

INTER TURN SHORT-CIRCUIT DETECTION IN VECTOR CONTROLLED PMS MOTOR USING AI

Lukáš Zezula

Bachelor Degree Programme (3), FEEC BUT

E-mail: xzezul06@stud.feec.vutbr.cz

Supervised by: Petr Blaha

E-mail: blahap@feec.vutbr.cz

Abstract: This paper deals with the diagnostics of inter turn faults in a vector controlled synchronous motor with permanent magnets. Inter turn faults are detected by a convolution neural network from adequately preprocessed current signals of the stator phases. The goal is to create a model within which different severity of inter turn faults will be simulated. Data from the simulations are preprocessed and transformed using Wavelet transform and the resulting scalograms are fed to a pre-trained convolution neural network GoogLeNet. This neural network's diagnostic capabilities are tested on a physical drive, capable of emulating faults.

Keywords: PMSM, ITF, Inter turn fault, Inter turn short-circuit, Vector control, Convolutional neural network, Motor fault diagnostics

1 ÚVOD

V několika posledních letech se výrazně rozšiřují aplikace synchronních motorů, především potom motorů s permanentními magnety (PMSM – permanent magnet synchronous machine). Tyto se staly standardní pohonnou jednotkou v průmyslových servopohonech a v současné době se jejich uplatnění rychle rozšiřuje i v oblasti dopravní techniky. Mezi jejich výhody patří menší objem, hmotnost a moment setrvačnosti. Dále potom vysoká momentová přetížitelnost a účinnost.

Mezizávitové zkraty (ITF – Inter turn faults) se vyskytují v důsledku porušení izolace na statorovém vinutí. Jedná se o jednu z nejvíce se vyskytujících poruch na elektrických motorech vůbec. Včasná diagnostika těchto zkratů je klíčová zejména proto, že včas nepodchycený mezizávitový zkrat může vyústit až ve vznícení motoru.

V rámci této práce je realizován model PMSM schopný simulovat ITF. Tento model je následně vektorově řízen a jsou simulovány průběhy fázových proudů pro různé závažnosti zkratu. Simulované proudy jsou zakódovány do jednoho signálu, na který je aplikována Vlnková transformace. Vzniklý set škálogramů je použit pro syntézu obrázků, na které je učena předučená konvoluční neuronová síť (CNN - convolution neural network) GoogLeNet. Řídicí algoritmus je následně implementován do reálného pohonu, který je schopný emulovat poruchy. Naměřená data jsou předzpracována obdobným způsobem a použita pro validaci neuronové sítě.

2 SIMULACE MEZIZÁVITOVÝCH ZKRATŮ

Pro simulaci ITF se ukazuje být nejpřesnější použití modelů motoru vytvořených pomocí metody konečných prvků. Tato práce však používá výsledky simulace pro učení CNN. Je tedy klíčové, aby byl použitý model univerzální pro více druhů PMSM i za cenu menší přesnosti. Tento fakt znemožňuje použití metody konečných prvků, která využívá přesnou geometrii daného motoru. Jedním ze základních požadavků potom je, aby parametry skutečného motoru, které jsou předány modelu, byly měřitelné nebo dohledatelné v jeho výrobní dokumentaci. Z tohoto důvodu byl použit matematický model PMSM. Běžné matematické popisy však nezahrnují fakt, že na reálném motoru


se fázové vinutí skládá z několika sériově/paralelně řazených cívek, což je pro správnou simulaci ITF klíčové. Tuto problematiku popsal Gu [1] a do modelu PMSM zahrnul počet cívek na jedné fázi a parametr γ , který kvantifikuje magnetické vazby mezi cívkami na jednom vinutí a lze jej vypočítat z naměřených indukčností. V této práci je použita *abc* varianta modelu převzatého z [1], protože diagnostika probíhá na základě fázových proudů.

Pro realizaci pohonu bylo použito vektorové řízení s *d* složkou řízenou do nuly tak, jak jej popisuje Sul [2]. Momentové řízení bylo rozšířeno o PI regulátor otáček s akčním zásahem proudu *q* složkou. Do celkového modelu byly doplněny Clarkovy a Parkovy transformace a model měniče s pulzně šířkovou modulací prostorovým vektorem.

Obecně jsou potom průběhy fázových proudů závislé na závažnosti zkratu *u* (*u* udává poměr zkratovaných závitů ku celkovému počtu závitů), odporu zkratu R_f , elektrické úhlové rychlosti ω_e a zátěžném momentu působícím na hřídeli T_{load} . V našem případě se jedna fáze skládá ze tří sériově řazených cívek a při $u=1$ je zkratována jedna z cívek tudíž 1/3 vinutí. S rostoucím momentem zátěže obecně roste amplituda fázových proudů, ale při ITF dochází rovněž ke změně rozvážení. Toto se později ukáže být klíčovou překážkou při diagnostice hloubky zkratu.

U neřízeného motoru ITF způsobí pouze nárůst proudu danou fází. Při řízení motoru s ITF vzniká závislost na parametrech a architektuře regulátorů, zejména potom na zesílení regulátorů proudu. Pro velká zesílení jsou mezizávitové zkraty na průbězích proudu okem dobře pozorovatelné, ale dochází k jejich nelineárnímu zkreslení. Naproti tomu při malých zesíleních je rozvážení způsobené regulátory proudu méně znatelné (zejména při malých rychlostech otáčení, kdy se průběhy proudů shodují se zdravým motorem) a průběhy nejsou zkresleny. Problémem při velkém zesílení regulátorů proudu je potom fakt, že regulační smyčka sklouzne k nestabilitě při ITF na znatelně menších závažnostech zkratu, proto v této práci uvažujeme menší zesílení (takové, aby byla odezva *d* a *q* složky proudu na skok žádané hodnoty při zabrzděném motoru bez překmitu).

Srovnání výsledků simulace s průběhy změřenými na reálném pohonu lze pro jeden konkrétní stav vidět na Obrázku 1.



Obrázek 1: Srovnání naměřených dat (plně) a simulace (čárkovaně) pro stav: $\omega_e = 1600$ rad/s; $u = 14/25$; $R_f = 0.04 \cdot R_s$; $T_{load} = 0.5$ Nm

Z Obrázku 1 je znatelný fázový posuv mezi simulací a měřenými daty. Ten je způsoben neshodou vzorkování v simulaci a na reálném pohonu. Rozdíl v amplitudách je způsoben odchylkou koeficientů tření v modelu od skutečných hodnot. Z obrázku je zřejmé, že rozvážení proudů v simulaci je shodné s rozvážením naměřeném na skutečném motoru. Odpor zkratu, pro který má smysl zkoumat průběhy proudů, je vztažen k odporu vinutí R_s . Pro zjednodušení diagnostiky bude v této práci uvažováno, že $R_f \ll R_s$. Veškerý proud tedy teče pouze zkratem.

3 PŘEDZPRACOVÁNÍ SIGNÁLŮ

Cílem předzpracování signálů je syntetizovat obrazovou informaci, která bude předána předučené CNN GoogLeNet. Syntéza tohoto obrázku bude probíhat na základě R, G a B složky. Tyto budou vytvořeny pomocí transformací signálů proudu a elektrické úhlové rychlosti.

Nejprve jsou změřeny průběhy proudů pro 5 elektrických otáček motoru. Toto odpovídá 5 periodám fázových proudů. Pro stanovení 5 elektrických otáček je použit přepočít z mechanického úhlu natočení (zjištěn například enkodérem) a počtu pólových dvojic. Následně jsou data transformována do jednoho signálu pomocí rovnice (1). Uvažujeme vzorkování signálu, kde k udává číslo vzorku.

$$I_{max}(k) = \max(I_a(k), I_b(k), I_c(k)) \quad (1)$$

Takto vzniklý signál je potom normalizovaný mezi hodnoty 0 (která odpovídá minimu) a 1 (která odpovídá maximu) tak, jak popisuje rovnice (2).

$$I_{max_norm}(k) = \frac{I_{max}(k) - \min(I_{max})}{\max(I_{max}) - \min(I_{max})} \quad (2)$$

Následně je aplikována spojitá Vlnková transformace. Jako mateřská vlnka je použita Morletova vlnka na škálách od 1 do 50. Vlastní výpočet transformace a tvar mateřské a otcovské vlnky popisuje Merry [3]. Výstupem této transformace je matice koeficientů C_{wt} , v níž řádky odpovídají jednotlivým škálám a sloupce vzorkům. Při použití Vlnkové transformace na diskrétní signál nastává problém s koeficienty odpovídající začátku a konci signálu, které jsou značně zkresleny vlivem ohraničení signálu. Z tohoto důvodu jsou z matice C_{wt} odstraněny sloupce náležící první a páté periodě průběhu proudů. Tímto vzniká nová matice C_{wt_filt} , která odpovídá třem periodám proudových signálů a nefiguruje v ní zkreslení. Z matice C_{wt_filt} je potom vytvořena B složka obrázku pomocí rovnice (3).


$$B = \text{round}\left(\frac{|C_{wt_filt}| - \min(|C_{wt_filt}|)}{\max(|C_{wt_filt}|) - \min(|C_{wt_filt}|)} \cdot 255\right) \quad (3)$$

Tímto je vytvořena B složka odpovídající původnímu škálogramu, ale s hodnotami koeficientů 0 až 255.

Aby bylo možné správně diagnostikovat závažnost zkratu, musí být kvantifikován vliv elektrické úhlové rychlosti. Tato bude předána do obrázku jako R složka, která je matice s rozměry odvozenými od B složky a konstantní hodnotou koeficientů rovnou R_{coef} . Ve zkoumaném případě je uvažován rozsah elektrických úhlových rychlostí 50-1700 rad/s. Elektrickou úhlovou rychlost lze stanovit přepočtem z mechanické úhlové rychlosti přes počet pólových dvojic. Koeficient R_{coef} se potom z ω_e vypočte dle rovnice (4).

$$R_{coef} = \text{round}\left(\left|\frac{\omega_e}{10}\right|\right) \quad (4)$$

Rozměry G složky jsou opět odvozeny od B složky a koeficienty matice jsou voleny 0. Ukázku vzniklých obrázků pro CNN lze vidět na Obrázku 2.



Obrázek 2: Obrázek pro zdravý průběh (vlevo) a pro ITF 12/25 (vpravo) při $\omega_e = 1450$ rad/s

4 UČENÍ KONVOLUČNÍ NEURONOVÉ SÍTĚ GOOGLNET

Pro diagnostiku byla použita předučená CNN GoogLeNet. Více o tom, co je GoogLeNet a jak vypadá architektura této sítě popisuje Szegedy v [4]. V rámci této práce byla v síti modifikována klasifikační vrstva a poslední výstupní vrstva. Tyto byly nahrazeny novými “čistými” vrstvami. Síť byla učena na průběhy získané ze simulace pro 3 hodnoty zátěžného momentu, elektrické úhlové rychlosti od 50 do 1700 rad/s s krokem 50 rad/s a závažnosti zkratu 0 až 25/25 s krokem 2/25. Pro získání většího kvanta dat bylo vytvořeno 10 průběhů pro každý stav a tyto byly uměle zašuměny bílým šumem s poměrem signál-šum 40 dB.

Síť byla učena algoritmem Back-propagation (neboli pomocí zpětného šíření chyby a následnou úpravou vah) s koeficientem učení 0.0001.

V prvním kole byla síť učena pouze na dva stavy: “Healthy“ udávající, že na motoru zkrat není a “ITF“ udávající, že na motoru zkrat je. Síť se byla schopna naučit s přesností diagnóz 91.32 %. Při validaci na datech z reálného pohonu se dosahovalo přesnosti 85 %. Toto relativně malé číslo je způsobeno tím, že průběhy proudů motoru s ITF se na nízkých elektrických úhlových rychlostech shodují s průběhy proudů zdravého motoru. V druhém kole byla síť učena detekovat závažnost zkratu. Přesnost diagnóz obecně nepřekročila 30 %. Toto velmi neuspokojivé číslo zaobaluje kromě již zmíněného problému také to, že rozvážení proudů se mění se zátěžným momentem. Existují tedy případy, kdy se shodují škálogramy dvou a více závažností zkratu pro různé momenty zátěže.

5 ZÁVĚR

Byl realizován model pro simulaci ITF. Obecně model velice dobře aproximuje realitu na vysokých otáčkách, kde je chyba rozvážení menší než 2 %. Jakmile je model použit na nízkých elektrických otáčkách (okolo 200-400 rad/s), chyba se zvyšuje, ale nepřekročí 10 %. Při předzpracování signálu je obecným problémem proměnlivost balíku dat v závislosti na rychlosti otáčení (při konstantní periodě vzorkování). Na vyšších rychlostech je balík dat příliš malý, což může mít za následek nekvalitní zpracování škálogramů. Při diagnostice zkratu bylo dosaženo přesnosti 85 %. Problémem je diagnostika na nízkých rychlostech, kde však daná porucha nepředstavuje prakticky žádné nebezpečí. Zlepšení diagnostiky lze dosáhnout vhodnou volbou rozsahu rychlostí. Při diagnostice hloubky zkratu nelze vycházet pouze z průběhů fázových proudů. V další fázi projektu budou do diagnostiky přidány i vhodně zpracované průběhy napětí na měniči jako G složka. Zátěžný moment potom bude znatelný z fázového posunu mezi proudem a napětím. Toto rovněž zlepší diagnostiku na nízkých otáčkách, kdy jsou ITF dobře viditelné právě na průbězích napětí na měniči.

REFERENCE

- [1] GU, B. G. Study of IPMSM Interturn Faults Part I: Development and Analysis of Models With Series and Parallel Winding Connections. *IEEE Transactions on Power Electronics*. 2016, **31**(8), 5931-5943. DOI: 10.1109/TPEL.2015.2496142. ISSN 0885-8993.
- [2] SUL, S. K. Control of electric machine drive system. Hoboken, N.J.: Wiley-IEEE Press, 2011. ISBN 978-0-470-59079-9. str. 230-235
- [3] MERRY, R. J. E. *Wavelet Theory and Applications A literature study* [online]. Eindhoven: Technische Universiteit Eindhoven, 2005 [cit. 2020-01-02]. DCT rapporten; Vol. 2005.053. Dostupné z: https://pdfs.semanticscholar.org/3311/243114e97eab6f35bea8c592ab8926a16009.pdf?_ga=2.70874768.121153195.1577962293-1411173960.1577700393
- [4] SZEGEDY, C., W. LIU, Y. JIA, et al. Going deeper with convolutions. In: *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2015, 2015, s. 1-9. DOI: 10.1109/CVPR.2015.7298594. ISBN 978-1-4673-6964-0.