

**ZÁPADOČESKÁ  
UNIVERZITA V PLZNI**

**FAKULTA  
ELEKTROTECHNICKÁ**

**DISERTAČNÍ PRÁCE**

**PLZEŇ, 2012**

**Ing. Jakub Talla**

**ZÁPADOČESKÁ UNIVERZITA V PLZNI**

**Fakulta elektrotechnická**

**DISERTAČNÍ PRÁCE**

k získání akademického titulu doktor

v oboru

Elektronika

**Ing. Jakub Talla**

**Estimace vybraných veličin elektrických  
pohonů a aktivních filtrů**

*Školitel: Doc. Ing. Luděk Piskač, CSc.*

*Datum státní doktorské zkoušky: 1. 7. 2009*

*Datum odevzdání práce: 3. 10. 2012*

V Plzni, 2012

## **Poděkování**

Na tomto místě bych rád poděkoval všem, kteří mě ovlivnili při psaní této disertační práce. V první řadě moje poděkování patří mému školiteli, panu Doc. Ing. Ludku Piskačovi, CSc. za odbornou podporu a vedení. Dále bych rád poděkoval Prof. Ing. Zdeňku Peroutkovi, Ph.D. za velmi cenné rady a připomínky při řešení jednotlivých výzkumných úkolů. Dále pak děkuji za rady kolegům z Katedry elektromechaniky a výkonové elektroniky a v neposlední řadě mým rodinným příslušníkům a přátelům za vytvoření příjemných podmínek při tvorbě této práce.

Tato disertační práce vznikla s podporou Evropského fondu pro regionální rozvoj a Ministerstva školství, mládeže a tělovýchovy ČR v rámci projektu Regionální inovační centrum elektrotechniky (RICE), číslo projektu CZ.1.05/2.1.00/03.0094.

Dále také tato práce vznikla za podpory Grantové agentury ČR v rámci projektu GA ČR 102/09/1164 a také s podporou studentského grantu SGS-2012-071.

V Plzni, 30. 9. 2012

Autor

## Anotace

Tato disertační práce se zabývá estimací vybraných veličin elektrických pohonů a aktivních filtrů. První část práce popisuje estimaci polohy a rychlosti rotoru dvou typů elektrických pohonů. Prvním je pohon se spínaným reluktančním motorem. Tento motor je elektronicky komutovaný a znalost polohy rotoru je nutným předpokladem pro kvalitní provoz pohonu. Druhým typem je vektorově řízený synchronní motor s vnějšími permanentními magnety. Zde je nutná znalost polohy rotoru tj. i permanentních magnetů pro potřeby vektorového řízení orientovaného na rotorový tok.

Práce se dále věnuje prediktivní estimací nestability vstupního LC filtru trakčního vozidla napájeného ze stejnosměrné troleje a jeho aktivní stabilizací. Prediktivní algoritmus odhaduje možné budoucí kmity vstupního LC filtru a zásahy do řízení pohonu se synchronním motorem s vnějšími permanentními magnety (řízeného pomocí přímého řízení momentu) se snaží tyto kmity potlačit (a při přechodových dějích pohonu je nevybudit).

Poslední část disertační práce se zabývá estimací první harmonické proudu odebíraného nelineární zátěží ze sítě s lehkými frekvenčními fluktuacemi mezi 49 až 51 Hz. Odhadnutá první (fundamentální) harmonická proudu je dále použita pro řízení jednofázového paralelního aktivního filtru k potlačení vyšších harmonických odebíraných ze sítě jednofázovou nelineární zátěží.

### Klíčová slova:

Estimace, Spínaný reluktanční motor, Synchronní motor s permanentními magnety, Bezsenzorové řízení, Umělá neuronová síť, Unscented Kalman filtr, Adaptivní model, Stabilita trakčního filtru, Aktivní filtrace, MGP-FIR filtr

## Abstract

The dissertation thesis deals with estimation of selected quantities in the field of electric drives and active power filters. The first part of this work is concerned to estimation of velocity and rotor position of two types of electric drives. First drive employs a switched reluctance motor. This type of motor is an electronically switched (commutated) and the information about rotor position is necessary for a proper operation. Second type of the drive employs a permanent magnet synchronous motor with vector control. The information about the position of the rotor with permanent magnets is needed for rotor flux-oriented vector control algorithm.

Next, the thesis deals with predictive instability estimation and active stabilization of an input LC filter of a traction vehicle which is supplied by DC-trolley wire. The predictive algorithm estimates future possible oscillations of the input LC filter and it tries to eliminate these oscillations by interventions to the control algorithm of the drive with permanent magnet synchronous machine (direct torque control).

Last part of the thesis investigates first harmonic component estimation in a distorted current drawn by nonlinear load, which would operate also by frequency fluctuations from 49 to 51 Hz. The estimated fundamental current is then used for control of a single-phase shunt-type active power filter which eliminates unwanted components drawn by nonlinear load.

### Keywords:

Estimation, Switched reluctance motor, Permanent magnet synchronous motor, Sensorless control, Artificial neural network, Unscented Kalman Filter, Adaptive model, Traction filter stability, Active power filtering, MGP-FIR filter

## Abstrakt

Diese Dissertation beschäftigt sich mit Schätzung von ausgewählten Größen im Bereich von Elektroantrieben und aktiven Netzfiltern. Der erste Teil befasst sich mit der Schätzung der Geschwindigkeit und Rotorlage bei zwei Typen von Elektroantrieben. Der erste Typ ist ein Elektroantrieb mit einem geschalteten Reluktanzmotor. Die Kommutation ist bei dieser Maschine elektronisch durchgeführt und die Information über die Rotorlage ist nötig für einen problemlosen Betrieb. Der zweite Typ von Elektroantrieb verwendet einen Permanentmagnet-Synchronmotor. In diesem Fall ist die Kenntnis der Rotorlage, bzw. Permanentmagnetlage erforderlich für die rotorfeldorientierte Vektorregelung.

Die Arbeit befasst sich weiter mit einer prädiktiven Abschätzung von Instabilität eines LC Eingangsfilters eines von Gleichstrom-Oberleitung versorgten Traktionsfahrzeug und mit aktiver Stabilisation von den LC Filter. Der prädiktive Algorithmus schätzt die möglichen zukünftigen Eingangsfilterschwingungen ab und versucht die Schwingungen durch aktive Eingriffe in die Permanentmagnet-Synchronmotorregelung (direkte Drehmomentregelung) zu beseitigen.

Der letzte Teil dieser Dissertation untersucht eine Abschätzung der ersten Harmonischen von Strom, der von nichtlinearen Verbrauchern aus Netz mit schwankender Frequenz (49 – 51 Hz) gezogen ist. Die abgeschätzte Grundharmonische ist dann für Regelung eines einphasigen parallelen aktiven Netzfilters benutzt, um die von einphasiger nichtlinearer Last gezogene Stromharmonische zurückzuhalten.

### Schlüsselwörter:

Abschätzung, geschaltete Reluktanzmotor, Permanentmagnet-Synchronmotor, sensorlose Regelung, künstlicher neuronaler Netze, Unscented Kalman Filter, adaptives Modell, Stabilität des Traktionsfilters, aktive Filterung, MGP-FIR Filter

## Obsah

### Kapitola 1

1	Úvod.....	12
1.1	Současný stav poznání ve zkoumané problematice .....	14
1.1.1	Estimace polohy spínaného reluktančního motoru pomocí adaptivního modelu s umělou neuronovou sítí .....	14
1.1.2	Estimace polohy synchronního motoru s permanentními magnety pomocí Unscented Kalman Filtru s adaptivním modelem s pomocnou neuronovou sítí.....	16
1.1.3	Prediktivní estimace a aktivní tlumení kmitů vstupního LC filtru trakčního vozidla s DTC řízeným PMSM.....	17
1.1.4	Estimace základní harmonické pomocí novelizovaného MGP-FIR filtru pro řízení jednofázového paralelního aktivního filtru.....	18
1.2	Cíle práce .....	19
1.2.1	Estimace polohy spínaného reluktančního motoru pomocí adaptivního modelu s umělou neuronovou sítí .....	19
1.2.2	Estimace polohy synchronního motoru s permanentními magnety pomocí Unscented Kalman Filtru s adaptivním modelem s pomocnou neuronovou sítí.....	19
1.2.3	Prediktivní estimace a aktivní tlumení kmitů vstupního LC filtru trakčního vozidla s DTC řízeným PMSM.....	20
1.2.4	Estimace základní harmonické pomocí novelizovaného MGP-FIR filtru pro řízení jednofázového paralelního aktivního filtru.....	20
1.3	Metodika řešení .....	21

### Kapitola 2

2	Estimace parametrů elektrických pohonů pro řízení elektrických motorů bez čidla polohy.....	23
2.1	Estimace polohy spínaného reluktančního motoru pomocí adaptivního modelu s umělou neuronovou sítí .....	24
2.1.1	Základní fyzikální pojmy a principy .....	24
2.1.2	Matematický model SRM .....	27
2.1.3	Měření a simulační model SRM .....	29

2.1.4	Základní princip bezsenzorového řízení SRM.....	30
2.1.5	Odhad polohy SRM pomocí modelu s umělou neuronovou sítí.....	31
2.1.6	Algoritmy pro zpřesnění odhadu polohy.....	34
2.1.7	Řídící platforma pro bezsenzorové řízení SRM.....	36
2.1.8	Výkonový měnič pro napájení SRM.....	38
2.1.9	Experimentální výsledky.....	39
2.1.10	Dílčí závěry kapitoly 2.1 .....	42
2.2	Estimace polohy synchronního motoru s permanentními magnety pomocí Unscented Kalman Filtru s adaptivním modelem s pomocnou neuronovou sítí ...	43
2.2.1	Úvod.....	43
2.2.2	Algoritmus Unscented Kalman Filteru .....	45
2.2.3	Unscented kalman filtr s pomocnou neuronovou sítí.....	49
2.2.4	Simulační model PMSM.....	50
2.2.5	Stochastický model PMSM pro NNUKF.....	51
2.2.6	NNUKF pro odhad polohy a rychlosti PMSM .....	53
2.2.7	Simulační výsledky a ověření algoritmu NNUKF.....	56
2.2.8	Dílčí závěry kapitoly 2.2 .....	59
Kapitola 3		
3	Prediktivní estimace a aktivní tlumení kmitů vstupního LC filtru trakčního vozidla s DTC řízeným PMSM.....	60
3.1	Úvod.....	60
3.2	Zjednodušený simulační model trakčního pohonu se vstupním LC filtrem.....	62
3.3	Aktivní stabilizace vstupního LC filtru algoritmem prediktivního řízení..	65
3.4	Vliv velikosti vstupní indukčnosti LC filtru .....	73
3.5	Měření frekvenčních charakteristik trakčního pohonu .....	74
3.6	Experimentální výsledky.....	75
3.7	Dílčí závěry kapitoly .....	79
Kapitola 4		
4	Estimace základní harmonické pomocí novelizovaného MGP-FIR filtru pro řízení jednofázového paralelního aktivního filtru .....	80
4.1	Úvod.....	80
4.2	Původní MGP-FIR filtr .....	81
4.3	Novelizovaný MGP-FIR filtr.....	83
4.4	Evoluční techniky pro nalezení fixních koeficientů subfiltrů MGP-FIR...	86



4.4.1	Genetický algoritmus pro nalezení fixních koeficientů MGP-FIR .....	87
4.4.2	Algoritmus diferenční evoluce pro nalezení fixních koeficientů MGP-FIR	92
4.4.3	Statistické zhodnocení optimalizačních algoritmů .....	94
4.5	Porovnání navržených filtrů.....	96
4.6	Experimentální výsledky MGP-FIR .....	97
4.7	Dílčí závěry kapitoly .....	102
Kapitola 5		
5	Závěr .....	103
5.1	Hlavní přínosy práce .....	104
5.2	Perspektivní směry dalšího výzkumu.....	105
6	Literatura.....	106
7	Seznam autorových publikací .....	113

## Seznam zkratk a důležitých symbolů

ANN	Umělá neuronová síť
APF	Aktivní výkonový filtr
DE	Diferenční evoluce
DTC	Přímé řízení momentu
EKF	Rozšířený (Extended) Kalmanův filtr
GA	Genetický algoritmus
MGP-FIR	Multiplikativní prediktivní filtr s adaptivními koeficienty s konečnou impulzní odezvou
MPC	Prediktivní regulátor
NNUKF	Unscented Kalman filtr s pomocnou neuronovou sítí
PMSM	Synchronní motor s permanentními magnety
PWM	Pulzně šířková modulace
SRM	Spínaný reluktanční motor
UKF	Unscented Kalman filtr
$\alpha, \beta$	Stojící souřadný systém
d, q	Rotující souřadný systém
$\vartheta_s$	Poloha vektoru magnetického toku statoru ve stojícím souřadném systému
$f_m$	Mechanická rychlost rotoru [Hz]
$f_{me}$	Mechanická rychlost rotoru přepočtená na elektrickou [Hz].... $f_{me} = p_p \cdot f_m$
$f_{mew}$	Požadovaná mechanická rychlost rotoru přepočtená na elektrickou
$\omega_{ref}$	reference úhlové rychlosti rotoru ( $p_p \cdot \omega_m$ )
$p_p$	počet pólpárů
$I_{sa}, I_{sb}, I_{sc}$	statorové proudy v jednotlivých fázích motoru
$I_{s\alpha}, I_{s\beta}$	složky vektoru statorového proudu ve stojícím souřadném systému
$I_{sd}, I_{sq}$	složky vektoru statorového proudu v rotujícím souřadném systému d-q
$I_{ref}$	reference proudu

$J$	moment setrvačnosti
$M$	moment motoru
$M_w$	požadovaný moment motoru
$M_z$	moment zátěže
$M_{ref}$	reference momentu motoru
$L_s$	indukčnost statoru
$L_f$	indukčnost vstupního LC filtru
$R_f$	odpor vstupního LC filtru
$R_s$	odpor statoru
$\bar{\Psi}_{PM}$	magnetický tok permanentních magnetů
$\bar{\Psi}_s$	vektor magnetického toku statoru
$\Psi_{ref}$	reference magnetického toku
$U_c$	napětí ve stejnosměrném obvodu měniče
$k_p$	konstanta Parkovy transformace
$I$	jednotková matice
$T_v$	perioda vzorkování (časový krok výpočtu)
$P, Q, R$	kovarianční matice
$Q, R$	váhové matice u algoritmu nejmenších čtverců
$K$	kalmanovo zesílení
$x$	vektor stavu systému
$\hat{x}$	vektor stavu systému estimovaný
$\hat{x}(k   k-1)$	predikce stavu systému
$\chi_{(k k-1)}$	predikované sigma body vektoru stavu
$\gamma_i (k k-1)$	predikované sigma body vektoru výstupu

# Kapitola 1

## Úvod

Tato disertační práce se zabývá estimací vybraných veličin elektrických pohonů a aktivních filtrů.

První část disertační práce (kapitola 2) je věnována estimaci polohy a rychlosti dvou typů motorů pro stále aktuální a perspektivní problematiku řízení elektrických pohonů bez čidla polohy. Pro klasické metody tzv. bezsenzorového řízení (tj. bez čidla polohy) je kritický přesný model pohonu v celém rozsahu provozu. Skutečné vlastnosti pohonu jsou ale ovlivňovány celou řadou vlivů, které nebývají modelovány, či je nejsme schopni přesně měřit. Některé parametry modelů použitých pro bezsenzorové řízení je možné odhadovat za provozu pohonu a tím zpřesnit estimaci polohy a rychlosti rotoru a touto problematikou se zabývá kapitola 2. Algoritmy jsou ověřeny na dvou motorech, které vyžadovaly rozdílné techniky odhadu polohy. Úvodem je představeno řízení elektronicky komutovaného spínaného reluktančního motoru bez čidla polohy s předem natrénovanou umělou neuronovou sítí z naměřených dat (kapitola 2.1). Pro tento typ pohonu byl vyvinut deterministický algoritmus s estimací fázového odporu. Z modelu tvořeného umělou neuronovou sítí a estimovaným odporem je dále odhadována skutečná poloha rotoru vůči statoru. Dále je představen

pohon se synchronním motorem s permanentními magnety, u kterého byla estimována poloha rotoru pomocí stochastického algoritmu známého jako Unscented Kalman filtr (kapitola 2.2). Stochastický model byl doplněn o adaptivní část, která reprezentuje chybu modelu a je současně odhadována s polohou a rychlostí rotoru.

Další část práce (kapitola 3) se zabývá prediktivní estimací kmitů vstupního LC filtru trakčního vozidla napájeného ze stejnosměrné troleje a jeho aktivní stabilizací prediktivním regulátorem. Zde se pomocí lineárního prediktivního řízení povedlo výrazné zlepšení oproti stávajícím algoritmům. Algoritmus predikuje možnost budoucích kmitů vstupního LC filtru a je schopen je rychle aktivně ztlumit zásahy do přímého řízení momentu pohonu se synchronním motorem s vnějšími povrchovými magnety.

Poslední část disertační práce řeší problematiku estimace základní harmonické proudu pomocí prediktivního adaptivního MGP-FIR filtru. Filtr má dvě multiplikatívni konstanty, které se adaptují na aktuální fluktuace frekvence základní harmonické (mezi 49 až 51 Hz). Predikce umožňuje estimaci okamžité hodnoty první harmonické nezpožděné o dobu jejího výpočtu. Tento filtr je použit pro řízení jednofázového aktivního filtru proudového typu.

## **1.1 Současný stav poznání ve zkoumané problematice**

Protože cílem práce je představit řešení estimačních algoritmů aplikovaných na více druhů problémů, je tato kapitola věnována hlavně nejdůležitějším publikacím, ze kterých vychází teoretický návrh algoritmů. Jednotlivé podkapitoly dále popisují současný stav poznání v konkrétních oblastech, kterým se disertační práce věnuje.

Hlavním referenčním zdrojem týkající se problematiky adaptivních systémů je možné považovat knihu Prof. Lennarta Ljunga: *System Identification - Theory for the User* [1]. Tato kniha se zabývá obecným přehledem identifikačních (adaptačních) algoritmů. Významnou autorskou prací, která se zabývá umělými neuronovými sítěmi a jejich adaptací je kniha Prof. Simona Haykina: *Neural Networks a Comprehensive foundation* [2]. Stejný autor také editoval další významnou publikaci, která se zabývá učením umělých neuronových sítí pomocí Extended a Unscented Kalman filtrů a jejich použití pro duální problémy (současné odhady parametrů i stavů modelů) s názvem *Kalman Filtering & Neural Networks* [3]. Mezi významná díla zabývající se obecně Kalmanovou filtrací patří knihy Dan Simon: *Optimal State Estimation* [4] a M. S. Grewal: *Kalman Filtering: Theory and Practice Using MATLAB* [5]. Aplikací umělých neuronových sítí, genetických algoritmů atd. v oblasti elektrických pohonů se zabývá kniha Prof. Peter Vas: *Artificial-Intelligence-Based Electrical Machines and Drives: Application of Fuzzy, Neural, Fuzzy-neural, and Genetic-Algorithm-based Techniques* [6].

### **1.1.1 Estimace polohy spínaného reluktančního motoru pomocí adaptivního modelu s umělou neuronovou sítí**

Metody bezsenzorového řízení spínaného reluktančního motoru (SRM) se dají rozdělit na metody pasivní a aktivní. Metody pasivní nezasahují žádným způsobem do samotného řízení SRM (nebo minimálně

např. je pro kvalitní odhad určený minimální proud aktivní fáze motoru, nutná je ale ve všech případech identifikace počáteční polohy) a jako budící signál pro identifikaci polohy využívají napětí a proudy vyvolané nadřazenými regulátory proudu/momentu/napětí. Aktivní metody identifikace naopak využívají injektování signálu většinou do neaktivních fází SRM a z následné reakce identifikují okamžitou polohu rotoru. Dále je možné metody rozdělit podle způsobu odhadu polohy na metody, které odhadují pouze komutační doby (výhodné především pro SRM, které jsou provozovány pouze v motorickém režimu, nebo na nenáročných aplikacích) a metody, které odhadují polohu rotoru kontinuálně. Základní zdroj literatury a obecný přehled bezsensorových technik najdeme v knize [7]. Metody odhadu polohy obecně využívají geometrickou anizotropii SRM, která se projevuje na vlastnosti impedance fáze motoru. Nejjednodušší technika pro určení komutačních okamžiků je založená na identifikaci přechodu z motorického na generátorický režim nebo naopak, které se projevují změnou polarit indukovaného napětí a tím ovlivní tvar fázového proudu. Díky tomu víme, že máme komutovat na další fázi. Problematická je zde účinnost pohonu a jeho chování hlavně ve vysokých otáčkách, kdy úhlové zpoždění doby komutace za ideálním okamžikem je velmi velké. Další možnou technikou je odhad polohy z okamžité hodnoty indukčnosti, která se projevuje změnou zvlnění proudu. Nejčastěji je využívána metoda odhadu polohy z vypočteného magnetického toku. Tato metoda je založená na číselné integraci rozdílu fázového napětí a úbytku na fázovém odporu. Výhodou této metody je, že jsou veličiny díky integraci rovnoměrně filtrovány a odhad polohy je pro střední a vyšší otáčky obecně velmi dobrý. Nevýhodou integrace je chování při velmi nízkých otáčkách, kdy se může výrazněji projevit chyba ve výpočtu magnetického toku. Z této metody vychází kapitola 2.1 této disertační práce. Nejjednodušší metodou založenou na odhadu komutačních okamžiků z magnetického toku se zabývá [8]. Metodou založenou na kontinuálním sledování polohy s adaptivním odhadem fázového odporu se zabývá např. práce [9]. Simulacemi neuronového estimátoru polohy vycházejícího z aproximovaného magnetického toku se zabývá publikace [10]. Dále je v práci řešena problematika různé přesnosti okamžitého odhadu polohy z vypočteného

magnetického toku. Touto problematikou se zabývá publikace [11], kde autoři používají fuzzy estimátor polohy doplněný o polynomiální filtr.

### **1.1.2 Estimace polohy synchronního motoru s permanentními magnety pomocí Unscented Kalman Filtru s adaptivním modelem s pomocnou neuronovou sítí**

Bezsenzorové řízení synchronních motorů s permanentními magnety (PMSM) je poslední dobou velice oblíbené téma vědecké komunity. Hlavními důvody jsou výhodné vlastnosti těchto typů motorů (hlavně dobrý poměr momentu a výkonu vůči objemu stroje, bezkartáčová komutace a s ní související bezproblémová údržba atd.) a nutnost přesné znalosti polohy pro kvalitní regulaci motoru (řešenou standardně pomocí absolutního čidla polohy). Odhady polohy PMSM se dají v základu rozdělit na dvě hlavní skupiny. Do první skupiny patří algoritmy využívající reluktanční anizotropii magnetického obvodu rotoru a jsou hlavně využívány v souvislosti s motory s magnety umístěnými uvnitř rotoru, kde bývá větší rozdíl mezi reluktancemi v tzv. d a q složce<sup>1</sup>. Do druhé skupiny tedy patří algoritmy tento rozdíl nevyužívající používaných hlavně pro PMSM s povrchovými magnety, kde bývá rozdíl reluktance v d a q složce často zanedbatelný. Zajímavý přehled různých technik odhadu najdeme např. v [11]. Nejčastěji používaná stochastická technika odhadu polohy a rychlosti PMSM je založená na Extended Kalman filtru (EKF) někdy též nazývaným Rozšířený Kalmanův filtr [12], [13]. Tato kapitola se zabývá též vlivem nepřesností a nemodelovaných nelinearit pohonu na odhady polohy a rychlosti PMSM a některé úvahy na toto téma lze nalézt zde [13]. V kapitole 2.2 je použit algoritmus Unscented Kalman Filteru představený S. J. Julierem [14] v roce 1999. Tento algoritmus je výpočetně náročnější než EKF, ale pro stejnou vzorkovací frekvenci dosahuje zpravidla vyšších přesností odhadů [15]. Využití UKF pro bezsenzorové řízení PMSM bylo již

---

<sup>1</sup> Rozdíl vychází z různé relativní permeability interního permanentního magnetu ( $\mu_r \approx 1$ ) a železného jádra tvořícího magnetický obvod rotoru. Rotory mívají často záměrně zvětšenou anizotropii (geometrií rozmístění magnetů) z důvodu využití reluktančního momentu vedoucího ke zvětšení celkového momentu motoru.



párkrát publikováno např. [16], ale zatím výraznějším rozšíření brání především vyšší výpočetní nároky (oproti EKF). Problematikou obecného rozšíření stochastického modelu systému o pomocnou adaptivní neuronovou síť, která modeluje chybovou funkci mezi stochastickým modelem a odhadovaným systémem se zabývají publikace [17], [18].

### ***1.1.3 Prediktivní estimace a aktivní tlumení kmitů vstupního LC filtru trakčního vozidla s DTC řízeným PMSM***

Řízení synchronního motoru s permanentními magnety (PMSM) pomocí přímého řízení momentu (DTC) je dobře známo a zabývají se jím např. publikace [11], [19], [20]. V literatuře [21] a [22] je popsán trakční systém pomocí obvodu skládajícího se z impedance měřírny, filtru v měřírně, troleje, filtru vozidla a jeho pohonu. Problémem nestability vstupního filtru, která může vést až ke zničení elektrické nebo mechanické části pohonu se zabývá publikace [23]. Metody tlumení kmitů se dají rozdělit na dva hlavní směry: Metody pasivního tlumení, které využívají většinou přídavný odpor umístěný paralelně ke kondenzátoru nebo indukčnosti filtru. Tyto metody vedou ke zvýšení joulových ztrát v obvodu filtru, snižují efektivitu pohonu a zvyšují hmotnost vstupního filtru [24]. Metodou aktivního tlumení filtru pomocí algoritmu virtuálního tlumícího odporu se zabývají publikace [25] a [26]. Jiná metoda aktivního tlumení používající korekční činitel vypočítaný mezi okamžitou hodnotou napětí na kondenzátoru a její téměř konstantní filtrovanou hodnotou je představena v publikacích [24] a [27]. Jinou metodu používající složité korekce a analýzy požadovaného momentu je možné nalézt zde [28]. Algoritmus použitého lineárního prediktivního řízení je poměrně známý a jeho odvození je možné nalézt např. v [29] a [30]. Mezi hlavní autory zabývající se aplikací algoritmů prediktivního řízení (nejen) v oblasti výkonové elektroniky a elektrických pohonů patří M. Morari a zajímavý článek, jehož je spoluautorem, na použití prediktivního regulátoru pro přímé řízení momentu synchronního motoru lze

nalézt zde [31]. Měřením frekvenčních charakteristik střídavých pohonů pro vyšetřování jejich stability se zabývá publikace [32].

#### ***1.1.4 Estimace základní harmonické pomocí novelizovaného MGP-FIR filtru pro řízení jednofázového paralelního aktivního filtru***

Z důvodu narůstajícího výkonu nelineárních zátěží připojených k energetické síti jsou stále aktuálnějšími problémy deformace síťových napětí, zatěžování nulového vodiče, vyšší ztráty způsobené skin efektem, rostoucí ztráty elektrických strojů a transformátorů atd. způsobené proudovými harmonickými odebranými ze sítě. Touto problematikou se obecně zabývá kniha [33], kde najdeme též řadu kompenzačních zařízení pasivních [34] i aktivních filtrů. Tato kapitola se zabývá řídicím algoritmem pro paralelní aktivní filtr proudového typu a lze najít mnoho publikací zabývajících se tímto tématem např. [35], [36], [37]. Metodou estimace fundamentální harmonické proudu potřebnou pro aktivní filtraci s IIR předfiltrem a FIR prediktorem se zabývá publikace [38]. Jinou oblíbenou metodou je využití Goertzel algoritmu pro estimaci fundamentální harmonické, ale ta je méně robustní pro frekvenční fluktuace základní harmonické [39]. Problematikou fluktuací frekvence základní harmonické sítě se zabývá publikace [40]. Algoritmem estimace fundamentální harmonické při frekvenčních fluktuacích pomocí IIR předfiltru a FIR prediktoru se zabývá publikace [41]. Jinou metodou řešící tento problém pomocí nelineárních nejmenších čtverců je publikace [42]. Nevýhodou obou předchozích algoritmů respektujících frekvenční fluktuace je jejich vysoká výpočetní náročnost. Tato kapitola vychází z využití MGP-FIR filtru pro extrakci fundamentální harmonické při lehkých frekvenčních fluktuacích poprvé představené Vaniem a Ovaskou [43]. Algoritmus byl poté lehce vylepšen a poprvé experimentálně ověřen T. Komrskou [44], který se tématem extrakce harmonických zabýval i ve své disertační práci [45].

## **1.2 Cíle práce**

Na základě podrobné analýzy současného stavu poznání ve zkoumané oblasti byly vytýčeny následující cíle této disertační práce:

### **1.2.1 Estimace polohy spínaného reluktančního motoru pomocí adaptivního modelu s umělou neuronovou sítí**

- Představení spínaného reluktančního motoru
- Vysvětlení odhadu polohy rotoru ze spřaženého magnetického toku
- Návrh umělé neuronové sítě jako funkčního aproximátoru polohy z magnetického toku a proudu fáze.
- Návrh algoritmů pro zpřesnění odhadu polohy
- Návrh řídicí platformy na bázi FPGA
- Experimentální ověření navržených algoritmů

### **1.2.2 Estimace polohy synchronního motoru s permanentními magnety pomocí Unscented Kalman Filtru s adaptivním modelem s pomocnou neuronovou sítí**

- Představení algoritmu Unscented Kalman Filtru
- Vysvětlení problematiky rozšíření stochastického modelu Unscented Kalman Filtru o pomocnou neuronovou sít'
- Návrh Unscented Kalman Filtru a Unscented Kalman filtru s adaptivním modelem s pomocnou neuronovou sítí pro odhad polohy a otáček vektorově řízeného pohonu se synchronním motorem s permanentními magnety
- Simulační ověření vlastností nového algoritmu

### ***1.2.3 Prediktivní estimace a aktivní tlumení kmitů vstupního LC filtru trakčního vozidla s DTC řízeným PMSM***

- Představení problematiky stability vstupního LC filtru trakčního vozidla napájeného ze stejnosměrné troleje
- Navržení algoritmu založeného na prediktivní estimaci kmitů vstupního LC filtru a účinnou stabilizací pomocí prediktivního řízení
- Porovnání nově navrženého algoritmu stabilizace založeného na prediktivním řízení s nejběžněji používaným řešením
- Experimentální ověření stabilizačních vlastností nově navrženého algoritmu na pohonu se synchronním motorem s permanentními magnety (PMSM) řízeného algoritmem přímého řízení momentu (DTC)

### ***1.2.4 Estimace základní harmonické pomocí novelizovaného MGP-FIR filtru pro řízení jednofázového paralelního aktivního filtru***

- Představení původního MGP-FIR filtru
- Vyřešení problému původního MGP-FIR filtru s normováním signálu a tím vylepšit filtrační vlastnosti
- Návrh novelizovaného MGP-FIR filtru s reálnými koeficienty
- Návrh algoritmu pro nalezení konstant fixní části filtru MGP-FIR a jeho statistické zhodnocení
- Experimentální ověření novelizovaného MGP-FIR filtru na jednofázovém paralelním aktivním filtru

### **1.3 Metodika řešení**

Tato disertační práce je členěna do pěti kapitol. V kapitole 1 je uvedena motivace vzniku této disertační práce, je zde detailně popsán současný stav poznání ve zkoumané problematice a uvedeny citace hlavních literárních pramenů, ze kterých popis současného stavu vychází. Dále jsou zde definovány cíle této disertační práce. Vlastní řešení začíná kapitolou 2.

Kapitola 2 je rozdělena do dvou podkapitol, které popisují algoritmy řízení dvou typů elektrických pohonů bez čidla polohy s adaptivním modelem na bázi umělé neuronové sítě. První část kapitoly 2 se týká řízení spínaného reluktančního motoru bez čidla polohy s adaptivním modelem s umělou neuronovou sítí a experimentálního ověření této metody. Druhá část kapitoly 2 se zabývá řízením pohonu se synchronním motorem s permanentními magnety pomocí stochastického algoritmu filtrace známého jako Unscented Kalman Filtr. Je zde použit algoritmus duální filtrace, který zároveň odhaduje neznámou rychlost a polohu rotoru PMSM, ale také koeficienty adaptivní části stochastického modelu (reprezentovaného umělou neuronovou sítí).

Kapitola 3 se zabývá stabilizací vstupního LC filtru trakčního pohonu se synchronním motorem s permanentními magnety řízeného algoritmem přímého řízení momentu. Pro tyto účely byl navržen stabilizační algoritmus na bázi lineárního prediktivního řízení. V této kapitole jsou dále uvedeny jak simulační tak experimentální výsledky navrženého algoritmu a porovnány s nejčastějším řešením tohoto problému.

V kapitole 4 je uvedena problematika aktivní filtrace jednofázových systémů s mírně fluktuujícími frekvencemi základní harmonické sítě. Tato kapitola vznikla během mého pobytu na Helsinské univerzitě technologií spolupráci s prof. S. J. Ovaskou. Mým úkolem bylo navržení MGP-FIR (Multiplicative General Parameter-Finite Impulse Response) filtru s reálnými koeficienty (použitým pro odhad první harmonické deformovaného proudu odebíraného ze sítě) a tím zlepšení filtračních vlastností algoritmu. Tento typ filtru byl do té doby navrhován pouze s koeficienty  $\pm 1$ . Dále je v disertaci představena problematika původní verze MGP-FIR filtru a

změněna jeho struktura způsobem, který tento problém řeší. Závěr této kapitoly je věnován simulačním a experimentálním výsledkům.

Kapitola 5 – Závěr shrnuje hlavní přínos této disertační práce a definuje perspektivní směry dalšího zkoumání ve vazbě na výsledky prezentované v této práci.

## Kapitola 2

# Estimace parametrů elektrických pohonů pro řízení elektrických motorů bez čidla polohy

Tato kapitola disertační práce se věnuje odhadu parametrů elektrických pohonů pro řízení elektrických motorů bez čidla polohy. V první podkapitole 2.1 je představena problematika řízení elektronicky komutovaného spínaného reluktančního motoru (SRM) bez čidla polohy s použitím předem trénované umělé neuronové sítě (ANN) z naměřených charakteristik. V druhé podkapitole 2.2 je představena stochastická metoda odhadu za pomoci unscented kalman filtru (UKF) s pomocnou neuronovou sítí, která se tzv. online adaptuje za provozu pohonu na chybovou funkci modelu (způsobenou parametrickou nepřesností modelu, nemodelovanými nelinearitami atd.).

## 2.1 *Estimace polohy spínaného reluktančního motoru pomocí adaptivního modelu s umělou neuronovou sítí*

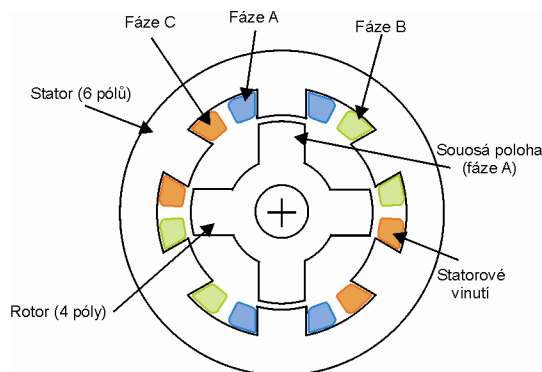
Tato kapitola popisuje řízení spínaného reluktančního motoru bez čidla polohy s předem trénovanou umělou neuronovou sítí (ANN) a adaptivním modelem založeným na průběžném odhadu fázového odporu motoru a zpřesněním určení okamžité polohy metodou váženého průměru. Hlavní závěry této kapitoly byly publikovány na zahraniční konferenci [46].

### 2.1.1 *Základní fyzikální pojmy a principy*

Spínaný reluktanční motor (SRM) je v našem případě točivý stroj, který má na statoru i rotoru vyjádřené *póly*, jejichž počty jsou označeny jako  $N_s$  a  $N_r$ . Neobsahuje permanentní magnety, a tedy může pracovat i při vyšších teplotách. Ztráty jsou převážně na statoru a ten lze snadno chladit. Protilehlé póly jsou spojeny do série, tak aby vytvářely S-J pólův pár na fázi. Všeobecně platí mezi počty pólů vztah:

$$N_r = N_s - \left(\frac{N_s}{m}\right) \quad (1)$$

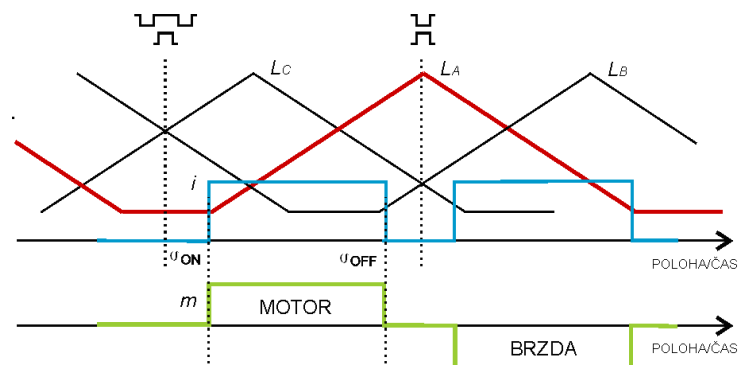
kde  $m$  je počet fází statoru. Na Obr.1 je typický 3fázový spínaný reluktanční motor v uspořádání 6/4.



Obr. 1 Spínaný reluktanční motor 6/4 (6 pólů na statoru a 4 na rotoru),  
Obrázek převzat z [8]



Jestliže se póly statoru a rotoru překrývají, znamená to, že daná fáze je v sousé poloze. V této pozici má příslušná fáze největší indukčnost. Nachází-li se póly statoru a rotoru mezi sousou polohou a nesousou polohou, daná fáze je v poloze částečného překrytí. Jestliže je osa, která prochází středem mezi rotorovými póly v ose s póly statoru buzené fáze, je daná fáze v nesousé poloze. Příslušná fáze má minimální indukčnost. Profil indukčnosti SRM má v idealizovaném případě tvar trojúhelníku, kde maximum je v sousé poloze a minimum v nesousé poloze. Obrázek 2 s idealizovanými průběhy indukčností pro třífázový SRM zobrazuje základní režimy – motorický (motor) a generátorický (brzda) pro fázi A a daný průběh rotace motoru.



Obr. 2: Napájení fází spínaného reluktančního motoru pro motorický (motor) a generátorický (brzda) režim. Obrázek převzat z [8]

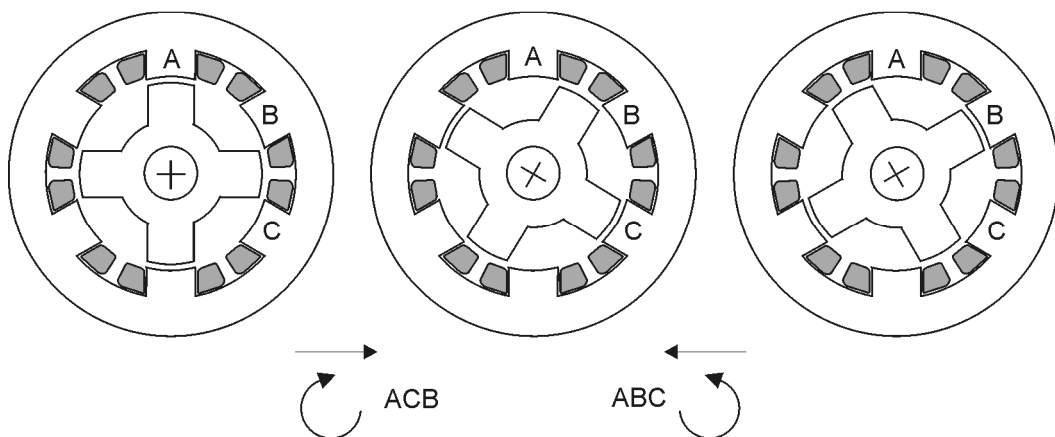
Jednotlivé fáze A, B a C jsou vzájemně posunuty úhel  $\Delta\vartheta$ . Jestliže je příslušná fáze napájena, tento interval je označen jako úhel vedení a je vymezen úhly  $\vartheta_{ON}$  a  $\vartheta_{OFF}$ . Jestliže je na fázi připojeno napětí, motor vytváří kladný moment ve směru narůstající indukčnosti, tj. z nesousé polohy se snaží rotor dostat do polohy s maximální indukčností, tedy do sousé polohy. Poloha rotoru k příslušné fázi je označena jako  $\vartheta$ . Z obrázku je patrné, že úhly jednotlivých fází  $\vartheta_A$ ,  $\vartheta_B$  a  $\vartheta_C$  jsou vzájemně posunuty o úhel:

$$\Delta\vartheta = \frac{2\pi}{m \cdot N_r} \quad (2)$$

Počet kroků m-fázového SRM za jednu otáčku je pak roven:

$$-\frac{\pi}{N_r} \leq \vartheta \leq \frac{\pi}{N_r} \quad (3)$$

Na následujícím obrázku (3) je znázorněn přechod od jedné sousé polohy ke druhé. Jsou zde postupně znázorněny sousá poloha fáze A ( $\vartheta_A = 0^\circ$ ), sousá poloha fáze C ( $\vartheta_A = 30^\circ, \vartheta_C = 0^\circ$ ) a sousá poloha fáze B ( $\vartheta_A = -30^\circ, \vartheta_B = 0^\circ$ ).



Obr. 3: Otáčení rotoru SRM pro různé sekvence buzení fází. Obrázek převzat z [8]

Aby se motor kontinuálně otáčel je zapotřebí budit jednotlivé fáze v závislosti na poloze rotoru. Příslušné fáze je nutné budit tak, aby vytvářely kladný moment. Spínací sekvence 3fázového spínaného reluktančního motoru jsou pro jeden směr ACB a pro směr opačný ABC. Poloha rotoru  $\vartheta$  se může měnit pouze v určitém intervalu, ten je dán vztahem:

$$-\frac{\pi}{N_r} \leq \vartheta \leq \frac{\pi}{N_r} \quad (4)$$

Ze vztahu vyplývá, že např. pro motor 6/4 se úhel  $\vartheta$  pohybuje v intervalu  $\langle -45^\circ; 45^\circ \rangle$ .

## 2.1.2 Matematický model SRM


Matematický model SRM se skládá z napěťových a pohybových rovnic. Jednotlivé fáze SRM je možné řídit samostatně a vzájemně se elektromagneticky téměř neovlivňují. Proto je model tvořen v případě 3fázového SRM třemi napěťovými rovnicemi a momentovou (a z toho vyplývající pohybovou) rovnicí, která je součtem momentů vytvářených jednotlivými fázemi.

### Napěťová rovnice

SRM je nelineární systém, který může být popsán matematickým modelem. Fázové napětí může být vyjádřeno vztahem:

$$u = R \cdot i + \frac{d\Psi(i, \vartheta)}{dt} \quad (5)$$

kde  $\Psi(i, \vartheta)$  je magnetický tok, který je funkcí fázového proudu  $i$  a polohy rotoru  $\vartheta$ , jak je znázorněno na Obr. 4.



Obr. 4: Grafické znázornění magnetického toku  $\Psi(i, \vartheta)$  uvedeného v napěťové rovnici fáze (5)

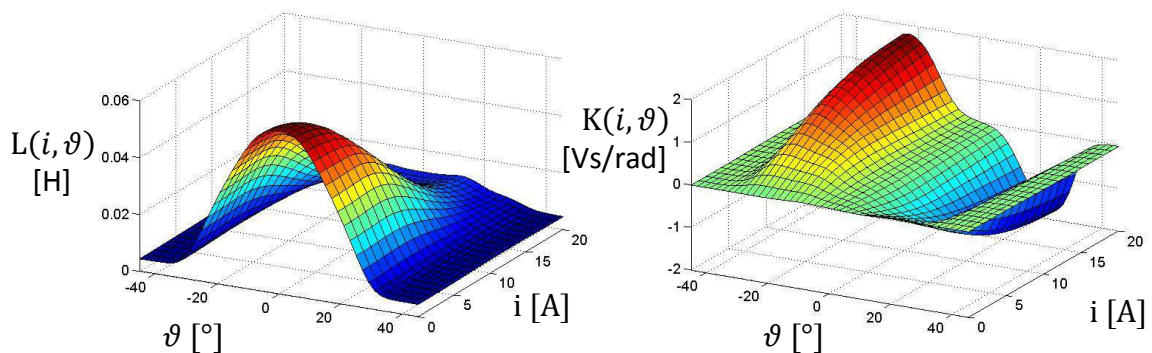
Fázové napětí může být proto vyjádřeno následujícím vztahem:

$$u = R \cdot i + \frac{\partial \Psi(i, \vartheta)}{\partial i} \cdot \frac{\partial i}{\partial t} + \frac{\partial \Psi(i, \vartheta)}{\partial \vartheta} \cdot \frac{\partial \vartheta}{\partial t} \quad (6)$$

První člen odpovídá úbytku napětí na odporu fáze  $R$ , druhý člen představuje napětí na fázové indukčnosti (parciální derivace  $\partial \Psi / \partial i$  je okamžitá hodnota dynamické indukčnosti  $L$ ) a poslední člen představuje indukované protinapětí  $u_i$  (parciální derivace  $\partial \Psi / \partial \vartheta$  odpovídá okamžitému činiteli magnetického toku  $K$ ). Rovnice lze tedy přepsat:

$$u = R \cdot i + L(i, \vartheta) \cdot \frac{\partial i}{\partial t} + K(i, \vartheta) \cdot \omega \quad (7)$$

kde  $\omega$  je elektrická úhlová rychlost SRM. Grafické znázornění  $L$  a  $K$  lze vidět na Obr.5.



Obr. 5: Grafické znázornění dynamické indukčnosti  $L(i, \vartheta)$  a činitele magnetického toku  $K(i, \vartheta)$  rovnice (7)


Vliv sycení magnetického obvodu je hlavně patrný kolem sousé polohy na výrazném poklesu indukčnosti pro vyšší proudy.

### **Momentová rovnice**

Moment vytvářený motorem je funkcí magnetického toku, a proto okamžitý moment není konstantní pro rozdílné polohy rotoru při konstantním proudu. Tím je vytvářeno zvlnění momentu a případný akustický hluk. Moment  $M_{ph}$  vytvářený jednou fází může být vyjádřen jako:

$$M_{ph} = \int_0^i \frac{\partial \Psi(i, \vartheta)}{\partial \vartheta} di \quad (8)$$

A jeho grafické znázornění lze vidět na Obr. 6.



Obr. 6 Grafické znázornění funkce  $M_{ph}(i, \vartheta)$  rovnice (8)

Výsledný moment na hřídeli pak vychází jako součet momentů od jednotlivých fází:

$$M_{ph} = \sum_{x=1}^m M_{ph_x} \quad (9)$$

### 2.1.3 Měření a simulační model SRM

Pro vytvoření matematického modelu SRM většinou vycházíme z naměřených charakteristik magnetického toku  $\Psi(i, \vartheta)$ . Tento magnetický tok zpravidla měříme nepřímou metodou jako:

$$\Psi = \sum_0^i (u - R \cdot i) \Delta t \quad (10)$$

pro různé úhly natočení statoru vůči rotoru, použitím výkonového měniče. Na fázi spínaného reluktančního motoru při aretaci rotoru ve známé poloze přivedeme kladné, obdélkové, nejlépe konstantní napětí do doby nárůstu

proudu do velikosti dané požadovaným rozsahem matematického modelu. Zaznamenáme průběhy proudů a napětí např. na osciloskopu s pamětí a v počítači provedeme následnou číslíkovou integraci, čímž dostaneme profil magnetického toku v závislosti na proudu pro danou polohu rotoru. Tímto způsobem provedeme měření toků pro další polohy rotoru. Jako částečná kontrola měření a výpočtu může sloužit fakt, že magnetický tok pro nulový proud je také nulový. Tudíž chyby integrace, či statické chyby měření (např. chyba v naměřeném fázovém odporu) se nám projeví jako zbytkový magnetický tok při poklesu proudu k nule. Dále je nutné naměřené hodnoty toku aproximovat diferencovatelnou po částech hladkou funkcí, aby bylo možné odvodit hodnoty indukčnosti, koeficientu protinapětí a fázového momentu. Pro tyto účely se většinou využívají kubické spline. Moment, indukčnost a koeficient protinapětí odvozujeme od aproximovaných naměřených charakteristik toku, kde:

$$L(i, \vartheta) = \frac{\Delta\Psi(i, \vartheta)}{\Delta i} \quad (11)$$

$$K(i, \vartheta) = \frac{\Delta\Psi(i, \vartheta)}{\Delta\vartheta} \quad (12)$$

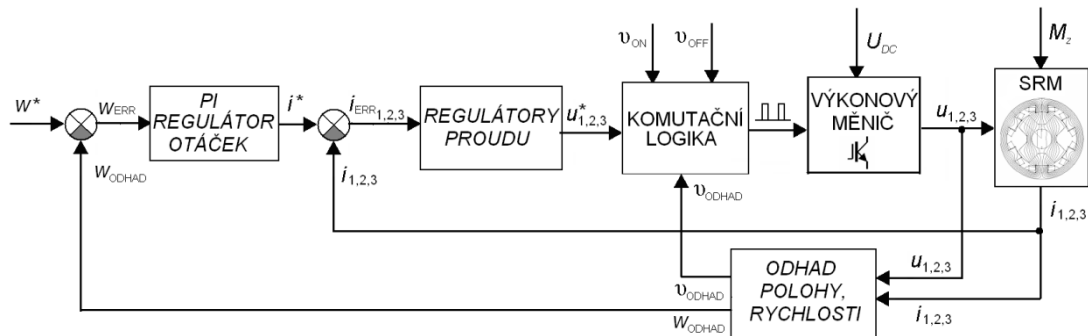
$$M_{ph} = \sum_0^i \frac{\Delta\Psi(i, \vartheta)}{\Delta\vartheta} \Delta i = \sum_0^i K(i, \vartheta) \cdot \Delta i \quad (13)$$

Moment setrvačnosti  $J$  (případně mechanické ztráty třením...) můžeme měřit doběhovou zkouškou. Více o problematice měření parametrů SRM např. zde [47].

### **2.1.4 Základní princip bezsenzorového řízení SRM**

Základní principy řízení SRM bez čidla polohy jsou dvě. První metoda kontinuálně odhaduje polohu rotoru vůči statoru a tím umožňuje např. přímé řízení momentu SRM (kde je znalost okamžité polohy nutná).

Druhá metoda je jednodušší a vychází pouze z odhadu komutačních časů, tj. kdy je třeba přestat budit aktivní fázi a začít budit další (mezi komutačními dobami není aktuální poloha známa). Algoritmem spadajícím do první kategorie využívající kontinuální odhad polohy z magnetického toku aktivní fáze SRM se zabývá tato kapitola a její základní schéma je na Obr. 8. Komplexní přehled dalších metod lze nalézt např. [7].



Obr. 8 Bezsenzorové řízení SRM při rychlostní regulaci pohonu

Rychlostní regulační smyčce je podřazená regulační proudová smyčka. Návrhy proudových, rychlostních a momentových regulátorů SRM se zabývají např. autoři práce [48], [49], [50], [51]. Ze tří proudových regulátorů (pro náš 3fázový SRM) je komutační logikou na základě okamžité odhadnuté polohy  $\vartheta_{\text{odhad}}$  a úhlů vedení  $\vartheta_{\text{ON}}$  a  $\vartheta_{\text{OFF}}$  vybrána aktivní fáze a ta je výkonovým měničem buzena na požadovanou hodnotu proudu danou regulátorem rychlosti. Hodnota úhlů vedení je závislá na režimu pohonu motorický/generátorický, rychlosti otáčení rotoru (pro vyšší rychlosti se zkracuje úhel vedení) a má také velký vliv na účinnost provozu pohonu a zvlnění momentu [51].

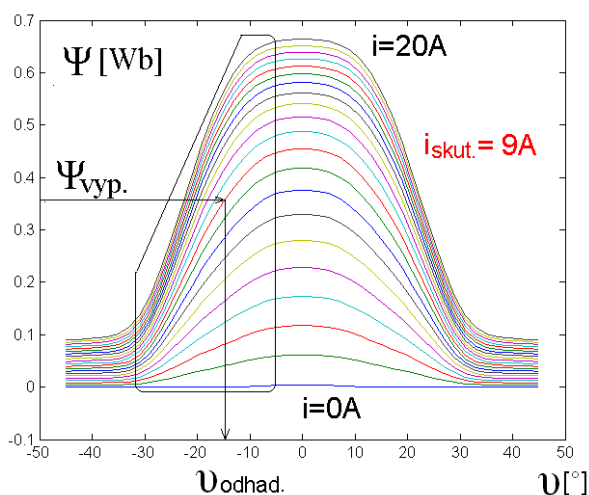
### 2.1.5 Odhad polohy SRM pomocí modelu s umělou neuronovou sítí

Princip metody vychází z využití nelinearity magnetického toku fáze v závislosti na poloze rotoru a okamžité hodnotě proudu. Metoda je výhodná tím, že magnetický tok je počítán integrací, čímž dochází


k eliminaci bílého šumu a potlačení dalších nežádoucích rychlých transientních jevů a statická chyba integrace (např. vlivem chybně změřeného odporu) se projeví jako zbytkový magnetický tok po poklesu proudu k nule a je možné ji v další periodě snížit nebo kompenzovat. Tok je počítán numerickou integrací podle vztahu (14):

$$\Psi = \sum_0^i (u - R \cdot i) \Delta t \quad (14)$$

Poté pro okamžitou hodnotu vypočteného toku a změřeného proudu je na základě předem změřených dat odhadnuta poloha rotoru (Obr. 9). Pro účely aproximace funkce polohy  $\vartheta(\Psi, i)$  byla použita 3vrstvá umělá neuronová síť s 12 neurony ve skryté vrstvě (ANN) zobrazená na Obr. 10.



Obr. 9 Základní princip odhadu polohy z vypočteného magnetického toku dle rov. (14) a okamžitého změřeného proudu fáze



Obr. 10 Základní schéma umělé neuronové sítě aproximující polohu rotoru jako funkci spočteného toku a okamžitého změřeného proudu fáze

Z Obr. 9 lze vidět, že metoda je vhodná jak pro vysoké tak i pro nižší hodnoty proudů. Komplikovaný je odhad kolem plně souosé ( $\sim 0^\circ$ ) a nesouosé polohy (přibližně  $-45^\circ$  až  $-30^\circ$ ), kde se magnetický tok v závislosti na poloze rotoru mění jen velmi málo a v případě nesouosé polohy je tok



velmi nízký pro celý rozsah proudů. V průběhu měření se ukázal možný odhad polohy z jedné fáze přibližně od  $-30^\circ$  a proudem nad 1A. Touto problematikou se zabývá např. [52] či autorovi publikace [46], [53]. Tří vrstvá umělá neuronová síť<sup>2</sup> o 2 vstupech  $\Psi$  a  $i$ , s 12 neurony ve skryté vrstvě a jedním výstupem s odhadnutou polohou byla natrénována ze změřených dat spřaženého magnetického toku pomocí algoritmu Levenberg-Marquardt<sup>3</sup>. Rovnice popisující funkci ANN estimátoru pro 12 neuronů ve skryté vrstvě:

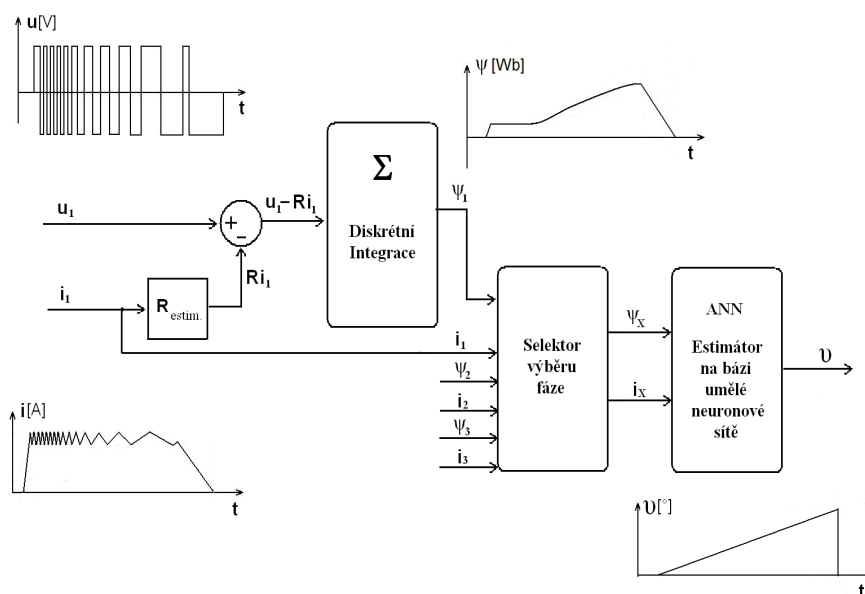
$$\begin{aligned}\vartheta_{(k)} = & V_1 \cdot \tanh(W_{1_1} \cdot \Psi_{(k)} + W_{1_2} \cdot i_{(k)} + B_1) \\ & + V_2 \cdot \tanh(W_{2_1} \cdot \Psi_{(k)} + W_{2_2} \cdot i_{(k)} + B_2) \cdots \\ & \cdots + V_{12} \cdot \tanh(W_{12_1} \cdot \Psi_{(k)} + W_{12_2} \cdot i_{(k)} + B_{12}) + C\end{aligned}\quad (15)$$

Parametry  $W_x$ ,  $B_x$ ,  $C$  jsou konstantní váhové koeficienty ANN,  $\Psi_{(k)}$  a  $i_{(k)}$  jsou vstupní proměnné v čase  $k$  a  $\vartheta_{(k)}$  je odhadnutá poloha. Základní schéma estimátoru polohy je zobrazeno na Obr. 11. Skládá se ze tří paralelně počítaných magnetických toků podle rov. (14), selektoru výběru fáze, ze které ANN estimátor určuje okamžitou polohu a samotného estimátoru polohy.

---

<sup>2</sup> Tento typ sítě s použitou nelineární funkcí ve skryté vrstvě typu tanh a lineární výstupní funkcí je univerzální funkční aproximátor [2]. Počet neuronů ve skryté vrstvě odpovídá schopnosti ANN aproximovat funkci v daném rozsahu. Vyšší počet neuronů než je dostatečný pro aproximaci nelineární funkce zvýší výpočetní náročnost algoritmu a může také přinášet problém s přepřímáním funkce (tzv. Overfitting problém) [2], [48].

<sup>3</sup> Levenberg-Marquardt algoritmus je metoda řešení problému nelineárních nejmenších čtverců vycházející z Gauss-Newton optimalizace [2]. Metoda hledá optimum pomocí iterativního gradientního algoritmu a stejně jako jiné gradientní metody je závislá na nastavení počátečních podmínek (počáteční inicializaci váhových koeficientů). Pro nalezení suboptimálního řešení je třeba vyzkoušet různé počáteční nastavení váhových koeficientů ANN. Jinou možnou metodou učení je např. heuristická metoda hledání suboptimálního řešení založená na multipopulačních technikách, která bude představena v kapitole 4.4.



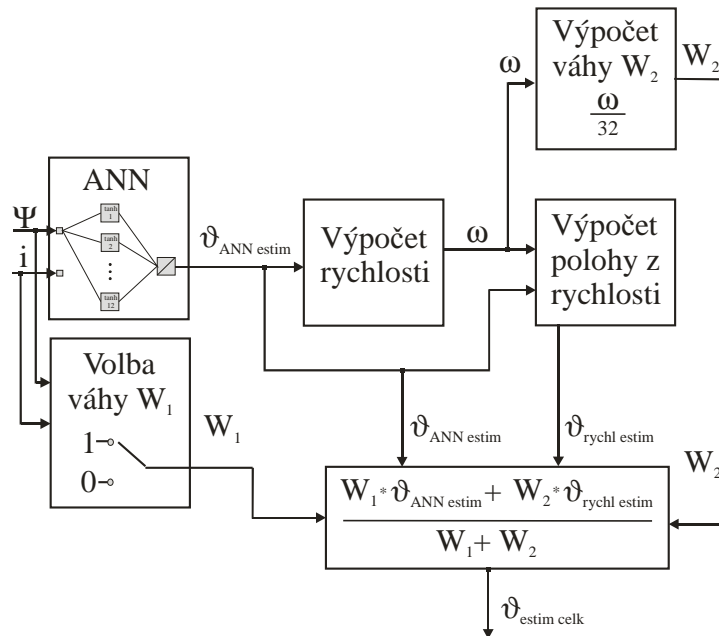
Obr. 11 Estimace polohy na bázi umělé neuronové sítě

Selektor výběru fáze se uplatní při současném buzení dvou fází a vybírá podle okamžitého spočteného toku fázi s větším magnetickým tokem. Tj. i fázi s vyšší přesností odhadu (platí pouze pro proudy větší než 1 A).

### 2.1.6 Algoritmy pro zpřesnění odhadu polohy

Použité algoritmy pro zpřesnění odhadu polohy jsou dva. První je adaptace odhadnutého fázového odporu použitého pro výpočet spřaženého magnetického toku. Metoda vychází ze základní myšlenky, že vypočtený magnetický tok fáze má mít pro nulový proud nulovou hodnotu (Obr. 4, nebo Obr. 9). Po poklesu proudu k nule se inkrementuje či dekrementuje odhadnutá hodnota fázového odporu  $R_{estim}$  podle zbytkového spočteného magnetického toku. Pokud pro nulový proud (po odbuzení fáze) vychází magnetický tok větší než nula, je hodnota  $R_{estim}$  inkrementována o  $0,0001 \Omega$  a naopak. Tímto způsobem je průběžně adaptována hodnota  $R_{estim}$  a umožňuje sledovat i změny fázového odporu vyvolané růstem či poklesem teploty statoru. Lépe odhadnutá hodnota odporu nám následně umožňuje přesnější výpočet magnetického toku a tím i přesnější odhad polohy. Druhý použitý algoritmus zlepšující odhad polohy je založený na výpočtu

zpřesněné polohy váženým průměrem mezi okamžitou odhadnutou polohou pomocí ANN estimátoru  $\vartheta_{ANN\ estim}$  a polohou vypočtenou z odhadnuté rychlosti  $\vartheta_{rychl\ estim}$ . Základní schéma tohoto algoritmu lze spatřit na Obr. 12.



Obr. 12 Zpřesnění odhadu polohy váženým průměrem

Rychlost je počítána pro  $\vartheta_{ANN\ estim} = -20^\circ$  (tato poloha je 12 krát za mechanickou otáčku pro motor se 3 fázemi a 4 póly na rotoru), kdy má odhad pomocí ANN nejvyšší přesnost (přesnost odhadu polohy pomocí ANN estimátoru odpovídá přibližně absolutní hodnotě z  $K(i, \vartheta)$  zobrazeném na Obr. 5). V tento okamžik je také inicializována počáteční hodnota integrátoru, díky němuž je počítána poloha z rychlosti. Váha polohy vypočtené z rychlosti  $W_2$  je přímo úměrná rychlosti otáčení. Tato váha vychází z předpokladu, že chyba v odhadnuté rychlosti (tj. i chyba ve vypočtené poloze  $\vartheta_{rychl\ estim}$ ) vlivem momentu SRM (nebo zátěžného momentu, atd.) bude nižší pro vyšší otáčky a je možné poloze vypočtené integrací z rychlosti více “věřit”.

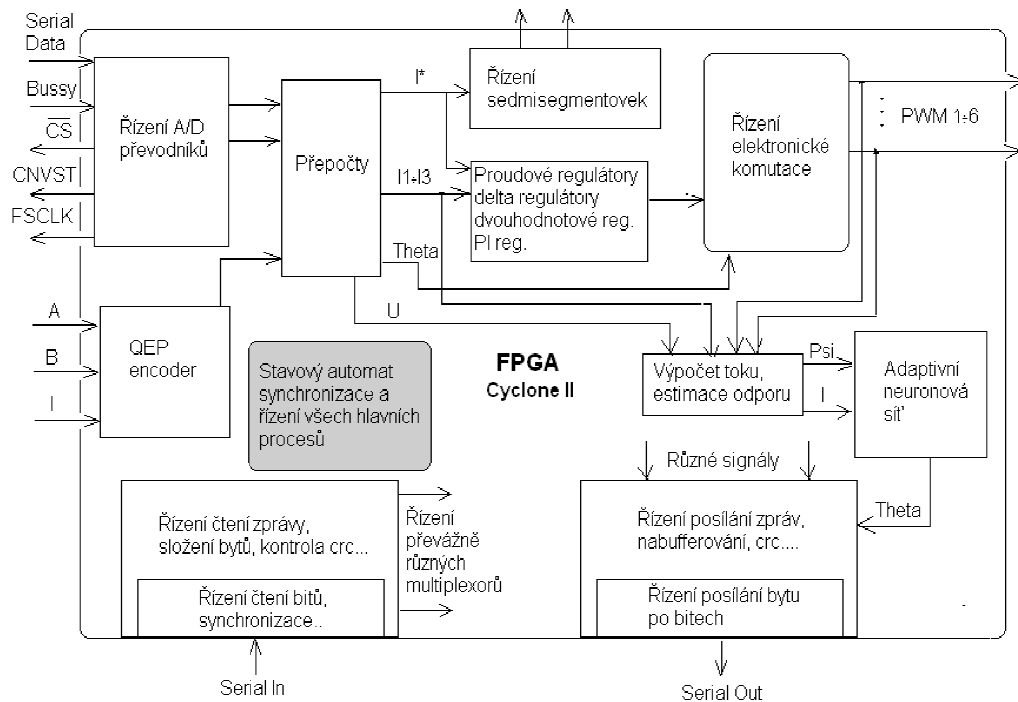
V reálné aplikaci bude váha  $W_2$  hlavně záviset na celkovém momentu setrvačnosti pohonu a způsobu jeho provozu<sup>4</sup>. Váha polohy z ANN  $W_1$  je pro jednoduchost buď 1, nebo 0 a je závislá na okamžité hodnotě spočteného toku a proudu.

### **2.1.7 Řídící platforma pro bezsenzorové řízení SRM**

Pro řízení spínaného reluktančního motoru bez čidla otáček je zvláště pro vysoké a naopak velmi nízké otáčky velmi důležité přesné a rychlé snímání elektrických veličin. Pro jejich následné rychlé zpracování a hlavně pro realizaci rychlé umělé neuronové sítě jako estimátoru polohy, byla vybrána hardwarová platforma založená na programovatelném logickém poli FPGA (Altera Cyclone II). Toto řešení poskytuje mnohonásobně vyšší výpočetní výkon pro paralelní výpočty (uplatněný hlavně u neuronové sítě) a velmi rychlé snímání a zpracování změřených veličin než srovnatelně taktovaný signálový procesor (100 MHz). Nevýhodou tohoto řešení je komplikovanější vývoj řídicích algoritmů a v našem případě také vývoj vlastní desky s rozhraním pro řízení elektrických pohonů (galvanické oddělení, A/D převodníky, datová komunikace s PC...). Na Obr. 13 lze vidět základní schéma vytvořené řídicí platformy na bázi FPGA. Systém je koncipován do jednotlivých segmentů pracujících většinou nezávisle na ostatních procesech. Samotnou synchronizaci a řízení jednotlivých procesů obstarává stavový automat. Platforma byla programována pomocí blocksetu DSP builder dodávaného firmou Altera pro programování programovatelných logických polí v prostředí Matlab Simulink. Informace o změřené a odhadnuté poloze rotoru SRM byla posílána v zabezpečených zprávách pomocí obvodu FTDI přes USB do počítače.


---

<sup>4</sup> Při zanedbání mechanických ztrát (tření, ventilační ztráty atd.) je  $\frac{d\omega}{dt} = \frac{M-M_z}{J}$ , kde  $M$  je moment motoru,  $M_z$  je zátěžný moment,  $J$  je moment setrvačnosti a  $\omega$  je úhlová rychlost rotoru. Chyba ve vypočtené rychlosti  $\Delta\omega$  pro konstantní akcelerační moment ( $M-M_z$ ) při zanedbání mechanických ztrát klesá s rychlostí lineárně (tj. chyba v poloze kvadraticky) z důvodu lineárně rostoucí frekvence odhadování rychlosti (12 krát za otáčku). Naopak chyba  $\Delta\omega$  způsobená třením je přibližně konstantní a způsobená ventilačními ztrátami lineárně roste v závislosti na rychlosti.




Obr. 13. Řídící platforma na bázi FPGA

Na Obr. 14 a 15 lze vidět fotografie řídicí platformy na bázi FPGA a celkovou fotografii konfigurace laboratorního pohonu se SRM.




Obr. 14. Řídící platforma na bázi FPGA s vytvořeným rozhraním pro řízení elektrických pohonů připojených k FPGA přes GPIO



Obr. 15. Fotografie řídicí platformy na bázi FPGA s Millerovým měničem (na levé straně stolu) a SRM (pod stolem)

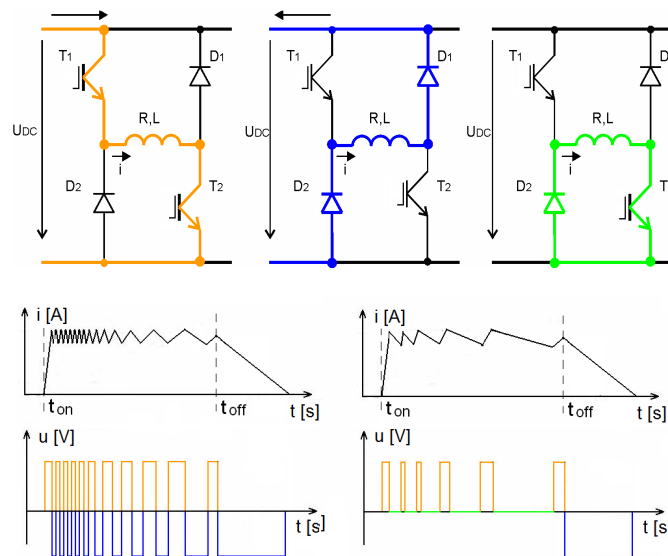
### 2.1.8 Výkonový měnič pro napájení SRM

Pro napájení SRM byl použit tzv. Millerův měnič (Obr. 16.). Tento typ měniče je nejčastěji používaný a umožňuje nezávislé řízení všech fází. Dále existuje ještě celá řada úspornějších zapojení (ať už z pohledu množství použitých aktivních součástek, nebo např. výkonových ztrát), které většinou neumožňují samostatné řízení jednotlivých fází či spínání v tzv. jedné polaritě. Základní přehled různých variant výkonových měničů SRM nalezneme např. v [8].



Obr. 16. Třífázový výkonový Millerův měnič. Obrázek převzat z [8]

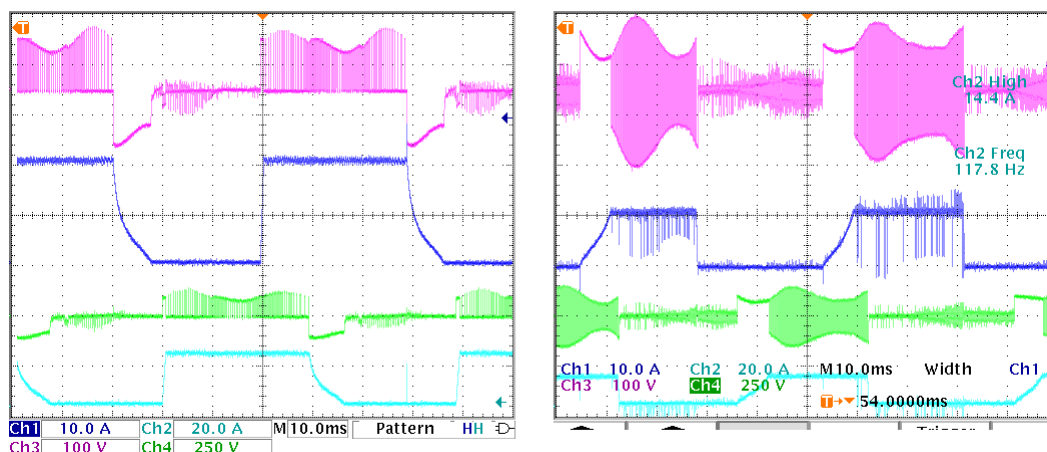
Millerův měnič umožňuje dvě varianty spínání. První je spínání ve dvou polaritách a bývá využíváno hlavně v generátorickém režimu a druhé je spínání v jedné polaritě používané v motorickém režimu (Obr. 17.).




Obr. 17. Režimy buzení fáze – Vlevo spínání ve dvou polaritách, Vpravo spínání v jedné polaritě

## 2.1.9 Experimentální výsledky

Experiment byl prováděn na laboratorním modelu 3fázového spínaného reluktančního motoru, který vznikl na základě strategické zakázky firmy Škoda Výzkum s.r.o. r. 1995/96: „Prvky moderních regulačních pohonů“. Motor má jmenovité otáčky  $RPM_N=2000$  ot/min a jmenovitý výkon  $P_N=3,5$  kW. Millerův měnič byl napájen z dynama napětím 120V. Informace o odhadnuté poloze byla posílána pro každý stupeň změřeného úhlu natočení přes USB do počítače. Obr. 18 zobrazuje průběhy proudů a napětí dvou fází pro motorický a generátorický režim pohonu u dvouhodnotové regulace proudu. Obr. 19 ukazuje celkový moment motoru u obdélníkového řízení proudu a lze na něm vidět velké zvlnění dané konstrukcí motoru a použitým obdélníkovým řízením proudu.




Obr. 18. Dvouhodnotová regulace proudů a odpovídající fázová napětí. Vlevo motorický a vpravo generátorický režim.




Obr. 19. Dvouhodnotová regulace proudů a odpovídající moment SRM změřený momentovým čidlem (50mV/Nm) pro 10 a 20 A.

Obrázek 20 ukazuje odhadnutou polohu pro 600 ot/min přímo z ANN. Lze vidět okamžiky, kdy je poloha chybně odhadnutá, projevující se propady modré křivky (odhadnuté polohy) vůči změřené skutečné poloze znázorněné zeleně. Tyto polohy přibližně odpovídají pro každou fázi nesouosé poloze mezi  $-40^\circ$  až  $-30^\circ$  (komutační úhly fází byly nastaveny na  $\vartheta_{ON} = -40^\circ$  a  $\vartheta_{OFF} = -5^\circ$ ). Výsledky odhadu polohy zobrazené na Obr. 21. odpovídají zpřesnění odhadu pomocí váženého průměru popsáno v kapitole 2.1.6. Obr. 22. vyjadřuje chybu odhadu polohy z ANN (zeleně) a po zpřesnění váženým průměrem (modře). Obr. 23-25. zobrazují totéž, ale pro nižší rychlost otáčení 200 ot/min.




Obr. 20. Odhad polohy z ANN estimátoru pro 600 ot/min




Obr. 21. Zpřesněný odhad polohy pro 600 ot/min







Obr. 22. Chyba odhadu polohy pro 600 ot/min, zeleně ANN estimátor, modře zpřesněná poloha



Obr. 23. Odhad polohy z ANN estimátoru pro 200 ot/min



Obr. 24. Zpřesněný odhad polohy pro 200 ot/min



Obr. 25. Chyba odhadu polohy pro 200 ot/min, zeleně ANN estimátor, modře zpřesněná poloha


### 2.1.10 Dílčí závěry kapitoly 2.1

V této kapitole byl představen adaptivní algoritmus odhadu polohy spínaného reluktančního motoru. Pro aproximaci polohy rotoru jako funkce magnetického toku a proudu byla použita umělá neuronová síť natrénována offline na naměřených datech. Z důvodu zlepšení odhadu polohy byla použita průběžná adaptace fázového odporu modelu a tím zpřesňován výpočet magnetického toku v dalším kroku. Dále byla počítána rychlost rotoru v okamžicích nejpřesnějšího odhadu polohy z umělé neuronové sítě. V tu chvíli byla inicializována počáteční poloha diskrétního integrátoru a z rychlosti počítána integrací nová poloha rotoru. Výsledná poloha rotoru byla následně vypočtena váženým průměrem z estimované polohy umělou neuronovou sítí a polohy odhadnuté integrací rychlosti. Díky tomuto algoritmu došlo k výraznému zpřesnění estimace polohy hlavně v kritických okamžicích, kdy je rotor blízko plně nesouosé polohy a nelze přesně odhadovat polohu z okamžitých hodnot proudu a spočteného magnetického toku fáze.

## 2.2 Estimace polohy synchronního motoru s permanentními magnety pomocí Unscented Kalman Filtru s adaptivním modelem s pomocnou neuronovou sítí

### 2.2.1 Úvod

Nejčastěji používanou stochastickou modelově orientovanou metodou pro odhad polohy a rychlosti PMSM je tzv. Extended Kalman Filtr (dále jen EKF někdy také v češtině označovaný jako rozšířený kalmanův filtr) [11], [13]. Základní rozdíl mezi EKF a Unscented Kalman Filtrem (UKF) je princip propagace gaussovského (normálního) rozdělení přes nelineární funkci. Zatímco EKF využívá lokální linearizaci v pracovním bodě (kolem střední hodnoty), přes kterou je gaussovská funkce propagována<sup>5</sup>, tak UKF využívá pomocné body v okolí střední hodnoty. Tyto body jsou propagovány přes nelineární funkci a na základě výsledku je rekonstruována nová gaussovská funkce (viz Obr. 26).



Obr. 26. Propagace gaussovského rozdělení přes nelineární funkci – vlevo linearizací (EKF), vpravo pomocnými body (UKF)

<sup>5</sup> Kalmanův filtr [54] a jeho nelineární varianty vychází z optimálního kvadratického odhadu [1], kde všechny odhadované veličiny mají gaussovské (normální) rozdělení. Pokud toto rozdělení nemají, nutně to ještě neznamená neschopnost odhadu veličiny, ale nelze zaručit optimalitu odhadu (tj. není estimátorem s minimální variancí). Pro kvalitnější odhady negaussovských veličin je možné použít např. particle filter, který ale vede často na vyšší výpočetní náročnost [55].

Tento typ transformace gaussovské funkce se v zahraniční literatuře nazývá Scaled Unscented Transform a byla poprvé představena Simonem J. Julierem v roce 1999 [14]. Hlavní výhoda UKF oproti EKF nastává, pokud je nelineární transformační funkce na škále variance či kovariance vstupní gaussovské funkce hladká a výrazněji nelineární (jak už napovídá Obr. 26). Hlavní nevýhodou UKF je vyšší výpočetní náročnost. To může způsobovat paradoxně situaci, pokud jsme limitováni výpočetním výkonem naší real-time platformy, vedoucí na nižší vzorkovací frekvence oproti EKF a tím možným zvětšením (ko)variance a tudíž i škály přes kterou propagujeme gaussovskou funkci. Díky tomu může EKF vykazovat lepší vlastnosti pro určité typy úloh a vždy záleží případ od případu, jestli je UKF výhodnějším řešením než EKF.

Stále aktuálním problémem stochastických algoritmů odhadu polohy a rychlosti PMSM, je dostatečně přesný a zároveň aplikačně použitelný matematický model. Řada jevů, které více či méně významněji ovlivňují chování pohonu, zůstává nemodelována [13] (např. problematika mrtvých časů, pulzně šířkové modulace, napěťových úbytků na výkonových polovodičových součástkách, teplotní změna odporu atd.). Další chyby stochastického modelu tvoří nepřesnost parametrů a chyby způsobené diskretizací modelu. Tato kapitola se proto pokouší nastínit jeden z možných směrů rozšíření estimace polohy pomocí UKF o online adaptovanou pomocnou umělou neuronovou síť (ANN), která modeluje chyby a nemodelované nelinearity klasického modelu PMSM ve stojících ( $\alpha$ ,  $\beta$ ) souřadnicích. Cílem bylo dosáhnout vyšších přesností odhadu hlavně z pohledu estimace v kritických nízkých otáčkách. Teoretické výsledky algoritmu EKF s online adaptovaným ANN modelem byly použity úspěšně na systémech s nemodelovanou nelinearitou [56] již v roce 1995 Stephenem C. Stubberudem a později upraveny pro UKF (Ronghui Zhan and Jianwei Wan [57]). V první podkapitole je popsán algoritmus UKF a jeho rozšíření o ANN (dále NNUKF), ve druhé podkapitole pak použitý matematický model PMSM a simulační model celého pohonu, ve třetí podkapitole simulační výsledky a jejich porovnání s klasickým UKF řešením. Z důvodu vysoké výpočetní náročnosti nebyly zatím simulační

výsledky experimentálně ověřeny. Souhrnné výsledky této kapitoly byly publikovány na zahraniční konferenci [58].

### 2.2.2 Algoritmus Unscented Kalman Filteru

UKF patří do kategorie tzv. Sigma-point kalman filtrů<sup>6</sup>. Tyto typy filtrů (jak již bylo zmíněno dříve) nepoužívají pro propagaci gaussovských rozdělení lokální linearizaci modelu, ale pomocných tzv. "Sigma" bodů. Pomocí této techniky dosahují vyšší přesnosti propagace gaussovského rozdělení a mohou dosáhnout z pohledu taylorova rozvoje nelineární funkce přesnosti druhého řádu (oproti EKF, který dosahuje maximálně prvního řádu, díky použité linearizaci) [14].

Základní princip algoritmů EKF i UKF je stejný. Nejprve se vypočte pomocí stochastického matematického modelu predikce stavu systému. V dalším kroku se na základě kovariancí spočte Kalmanovo zesílení a nakonec na základě změřených hodnot a predikovaného výstupu dochází ke korekci odhadu stavu systému.

Stavová rovnice systému v čase  $t = k T_s$  je dána rovnicí (16):

$$x_{(k+1)} = f(x_{(k)}, u_{(k)}) + v_{(k)} \quad (16)$$

,kde  $f$  je obecně nelineární přechodová funkce modelu systému,  $x_{(k)}$  a  $x_{(k+1)}$  je hodnota vektoru stavu v čase  $k$ , respektive v  $k+1$ ,  $u_{(k)}$  je okamžitá známá hodnota (či vektor hodnot) vstupu systému a  $v_{(k)}$  je vektor okamžitých hodnot šumu reprezentující nepřesnost mat. modelu, chybu výpočtu atd.

Výstupní rovnice systému je dána předpisem:

$$y_{(k)} = h(x_{(k)}, u_{(k)}) + n_{(k)} \quad (17)$$

---

<sup>6</sup> Mezi další nejznámější Sigma-point Kalman Filtery patří např. Cubature Kalman Filter (UKF pomocí specifického nastavení může na Cubature Kalman Filter degradovat), Central Difference Kalman Filter, The Divided Difference Kalman Filter atd.

kde  $h$  je obecně nelineární výstupní funkce modelu systému,  $y_{(k)}$  a  $n_{(k)}$  je vektor okamžitých hodnot šumu měření.

Samotný algoritmus UKF vychází z počáteční (očekávané) inicializace stavových proměnných:

$$\hat{x}_{(0)} = E(x_{(0)}) \quad (18)$$

A inicializační diagonální kovarianční stavové matice  $P$  (která odpovídá očekávané přesnosti odhadu počátečního stavu):

$$P_{(0)} = E[(x_{(0)} - \hat{x}_{(0)})(x_{(0)} - \hat{x}_{(0)})^T] \quad (19)$$

Poté je kolem očekávaného vektoru stavové veličiny vygenerováno  $2L+1$  pomocných sigma-bodů (vektorů stavu), kde  $L$  je hodnota dimenze vektoru stavu  $x$ . Jeden sigma-bod odpovídá střední hodnotě vektoru stavu a zbylé jsou symetricky rozmístěné v jednotlivých dimenzích prostoru a odpovídají kovarianci vektoru stavu. Z těchto bodů je vytvořena matice tohoto tvaru:

$$\chi_{(k-1)} = [\hat{x}_{(k-1)} \quad \hat{x}_{(k-1)} + \eta\sqrt{P_{(k-1)}} \quad \hat{x}_{(k-1)} - \eta\sqrt{P_{(k-1)}}] \quad (20)$$

Pokud je algoritmus v klasické formě (nikoliv tzv. odmocninové [15]) je tvorba odmocniny kovarianční matice  $P_{(k-1)}$  pomocí choleského dekompozice jedna z možných slabin algoritmu vedoucí k možné numerické nestabilitě. Důvodem je nutná pozitivní semidefinitnost matice  $P$ , aby odmocnina z této matice měla řešení v oboru reálných čísel. Lepších numerických vlastností dosahuje algoritmus v odmocninových formách (tj. v QR formě [15] či LDL/UDU formě [59]).

$\eta$  je předem zvolený parametr, který se podílí na rozmístění sigma-bodů. Pro výpočet tohoto parametru je použit vzorec:

$$\eta = \sqrt{L + \lambda} \quad (21)$$

kde koeficient  $\lambda$  lze získat ze vztahu:

$$\lambda = L(\alpha^2 - 1) \quad (22)$$

a parametrem  $\alpha$  se upravuje rozptřeni (vzdálenost) sigma-bodů od střední hodnoty stavového vektoru ( $0 < \alpha < 1$ ).

Dále je pro všechny sigma-body spočtena predikce pomocí propagace přes stavovou nelineární přechodovou funkci:

$$\chi_{(k|k-1)} = f(\chi_{(k-1)}, u_{(k-1)}) \quad (23)$$

Z predikovaných sigma-bodů je spočtena predikovaná střední hodnota vektoru stavu:

$$\hat{x}_{(k)}^- = \sum_{i=0}^{2L} W_i^{(m)} \chi_{(k|k-1)} \quad (24)$$

a kovarianční matice chyby odhadu stavu:

$$P_{(k)}^- = \sum_{i=0}^{2L} W_i^{(c)} [\chi_{i(k|k-1)} - \hat{x}_{(k)}^-] [\chi_{i(k|k-1)} - \hat{x}_{(k)}^-]^T + Q \quad (25)$$

$W$  jsou váhy příslušné jednotlivým sigma-bodům a pro váhy odpovídající střední hodnotě platí:

$$W_0^{(m)} = \frac{\lambda}{L + \lambda} \quad \text{a} \quad W_0^{(c)} = \frac{\lambda}{L + \lambda} + (1 - \alpha^2 + \beta) \quad (26)$$

A pro ostatní sigma-body ( $i=1 \dots 2L$ ):

$$W_i^{(m)} = W_i^{(c)} = \frac{1}{2(L + \lambda)} \quad (27)$$

$W_i^{(m)}$  jsou váhy pro výpočet predikované střední hodnoty a  $W_i^{(c)}$  jsou váhy pro výpočet kovarianční matice stavu.  $Q$  je kovarianční matice šumu stavu (procesu) a  $\beta$  je parametr vyjadřující statistickou distribuci stavových proměnných (pro gaussovskou  $\beta = 2$ ).

Predikované sigma-body jsou dále propagovány přes výstupní funkci a je vypočtena střední hodnota výstupního vektoru:

$$\gamma_{(k|k-1)} = h(\chi_{(k|k-1)}) \quad (28)$$

$$\hat{y}_{(k)}^- = \sum_{i=0}^{2L} W_i^{(m)} \gamma_{i(k|k-1)} \quad (29)$$

Dále je spočtena celková výstupní kovarianční matice  $P_{y(k),y(k)}$  a křížná kovarianční matice  $P_{x(k),y(k)}$

$$P_{y(k),y(k)} = \sum_{i=0}^{2L} W_i^{(c)} [\gamma_{i(k|k-1)} - \hat{y}_{(k)}^-] [\gamma_{i(k|k-1)} - \hat{y}_{(k)}^-]^T + R \quad (30)$$

$$P_{x(k),y(k)} = \sum_{i=0}^{2L} W_i^{(c)} [\chi_{i(k|k-1)} - \hat{x}_{(k)}^-] [\gamma_{i(k|k-1)} - \hat{y}_{(k)}^-]^T \quad (31)$$

$R$  je kovarianční matice vyjadřující šum měření. Dále je spočteno kalmanovo zesílení a provedena korekce predikovaného stavu systému (na základě rozdílu změřených a predikovaných výstupních hodnot) a kovariance  $P_{(k)}$ .

$$K_{(k)} = P_{x(k),y(k)} P_{y(k),y(k)}^{-1} \quad (32)$$




$$\hat{x}_{(k)} = \hat{x}_{(k)}^- + K_{(k)}(\hat{y}_{(k)} - \hat{y}_{(k)}^-) \quad (33)$$

$$P_{(k)} = P_{(k)}^- + K_{(k)}P_{y(k),y(k)}^{-1}K_{(k)}^T \quad (34)$$

V dalším kroku jsou opět spočteny nové sigma-body kolem predikovaného stavu a opět propagovány přes nelineární systém.

### 2.2.3 Unscented kalman filtr s pomocnou neuronovou sítí

Základní myšlenka tohoto algoritmu spočívá v rozšíření stavového prostoru o parametry modelu. V našem případě je stavový prostor rozšířený o váhy ANN, jejíž výstup je přičten k odhadnutému stavu stochastického modelu. Váhy jsou adaptovány tak, aby se snížila chyba v odhadovaném výstupu systému. V případě odhadu polohy a rychlosti PMSM byla použita adaptace ANN pouze k modelování chyby mezi zjednodušeným stochastickým modelem PMSM a modelem reprezentujícím reálný pohon:



Obr. 27. Rozšířený stavový model o umělou neuronovou sítí modelující chybovou funkci stochastického modelu

$$x_{kor(k)} = x_{(k)} + x_{err(k)} \quad (35)$$

$$x_{kor(k)} = f(x_{kor(k-1)}, u_{(k-1)}) + ANN(x_{kor(k-1)}, u_{(k-1)}, W_{(k-1)})$$

Celkový (rozšířený) stavový vektor UKF, který je cyklicky updatetován, tedy obsahuje korigované stavové veličiny stochastického modelu a váhové koeficienty ANN:

$$x_{(k)}^a = \begin{bmatrix} x_{kor(k)} \\ W_{(k)} \end{bmatrix} \quad (36)$$

Výstupní stavová rovnice zůstává zachována:

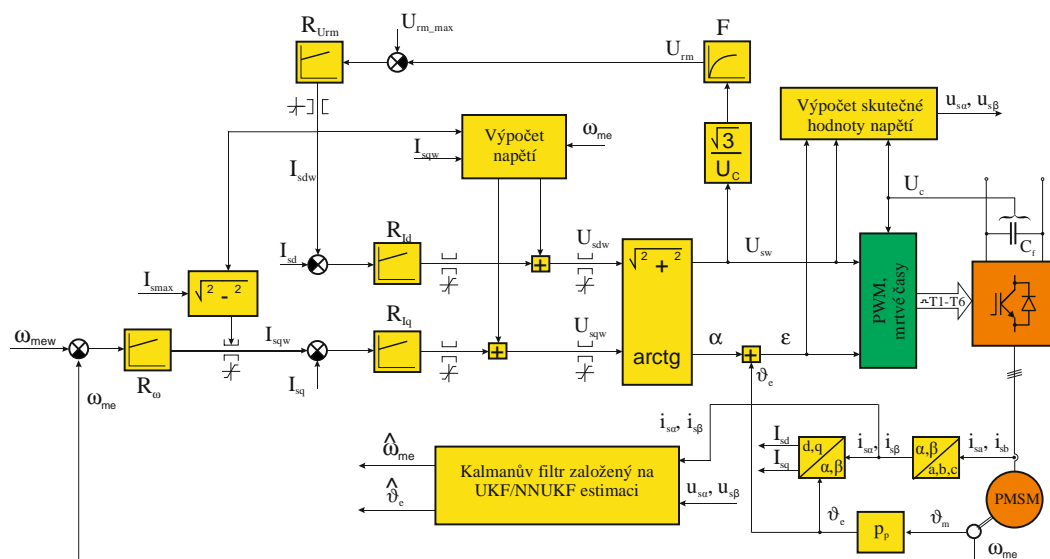
$$y_{(k)} = h(x_{kor(k)}) \quad (37)$$

Další podrobnosti budou uvedeny v kapitole 2.2.6.

### **2.2.4 Simulační model PMSM**

Základní regulační schéma uvedené na Obr. 28. je založené na vektorovém řízení orientovaném na magnetický tok rotoru (jehož pozice je determinována polohou permanentních magnetů tj. natočením rotoru) s vnější rychlostní a vnitřní proudovou regulační smyčkou. Rychlostní proporcčně integrační (PI) regulátor minimalizuje regulační odchylku mezi požadovanou a skutečnou rychlostí PMSM. Výstupem regulátoru rychlosti je požadovaná veličina pro momentotvornou složku proudu  $I_{sqw}$ , která je ekvivalentem požadovaného momentu. Požadovaná tokotvorná složka proudu je za normálních okolností nulová až do jmenovitých otáček. Pro vyšší než jmenovité otáčky je požadované napětí střídače vyšší než je schopen střídač vytvořit a dochází pomocí regulátoru  $R_{U_{rm}}$  k růstu tokotvorné složky proudu. Tato složka pomocí regulátoru  $R_{I_d}$  zapříčiní odbuzování motoru (statorový magnetický tok tokotvorné složky působí proti magnetickému toku magnetů) a je možné dosáhnout vyšších otáček PMSM. Zároveň je třeba omezit momentotvornou složku proudu tak, aby nebyl překročen maximální proud motoru. Dynamické vlastnosti regulační struktury vylepšuje od vazbovací blok výpočet napětí, který provádí dopředný výpočet napětí přibližně odpovídající požadovaným proudům. Výstup proudových regulátorů s od vazbením odpovídá požadovanému napětí v d-q souřadnicích. Následně je toto napětí transformováno do prostorového vektoru ve formě amplitudy a relativního fázového natočení a

v součtu s odhadnutou nebo změřenou polohou rotoru nám dává skutečný požadovaný vektor napětí. Z tohoto vektoru napětí jsou dále se změřeným napětím na kondenzátoru  $U_c$  stejnosměrného meziobvodu vytvořena 3 fázová napětí a komparací se symetrickým pilovým signálem vytvořeny diskretní PWM signály pro jednotlivé prvky měniče. Pro regulaci PMSM bez čidla polohy je nutné pro stochastický model znát komponenty statorového vektoru napětí a proudu ve stacionárních ( $\alpha, \beta$ ) souřadnicích. Napětí je rekonstruováno na základě okamžitého napětí na kondenzátoru stejnosměrného meziobvodu a známého aktuálního vektoru statorového napětí. Z kalmanova filtru jsou výstupními veličinami odhadnutá poloha rotoru (pro potřeby transformace vektoru proudu do d-q souřadnic) a rychlost otáčení rotoru (regulovaná veličina u regulační smyčky rychlosti).



Obr. 28. Vektorové řízení PMSM se stochastickým estimátorem polohy na bázi Unscented Kalman filtru či Unscented Kalman filtru s adaptivním modelem s pomocnou neuronovou sítí

### 2.2.5 Stochastický model PMSM pro NNUKF

Stochastický predikční model PMSM může být buď ve stacionárním ( $\alpha$ - $\beta$ ) nebo rotačním (d-q) systému. Rovnice PMSM pro rotační d-q systém

jsou jednodušší, ale nevýhodou je nutnost transformace statorových proudů do rotačních souřadnic (a s tím i související např. problematika transformace statistického rozdělení). Tato transformace je známá jako Parkova a je v maticové interpretaci pomocí rotační matice časově variantní (je závislá na natočení polohy rotoru PMSM). Z tohoto důvodu bývá preferován model PMSM ve stacionárním systému. Protože výpočetní náročnost UKF je silně závislá na počtu stavů  $O(L^3)$ , snažíme se obecně snížit počet potřebných stavů na minimum. Pro odvození našeho redukovaného<sup>7</sup> modelu vyjdeme ze známých diskrétních rovnic PMSM se zanedbaným zátěžným momentem<sup>8</sup>:

$$i_{s\alpha(k+1)} = \left(1 - \frac{R_s}{L_s} \Delta t\right) i_{s\alpha(k)} + \frac{\Psi_{pm}}{L_s} \Delta t \omega_{(k)} \sin v_{e(k)} + u_{s\alpha(k)} \frac{\Delta t}{L_s} \quad (38)$$

$$i_{s\beta(k+1)} = \left(1 - \frac{R_s}{L_s} \Delta t\right) i_{s\beta(k)} - \frac{\Psi_{pm}}{L_s} \Delta t \omega_{(k)} \cos v_{e(k)} + u_{s\beta(k)} \frac{\Delta t}{L_s} \quad (39)$$

$$\omega_{(k+1)} = \left(1 - \frac{B}{J} \Delta t\right) \omega_{(k)} + \Delta t \frac{k_p p_p^2 \Psi_{pm}}{J} (i_{s\beta(k)} \cos v_{e(k)} - i_{s\alpha(k)} \sin v_{e(k)}) \quad (40)$$

$$v_{e(k+1)} = v_{e(k)} + \omega_{(k)} \Delta t \quad (41)$$

Se stavovým vektorem  $x_{(k+1)} = [i_{s\alpha(k+1)}, i_{s\beta(k+1)}, \omega_{(k+1)}, v_{e(k+1)}]^T$  a výstupním vektorem  $y_{(k+1)} = [i_{s\alpha(k+1)}, i_{s\beta(k+1)}]^T$ .

Pro zjednodušení zápisu provedeme substituci za konstanty u jednotlivých stavových proměnných:

$$a = 1 - \frac{R_s}{L_s} \Delta t; \quad b = \frac{\Psi_{pm}}{L_s} \Delta t; \quad c = \frac{\Delta t}{L_s}; \quad d = 1 - \frac{B}{J} \Delta t; \quad e = \Delta t \frac{k_p p_p^2 \Psi_{pm}}{J} \quad (42)$$

Rovnice modelu po substituci za konstantní členy mají tedy tvar:

<sup>7</sup> Většinou bývá používán stochastický model se 4 či 5 stavovými proměnnými [13]

<sup>8</sup> Zátěžný moment si můžeme dovést zanedbat, protože by se projevil offsetovou chybou, kterou umí algoritmus NNUKF odstranit

$$i_{s\alpha(k+1)} = a \cdot i_{s\alpha(k)} + b \cdot \omega(k) \sin v_e(k) + c \cdot u_{s\alpha(k)} \quad (43)$$

$$i_{s\beta(k+1)} = a \cdot i_{s\beta(k)} - b \cdot \omega(k) \cos v_e(k) + c \cdot u_{s\beta(k)} \quad (44)$$

$$\omega(k+1) = d \cdot \omega(k) + e \cdot (i_{s\beta(k)} \cos v_e(k) - i_{s\alpha(k)} \sin v_e(k)) \quad (45)$$

$$v_e(k+1) = v_e(k) + \omega(k) \Delta t \quad (46)$$

Redukci stavových rovnic dosáhneme tím, že rovnice pro proudy  $i_{s\alpha(k+1)}$  a  $i_{s\beta(k+1)}$  označíme jako výstupní veličiny. Tímto redukuje počet stavových veličin na dvě  $x_{(k+1)} = [\omega(k+1), v_e(k+1)]^T$

Stavové rovnice jsou tedy ve formě:

$$\omega(k+1) = d \cdot \omega(k) + e \cdot (i_{s\beta(k)} \cos v_e(k) - i_{s\alpha(k)} \sin v_e(k)) \quad (47)$$

$$v_e(k+1) = v_e(k) + \omega(k) \Delta t \quad (48)$$

A výstupní rovnice jsou:

$$i_{s\alpha(k+1)} = a \cdot i_{s\alpha(k)} + b \cdot \omega(k) \sin v_e(k) + c \cdot u_{s\alpha(k)} \quad (49)$$

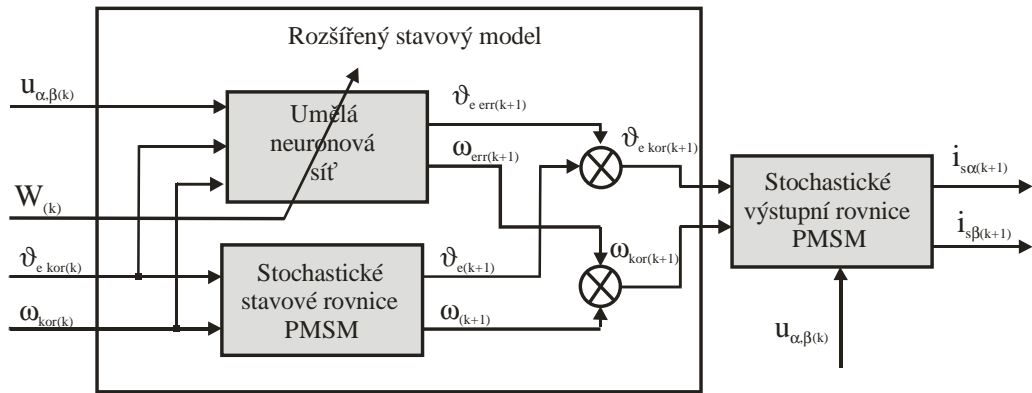
$$i_{s\beta(k+1)} = a \cdot i_{s\beta(k)} - b \cdot \omega(k) \cos v_e(k) + c \cdot u_{s\beta(k)} \quad (50)$$

V další kapitole 2.2.5 je popsán celkový stavový vektor rozšířený o váhy ANN.

### **2.2.6 NNUKF pro odhad polohy a rychlosti PMSM**

V kapitole 2.2.3 bylo zmíněné, že celkový stavový vektor se u algoritmu NNUKF skládá ze dvou částí. První část tvoří stavové proměnné

stochastického modelu PMSM představené v předchozí kapitole a druhou část rozšířeného stavového vektoru tvoří váhy ANN:




Obr. 29. Stochastický model PMSM rozšířený o adaptivní část, která je reprezentovaná umělou neuronovou sítí

$$\begin{aligned}
 x_{(k+1)}^a = \begin{bmatrix} x_{(k+1)} \\ W_{(k+1)} \end{bmatrix} &= \begin{bmatrix} \omega_{(k+1)} + \omega_{err(k+1)} \\ v_{e(k+1)} + v_{e err(k+1)} \\ w_{1(k+1)} \\ \dots \\ w_{N(k+1)} \end{bmatrix} \\
 &= \begin{bmatrix} d \cdot \omega_{kor(k)} + e \cdot (i_{s\beta(k)} \cos v_{e kor(k)} - i_{s\alpha(k)} \sin v_{e kor(k)}) + \omega_{err(k+1)} \\ v_{e kor(k)} + \omega_{kor(k)} \Delta t + v_{e err(k+1)} \\ w_{1(k)} \\ \dots \\ w_{N(k)} \end{bmatrix} \quad (50)
 \end{aligned}$$

kde  $\begin{bmatrix} \omega_{err(k+1)} \\ v_{e err(k+1)} \end{bmatrix} = f(u_{s\alpha(k)}, u_{s\beta(k)}, \omega_{kor(k)}, v_{e kor(k)}, W_{(k)})$  je obecně nelineární funkce reprezentovaná umělou neuronovou sítí.

Umělá neuronová síť byla použita třívrstvá typu feedforward s nelineární funkcí tangens hyperbolický ve skryté vrstvě a výstupní lineární funkcí. Její základní schéma je uvedené na Obr. 30.



Obr. 30. Adaptivní část stochastického modelu reprezentovaná třívrstvou dopřednou umělou neuronovou sítí s 6 neurony ve skryté vrstvě

Tento typ neuronové sítě je univerzální funkční aproximátor [2] a její funkční předpis odpovídá maticově zapsané rovnici:

$$\begin{bmatrix} \omega_{err(k+1)} \\ v_{err(k+1)} \end{bmatrix} = W_{2(k)} \left[ \begin{array}{c} \tanh \left( W_{1(k)} \begin{bmatrix} u_{s\alpha(k)} \\ u_{s\beta(k)} \\ \omega(k) \\ v_e(k) \\ 1 \end{bmatrix} \right) \\ 1 \end{array} \right] \quad (51)$$

kde  $W_{1(k)} \in R^{Neur \times (Nin + Nst + 1)}$  je matice váhových koeficientů skryté vrstvy neuronové sítě,  $W_{2(k)} \in R^{Nst \times (Neur + 1)}$  je matice váhových koeficientů výstupní vrstvy,  $Neur$  je počet neuronů ve skryté vrstvě,  $Nst$  je počet stavových proměnných stochastického modelu (v našem případě  $Nst = 2$ ) a  $Nin$  je počet vstupních proměnných stochastického modelu (pro náš model  $Nin = 2$ ). Celkový vektor adaptovaných vah  $W_{(k)}$  (z jehož prvků jsou tvořeny matice vah  $W_{1(k)}$  a  $W_{2(k)}$  pro maticový výpočet neuronové sítě) má tedy rozměr  $W_{(k)} \in R^{1 \times (Neur(Nin + Nst + 1) + Nst(Neur + 1))}$

Celkový rozšířený stavový vektor má tedy po úpravě dimenzi:

$$x_{(k)}^a = \begin{bmatrix} x_{(k)} \\ W_{(k)} \end{bmatrix} \in R^{1 \times (Neur(2Nst+Nin+1)+2Nst)} \quad (52)$$

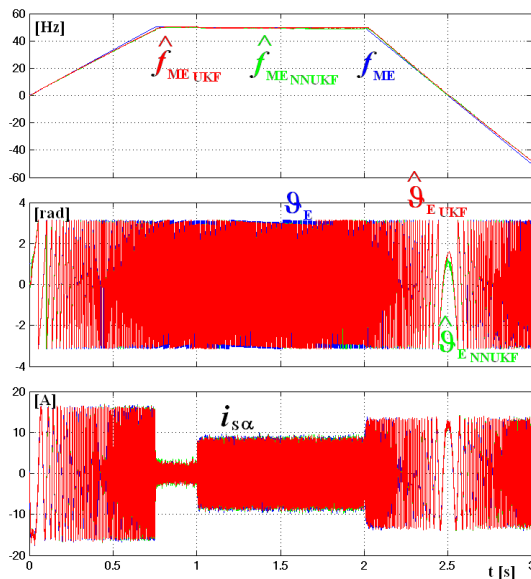
Z rovnice 52 vidíme, že zvolený počet neuronů ve skryté vrstvě (parametr *Neur*) výrazně ovlivňuje celkovou velikost rozšířeného stavového prostoru. Příliš nízký počet neuronů ve skryté vrstvě snižuje schopnost ANN se adaptovat dostatečně přesně na chybovou funkci stochastického modelu. Naopak příliš velký počet neuronů ve skryté vrstvě vede nejen na vyšší výpočetní náročnost, ale také na tzv. overfitting ANN (přeaproximování) a zhoršené schopnosti extrapolace chybové funkce [2]. Pro náš případ se jako rozumný kompromis trvale adaptované ANN jeví použití 6 neuronů ve skryté vrstvě (na základě simulačních experimentů). I přes tento poměrně malý počet neuronů došlo k nárůstu prvků celkového stavového vektoru z 2 (v případě odhadu pouze pomocí UKF) na 46 v případě NNUKF (tj. nárůst o současně hledaných 44 váhových koeficientů ANN). Z důvodu vysoké výpočetní náročnosti nebylo možné při stávajících podmínkách experimentálně ověřit algoritmus, a proto se další kapitola zabývá pouze simulačním ověřením. Algoritmus se dá výrazně paralelizovat a tím v budoucnu implementovat na nových embedded platformách (rychlých výcejádrových embedded procesorech či moderních FPGA polích).

### **2.2.7 Simulační výsledky a ověření algoritmu NNUKF**


Popon s PMSM byl testován s paralelně pracujícím odhadem polohy a rychlosti UKF a NNUKF estimátoru. Vzorovací perioda pro oba kalmanovo filtry byla 200  $\mu$ s a nosná frekvence PWM byla 10 kHz. Na Obr. 31 a 32 lze vidět lichoběžníkový profil rychlosti procházející nulovými otáčkami. V čase 1s došlo ke skokové změně zátěžného momentu z 2 Nm na 10Nm. Na levé straně je možné vidět modře skutečné mechanické otáčky přepočtené na elektrické  $f_{ME}$  [Hz], otáčky odhadnuté UKF  $f_{ME\ UKF}$  [Hz] (červeně) a zeleně odhadnuté pomocí NNUKF  $f_{ME\ NNUKF}$ . Totéž je zde zobrazeno pro elektrickou polohu rotoru a proud ve stacionárním



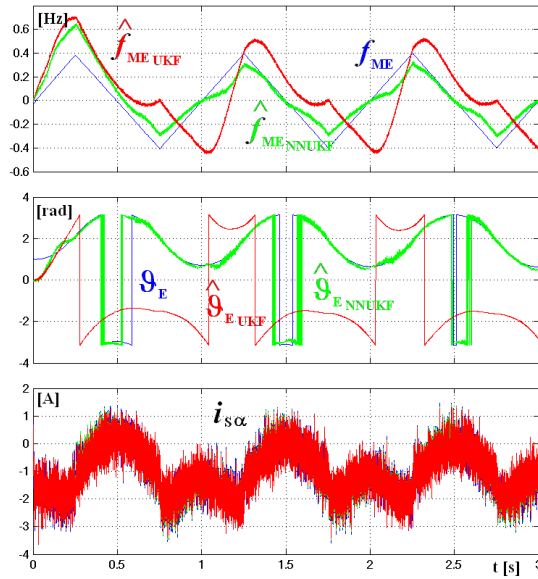
souřadném systému  $i_{s\alpha}$ . Vpravo (Obr 32.) lze vidět chyby v odhadu. Nahoře je chyba v odhadnutých otáčkách pomocí NNUKF a pod tím chyba odhadu UKF. Jako poslední dole je zobrazena chyba odhadu elektrické polohy obou estimátorů. Z obrázků je patrný nepatrně horší odhad NNUKF pro vysoké otáčky, ale přesnější odhad pro otáčky blízké nule (zpřesnění odhadu otáček a polohy v okolí nulových rychlostí bylo cílem použití tohoto algoritmu). Obr. 33. a 34. zobrazuje stejné veličiny pro trojúhelníkový profil a průchod nulovými otáčkami s nízkým akceleračním momentem. Dále byla použita inicializační poloha rotoru rozdílná oproti inicializační hodnotě kalmanových filtrů. Zde je již velmi patrný lepší odhad NNUKF oproti UKF a to jak v odhadování rychlosti tak polohy. Obr. 35. a 36. ukazují lichoběžníkový profil rychlosti pro rozdílný parametr stochastického modelu motoru oproti “reálnému” motoru (odpor  $R_s \text{ UKF} = R_s \text{ NNUKF} = 1,5 R_s$ ) a schopnost NNUKF se adaptovat a estimovat polohu a rychlost s poměrně malou chybou i ve velmi nízkých otáčkách.




Obr. 31. Odhad polohy a rychlosti pohonu s PMSM s lichoběžníkovým rychlostním profilem a skokovou změnou zátěžného momentu z 2 na 10 Nm v čase 1s



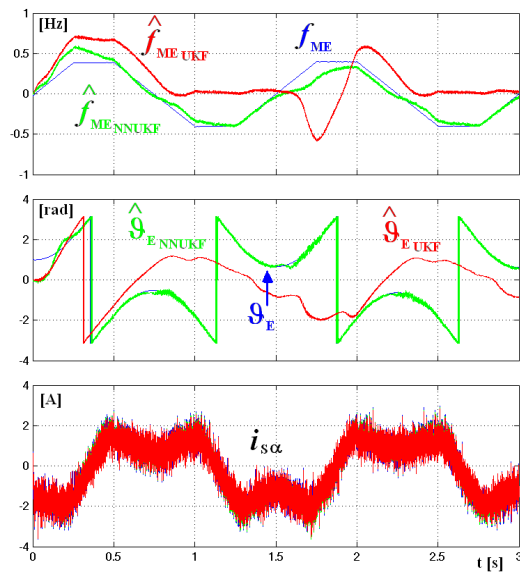
Obr. 32. Chyby v odhadu rychlosti a polohy pro případ na Obr. 31.




Obr. 33. Odhad polohy a rychlosti pohonu s PMSM s trojúhelníkovým rychlostním profilem a inicializační chybou odhadu polohy UKF/NNUKF



Obr. 34. Chyby v odhadu rychlosti a polohy pro případ na Obr. 33.



Obr. 35. Odhad polohy a rychlosti pohonu s PMSM s lichoběžníkovým rychlostním profilem, inicializační chybou odhadu polohy filtrů a rozdílným parametrem motoru (odporu  $R_{s\text{ UKF}} = R_{s\text{ NNUKF}} = 1,5 R_s$ )



Obr. 36. Chyby v odhadu rychlosti a polohy pro případ na Obr. 35.

### **2.2.8 Dílčí závěry kapitoly 2.2**

Tato kapitola popisuje mechanismus odhadu polohy pomocí Unscented Kalman Filtru (UKF). Tento stochastický pozorovatel stavu lze rozšířit o adaptaci parametrů modelu a provádět tzv. duální filtraci (současný odhad parametrů stochastického modelu a stavových proměnných). Protože ideální parametry stochastického modelu PMSM jsou pro jednoduché matematické modely časově proměnné (z důvodu nelinearity, mrtvých časů, úbytků na součástkách atd.), tak tato kapitola představuje rozšíření stochastického modelu PMSM o online adaptovanou umělou neuronovou síť (ANN), která modeluje tyto nelinearity a pomáhá zlepšit odhad stavových proměnných v dalším kroku. Simulační výsledky ukazují možnou perspektivu tohoto algoritmu hlavně v kritických nízkých otáčkách, kde je největší rozdíl mezi jednoduchým stochastickým modelem a "reálným" pohonem (větší vliv mrtvých časů a úbytků na polovodičích).

## Kapitola 3

# Prediktivní estimace a aktivní tlumení kmitů vstupního LC filtru trakčního vozidla s DTC řízeným PMSM

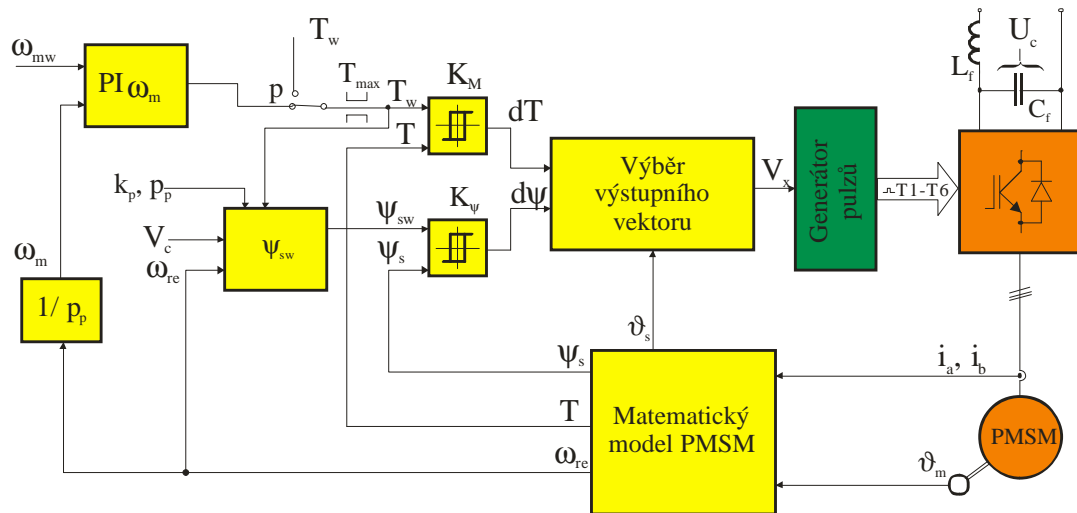
### *3.1 Úvod*

Tato kapitola disertační práce se zabývá prediktivní estimací a aktivní stabilizací kmitů LC filtru trakčního vozidla se synchronním motorem s vnějšími permanentními magnety (PMSM) regulovaného algoritmem přímého řízení momentu (DTC) napájeného ze stejnosměrné troleje. V úvodu je vysvětlena problematika stability vstupního filtru trakčního vozidla, následuje popis algoritmu stabilizace pomocí prediktivního řízení, počítačové simulace a závěrem jsou uvedeny výsledky měření navrženého algoritmu a porovnány s nejčastěji používaným řešením. Souhrnné výsledky této kapitoly byly publikovány na mezinárodní konferenci [60].

V důsledku používání polovodičových měničů v pohonech stejnosměrné trakce jsou do troleje pohonem injektovány proudové

harmonické, které jsou trolejí dále přenášeny. Trolej je možno popsat jako impedanci závislou na vzdálenosti hnacího vozidla od měřírny. Proudové harmonické na impedanci troleje vytváří úbytky napětí, a proto lze předpokládat, že napětí troleje kromě stejnosměrné složky obsahuje i další harmonické. Je-li frekvence napěťové harmonické totožná s rezonanční frekvencí pohonu, dojde k rozkmitání vstupního LC filtru pohonu. Kmity mohou být buzeny napěťovými harmonickými v troleji, které jsou důsledkem aktivity jiného hnacího vozidla na stejném napájecím úseku, ale i proudovými harmonickými generovanými vozidlem samotným. Tento problém je stále aktuální a jeho možným řešením pomocí prediktivního řízení u pohonu s PMSM motorem regulovaným přímým řízením momentu se zabývá tato kapitola.

Použité přímé řízení momentu PMSM s povrchovými magnety je velmi dobře známo a popsáno v literatuře [19] a jeho základní schéma je uvedeno na Obr. 37. Algoritmus umožňuje práci pohonu jak v tzv. rychlostním módu pomocí regulátoru otáček tak v momentovém módu, kdy je požadovanou veličinou přímo moment motoru. Mezi těmito dvěma módy je možné přecházet pomocí naznačeného přepínače  $p$ . V rychlostním módu do proporčně integračního ( $PI\omega_m$ ) regulátoru vstupuje požadovaná a skutečná rychlost otáčení motoru. Výstupem regulátoru je požadovaný moment  $T_w$ , který je referencí pro hysterezní regulátor momentu (komparátor  $K_M$ ). Skutečný moment motoru zavedený do regulátoru je vypočítán pomocí matematického modelu PMSM na základě změřených fázových proudů a polohy rotoru. Dále je spočten skutečný statorový tok  $\Psi_s$  a spolu s požadovaným tokem zavedený do hysterezního regulátoru toku (komparátor  $K_\psi$ ). Na základě výstupu hysterezních regulátorů a fázového natočení rotorového toku  $v_s$  je vybrán optimální výstupní vektor napětí  $V_x$  a jemu odpovídající kombinace sepnutí jednotlivých prvků napěťového střídače. V případě momentového řízení je spínačem  $p$  vyřazena regulační smyčka rychlosti a požadovaný moment je přímo zadáván.




Obr. 37. Regulační schéma DTC řízení PMSM

Pro měření frekvenčních charakteristik a ověření aktivního tlumení vstupního filtru byl použit momentový mód (pohon byl řízen na konstantní moment) a pohon s PMSM byl mechanicky zatížen asynchronním motorem z důvodu simulace vysokého momentu setrvačnosti trakčního vozidla (asynchronní motor byl řízen na konstantní otáčky).

### 3.2 Zjednodušený simulační model trakčního pohonu se vstupním LC filtrem

Zjednodušený model reprezentující trakčního pohonu se vstupním LC filtrem je zobrazeno na Obr. 38. Trolejové napětí je reprezentováno stejnosměrným zdrojem  $U_{dc}$  poskytujícím konstantní napětí. Vstupní filtr se skládá z indukčnosti  $L_f$ , kondenzátoru  $C_f$  a parazitního odporu  $R_L$ . Samotný trakční pohon je simulován jako proudový zdroj odebírající výkon  $P$  ze vstupního filtru.



Obr. 38. Zjednodušený simulační model trakčního pohonu se vstupním LC filtrem napájeného ze stejnosměrné troleje

Základní simulační parametry obvodu jsou:  $U_{dc}=100$  V,  $R_L=0,02$   $\Omega$ ,  $L_f=6$  mH,  $C_f=4$  mF. Parametry vstupního filtru byly voleny tak, aby odpovídaly rezonanční frekvenci kolem 30 Hz, která je typická pro vozidla lehké trakce [24]. Odebíraný výkon z filtru odpovídá vzorci (53):


$$P = U_c \cdot i_z = T \cdot \omega_m \quad (53)$$

kde  $T$  je moment produkovaný motorem a  $\omega_m$  je mechanická rychlost otáčení rotoru. Protože je velmi komplikované měření odebíraného proudu  $i_z$  ze vstupního filtru<sup>9</sup>, je tento proud vypočítáván ze změřeného napětí na kondenzátoru a známého odebíraného mechanického výkonu (54).


$$i_z = (T \cdot \omega_m) / U_c \quad (54)$$

Z obrázků 39 a 40 vyplývá, že u tohoto typu obvodu dochází při skokové změně odebíraného výkonu k téměř netlumeným oscilacím vstupního filtru. Tlumení kmitů je dáno pouze nízkým parazitním odporem. V tomto případě byly v obvodu vyvolány skokovou změnou odebíraného výkonu z 1 kW na 1,5 kW v čase 0,1 sekundy.

<sup>9</sup> Mimo jiné proto, že vzdálenost mezi tranzistory napěťového střídače a kondenzátory stejnosměrného obvodu musí být z důvodu minimalizace parazitních indukčností co možná nejmenší, odebíraný proud má pulsní charakter atd.



Obr. 39. Odezva napětí  $U_c$  na kondenzátoru LC filtru pro požadovanou skokovou změnou odebraného výkonu z 1 kW na 1,5 kW bez aktivního tlumení




Obr. 40. Ekvivalentní odebraný proud  $i_z$  z LC filtru pro požadovanou skokovou změnou odebraného výkonu z 1 kW na 1,5 kW bez aktivního tlumení

Několik používaných metod pro aktivní tlumení vstupního LC filtru bylo zmíněno v kapitole 1.1.3 popisující současný stav poznání v dané problematice. Jedna z nejčastěji používaných metod je detailně popsána v [24]. Tato metoda byla vybrána jako referenční pro porovnání s navrženou metodou stabilizace pomocí prediktivního regulátoru. Metoda aktivně tlumí kmitů úpravou požadovaného momentu  $T_w$  a vychází ze vzorce (55):

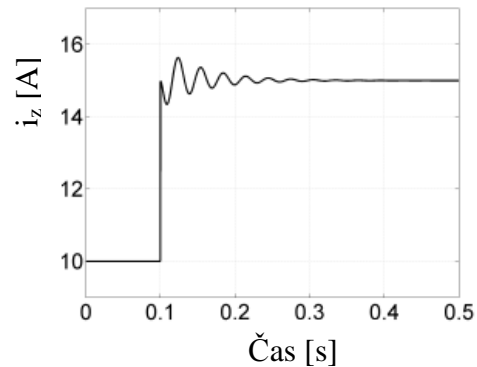
$$T_{corr} = T_w \left( \frac{U_c}{U_{c \text{ filtered}}} \right)^n \quad (55)$$

kde  $T_{corr}$  je nová korigovaná hodnota požadovaného momentu,  $T_w$  je původní požadovaná hodnota momentu z DTC řízení,  $U_c$  je okamžitá hodnota napětí kondenzátoru a  $U_{c \text{ filtered}}$  je filtrovaná (průměrovaná přes několik period kmitů) hodnota napětí na kondenzátoru a exponent  $n$  je koeficient rychlosti stabilizace kmitů. Vyšší exponent  $n$  vede k rychlejšímu zatlumení kmitů. Simulace prováděny s  $n=2$  jsou uvedeny na Obr. 41, 42.





Obr. 41. Odezva napětí  $U_c$  na kondenzátoru LC filtru pro požadovanou skokovou změnu odebraného výkonu z 1 kW na 1,5 kW s aktivním tlumením dle rov. (55)



Obr. 42. Ekvivalentní odebíraný proud  $i_z$  z LC filtru pro požadovanou skokovou změnu odebraného výkonu z 1 kW na 1,5 kW s aktivním tlumením dle rov. (55)

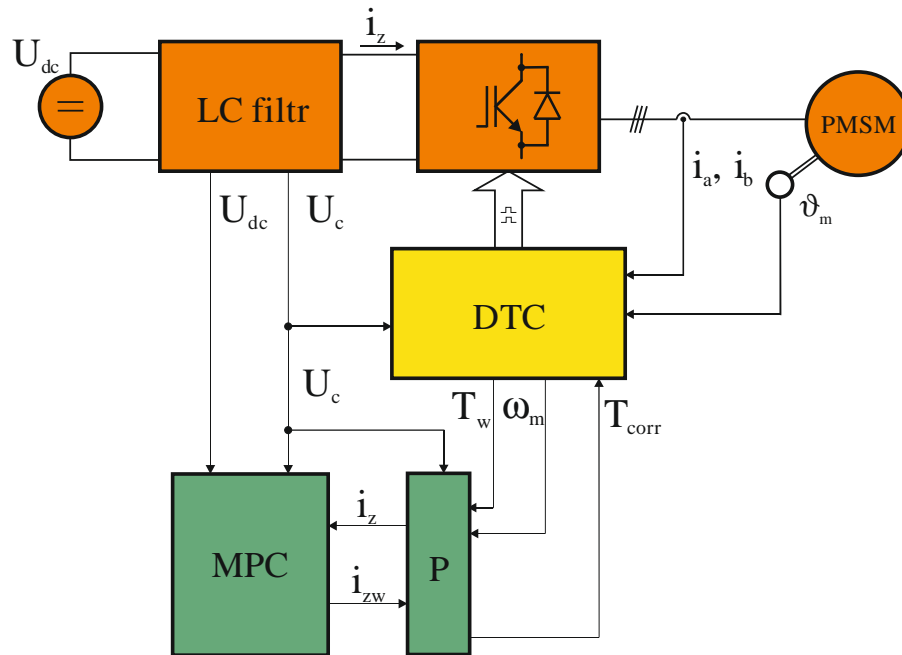
### 3.3 Aktivní stabilizace vstupního LC filtru algoritmem prediktivního řízení

Díky zjednodušenému modelu vstupního filtru trakčního pohonu uvedeného v předchozí kapitole 3.2 (který jsme si mohli dovolit díky velkému momentu setrvačnosti pohonu<sup>10</sup>) jsme docílili linearizaci našeho problému a ve výsledku relativně jednoduchého možného řešení pomocí lineárního prediktivního regulátoru (dále jen MPC – Model Predictive Controller). Prediktivní regulátor (blok MPC) je zobrazen na Obr. 43. Stejně jako předchozí uvedená referenční metoda vychází z korekce požadovaného momentu algoritmu DTC. Z okamžitých otáček, požadovaného momentu motoru a napětí na kondenzátoru je vypočítán podle vzorce (54) ekvivalentní požadovaný odebíraný proud z výstupního LC filtru  $i_z$ . Tento proud společně s okamžitou hodnotou napětí na kondenzátoru LC filtru  $U_c$  a okamžitou hodnotou trolejového napětí  $U_{dc}$  vstupuje do prediktivního regulátoru. Ten na základě těchto hodnot spočítá korigovaný proud  $i_{zw}$ , který je zpětně přepočítán pomocí vzorce (56) na hodnotu korigovaného požadovaného momentu  $T_{corr}$ :

<sup>10</sup> U pohonů s velmi malým momentem setrvačnosti s ohledem k rezonanční frekvenci LC filtru by stabilizace mohla způsobit kmitání rychlosti otáčení rotoru a vést ke zhoršeným výsledkům či až k nestabilnímu chování algoritmu.

$$T_{corr} = U_c \cdot \frac{i_{zw}}{\omega_m} \quad (56)$$

Tato hodnota je poté nová referenční pro regulátor momentu algoritmu DTC.



Obr. 43. Základní schéma stabilizace LC filtru pohonu s PMSM řízeného algoritmem DTC pomocí prediktivního regulátoru (MPC)

Algoritmus MPC vychází ze stavového popisu lineárního systému:

$$x_{(k+1)} = A \cdot x_{(k)} + B \cdot u_{(k)} \quad (57)$$

$$y_{(k+1)} = C \cdot x_{(k+1)} \quad (58)$$

kde  $x_{(k)}$  je vektor okamžitého stavu systému,  $u_{(k)}$  je obecně vektor okamžitého známého vstupu systému,  $x_{(k+1)}$  je stav systému v čase  $k+1$ ,  $y_{(k+1)}$  je vektor výstupních veličin v čase  $k+1$ , matice  $A$  je matice dynamiky systému,  $B$  je vstupní matice systému a  $C$  je výstupní matice systému. Dále provedeme predikci a dosažení pro budoucí stavy a výstupy systému (59).

$$\begin{aligned}
 y_{(k+1)} &= C \cdot x_{(k+1)} = CA \cdot x_{(k)} + CB \cdot u_{(k)} \\
 x_{(k+2)} &= A \cdot x_{(k+1)} + B \cdot u_{(k+1)} = A^2 \cdot x_{(k)} + AB \cdot u_{(k)} + B \cdot u_{(k+1)} \\
 y_{(k+2)} &= C \cdot x_{(k+2)} = CA^2 \cdot x_{(k)} + CAB \cdot u_{(k)} + CB \cdot u_{(k+1)} \\
 x_{(k+3)} &= A \cdot x_{(k+2)} + B \cdot u_{(k+2)} \\
 x_{(k+3)} &= A^3 \cdot x_{(k)} + A^2B \cdot u_{(k)} + AB \cdot u_{(k+1)} + B \cdot u_{(k+2)} \\
 y_{(k+3)} &= C \cdot x_{(k+3)} = CA^3 \cdot x_{(k)} + CA^2B \cdot u_{(k)} + CAB \cdot u_{(k+1)} + CB \cdot u_{(k+2)} \\
 &\dots
 \end{aligned} \tag{59}$$

V rovnicích predikce výstupu systému (59) vidíme dvě části. První část, kterou je násoben počáteční stav, je predikce stavu při nulovém vstupu systému. Druhou část tvoří vliv jednotlivých vstupů na budoucí chování systému. Rovnici predikce lze tedy také rozepsat např. pro predikci o pět kroků:

$$\begin{aligned}
 \begin{bmatrix} y_{(k+1)} \\ y_{(k+2)} \\ y_{(k+3)} \\ y_{(k+4)} \\ y_{(k+5)} \end{bmatrix} &= \begin{bmatrix} CA \\ CA^2 \\ CA^3 \\ CA^4 \\ CA^5 \end{bmatrix} \cdot \begin{bmatrix} x_{(k)} \\ x_{(k)} \\ x_{(k)} \\ x_{(k)} \\ x_{(k)} \end{bmatrix}^T + \begin{bmatrix} CB & 0 & 0 & 0 & 0 \\ CAB & CB & 0 & 0 & 0 \\ CA^2B & CAB & CB & 0 & 0 \\ CA^3B & CA^2B & CAB & CB & 0 \\ CA^4B & CA^3B & CA^2B & CAB & CB \end{bmatrix} \cdot \begin{bmatrix} u_{(k)} \\ u_{(k+1)} \\ u_{(k+2)} \\ u_{(k+3)} \\ u_{(k+4)} \end{bmatrix} \\
 Y &= F \cdot X + G \cdot U
 \end{aligned} \tag{60}$$

Takto vytvořená predikční rovnice má z pohledu MPC horizont řízení i predikce 5 kroků<sup>11</sup>. Dále pro jednoduchost přepíšeme matice do formy:

$$Y = F \cdot X + G \cdot U \tag{61}$$

Protože vektor budoucích výstupů systému je z pohledu řízení vektor požadovaných veličin ( $W$ ) a neznámá je velikost budoucích akčních zásahů, je možné rovnici přepsat do tvaru (62):

$$G \cdot U = W - F \cdot X \tag{62}$$

---

<sup>11</sup> Někdy bývá použit horizont predikce systému delší než horizont řízení, v těchto případech odvodíme matice stejným způsobem, pouze budoucí akční zásahy (které jsou delší než horizont řízení) nahradíme nejčastěji nulami.

A tedy vektor akčních veličin je:

$$U = G_{inv}(W - F \cdot X) \quad (63)$$

kde  $G_{inv}$  je invertovaná matice  $G$ . Matice  $G$  není obecně čtvercová<sup>12</sup>, nebývá také nutné regulovat všechny stavové veličiny systému (nebo některé veličiny je nutné regulovat s větší prioritou) a také je nutné respektovat fyzikální realitu (která samozřejmě neumožňuje neomezeně velké akční zásahy), a proto je možné<sup>13</sup> hledat řešení inverze matice  $G$  pomocí vážených regularizovaných nejmenších čtverců<sup>14</sup>.

Řešením inverze matice  $G$  je tedy rovnice:

$$G_{inv} = (G^T \cdot Q \cdot G + R) \setminus (G^T \cdot Q) \quad (64)$$

,která se řeší většinou QR faktorizací nebo např. pomocí SVD (dekompozicí singulárních hodnot), která nám umožňuje najít optimální redukované řešení nejmenších čtverců. Koeficient  $Q$  je váhová čtvercová matice (většinou diagonální) o velikosti  $Q \in R^{Gv \times Gv}$ , která vyjadřuje prioritu regulace jednotlivých výstupních veličin a  $R \in R^{Gš \times Gš}$  je také čtvercová diagonální regularizační matice určující velikost jednotlivých predikovaných akčních zásahů.  $Gv$  odpovídá výšce matice  $G$  a  $Gš$  odpovídá její šířce.

Pro odvození prediktivního regulátoru pro aktivní tlumení vstupního LC filtru vycházíme z obvodu na Obr. 38 a pro ten sepíšeme stavové rovnice:

---

<sup>12</sup> Protože  $C \cdot B$ ,  $C \cdot A \cdot B$  atd. nebývá čtvercovou submaticí matice  $G$ . Fyzikálně to odpovídá nekonečnému množství různých řešení.

<sup>13</sup> V našem případě bez tvrdých omezení je možné hledat řešení jednoduchou kvadratickou normou a tudíž algoritmem nejmenších čtverců. Pro použití jiných norem či s tvrdými omezeními je většinou nutné použít pro nalezení koeficientů regulátoru některého algoritmu z oblasti dynamického programování, či jiných druhů matematických optimalizací.

<sup>14</sup> Váhováním určujeme, která stavová veličina má z pohledu regulace prioritu a regularizací omezujeme velikost akčních zásahů.

$$x_{(k+1)} = \begin{bmatrix} 1 - \frac{R_L}{L_f} \cdot dT & -\frac{1}{L_f} \cdot dT & \frac{1}{L_f} \cdot dT & 0 & 0 \\ \frac{1}{C_f} \cdot dT & 0 & 0 & -\frac{1}{C_f} \cdot dT & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & -dT & 1 \end{bmatrix} \cdot \begin{bmatrix} i_{L(k)} \\ U_C(k) \\ U_{DC(k)} \\ i_{zcor(k)} \\ \text{int}_{iz(k)} \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \\ 0 \end{bmatrix} di_{zcor(k)} \quad (65)$$

$$x_{(k+1)} = A \cdot x_{(k)} + B \cdot u_{(k)}$$

, kde  $R_L$ ,  $C_f$ , a  $L_f$  jsou parametry vstupního filtru,  $dT$  je vzorkovací perioda prediktivního regulátoru. Stavový vektor je dále nadefinován:  $i_L$  je proud odebíraný LC filtrem z troleje,  $U_C$  je napětí na kondenzátoru LC filtru,  $U_{DC}$  je hodnota trolejového napětí a  $i_{zcor}$  je „skutečný“ tj. korigovaný proud z předcházejícího kroku. Veličina  $\text{int}_{iz}$  se počítá podle vzorce (66):

$$\text{int}_{iz(k+1)} = \text{int}_{iz(k)} + (i_{zw} - i_{zcor(k)}) \cdot dT \quad (66)$$

a vyjadřuje integrační složku prediktivního regulátoru, která odstraňuje trvalou regulační odchylku mezi korigovaným a požadovaným proudem  $i_{zw}^{15}$ , který je vypočten z požadovaného momentu  $T_w$  dle rov. (54).

A nakonec  $di_{zcor}$  je vypočtená akční veličina regulátoru definovaná jako přírůstek korigované veličiny<sup>16</sup>:

$$i_{zcor(k)} = i_{zcor(k-1)} + di_{zcor(k)} \quad (67)$$

Veličina  $i_{zcor}$  je zpětně přepočítána na korigovaný požadovaný moment pro DTC algoritmus podle vzorce (54). Výstupní rovnice stavového modelu je v našem případě jednoduchá:

<sup>15</sup> Stavová veličina  $\text{int}_{iz(k)}$  je požadována nulová a díky ní prediktivní regulátor podobně jako PI odstraňuje trvalou regulační odchylku.

<sup>16</sup> Tedy v rov. (67) je  $i_{zcor}$  výstupní regulovaná veličina, a  $di_{zcor}$  je akční veličina regulátoru. Požadovanou veličinou je pro prediktivní regulátor  $I_{zw}$  (vypočtená z  $T_w$  dle rov. (54)) a je např. zadaná řidičem trakčního vozidla.

$$y_{(k+1)} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} i_{L(k+1)} \\ U_{C(k+1)} \\ U_{DC(k+1)} \\ i_{zcor(k+1)} \\ int_{iz(k+1)} \end{bmatrix} \quad (68)$$

Na základě matic stavového systému je sestavena matice  $G$ . Pro náš případ byl použit stejný horizont řízení i predikce výstupu systému a to o 5 kroků dopředu (tj. matice  $G$  odpovídá uvedené v rov. 60). Vzorkovací frekvence byla s ohledem na požadovanou dynamiku a rezonanční frekvenci LC filtru zvolena  $dT = 1 \text{ ms}^{17}$ . Požadované veličiny prediktivního regulátoru jsou:

$$W = [0, U_{cw}, 0, i_{zw}, 0]^T \quad (69)$$

Proud  $i_L$  (první prvek vektoru) a napětí  $U_{dc}$  (třetí prvek) nejsou regulovanou veličinou a proto mají ve vektoru  $W$  nulové hodnoty (odpovídající váhové koeficienty matice  $Q$  budou také nulové). Napětí na kondenzátoru se snažíme stabilizovat a jeho požadovaná velikost odpovídá přibližně střední hodnotě napětí na kondenzátoru. Další regulovanou veličinou je požadovaný proud  $i_{zw}$  odpovídající dle rov. (56) požadovanému momentu. Posledním prvkem vektoru je nulová požadovaná trvalá regulační odchylka mezi požadovaným a korigovaným proudem  $i_z$  (tj. mezi požadovaným  $T_w$  a korigovaným  $T_{corr}$  momentem). Váhy jednotlivých regulovaných veličin je nutné nalézt experimentálně a vyšší číslo znamená vyšší prioritu regulace dané veličiny. Pro simulační ověření algoritmu byly nalezeny tyto váhové koeficienty:

$$\text{váhové koeficienty} = [0, 150, 0, 100, 500] \quad (70)$$

Váhová matice  $Q$  je v našem případě diagonální a skládá se z jednotlivých váhových koeficientů:

<sup>17</sup> Náš predikční horizont tedy činil 5 ms, které s ohledem na periodu kmitů filtru kolem 30 ms poskytoval dostatečný horizont predikce výstupu pro kvalitní ztlumení kmitů při zachování nízké výpočetní náročnosti algoritmu a vysoké dynamiky pohonu.

$$váhy = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 150 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 100 & 0 \\ 0 & 0 & 0 & 0 & 500 \end{bmatrix} \quad (71)$$

$$Q = \begin{bmatrix} váhy & 0 & 0 & 0 & 0 \\ 0 & váhy & 0 & 0 & 0 \\ 0 & 0 & váhy & 0 & 0 \\ 0 & 0 & 0 & váhy & 0 \\ 0 & 0 & 0 & 0 & váhy \end{bmatrix} \quad (72)$$

kde matice *váhy* je submaticí matice  $Q$ <sup>18</sup>.

Ta má pro horizont řízení 5 kroků a pětičlenného stavového vektoru velikost 25x25 prvků. Regularizační matice<sup>19</sup>  $R$  byla zvolena:

$$R = \begin{bmatrix} 0.4 & 0 & 0 & 0 & 0 \\ 0 & 0.4 & 0 & 0 & 0 \\ 0 & 0 & 0.4 & 0 & 0 \\ 0 & 0 & 0 & 0.4 & 0 \\ 0 & 0 & 0 & 0 & 0.4 \end{bmatrix} \quad (73)$$

a má díky horizontu řízení 5x5 prvků. I tato matice bývá většinou pouze diagonální (se shodným regularizačním koeficientem po celé diagonále).

Po spočtení matice  $G_{inv}$  (dle vzorce 64) je dále použita pouze její první řádka odpovídající prvnímu akčnímu zásahu. Další akční zásahy není třeba počítat, protože v dalším kroku je nový akční zásah spočten na základě nově změřených hodnot. Řízení tedy realizuje funkci:

$$u_{(k+1)} = G_{inv1}(W - F \cdot X_{(k)}) \quad (74)$$


---

<sup>18</sup> Je možné změnou submatic *váhy* matice  $Q$  dosáhnout jinou prioritu regulace v jednotlivých predikčních krocích. V praxi se toto nepoužívá. Také je možné nastavením nediagonálních prvků matice *váhy* dosáhnout změny priority regulace s ohledem na regulační odchylku jiné stavové veličiny.


<sup>19</sup> I v případě regularizační matice  $R$  je možné měnit váhu akčních zásahů v jednotlivých predikčních krocích. Zde ale vyšší číslo odpovídá nižší prioritě.

,kde  $G_{inv1}$  je vektor (první řádka matice  $G$ ) vypočtených koeficientů regulátoru,  $W$  je vektor požadovaných veličin na horizontu predikce regulátoru a  $F \cdot X_k$  je predikovaný výstup při nulovém vstupu systému<sup>20</sup>.

Simulace byla prováděna pro stejný případ jako u referenční metody či nezatlumeného filtru a výsledky lze vidět na Obr. 44 a 45.



Obr. 44. Odezva napětí  $U_c$  na kondenzátoru LC filtru pro požadovanou skokovou změnu odebíraného výkonu z 1 kW na 1,5 kW s aktivním tlumením pomocí MPC



Obr. 45. Ekvivalentní odebíraný proud  $i_z$  z LC filtru pro požadovanou skokovou změnu odebíraného výkonu z 1 kW na 1,5 kW s aktivním tlumením pomocí MPC

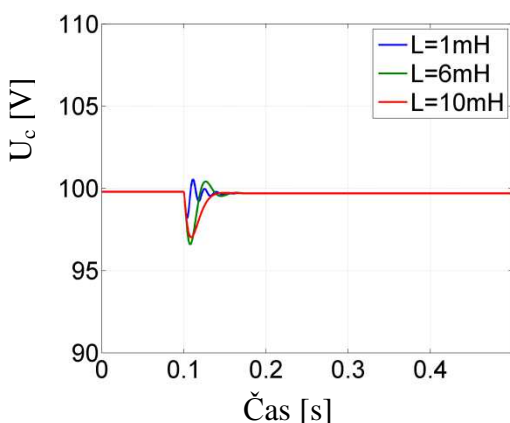
Z obrázků (44, 45) je patrné rychlé zatlumení kmitů napětí na kondenzátoru (oproti referenční metodě Obr. 41, 42) při zachování vysoké dynamiky na požadovanou skokovou změnu výkonu odebíraného z LC filtru.

<sup>20</sup> Predikovaný výstup, při nulovém vstupu systému, je nutné spočítat každý krok a je to výpočetně nejnáročnější část algoritmu. Pro náš případ, se zanedbáním predikce vývoje integrace regul. odchylky  $int_{Iz(k)} \approx int_{Iz(k+5)}$ , se jednalo o 25 násobení a 25 součtů v pevné řádové čárce. Přenásobení predikovaných regulačních odchylek koeficienty regulátoru a spočtení výsledného akčního zásahu obnášelo dalších 13 násobení a 13 součtů. S ohledem na absenci dělení, či jiných problematických výpočtů a vzorkovací periodě regulátoru 1 ms, není problém v realizaci algoritmu na relativně běžném procesoru.




### 3.4 Vliv velikosti vstupní indukčnosti LC filtru

Simulační výsledky na Obr. 46 a 47 ukazují vliv změny indukčnosti vstupního filtru. Tento jev nastává u trakčních vozidel, kdy se vstupní indukčnost LC filtru mění v závislosti na vzdálenosti vozidla od napájecí stanice. Z tohoto důvodu algoritmy stabilizace vstupního filtru musí být dostatečně robustní vůči těmto změnám. Pro účely ověření robustnosti prediktivního regulátoru byl navržen regulátor pro parametry filtru s  $L_f = 6$  mH. Dále byl tento regulátor simulován pro rozdílné parametry vstupní indukčnosti ( $L_f = 1, 6$  a  $10$  mH) pro stejnou požadovanou skokovou změnu výkonu z 1 kW na 1,5 kW v čase 0,1 s jako v předchozích případech.



Obr. 46. Odezva napětí  $U_c$  na kondenzátoru LC filtru pro požadovanou skokovou změnu odebíraného výkonu z 1 kW na 1,5 kW s aktivním tlumením pomocí MPC

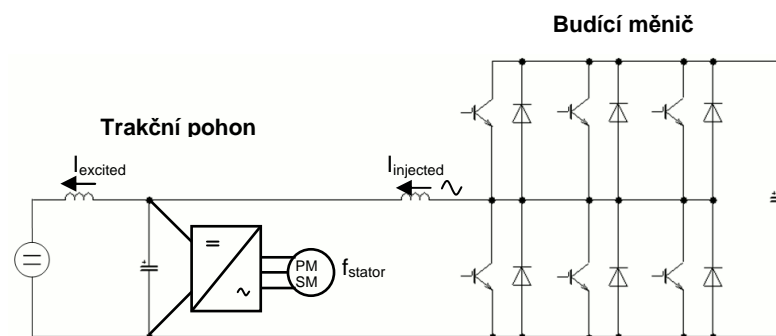


Obr. 47. Ekvivalentní odebíraný proud  $i_z$  z LC filtru pro požadovanou skokovou změnu odebíraného výkonu z 1 kW na 1,5 kW s aktivním tlumením pomocí MPC

Z obrázků je patrné, že regulátor se chová dostatečně robustně v celém zkoumaném rozsahu vstupních indukčností.

### 3.5 Měření frekvenčních charakteristik trakčního pohonu


Frekvenční analýza je důležitou metodou vyšetřování stability elektrických pohonů. Metoda měření frekvenčních charakteristik umožňuje nalézt nebezpečné rezonanční frekvence trakčního pohonu. Použitá metodika vychází z měření frekvenčních charakteristik lineárních systémů a je podrobně popsána v [61]. Základní konfigurace měření je zobrazena na Obr. 48. Během měření je do LC filtru ze strany pohonu injektován proud  $I_{\text{injected}}$  pro frekvence 10 až 40 Hz (aby pokrýval dostatečný rozsah v okolí očekávané rezonanční frekvence LC filtru) a je měřen odebíraný proud  $I_{\text{excited}}$  v místě, kde by byl pohon připojen ke stejnosměrné troleji. Amplitudová frekvenční charakteristika je poté tvořena poměrem amplitudy dané frekvenční složky excitovaného proudu ( $\Delta I_{\text{excited}}$ ) k proudu injektovanému ( $\Delta I_{\text{injected}}$ ). Fázová frekvenční charakteristika vyjadřuje jejich vzájemné fázové posunutí. Tato měření se provádějí pro různé rychlosti otáčení PMSM (frekvence statorových proudů). Pohon s PMSM je při měření mechanicky zatížen asynchronním motorem řízeným na konstantní otáčky z důvodu simulace velkého momentu setrvačnosti trakčního vozidla a je řízen v momentovém módu DTC s požadovaným konstantním momentem.



Obr. 48. Základní schéma měření frekvenčních charakteristik


### 3.6 Experimentální výsledky

Na Obr. 49. lze vidět naměřené typické průběhy rychlostního módu (regulátoru momentu je nadřazena rychlostní regulační smyčka) DTC PMSM při trojúhelníkovém rychlostním profilu. Obr. 50 zobrazuje momentový mód pohonu, kdy je přímo zadávaný požadovaný moment motoru.




Obr. 49. Řízení DTC PMSM v rychlostním módu s reverzací  $f_{rmax}=100\text{Hz}$ .

Kanál1: rotorová rychlost (40 Hz/dílek), Kanál2: fázový proud (10 A/dílek), Kanál3: statorový mag. tok (0,027 Wb/dílek), Kanál4: moment (5 Nm/dílek).



Obr. 50. Řízení DTC PMSM v momentovém módu s pomalou změnou momentu z 5Nm na -5Nm. Kanál1: rotorová rychlost (40 Hz/dílek), Kanál2: fázový proud (10 A/dílek), Kanál3: statorový mag. tok (0,027 Wb/dílek), Kanál4: moment (5 Nm/dílek).

Na Obr. 51. je naměřená amplitudová a fázová frekvenční charakteristika pohonu s aktivně netlumeným LC filtrem pro různé frekvence statorových proudů  $f_{\text{stator}}$  (tj. rychlosti otáčení PMSM) a různé frekvence injektovaných proudů do LC filtru  $f_{\text{injected}}$ . Z obrázku lze velmi dobře vidět rezonanční frekvence LC filtru v okolí 25 Hz a až trojnásobné zesílení injektovaných proudů v okolí rezonanční frekvence.




Obr. 51. Naměřená amplitudová a fázová frekvenční charakteristika pohonu s aktivně netlumeným LC filtrem pro různé frekvence statorových proudů

$f_{\text{stator}}$ . Parametry DTC PMSM :  $T_w=5$  Nm,  $V_{\text{dc}}=200$  V,  $f_{\text{stator}}=0-70$  Hz,


$f_{\text{injected}} = 15-40$  Hz,  $\Delta T=1,0$  Nm,  $\Delta \psi=0,009$  Wb.

Obrázek 52. zobrazuje tlumící schopnosti referenční metody popsané rovnicí (55) a lze vidět lehký útlum rezonanční frekvence zvyšující se s frekvencí statorových proudů  $f_{\text{stator}}$  tj. i výkonem pohonu.



Obr. 52. Naměřená amplitudová a fázová frekvenční charakteristika pohonu s aktivně tlumeným LC filtrem dle rov. (55) pro různé frekvence statorových proudů  $f_{\text{stator}}$ . Parametry DTC PMSM :  $T_w=5$  Nm,  $V_{\text{dc}}=200$  V,  $f_{\text{stator}}=0-70$  Hz,  $f_{\text{injected}} = 15-40$  Hz,  $\Delta T=1,0$  Nm,  $\Delta\psi=0,009$  Wb..


Obrázky 53 a 54 ukazují tlumící schopnosti algoritmu založeného na MPC. Pro výsledky na Obr. 53 byl použit regulátor navržený s diagonálním vektorem matice váhy s koeficienty  $[0,150,0,100,500]$ . Pro Obr. 54. byl druhý koeficient, odpovídající důrazu na regulaci napětí na kondenzátoru LC filtru  $U_c$  diagonálního vektoru matice váhy, zvýšen na 800 tj.  $[0,800,0,100,500]$ . Takto navržený regulátor má vynikající tlumící schopnosti, ale zároveň je více ovlivňován referenční moment DTC PMSM. Tímto způsobem lze jednoduše měnit razanci potlačení kmitů jedním parametrem při návrhu regulátoru. Statorová frekvence  $f_{\text{stator}} = 0$  Hz odpovídá nezatlumenému filtru a se zvyšujícím se výkonem pohonu (tj. zvyšujícím se  $f_{\text{stator}}$ ) dochází k výraznějšímu tlumení kmitů LC filtru ze strany pohonu.



Obr. 53. Naměřená amplitudová a fázová frekvenční charakteristika pohonu s aktivně tlumeným LC filtrem prediktivním regulátorem s nižším důrazem na potlačení kmitů - s diagonálním vektorem matice váhy [0,150,0,100,500].

Parametry DTC PMSM :  $T_w=5$  Nm,  $V_{dc}=200$  V,  $f_{stator}=0-70$  Hz,

$f_{injected} = 15-40$  Hz,  $\Delta T=1,0$  Nm,  $\Delta \psi=0,009$  Wb.



Obr. 54. Naměřená amplitudová a fázová frekvenční charakteristika pohonu s aktivně tlumeným LC filtrem prediktivním regulátorem s vyšším důrazem na potlačení kmitů - s diagonálním vektorem matice váhy [0,800,0,100,500]

Parametry DTC PMSM :  $T_w=5$  Nm,  $V_{dc}=200$  V,  $f_{stator}=0-70$  Hz,

$f_{injected} = 15-40$  Hz,  $\Delta T=1,0$  Nm,  $\Delta \psi=0,009$  Wb.

### **3.7 Dílčí závěry kapitoly**

Kapitola 3 se zabývá prediktivní estimací a aktivní stabilizací kmitů LC filtru trakčního vozidla se synchronním motorem s vnějšími permanentními magnety (PMSM) regulovaného algoritmem přímého řízení momentu (DTC) napájeného ze stejnosměrné troleje. V úvodu kapitoly je popsána problematika stability trakčního vozidla a dále je odvozen prediktivní regulátor ze stavových rovnic lineárního systému. Následuje návrh prediktivního regulátoru jako stabilizátoru kmitů LC filtru a v poslední části jsou uvedeny experimentální výsledky. Z výsledků je patrná velmi kvalitní stabilizace prediktivním řízením a porovnána s nejčastěji používaným algoritmem. Vlastnosti regulátoru a jeho schopnosti potlačit kmity jsou závislé na diagonálním vektoru matice váhy. Jednoduchou změnou parametru tohoto vektoru je možné měnit důraz na potlačení kmitů a tím uzpůsobovat zásahy do požadovaného momentu algoritmu přímého řízení momentu PMSM.

## Kapitola 4

# Estimace základní harmonické pomocí novelizovaného MGP-FIR filtru pro řízení jednofázového paralelního aktivního filtru

### *4.1 Úvod*

Tato kapitola disertační práce se zabývá novelizovaným algoritmem MGP-FIR (Multiplicative General Parameter-Finite Impulse Response filter) filtru a jeho využitím v řízení jednofázového aktivního paralelního filtru. Touto problematikou jsem se zabýval na stáži u Prof. S. J. Ovasky na Helsinské univerzitě technologií. Prof. Ovaska se delší dobou teoreticky zabývá řešením extrakce první harmonické z deformovaného signálu při lehkých frekvenčních fluktuacích základní harmonické. Pro tyto účely vyvinul a publikoval řadu článků o MGP-FIR filtru s  $\pm 1$  koeficienty fixní části filtru [43]. Tato kapitola je motivována představením algoritmu založeným



na reálných koeficientech, které umožňují zkrácení filtru a zlepšení filtračních vlastností. Pro tyto účely bylo nutné použít jinou metodu návrhu filtru založenou na genetických algoritmech či hybridní diferenční evoluci. Předchozí řešení MGP-FIR filtru měla také slabinu v podobě normování a zpětné rekonstrukce signálu, která umožňovala přenos vstupního šumu na výstup filtru a dále do regulace. Proto byl pozměněn algoritmus adaptace signálu, který tento problém odstraňuje.

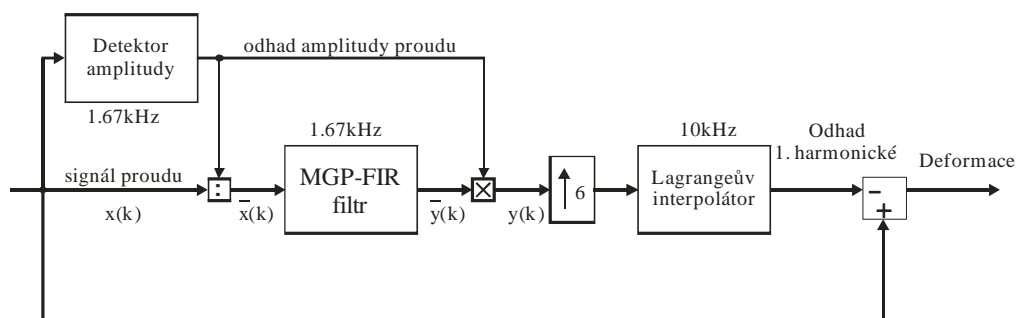
Hlavní výsledky problematiky této kapitoly jsou publikovány na mezinárodních konferencích (základní schéma novelizovaného MGP-FIR [62], návrh koeficientů pomocí genetického algoritmu [63], měření aktivního filtru s MGP-FIR a návrh regulátorů aktivního filtru [64]).

## 4.2 Původní MGP-FIR filtr

Původní verze MGP-FIR filtru pro extrakci základní harmonické byla poprvé představena v [43]. Mezi Hlavní výhody tohoto řešení patří:

- 1) Nízká výpočetní náročnost (pouze 5 násobení a  $N+2$  součtů, kde  $N$  je délka filtru)
- 2) Kvalitní extrakce první harmonické bez fázového zpoždění
- 3) Robustní algoritmus adaptace filtru na frekvenční fluktuace kolem základní harmonické

Dále se výzkum v oblasti MGP-FIR soustředil převážně na zrychlení výpočtu výkonnostní (fitness) funkce či změnu jejího charakteru [65], [44]. Tato funkce determinuje hodnotu fixních koeficientů MGP-FIR. Původní verze filtru je zobrazena na Obr. 55



Obr. 55. Základní schéma estimátoru první harmonické původního MGP-FIR filtru

Kompletní původní estimátor první harmonické je založen na několika jednoduchých algoritmech symbolizovaných graficky jednotlivými bloky. Estimátor amplitudy zajišťuje normalizaci vstupního a zpětnou rekonstrukci výstupního signálu filtru<sup>21</sup>, Lagrangeův interpolátor slouží k interpolaci bodů výstupního sinusového signálu z 1,67 kHz na 10 kHz. Tato rekonstrukce způsobuje zpoždění minimálně jednoho vzorku a je kompenzována predikcí MGP-FIR filtru. Vstupní frekvence 1,67 kHz byla zvolena jako kompromis mezi délkou filtru (tj. i jeho výpočetní náročností) a kvalitou filtrace. Výstupní vzorkovací frekvence je na výstupu navýšena na 10 kHz (Lagrangeovo interpolací) pro dostatečně rychlou odezvu proudových regulátorů a tento odhadnutý výstupní sinusový signál je odečten od vstupního deformovaného signálu. Tímto způsobem je vytvořena zbytková křivka obsahující pouze deformace a šum, která je zavedena do regulátoru proudu a generovaná v opačné polaritě do sítě.

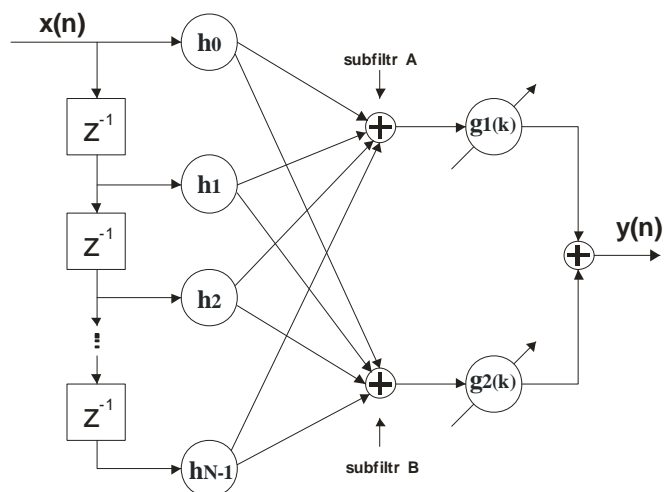
Algoritmus samotného MGP-FIR filtru je uveden na Obr. 56. Skládá se ze dvou FIR filtrů, které spolu sdílejí buffer vstupních hodnot a jejichž výstup je přenásoben adaptivní konstantou  $g$ . Jednotlivé fixní koeficienty  $h$  přísluší vždy buď subfiltru A nebo B. Celkový výstup filtru je pak dán rovnicí (75)

$$y(k) = \overbrace{g_{1(k)} \sum_{n=0}^{N-1} h_A x_{(k-n)}}^{\text{subfiltr A}} + \overbrace{g_{2(k)} \sum_{n=0}^{N-1} h_B x_{(k-n)}}^{\text{subfiltr B}} \quad (75)$$

kde  $h_A$  a  $h_B$  jsou fixní koeficienty subfiltru A a B,  $g_{1(k)}$  a  $g_{2(k)}$  jsou multiplikativní parametry upravující se podle aktuální frekvence základní harmonické.

---

<sup>21</sup> Tato normalizace je nutná z hlediska stability adaptace pomocí Widrow-Hoff LMS algoritmu [1]



Obr. 56. Schéma MGP-FIR filtru se dvěma adaptivními koeficienty

Algoritmus pro predikci o  $p$ -kroků a adaptaci na fluktuace základní harmonické vychází z Widrow-Hoff algoritmu podle vzorce (76,77):


$$g_{1(k+1)} = g_{1(k)} + \mu \overbrace{[x_{(k)} - y_{(k-p)}]}^{\text{chyba predikce}} \sum_{n=0}^{\overbrace{N-1}^{\text{subfiltr A}}} h_A x_{(k-n)} \quad (76)$$

$$g_{2(k+1)} = g_{2(k)} + \mu \overbrace{[x_{(k)} - y_{(k-p)}]}^{\text{chyba predikce}} \sum_{n=0}^{\overbrace{N-1}^{\text{subfiltr B}}} h_B x_{(k-n)} \quad (77)$$

kde  $\mu$  je adaptační konstanta určující rychlost adaptace. Pro zajištění stability adaptace musí být  $\mu < 1$ . Zároveň je stabilita algoritmu závislá na amplitudě vstupního signálu, a proto je nutné jeho normování.

### 4.3 Novelizovaný MGP-FIR filtr

Původní verze MGP-FIR filtru měla slabinu v adaptačním mechanismu. Detektor amplitudy, který byl v původní verzi realizovaný bufferem s plovoucím oknem pro hledání maxima (používal se buffer s plovoucím oknem MGP-FIR filtru), přenášel šum vstupu na výstup filtru (Obr. 57).



Obr. 57. Problematika přenosu šumu původním MGP-FIR filtrem

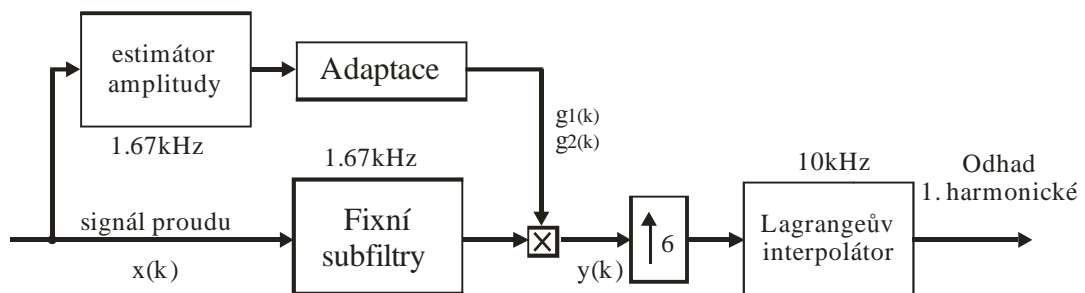
Pro odstranění tohoto efektu byla změněna metoda adaptace multiplikativních parametrů. Metoda normování vstupního signálu byla zaměněna za metodu normalizované adaptace tzv. normalizovaný Widrow-Hoff pravidlo. Adaptace multiplikativních koeficientů probíhá podle vzorce:

$$g_{1(k+1)} = g_{1(k)} + \frac{\mu}{A^2} \overbrace{[x_{(k)} - y_{(k-p)}]}^{\text{chyba predikce}} \sum_{n=0}^{N-1} \overbrace{h_A}_{\text{subfiltr A}} x_{(k-n)} \quad (78)$$

$$g_{2(k+1)} = g_{2(k)} + \frac{\mu}{A^2} \overbrace{[x_{(k)} - y_{(k-p)}]}^{\text{chyba predikce}} \sum_{n=0}^{N-1} \overbrace{h_B}_{\text{subfiltr B}} x_{(k-n)} \quad (79)$$


kde A je odhadnutá amplituda vstupního signálu. Výpočetní náročnost algoritmu zůstává přitom zachována.

Novelizovaná struktura MGP-FIR je ukázána na Obr. 58.



Obr. 58. Novelizovaná struktura MGP-FIR filtru

Nenormovaný signál prochází celým filtrem a je tedy pouze normována adaptační konstanta. Pro otestování novelizovaného MGP-FIR byl použit přechodový děj ukázaný na Obr. 59. Amplituda vstupního signálu byla v čase 1,8 vteřiny (tj. po úvodním ustálení adaptačních konstant) skokově změněna z 1 na 10. Vstupní signál byl nezarušený a čistě sinusový, aby novelizovaný MGP-FIR nebyl zvýhodněn potlačením šumu a bylo možné otestovat pouze dynamické vlastnosti v přechodových dějích. Z obrázku vyplývá, že nová metoda poskytuje rychlejší konvergenci a hladší průběh transientního jevu. Pokus byl činěn na dvou MGP-FIR filtrech délky 40 se shodnými fixními koeficienty. Průměrná chyba byla počítána jako absolutní hodnota chyby mezi vstupním a výstupním signálem filtru podělená amplitudou vstupního signálu a zprůměrovaná přes všechny vzorky okna.



Obr. 59. Test nové struktury MGP-FIR filtru v dynamických změnách. Vlevo novelizovaný MGP-FIR a vpravo původní verze. Zeleně je vstupní signál filtru a modře je jeho výstupní signál (odezva). Nahoře jsou zobrazeny rozdíly (chyby) mezi vstupním a výstupním signálem

Další novelizace MGP-FIR proběhla v jeho části fixních subfiltrů. Původní verze MGP-FIR obsahovala pouze fixní koeficienty o hodnotách  $\pm 1$ . Výhodou tohoto řešení byla hlavně nízká výpočetní náročnost a poměrně jednoduché nalezení koeficientů subfiltrů pomocí technik evolučního programování. Nevýhodou byla nutná větší délka filtru a s tím spojená pomalejší reakce na změny vstupního signálu. Umístění nul filtru bylo

použitím  $\pm 1$  koeficientů samozřejmě limitováno. V novelizované verzi byly použity reálné koeficienty, které umožňují přesnější umístění nul filtru a tím jeho zkrácení. Díky tomu má filtr rychlejší odezvu na změny signálu a rychlejší konvergenci.

Výpočetní náročnost originální struktury MGP-FIR filtru byla:

Detektor amplitudy: 1 dělení a 1 násobení

MGP-FIR: 5 násobení a  $N+2$  součtů; kde  $N$  je délka filtru

Celkově: 6 násobení, 1 dělení a  $N+14$  součtů

Výpočetní náročnost novelizované struktury MGP-FIR filtru byla:

Detektor amplitudy: 1 dělení a 1 násobení

MGP-FIR:  $N+5$  násobení a  $N+2$  součtů; kde  $N$  je délka filtru

Celkově:  $N+6$  násobení, 1 dělení a  $N+14$  součtů

Výpočetní náročnost novelizovaného filtru je samozřejmě vyšší, ale je možné zkrátit filtr na polovinu a zároveň zlepšit filtrační i dynamické vlastnosti (jak bude ukázáno dále). Tím je výpočetní náročnost novelizovaného algoritmu přibližně shodná s původní verzí. Nalezení reálných fixních koeficientů je ale náročnější úloha a bylo třeba vytvořit nový mechanismus hledání založený na genetických algoritmech a diferenční evoluci.

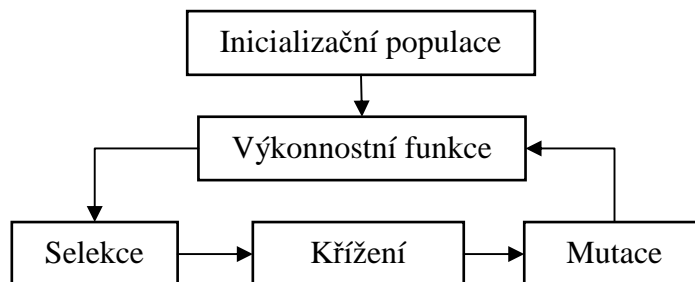
#### ***4.4 Evoluční techniky pro nalezení fixních koeficientů subfiltrů MGP-FIR***

Nalezení fixních koeficientů MGP-FIR je úloha velmi složitá a nelineární (na rozdíl od klasických FIR filtrů). Hlavními důvody jsou adaptace filtru tj. jeho časová proměnnost a rozdělení filtru na dva subfiltry a tedy nutnost nalézt nejen fixní koeficienty, ale také jejich příslušnost k jednotlivým subfiltrům. Pro úlohu nalezení koeficientů původního MGP-FIR s  $\pm 1$  koeficienty Ovaska a Vainio [43] představili jednoduchý a efektivní algoritmus založený na evolučním programování. Toto řešení není ale

výhodné pro reálné koeficienty, a proto byly zvoleny jiné evoluční techniky. První technika je založena na hledání reálných koeficientů v interpretaci pevné řádové čárky. S ohledem na binární reprezentaci koeficientů i jejich příslušností k jednotlivým subfiltrům byla použita optimalizační metoda založená na genetickém algoritmu. Druhá technika vychází z interpretace čísel v plovoucí řádové čárce a binární reprezentaci příslušnosti koeficientů. Pro tyto účely byl rozšířen algoritmus diferenční evoluce hledající fixní koeficienty o binární mutaci jejich příslušnosti.

#### **4.4.1 Genetický algoritmus pro nalezení fixních koeficientů MGP-FIR**

Základní princip genetického algoritmu vychází ze schématu na Obr. 60.



Obr. 60. Základní schéma genetického algoritmu

Na začátku je vytvořena náhodně inicializační populace kandidátských řešení (vektorů). Pro tyto řešení je poté spočtena výkonnostní funkce, která ohodnocuje jednotlivá řešení. Dále je provedena selekce těchto řešení na základě jejich evaluace a kandidáti (zpravidla nejlepší řešení) jsou křížena mezi sebou a mutována pro získání nových kandidátských vektorů. Pro ně je opět spočítána výkonnostní funkce a opět jsou vybrána nová kandidátská řešení. Cyklus se opakuje do té doby, než je buď nalezeno dostatečně kvalitní řešení, nebo vyčerpán maximální počet cyklů.

### Výkonnostní funkce

Výkonnostní funkce, která evaluovala kvalitu filtru se skládala ze dvou kritérií. První kritérium bylo, aby na testovací signál obsahující vyšší harmonické složky a šum, měl výstup filtru a první harmonická vstupního signálu co možná nejmenší rozdíl. Pro tyto účely bylo použito ITAE kritérium.

$$ITAE = \sum_{k=0}^{N-1} k |e_{(k)}| \quad (80)$$

kde  $e_{(k)} = x_F - y_{(k-1)}$  je chyba mezi první (fundamentální) harmonickou vstupního signálu a výstupního signálu zpožděného o jeden krok. Druhým kritériem je tzv. parametr Noise Gain (NG), který je úměrný přenosové funkci subfiltrů MGP-FIR filtru a tedy zároveň i jeho impulzní odezvě (která má být samozřejmě co nejnižší).

$$NG_{(k)} = \sum_{k=0}^{N-1} [g_{1(k)} h_A]^2 + \sum_{k=0}^{N-1} [g_{2(k)} h_B]^2 \quad (81)$$

Celková výkonnostní funkce má tedy multikriteriální tvar:

$$F = \frac{1000}{ITAE \cdot NG_{MAX}} \quad (82)$$

$NG_{MAX}$  je maximální hodnota NG parametru zjištěná během adaptace filtru na testovací signál.

Testovací signál obsahoval celkově 3\*300 tj. 900 vzorků. Každých 300 vzorků odpovídalo jednotlivým prvním harmonickým testovacím sekvencím tj. 49 Hz, 50 Hz a 51 Hz. V tomto frekvenčním rozpětí je předpokládána maximální fluktuace základní harmonické. Každá z těchto vstupních sekvencí obsahovala první harmonickou dané frekvence a byla zarušena typickými deformacemi v energetických sítích tj. vyššími lichými



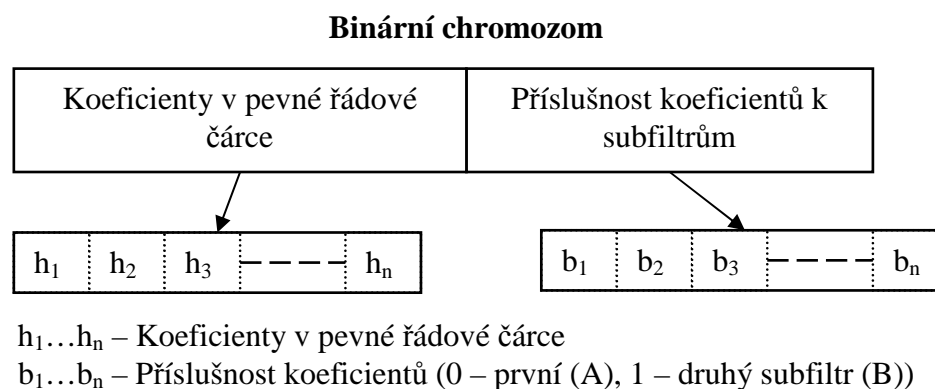
harmonickými a šumem. Vyšší harmonické poté determinovaly polohu nul výsledného filtru a šum byl použit jako prevence přeaproximování (overfitting problém známý z problematiky adaptace umělých neuronových sítí). Vstupní signál měl tedy tvar:

$$x_{(k)} = \sin(\omega_F \cdot k) + \sum_{m \in \{3,5,7,9,11,13,15\}} 0,2 \cdot \sin(m \cdot \omega_F \cdot k) + w_{(k)} \quad (83)$$

,kde  $\omega_F$  koresponduje se třemi základními harmonickými (49 Hz, 50 Hz, 51 Hz) a  $w_{(k)}$  odpovídá okamžité hodnotě bílého gaussovského šumu.

### ***Binární kódování kandidátského vektoru - chromozomu***

Dále je třeba definovat vektor řešení (hledaných parametrů filtru) v binární interpretaci jako kandidátské řešení genetického algoritmu. Tomuto kandidátskému vektoru se říká chromozom a má pro MGP-FIR filtr tvar:



Obr. 61. Binární kódování chromozomu pro filtr délky  $n$


Chromozom (kandidátský vektor) má dvě části. První část obsahuje koeficienty v pevné řádové čáře a druhou část chromozomu tvoří binárně reprezentované příslušnosti koeficientů k jednotlivým subfiltrům (0 znamená, že koeficient přísluší subfiltru A a 1 subfiltru B). Parametr  $n$  odpovídá délce hledaného filtru.

### ***Inicializační populace kandidátských vektorů***

Inicializační populace čítala 300 náhodně vygenerovaných kandidátských vektorů/chromozomů pro navrhované filtry do délky 25. Pro delší filtry byla inicializační populace zvětšena na 500. Obecně lze nalézt doporučení v literatuře [43], že velikost populace by měla čítat přibližně dvojnásobek délky chromozomu. V našem případě filtr délky 20 čítal 20\*16 (pro interpretaci koeficientů v šestnáctibitové pevné řádové čárce) +20 bitů (udávající příslušnost k subfiltrům). Zvyšováním populace samozřejmě výrazně roste výpočetní náročnost algoritmu. Nejnáročnější část na výpočet je paralelní výpočet výkonnostní funkce pro každý kandidátský vektor.

### ***Selekce kandidátských řešení***


Pro selekci jsou zachovány chromozomy a jejich výsledky dané výkonnostní funkcí (v odborné literatuře označované jako rodiče - parents ) a nové chromozomy (označované jako potomci - offspring) vytvořené jejich mutací a křížením a jejich ohodnocení výkonnostní funkcí. Máme tedy dvě populace a v rámci selekce je třeba z nich vytvořit populaci novou a s ní opět provést křížení atd. Selekcí je možné provádět různými způsoby. První metoda spočívá v zachování nejlepších kandidátů z původní a nové populace podle evaluace výkonnostní funkce (Obr. 62. vlevo). Toto řešení má velkou výhodu v rychlosti konvergence k nějakému ustálenému řešení. Problematická je zde poměrně rychlá ztráta diverzity řešení (chromozomů). Druhá metoda diverzitu ztrácí velmi pomalu, ale zároveň také pomaleji konverguje. Metoda spočívá v nahrazení staršího chromozomu novějším, pouze pokud má novější chromozom lepší evaluaci a zároveň vznikl křížením tohoto staršího chromozomu (tj. je jeho přímým potomkem). Nejlepší řešení se nakonec ukázala kombinace obou dvou algoritmů, přičemž je zpočátku použita druhá varianta selekce a ke konci je vybrána selekce výběru nejlepších (Obr. 62. Vpravo, změna selekce nastala po 190 cyklech).



Obr. 62 Porovnání druhů selekce

### ***Křížení a mutace***

Po selekci jsou jednotlivé chromozomy náhodně seřazeny a mezi sebou kříženy (opět s předem definovanou pravděpodobností). Ze dvou původních chromozomů jsou křížením vytvořeny dva nové. Nejlepší výsledky poskytovalo čtyřbodové křížení, které je zobrazené na Obr. 63. Body křížení jsou opět náhodně vybrány.



Obr. 63. 4 bodové křížení chromozomů

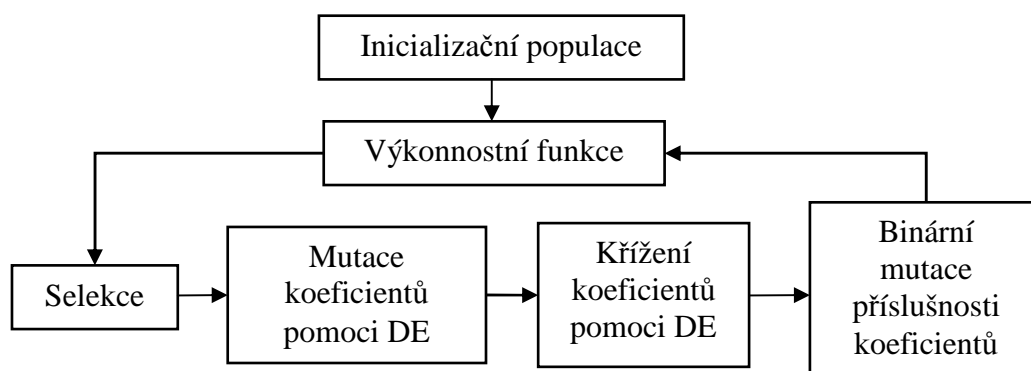
Nakonec je náhodně vybrán jeden bit a s předem definovanou pravděpodobností mutován (tj. logicky negován).

### ***Doporučené nastavení genetického algoritmu***

Pravděpodobnost mutace	=0,7
Pravděpodobnost křížení	=0,7
Počet bodů křížení	= 4
Velikost populace	>300
Počet iterací	>200

#### 4.4.2 Algoritmus diferenční evoluce pro nalezení fixních koeficientů MGP-FIR

Hlavní výhodou diferenční evoluce oproti genetickému algoritmu je v možnosti přirozené optimalizace reálných čísel bez nutnosti převodu do pevné řádové čárky. Tato metoda je opět negradientní, založena na multipopulačním algoritmu a byla poprvé představena v roce 1995 [66]. Základní schéma algoritmu použitého pro nalezení fixních koeficientů MGP-FIR lze vidět na Obr. 64.




Obr. 64 Schéma diferenční evoluce pro nalezení fixních koeficientů rozšířené o binární mutaci příslušnosti k subfiltrům

Algoritmus se skládá ze stejných typů operací představených v kapitole o genetickém algoritmu. Odlišuje se posledním blokem, kde je prováděná binární mutace příslušnosti jednotlivých koeficientů k jednotlivým subfiltrům.

##### *Kandidátský vektor diferenční evoluce*

Kandidátský vektor má stejně jako v případě GA dvě části (Obr. 65). První část tvoří koeficienty reprezentované číslem v plovoucí řádové čárce a druhá část je tvořena binární reprezentací příslušnosti koeficientů k subfiltrům.

### Chromozom diferenční evoluce



$h_1 \dots h_n$  – Koeficienty v plovoucí řádové čáře

$b_1 \dots b_n$  – Příslušnost koeficientů (0 – první (A), 1 – druhý subfiltr (B))

Obr. 65. Kódování chromozomu diferenční evoluce filtru délky  $n$

#### *Inicializační populace kandidátských vektorů*

Reálné koeficienty jsou náhodně generovány v rozpětí -3 až 3. Rozsah koeficientů odpovídá prostoru, v němž je hledáno řešení, tj. kde očekáváme buď optimální řešení výkonnostní funkce, nebo větší množství dostatečně kvalitních řešení. Druhá část kandidátských vektorů je tvořena náhodně vygenerovanými binárními čísly vyjadřujícími příslušnost koeficientů k subfiltrům. Celková velikost populace byla volena přibližně dvojnásobná k délce hledaného filtru.

#### *Selekce kandidátských řešení*

Pro selekci byla použita metoda shodná s představenou dříve u genetického algoritmu v kapitole 4.4.1.

#### *Mutace reálných koeficientů*

Algoritmů mutace existuje celá řada a nejčastější jsou představeny zde [67]. Pro naše účely vykazoval dobré vlastnosti nejjednodušší algoritmus mutace popsán vzorcem:

$$H_{mut} = H_i + F(H_{r1} - H_{r2}) \quad (84)$$

, kde  $H_{mut}$  je zmutovaný vektor koeficientů,  $H_i$  je původní vektor,  $H_{r1}$  a  $H_{r2}$  jsou náhodně vybrané vektory koeficientů a  $F$  je mutační konstanta určující vzdálenost zmutovaného vektoru od původního.

**Křížení reálných koeficientů**

Křížení je u diferenční evoluce doplňková operace k mutaci. Během této operace jsou s určitou pravděpodobností vybrány jednotlivé reálné koeficienty filtru a nahrazeny zmutovanými.

**Mutace příslušnosti koeficientů**

Zde jsou s předem nastavenou pravděpodobností mutovány (tj. negovány) binární koeficienty příslušnosti.

**Doporučené nastavení genetického algoritmu**

Mutační konstanta reálných koeficientů	$F = 0,05 - 0,15$
Pravděpodobnost křížení reálných koeficientů	$= 0,1 - 0,3$
Pravděpodobnost mutace příslušnostního koef.	$= 0,05$
Velikost populace	$> 2 \cdot \text{Délka filtru}$
Počet iterací	$> 2000$

**4.4.3 Statistické zhodnocení optimalizačních algoritmů**

Pro účel statistického zhodnocení a porovnání algoritmů (GA a DE) bylo provedeno 20 cyklů hledání parametrů fixní části filtru. Každý test v případě GA obsahoval 500 iterací. Celkové harmonické zkreslení testovacího signálu uvedeného v kapitole výkonnostní funkce bylo 52%. Výsledky pro různé délky filtrů jsou uvedeny v tabulce 1. Vždy je uvedena střední hodnota výsledků a jejich standardní odchylka.

Tab. 1. Výsledky genetického algoritmu

Délka Filtru	16 $\mu = 0,002$		20 $\mu = 0,0017$		25 $\mu = 0,0015$		30 $\mu = 0,001$		35 $\mu = 0,0007$		40 $\mu = 0,0005$	
	Avg	Dev	Avg	Dev	Avg	Dev	Avg	Dev	Avg	Dev	Avg	Dev
Výkon.fc.	1,42	0,04	2,81	0,11	3,42	0,15	4,03	0,25	4,96	0,22	5,15	0,21
ITAE	4849	216	3225	220	3040	117	3079	94	2727	101	2679	133
NG	0,164	0,003	0,125	0,004	0,111	0,002	0,102	0,002	0,087	0,001	0,082	0,002
THD	4,14	0,22	1,91	0,04	1,91	0,04	1,80	0,12	1,69	0,04	1,64	0,04

Avg = Střední hodnota, Dev = Standardní odchylka

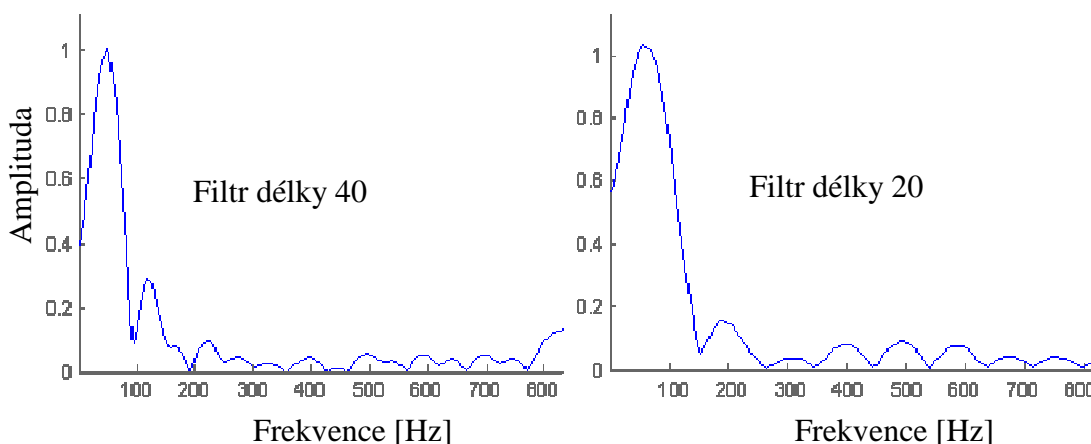
Algoritmus diferenční evoluce byl testován pro 6000 iterací a počet kandidátských vektorů v populaci čítal čtyřnásobek délky filtru. Použitý testovací signál byl shodný s GA.

Tab. 2. Výsledky diferenční evoluce

Délka Filtru	16 $\mu = 0,002$		20 $\mu = 0,0017$		25 $\mu = 0,0015$		30 $\mu = 0,001$		35 $\mu = 0,0007$		40 $\mu = 0,0005$	
	Avg	Dev	Avg	Dev	Avg	Dev	Avg	Dev	Avg	Dev	Avg	Dev
Výkon. fc.	1,59	0,06	2,84	0,05	3,51	0,08	4,12	0,09	5,03	0,11	5,16	0,16
ITAE	4829	299	3210	205	3103	112	3086	91	2684	148	2678	142
NG	0,199	0,003	0,138	0,004	0,128	0,004	0,102	0,002	0,087	0,001	0,082	0,001
THD	3,43	0,18	0,96	0,30	1,10	0,24	0,81	0,19	0,74	0,05	0,71	0,06


Avg = Střední hodnota, Dev = Standardní odchylka

Z tabulky 1 a 2 lze vidět, že výsledky filtrů výkonnostní funkce rostou podle očekávání s délkou filtru. Standardní odchylka výsledků výkonnostní funkce také roste s délkou filtru. Důvodem je větší složitost optimalizačního algoritmu daná větším počtem hledaných parametrů. Při porovnání výpočetní náročnosti algoritmů byla v menší výhodě diferenční evoluce pro kratší filtry. Naopak pro delší filtry např. délky 40 byla výpočetní doba DE přibližně desetinásobná oproti GA. Kvalita nalezených řešení byla lepší u DE a odpovídala vyšší přesnosti koeficientů v plovoucí řádové čárce oproti 16 bitové interpretaci koeficientů u GA. Zároveň se počítalo s implementací v procesoru v pevné řádové čárce, takže pro tyto účely byly výsledky GA dostatečné. Frekvenční charakteristiky dvou nejlepších nalezených filtrů lze vidět na Obr. 66.



Obr. 66. Frekvenční charakteristiky nalezených filtrů

Z frekvenčních charakteristik nalezených filtrů lze vidět dobrý útlum na lichých frekvencích, které obsahoval testovací signál a zároveň celkový útlum na všech vyšších frekvencích, který odpovídá malé odezvě na diracův impuls (daný parametrem NG). Odezva filtrů na amplitudové změny lze vidět na Obr. 67. Podle očekávání má filtr kratší délky rychlejší odezvu.



Obr. 67. Amplitudová odezva nalezených filtrů

Průměrná chyba byla počítána jako absolutní hodnota chyby mezi vstupním a výstupním signálem filtru podělená amplitudou vstupního signálu zprůměrovaná přes všechny vzorky okna.

#### 4.5 Porovnání navržených filtrů

Několik testovacích metod na ověření a porovnání vlastností navržených filtrů lze najít např. [41] a [44]. Tato metoda porovnává pouze kvazistacionární chování filtru (bez přechodového děje) na signál deformovaný typickými lichými harmonickými. Výsledky lze najít v tabulce 3. Všechny porovnávané algoritmy umožňují sledovat lehké fluktuace kolem základní harmonické bez fázového či časového posunu a jsou založeny na adaptivních FIR filtrech.



Tab. 3. Porovnání navržených filtrů

Řád Harmonické	Vstupní signál	Výstupní signál				
		Han et al. (2005)	Komrska et al. (2008)	Filtr délky 40 s +1/-1	Filtr délky 20 s reál. koef.	Filtr délky 40 s reál. koef.
Základní	100	100	100	100	100	100
3rd	-	-	0,51	0,58	0,56	0,60
5th	22,60	0,530	1,57	0,40	0,19	0,37
7th	10,50	0,245	0,19	0,29	0,19	0,16
9th	-	-	0,17	0,20	0,21	0,19
11th	7,30	0,100	0,07	0,32	0,04	0,19
13th	4,70	0,075	0,25	0,18	0,10	0,10
<b>THD</b>	<b>26,40</b>	<b>0,600</b>	<b>1,69</b>	<b>0,87</b>	<b>0,67</b>	<b>0,77</b>

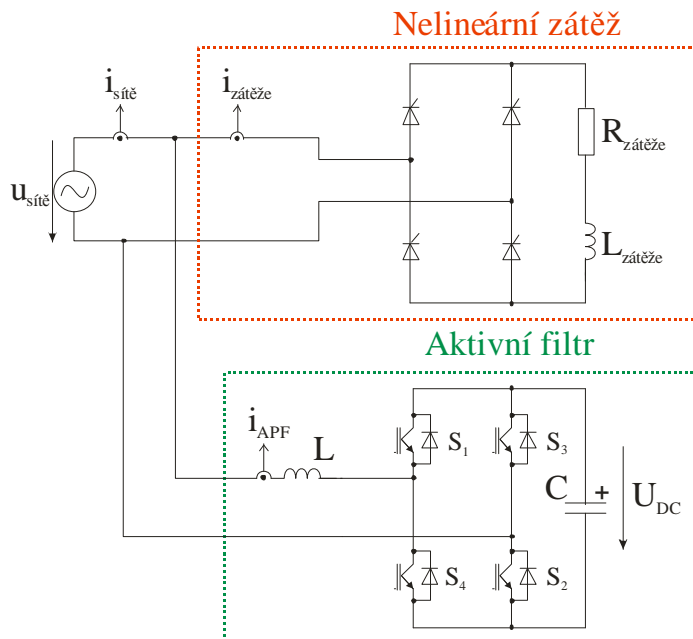
*Třetí a devátá harmonická vznikají vlivem adaptace  $g_1$  a  $g_2$ . (Amplitudovou modulací)*

Algoritmus navržený kolektivem Hana je velmi výpočetně náročný a vyžaduje IIR předfiltraci s následným FIR prediktorem a korektorem útlumu amplitudy. Má nejlepší výsledky, ale na úkor mnohonásobně vyšší výpočetní náročnosti. Druhý algoritmus prezentovaný T. Komrskou [44] je původní verzí MGP-FIR s +1/-1 fixními koeficienty hledanými pomocí algoritmu evolučního programování. Dalším algoritmem je novelizovaný MGP-FIR s +1/-1 koeficienty hledanými pomocí GA a nejlepší nalezené filtry s reálnými koeficienty pomocí DE. Vynikajících výsledků dosahoval hlavně kratší filtr délky 20, který má výborný útlum na charakteristických lichých harmonických. Filtr s reálnými koeficienty délky 40 má celkově lepší útlum v rámci celého frekvenčního spektra, a proto v tomto testu skončil až na třetím místě. U filtru s +1/-1 koeficienty se projevila lepší (ale také zároveň složitější) metoda nalezení fixních koeficientů pomocí GA oproti evolučnímu programování použitým T. Komrskou. Třetí a devátá harmonická se u filtru MGP-FIR objevují vlivem adaptace multiplikačních parametrů.

#### 4.6 Experimentální výsledky MGP-FIR

Pro ověření požadovaných vlastností novelizovaného MGP-FIR filtru byl připraven experiment s jednofázovým aktivním filtrem (jednofázovým napěťovým střídačem) a typickou nelineární zátěží typu jednofázového

tyristorového měniče zatíženého odporovo-induktivní zátěží. MGP-FIR filtr byl použit nejlepší nalezený (diferenční evolucí) délky 20. Algoritmus řízení byl implementovaný v pevné řádové čarce v procesoru firmy Texas Instrument TMS320F2812. Základní schéma experimentu je zobrazena na Obr. 68. a je podrobně popsán v [64].

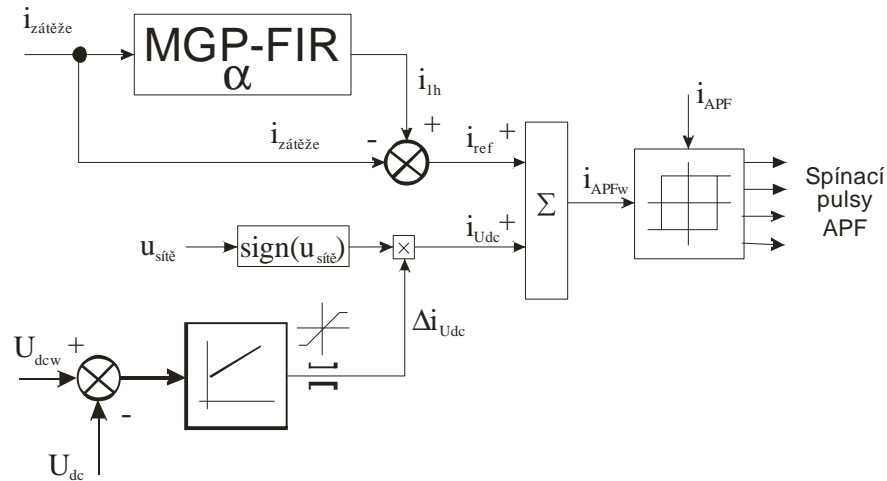


Obr. 68. Základní konfigurace experimentu s jednofázovým paralelním aktivním filtrem a nelineární zátěží tvořenou tyristorovým usměrňovačem

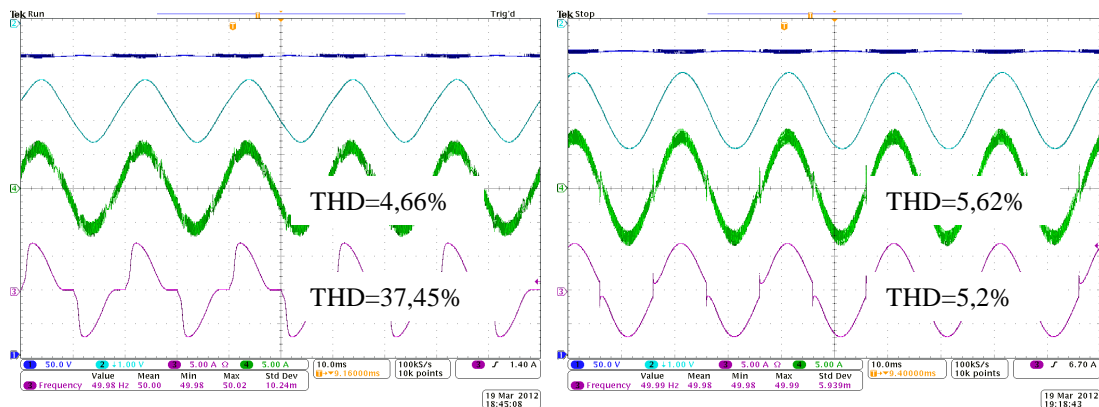
Řídicí schéma lze vidět na Obr. 69. Skládá se z hysterezního regulátoru proudu, jehož referenční (požadovaný) proud je tvořen dvěma složkami. První část je obsahuje pouze deformace odebíraného proudu zátěže získaného pomocí MGP-FIR a druhou část tvoří proud řídicí napětí na kondenzátoru aktivního filtru na požadovanou úroveň přibližně 450 V. Více se problematikou měření a regulace paralelního aktivního filtru zabývá publikace [64].

Na Obr. 70. a 71. lze vidět výsledky měření pro 50 Hz fundamentální harmonickou a různé úhly řízení tyristorového měniče. Obr. 72. a 73 zobrazují spektrální analýzu odebíraného proudu nelineární zátěží (pro případy zobrazené na Obr. 70. a 71.) a celkového odebíraného proudu ze sítě (po kompenzaci aktivním filtrem). Z obrázků vyplývá, že použití aktivního filtru pro redukci THD odebíraného proudu má smysl pouze pro

vice deformované průběhy. U experimentu na Obr. 70. došlo k redukci THD odebíraného proudu z 37,45% na pouhých 4,66%. Naopak u experimentu na Obr. 71. došlo k nárůstu THD po “kompenzaci” z 5,2% na 5,62%. Obr. 74. a 75. (a k tomu spektrální analýzy na Obr. 76., 77.) ukazují schopnosti MGP-FIR filtru při frekvenčních fluktuacích (48 Hz a 52 Hz). Obr. 78. a 79. zobrazují rychlost reakce na transientní děj vyvolaný skokovou změnou zátěže.



Obr. 69. Základní schéma řídicího algoritmu aktivního filtru




Obr. 70. Experimentální výsledky pro  $u_{sítě}=230V/50Hz$ , Tyristorový usměrňovač s ( $\alpha=30^\circ$ ,  $R=45\Omega$ ,  $L=16mH$ ),


- 1  $U_{dc}$  – APF DC napětí [50V/dílek]
- 2  $i_{1h}$  - estimovaná první harmonická
3.  $i_{zátěže}$  – odebíraný proud zátěží [5A/dílek]
4.  $i_{sítě}$  – kompenzovaný proud sítě [5A/dílek]

Obr. 71. Experimentální výsledky pro  $u_{sítě}=230V/50Hz$ , Tyristorový usměrňovač s ( $\alpha=0^\circ$ ,  $R=45\Omega$ ,  $L=34mH$ ),




- 1  $U_{dc}$  – APF DC napětí [50V/dílek]
- 2  $i_{1h}$  - estimovaná první harmonická
3.  $i_{zátěže}$  – odebíraný proud zátěží [5A/dílek]
4.  $i_{sítě}$  – kompenzovaný proud sítě [5A/dílek]



Obr. 72. Spektrální analýza případu na obr. 70. Nahoře analýza odebíraného proudu zátěží ( $i_{zátěže}$ ), dole analýza celkového odebíraného proudu ze sítě ( $i_{sítě}$ )




Obr. 73. Spektrální analýza případu na obr. 71. Nahoře analýza odebíraného proudu zátěží ( $i_{zátěže}$ ), dole analýza celkového odebíraného proudu ze sítě ( $i_{sítě}$ )



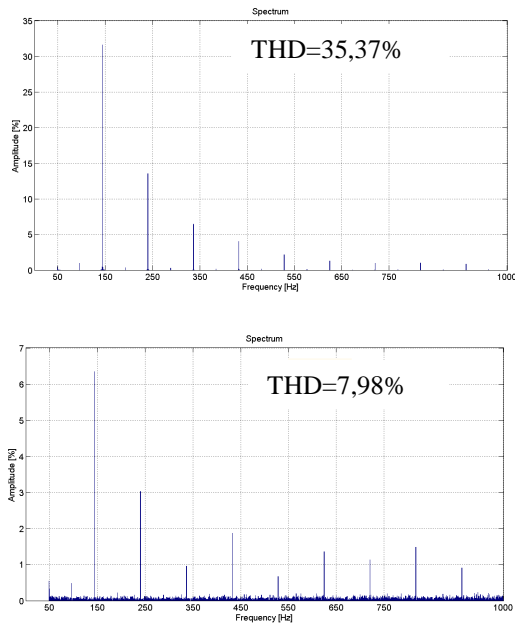
Obr. 74. Experimentální výsledky pro  $u_{sítě}=230V/48Hz$ , Tyristorový usměrňovač s ( $\alpha=30^\circ$ ,  $R=45\Omega$ ,  $L=16mH$ )

- 1  $U_{dc}$  – APF DC napětí [50V/dílek]
- 2  $i_{1h}$  - estimovaná první harmonická
3.  $i_{zátěže}$  – odebíraný proud zátěží [5A/dílek]
4.  $i_{sítě}$  – kompenzovaný proud sítě [5A/dílek]

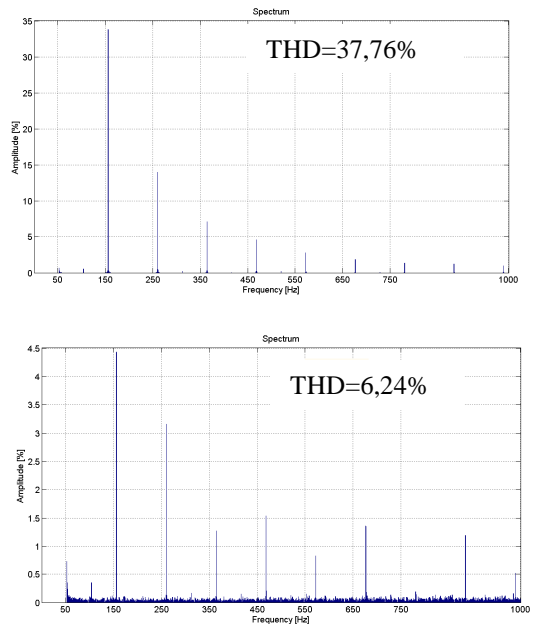


Obr. 75. Experimentální výsledky pro  $u_{sítě}=230V/52Hz$ , Tyristorový usměrňovač s ( $\alpha=30^\circ$ ,  $R=45\Omega$ ,  $L=16mH$ )


- 1  $U_{dc}$  – APF DC napětí [50V/dílek]
- 2  $i_{1h}$  - estimovaná první harmonická
3.  $i_{zátěže}$  – odebíraný proud zátěží [5A/dílek]
4.  $i_{sítě}$  – kompenzovaný proud sítě [5A/dílek]



Obr. 76. Spektrální analýza případu na obr. 74. Nahoře analýza odebíraného proudu zátěží ( $i_{zátěže}$ ), dole analýza celkového odebíraného proudu ze sítě ( $i_{sítě}$ )




Obr. 77. Spektrální analýza případu na obr. 75. Nahoře analýza odebíraného proudu zátěží ( $i_{zátěže}$ ), dole analýza celkového odebíraného proudu ze sítě ( $i_{sítě}$ )



Obr. 78. Skoková změna proudu zátěže ( $i_{zátěže}$ ), pro  $u_{sítě}=230V/50Hz$ , Tyristorový usměrňovač s ( $\alpha=30^\circ$ ,  $L=16mH$ , skoková změna  $R_{zátěže}=65 \Omega$  na  $42 \Omega$ )

- 1  $U_{dc}$  – APF DC napětí [50V/dílek]
- 2  $i_{1h}$  - estimovaná první harmonická
3.  $i_{zátěže}$  – odebíraný proud zátěží [5A/dílek]
4.  $i_{sítě}$  – kompenzovaný proud sítě [5A/dílek]



Obr. 79. Skoková změna proudu zátěže ( $i_{zátěže}$ ), pro  $u_{sítě}=230V/50Hz$ , Tyristorový usměrňovač s ( $\alpha=30^\circ$ ,  $L=16mH$ , skoková změna  $R_{zátěže}=42 \Omega$  na  $65 \Omega$ )

- 1  $U_{dc}$  – APF DC napětí [50V/dílek]
- 2  $i_{1h}$  - estimovaná první harmonická
3.  $i_{zátěže}$  – odebíraný proud zátěží [5A/dílek]
4.  $i_{sítě}$  – kompenzovaný proud sítě [5A/dílek]

#### **4.7 Dílčí závěry kapitoly**

Ve čtvrté kapitole byl představen novelizovaný algoritmus MGP-FIR filtru. Tento typ prediktivního filtru se dvěma multiplikatívními koeficienty se díky adaptaci dokáže přizpůsobovat na lehké frekvenční fluktuace vstupního signálu a díky tomu lépe estimovat základní harmonickou proud. Algoritmus MGP-FIR byl novelizován ve dvou ohledech. První novelizace odstraňuje problém starší verze s přenosem šumu způsobený normováním vstupního signálu. Druhou novelizací je změna  $\pm 1$  koeficientů fixní části filtru za reálné koeficienty, která umožňuje současné zkrácení filtru a zlepšení filtračních vlastností. Tato změna sebou přináší komplikovanější návrh fixní části MGP-FIR a pro tyto účely byly představeny algoritmy založené na genetickém algoritmu a diferenční evoluci. V poslední části kapitoly byly experimentálně ověřeny vlastnosti novelizovaného MGP-FIR filtru na paralelním jednofázovém aktivním filtru a typické nelineární zátěži typu tyristorový usměrňovač pracující do RL zátěže.

# Kapitola 5

## Závěr

Tato disertační práce se zabývá estimací vybraných veličin elektrických pohonů a aktivních filtrů. Práce je členěna do tří hlavních kapitol (2,3,4), které vycházejí z autorových nejvýznamnějších témat, kterými se během studia zabýval a kde představil nějaké originální řešení problému. První část se týká aplikace adaptivních modelů pro zpřesnění estimace polohy dvou typů elektrických pohonů. Prvním byl spínaný reluktanční motor a druhým synchronní motor s vnějšími permanentními magnety. Další kapitola se zabývá stabilizací vstupního LC filtru vozidla lehké trakce prediktivním řízením, které estimuje možné budoucí kmity filtru a aktivně je tlumí změnou požadovaného momentu. Experiment byl prováděn na pohonu se synchroním motorem s permanentními magnety řízeným pomocí algoritmu přímého řízení momentu. Třetí kapitola se zabývá prediktivním MGP-FIR filtrem, který dokáže estimovat základní harmonickou signálu při lehkých frekvenčních fluktuacích bez zpoždění či fázového posuvu. Tento typ filtru je dále použit jako zdroj referenčního signálu pro jednofázový paralelní aktivní filtr

## **5.1 Hlavní přínosy práce**

### **Estimace parametrů elektrických pohonů pro řízení elektrických motorů bez čidla polohy**

V této kapitole je představena problematika řízení dvou typů pohonů bez čidla polohy.

První část se řeší odhad polohy u elektronicky komutovaného spínaného reluktančního motoru. Zde je ukázán možný návrh algoritmu odhadu polohy využívající předem natrénovanou umělou neuronovou síť s adaptivním odhadem statorového odporu. Dále je algoritmus rozšířen o výpočet okamžité přesnosti odhadu polohy a implementován v programovatelném logickém poli FPGA. Výsledky jsou experimentálně ověřeny na laboratorním prototypu.

Druhá část kapitoly se zabývá odhadem polohy u synchronního motoru s permanentními magnety. V této souvislosti je představen poměrně málo známý algoritmus Unscented Kalman Filtru, kterým je poloha rotoru odhadována. Dále je představen algoritmus duální filtrace s online adaptovanou umělou neuronovou sítí, která je adaptivní částí stochastického modelu pohonu. Výsledky této části kapitoly nebylo možné z důvodu vysoké výpočetní náročnosti ověřit experimentálně a proto je zakončena pouze simulacemi.

### **Prediktivní estimace a aktivní tlumení kmitů vstupního LC filtru trakčního vozidla s DTC řízeným PMSM**

V této kapitole je poprvé představen algoritmus stabilizace vstupního LC filtru vozidla lehké trakce napájeného ze stejnosměrné troleje pomocí prediktivního regulátoru. Hlavním přínosem této kapitoly je představení problematiky stability vstupního filtru a porovnání nově navrženého algoritmu s nejčastějším řešením tohoto problému. Jsou zde také uvedeny experimentální výsledky změřené na reálném pohonu se synchroním motorem s permanentními magnety řízeného přímým řízením momentu. Algoritmus má velmi slibné výsledky, je poměrně nenáročný na



implementaci a je tedy velmi slibným z pohledu budoucích reálných aplikací v průmyslu.

### **Estimace základní harmonické pomocí novelizovaného MGP-FIR filtru pro řízení jednofázového paralelního aktivního filtru**

Tato kapitola se zabývá novelizovaným algoritmem MGP-FIR použitelným pro účely synchronizace výkonových měničů s napájecí jednofázovou sítí či např. řízení aktivního jednofázového paralelního filtru. Hlavním přínosem této kapitoly je popis problému dřívější struktury MGP-FIR a jeho vyřešení. Dalším přínosem je představení MGP-FIR filtru s reálnými koeficienty, které umožňují zkrácení filtru a zároveň zlepšení filtračních vlastností při zachování nízké výpočetní náročnosti. Výsledky jsou experimentálně ověřeny na jednofázovém aktivním paralelním filtru.

## **5.2 Perspektivní směry dalšího výzkumu**

Mezi perspektivní oblasti v estimaci patří obecně algoritmy duálního řízení. V rámci duálního řízení je systém řízený tak, aby byly zároveň kvalitně odhadovány estimované veličiny. Tyto typy algoritmů budou mít větší význam např. u odhadování polohy rotoru PMSM motorů s vnitřními povrchovými magnety a spojí tím zatím poměrně samostatné výzkumné oblasti. První využívající stochastických filtračních algoritmů a druhou využívající reluktanční anizotropii motoru. Další perspektivní oblastí může být online stochastické odhadování parametrů pohonů a tím zpřesnění bezsenzorového řízení. Tato problematika je nastíněna v disertační práci v kapitole 2.2, ale řada problémů je stále nevyřešena a snížení výpočetní náročnosti algoritmů může vést k zajímavým reálným aplikacím.

## Literatura

- [1] Ljung, L., *System Identification: Theory for the User*,. Englewood Cliffs, NJ:Prentice-Hall, 1987
- [2] Haykin, S., *Neural Networks: A Comprehensive Foundation*, 2<sup>nd</sup> ed. Englewood Cliffs, NJ: Prentice-Hall, 1999.
- [3] Haykin, S., Ed. *Kalman Filtering and Neural Networks*. Wiley, 2001.
- [4] Simon, D., *Optimal State Estimation*. New York: Wiley, 2006..
- [5] Grewal, M. S., Andrews, A. P., "*Kalman Filtering: Theory and Practice Using Matlab*", John Wiley & sons, Ltd, 2001.
- [6] P. Vas, P., *Artificial Intelligence-Based Electrical Machines and Drives: Applications of Fuzzy, Neural, Fuzzy-Neural and Genetic Algorithm Based Techniques*. New York: Oxford Univ. Press, 1999..
- [7] Miller, T. J. E.: *Electronic Control of Switched Reluctance Machines*. Newnes Power Engineers Series, 2001, ISBN: 7506-50737.
- [8] Michalík M.: *Řízení pohonu se spínaným reluktančním motorem*, Disertační práce, Plzeň: Západočeská univerzita v Plzni, 2009.
- [9] Hrabáč.R.: *Elektrický regulovaný pohon se spínaným reluktančním motorem bez snímače polohy*, Disertační práce, Ostrava: Technická univerzita Ostrava, 2008.
- [10] Mese, E.; Torrey, D., A., "An approach for sensorless position estimation for switched reluctance motors using artificial neural networks," *Power Electronics, IEEE Transactions on* , vol.17, no.1, pp.66-75, Jan 2002.
- [11] Vas, P., *Sensorless Vector and Direct Torque Control*. Oxford University Press, New York, USA, 1998.
- [12] Bolognani, S.; Zigliotto, M.; Zordan, M.: *Extended-Range PMSM Sensorless Speed Drive Based on Stochastic Filtering*. *IEEE Trans. on Power Electronics*, Vol. 16, No. 1, January 2001, pp. 110 – 117
- [13] Peroutka Z., Šmídl V., and D. Vošmik, "*Challenges and Limits of Extended Kalman Filter based Sensorless Control of Permanent Magnet Synchronous Machine Drives*," in *EPE 2009, Barcelona, Spain*, 2009.

- [14] Julier S. J. "*The scaled unscented transformation.*" Feb. 2000.
- [15] Merwe R Vander, Wan E A., *The Square-Root Unscented Kalman Filter for State and Parameter estimation*, International Conference on Acoustics, Speech and Signal Processing, Salt Lake City, UT, 2001
- [16] Nanga Ndjana H. J. and Lautier Ph., "*Sensorless vector control of an IPMSM using unscented Kalman filtering,*" in Proc. of IEEE International Symposium on Ind. Electron. (ISIE 2006), vol. 3, Jul. 2006, 2242–2247.
- [17] Stubberud, S. C., Lobbia R. N., and Owen M., "*An Adaptive Extended Kalman Filter Using Artificial Neural Networks,*" Proceedings of the 34th IEEE Conference on Decision and Control, New Orleans, pp. 1852-1856, Louisiana, December, 1995.
- [18] Ronghui Zhan and Jianwei Wan, "*Neural Network-Aided Adaptive unscented Kalman Filter for nonlinear state estimation.*" IEEE Signal Processing Letters, 1070-9908, 2006, IEEE.
- [19] Zhong, L.; Rahman, M.F.; Hu, W.Y.; Lim, K.W.; , "*Analysis of direct torque control in permanent magnet synchronous motor drives,*" Power Electronics, IEEE Transactions on , vol.12, no.3, pp.528-536, May 1997.
- [20] .Luukko, J.; Pyrhonen, O.; Niemela, M.; Pyrhonen, J.; , "*Limitation of the load angle in a direct-torque-controlled synchronous machine drive,*" Industrial Electronics, IEEE Transactions on , vol.51, no.4, pp. 793- 798, Aug. 2004
- [21] Hill, R., J.: *A Frequency Domain Model for 3kV DC Traction DC-Side Resonance Identification.* IEEE Transactions on Power Systems, Vol. 10. No. 3. August 1995.
- [22] Holtz, J., Klein, H. J.: *The Propagation of Harmonic Currents Generated by Inverter-Fed Locomotives in the Distributed Overhead Supply System.* IEEE Transactions on Power Electronics. VOL. 4. NO. 2, APRIL 1989.
- [23] Winterling, M., W.; Tuinman, E.; Deleroi, W.; "*Attenuation of ripple torques in inverter supplied traction drives,*" Power Electronics and

- Variable Speed Drives, 1998. Seventh International Conference on (Conf. Publ. No. 456) , vol., no., pp.364-369, 21-23 Sep 1998.
- [24] Peroutka, Z.; " *Selected Problems of Modern AC Motor Traction Drives,*" EDPE 2011-Electric Drives and Power Electronics, the 17th Conference on, Slovakia, pp 23-36, Sept. 2011.
- [25] Wiseman, J.C.; Bin Wu; Castle, G.S.P.; "A *PWM current-source rectifier with active damping for high power medium voltage applications,*" Power Electronics Specialists Conference, 2002. pesc 02. 2002 IEEE 33rd Annual , vol.4, no., pp. 1930- 1934, 2002.
- [26] Michalík, J.; Molnár, J.; Peroutka, Z.; , "Active suppression of low-frequency disturbances on AC side of traction active current-source rectifier," IECON 2010 - 36th Annual Conference on IEEE Industrial Electronics Society, vol., no., pp.339-344, 7-10 Nov. 2010.
- [27] Sudhoff, S.D.; Corzine, K.A.; Glover, S.F.; Hegner, H.J.; Robey, H.N., Jr.; "DC link stabilized field oriented control of electric propulsion systems," Energy Conversion, IEEE Transactions on , vol.13, no.1, pp.27-33, Mar 1998.
- [28] Mosskull, H.; Galic, J.; Wahlberg, B.; , "Stabilization of Induction Motor Drives With Poorly Damped Input Filters," Industrial Electronics, IEEE Transactions on , vol.54, no.5, pp.2724-2734, Aug. 2007.
- [29] Camacho, E. F., Bordons, C; , "Model Predictive Control," Springer-Verlag, London 2004. ISBN 1-85233-694-3.
- [30] Gambier, A.; Unbehauen, H.; , "A state-space generalized model-based predictive control for linear multivariable systems and its interrelation with the receding horizon LQG-control," Decision and Control, 1993., Proceedings of the 32nd IEEE Conference on , vol., no., pp.817-822 vol.1, 15-17 Dec 1993.
- [31] Geyer, T.; Beccuti, G.A.; Papafotiou, G.; Morari, M.; "Model Predictive Direct Torque Control of permanent magnet synchronous motors," Energy Conversion Congress and Exposition (ECCE), 2010 IEEE , vol., no., pp.199-206, 12-16 Sept. 2010.
- [32] Glasberger, T.; Janda, M.; Peroutka, Z.; Majorszky, J.; "A new method for AC traction drive frequency characteristic measurement,"

- Power Electronics and Applications (EPE 2011), Proceedings of the 2011-14th European Conference on , vol., no., pp.1-8, Aug. 30 2011-Sept. 1 2011.
- [33] Francesco Lattarulo, "*Electromagnetic Compatibility in Power Systems*", Elsevier, 328 pages, October 2006.
- [34] Das, J.C., "*Passive filters - potentialities and limitations*", IEEE Transactions on Industry Applications, vol. 40, no. 1, pp 232-241, Jan. 2004.
- [35] Grady, W.M.; Samotyj, M.J.; Noyola, A.H., "*Survey of active power line conditioning methodologies*," Power Delivery, IEEE Transactions on , vol.5, no.3, pp.1536-1542, Jul 1990.
- [36] Akagi, H., "*Trends in active power line conditioners*," Industrial Electronics, Control, Instrumentation, and Automation, 1992. Power Electronics and Motion Control., Proceedings of the 1992 International Conference on , vol., no., pp.19-24 vol.1, 9-13 Nov 1992
- [37] Donghua Chen; Shaojun Xie, "*Review of the control strategies applied to active power filters*," *Electric Utility Deregulation, Restructuring and Power Technologies*, 2004. (DRPT 2004). Proceedings of the 2004 IEEE International Conference on , vol.2, no., pp. 666-670 Vol.2, 5-8 April 2004
- [38] Kilic , T., Milun, S., and Petrovic, G., "*Design and Implementation of Predictive Filtering System for Current Reference Generator of Active Power Filters*", International Journal of Electrical Power and Energy Systems, 29, 106–112, 2007.
- [39] Gonzalez, S.A.; Garcia-Retegui, R.; Benedetti, M., "*Harmonic Computation Technique Suitable for Active Power Filters*," Industrial Electronics, IEEE Transactions on , vol.54, no.5, pp.2791-2796, Oct. 2007
- [40] Short, J.A.; Infield, D.G.; Freris, L.L., "*Stabilization of Grid Frequency Through Dynamic Demand Control*," Power Systems, IEEE Transactions on , vol.22, no.3, pp.1284-1293, Aug. 2007
- [41] Han B., M.; Bae B.,; Ovaska, S.J., "*Reference signal generator for active power filters using improved adaptive predictive filter*,"

- Industrial Electronics, IEEE Transactions on , vol.52, no.2, pp. 576-584, April 2005
- [42] R. Chudamani, K. Vasudevan, and C.S. Ramalingam, "Non-linear least-squares-based harmonic estimation algorithm for a shunt active power filter", IET Pwr. Electr. 2, 134 (2009), DOI:10.1049/iet-pel:20080006
- [43] Ovaska, S.J.; Vainio, O., "Evolutionary-programming-based optimization of reduced-rank adaptive filters for reference generation in active power filters," Industrial Electronics, IEEE Transactions on , vol.51, no.4, pp. 910-916, Aug. 2004
- [44] Komrska, T., Žák, J., Ovaska, S., Peroutka, Z., "Computationally Efficient Current Reference Generator for 50-Hz and 16.7-Hz Shunt Active Power Filters," International Journal of Electronics. Vol. 97, No. 1, 2010, pp. 63 – 81.
- [45] Komrska T.: *Sofistikovaná synchronizace a řízení jednofázových měničů s vlastní komutací připojených k síti*, Disertační práce, Plzeň: Západočeská univerzita v Plzni, 2011.
- [46] Talla J., Stehlík, J., "FPGA based neural network position and speed estimator for switched reluctance motor drive," Proceeding CSECS'08 Proceedings of the 7th conference on Circuits, systems, electronics, control and signal processing, Pages 139-144, 2008, ISBN: 978-960-474-035-2
- [47] Fořt, J.: *Pohon se spínaným reluktančním motorem*. Doktorská disertační práce. FEL ZČU. Plzeň, 2003.
- [48] Talla, J.: *Fuzzy regulace spínaného reluktančního motoru*, Diplomová práce, ZČU v Plzni, 2006
- [49] Talla, J., Fořt, J., Michalík, M. *Porovnání regulačních variant proudové smyčky spínaného reluktančního motoru - simulace*. 22160-45-08. vyd. Plzeň : Západočeská univerzita , 2008. 16 s.
- [50] Fořt, J., Michalík, M., Talla, J. *Porovnání regulačních variant proudové smyčky spínaného reluktančního motoru - měření*. 22160-48-08. vyd. Plzeň : Západočeská univerzita , 2008. 22 s.
- [51] Talla, J. *Regulace spínaného reluktančního motoru bez čidla polohy*. Práce ke státní doktorské zkoušce, ZČU v Plzni, 2006.

- [52] Cheok A. D., Zhang, F. "*Fuzzy logic rotor position estimation based switched reluctance motor DSP drive with accuracy enhancement*," IEEE Trans. Power Electron., vol. 20, no. 4, pp. 908–921, Jul. 2005.
- [53] Talla, J. *Adaptivní řízení spínaného reluktančního motoru bez čidla polohy*. In Elektrotechnika a informatika 2008. Část 2, Elektronika. V Plzni: Západočeská univerzita, 2008. s. 121-124. ISBN: 978-80-7043-701-8
- [54] Kalman, R. E. "A New Approach to Linear Filtering and Prediction Problems," TRANS. ASME, Series D, Journal Of Basic Engineering, vol. 82, 1960, pp. 35-45.
- [55] Kitagawa, G. "Monte carlo filter and smoother for non-Gaussian nonlinear state space models". Journal of Computational and Graphical Statistics 5 (1): 1–25. doi:10.2307/1390750, 1996
- [56] Stubberud S. C., Lobbia R. N., and Owen M., "An adaptive extended Kalman filter using artificial neural networks," in Proc. 34th IEEE Conf. Decision Contr., vol. 2, Dec. 1995, pp. 1852–1856.
- [57] Ronghui Zhan and Jianwei Wan, "Neural Network-Aided Adaptive unscented Kalman Filter for nonlinear state estimation." IEEE Signal Processing Letters, 1070-9908, 2006, IEEE.
- [58] Talla, J., Peroutka, Z. *Neural Network Aided Unscented Kalman Filter for Sensorless Control of PMSM*. In EPE 2011 - The 14th European Conference on Power Electronics and Applications. New York: IEEE, 2011. s. 1-9. ISBN: 978-1-61284-167-0
- [59] Ghanbarpour Asl H., and Pourtakdoust S. H., "UD Covariance Factorization for Unscented Kalman Filter using Sequential Measurements Update." World Academy of Science, Engineering and Technology 34 2007
- [60] Glasberger, T., Talla, J., Janda, M., Peroutka, Z., Šmídl, V. *DTC Controlled PMSM Traction Drive Input LC filter Stabilization Using Model Predictive Control*. In EPE PEMC 2012 ECCE Europe - 15th International Power Electronics and Motion Conference and Exposition. New York: IEEE, 2012. s. DS1e.4-1-DS1e.4-7. ISBN: 978-1-4673-1971-3

- [61] Janda, M., Majorszký, J. *Měření frekvenčních charakteristik trakčního pohonu.* In Elektrické pohony. Praha: Česká elektrotechnická společnost, ÚOS Elektrické pohony, 2011. s. 1-5. ISBN: 978-80-02-02308-1
- [62] Talla, J., Peroutka, Z., Ovaska S., J., Blahník, V., *Current Reference Generator for Single-Phase Shunt Active Power Filters Based on MGP-FIR.* Přijato k prezentaci. IECON 2012, Motreal
- [63] Talla, J., Peroutka, Z., Ovaska S., J., Stehlík, J., *Genetic Algorithm Based Optimization of MGP-FIR Current Reference Generator for Active Power Filters.* In 2012 Soft Computing Models in Industrial and Environmental Applications. Ostrava, 2012. s. 429-438. ISBN: 978-3-642-33018-6, ISSN: 2194-5357
- [64] Talla, J., Blahník, V., Peroutka, Z., *Single-Phase Shunt Active Power Filter with Hysteresis Current Control Based on MGP-FIR.* In 2012 International Conference on Applied Electronics. Plzeň: Západočeská univerzita v Plzni, 2012. s. 309-312. ISBN: 978-80-261-0038-6 , ISSN: 1803-7232
- [65] Martikainen, J.; Ovaska, S.J., "*Fitness Function Approximation by Neural Networks in the Optimization of MGP-FIR Filters,*" Adaptive and Learning Systems, 2006 IEEE Mountain Workshop on , vol., no., pp.7-12, 24-26 July 2006
- [66] Storn, R.; Price, K., "*Differential evolution – a simple and efficient adaptive scheme for global optimization over continuous spaces,*" Technical report, ICSI, March 1995
- [67] Storn, R.; Price, K., "*Differential Evolution – A simple evolution strategy for fast optimization,*" Dr. Dobb's Journal, April 97, pp. 18–24 and p. 78.



## Seznam autorových publikací

### Seznam autorových publikací v časopisech

- [A1] Talla, J. *Adaptivní řízení spínaného reluktančního motoru bez čidla polohy*. In *Electroscope* 2008, roč. 2008 ISSN: 1802-4564

### Seznam autorových publikací prezentovaných na mezinárodních konferencích (chronologicky)

- [A2] Talla J., Stehlík, J., " *FPGA based neural network position and speed estimator for switched reluctance motor drive,*" Proceeding CSECS'08 Proceedings of the 7th conference on Circuits, systems, electronics, control and signal processing, Pages 139-144, 2008, ISBN: 978-960-474-035-2
- [A3] Talla, J., Peroutka, Z. *Neural Network Aided Unscented Kalman Filter for Sensorless Control of PMSM*. In *EPE 2011 - The 14th European Conference on Power Electronics and Applications*. New York: IEEE, 2011. s. 1-9. ISBN: 978-1-61284-167-0
- [A4] Janík, D., Peroutka, Z., Talla, J. *Vector position identification method for one phase converter control system*. In *2012 International Conference on Applied Electronics*. Plzeň: Západočeská univerzita v Plzni, 2012. s. 115 - 118. ISBN: 978-80-261-0038-6, ISSN: 1803-7232
- [A5] Glasberger, T., Talla, J., Janda, M., Peroutka, Z., Šmídl, V. *DTC Controlled PMSM Traction Drive Input LC filter Stabilization Using Model Predictive Control*. In *EPE PEMC 2012 ECCE Europe - 15th International Power Electronics and Motion Conference and Exposition*. New York: IEEE, 2012. s. DS1e.4-1-DS1e.4-7. ISBN: 978-1-4673-1971-3

- [A6] Blahník, V., Peroutka, Z., Žák, J., Talla, J. *Elimination of Dead-Time Effect Causing Current Distortion of Single-Phase Power Converters*. In EPE PEMC 2012 ECCE Europe - 15th International Power Electronics and Motion Conference and Exposition. New York: IEEE, 2012. s. DS1e.3-1-DS1e.3-6. ISBN: 978-1-4673-1971-3
- [A7] Blahník, V., Peroutka, Z., Talla, J. *Control of Primary H-bridge Cascade Multilevel Converter for New Generation of Locomotive*. In 2012 International Conference on Applied Electronics. Plzeň: Západočeská univerzita v Plzni, 2012. s. 29-32. ISBN: 978-80-261-0038-6 , ISSN: 1803-7232
- [A8] Talla, J., Blahník, V., Peroutka, Z., *Single-Phase Shunt Active Power Filter with Hysteresis Current Control Based on MGP-FIR*. In 2012 International Conference on Applied Electronics. Plzeň: Západočeská univerzita v Plzni, 2012. s. 309-312. ISBN: 978-80-261-0038-6, ISSN: 1803-7232
- [A9] Talla, J., Peroutka, Z., Ovaska S., J., Stehlík, J., *Genetic Algorithm Based Optimization of MGP-FIR Current Reference Generator for Active Power Filters*. In 2012 Soft Computing Models in Industrial and Environmental Applications. Ostrava, 2012. s. 429-438. ISBN: 978-3-642-33018-6, ISSN: 2194-5357
- [A10] Talla, J., Peroutka, Z., Ovaska S., J., Blahník, V., *Current Reference Generator for Single-Phase Shunt Active Power Filters Based on MGP-FIR*. Přijato k prezentaci. IECON 2012, Motreal

### **Seznam autorových publikací prezentovaných na českých konferencích (chronologicky)**

- [A11] Cédl, M., Řeháček, J., Talla, J. *Laboratoř vzdáleného řízení pro výuku elektrických pohonů*. In Elektrické pohony. Plzeň: Česká elektrotechnická společnost, 2007. s. 1-6. ISBN: 978-80-02-01921-3
- [A12] Michalík, M., Talla, J. *Regulace spínaného reluktančního motoru*. In Elektrické pohony. Plzeň: Česká elektrotechnická společnost, 2007. s. 1-7. ISBN: 978-80-02-01921-3

- [A13] Cédli, M., Řeháček, J., Talla, J. *Mechatronické systémy pro podporu výuky*. In Liberecké elektrické pohony. Liberec: Technická univerzita, 2007. s. 123-127. ISBN: 978-80-7372-272-2
- [A14] Talla, J., Michalík, M. *Model-based design implementace neuronového regulátoru spínaného reluktančního motoru*. In Elektrotechnika a informatika 2007. Část 2., Elektronika. V Plzni: Západočeská univerzita, 2007. s. 117-120. ISBN: 978-80-7043-571-7
- [A15] Talla, J. *Adaptivní řízení spínaného reluktančního motoru bez čidla polohy*. In Elektrotechnika a informatika 2008. Část 2., Elektronika. V Plzni: Západočeská univerzita, 2008. s. 121-124. ISBN: 978-80-7043-701-8
- [A16] Talla, J. *Estimace polohy rotoru spínaného reluktančního motoru*. In Elektrické pohony. Praha: Český svaz vědeckotechnických společností, 2009. s. 1-9. ISBN: 978-80-02-02151-3
- [A17] Talla, J. *Control algorithm for one phase shunt-type active power filters based on revised MGP-FIR filter*. In Elektrické pohony. Praha: Česká elektrotechnická společnost, ÚOS Elektrické pohony, 2011. s. 1-14. ISBN: 978-80-02-02308-1

### **Seznam autorových výzkumných zpráv (chronologicky)**

- [A18] Blahník, V., Cédli, M., Sutnar, Z., Talla, J., *Měření parametrů třívinutového středofrekvenčního transformátoru TR1C 50-65*. Plzeň, 2008.
- [A19] Blahník, V., Cédli, M., Sutnar, Z., Talla, J., *Měření parametrů pětivínutového středofrekvenčního transformátoru TR1C 60-70*. Plzeň, 2008.
- [A20] Talla, J., Fořt, J., Michalík, M. *Porovnání regulačních variant proudové smyčky spínaného reluktančního motoru - simulace*. 22160-45-08. vyd. Plzeň: Západočeská univerzita, 2008. 16 s.
- [A21] Fořt, J., Michalík, M., Talla, J. *Porovnání regulačních variant proudové smyčky spínaného reluktančního motoru - měření*. 22160-48-08. vyd. Plzeň: Západočeská univerzita, 2008. 22 s.

## Seznam autorových funkčních vzorků

- [A22] Blahník, V., Talla, J. *Číslicový MGP-FIR filtr umožňující odhad první harmonické zkresleného signálu*. 2012.
- [A23] Blahník, v., Talla, J. *Zapojení regulátorů činného a jakového proudu vycházející z vektorového řízení napěťového pulzního usměřovače*. 2012.
- [A24] Blahník, V., Talla, J. *Hysterezní regulátory proudu pro aktivní filtr*. 2012.
- [A25] Blahník, V., Talla, J. *Řízený jednofázový střídač s aktivní eliminací mrtvých časů*. 2012.
- [A26] Blahník, V., Talla, J. *Aktivní filtr pro jednofázovou nelineární zátěž*. 2012.