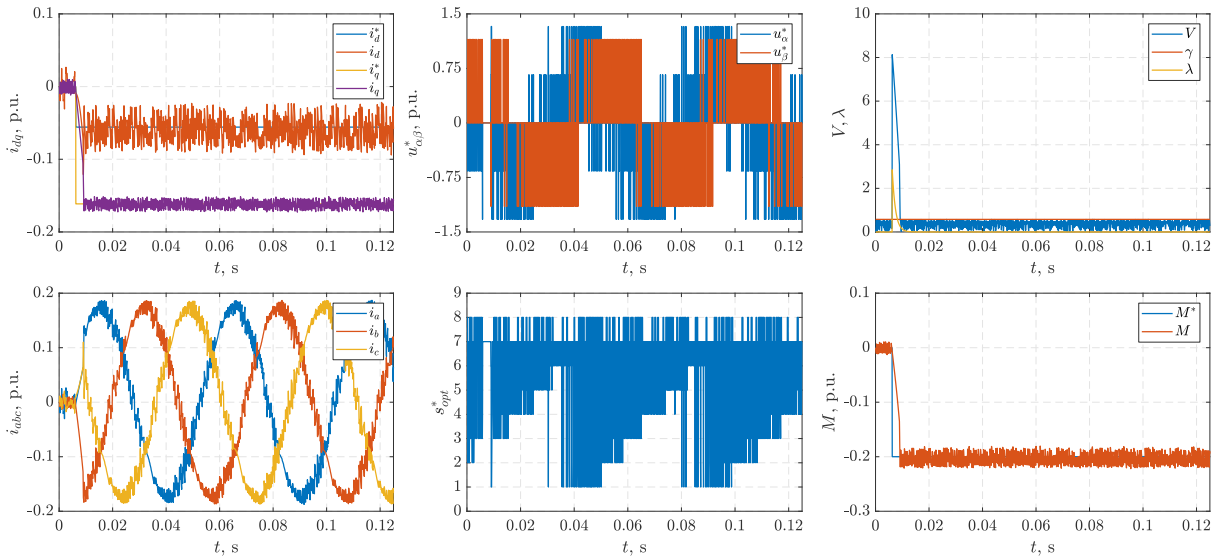

(b) MP-DCC algoritam s parametrima za penalizaciju u stacionarnom stanju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$)

Slika 5.11: Usporedba MP-DCC algoritma s različitim kombinacijama parametara za penalizaciju u stacionarnom stanju (q_1, r_1, p_1) za $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u.

Na slici 5.12 prikazana je skokovita promjena referentnog momenta s $M^* = -0.5$ p.u. na $M^* = -1.0$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. za MP-DCC algoritam temeljen na fleksibilnoj upravljačkoj Ljapunovljevoj funkciji s parametrima za penalizaciju ($q_0 = 1$, $r_0 = 10$, $p_0 = 1$, $q_1 = 1$, $r_1 = 100$, $p_1 = 1$). Simulacija je provedena za 2000 koraka uzorkovanja što je ekvivalentno vremenu $t = 0.125$ s. Proračunate su vrijednosti sklopne frekvencije i ukupnog harmoničkog izobličenja u obje radne točke s istim vrijednostima parametara za penalizaciju:

- $M^* = -0.5$ p.u. $\rightarrow f_{sw} = 1504$ Hz, $\text{THD}_\text{i} = 4.53\%$,
- $M^* = -1.0$ p.u. $\rightarrow f_{sw} = 1383$ Hz, $\text{THD}_\text{i} = 2.64\%$.

Iz priloženih vrijednosti može se zaključiti da je sklopna frekvencija s razvijenim algoritmom varijabilna te ovisi o radnoj točki, kao i harmoničko izobličenje struje. Osim radnom

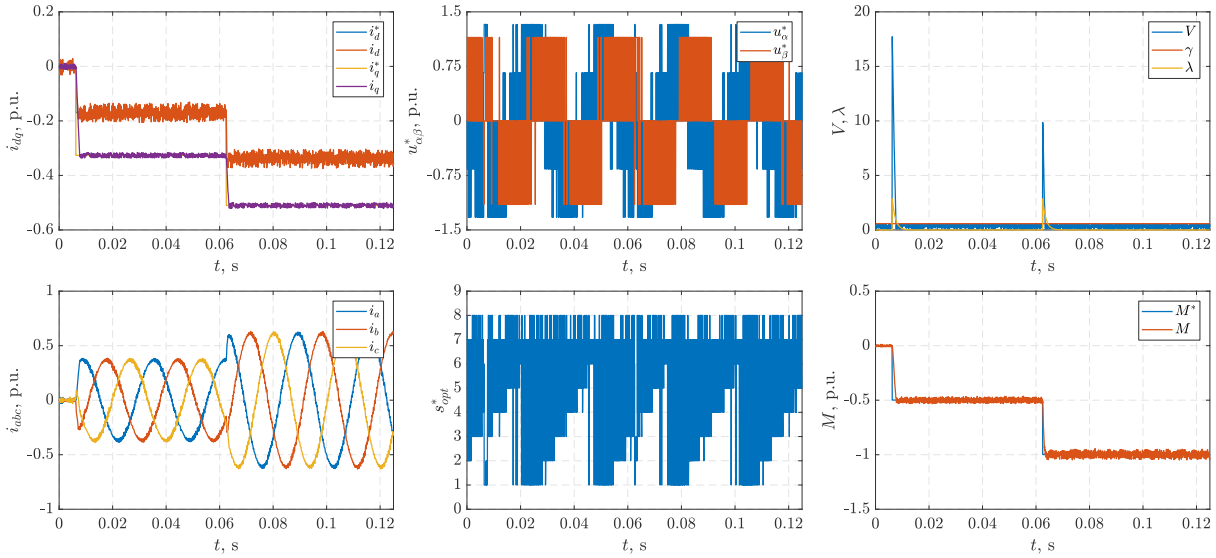

Slika 5.12: Skokovita promjena referentnog momenta s $M^* = -0.5$ p.u. na $M^* = -1.0$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. za MP-DCC algoritam temeljen na fleksibilnoj upravljačkoj Ljapunovljevoj funkciji

točkom i parametrima za penalizaciju, harmoničko izobličenje struje je uvjetovano parametrima generatora (ponajviše iznosima induktiviteta L_d i L_q), iznosom napona istosmjernog međukruga i frekvencijom izvođenja algoritma. U pravilu, povećanje referentne vrijednosti struje (uslijed porasta referentne vrijednosti momenta) vodi k manjem harmoničkom izobličenju te boljim performansama upravljanja. Osobito je problematično područje malih iznosa struje kada je harmoničko izobličenje veliko, čak i u slučaju odabira parametara za penalizaciju kojima se isključivo penalizira regulacijsko odstupanje struje.

Provedene su simulacije za četiri različite kombinacije vrijednosti parametara za penalizaciju u stacionarnom stanju (q_1, r_1, p_1) u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora

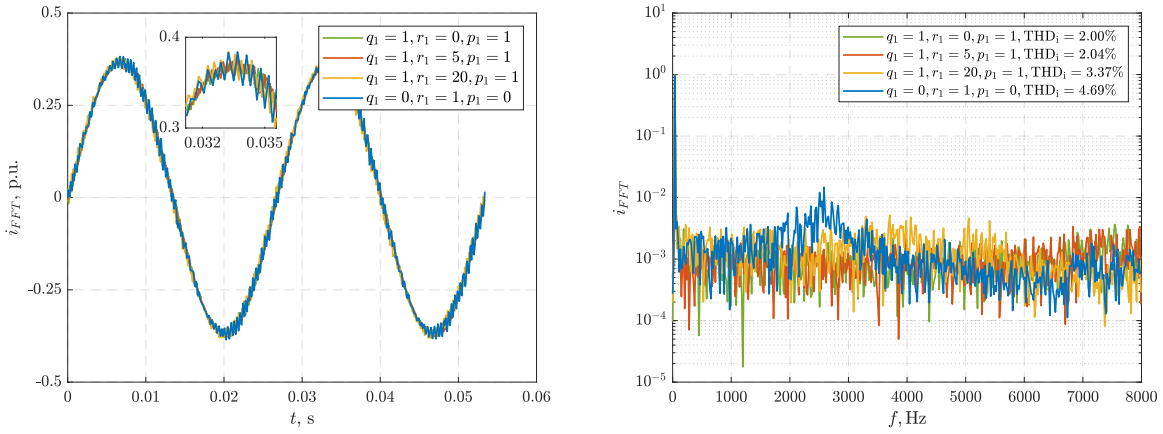

(a) Fazna struja

(b) Frekvencijski spektar

Slika 5.13: Frekvencijska analiza razvijenog MP-DCC algoritma u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u.

$\omega = 0.5$ p.u. Nad faznim strujama u mirujućem $\alpha\beta$ koordinatnom sustavu, prikazanim na slici 5.13a, provedena je frekvencijska analiza, točnije brza Fourierova transformacija, (engl. *fast Fourier transform*, FFT) te je dobiveni frekvencijski spektar prikazan na slici 5.13b. Kao što je navedeno i ranije u tekstu, povećanjem vrijednosti parametra za penalizaciju promjene vektora napona odnosno sklopnog stanja (r_1), očekivano dolazi do povećanog harmoničkog izobličenja i oscilacija struje oko referentne vrijednosti (engl. *current ripple*). Najveće harmoničko izobličenje, tj. najveći udio viših harmonika je prisutan za kombinaciju vrijednosti parametara ($q_1 = 0$, $r_1 = 1$, $p_1 = 0$), dok je najmanje harmoničko izobličenje za kombinaciju vrijednosti parametara ($q_1 = 1$, $r_1 = 0$, $p_1 = 1$).

Proračunate vrijednosti sklopne frekvencije i ukupnog harmoničkog izobličenja za prikazane te dodatne kombinacije vrijednosti parametara (q_1, r_1, p_1) u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. su prikazane u tablici 5.2. U [130] razvijen je jedan od prvih FCS-MPC algoritama primijenjenih na dvorazinske pretvarače s kriterijskom funkcijom kojom se penalizira samo regulacijsko odstupanje struje. Navedeni algoritam (uz dodatak fleksibilne upravljačke Ljapunovljeve funkcije) predstavlja specijalan slučaj razvijenog MP-DCC algoritma kada se u stacionarnom stanju penalizira samo regulacijsko odstupanje struje ($q_1 = 1$, $r_1 = 0$, $p_1 = 1$). Važno je uočiti da već malim povećanjem iznosa parametra za penalizaciju promjene vektora napona ($r_1 = 5$) dolazi do značajnog smanjenja sklopne frekvencije (4048 Hz $\rightarrow$ 3249 Hz) uz zanemarivo povećanje ukupnog harmoničkog izobličenja (2.00 % $\rightarrow$ 2.08 %).

Tablica 5.2: Sklopna frekvencija i ukupno harmoničko izobličenje za različite vrijednosti parametara za penalizaciju u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u.

Algorithm	f_{sw} [Hz]	THD$_i$ [%]
Praćenje referentne vrijednosti struje [130]	4048	2.00
MP-DCC algoritam s fleksibilnom upravljačkom Ljapunovljevom funkcijom ($q_1 = 1$, $r_1 = 0$, $p_1 = 1$)	4048	2.00
MP-DCC algoritam s fleksibilnom upravljačkom Ljapunovljevom funkcijom ($q_1 = 1$, $r_1 = 5$, $p_1 = 1$)	3249	2.08
MP-DCC algoritam s fleksibilnom upravljačkom Ljapunovljevom funkcijom ($q_1 = 1$, $r_1 = 10$, $p_1 = 1$)	2704	2.23
MP-DCC algoritam s fleksibilnom upravljačkom Ljapunovljevom funkcijom ($q_1 = 1$, $r_1 = 15$, $p_1 = 1$)	2062	2.91
MP-DCC algoritam s fleksibilnom upravljačkom Ljapunovljevom funkcijom ($q_1 = 1$, $r_1 = 20$, $p_1 = 1$)	1822	3.48
MP-DCC algoritam s fleksibilnom upravljačkom Ljapunovljevom funkcijom ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$)	1538	4.53
MP-DCC algoritam s fleksibilnom upravljačkom Ljapunovljevom funkcijom ($q_1 = 0$, $r_1 = 1$, $p_1 = 0$)	1563	4.64

Daljnjim povećanjem vrijednosti parametra r_1 dolazi do drastičnog opadanja sklopne frekvencije, ali i porasta ukupnog harmoničkog izobličenja. Kao što je navedeno ranije u tekstu, kombinacije vrijednosti parametara ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) i ($q_1 = 0$, $r_1 = 1$, $p_1 = 0$) osiguravaju isključivo penalizaciju promjene vektora napona u stacionarnom stanju zbog relativnog odnosa vrijednosti parametra r_1 spram q_1 i p_1. Prema proračunatim iznosima sklopne frekvencije i ukupnog harmoničkog izobličenja slijedi da kombinacija vrijednosti parametara ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) osigurava manje sklopne gubitke te manje harmoničko izobličenje struje u usporedbi s kombinacijom vrijednosti parametara ($q_1 = 0$, $r_1 = 1$, $p_1 = 0$) stoga ju je uputno koristiti u slučaju da je prioritet minimizacija sklopne frekvencije.

Na slici 5.14 prikazana je usporedba sklopne frekvencije i ukupnog harmoničkog izobličenja za različite kombinacije vrijednosti parametara za penalizaciju u stacionarnom stanju (q_1, r_1, p_1) u čitavom radnom području generatora (ovisnost navedenih veličina o momentu i brzini rotora). Priloženi grafovi potvrđuju ranije navedenu činjenicu da uključenje penalizacije promjene vektora napona u stacionarnom stanju čak i s malim iznosom ($r_1 = 5$) dovodi do značajnog smanjenja sklopne frekvencije uz zanemariv porast ukupnog harmoničkog izobličenja. Promjenom momenta i brzine rotora dolazi do promjene sklopne frekvencije, no trend navedene promjene nije jednoznačan te ovisi o kombinaciji vrijednosti parametara za penalizaciju. Također se može uočiti da kombinacije vrijednosti parametara gdje je penalizacija regulacijskog odstupanja struje dominantnija nad penalizacijom promjene vektora napona pokazuju veće promjene u sklopnoj frekvenciji promjenom radne točke. S druge strane, porast momenta odnosno iznosa amplitude struje u pravilu uzrokuje smanjenje ukupnog harmoničkog izobličenja struje.

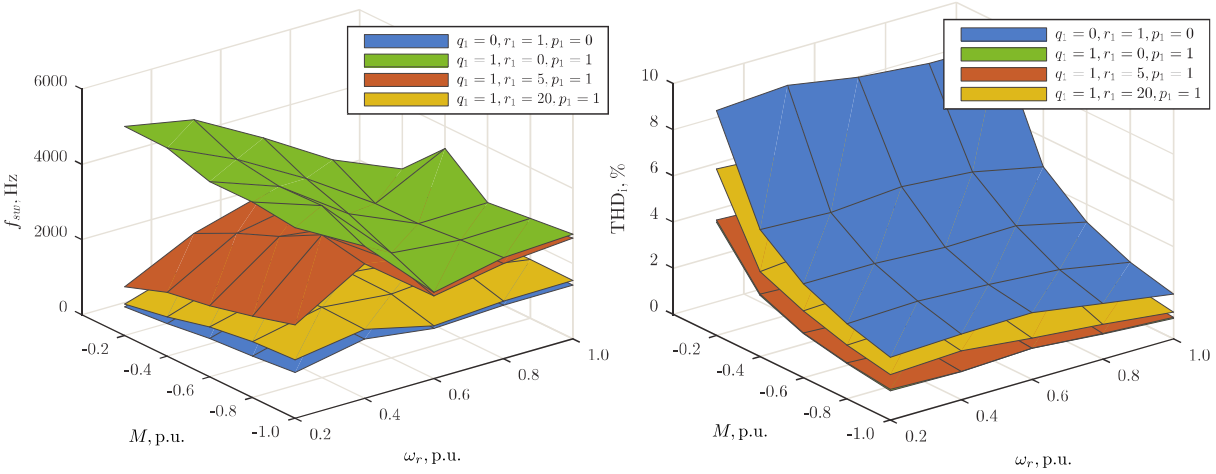

(a) Sklopna frekvencija

(b) Ukupno harmoničko izobličenje

Slika 5.14: Usporedba sklopne frekvencije i ukupnog harmoničkog izobličenja za različite kombinacije vrijednosti parametara za penalizaciju u stacionarnom stanju (q_1, r_1, p_1) u čitavom radnom području generatora

5.4.5. Analiza utjecaja mrtvog vremena generatorskog pretvarača

Na slikama 5.15 i 5.16 prikazana je usporedba MP-DCC algoritma s fleksibilnom upravljačkom Ljapunovljevom funkcijom te parametrima za penalizaciju ($q_1 = 1$, $r_1 = 0$, $p_1 = 1$) i ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u. kada se mrtvo vrijeme generatorskog pretvarača $T_{dt} = 4\ \mu$s uzima u obzir prilikom sinteze MPC regulatora te kada se zanemaruje. Simulacije su provedene za 2000 koraka uzorkovanja što je ekvivalentno vremenu $t = 0.125$ s. U slučaju da se mrtvo vrijeme uzima u obzir, koristi se prošireni model sustava koji osim modela sinkronog generatora sa stalnim magnetima uključuje i mrtvo vrijeme pretvarača prema izrazu (5.31) te se vrijednost opadanja upravljačke Ljapunovljeve funkcije $b(k)$ računa prema izrazu (5.53).

Proračunate vrijednosti sklopne frekvencije i ukupnog harmoničkog izobličenja struje uz vrijednosti parametara za penalizaciju ($q_1 = 1$, $r_1 = 0$, $p_1 = 1$) su jednake:

– bez mrtvog vremena $T_{dt} \rightarrow f_{sw} = 2007$ Hz, $\text{THD}_\text{i} = 5.10\%$,

– s mrtvim vremenom $T_{dt} \rightarrow f_{sw} = 5521$ Hz, $\text{THD}_\text{i} = 4.89\%$.

Iz priloženih vrijednosti se može uočiti da se uzimanjem u obzir mrtvog vremena neznatno smanjuje ukupno harmoničko izobličenje struje, dok dolazi do značajnog porasta sklopne frekvencije. Naime, uzimanjem u obzir mrtvog vremena algoritam uzima u obzir vektor napona koji je aktivan tijekom mrtvog vremena odnosno promjenu struje unutar navedenog perioda te

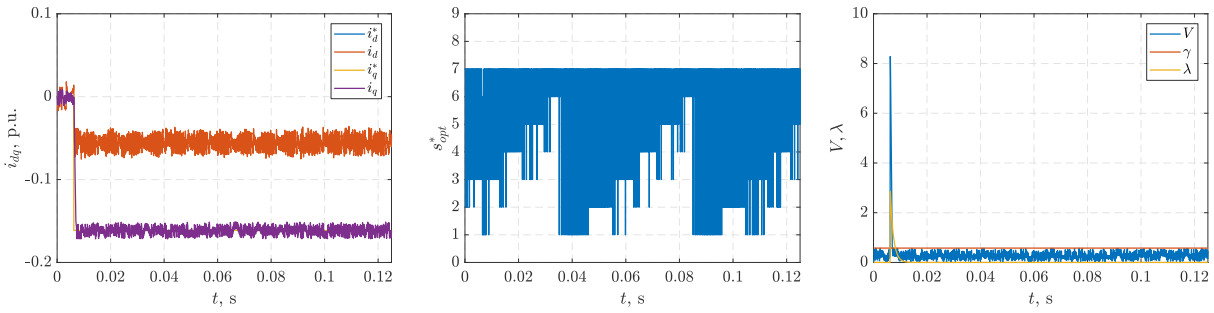

(a) MP-DCC algoritam bez uzimanja u obzir mrtvog vremena generatorskog pretvarača

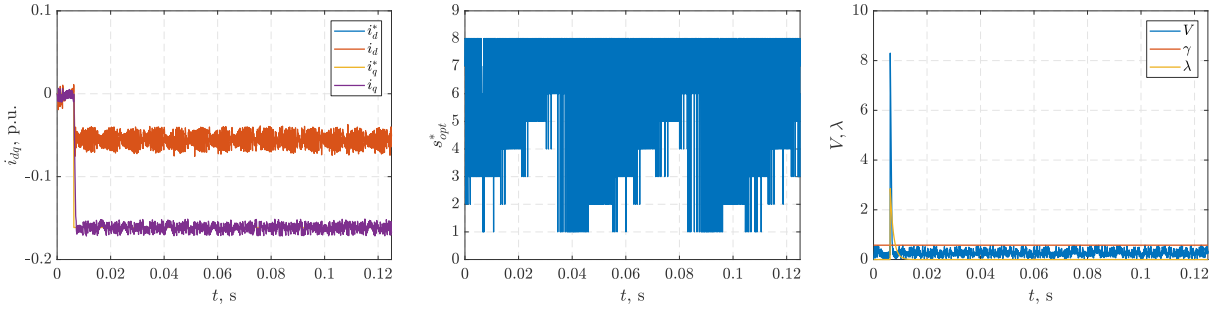

(b) MP-DCC algoritam s uzimanjem u obzir mrtvog vremena generatorskog pretvarača

Slika 5.15: Usporedba MP-DCC algoritma s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 0$, $p_1 = 1$) u radnoj točki $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u. bez uzimanja i s uzimanjem u obzir mrtvog vremena generatorskog pretvarača

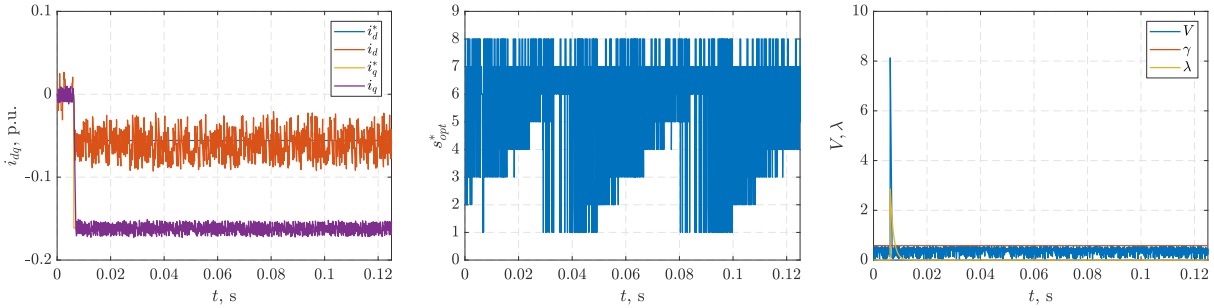

(a) MP-DCC algoritam bez uzimanja u obzir mrtvog vremena generatorskog pretvarača

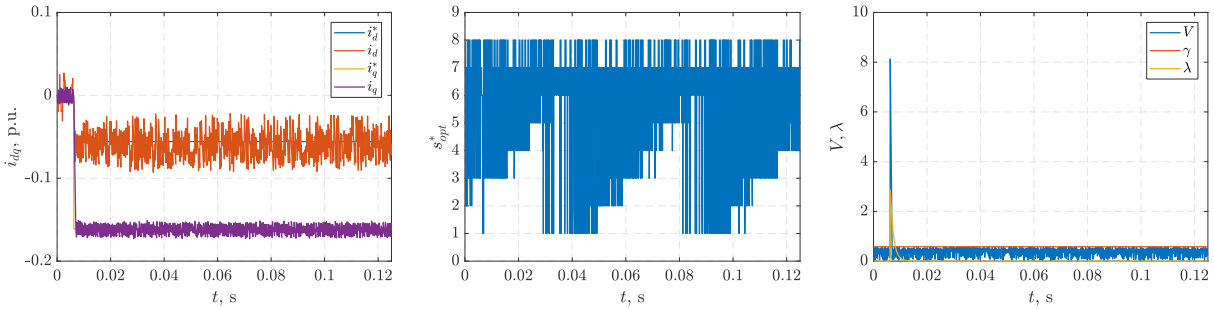

(b) MP-DCC algoritam s uzimanjem u obzir mrtvog vremena generatorskog pretvarača

Slika 5.16: Usporedba MP-DCC algoritma s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u. bez uzimanja i s uzimanjem u obzir mrtvog vremena generatorskog pretvarača

kao optimalan vektor proglašava onaj kojim se minimizira regulacijsko odstupanje struje. U velikom broju trenutaka uzorkovanja radi se o vektoru napona kojim je potrebno ostvariti dva ili tri sklapanja što u konačnici vodi k velikoj sklopnoj frekvenciji.

Proračunate vrijednosti sklopne frekvencije i ukupnog harmoničkog izobličenja struje uz vrijednosti parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) su jednake:

- bez mrtvog vremena $T_{dt} \rightarrow f_{sw} = 978$ Hz, $\text{THD}_\text{i} = 9.16\%$,
- s mrtvim vremenom $T_{dt} \rightarrow f_{sw} = 962$ Hz, $\text{THD}_\text{i} = 8.96\%$.

Iz priloženih vrijednosti se može uočiti da uzimanjem u obzir mrtvog vremena dolazi do neznatnog smanjenja sklopne frekvencije, uz istovremeno smanjenje harmoničkog izobličenja struje. Navedena pojava je posljedica točnijeg modela sustava što rezultira ispravnim odabirom optimalnog vektora napona kojim se minimiziraju sklopni gubici uz zadržavanje struje unutar upravljačkog invarijantnog skupa. No, budući da je mrtvo vrijeme pretvarača malog iznosa u usporedbi s vremenom uzorkovanja ($T_{dt} = 4\ \mu$s, $T_s = 62.5\ \mu$s $\rightarrow T_{dt} = 0.064 \cdot T_s$), ne dolazi do značajnijeg poboljšanja performansi u usporedbi sa slučajem kada se mrtvo vrijeme ne uzima u obzir.

Na slici 5.17 prikazana je usporedba MP-DCC algoritma s fleksibilnom upravljačkom Ljapunovljevom funkcijom te parametrima za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u. kada se znatno uvećano mrtvo vrijeme generatorskog pretvarača $T_{dt} = \frac{T_s}{2}$ uzima u obzir prilikom sinteze MPC regulatora te kada se

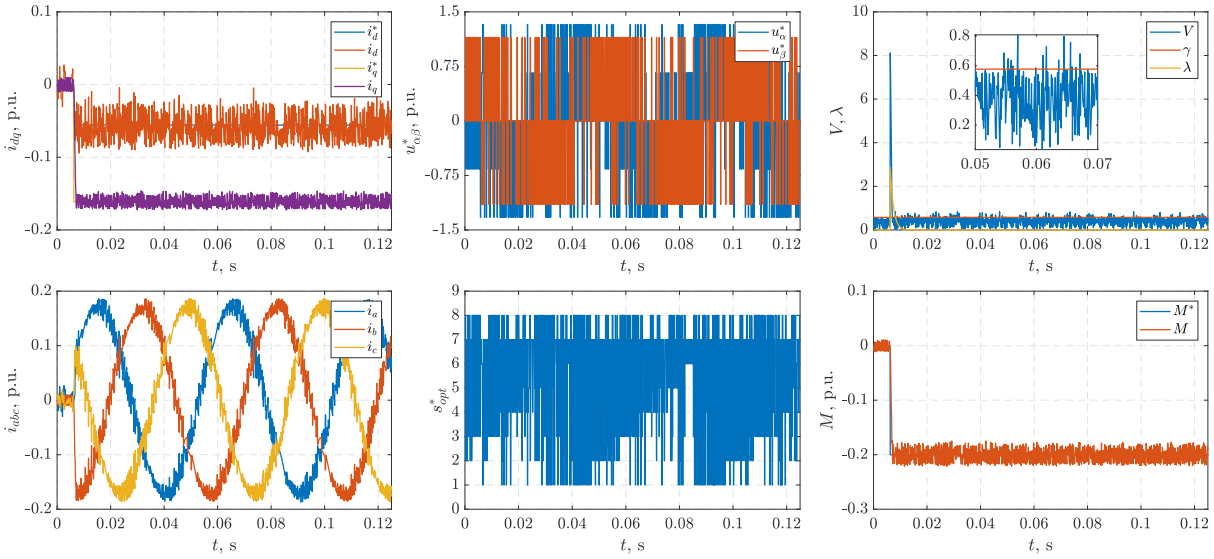

(a) MP-DCC algoritam bez uzimanja u obzir mrtvog vremena generatorskog pretvarača

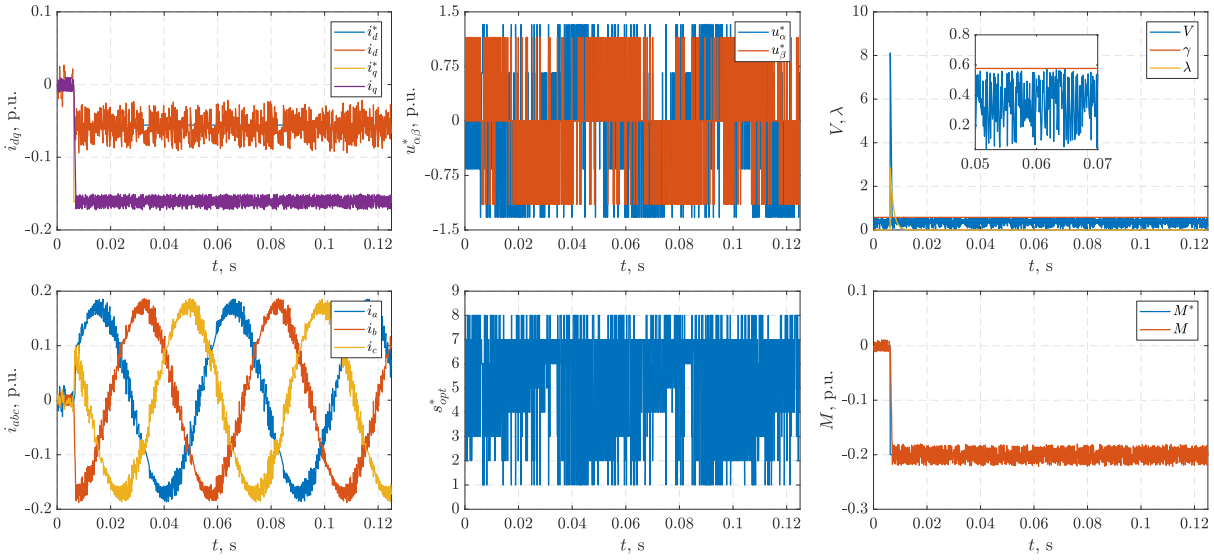

(b) MP-DCC algoritam s uzimanjem u obzir mrtvog vremena generatorskog pretvarača

Slika 5.17: Usporedba MP-DCC algoritma s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u. bez uzimanja i s uzimanjem u obzir znatno uvećanog mrtvog vremena generatorskog pretvarača $T_{dt} = \frac{T_s}{2}$

zanemaruje. Simulacije su provedene za 2000 koraka uzorkovanja što je ekvivalentno vremenu $t = 0.125$ s. Proračunate vrijednosti sklopne frekvencije i ukupnog harmoničkog izobličenja struje uz vrijednosti parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) uz uvećan iznos mrtvog vremena su jednake:

– bez mrtvog vremena $T_{dt} \rightarrow f_{sw} = 1376$ Hz, $\text{THD}_\text{i} = 9.79\%$,

– s mrtvim vremenom $T_{dt} \rightarrow f_{sw} = 1305$ Hz, $\text{THD}_\text{i} = 8.65\%$.

Iz priloženih vrijednosti kao i odziva može se zaključiti da relativnim povećanjem iznosa mrtvog vremena u odnosu na vrijeme uzorkovanja te zanemarivanjem mrtvog vremena u algoritmu dolazi do učestalog kršenja ograničenja definiranog upravljačkom Ljapunovljevom funkcijom

što dovodi do povećanih oscilacija struje, a time i momenta. No, uzimanjem u obzir mrtvog vremena u algoritmu uslijed korištenja ispravnog modela ne dolazi do kršenja ograničenja što rezultira manjom sklopnom frekvencijom, ali i manjim harmoničkim izobličenjem struje.

5.4.6. Analiza utjecaja promjene vrijednosti parametara generatora

Na slikama 5.18, 5.19, 5.20 i 5.21 prikazani su odzivi MP-DCC algoritma s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u., uz pogrešne vrijednosti parametara generatora (50% i 200% nominalnih vrijednosti) u predikcijskom modelu. Simulacije su provedene za 2000 koraka uzorkovanja što je ekvivalentno vremenu $t = 0.125$ s. Proračunate vrijednosti sklopne frekvencije i ukupnog harmoničkog izobličenja za simulirane slučajeve prikazane su u tablici 5.3.

Pogrešna vrijednost otpora statora R_s ne utječe značajnije na performanse upravljanja razvijenog algoritma. Naime, u slučaju generatora velikih snaga vrijednost otpora statora zbog malog iznosa obično nema značajniji utjecaj na predikcijski model stoga vrijednosti sklopne frekvencije i ukupnog harmoničkog izobličenja ne odudaraju značajnije od vrijednosti kada se u predikcijskom modelu koristi nominalna vrijednost otpora statora.

U usporedbi s otporom statora R_s, pogrešne vrijednosti induktiviteta L_d i L_q imaju značajan utjecaj na performanse upravljanja. Ako se u predikcijskom algoritmu koriste manje vrijednosti

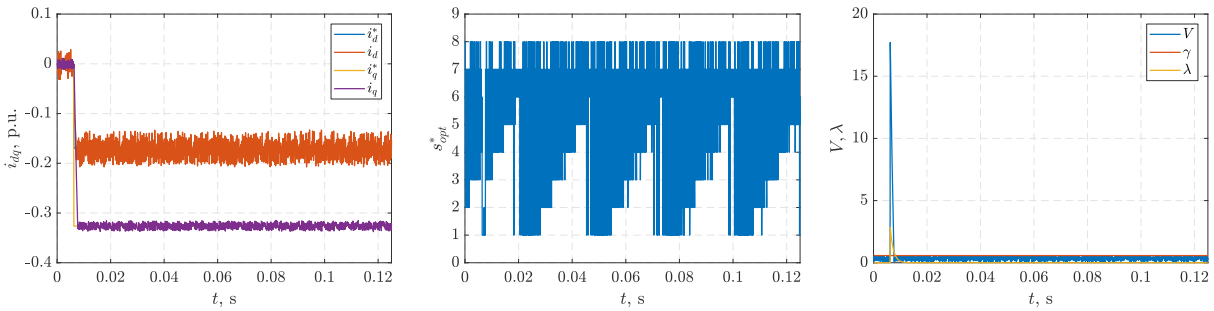

(a) MP-DCC algoritam s vrijednosti otpora statora $R_s^{MPC} = 0.5R_s$

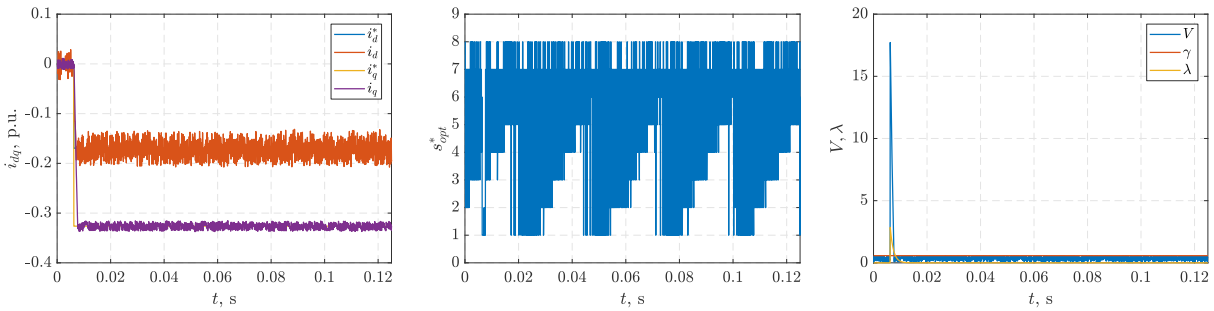

(b) MP-DCC algoritam s vrijednosti otpora statora $R_s^{MPC} = 2R_s$

Slika 5.18: MP-DCC algoritam s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. s pogrešnim vrijednostima otpora statora R_s u predikcijskom modelu

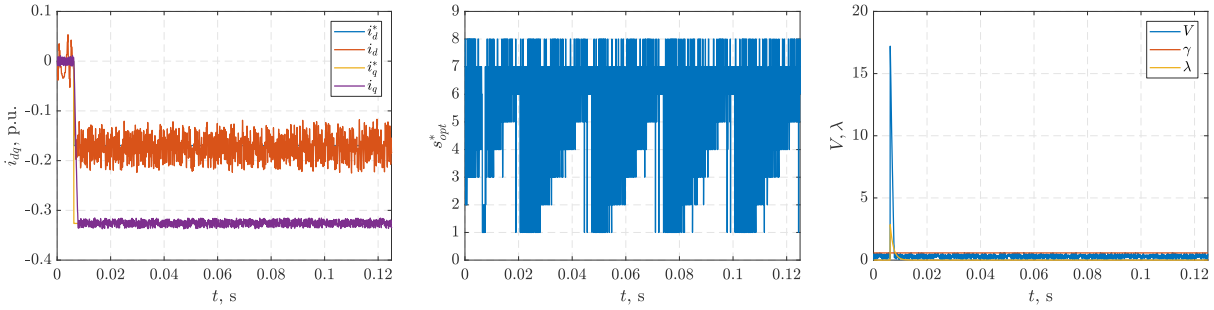

(a) MP-DCC algoritam s vrijednosti induktiviteta $L_d^{MPC} = 0.5L_d$

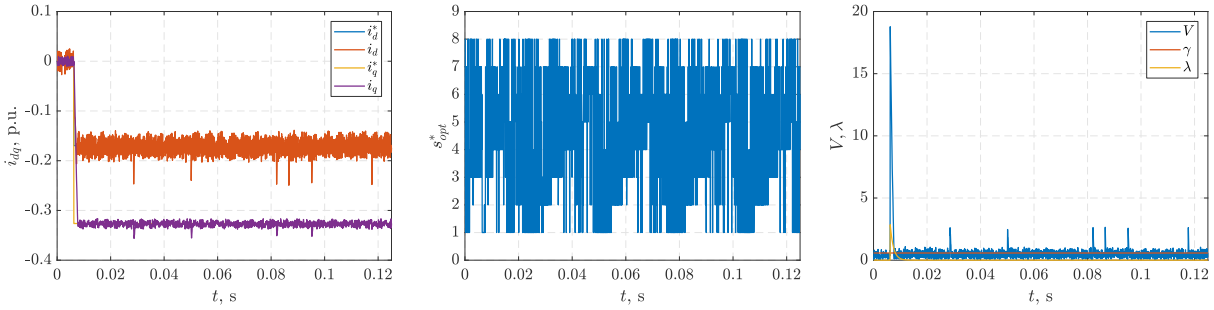

(b) MP-DCC algoritam s vrijednosti induktiviteta $L_d^{MPC} = 2L_d$

Slika 5.19: MP-DCC algoritam s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. s pogrešnim vrijednostima induktiviteta L_d u predikcijskom modelu

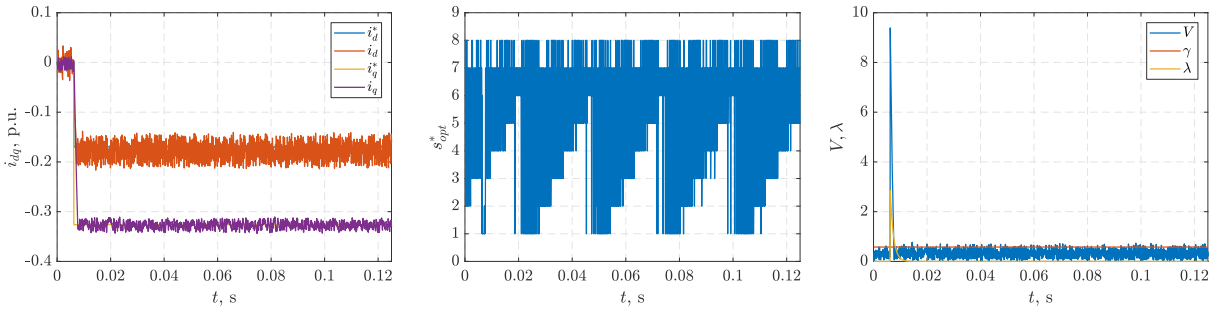

(a) MP-DCC algoritam s vrijednosti induktiviteta $L_q^{MPC} = 0.5L_q$

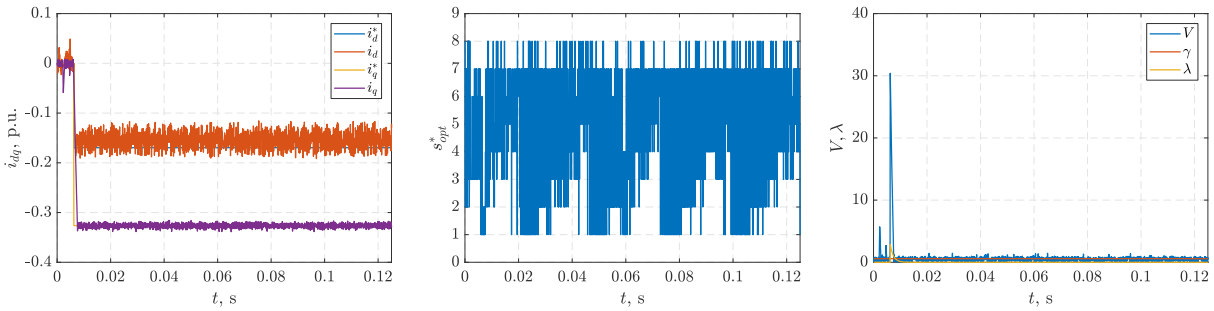

(b) MP-DCC algoritam s vrijednosti induktiviteta $L_q^{MPC} = 2L_q$

Slika 5.20: MP-DCC algoritam s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. s pogrešnim vrijednostima induktiviteta L_q u predikcijskom modelu

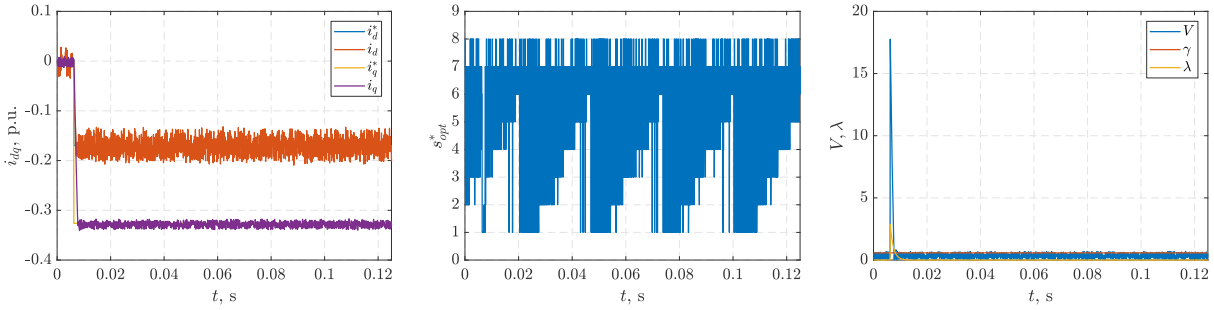

(a) MP-DCC algoritam s vrijednosti magnetskog toka stalnih magneta $\psi_{md}^{MPC} = 0.5\psi_{md}$

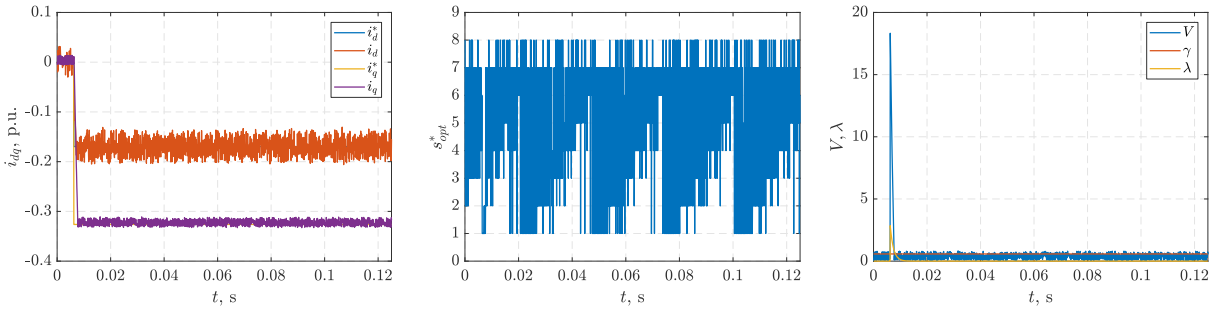

(b) MP-DCC algoritam s vrijednosti magnetskog toka stalnih magneta $\psi_{md}^{MPC} = 2\psi_{md}$

Slika 5.21: MP-DCC algoritam s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. s pogrešnim vrijednostima magnetskog toka stalnih magneta ψ_{md} u predikcijskom modelu

induktiviteta (50%) od nominalnih vrijednosti, dolazi do manje sklopne frekvencije i većeg harmoničkog izobličenja struje. U suprotnom slučaju, kada se koriste veće vrijednosti induktiviteta (200%) od nominalnih, dolazi do značajnog povećanja sklopne frekvencije te smanjenja ukupnog harmoničkog izobličenja. Promatrajući iznos upravljačke Ljapunovljeve funkcije, može se

Tablica 5.3: Sklopna frekvencija i ukupno harmoničko izobličenje za različite vrijednosti parametara za penalizaciju u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u.

Varijacija vrijednosti parametara	f_{sw} [Hz]	THD_i [%]
nominalne vrijednosti	**1549**	**4.55**
$R_s^{MPC} = 0.5R_s$	1526	4.61
$R_s^{MPC} = 2R_s$	1541	4.53
$L_d^{MPC} = 0.5L_d$	1330	5.85
$L_d^{MPC} = 2L_d$	2786	3.74
$L_q^{MPC} = 0.5L_q$	1261	4.62
$L_q^{MPC} = 2L_q$	2500	4.05
$\psi_{md}^{MPC} = 0.5\psi_{md}$	1597	4.32
$\psi_{md}^{MPC} = 2\psi_{md}$	1905	4.21

uočiti da slučajevi s dvostrukom većim iznosom induktiviteta u predikcijskom modelu od stvarnog uzrokuju česta kršenja ograničenja, a u nekim slučajevima i neželjene oscilacije u odzivu struje. No, unatoč narušenim performansama upravljanja, stabilnost algoritma nije narušena.

Pogrešna vrijednost magnetskog toka uzrokuje veću sklopnu frekvenciju te nešto manje ukupno harmoničko izobličenje struje. No, u usporedbi s induktivitetima L_d i L_q pogrešna vrijednost magnetskog toka ne utječe značajnije na performanse upravljanja.

5.5. Eskperimentalni rezultati

Opisani MP-DCC algoritam temeljen na fleksibilnoj upravljačkoj Ljapunovljevoj funkciji implementiran je u digitalni sustav upravljanja temeljen na ADSP-21992 mikroprocesoru korištenjem programskog alata *AlgoCAD* te potom provjeren na laboratorijskom postavu koji je opisan u poglavlju 3. Najvažniji podaci laboratorijskog postava koji se sastoji od sinkronog generatora sa stalnim magnetima, AC-DC-AC pretvarača i asinkronog motora koji emulira rad vjetroturbine ponovljeni su u nastavku:

PMG: Tema LPMR-450, $P_n = 375$ kW, $E_n = 400$ V, $I_n = 596$ A, $f_n = 75$ Hz, $n_n = 1500$ rpm.
AC-DC-AC pretvarač: Končar KONvert W1500, $P_n = 520$ kW, $U_n = 400$ V, $I_n = 750$ A, $U_{dc} = 650$ V.
AM: Končar 8AZJ 405-04, $P_n = 560$ kW, $U_n = 400$ V, $I_n = 967$ A, $f_n = 50$ Hz, $n_n = 1490$ rpm, $\cos\varphi_n = 0.87$.
Bazne vrijednosti: $U_b = 326$ V, $I_b = 843$ A, $f_b = 75$ Hz, $n_{rb} = 1500$ okr/min, $\omega_{rb} = 471$ rad/s, $M_b = 2389$ Nm, $Z_b = 0.39\ \Omega$, $L_b = 0.83$ mH, $\psi_b = 0.69$ Wb.

Razvijeni algoritam implementiran je na frekvenciji uzorkovanja $f_s = 16$ kHz (prekidna rutina MID1000 u programskom alatu *AlgoCAD*). Kao što je navedeno ranije u tekstu, razvijeni algoritam pripada skupini FCS-MPC algoritama (specifično MP-DCC algoritmima) koji u pravilu zahtijevaju znatno višu frekvenciju izvođenja u usporedbi da bi se postiglo prihvatljivo harmoničko izobličenje struje u usporedbi sa standardnim algoritmima. Navedena frekvencija izvođenja algoritma odabrana je uzimajući u obzir složenost razvijenog algoritma te ograničenja računalnih resursa digitalnog sustava upravljanja, uz očuvanje zadovoljavajućih performansi upravljanja algoritma. Osim samog algoritma upravljanja, zaštitne funkcije generatorskog pretvarača implementirane su na frekvenciji uzorkovanja $f_s = 32$ kHz, dok je proračun konstanti algoritma implementiran na frekvenciji uzorkovanja $f_s = 25$ Hz.

U nastavku je prikazana metodologija kompenzacije jednog ciklusa kašnjenja digitalnog sustava, eksperimentalni odzivi uključenja generatorskog pretvarača s razvijenim algoritmom pri različitim brzinama, usporedba eksperimentalnih odziva s i bez kompenzacije ciklusa kašnjenja digitalnog sustava te eksperimentalni odzivi razvijenog algoritma s različitim vrijednostima parametara za penalizaciju. Eksperimenti s i bez kompenzacije ciklusa kašnjenja digitalnog sustava provedeni su u trajanju 0.0313 s, a preostali eksperimenti u trajanju 0.155 s. U programskom alatu *r_parnad* definirano je snimanje varijabli digitalnog sustava u 500 točaka unutar definiranog vremenskog okvira koji odgovara trajanju eksperimenta.

5.5.1. Kompenzacija kašnjenja ciklusa digitalnog sustava

Potreba za kompenzacijom kašnjenja digitalnog sustava prilikom implementacije FCS-MPC algoritama je otprije poznata u znanstvenoj literaturi. Uobičajeno se na početku svakog perioda uzorkovanja mjeri struja, proračunava se predikcija budućih vrijednosti struje i vrijednost kriterijske funkcije za svaki vektor napona te se vektor napona s najmanjim iznosom kriterijske funkcije (optimalni vektor napona) primjenjuje na kraju perioda uzorkovanja. U slučaju razvijenog algoritma predikcija vrijednosti struje u narednom koraku uzorkovanja $\boldsymbol{x}(k+1)$ na temelju mjerene vrijednosti struje u trenutnom koraku $\boldsymbol{x}(k)$ može se zapisati ranije izvedenim izrazom:

$$\boldsymbol{x}(k+1) = f(\boldsymbol{x}(k), \boldsymbol{u}(k), \boldsymbol{\theta}_{re}(k), \boldsymbol{\omega}_{re}(k)), \tag{5.55}$$

gdje je funkcijom f opisana dinamika sustava. No, proračun optimalnog vektora napona nije trenutan u digitalnom sustavu, već traje određeni period ovisno o računalnoj složenosti algoritma. Iz navedenog razloga, struja na kraju perioda uzorkovanja, tj. u trenutku primjene optimalnog vektora napona više nije jednaka struji na početku perioda uzorkovanja čiji se iznos koristi prilikom predikcije. Ako se navedeno kašnjenje digitalnog sustava ne kompenzira odgovarajućom metodom, dolazi do povećanja harmoničkog izobličenja struje te narušavanja performansi algoritma upravljanja.

Standardan način kompenzacije kašnjenja digitalnog sustava u sustavima upravljanja temeljenim na FCS-MPC algoritmima opisan je u [131]. Primjena navedene metode kompenzacije kašnjenja ciklusa digitalnog sustava na razvijeni algoritam prikazana je na slici 5.22. Nakon mjerenja struje na početku perioda uzorkovanja primjenjuje se optimalni vektor proračunat u prošlom periodu uzorkovanja $\boldsymbol{u}^*_{opt}(k)$. Potom se proračunava vrijednost struje na kraju perioda na temelju matematičkog modela sustava i primijenjenog optimalnog vektora napona proračunatog u prethodnom periodu sljedećim izrazom:

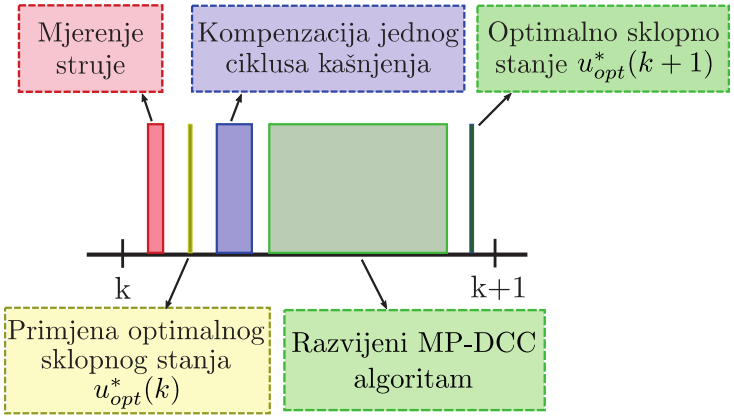

Slika 5.22: Kompenzacija kašnjenja jednog ciklusa izvođenja algoritma u digitalnom sustavu

$$\boldsymbol{x}(k+1) = f(\boldsymbol{x}(k), \boldsymbol{u}^*_{opt}(k), \theta_{re}(k), \omega_{re}(k)). \tag{5.56}$$

Proračunata vrijednost na kraju perioda k, tj. na početku perioda $k+1$ $\boldsymbol{x}(k+1)$, koristi se za predikciju vrijednosti struja na kraju $k+1$ perioda za svaki od vektora napona $\boldsymbol{u}(k+1)$:

$$\boldsymbol{x}(k+2) = f(\boldsymbol{x}(k+1), \boldsymbol{u}(k+1), \theta_{re}(k+1), \omega_{re}(k)). \tag{5.57}$$

Za svaki od vektora napona proračunava se kriterijska funkcija te se proračunati optimalni vektor napona $\boldsymbol{u}^*_{opt}(k+1)$ primjenjuje na početku narednog perioda uzorkovanja, točnije neposredno nakon uzorkovanja struje. Pretpostavka je da se zbog velikog momenta inercije sustava brzina rotora ω_{re} može smatrati nepromjenjivog između dva ciklusa uzorkovanja, dok se promjena kuta rotora može proračunati prema izrazu (5.22). Primjenom opisane metode kompenzacije kašnjenja digitalnog sustava smanjuje se harmoničko izobličenje struje te dolazi do poboljšanja performansi upravljanja. Također, budući da se optimalni vektor primjenjuje nakon mjerenja struje izbjegavaju se prijelazne pojave u uzorku struje koje se pojavljuju prilikom promjene sklopnog stanja.

5.5.2. Uključenje generatorskog pretvarača uz razvijeni MP-DCC algoritam

Na slici 5.23 prikazano je uključenje generatorskog pretvarača (leteći start) pri brzinama $\omega_r = 0.266$ p.u. i $\omega_r = 0.33$ p.u. uz razvijeni MP-DCC algoritam u trenutku $t = 0.01$ s.

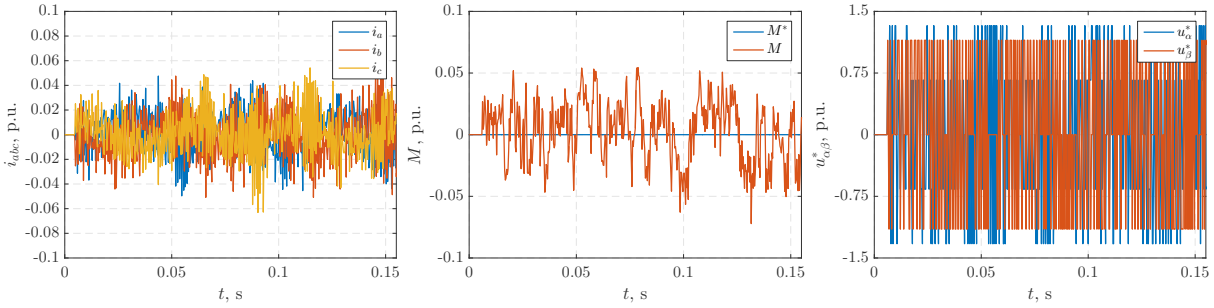

(a) Uključenje generatorskog pretvarača pri brzini rotora $\omega_r = 0.266$ p.u.

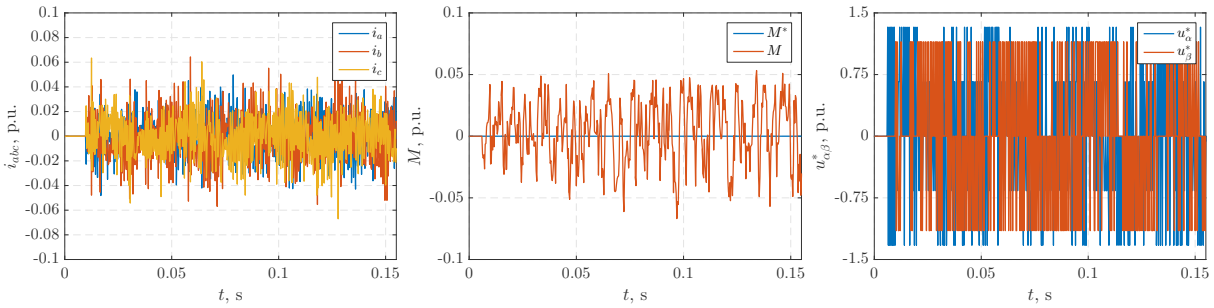

(b) Uključenje generatorskog pretvarača pri brzini rotora $\omega_r = 0.33$ p.u.

Slika 5.23: Uključenje generatorskog pretvarača uz razvijeni MP-DCC algoritam

Prikazani su odzivi mjerene struje $\boldsymbol{i}_{abc}$, referentne M^* i proračunate M vrijednosti elektromagnetskog momenta i referentnog vektora napona $\boldsymbol{u}^*_{\alpha\beta}$.

U trenutku $t = 0.01$ s dolazi do uključenja generatorskog pretvarača pri brzinama rotora $\omega_r = 0.266$ p.u. ($n_r = 400$ okr/min) i $\omega_r = 0.33$ p.u. ($n_r = 500$ okr/min) te u navedenom trenutku započinje djelovanje implementiranog MP-DCC algoritma upravljanja. Prilikom uključenja primijenjen je nul-vektor U_0 (sklopno stanje 000) da bi se smanjio porast struje u trenutku uklopa. Iz priloženih odziva može se zaključiti da je porast struje i udarac momenta tijekom uključenja generatorskog pretvarača prihvatljiv te struja u praznom hodu ne prelazi vrijednost $\boldsymbol{i}_{abc} \approx 0.06$ p.u..

Standardni algoritmi vektorskog upravljanja temeljeni na PI regulatoru i nekoj od inačica PWM-a zahtijevaju poznavanje induciranog napona, brzine i kuta rotora prije samog uključenja generatorskog pretvarača da bi se uspješno ostvario leteći start, tj. spriječio značajan porast struje prilikom uklopa. S druge strane, razvijeni MP-DCC algoritam ima značajno naprednije dinamičke performanse u usporedbi s ranije navedenim standardnim algoritmima te uspješno ostvaruje leteći start bez dodatnih modifikacija prije samog uklopa.

5.5.3. Usporedba odziva s i bez kompenzacije kašnjenja ciklusa digitalnog sustava

Na slici 5.24 prikazano je djelovanje razvijenog MP-DCC algoritma s i bez kompenzacije kašnjenja digitalnog sustava uz referentnu vrijednost momenta $M^* = 0$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u., uz uključenje generatorskog pretvarača u trenutku $t = 0.01$ s.

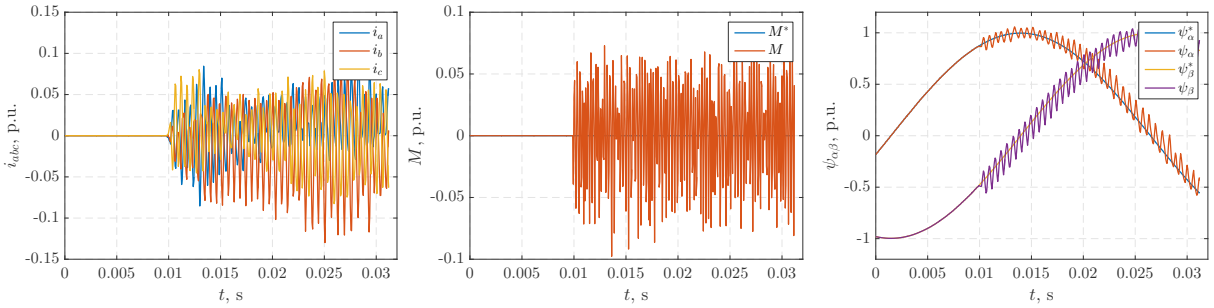

(a) Bez kompenzacije kašnjenja digitalnog sustava

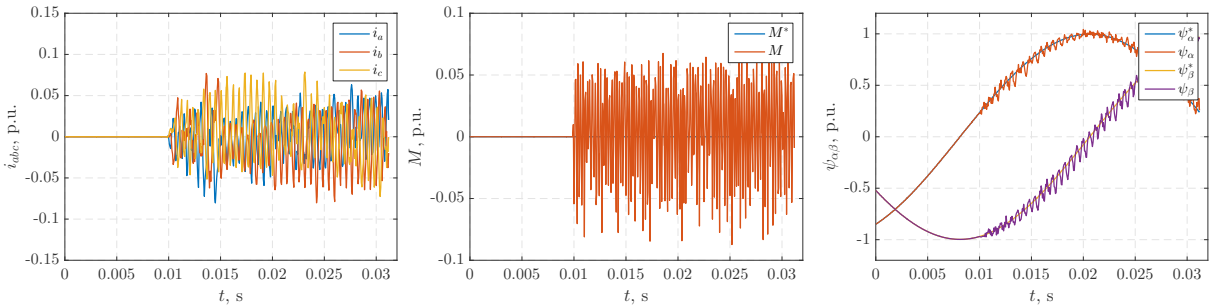

(b) S kompenzacijom kašnjenja digitalnog sustava

Slika 5.24: Razvijeni MP-DCC algoritam s i bez kompenzacije kašnjenja digitalnog sustava

Prikazani su odzivi mjerene struje $\boldsymbol{i}_{abc}$, referentne M^* i proračunate M vrijednosti elektromagnetskog momenta te referentne $\boldsymbol{\psi}^*_{\alpha\beta}$ i proračunate $\boldsymbol{\psi}_{\alpha\beta}$ vrijednosti magnetskog toka.

U trenutku $t = 0.01$ s dolazi do uključenja generatorskog pretvarača, a potom generator radi u praznom hodu. Kao što je objašnjeno u potpoglavlju 5.5.1, jedan od izazova prilikom implementacije FCS-MPC algoritama je kompenzacija kašnjenja ciklusa izvođenja digitalnog sustava uslijed proračuna optimalnog vektora napona. Da bi se smanjilo harmoničko izobličenje struje i poboljšale performanse upravljanja primijenjena je metoda kompenzacije kašnjenja ciklusa izvođenja digitalnog sustava opisana u potpoglavlju 5.5.1 (izvorno razvijena u [131]). Ako ciklus kašnjenja digitalnog sustava nije kompenziran struja u praznom hodu prelazi vrijednost $\boldsymbol{i}_{abc} > 0.1$ p.u., uz značajnije harmoničko izobličenje magnetskog toka. S druge strane, ako je ciklus kašnjenja digitalnog sustava kompenziran struja ne prelazi $\boldsymbol{i}_{abc} \approx 0.08$ p.u. te je harmoničko izobličenje magnetskog toka smanjeno. Iz navedenog razloga implementirana metoda za kompenzaciju ciklusa kašnjenja digitalnog sustava je primijenjena i pri preostalim provedenim eksperimentima.

5.5.4. Analiza utjecaja parametara za penalizaciju na upravljačke performanse

Na slici 5.25 prikazana je usporedba MP-DCC algoritma s fleksibilnom upravljačkom Ljapunovljevom funkcijom uz veličinu upravljačkog invarijantnog skupa $\gamma = \frac{1}{\sqrt{3}}$ te parametrima za penalizaciju ($q_1 = 1$, $r_1 = 0$, $p_1 = 1$) i ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) za $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u. Budući da je razmatran učinak parametara za penalizaciju u drugom režimu rada, tj. u stacionarnom stanju (q_1, r_1, p_1), parametri za penalizaciju u prvom režimu rada, tj. u prijelaznoj pojavi, u svim su slučajevima postavljeni na jednake iznose ($q_0 = 1$, $r_0 = 0$, $p_0 = 1$).

Prikazane su referentne $\boldsymbol{i}^*_{dq}$ i mjerene $\boldsymbol{i}_{dq}$ vrijednosti struje u sinkronom dq koordinatnom sustavu, mjerene vrijednosti struje $\boldsymbol{i}_{abc}$ u mirujućem *abc* koordinatnom sustavu, optimalni vektora napona $\boldsymbol{u}^*_{\alpha\beta}$ u mirujućem $\alpha\beta$ koordinatnom sustavu te optimalno sklopno stanje s^*_{opt}, fleksibilna upravljačka Ljapunovljeva funkcija V, parametar kojim se definira veličina upravljačkog invarijantnog skupa γ te referentna M^* i proračunata M vrijednost momenta generatora.

Ako su vrijednosti parametara za penalizaciju postavljene na ($q_1 = 1$, $r_1 = 0$, $p_1 = 1$), penalizira se isključivo regulacijsko odstupanje struje u stacionarnom stanju čime se ostvaruje smanjenje harmoničkog izobličenja struje, ali i povećanje sklopne frekvencije ($f_{sw} = 3560$ Hz). No, ako se parametri za penalizaciju postave na ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$), osigurava se smanjenje sklopne frekvencije ($f_{sw} = 2440$ Hz), a time i minimizacija sklopnih gubitaka u stacionarnom stanju. No, time se uzrokuje povećanje harmoničkog izobličenja struje te posljedično i povećanje oscilacija momenta. U tom slučaju optimalan vektor napona je onaj kojim se osigurava minimalan broj sklapanja u odnosu na primijenjeni vektor napona iz prethodnog trenutka uzorkovanja bez kršenja dodatnog ograničenja koje se uvodi fleksibilnom upravljačkom Ljapu-

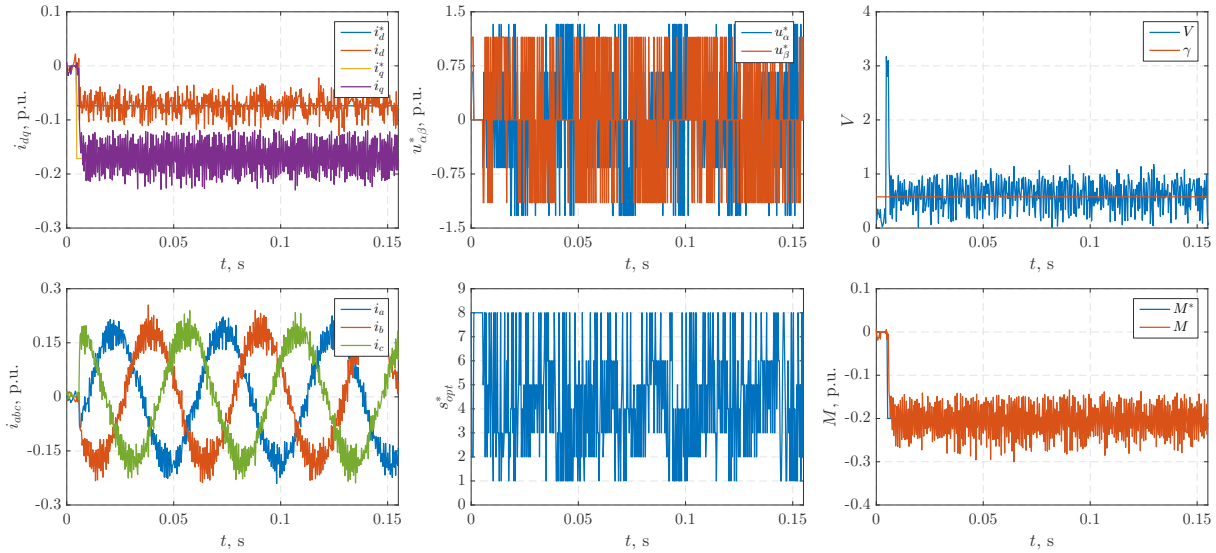

(a) MP-DCC algoritam s parametrima za penalizaciju u stacionarnom stanju ($q_1 = 1$, $r_1 = 0$, $p_1 = 1$)

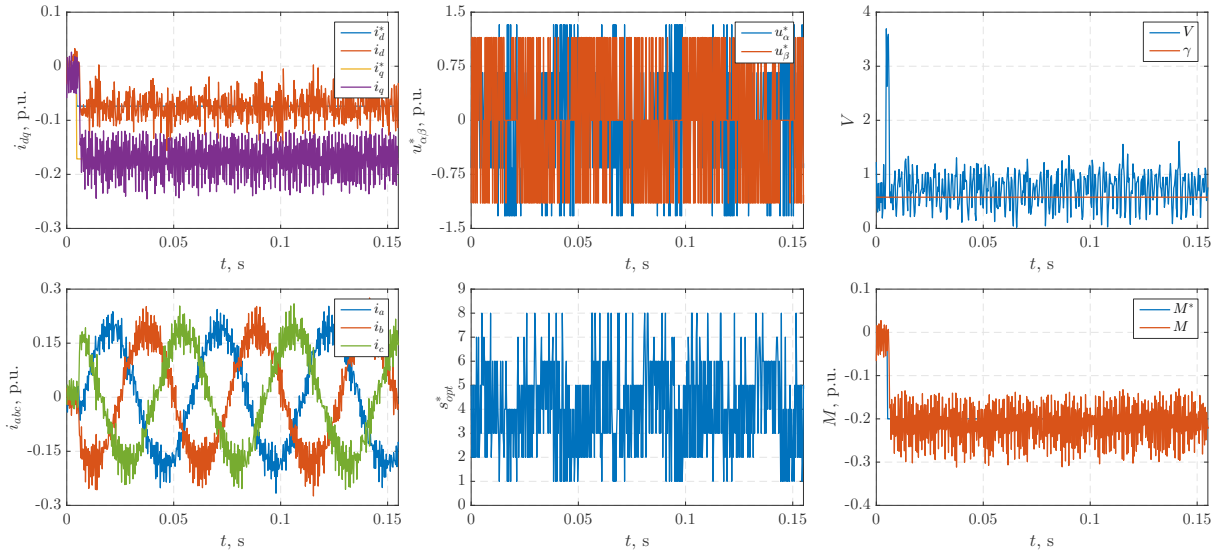

(b) MP-DCC algoritam s parametrima za penalizaciju u stacionarnom stanju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$)

Slika 5.25: Usporedba MP-DCC algoritma s različitim kombinacijama parametara za penalizaciju u stacionarnom stanju (q_1, r_1, p_1) za $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u.

novljevom funkcijom. U idealnom slučaju zadržava se optimalni vektor napona iz prethodnog koraka uzorkovanja ako će primjenom tog vektora struja u narednom koraku ostati unutar upravljačkog invarijantnog skupa.

U usporedbi sa simulacijskim rezultatima za istu referentnu vrijednost momenta pri istoj brzini rotora može se uočiti da u slučaju eksperimentalnih odziva upravljačka Ljapunovljeva funkcija krši ograničenje definirano parametrom γ što ima za posljedicu značajno veće harmoničko izobličenje struje, oscilacije momenta, ali i prosječno višu sklopnu frekvenciju. Navedena pojava može se objasniti odstupanjem vrijednosti parametara generatora koji se koriste u MP-DCC algoritmu i stvarnih vrijednosti kao i dodatnim pojavama u sustavu koje nisu modelirane, a mogu narušiti točnost predikcije budućih vrijednosti struja.

6. Upravljanje momentom u području slabljenja magnetskog toka

6.1. Pregled literature

U elektromotornim pogonima gdje se koriste istosmjerni ili asinkroni strojevi uobičajeno se pod pojmom slabljenja magnetskog toka (engl. *flux weakening*) smatra područje iznad nazivne brzine rotora. Povećanje brzine rotora iznad nazivne vrijednosti nije moguće dodatnim povećanjem napona statora, jer takav pristup vodi k više neželjenih posljedica koje su navedene u nastavku. Električni strojevi su uobičajeno projektirani za rad u koljenu krivulje magnetiziranja (nazivni magnetski tok) pri nazivnom naponu te bi dodatno povećanje napona uzrokovalo rad u nelinearnom dijelu krivulje magnetiziranja. U tom slučaju dolazi do magnetskog zasićenja te značajnog porasta struje magnetiziranja (struja postaje nekoliko puta veća od nazivne vrijednosti) uz zanemarivo povećanje vrijednosti magnetskog toka. Osim značajnog povećanja struje magnetiziranja, povećanje napona iznad nazivne vrijednosti može imati štetan utjecaj na izolaciju statorskog namota asinkronog stroja. Također, maksimalna vrijednost napona koja se dovodi na stezaljke stroja određena je naponom istosmjernog međukruga i tipom modulacije. tj. svojstvima pretvarača napona i frekvencije koji je obično projektiran tako da je maksimalna vrijednost izlaznog napona nešto veća od nazivne vrijednosti priključenog stroja. Iz tog razloga također nije moguće povećati napon značajno iznad nazivne vrijednosti. Iz navedenih razloga napon se u području slabljenja magnetskog toka održava na nazivnoj vrijednosti, dok magnetski tok opada uslijed povećanja brzine rotora. U slučaju asinkronog stroja struja statora se u sinkronom dq koordinatnom sustavu rastavlja na komponentu koja stvara magnetski tok (i_{sd}) i komponentu koja stvara elektromagnetski moment (i_{sq}). U području slabljenja magnetskog toka dolazi do smanjenja iznosa struje i_{sd} što omogućava povećanje iznosa struje i_{sq}. No, budući da dolazi do smanjenja magnetskog toka potrebno je značajno povećati vrijednost komponente struje i_{sq} da bi se održala vrijednost elektromagnetskog momenta. No, strujna zaliha to ne dopušta, tj. u tom slučaju ukupan iznos struje bi prešao nazivnu vrijednost što bi dovelo do termičkog preopterećenja stroja. Iz navedenog razloga dolazi do smanjenja vrijednosti elektromagnetskog momenta u području slabljenja magnetskog toka. U tradicionalnim elektromotornim pogonima

se radno područje ispod nazivne brzine rotora uobičajeno nazivna područjem konstantnog momenta (uz nazivnu vrijednost struje može se razviti nazivni moment), dok se područje iznad nazivne brzine rotora naziva područjem konstantne snage (uslijed porasta brzine rotora dolazi do smanjenja razvijenog momenta uz očuvanje vrijednosti razvijene snage).

Slično razmatranje vrijedi i za sinkrone generatore sa stalnim magnetima, uz razliku da je magnetski tok u stroju posljedica stalnih magneta na rotoru. U slučaju da su magneti smješteni u unutrašnjosti rotora, generator razvija dodatni reluktantni moment koji je posljedica magnetske asimetrije u uzdužnoj (d) i poprečnoj (q) osi. U slučaju takvog tipa generatora referentna vrijednost struje proračunava se prema MTPA algoritmu da bi se ostvarilo upravljanje s minimalnim gubicima na otporu statora. Budući da je prema navedenom algoritmu referentna vrijednost struje i_d^* u svakoj radnoj točki negativna, MTPA algoritam ostvaruje slabljenje magnetskog toka u čitavom radnom području generatora, neovisno o brzini rotora. No, povećanjem brzine rotora dolazi do proporcionalnog povećanja induciranog napona generatora, a time i napona statora, tj. potrebnog napona na izlazu generatorskog pretvarača. Ako napon statora postane veći od maksimalnog izlaznog napona generatorskog pretvarača (definiran naponom istosmjernog međukruga i korištenim tipom modulacije), diode postaju propusno polarizirane i provedu struju kojom nije moguće upravljati. U navedenim uvjetima dolazi do gubitka upravljivosti što može imati štetne posljedice za čitav pogon s električnog, ali i mehaničkog aspekta. Da bi se spriječio porast induciranog napona generatora, a time i napona statora iznad dozvoljene granice, potrebno je dodatno slabiti magnetski tok stalnih magneta. Algoritmi upravljanja koji osiguravaju rad na ograničenju napona dodatnim slabljenjem magnetskog toka stalnih magneta u znanstvenoj literaturi se obično nazivaju algoritmima slabljenja magnetskog toka zbog analogije s tradicionalnim elektromotornim pogonima.

Analiza radnih točaka u čitavom rasponu brzina rotora za sinkrone strojeve sa stalnim magnetima dana je u radovima [132–136]. U slučaju sinkronog stroja s unutrašnjim stalnim magnetima i konačnom maksimalnom brzinom rotora (karakteristična struja izvan ograničenja struje), najveći ostvarivi moment definiran je referentnom vrijednosti struje koja se nalazi na sjecištu ograničenja struje i napona. U slučaju sinkronog stroja s unutrašnjim stalnim magnetima i beskonačnom maksimalnom brzinom rotora (karakteristična struja unutar ograničenja struje), referentna vrijednost struje definirana je na sličan način kao i u prethodnom slučaju do vrijednosti brzine rotora definirane konstrukcijom samog stroja. No, iznad navedene brzine rotora referentna vrijednost struje se određuje prema MTPV (engl. *maximum torque per voltage*) ili MTPF (engl. *maximum torque per flux*) krivulji. Algoritmi za proračun referentne vrijednosti struje u području slabljenja magnetskog toka uobičajeno su temeljeni na signalima predupravljanja (engl. *feedforward*) ili na povratnoj vezi (engl. *feedback*).

Algoritmi temeljeni na signalima predupravljanja [137–141] pripadaju grupi algoritama u otvorenoj petlji (engl. *open loop*) temeljenih na modelu sinkronog stroja sa stalnim magnetima.

Referentna vrijednost struje proračunava se analitički ili se određuje na temelju eksperimentalnih mjerenja. Analitički pristup podrazumijeva rješavanje kompleksnih jednadžbi višeg reda s promjenjivim parametrima stroja, uz zadanu brzinu rotora, napon istosmjernog međukruga i referentnu vrijednost momenta. Zbog kompleksnosti samog proračuna pronalazak analitičkog rješenja je složen te se radi jednostavnosti implementacije u digitalnom sustavu referentne vrijednosti struje dobivene na temelju eksperimentalnih mjerenja ili metode konačnih elemenata (engl. *finite element method*, FEM) obično pohranjuju u pregledne tablice. Algoritme temeljene na signalima predupravljanja karakteriziraju visoke dinamičke performanse. No, navedeni algoritmi su osjetljivi na promjenu vrijednosti parametara stroja što može rezultirati radom u suboptimalnoj radnoj točki ili čak nestabilnim radom sustava uslijed značajnijih modelskih neodređenosti.

Algoritmi temeljeni na povratnoj vezi [142–146] pripadaju grupi algoritama u zatvorenoj petlji (engl. *closed loop*). Navedeni algoritmi zasnivaju se na dodatnoj strukturi upravljanja strujom u uzdužnoj d osi i_d. Signal u povratnoj vezi navedenih struktura uobičajeno je napon stroja ili brzina rotora. Budući da se radi o upravljanju u zatvorenoj petlji, ova grupa algoritama je robusnija na pogrešne vrijednosti parametara stroja i modelske neodređenosti u usporedbi s algoritmima temeljenim na signalima predupravljanja. No, potrebno je ispravnom sintezom dodatne upravljačke strukture te odgovarajućim podešavanjem parametara regulatora osigurati stabilnost čitavog sustava upravljanja.

6.1.1. Treći znanstveni doprinos

U doktorskoj disertaciji je razvijena metoda upravljanja momentom u području slabljenja magnetskog toka temeljena na koordiniranom radu PI regulatora napona i momenta [147]. Razvijena metoda pripada grupi algoritama temeljenih na povratnoj vezi te je prilagođena za upravljanje sinkronim generatorima sa stalnim magnetima u unutrašnjosti rotora. PI regulatorom napona održava se napon generatora na maksimalnom dozvoljenom iznosu, dok se PI regulatorom momenta osigurava ispravno praćenje referentne vrijednosti momenta. Za razliku od većine ranije navedenih algoritama temeljenih na povratnoj vezi koji podrazumijevaju rad na ograničenju napona i struje (najveća dopuštena snaga), razvijena metoda osigurava rad na ograničenju napona uz praćenje referentne vrijednosti momenta u čitavom radnom području generatora.

6.2. Metoda slabljenja magnetskog toka temeljena na PI regulatorima napona i momenta

Matematički model sinkronog stroja s unutrašnjim stalnim magnetima u sinkronom dq koordinatnom sustavu u stacionarnom stanju je jednak:

$$\begin{aligned} u_d &= i_d R_s - \omega_{re} L_q i_q, \\ u_q &= i_q R_s + \omega_{re} L_d i_d + \omega_{re} \psi_{md}, \end{aligned} \tag{6.1}$$

gdje je $\boldsymbol{u}_{dq}$ napon, $\boldsymbol{i}_{dq}$ struja, ω_{re} električna brzina rotora, R_s otpor statora, L_d i L_q induktiviteti u d i q osi, a ψ_{md} magnetski tok stalnih magneta. Elektromagnetski moment jednak je:

$$\begin{aligned} M_{em} &= M_{PM} + M_{rel} \\ &= \frac{3}{2} p(\psi_{md} i_q) + \frac{3}{2} p((L_d - L_q) i_d i_q), \end{aligned} \tag{6.2}$$

gdje je M_{em} ukupni elektromagnetski moment, M_{PM} komponenta momenta uzrokovana magnetskim tokom stalnih magneta, M_{rel} reluktantni moment uzrokovan magnetskom asimetrijom stroja, dok je p broj pari polova stroja. U slučaju da se radi o sinkronom stroju s površinskim stalnim magnetima ($L_d = L_q$) ne postoji reluktantni moment te je struja i_d jednaka nuli do ulaska u područje slabljenja magnetskog toka. S druge strane, u slučaju sinkronog stroja s unutrašnjim stalnim magnetima ($L_d \neq L_q$) struja i_d se u čitavom radnom području regulira na negativni iznos definiran MTPA krivuljom s ciljem ostvarivanja reluktantnog momenta. Iz navedenog razloga magnetski tok stalnih magneta se slabi u čitavom radnom području generatora, no pod područjem slabljenja magnetskog toka smatra se rad na ograničenju napona.

6.2.1. Ograničenja napona i struje generatora

Na temelju matematičkog modela danog izrazom (6.1), uz zanemarenje pada napona na otporu statora R_s, slijede izrazi ograničenja struje i napona:

$$\begin{aligned} &i_d^2 + i_q^2 \leq I_{max}^2, \\ &(L_d i_d + \psi_{md})^2 + (L_q i_q)^2 \leq \frac{U_{max}^2}{\omega_{re}^2}, \end{aligned} \tag{6.3}$$

gdje je I_{max} najveća dozvoljena vrijednost struje definirana nazivnim vrijednostima struja generatorskog pretvarača i generatora, a U_{max} najveća dozvoljena vrijednost napona određena naponom istosmjernog međukruga i tipom modulacije.

Na slici 6.1 prikazana su ograničenja napona i struje generatora s unutrašnjim magnetima u sinkronom dq koordinatnom sustavu. Ograničenje struje prikazano je kao kružnica s polumje-

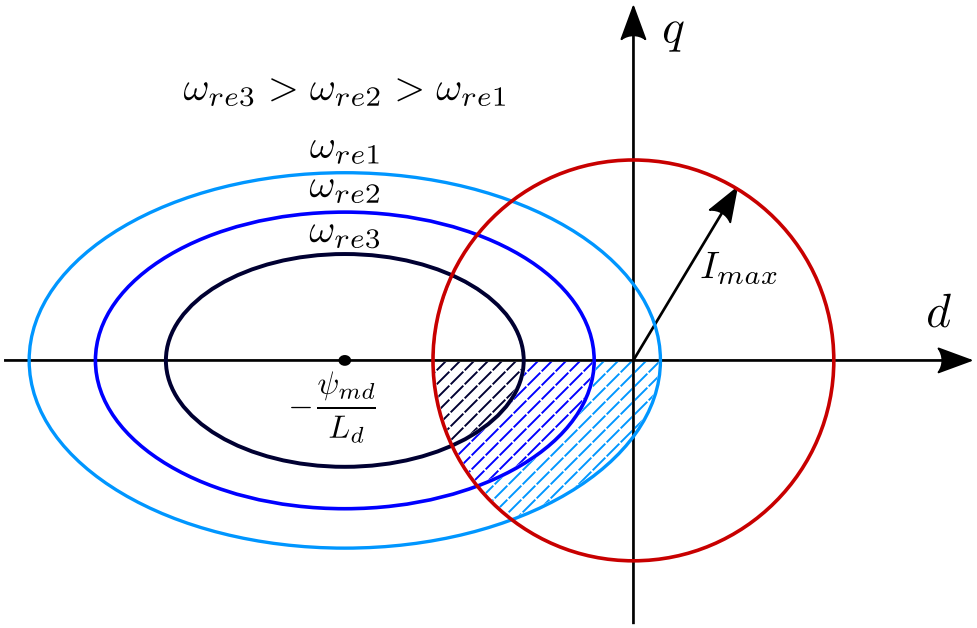

Slika 6.1: Ograničenja napona i struje generatora

rom I_{max}, dok je ograničenje napona prikazano kao elipsa koja se smanjuje povećanjem brzine rotora ω_{re} prema izrazu (6.3). Područje dopuštenog trajnog rada generatora je zajednička površina unutar ograničenja napona i struje. U slučaju generatora analizira se površina u trećem kvadrantu budući da je vrijednost struje i_q negativna u generatorskom režimu rada.

Povećanjem brzine vjetra dolazi i do povećanja brzine rotora te se dopušteno područje rada smanjuje. U tom slučaju je potrebno nekim od algoritama slabljenja magnetskog toka osigurati rad unutar dozvoljenog područja. Ako se referentna vrijednost struje nalazi izvan elipse koja definira ograničenje napona, izlazi PI regulatora struja u strukturi vektorskog upravljanja, tj. referentne vrijednosti napona u_d^* i u_q^* se ne mogu ostvariti što dovodi do zasićenja PI regulatora struja. U tom slučaju nije moguće pratiti referentnu vrijednost struje te dolazi do gubitka upravljivosti. Da bi se to spriječilo, algoritam slabljenja magnetskog toka koji osigurava modifikaciju referentne vrijednosti struje i omogućava rad na ograničenju napona treba biti uključen u strukturu upravljanja generatorom.

6.2.2. Razvijena struktura upravljanja u području slabljenja magnetskog toka

Na slici 6.2 prikazana je struktura vektorskog upravljanja uz dodatnu strukturu slabljenja magnetskog toka. U slučaju ulaska u područje slabljenja magnetskog toka, referentne vrijednosti struja $\boldsymbol{i}_{dq}^*$ su osim referentnom vrijednošću momenta M^* prema MTPA algoritmu definirane i strukturom slabljenja magnetskog toka koja će detaljnije biti opisana u nastavku.

Na slici 6.3 prikazana je razvijena struktura slabljenja magnetskog toka. Metoda se temelji na koordiniranom radu PI regulatora napona i momenta. Kada generator radi unutar ograničenja struje i napona referentne vrijednosti struja se proračunavaju na temelju referentne vrijednosti

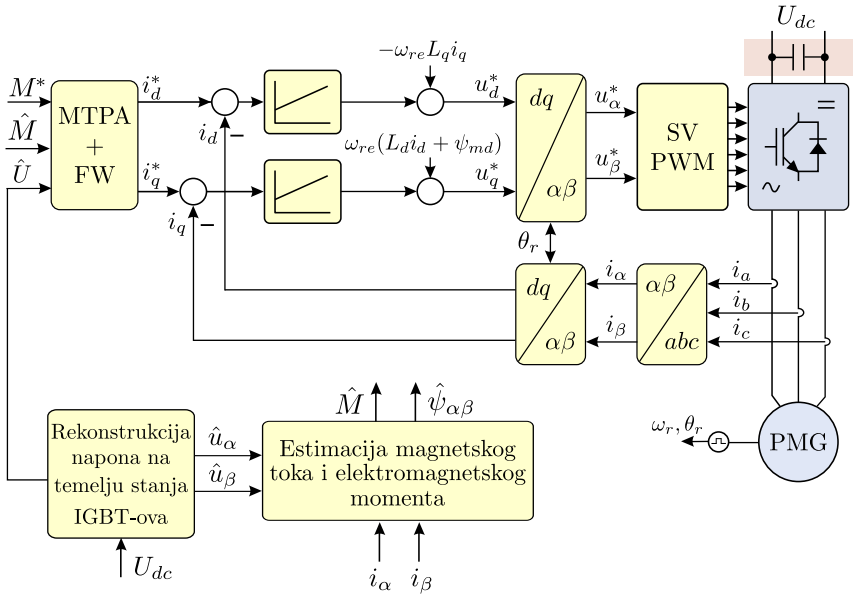

Slika 6.2: Struktura vektorskog upravljanja uz strukturu slabljenja magnetskog toka

momenta M^* prema MTPA algoritmu te su jednake i_d^{MTPA} i i_q^{MTPA}. Napon generatora $\hat{U}$ proračunava se prema sljedećem izrazu:

$$\hat{U} = \sqrt{\hat{u}_\alpha^2 + \hat{u}_\beta^2}, \tag{6.4}$$

gdje su $\hat{u}_\alpha$ i $\hat{u}_\beta$ komponente napona generatora u mirujućem $\alpha\beta$ koordinatnom sustavu rekonstruirane na temelju mjerenog napona istosmjernog međukruga U_{dc} i sklopnih stanja IGBT-ova generatorskog pretvarača uz kompenzaciju mrtvog vremena. Najveća dopuštena vrijednost faznog napona uz vektorsku modulaciju širine impulsa (SVPWM) jednaka je:

$$U_{max} = \kappa \frac{U_{dc}}{\sqrt{3}}, \tag{6.5}$$

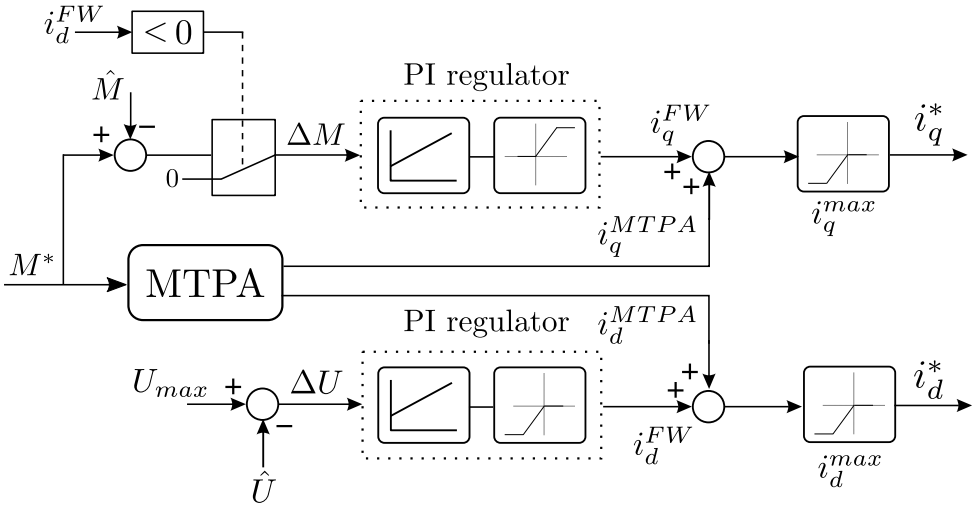

Slika 6.3: Razvijena struktura slabljenja magnetskog toka

gdje je κ sigurnosni faktor kojim se smanjuje najveća dopuštena vrijednost napona te se uobičajeno odabire u rasponu $0.85 \div 0.95$ [146].

Kada vrijednost rekonstruiranog napona prijeđe iznos maksimalne dopuštene vrijednosti U_{max}, PI regulator napona na svom izlazu daje negativnu vrijednost struje i_d^{FW} koja se pribraja referentnoj vrijednosti prema MTPA algoritmu i_d^{MTPA}. U tom slučaju dolazi do smanjenja napona u_q prema (6.1) te se napon $\hat{U}$ održava ispod maksimalne dopuštene vrijednosti U_{max}.

Međutim, u slučaju sinkronog generatora sa stalnim magnetima u unutrašnjosti rotora, uslijed povećanja iznosa struje i_d dolazi i do povećanja iznosa reluktantnog momenta M_{rel} prema (6.2). Odstupanje razvijenog momenta od referentne vrijednosti vodi k radu u suboptimalnoj radnoj točki. Da bi se razvijeni moment održao na referentnoj vrijednosti uveden je PI regulator momenta. U uvedenoj regulacijskoj petlji momenta signal u povratnoj vezi je estimirani moment $\hat{M}$. Elektromagnetski moment sinkronog generatora s unutrašnjim stalnim magnetima može se proračunati korištenjem struja u sinkronom dq koordinatnom sustavu i parametara stroja prema (6.2), vektorskim produktom estimiranog magnetskog toka i mjerene struje u mirujućem $\alpha\beta$ koordinatnom sustavu te na temelju proračunate radne snage i mjerene brzine generatora [148]. U razvijenoj strukturi korištena je estimacija momenta vektorskim produktom estimiranog magnetskog toka i mjerene struje u mirujućem $\alpha\beta$ koordinatnom sustavu radi veće robusnosti na promjenu parametara generatora u usporedbi s drugim metodama te zadovoljavajuće dinamike i točnosti:

$$\hat{M} = \frac{3}{2} p(\hat{\psi}_\alpha i_\beta - \hat{\psi}_\beta i_\alpha), \tag{6.6}$$

gdje je $\boldsymbol{i}_{\alpha\beta}$ mjerena struja, a $\hat{\boldsymbol{\psi}}_{\alpha\beta}$ estimirani magnetski tok. Kao i kod algoritma za upravljanje bez mjernog člana brzine rotora, magnetski tok je estimiran integracijom induciranog napona koji slijedi iz modela generatora:

$$\hat{\boldsymbol{\psi}}_{\alpha\beta} = \int \hat{\boldsymbol{e}}_{\alpha\beta} \, \mathrm{d}t = \int \left(\hat{\boldsymbol{u}}_{\alpha\beta} - \boldsymbol{i}_{\alpha\beta} \cdot R_s \right) \, \mathrm{d}t. \tag{6.7}$$

Kada vrijednost estimiranog momenta $\hat{M}$ postane veća od referentne vrijednosti M^*, na izlazu PI regulatora momenta je pozitivna vrijednost struje i_q^{FW} koja se pribraja referentnoj vrijednosti prema MTPA algoritmu i_q^{MTPA}. Budući da je struja i_q^{MTPA} negativna, djelovanjem PI regulatora momenta dolazi do smanjenja referentne vrijednosti i_q^*. Time se osigurava ispravno praćenje referentne vrijednosti momenta M^* odnosno sprječava povećanje momenta uslijed povećanja negativne vrijednosti struje i_d. PI regulator momenta je aktivan samo u području slabljenja magnetskog toka, tj. kada je signal na izlazu PI regulatora napona i_d^{FW} manji od nule. Time se osigurava da je rad PI regulatora momenta onemogućen tijekom prijelaznih pojava unutar ograničenja napona i struje.

Ograničenja referentnih vrijednosti struja i_d^{max} i i_q^{max} proračunavaju se prema sljedećim izra-

zima:

$$\begin{aligned} i_d^{max} &= -I_{max}, \\ i_q^{max} &= -\sqrt{I_{max}^2 - i_d^{*2}}. \end{aligned} \tag{6.8}$$

Uz navedeni način proračuna ograničenja prioritet ima PI regulator napona kojim se osigurava rad na naponskom ograničenju.

6.2.3. Trajektorija struje u području slabljenja magnetskog toka

Na slici 6.4 prikazana je trajektorija struje u području slabljenja magnetskog toka. Radi jednostavnosti, razmatrana je konstantna vrijednost referentnog momenta M^*. Pri brzini rotora ω_{re1} radna točka A je unutar ograničenja struje i napona te se nalazi na MTPA krivulji. Međutim, uslijed povećanja brzine rotora s ω_{re1} na ω_{re2}, radna točka A se nalazi izvan ograničenja napona. Ako je aktivan samo PI regulator napona, bez kompenzacije porasta momenta, uslijed porasta negativne struje i_d aktivna radna točka postaje B koja se nalazi na sjecištu ograničenja napona za brzinu ω_{re2} i krivulje konstantnog momenta za vrijednost veću od referentne $M > M^*$, uslijed povećanja reluktantnog momenta. Kao što je navedeno ranije u tekstu, vrijednost momenta koja je veća od referentne vodi k suboptimalnom radnom području, tj. manjem iskorištenju energije vjetra i većim gubicima sustava. No, ako je uz PI regulator napona aktivan i PI regulator momenta, tada se uslijed porasta brzine rotora radna točka kreće sjecištem ograničenja napona i krivulje konstantnog momenta za referentnu vrijednost M^* što vodi k optimalnoj radnoj točki C. U tom slučaju ograničenje napona je zadovoljeno, uz razvijeni moment jednak referentnoj vrijednosti.

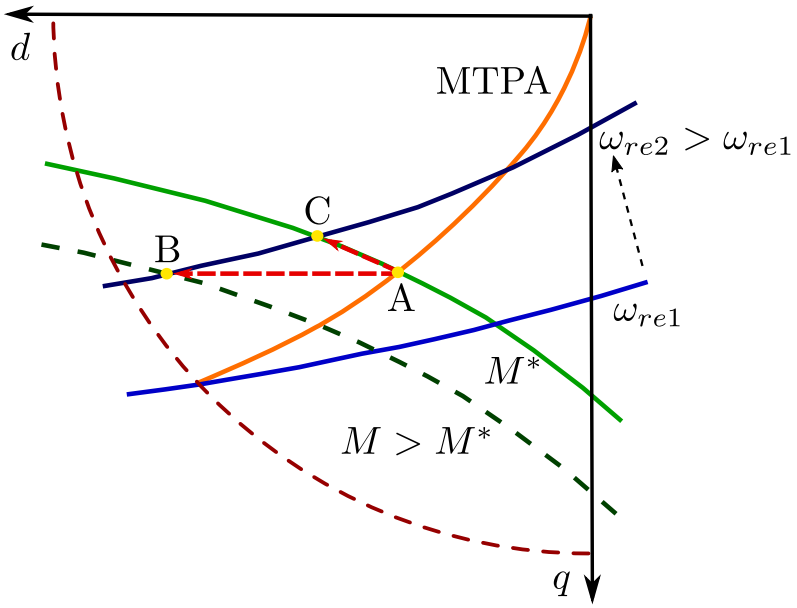

Slika 6.4: Trajektorija struje u području slabljenja magnetskog toka

6.3. Eksperimentalni rezultati

Opisana metoda slabljenja magnetskog toka temeljena na koordiniranom radu PI regulatora napona i momenta implementirana je u digitalni sustav temeljen na ADSP-21992 mikroprocesoru korištenjem programskog alata *AlgoCAD* te potom provjerena na laboratorijskom postavu koji je opisan u poglavlju 3. Najvažniji podaci laboratorijskog postava koji se sastoji od sinkronog generatora sa stalnim magnetima, AC-DC-AC pretvarača i asinkronog motora koji emulira rad vjetroturbine ponovljeni su u nastavku:

PMG: Tema LPMR-450, $P_n = 375$ kW, $E_n = 400$ V, $I_n = 596$ A, $f_n = 75$ Hz, $n_n = 1500$ rpm.
AC-DC-AC pretvarač: Končar KONvert W1500, $P_n = 520$ kW, $U_n = 400$ V, $I_n = 750$ A, $f_{sw} = 2$ kHz, $U_{dc} = 650$ V.
AM: Končar 8AZJ 405-04, $P_n = 560$ kW, $U_n = 400$ V, $I_n = 967$ A, $f_n = 50$ Hz, $n_n = 1490$ rpm, $\cos\varphi_n = 0.87$.
Bazne vrijednosti: $U_b = 326$ V, $I_b = 843$ A, $f_b = 75$ Hz, $n_{rb} = 1500$ okr/min, $\omega_{rb} = 471$ rad/s, $M_b = 2389$ Nm, $Z_b = 0.39\ \Omega$, $L_b = 0.83$ mH, $\psi_b = 0.69$ Wb.

Upravljačka struktura vektorskog upravljanja implementirana je na frekvenciji uzorkovanja $f_s = 10$ kHz (prekidna rutina SLOW100 u programskom alatu *AlgoCAD*). Rad u slabljenju magnetskog toka vezan je uz promjenu brzine rotora koja je u slučaju vjetrogeneratora sporo promjenjiva veličina u usporedbi s električnim veličinama (npr. struja). Iz navedenog razloga razvijena metoda je implementirana na frekvenciji uzorkovanja $f_s = 5$ kHz (prekidna rutina MID1000 u programskom alatu *AlgoCAD*).

U nastavku su prikazani eksperimentalni odzivi ulaska u područje slabljenja magnetskog toka i izlaska iz područja slabljenja magnetskog toka s i bez djelovanja PI regulatora momenta uz različite referentne vrijednosti momenta. Napon istosmjernog međukruga reguliran je na vrijednost $U_{dc} = 650$ V sa strane mrežnog pretvarača. Maksimalna dopuštena vrijednost napona U_{max} određena je prema (6.5), uz odabir faktora sigurnosti $\kappa = 0.87$.

Eksperimenti su provedeni u trajanju 1.5 s i 2 s, ovisno o referentnoj vrijednosti momenta. U programskom alatu *r_parnad* definirano je snimanje varijabli digitalnog sustava u 500 točaka unutar definiranog vremenskog okvira koji odgovara trajanju eksperimenta.

Prikazani su odzivi električne brzine rotora ω_{re}, referentne M^* i estimirane $\hat{M}$ vrijednosti momenta, regulacijskih odstupanja PI regulatora napona ΔU i momenta ΔM, referentnih vrijednosti struja prema MTPA algoritmu i_d^{MTPA} i i_q^{MTPA}, ukupnih referentnih vrijednosti struja i_d^* i i_q^* te mjerenih struja i_d i i_q.

6.3.1. Ulazak u područje slabljenja magnetskog toka bez regulatora momenta

Na slici 6.5 prikazan je ulazak u područje slabljenja magnetskog toka bez aktivnog PI regulatora momenta u razvijenoj strukturi za referentne vrijednosti momenta $M^* = -0.2$ p.u. (promjena brzine rotora s $n_r = 1330$ okr/min na $n_r = 1470$ okr/min) i $M^* = -0.4$ p.u. (promjena brzine rotora s $n_r = 1200$ okr/min na $n_r = 1350$ okr/min).

U prvom slučaju ograničenje napona postaje aktivno pri brzini rotora $n_r \approx 1400$ okr/min, dok u drugom slučaju pri brzini rotora $n_r \approx 1240$ okr/min. Iz priloženog se može zaključiti da dostizanje ograničenja napona ne ovisi isključivo o brzini rotora već i o razvijenom momentu. U trenutku dostizanja ograničenja napona ulaz u PI regulator napona ΔU postaje negativan

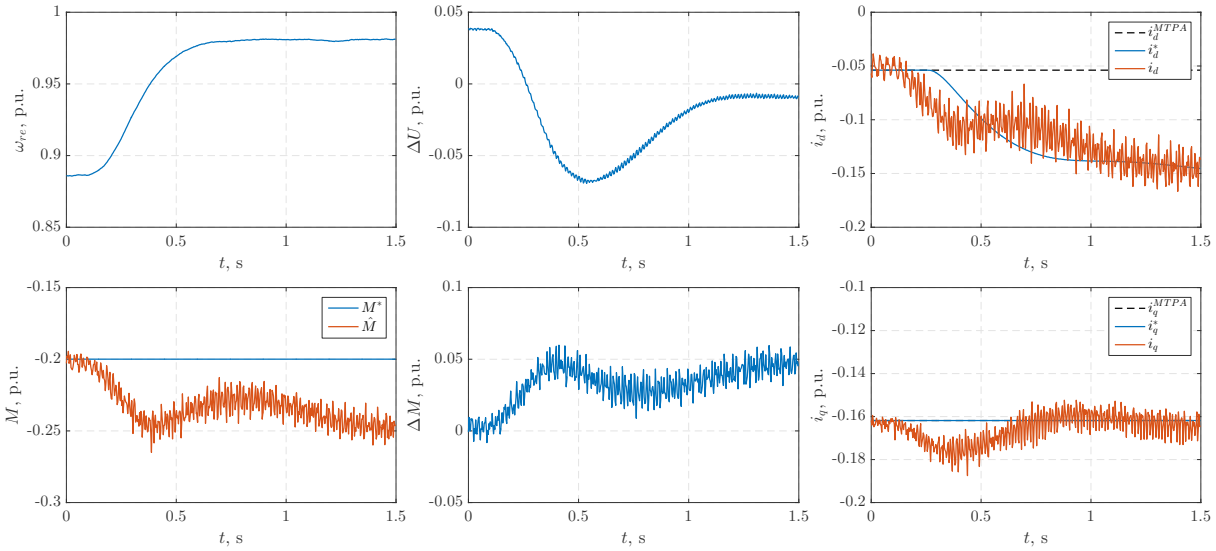

(a) Promjena brzine rotora s $n_r = 1330$ okr/min na $n_r = 1470$ okr/min uz moment $M^* = -0.2$ p.u.

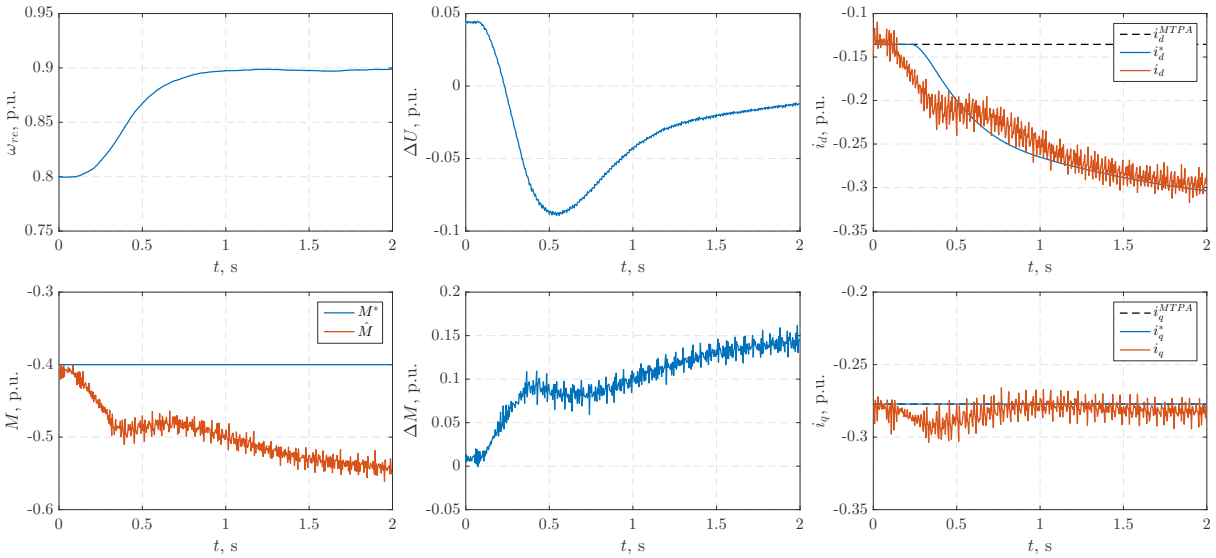

(b) Promjena brzine rotora s $n_r = 1200$ okr/min na $n_r = 1350$ okr/min uz moment $M^* = -0.4$ p.u.

Slika 6.5: Ulazak u područje slabljenja magnetskog toka bez PI regulatora momenta za različite referentne vrijednosti momenta

te se aktivira razvijena struktura slabljenja magnetskog toka. PI regulator napona na svom izlazu stvara struju i_d^{FW} kojom se dodatno slabi magnetski tok te osigurava rad na ograničenju napona. No, budući da regulator momenta nije aktivan, uslijed stvaranja dodatnog reluktantnog momenta dolazi do odstupanja razvijenog momenta od referentne vrijednosti (25% u prvom slučaju i 37.5% u drugom slučaju).

6.3.2. Izlazak iz područja slabljenja magnetskog toka bez regulatora momenta

Na slici 6.6 prikazan je izlazak iz područja slabljenja magnetskog toka bez aktivnog PI regulatora momenta u razvijenoj strukturi za referentne vrijednosti momenta $M^* = -0.2$ p.u.

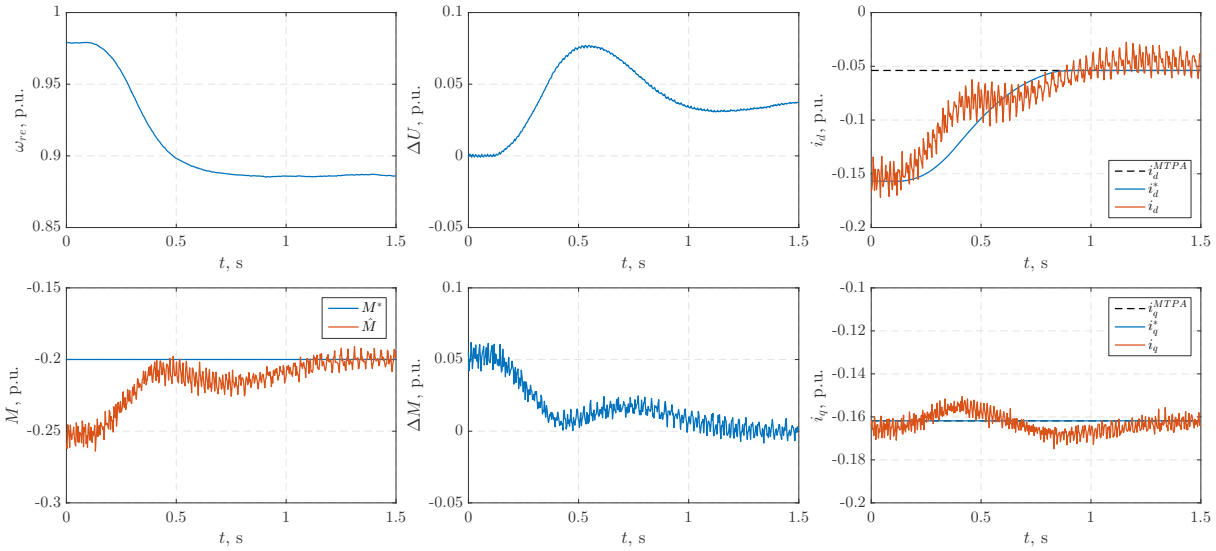

(a) Promjena brzine rotora s $n_r = 1470$ okr/min na $n_r = 1330$ okr/min uz moment $M^* = -0.2$ p.u.

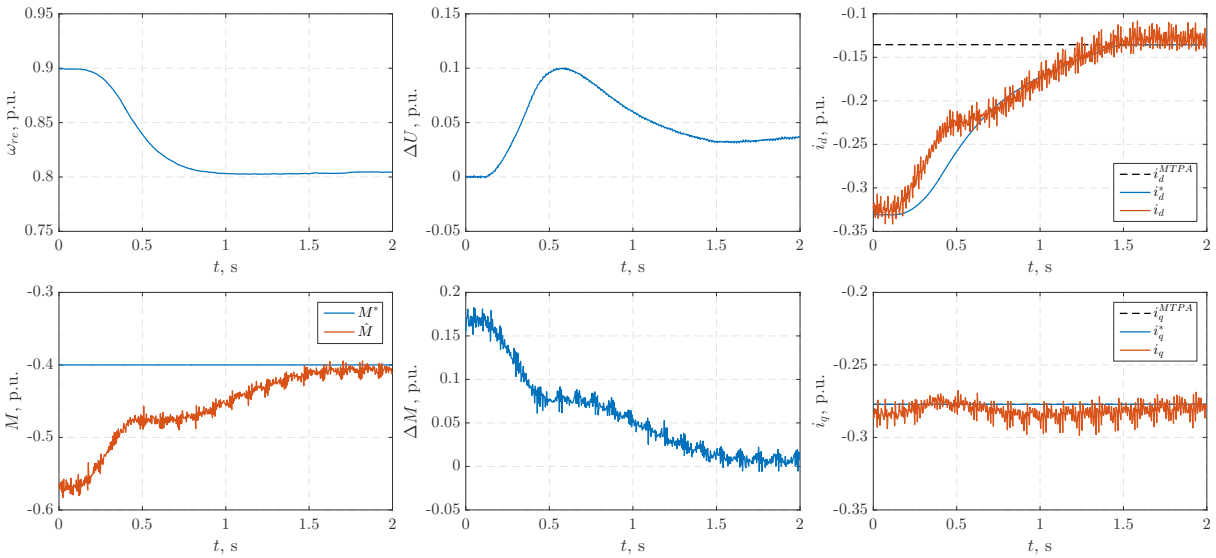

(b) Promjena brzine rotora s $n_r = 1350$ okr/min na $n_r = 1200$ okr/min uz moment $M^* = -0.4$ p.u.

Slika 6.6: Izlazak iz područja slabljenja magnetskog toka bez PI regulatora momenta za različite referentne vrijednosti momenta

(promjena brzine rotora s $n_r = 1470$ okr/min na $n_r = 1330$ okr/min) i $M^* = -0.4$ p.u. (promjena brzine rotora s $n_r = 1350$ okr/min na $n_r = 1200$ okr/min).

Smanjenjem brzine rotora dolazi i do smanjenja napona. Kada regulacijsko odstupanje napona ΔU postane pozitivno radna točka više nije na ograničenju napona te referentne vrijednosti struja i_d^* i i_q^* postaju jednake onima proračunatima prema MTPA algoritmu i_d^{MTPA} i i_q^{MTPA}.

6.3.3. Ulazak u područje slabljenja magnetskog toka s regulatorom momenta

Na slici 6.7 prikazan je ulazak u područje slabljenja magnetskog toka s aktivnim PI regulatorom momenta u razvijenoj strukturi za referentne vrijednosti momenta $M^* = -0.2$ p.u. (pro-

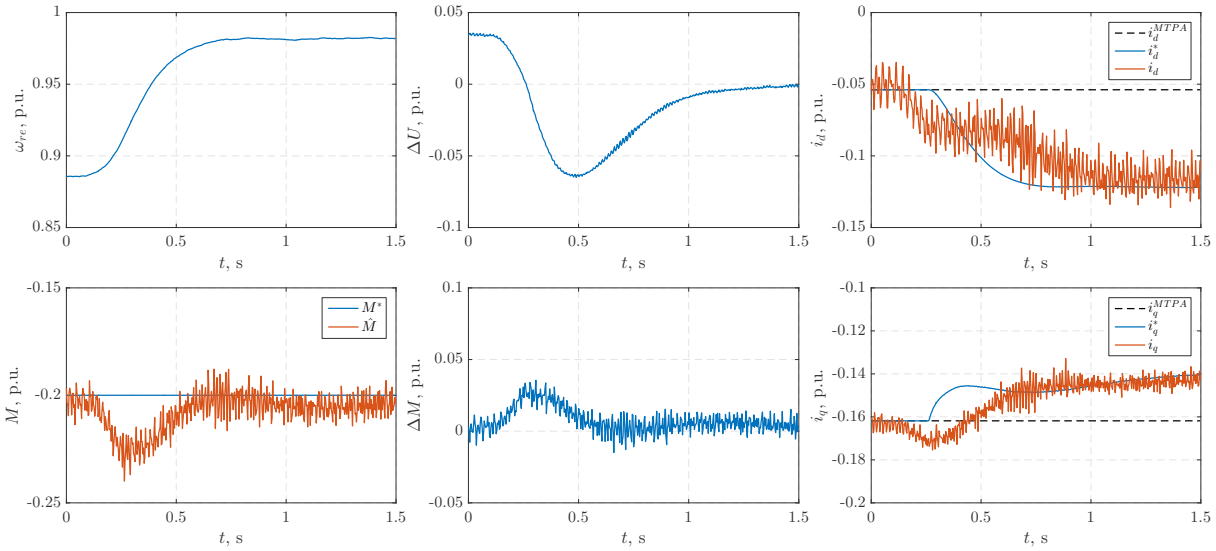

(a) Promjena brzine rotora s $n_r = 1330$ okr/min na $n_r = 1470$ okr/min uz moment $M^* = -0.2$ p.u.

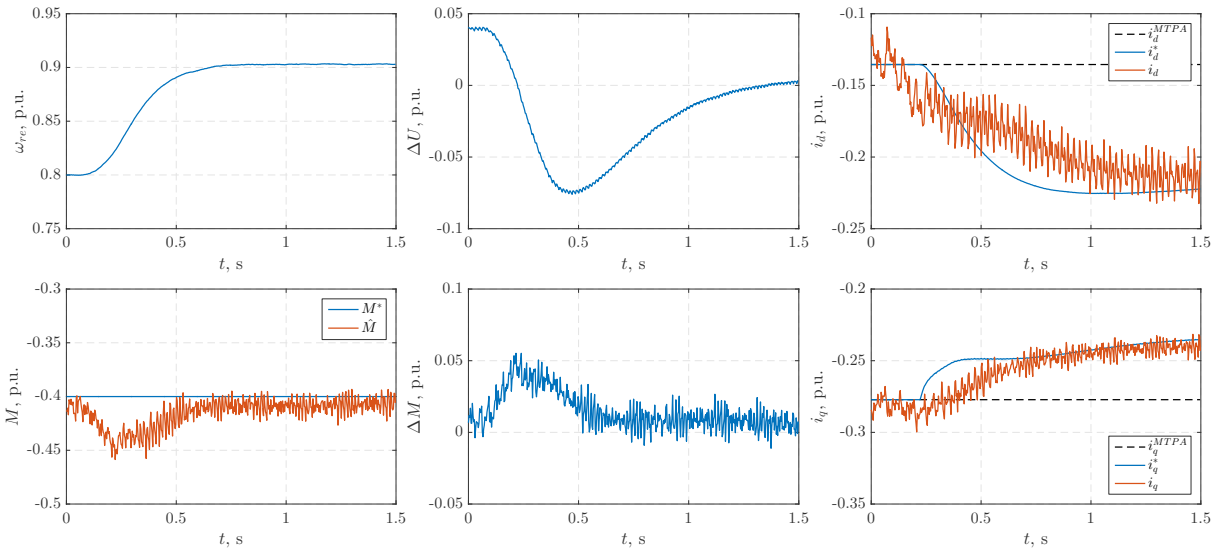

(b) Promjena brzine rotora s $n_r = 1200$ okr/min na $n_r = 1350$ okr/min uz moment $M^* = -0.4$ p.u.

Slika 6.7: Ulazak u područje slabljenja magnetskog toka s PI regulatorom momenta za različite referentne vrijednosti momenta

mjena brzine rotora s $n_r = 1330$ okr/min na $n_r = 1470$ okr/min) i $M^* = -0.4$ p.u. (promjena brzine rotora s $n_r = 1200$ okr/min na $n_r = 1350$ okr/min).

U slučaju kada je aktivan i PI regulator momenta, u trenutku aktivacije ograničenja napona PI regulator napona osigurava struju negativnu i_d^{FW} kojom se regulira napon na maksimalnu dopuštenu vrijednost, dok PI regulator momenta osigurava struju pozitivnu i_q^{FW} kojom se regulira moment na referentnu vrijednost.

6.3.4. Izlazak iz područja slabljenja magnetskog toka s regulatorom momenta

Na slici 6.8 prikazan je izlazak iz područja slabljenja magnetskog toka s aktivnim PI

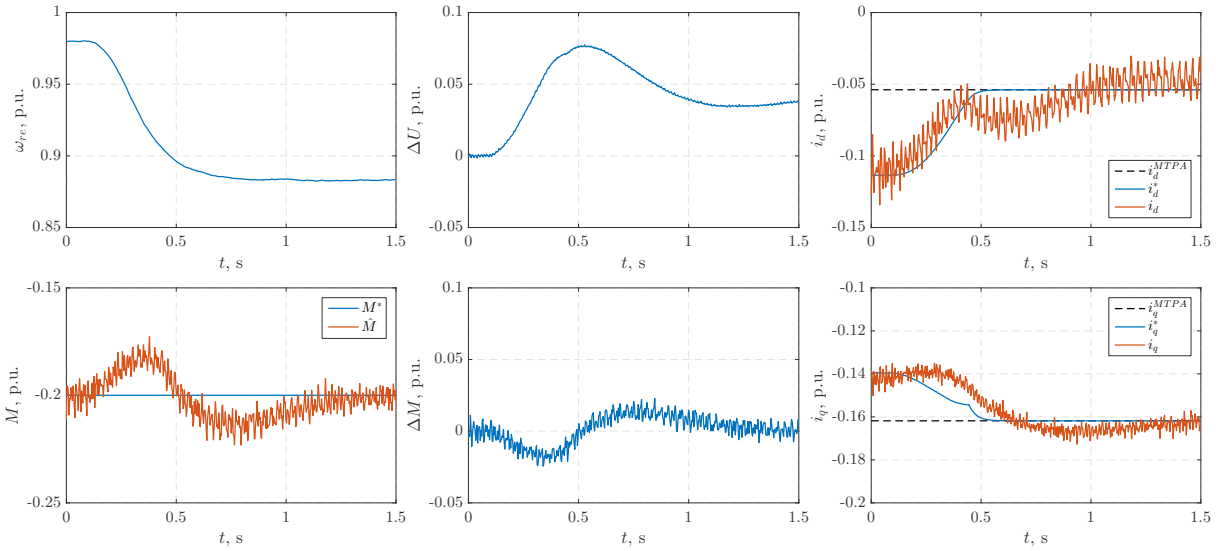

(a) Promjena brzine rotora s $n_r = 1470$ okr/min na $n_r = 1330$ okr/min uz moment $M^* = -0.2$ p.u.

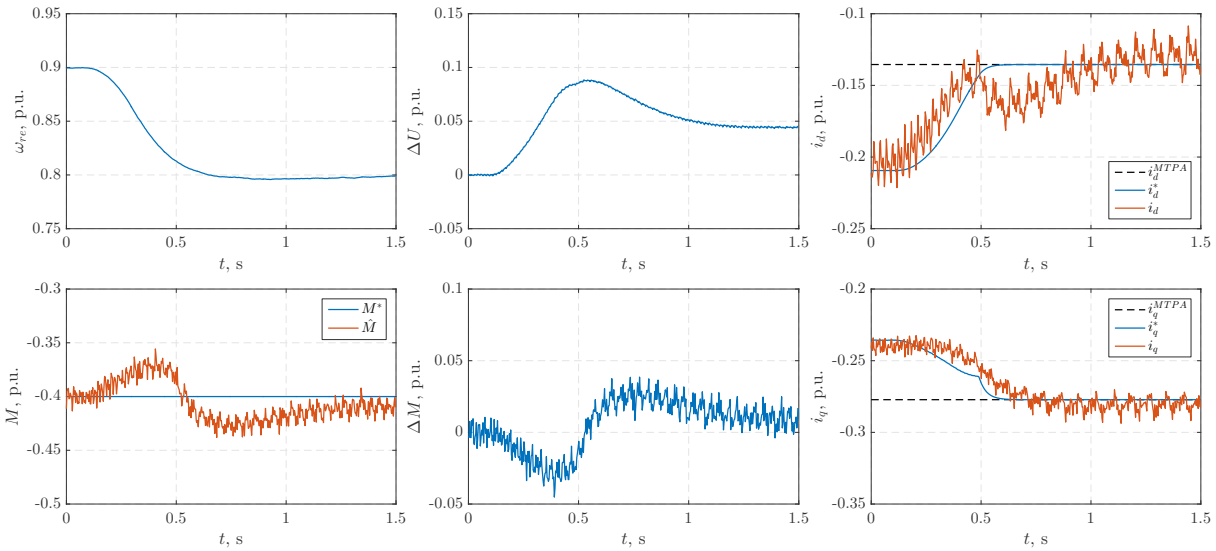

(b) Promjena brzine rotora s $n_r = 1350$ okr/min na $n_r = 1200$ okr/min uz moment $M^* = -0.4$ p.u.

Slika 6.8: Izlazak iz područja slabljenja magnetskog toka s PI regulatorom momenta za različite referentne vrijednosti momenta

regulatorom momenta u razvijenoj strukturi za referentne vrijednosti momenta $M^* = -0.2$ p.u. (promjena brzine rotora s $n_r = 1470$ okr/min na $n_r = 1330$ okr/min) i $M^* = -0.4$ p.u. (promjena brzine rotora s $n_r = 1350$ okr/min na $n_r = 1200$ okr/min).

Smanjenjem brzine rotora dolazi do smanjenja napona što uzrokuje manju vrijednost na izlazu PI regulatora napona i_d^{FW}. Budući da se time smanjuje ukupna struja i_d, smanjuje se i dodatni reluktantni moment, pa dolazi i do smanjenja vrijednosti na izlazu PI regulatora momenta i_q^{FW} kojom se kompenzira porast momenta. Kada regulacijsko odstupanje PI regulatora napona ΔU postane pozitivno, radna točka je unutar ograničenja napona te su izlazi oba PI regulatora i_d^{FW} i i_q^{FW} jednaki nuli, a referentne vrijednosti struja su jednake proračunatima prema MTPA algoritmu i_d^{MTPA} i i_q^{MTPA}.

7. Zaključak

U posljednja dva desetljeća energija vjetra je jedan od vodećih obnovljivih izvora energije te dolazi do značajnog razvoja sustava za pretvorbu energije vjetra. Ovisno o strukturi upravljanja brzinom vjetroturbine, generatoru i komponentama učinske elektronike ističu se četiri tipa vjetroelektrana. Zbog brojnih prednosti pred ostalim tipovima vjetroelektrana i aktualnih znanstvenih istraživanja, četvrti tip vjetroelektrane, zasnovan na sinkronom generatoru sa stalnim magnetima i AC-DC-AC pretvaraču pune snage, razmatran je u doktorskoj disertaciji. Usko područje istraživanja čine napredni algoritmi upravljanja sinkronim generatorom s unutrašnjim stalnim magnetima. Pod naprednim algoritmima upravljanja podrazumijevaju se upravljačke strukture koje nadilaze ograničenja i performanse standardnih struktura upravljanja poput vektorskog upravljanja u koordinatnom sustavu magnetskog toka rotora ili izravnog upravljanja momentom.

U doktorskoj disertaciji dan je pregled znanstvene literature vezan uz uključenje generatorskog pretvarača u vrtnji sinkronog generatora sa stalnim magnetima (leteći start) i rad bez mjernog člana brzine rotora, algoritme modelskog prediktivnog upravljanja dvorazinskim pretvaračem i sinkronim strojem sa stalnim magnetima, te upravljanje u području slabljenja magnetskog toka, tj. na ograničenju napona sinkronog generatora sa stalnim magnetima. Također je u svakom od navedenih područja razvijen novi algoritam koji predstavlja nadogradnju nekog od postojećih algoritama u znanstvenoj literaturi. Razvijeni algoritmi su simulacijski provjereni u programskim okolinama MATLAB/Simulink i PLECS te eksperimentalno potvrđeni na laboratorijskom postavu (sinkroni generator sa stalnim magnetima nazivne snage 375 kW, AC-DC-AC pretvarač nazivne snage 520 kW i asinkroni motor nazivne snage 560 kW koji emulira rad vjetroturbine). Algoritmi su implementirani u digitalnom sustavu upravljanja generatorskog pretvarača koji se temelji na ADSP-21992 procesoru.

Razvijena metoda uključenja generatorskog pretvarača u vrtnji generatora (leteći start) i upravljanja bez mjernog člana brzine rotora temelji se na mjerenju induciranog napona generatora i fazno zatvorenoj petlji. Premda u znanstvenoj literaturi postoji veći broj struktura estimacije brzine i kuta rotora, postoji mali broj znanstvenih radova vezanih uz uključenje pretvarača tijekom vrtnje stroja. Rezultati pokazuju da razvijena metoda osigurava uključenje generatorskog pretvarača uz mali porast struje i zanemarivi udarac momenta te prelazak u kontinuiran

rad bez mjernog člana brzine rotora. Također je potvrđen rad bez mjernog člana brzine vrtnje pri promjeni referentne vrijednosti momenta ili brzine rotora. Korištenjem razvijenog algoritma povećava se robusnost sustava budući da se izbjegava korištenje mjernog člana brzine rotora, ali i izbjegava porast struje i udarac momenta prilikom uključenja što je od osobite važnosti kod generatora velikih snaga koji su karakteristični za vjetroelektrane.

Razvijeni algoritam modelskog prediktivnog izravnog upravljanja strujama omogućava smanjenje sklopnih gubitaka generatorskog pretvarača. Algoritam zamjenjuje standardnu strukturu vektorskog upravljanja temeljenu na PI regulatorima struja, signalima rasprezanja i pulsnoširinskoj modulaciji. Sklopkama generatorskog pretvarača se izravno upravlja čime se poboljšavaju dinamička svojstva, ali i omogućava smanjenje sklopnih gubitaka pretvarača ispravnim odabirom kriterijske funkcije. Stabilnost i uzastopna dopustivost algoritma osigurana je fleksibilnom upravljačkom Ljapunovljevom funkcijom. Upravo navedena funkcija omogućava smanjenje sklopnih gubitaka tijekom prijelazne pojave, ali i u stacionarnom stanju. Također je analiziran i utjecaj mrtvog vremena pretvarača na algoritam. Rezultati pokazuju da je odgovarajućim odabirom vrijednosti parametara za penalizaciju moguće postići željeni kompromis između prihvatljivog harmoničkog izobličenja struje i manjih sklopnih gubitaka generatorskog pretvarača.

Razvijena metoda upravljanja u području slabljenja magnetskog toka temelji se na koordiniranom radu PI regulatora napona i momenta. Većina znanstvenih radova razmatra radnu točku na ograničenju struja i napona (maksimalna snaga) što često ne odgovara stvarnim zahtjevima pogona. Razvijena metoda osigurava rad na ograničenju napona neovisno o referentnoj vrijednosti momenta, tj. nije razmatrana samo radna točka maksimalne snage. PI regulator napona osigurava rad na ograničenju napona, dok PI regulator momenta osigurava kompenzaciju porasta momenta uslijed povećanja reluktantnog momenta, tj. ispravno praćenje referentne vrijednosti momenta. Rezultati pokazuju da ulazak u područje slabljenja magnetskog toka ovisi o referentnom momentu te brzini rotora. Koordinirani rad PI regulatora napona i momenta osigurava praćenje točke sjecišta ograničenja napona i krivulje momenta koja odgovara referentnoj vrijednosti što je optimalna radna točka u području slabljenja magnetskog toka.

Osim na sinkrone generatore sa stalnim magnetima, razvijeni algoritmi su uz manje modifikacije primjenjivi i na sinkrone motore sa stalnim magnetima. S obzirom na relativno malu računalnu složenost, metode upravljanja bez mjernog člana brzine rotora i upravljanja momentom u području slabljenja magnetskog toka imaju široku industrijsku primjenu budući da njihova implementacija na većini komercijalnih mikroprocesora nije zahtjevna. S druge strane, algoritam modelskog prediktivnog upravljanja je računalno složeniji jer zahtijeva veću frekvenciju uzorkovanja od standardnih algoritama, stoga implementacija navedenog algoritma u standardnom digitalnom sustavu upravljanja predstavlja izazov.

Literatura

[1] Paris: REN21 Secretariat, “Renewables 2017 Global Status Report”, REN21, Tech. Rep., 2017.

[2] Paris: REN21 Secretariat, “Renewables Global Futures Report: Great debates towards 100% renewable energy”, REN21, Tech. Rep., 2017.

[3] Nghiem, A., Mbistrova, A., “Wind in power: 2016 European statistics”, WindEurope, Tech. Rep., 2017.

[4] Giorgio Corbetta, A. H., Pineda, I., “Wind energy scenarios for 2030”, WindEurope, Tech. Rep., 2015.

[5] Liserre, M., Cardenas, R., Molinas, M., Rodriguez, J., “Overview of multi-mw wind turbines and wind parks”, IEEE Transactions on Industrial Electronics, Vol. 58, No. 4, 2011, str. 1081–1095.

[6] Li, H., Yang, C., Zhao, B., Wang, H., Chen, Z., “Aggregated models and transient performances of a mixed wind farm with different wind turbine generator systems”, Electric Power Systems Research, Vol. 92, 2012, str. 1–10.

[7] Chinchilla, M., Arnaltes, S., Burgos, J. C., “Control of permanent-magnet generators applied to variable-speed wind-energy systems connected to the grid”, IEEE Transactions on energy conversion, Vol. 21, No. 1, 2006, str. 130–135.

[8] Grabic, S., Celanovic, N., Katic, V. A., “Permanent magnet synchronous generator cascade for wind turbine application”, IEEE Transactions on Power Electronics, Vol. 23, No. 3, 2008, str. 1136–1142.

[9] Ribrant, J., Bertling, L., “Survey of failures in wind power systems with focus on swedish wind power plants during 1997-2005”, in Power Engineering Society General Meeting, 2007. IEEE. IEEE, 2007, str. 1–8.

[10] Yaramasu, V., “Predictive control of multilevel converters for megawatt wind energy conversion systems”, Doktorski rad, Ph. D. dissertation, Ryerson Univ., Toronto, ON, Canada, 2014.

[11] Yaramasu, V., Wu, B., “Predictive control of a three-level boost converter and an npc inverter for high-power pmsg-based medium voltage wind energy conversion systems”, IEEE Trans. Power Electron, Vol. 29, No. 10, 2014, str. 5308–5322.

[12] 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.

[13] Papathanassiou, S. A., Papadopoulos, M. P., “Mechanical stresses in fixed-speed wind turbines due to network disturbances”, IEEE Transactions on Energy Conversion, Vol. 16, No. 4, 2001, str. 361–367.

[14] Estima, J. O., “Development and analysis of permanent magnet synchronous motor drives with fully integrated inverter fault-tolerant capabilities”, Doktorski rad, 2012.

[15] Wu, B., Lang, Y., Zargari, N., Kouro, S., Power conversion and control of wind energy systems. John Wiley & Sons, 2011, Vol. 76.

[16] Bariša, T., Sumina, D., Kutija, M., “Control of generator-and grid-side converter for the interior permanent magnet synchronous generator”, in 2015 International Conference on Renewable Energy Research and Applications (ICRERA). IEEE, 2015, str. 1015–1020.

[17] Pan, C.-T., Sue, S.-M., “A linear maximum torque per ampere control for ipmsm drives over full-speed range”, IEEE Transactions on Energy Conversion, Vol. 20, No. 2, 2005, str. 359–366.

[18] 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.

[19] Morimoto, S., Takeda, Y., Hirasa, T., “Current phase control methods for permanent magnet synchronous motors”, IEEE Transactions on Power Electronics, Vol. 5, No. 2, 1990, str. 133–139.

[20] Dannehl, J., Fuchs, F. W., Thøgersen, P. B., “Pi state space current control of grid-connected pwm converters with lcl filters”, IEEE Transactions on Power Electronics, Vol. 25, No. 9, 2010, str. 2320–2330.

[21] Benjak, O., Gerling, D., “Review of position estimation methods for PMSM drives without a position sensor, part III”, in 2010 International Conference on Electrical Machines and Systems, 2010, str. 873-878.

[22] 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.

[23] Tong, L., Zou, X., Feng, S., Chen, Y., Kang, Y., Huang, Q., Huang, Y., “An SRF-PLL-based sensorless vector control using the predictive deadbeat algorithm for the direct-driven permanent magnet synchronous generator”, IEEE Transactions on Power Electronics, Vol. 29, No. 6, 2014, str. 2837–2849.

[24] Lee, K.-W., Ha, J.-I., “Evaluation of back-EMF estimators for sensorless control of permanent magnet synchronous motors”, Journal of Power Electronics, Vol. 12, No. 4, 2012, str. 604–614.

[25] Genduso, F., Miceli, R., Rando, C., Galluzzo, G. R., “Back EMF sensorless-control algorithm for high-dynamic performance PMSM”, IEEE Transactions on Industrial Electronics, Vol. 57, No. 6, 2010, str. 2092–2100.

[26] Zhao, Y., Qiao, W., Wu, L., “Improved rotor position and speed estimators for sensorless control of interior permanent-magnet synchronous machines”, IEEE Journal of Emerging and Selected Topics in Power Electronics, Vol. 2, No. 3, 2014, str. 627–639.

[27] Yan, J., Lin, H., Feng, Y., Guo, X., Huang, Y., Zhu, Z., “Improved sliding mode model reference adaptive system speed observer for fuzzy control of direct-drive permanent magnet synchronous generator wind power generation system”, IET Renewable Power Generation, Vol. 7, No. 1, 2013, str. 28–35.

[28] Qiao, W., Yang, X., Gong, X., “Wind speed and rotor position sensorless control for direct-drive PMG wind turbines”, IEEE Transactions on Industry Applications, Vol. 48, No. 1, 2012, str. 3–11.

[29] Kim, H., Son, J., Lee, J., “A high-speed sliding-mode observer for the sensorless speed control of a PMSM”, IEEE Transactions on Industrial Electronics, Vol. 58, No. 9, 2011, str. 4069–4077.

[30] 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, 2010, str. 1270–1278.

[31] Zhang, G., Wang, G., Xu, D., Ni, R., Jia, C., "Multiple-AVF cross-feedback-network-based position error harmonic fluctuation elimination for sensorless IPMSM drives", IEEE Transactions on Industrial Electronics, Vol. 63, No. 2, 2016, str. 821–831.

[32] Ramezani, M., Ojo, O., "The modeling and position-sensorless estimation technique for a nine-phase interior permanent-magnet machine using high-frequency injections", IEEE Transactions on Industry Applications, Vol. 52, No. 2, 2016, str. 1555–1565.

[33] Quang, N. K., Hieu, N. T., Ha, Q., "FPGA-based sensorless PMSM speed control using reduced-order extended Kalman filters", IEEE transactions on Industrial Electronics, Vol. 61, No. 12, 2014, str. 6574–6582.

[34] 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.

[35] Bolognani, S., Tubiana, L., Zigliotto, M., "EKF-based sensorless IPM synchronous motor drive for flux-weakening applications", IEEE Transactions on Industry Applications, Vol. 39, No. 3, 2003, str. 768–775.

[36] Kutija, M., Sumina, D., Čolović, I., "Magnetization of speed sensorless squirrel-cage induction generator for wind power application using a phase-locked loop", Electric power systems research, Vol. 122, 2015, str. 119–129.

[37] Comanescu, M., Xu, L., "An improved flux observer based on PLL frequency estimator for sensorless vector control of induction motors", IEEE Transactions on Industrial Electronics, Vol. 53, No. 1, 2006, str. 50–56.

[38] Lascu, C., Boldea, I., Blaabjerg, F., Chen, W., "A class of flux observers for doubly-fed induction generators used in small power wind generation systems", in Energy Conversion Congress and Exposition (ECCE), 2013 IEEE. IEEE, 2013, str. 2289–2295.

[39] Rodríguez, P., Pou, J., Bergas, J., Candela, J. I., Burgos, R. P., Boroyevich, D., "Decoupled double synchronous reference frame PLL for power converters control", IEEE Transactions on Power Electronics, Vol. 22, No. 2, 2007, str. 584–592.

[40] Ekström, R., Leijon, M., "Lower order grid current harmonics for a voltage-source inverter connected to a distorted grid", Electric power systems research, Vol. 106, 2014, str. 226–231.

[41] 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.

[42] Qiu, J., Shi, C., “Flux observer with two-phase-type PLL for sensorless direct torque control of surface mounted PMSM drives”, in IECON 2011-37th Annual Conference on IEEE Industrial Electronics Society. IEEE, 2011, str. 1860–1865.

[43] 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.

[44] 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.

[45] Bolognani, S., Ortombina, L., Tinazzi, F., Zigliotto, M., “Model sensitivity of fundamental-frequency-based position estimators for sensorless pm and reluctance synchronous motor drives”, IEEE Transactions on Industrial Electronics, Vol. 65, No. 1, 2018, str. 77–85.

[46] Schroedl, M., “Sensorless control of ac machines at low speed and standstill based on the" inform" method”, in Industry Applications Conference, 1996. Thirty-First IAS Annual Meeting, IAS’96., Conference Record of the 1996 IEEE, Vol. 1. IEEE, 1996, str. 270–277.

[47] Jansen, P., Corley, M., Lorenz, R., “Flux, position, and velocity estimation in ac machines at zero and low speed via tracking of high frequency saliencies”, EPE Journal, Vol. 9, No. 1-2, 1999, str. 45–50.

[48] Corley, M. J., Lorenz, R. D., “Rotor position and velocity estimation for a salient-pole permanent magnet synchronous machine at standstill and high speeds”, IEEE Transactions on Industry Applications, Vol. 34, No. 4, 1998, str. 784–789.

[49] Jang, J.-H., Ha, J.-I., Ohto, M., Ide, K., Sul, S.-K., “Analysis of permanent-magnet machine for sensorless control based on high-frequency signal injection”, IEEE Transactions on Industry Applications, Vol. 40, No. 6, 2004, str. 1595–1604.

[50] Zhang, G., Wang, G., Xu, D., Zhao, N., “Adaline-network-based pll for position sensorless interior permanent magnet synchronous motor drives”, IEEE Transactions on Power Electronics, Vol. 31, No. 2, 2016, str. 1450–1460.

[51] Zine, W., Makni, Z., Monmasson, E., Idkhajine, L., Condamin, B., “Interests and limits of machine learning-based neural networks for rotor position estimation in ev traction drives”, IEEE Transactions on Industrial Informatics, Vol. 14, No. 5, 2018, str. 1942–1951.

[52] Lin, F.-J., Hung, Y.-C., Chen, J.-M., Yeh, C.-M., "Sensorless ipmsm drive system using saliency back-emf-based intelligent torque observer with mtpa control", IEEE Transactions on Industrial Informatics, Vol. 10, No. 2, 2014, str. 1226–1241.

[53] Lian, K.-Y., Chiang, C.-H., Tu, H.-W., "Lmi-based sensorless control of permanent-magnet synchronous motors", IEEE Transactions on Industrial Electronics, Vol. 54, No. 5, 2007, str. 2769–2778.

[54] Borisavljevic, A., Ho, E., Takahashi, T., "Fan drive starting into naturally rotating load by sinusoidal sensorless permanent magnet motor control", in Power Electronics and Motion Control Conference, 2006. EPE-PEMC 2006. 12th International. IEEE, 2006, str. 1190–1198.

[55] Doktar, A., Strandberg, S., Ollila, J., "Frequency converter start-up", uS Patent 8,350,506. Jan. 8 2013.

[56] Nilson, T. A. G., "Method for restarting a synchronous permanent magnet motor still rotating", uS Patent 6,201,367. Mar. 13 2001.

[57] 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.

[58] 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, 2018, str. 1097–1106.

[59] Borisavljevic, A., "Measurement of speed and direction of coasting permanent magnet synchronous motor", uS Patent 7,965,053. Jun. 21 2011.

[60] Hanamoto, T., Yamada, H., Okuyama, Y., "Position sensorless start-up method of surface permanent magnet synchronous motor using nonlinear rotor position observer", in Power Electronics Conference (IPEC-Hiroshima 2014-ECCE-ASIA), 2014 International. IEEE, 2014, str. 1811–1815.

[61] 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.

[62] 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.

[63] Marčetić, D., "Mikroprocesorsko upravljanje energetskim pretvaračima", FTN Izdavaštvo, 2014.

[64] Hinkkanen, M., Luomi, J., "Modified integrator for voltage model flux estimation of induction motors", IEEE Transactions on Industrial Electronics, Vol. 50, No. 4, 2003, str. 818–820.

[65] Hu, J., Wu, B., "New integration algorithms for estimating motor flux over a wide speed range", IEEE transactions on power electronics, Vol. 13, No. 5, 1998, str. 969–977.

[66] Preindl, M., Bolognani, S., "Comparison of direct and pwm model predictive control for power electronic and drive systems", in Applied Power Electronics Conference and Exposition (APEC), 2013 Twenty-Eighth Annual IEEE. IEEE, 2013, str. 2526–2533.

[67] Leon, J. I., Kouro, S., Franquelo, L. G., Rodriguez, J., Wu, B., "The essential role and the continuous evolution of modulation techniques for voltage-source inverters in the past, present, and future power electronics", IEEE Trans. Ind. Electron, Vol. 63, No. 5, 2016, str. 2688–2701.

[68] Preindl, M., Bolognani, S., Danielson, C., "Model predictive torque control with pwm using fast gradient method", in Applied Power Electronics Conference and Exposition (APEC), 2013 Twenty-Eighth Annual IEEE. IEEE, 2013, str. 2590–2597.

[69] Richter, S., Mariéthoz, S., Morari, M., "High-speed online mpc based on a fast gradient method applied to power converter control", in American Control Conference (ACC), 2010. IEEE, 2010, str. 4737–4743.

[70] Cimini, G., Bernardini, D., Bemporad, A., Levijoki, S., "Online model predictive torque control for permanent magnet synchronous motors", in Industrial Technology (ICIT), 2015 IEEE International Conference on. IEEE, 2015, str. 2308–2313.

[71] Liu, J., Gong, C., Han, Z., Yu, H., "Ipmsm model predictive control in flux-weakening operation using an improved algorithm", IEEE Transactions on Industrial Electronics, 2018.

[72] Bordons, C., Montero, C., "Basic principles of mpc for power converters: Bridging the gap between theory and practice", IEEE Industrial Electronics Magazine, Vol. 9, No. 3, 2015, str. 31–43.

[73] Judewicz, M. G., Gonzalez, S. A., Echeverria, N. I., Fischer, J. R., Carrica, D. O., "Generalized predictive current control (gpcc) for grid-tie three-phase inverters", IEEE Transactions on Industrial Electronics, Vol. 63, No. 7, 2016, str. 4475–4484.

[74] Vazquez, S., Montero, C., Bordons, C., Franquelo, L. G., "Model predictive control of a vsi with long prediction horizon", in Industrial Electronics (ISIE), 2011 IEEE International Symposium on. IEEE, 2011, str. 1805–1810.

[75] Vazquez, S., Montero, C., Bordons, C., Franquelo, L. G., "Design and experimental validation of a model predictive control strategy for a vsi with long prediction horizon", in Industrial Electronics Society, IECON 2013-39th Annual Conference of the IEEE. IEEE, 2013, str. 5788–5793.

[76] Bolognani, S., Bolognani, S., Peretti, L., Zigliotto, M., "Design and implementation of model predictive control for electrical motor drives", IEEE Transactions on industrial electronics, Vol. 56, No. 6, 2009, str. 1925–1936.

[77] Mariéthoz, S., Domahidi, A., Morari, M., "Sensorless explicit model predictive control of permanent magnet synchronous motors", in Electric Machines and Drives Conference, 2009. IEMDC'09. IEEE International. IEEE, 2009, str. 1250–1257.

[78] Belda, K., Vošmik, D., "Explicit generalized predictive control of speed and position of pmsm drives", IEEE Transactions on Industrial Electronics, Vol. 63, No. 6, 2016, str. 3889–3896.

[79] Vazquez, S., Rodriguez, J., Rivera, M., Franquelo, L. G., Norambuena, M., "Model predictive control for power converters and drives: Advances and trends", IEEE Transactions on Industrial Electronics, Vol. 64, No. 2, 2017, str. 935–947.

[80] Quevedo, D. E., Aguilera, R. P., Perez, M. A., Cortés, P., Lizana, R., "Model predictive control of an afe rectifier with dynamic references", IEEE Transactions on Power Electronics, Vol. 27, No. 7, 2012, str. 3128–3136.

[81] Arif, B., Tarisciotti, L., Zanchetta, P., Clare, J. C., Degano, M., "Grid parameter estimation using model predictive direct power control", IEEE Transactions on Industry Applications, Vol. 51, No. 6, 2015, str. 4614–4622.

[82] Panten, N., Hoffmann, N., Fuchs, F. W., "Finite control set model predictive current control for grid-connected voltage-source converters with lcl filters: A study based on different state feedbacks", IEEE Transactions on Power Electronics, Vol. 31, No. 7, 2016, str. 5189–5200.

[83] Falkowski, P., Sikorski, A., "Finite control set model predictive control for grid-connected ac–dc converters with lcl filter", IEEE Transactions on Industrial Electronics, Vol. 65, No. 4, 2018, str. 2844–2852.

[84] Dragičević, T., "Model predictive control of power converters for robust and fast operation of ac microgrids", IEEE Transactions on Power Electronics, Vol. 33, No. 7, 2018, str. 6304–6317.

[85] Zhang, Z., Hackl, C., Wang, F., Chen, Z., Kennel, R., "Encoderless model predictive control of back-to-back converter direct-drive permanent-magnet synchronous generator wind turbine systems", in Power Electronics and Applications (EPE), 2013 15th European Conference on. IEEE, 2013, str. 1–10.

[86] Yaramasu, V., Wu, B., Rivera, M., Rodriguez, J., "A new power conversion system for megawatt pmsg wind turbines using four-level converters and a simple control scheme based on two-step model predictive strategy—part ii: Simulation and experimental analysis", IEEE Journal of Emerging and Selected Topics in Power Electronics, Vol. 2, No. 1, 2014, str. 14–25.

[87] Yaramasu, V., Wu, B., Alepuz, S., Kouro, S., "Predictive control for low-voltage ride-through enhancement of three-level-boost and npc-converter-based pmsg wind turbine", IEEE Transactions on Industrial Electronics, Vol. 61, No. 12, 2014, str. 6832–6843.

[88] Kou, P., Liang, D., Li, J., Gao, L., Ze, Q., "Finite-control-set model predictive control for dfig wind turbines", IEEE Transactions on Automation Science and Engineering, 2017.

[89] Preindl, M., Bolognani, S., "Model predictive direct speed control with finite control set of pmsm drive systems", IEEE Transactions on Power Electronics, Vol. 28, No. 2, 2013, str. 1007–1015.

[90] Fuentes, E., Kalise, D., Rodríguez, J., Kennel, R. M., "Cascade-free predictive speed control for electrical drives", IEEE Transactions on Industrial Electronics, Vol. 61, No. 5, 2014, str. 2176–2184.

[91] Mwasilu, F., Choi, H. H., Jung, J.-W. *et al.*, "Finite set model predictive control of interior pm synchronous motor drives with an external disturbance rejection technique", IEEE/ASME Transactions on Mechatronics, Vol. 22, No. 2, 2017, str. 762–773.

[92] Morel, F., Lin-Shi, X., Rétif, J.-M., Allard, B., Buttay, C., "A comparative study of predictive current control schemes for a permanent magnet synchronous machine drive", IEEE Transactions on Industrial Electronics, Vol. 56, No. 7, 2009, str. 2715–2728.

[93] Preindl, M., Bolognani, S., "Model predictive direct torque control with finite control set for pmsm drive systems, part 1: Maximum torque per ampere operation", IEEE Transactions on Industrial Informatics, Vol. 9, No. 4, 2013, str. 1912–1921.

[94] Preindl, M., Bolognani, S., “Model predictive direct torque control with finite control set for pmsm drive systems, part 2: field weakening operation”, IEEE Transactions on Industrial Informatics, Vol. 9, No. 2, 2013, str. 648–657.

[95] Preindl, M., Schaltz, E., “Sensorless model predictive direct current control using novel second-order pll observer for pmsm drive systems”, IEEE Transactions on Industrial Electronics, Vol. 58, No. 9, 2011, str. 4087–4095.

[96] Xie, W., Wang, X., Wang, F., Xu, W., Kennel, R. M., Gerling, D., Lorenz, R. D., “Finite-control-set model predictive torque control with a deadbeat solution for pmsm drives”, IEEE Transactions on Industrial Electronics, Vol. 62, No. 9, 2015, str. 5402–5410.

[97] Sandre-Hernandez, O., Rangel-Magdaleno, J., Morales-Caporal, R., “A comparison on finite-set model predictive torque control schemes for pmsm’s”, IEEE Transactions on Power Electronics, 2017.

[98] Geyer, T., Papafotiou, G., Morari, M., “Model predictive direct torque control—part i: Concept, algorithm, and analysis”, IEEE Transactions on Industrial Electronics, Vol. 56, No. 6, 2009, str. 1894–1905.

[99] Papafotiou, G., Kley, J., Papadopoulos, K. G., Bohren, P., Morari, M., “Model predictive direct torque control—part ii: Implementation and experimental evaluation”, IEEE Transactions on industrial electronics, Vol. 56, No. 6, 2009, str. 1906–1915.

[100] Geyer, T., Beccuti, G. A., Papafotiou, G., Morari, M., “Model predictive direct torque control of permanent magnet synchronous motors”, in Energy Conversion Congress and Exposition (ECCE), 2010, str. 199–206.

[101] Geyer, T., “Computationally efficient model predictive direct torque control”, in Energy Conversion Congress and Exposition (ECCE), 2010 IEEE. IEEE, 2010, str. 207–214.

[102] Geyer, T., “A comparison of control and modulation schemes for medium-voltage drives: Emerging predictive control concepts versus pwm-based schemes”, IEEE Transactions on Industry Applications, Vol. 47, No. 3, 2011, str. 1380–1389.

[103] Stellato, B., Geyer, T., Goulart, P. J., “High-speed finite control set model predictive control for power electronics”, IEEE Transactions on power electronics, Vol. 32, No. 5, 2017, str. 4007–4020.

[104] Choi, D.-K., Lee, K.-B., “Dynamic performance improvement of ac/dc converter using model predictive direct power control with finite control set”, IEEE Transactions on Industrial Electronics, Vol. 62, No. 2, 2015, str. 757–767.

[105] Zhang, Y., Peng, Y., Yang, H., “Performance improvement of two-vectors-based model predictive control of pwm rectifier”, IEEE Transactions on Power Electronics, Vol. 31, No. 8, 2016, str. 6016–6030.

[106] Yan, Y., Wang, S., Xia, C., Wang, H., Shi, T., “Hybrid control set-model predictive control for field-oriented control of vsi-pmsm”, IEEE Transactions on Energy Conversion, Vol. 31, No. 4, 2016, str. 1622–1633.

[107] Wang, T., Liu, C., Lei, G., Guo, Y., Zhu, J., “Model predictive direct torque control of permanent magnet synchronous motors with extended set of voltage space vectors”, IET Electric Power Applications, Vol. 11, No. 8, 2017, str. 1376–1382.

[108] Zhou, Z., Xia, C., Yan, Y., Wang, Z., Shi, T., “Torque ripple minimization of predictive torque control for pmsm with extended control set”, IEEE Transactions on Industrial Electronics, Vol. 64, No. 9, 2017, str. 6930–6939.

[109] Zhang, Y., Bai, Y., Yang, H., “A universal multiple-vector-based model predictive control of induction motor drives”, IEEE Transactions on Power Electronics, Vol. 33, No. 8, 2018, str. 6957–6969.

[110] Song, Z., Tian, Y., Chen, W., Zou, Z., Chen, Z., “Predictive duty cycle control of three-phase active-front-end rectifiers”, IEEE Trans. Power Electron., Vol. 31, No. 1, 2016, str. 698–710.

[111] Aguilera, R. P., Quevedo, D. E., “Stability analysis of quadratic mpc with a discrete input alphabet”, IEEE Transactions on Automatic Control, Vol. 58, No. 12, 2013, str. 3190–3196.

[112] Aguilera, R. P., Quevedo, D. E., “Predictive control of power converters: Designs with guaranteed performance”, IEEE Transactions on Industrial Informatics, Vol. 11, No. 1, 2015, str. 53–63.

[113] Kwak, S., Yoo, S.-J., Park, J., “Finite control set predictive control based on lyapunov function for three-phase voltage source inverters”, IET Power Electronics, Vol. 7, No. 11, 2014, str. 2726–2732.

[114] Akter, M. P., Mekhilef, S., Tan, N. M. L., Akagi, H., “Modified model predictive control of a bidirectional ac–dc converter based on lyapunov function for energy storage systems”, IEEE Transactions on Industrial Electronics, Vol. 63, No. 2, 2016, str. 704–715.

[115] Alam, K. S., Akter, M. P., Xiao, D., Zhang, D., Rahman, F. M., “Asymptotically stable predictive control of a grid-connected converter based on discrete space vector modulation”, IEEE Transactions on Industrial Informatics, 2018.

[116] Jung, J.-W. *et al.*, “Asymptotic stability constraints for direct horizon-one model predictive control of spmsm drives”, IEEE Transactions on Power Electronics, 2018.

[117] Jung, J.-W. *et al.*, “Finite control set model predictive control to guarantee stability and robustness for surface-mounted pm synchronous motors”, IEEE Transactions on Industrial Electronics, 2018.

[118] Liu, Q., Hameyer, K., “Torque ripple minimization for direct torque control of pmsm with modified fcsmpc”, IEEE Transactions on Industry Applications, Vol. 52, No. 6, 2016, str. 4855–4864.

[119] Preindl, M., “Robust control invariant sets and lyapunov-based mpc for ipm synchronous motor drives”, IEEE Transactions on Industrial Electronics, Vol. 63, No. 6, 2016, str. 3925–3933.

[120] Barisa, T., Iles, S., Sumina, D., Matusko, J., “Model predictive direct current control of permanent magnet synchronous generator based on flexible lyapunov function considering converter dead time”, IEEE Transactions on Industry Applications, 2018.

[121] Rawlings, J. B., Mayne, D. Q., Diehl, M., Model Predictive Control: Theory, Computation, and Design. Nob Hill Publishing, 2017.

[122] Geyer, T., Model predictive control of high power converters and industrial drives. John Wiley & Sons, 2016.

[123] Choi, J.-W., Sul, S.-K., “Inverter output voltage synthesis using novel dead time compensation”, IEEE transactions on Power Electronics, Vol. 11, No. 2, 1996, str. 221–227.

[124] Jeong, S.-G., Park, M.-H., “The analysis and compensation of dead-time effects in pwm inverters”, IEEE Transactions on Industrial Electronics, Vol. 38, No. 2, 1991, str. 108–114.

[125] Lewicki, A., “Dead-time effect compensation based on additional phase current measurements.”, IEEE Trans. Industrial Electronics, Vol. 62, No. 7, 2015, str. 4078–4085.

[126] Bedetti, N., Calligaro, S., Petrella, R., “Self-commissioning of inverter dead-time compensation by multiple linear regression based on a physical model”, IEEE Transactions on Industry Applications, Vol. 51, No. 5, 2015, str. 3954–3964.

[127] Lee, D.-H., Ahn, J.-W., “A simple and direct dead-time effect compensation scheme in pwm-vsi”, IEEE Transactions on Industry Applications, Vol. 50, No. 5, 2014, str. 3017–3025.

[128] Lazar, M., “Flexible control lyapunov functions”, in American Control Conference, 2009. ACC’09. IEEE, 2009, str. 102–107.

[129] Preindl, M., Schaltz, E., Thogersen, P., “Switching frequency reduction using model predictive direct current control for high-power voltage source inverters”, IEEE Transactions on Industrial Electronics, Vol. 58, No. 7, 2011, str. 2826–2835.

[130] Rodriguez, J., Pontt, J., Silva, C. A., Correa, P., Lezana, P., Cortés, P., Ammann, U., “Predictive current control of a voltage source inverter”, IEEE transactions on industrial electronics, Vol. 54, No. 1, 2007, str. 495–503.

[131] Cortes, P., Rodriguez, J., Silva, C., Flores, A., “Delay compensation in model predictive current control of a three-phase inverter”, IEEE Transactions on Industrial Electronics, Vol. 59, No. 2, 2012, str. 1323–1325.

[132] 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.

[133] Soong, W. L., Miller, T., “Field-weakening performance of brushless synchronous ac motor drives”, IEE Proceedings-Electric Power Applications, Vol. 141, No. 6, 1994, str. 331–340.

[134] Bianchi, N., Bolognani, S., “Parameters and volt-ampere ratings of a synchronous motor drive for flux-weakening applications”, IEEE transactions on power electronics, Vol. 12, No. 5, 1997, str. 895–903.

[135] Yoon, Y.-D., Lee, W.-J., Sul, S.-K., “New flux weakening control for high saliency interior permanent magnet synchronous machine without any tables”, in Power Electronics and Applications, 2007 European Conference on. IEEE, 2007, str. 1–7.

[136] Olarescu, N., Weinmann, M., Zeh, S., Musuroi, S., “Novel flux weakening control algorithm for pmsms”, in Power Engineering, Energy and Electrical Drives, 2009. POWERENG’09. International Conference on. IEEE, 2009, str. 123–127.

[137] Tursini, M., Chiricozzi, E., Petrella, R., “Feedforward flux-weakening control of surface-mounted permanent-magnet synchronous motors accounting for resistive voltage drop”, IEEE Transactions on industrial electronics, Vol. 57, No. 1, 2010, str. 440–448.

[138] Verl, A., Bodson, M., “Torque maximization for permanent magnet synchronous motors”, IEEE Transactions on Control Systems Technology, Vol. 6, No. 6, 1998, str. 740–744.

[139] Zhu, L., Wen, X., "A new precise torque control method of pmsms in flux-weakening operation", in Transportation Electrification Asia-Pacific (ITEC Asia-Pacific), 2014 IEEE Conference and Expo. IEEE, 2014, str. 1–4.

[140] Bech, M. M., Frederiksen, T. S., Sandholdt, P., "Accurate torque control of saturated interior permanent magnet synchronous motors in the field-weakening region", in Industry Applications Conference, 2005. Fourtieth IAS Annual Meeting. Conference Record of the 2005, Vol. 4. IEEE, 2005, str. 2526–2532.

[141] Zhang, Y., Xu, L., Mustafa, K., Chi, S., Illindala, M. *et al.*, "Experimental verification of deep field weakening operation of a 50-kw ipm machine by using single current regulator", IEEE Transactions on Industry Applications, Vol. 47, No. 1, 2011, str. 128–133.

[142] Kwon, T.-S., Sul, S.-K., "Novel antiwindup of a current regulator of a surface-mounted permanent-magnet motor for flux-weakening control", IEEE Transactions on industry applications, Vol. 42, No. 5, 2006, str. 1293–1300.

[143] Sue, S.-M., Pan, C.-T., "Voltage-constraint-tracking-based field-weakening control of ipm synchronous motor drives", IEEE Transactions on Industrial Electronics, Vol. 55, No. 1, 2008, str. 340–347.

[144] Jevremovic, V. R., Marcetic, D. P., "Closed-loop flux-weakening for permanent magnet synchronous motors", in 4th IET Conference on Power Electronics, Machines and Drives. IET, 2008, str. 717-721.

[145] Stojan, D., Drevensek, D., Plantic, Z., Grcar, B., Stumberger, G., "Novel field-weakening control scheme for permanent-magnet synchronous machines based on voltage angle control", IEEE Transactions on Industry Applications, Vol. 48, No. 6, 2012, str. 2390–2401.

[146] Bolognani, S., Calligaro, S., Petrella, R., "Adaptive flux-weakening controller for interior permanent magnet synchronous motor drives", IEEE Journal of Emerging and Selected Topics in Power Electronics, Vol. 2, No. 2, 2014, str. 236–248.

[147] Pravica, L., Bariša, T., "Torque control of a wind power permanent magnet generator in a flux weakening region", in Electrical Drives and Power Electronics (EDPE), 2017 19th International Conference on. IEEE, 2017, str. 273–278.

[148] Jukic, F., Sumina, D., Erceg, I., "Comparison of torque estimation methods for interior permanent magnet wind power generator", in Electrical Drives and Power Electronics (EDPE), 2017 19th International Conference on. IEEE, 2017, str. 291–296.

Popis oznaka i kratica

Kratice

SCIG	*squirrel cage induction generator*
DFIG	*doubly fed induction generator*
WRIG	*wound rotor induction generator*
PMG	*permanent magnet generator*
WRSG	*wound rotor synchronous generator*
IGBT	*insulated gate bipolar transistor*
WECS	*wind energy conversion system*
MPPT	*maximum power point tracking*
RFOC	*rotor field oriented control*
DTC	*direct torque control*
MTPA	*maximum torque per ampere*
PWM	*pulse width modulation*
SVPWM	*space vector pulse width modulation*
LVRT	*low voltage ride through*
VOC	*voltage oriented control*
MRAS	*model reference adaptive system*
SMO	*sliding mode observer*
EKF	*extended Kalman filter*
PLL	*phase locked loop*
EEF	*extended electromotive force*
HF	*high frequency*
INFORM	*indirect flux detection by on-line reactance measurement*
AI	*artificial intelligence*
NN	*neural network*
LPF	*low pass filter*
MPC	*model predictive control*

CCS-MPC	*continuous control set model predictive control*
FCS-MPC	*finite control set model predictive control*
GPC	*generalized predictive control*
EMPC	*explicit model predictive control*
CARIMA	*controlled auto-regressive integrated moving average*
UPS	*uninterrupted power supply*
OSV-MPC	*optimal switching vector model predictive control*
OSS-MPC	*optimal switching sequence model predictive control*
MP-DSC	*model predictive direct speed control*
MP-DTC	*model predictive direct torque control*
MP-DPC	*model predictive direct power control*
MP-DCC	*model predictive direct current control*
NPC	*neutral point clamped*
CLF	*control Lyapunov function*
CIS	*control invariant set*
THD	*total harmonic distortion*
FFT	*fast Fourier transform*
FW	*flux weakening*
MTPV	*maximum torque per voltage*
MTPF	*maximum torque per flux*
FEM	*finite element method*

Oznake

P_n	nazivna snaga
U_n	nazivni napon
E_n	nazivni inducirani napon generatora
I_n	nazivna struja
f_n	nazivna frekvencija
n_n	nazivna brzina rotora
$\boldsymbol{u}_{abc}$	napon statora generatora u *abc* koordinatnom sustavu
$\boldsymbol{u}_{\alpha\beta}$	napon statora generatora u $\alpha\beta$ koordinatnom sustavu
$\boldsymbol{u}_{dq}$	napon statora generatora u sinkronom *dq* koordinatnom sustavu
$\boldsymbol{i}_{abc}$	struja generatora u *abc* koordinatnom sustavu
$\boldsymbol{i}_{\alpha\beta}$	struja generatora u $\alpha\beta$ koordinatnom sustavu
$\boldsymbol{i}_{dq}$	struja generatora u sinkronom *dq* koordinatnom sustavu
$\boldsymbol{\psi}_{abc}$	magnetski tok generatora u *abc* koordinatnom sustavu
$\boldsymbol{\psi}_{\alpha\beta}$	magnetski tok generatora u $\alpha\beta$ koordinatnom sustavu
$\boldsymbol{\psi}_{dq}$	magnetski tok generatora u sinkronom *dq* koordinatnom sustavu
R_s	otpor statora
L_d	induktivitet u izravnoj *d* osi
L_q	induktivitet u poprečnoj *q* osi
L_0	srednja vrijednost induktiviteta
L_2	amplituda oscilacija induktiviteta
ψ_{md}	magnetski tok stalnih magneta
ω_r	mehanička kutna brzina rotora
ω_{re}	električna kutna brzina rotora
θ_r	mehanički kut rotora
θ_{re}	električni kut rotora
p	broj pari polova
M_{em}	elektromagnetski moment
$\boldsymbol{i}_{dq}^*$	referentna vrijednost struje u sinkronom *dq* koordinatnom sustavu
$\boldsymbol{u}_{dq}^*$	referentna vrijednost napona u sinkronom *dq* koordinatnom sustavu
$\boldsymbol{u}_{\alpha\beta}^*$	referentna vrijednost napona u $\alpha\beta$ koordinatnom sustavu
M^*	referentna vrijednost momenta
U_{dc}	napon istosmjernog međukruga
f_{sw}	sklopna frekvencija
T_{dt}	mrtvo vrijeme pretvarača

θ_u	kut induciranog napona generatora
U_{amp}	amplituda mjerenog napona generatora
θ_{rph}	kut rotora u fazi predsinkronizacije
$\hat{\theta}_{re}$	estimirani kut rotora
$\hat{\omega}_{re}$	estimirana brzina rotora
$\psi_{\alpha\beta ph}$	magnetski tok u fazi predsinkronizacije
$\hat{\psi}_{\alpha\beta}$	estimirani magnetski tok u $\alpha\beta$ koordinatnom sustavu
$\hat{\psi}_{\hat{d}\hat{q}}$	estimirani magnetski tok u estimiranom sinkronom dq koordinatnom sustavu
$\hat{\boldsymbol{u}}_{\alpha\beta}$	rekonstruirani napon generatora u $\alpha\beta$ koordinatnom sustavu
$\hat{\boldsymbol{u}}_{abc}$	rekonstruirani napon generatora u abc koordinatnom sustavu
T_{PWM}	vremenski period pulsno-širinske modulacije
$\hat{\boldsymbol{e}}_{\alpha\beta}$	estimirani inducirani napon generatora u $\alpha\beta$ koordinatnom sustavu
K_p^{PLL}	proporcionalno pojačanje PI regulatora PLL strukture
T_i^{PLL}	vremenska konstanta PI regulatora PLL strukture
$\boldsymbol{x}$	varijabla stanja sustava
$\boldsymbol{u}$	upravljačka veličina sustava
A_c	matrica dinamike sustava u kontinuiranoj vremenskoj domeni
A_d	matrica dinamike sustava u diskretnoj vremenskoj domeni
B_c	ulazna matrica sustava u kontinuiranoj vremenskoj domeni
B_d	ulazna matrica sustava u diskretnoj vremenskoj domeni
C_c	izlazna matrica sustava u kontinuiranoj vremenskoj domeni
C_d	izlazna matrica sustava u diskretnoj vremenskoj domeni
G_c	matrica poremećaja sustava u kontinuiranoj vremenskoj domeni
G_d	matrica poremećaja sustava u diskretnoj vremenskoj domeni
T_s	vrijeme uzorkovanja
J	kriterijska funkcija
N	predikcijski horizont
l	kriterijska funkcija u trenutnom koraku
F	kriterijska funkcija u posljednjem koraku
Q	matrica penalizacije regulacijskog odstupanja varijabli stanja u trenutnom koraku
R	matrica penalizacije promjene upravljačke veličine
P	matrica penalizacije regulacijskog odstupanja varijabli stanja u posljednjem koraku
$\mathscr{X}$	skup dopuštenih vrijednosti varijabli stanja u trenutnom koraku
$\mathscr{X}_N$	skup dopuštenih vrijednosti varijabli stanja u posljednjem koraku
$\mathscr{U}$	skup dopuštenih vrijednosti upravljačke veličine
S_x	sklopno stanje IGBT-a generatorskog pretvarača
m	varijabla koja određuje režim rada MP-DCC algoritma

$\mathscr{B}$	skup koji sadrži referentnu vrijednost struje
V	upravljačka Ljapunovljeva funkcija
λ	funkcija kojom se dodaje fleksibilnost upravljačkoj Ljapunovljevoj funkciji
b	varijabla koja definira brzinu opadanja upravljačke Ljapunovljeve funkcije
γ	veličina podrazinskog skupa upravljačke Ljapunovljeve funkcije
$\boldsymbol{y}$	odstupanje referentne vrijednosti magnetskog toka
Ω	podrazinski skup upravljačke Ljapunovljeve funkcije
$\boldsymbol{u}^*_{opt}$	optimalni vektor napona
$\boldsymbol{s}^*_{opt}$	optimalno sklopno stanje
$\mathrm{THD_i}$	ukupno harmoničko izobličenje struje
N_{sw}	broj promjene sklopnih stanja
R_s^{MPC}	otpor statora korišten u modelu za predikciju
L_d^{MPC}	induktivitet u izravnoj d osi korišten u modelu za predikciju
L_q^{MPC}	induktivitet u poprečnoj q osi korišten u modelu za predikciju
ψ_{md}^{MPC}	magnetski tok stalnih magneta korišten u modelu za predikciju
M_{PM}	komponenta momenta uzrokovana magnetskim tokom stalnih magneta
M_{rel}	reluktantni moment
I_{max}	maksimalna dopuštena vrijednost struje
U_{max}	maksimalna dopuštena vrijednost napona
$\hat{U}$	amplituda rekonstruiranog napona generatora
κ	sigurnosni faktor
$\hat{M}$	estimirani moment
i_d^{FW}	izlaz PI regulatora napona
i_q^{FW}	izlaz PI regulatora momenta
i_d^{MTPA}	referentna vrijednost struje u izravnoj d osi prema MTPA algoritmu
i_q^{MTPA}	referentna vrijednost struje u poprečnoj q osi prema MTPA algoritmu
i_d^{max}	maksimalna vrijednost struje u izravnoj d osi
i_q^{max}	maksimalna vrijednost struje u poprečnoj q osi

Popis slika

2.1. Struktura sustava za pretvorbu energije vjetra [11] 6
2.2. Tipovi sustava za pretvorbu energije vjetra [11] 8
2.3. Struktura razmatranog sustava za pretvorbu energije vjetra 15
2.4. Standardna struktura upravljanja generatorskim dijelom AC-DC-AC pretvarača 16
2.5. Standardna struktura upravljanja mrežnim dijelom AC-DC-AC pretvarača . . . 18

3.1. Shema laboratorijskog postava 20
3.2. AC-DC-AC pretvarač 21
3.3. Sinkroni generator sa stalnim magnetima i asinkroni motor 21
3.4. Spojka i mjerni član momenta HBM T40B 22
3.5. Pretvornik signala HBM TIM40 22
3.6. Digitalni sustav upravljanja 23
3.7. Programski alat *AlgoCad* 24
3.8. Programski alat *r_parnad* 24

4.1. Struktura upravljanja bez mjernog člana brzine rotora 31
4.2. Struktura određivanja kuta rotora u fazi predsinkronizacije 32
4.3. Struktura estimacije brzine i kuta rotora 33
4.4. Struktura estimacije brzine i kuta rotora bez algoritma letećeg starta 38
4.5. Uključenje generatorskog pretvarača uz strukturu estimacije bez algoritma letećeg starta pri brzini rotora $\omega_r = 0.33$ p.u. 38
4.6. Faza predsinkronizacije uz strukturu estimacije s algoritmom letećeg starta pri brzini rotora $\omega_r = 0.33$ p.u. 39
4.7. Faza sinkronizacije uz strukturu estimacije s algoritmom letećeg starta pri brzini rotora $\omega_r = 0.33$ p.u. 40
4.8. Promjena referentne vrijednosti momenta s $M^* = 0$ p.u. na $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.33$ p.u. 41
4.9. Promjena brzine rotora s $\omega_r = 0.33$ p.u. na $\omega_r = 0.4$ p.u. pri referentnoj vrijednosti momenta $M^* = -0.2$ p.u. 42

4.10. Uključenje generatorskog pretvarača uz strukturu estimacije bez algoritma letećeg starta pri brzini rotora $\omega_r = 0.33$ p.u. 43
4.11. Faza predsinkronizacije u trenutku uz strukturu estimacije s algoritmom letećeg starta pri brzini rotora $\omega_r = 0.33$ p.u. 44
4.12. Faza sinkronizacije uz strukturu estimacije s algoritmom letećeg starta pri brzini rotora $\omega_r = 0.33$ p.u. 45
4.13. Promjena referentne vrijednosti momenta s $M^* = 0$ p.u. na $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.33$ p.u. 46
4.14. Promjena brzine rotora s $\omega_r = 0.33$ p.u. na $\omega_r = 0.4$ p.u. pri referentnoj vrijednosti momenta $M^* = -0.2$ p.u. 47

5.1. Koncept modelskog prediktivnog upravljanja 56
5.2. Struktura upravljanja temeljena na razvijenom MP-DCC algoritmu 62
5.3. Topologija generatorskog pretvarača i vektori napona 64
5.4. Smjer struje u jednoj fazi pretvarača 66
5.5. Mrtvo vrijeme pretvarača 67
5.6. Dijagram toka razvijenog MP-DCC algoritma 74
5.7. MP-DCC algoritam bez ograničenja definiranog upravljačkom Ljapunovljevom funkcijom za $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. 78
5.8. MP-DCC algoritam uz različite vrijednosti veličine upravljačkog invarijantnog skupa γ za $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. 80
5.9. Usporedba MP-DCC algoritma sa standardnom i fleksibilnom upravljačkom Ljapunovljevom funkcijom s parametrima za penalizaciju ($q_0 = 1$, $r_0 = 0$, $p_0 = 1$) za $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. 81
5.10. Usporedba MP-DCC algoritma sa standardnom i fleksibilnom upravljačkom Ljapunovljevom funkcijom s parametrima za penalizaciju ($q_0 = 1$, $r_0 = 50$, $p_0 = 1$) za $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. 82
5.11. Usporedba MP-DCC algoritma s različitim kombinacijama parametara za penalizaciju u stacionarnom stanju (q_1, r_1, p_1) za $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u. 84
5.12. Skokovita promjena referentnog momenta s $M^* = -0.5$ p.u. na $M^* = -1.0$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. za MP-DCC algoritam temeljen na fleksibilnoj upravljačkoj Ljapunovljevoj funkciji 85
5.13. Frekvencijska analiza razvijenog MP-DCC algoritma u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. 85
5.14. Usporedba sklopne frekvencije i ukupnog harmoničkog izobličenja za različite kombinacije vrijednosti parametara za penalizaciju u stacionarnom stanju (q_1, r_1, p_1) u čitavom radnom području generatora 87

5.15. Usporedba MP-DCC algoritma s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 0$, $p_1 = 1$) u radnoj točki $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u. bez uzimanja i s uzimanjem u obzir mrtvog vremena generatorskog pretvarača . 88
5.16. Usporedba MP-DCC algoritma s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u. bez uzimanja i s uzimanjem u obzir mrtvog vremena generatorskog pretvarača 89
5.17. Usporedba MP-DCC algoritma s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u. bez uzimanja i s uzimanjem u obzir znatno uvećanog mrtvog vremena generatorskog pretvarača $T_{dt} = \frac{T_s}{2}$ 90
5.18. MP-DCC algoritam s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. s pogrešnim vrijednostima otpora statora R_s u predikcijskom modelu 91
5.19. MP-DCC algoritam s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. s pogrešnim vrijednostima induktiviteta L_d u predikcijskom modelu 92
5.20. MP-DCC algoritam s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. s pogrešnim vrijednostima induktiviteta L_q u predikcijskom modelu 92
5.21. MP-DCC algoritam s vrijednostima parametara za penalizaciju ($q_1 = 1$, $r_1 = 100$, $p_1 = 1$) u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. s pogrešnim vrijednostima magnetskog toka stalnih magneta ψ_{md} u predikcijskom modelu 93
5.22. Kompenzacija kašnjenja jednog ciklusa izvođenja algoritma u digitalnom sustavu 96
5.23. Uključenje generatorskog pretvarača uz razvijeni MP-DCC algoritam 97
5.24. Razvijeni MP-DCC algoritam s i bez kompenzacije kašnjenja digitalnog sustava 98
5.25. Usporedba MP-DCC algoritma s različitim kombinacijama parametara za penalizaciju u stacionarnom stanju (q_1, r_1, p_1) za $M^* = -0.2$ p.u. pri brzini rotora $\omega_r = 0.266$ p.u. 100

6.1. Ograničenja napona i struje generatora 105
6.2. Struktura vektorskog upravljanja uz strukturu slabljenja magnetskog toka . . . 106
6.3. Razvijena struktura slabljenja magnetskog toka 106
6.4. Trajektorija struje u području slabljenja magnetskog toka 108
6.5. Ulazak u područje slabljenja magnetskog toka bez PI regulatora momenta za različite referentne vrijednosti momenta 110

6.6. Izlazak iz područja slabljenja magnetskog toka bez PI regulatora momenta za različite referentne vrijednosti momenta 111
6.7. Ulazak u područje slabljenja magnetskog toka s PI regulatorom momenta za različite referentne vrijednosti momenta 112
6.8. Izlazak iz područja slabljenja magnetskog toka s PI regulatorom momenta za različite referentne vrijednosti momenta 113

Popis tablica

5.1. Vektori napona dvorazinskog generatorskog pretvarača u mirujućem $\alpha\beta$ koordinatnom sustavu 65
5.2. Sklopna frekvencija i ukupno harmoničko izobličenje za različite vrijednosti parametara za penalizaciju u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. 86
5.3. Sklopna frekvencija i ukupno harmoničko izobličenje za različite vrijednosti parametara za penalizaciju u radnoj točki $M^* = -0.5$ p.u. pri brzini rotora $\omega_r = 0.5$ p.u. 93

Životopis

Tin Bariša rođen je 1990. godine u Zagrebu gdje je završio XV. gimnaziju. Fakultet elektrotehnike i računarstva Sveučilišta u Zagrebu upisuje 2009. godine. Diplomirao je 2014. godine na Zavodu za elektrostrojarstvo i automatizaciju. Od siječnja 2015. godine do prosinca 2018. bio je zaposlen na Zavodu za elektrostrojarstvo i automatizaciju kao istraživač na projektu „Razvoj naprednih energetski učinkovitih struktura upravljanja generatorom s permanentnim magnetima bez mjernog člana brzine vrtnje“ financiranom od Hrvatske zaklade za znanost. Od veljače 2019. radi kao aplikacijski inženjer u tvrtki dSpace engineering d.o.o.

Poslijediplomski studij na Fakultetu elektrotehnike i računarstva upisao je 2014. godine. Objavio je tri znanstvena rada u časopisima indeksiranim u CC bazi, deset radova u zbornicima skupova s međunarodnom recenzijom i jedan rad na domaćem stručnom skupu. Područje njegovog znanstvenog istraživanja je upravljanje bez mjernog člana brzine vrtnje i modelsko prediktivno upravljanje sinkronim strojevima sa stalnim magnetima.

Tijekom studija mag. ing. Tin Bariša dobio je četiri priznanja Josip Lončar Fakultetskog vijeća FER-a za osobiti uspjeh u akademskim godinama 2009./2010. - 2012./2013., a za ukupan uspjeh na diplomskom studiju primio je i Brončanu plaketu „Josip Lončar“ u akademskoj godini 2013./2014. Također je jedan od dobitnika Rektorove nagrade u akademskoj godini 2013./2014.

Aktivno govori i piše engleski jezik, a služi se i njemačkim jezikom.

Popis radova

Radovi u časopisima

1. Bariša, T., Ileš, Š., Sumina, D., Matuško, J., "Model Predictive Direct Current Control of Permanent Magnet Synchronous Generator based on Flexible Lyapunov Function Considering Converter Dead Time", *IEEE Transactions on Industrial Applications*, Vol. 54, No. 3, 2018., str. 2899-2912
2. 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, 2018., str. 1097-1106

3. 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, str. 457-465

Radovi u zbornicima skupova

1. 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, 2018.
2. Ileš, Š., Bariša, T., Sumina, D., Matuško, J., "Hybrid CCS/FCS Model Predictive Current Control of a Grid Connected Two-Level Converter", *2018 IEEE 18th International Power Electronics and Motion Control Conference (PEMC)*, Budapest, 2018.
3. Jukić, F., Bariša, T., Pravica, L., Sumina, D., "Flying Start of a Permanent Magnet Wind Generator Using Discontinuous Currents and Sliding-Mode Observer", *11th Mediterranean Conference on Power Generation, Transmission, Distribution and Energy Conversion (MEDPOWER) 2018*, Dubrovnik, 2018.
4. Pravica, L., Bariša, T., "Torque control of a wind power permanent magnet generator in a flux weakening region", *2017 19th International Conference on Electrical Drives and Power Electronics (EDPE)*, Dubrovnik, 2017.
5. Bariša, T., Ileš, Š., Sumina, D., Matuško, J., "Flexible Lyapunov function based model predictive direct current control of permanent magnet synchronous generator", *2016 IEEE International Power Electronics and Motion Control Conference (PEMC)*, Varna, 2016.
6. Mrčela, I., Sumina, D., Sačić, F., Bariša, T., "A wind turbine two level back-to-back converter power loss study", *2016 IEEE International Power Electronics and Motion Control Conference (PEMC)*, Varna, 2016.
7. Bariša, T., Erceg, I., Marković, I., "Estimation of stator resistance and rotor speed for IPMSG using model reference adaptive system", *2016 IEEE International Energy Conference (ENERGYCON)*, Leuven, 2016.
8. Bariša, T., Sumina, D., Kutija, M., "Control of generator-and grid-side converter for the interior permanent magnet synchronous generator", *2015 International Conference on Renewable Energy Research and Applications (ICRERA)*, Palermo, 2015.
9. Bariša, T., Sumina, D., Kutija, M., "Comparison of maximum torque per ampere and loss minimization control for the interior permanent magnet synchronous generator", *2015 18th International Conference on Electrical Drives and Power Electronics (EDPE)*, Tatranska Lomnica, 2015.
10. Bariša, T., Bartulović, M., Žužić, G., Ileš, Š., Matuško, J., Kolonić F., "Nonlinear predictive control of a tower crane using reference shaping approach", *2014 16th International Power Electronics and Motion Control Conference and Exposition*, Antalya, 2014.

Radovi na stručnim skupovima

1. Žarko, D., Stipetić, S., Sumina, D., Bariša, T., "Permanent magnet generators for wind powerplants", *13. savjetovanje HRO CIGRÉ*, Šibenik, 2017.

Curriculum vitae

Tin Bariša was born in 1990 in Zagreb, Croatia where he graduated from XV Gymnasium. In 2009 he enrolled at the Faculty of Electrical Engineering and Computing, University of Zagreb and graduated at the Department of Electrical Machines, Drives and Automation in 2014. Since January 2015 until December 2018, he has worked at the Department of Electric Machines, Drives and Automation as research assistant on the project "Development of advanced energy efficient algorithms for sensorless control of permanent magnet generators" financed by Croatian science foundation. Since February 2019 he is working as application engineer at dSpace engineering d.o.o.

In 2014, he started his PhD studies at the Faculty of Electrical Engineering and Computing. He co-authored three papers published in journals indexed in Current Contents database and ten papers in proceedings of international conferences. His scientific interests include sensorless control and model predictive control of permanent magnet synchronous machines.

He was awarded four “Josip Lončar“ awards for outstanding success in academic years 2009/2010 - 2012/2013 and the Bronze plaque “Josip Lončar“ for overall success during graduate studies in academic year 2013/2014. He was also one of recipients of Rector’s award in academic year 2013/2014.

He has good knowledge of English and basic knowledge of the German language.