

Ing. David Vošmik, prof. Ing. Zdeněk Peroutka, Ph.D., doc. Ing. Václav Šmídl, Ph.D.

Hybridní estimátor s bayesovským výběrem optimálního modelu a jeho aplikace pro bezsenzorové řízení PMSM

Technická zpráva

Pracovní balíček:

11 – Elektrické části pohonů

Rok řešení:

2013



**FAKULTA
ELEKTROTECHNICKÁ**
ZÁPADOČESKÉ
UNIVERZITY
V PLZNI

2013

Pracoviště: Regionální inovační centrum elektrotechniky,
Fakulta elektrotechnická

Výzkumná zpráva č.: 22190 - 051 - 2013

Hybridní estimátor s bayesovským výběrem optimálního modelu a jeho aplikace pro bez-senzorové řízení PMSM

Druh úkolu: vědecko-výzkumný
Řešitelé: Ing. David Vošmik,
prof. Ing. Zdeněk Peroutka, Ph.D.,
doc. Ing. Václav Šmídl, Ph.D.
Vedoucí úkolu: prof. Ing. Zdeněk Peroutka, Ph.D.
Počet stran: 24
Datum: Listopad 2013
Revize: 1

Tato práce vznikla s podporou projektu TE01020038 „Centrum kompetence drážních vozidel“.

Anotace

Výzkumná zpráva se zabývá algoritmem výběru statisticky optimálního modelu pro bezsenzorové řízení PMSM. Hlavní myšlenkou je přepínat mezi modely na základě srovnání, který z algoritmů poskytuje v daný moment kvalitativně lepší výsledky estimace, neboli který z algoritmů má v daný moment nejpravděpodobněji správný výsledek estimace. Výběr se provádí z modelů založených na rozšířeném Kalmanově filtru (EKF) a injektážního algoritmu.

Abstract

This research report deals with statistical optimal model selection algorithm for sensorless control of PMSM. Main idea is switching between particular estimation algorithm based on particular algorithm likelihood calculations. Outputs of a particular algorithm with highest likelihood are selected for feedback of drive control. EKF and injection algorithm was considered as particular estimation algorithms.

Seznam symbolů a zkratek

ARC	absolutní čidlo polohy
DSP	digitální signálový procesor
EKF	Extended Kalman Filter (rozšířený Kalmanův filtr)
PLL	Phase Lock Loop (fázový závěs)
PMSM	synchronní motor s povrchovými permanentními magnety na rotoru
PWM	pulsně šířková modulace
H	výstupní matice systému
$\mathbf{i}_s$	vektor statorového proudu
i_{sa}, i_{sb}	statorové proudy ve fázích a, b
$i_{s\alpha}, i_{s\beta}$	složky vektoru proudu v α, β systému
$\hat{i}_{s\alpha inj}(k)$	odhadovaná hodnota složky α vektoru statorového proudu pomocí injektážní metody
$\hat{i}_{s\beta inj}(k)$	odhadovaná hodnota složky β vektoru statorového proudu pomocí injektážní metody
$\hat{i}_{s\alpha inj_ \pi}(k)$	odhadovaná hodnota složky α vektoru statorového proudu pomocí injektážní metody s posunutou polohou rotoru o π
$\hat{i}_{s\beta inj_ \pi}(k)$	odhadovaná hodnota složky β vektoru statorového proudu pomocí injektážní metody s posunutou polohou rotoru o π
l	délka okna
L_s	indukčnost statoru
m_1	model EKF (hybridní estimátor)
m_2	model injektážní algoritmus (hybridní estimátor)
m_3	model injektážní algoritmus posunutý o π (hybridní estimátor)
M_t	matice modelů $M_t \in \{m_1, m_2, m_3\}$
p	počet pólpárů
$p(M_t y_{1:t})$	aposteriorní pravděpodobnost modelu M_t
$p(M_t)$	apriorní pravděpodobnost modelu M_t

$p(y_t M_t)$	marginální pravděpodobnost pozorování pro případ, že model M_t je pravdivý
P	kovarianční matice odhadu stavu systému
Q	kovarianční matice odpovídající šumu modelu systému
R	kovarianční matice odpovídající šumu pozorování systému
R_s	rezistivita statoru
$S_{\tau inj}, S_{\tau inj_ \pi}$	kovarianční matice estimace polohy rotoru pomocí injektážní metody
t	čas
$\mathbf{t}$	matice přechodu
$u_{s\alpha}, u_{s\beta}$	složky vektoru požadovaného napětí statoru v α, β systému
α	úhel natočení vektoru v d, q souřadném systému
ϑ_e	poloha vektoru toku permanentních magnetů (poloha osy d souřadného systému d, q)
$\hat{\vartheta}_e$	hybridním estimátorem estimovaná poloha vektoru toku permanentních magnetů ve stojícím souřadném systému α, β
$\hat{\vartheta}_{e_{kal}}$	EKF estimovaná poloha vektoru toku permanentních magnetů ve stojícím souřadném systému α, β
$\hat{\vartheta}_{e_{inj}}$	injektážní metodou estimovaná poloha vektoru toku permanentních magnetů
ϕ	faktor zapomínání u filtru s exponenciálním zapomínáním
ψ_{PM}	magnetický tok permanentních magnetů
ω_{me}	mechanická úhlová rychlost rotoru přepočtená na elektrickou [rad/s], $\omega_{me} = \omega_m \cdot p$
$\hat{\omega}_{me}$	hybridním estimátorem estimovaná mechanická úhlová rychlost rotoru přepočtená na elektrickou
$\hat{\omega}_{me_{kal}}$	EKF estimovaná mechanická úhlová rychlost rotoru přepočtená na elektrickou
$\hat{\omega}_{me_{inj}}$	injektážní metodou estimovaná mechanická úhlová rychlost rotoru přepočtená na elektrickou

Obsah

1 Úvod	6
2 Výběr optimálního modelu	6
2.1 Určení apriorní pravděpodobnosti modelů	8
2.2 Marginální pravděpodobnost pozorování modelu s EKF	8
2.3 Marginální pravděpodobnost pozorování modelů založených na injektážní metodě	9
3 Dynamický výběr modelů-zapomínání	11
4 Dynamický výběr modelů-Markovský model	16
5 Závěr	23

Revize	Změny
1	První verze dokumentu

1 Úvod

Problematika výběru optimálního estimačního modelu je objektem této výzkumné zprávy. Nutnost hledání optimálního estimačního algoritmu vychází z faktu, že žádný z dosud známých estimačních algoritmů není schopen spolehlivě estimovat polohu magnetického toku a el. rotorovou rychlost v celém otáčkovém spektru pohonu. Zde představovaný algoritmus vychází z teorie Skrytých Markovských modelů (Hidden Markov Models HMM). Hlavní myšlenkou je přepínat mezi modely na základě srovnání, který z algoritmů poskytuje v daný moment kvalitativně lepší výsledky estimace, neboli který z algoritmů má nejpravděpodobněji správný výsledek estimace. Toto srovnání se dá provést buď heuristicky [Hilairet2011], nebo statisticky optimálně. Druhé variantě se věnuje tato zpráva. Cílem této zprávy je ukázat, jak se tento v bezsenzorovém řízení pohonů zcela nový způsob výběru nejlepšího modelu aplikuje a jaké nové možnosti výzkumu i nasazení otevírá.

Principiálně je bayesovský algoritmus znázorněn na Obr. 1. Tento algoritmus přistupuje k problému estimace tak, že nahlíží na problematiku estimace jako na výběr jednoho z následujících modelů:

m_1 : Rozšířený Kalmanův filtr, uplatní se zejména v oblasti nízkých, středních a vysokých otáček.

m_2 : Injektážní algoritmus, který vyniká v ultra nízkých otáčkách a při stojícím rotoru.


m_3 : Injektážní algoritmus stejný jako v případě m_2 . Výstup algoritmu je však posunut o π . Ověřováním věrohodnosti takového modelu se testuje možnost, že injektážní algoritmus našel špatně magnetickou polaritu.

Na základě vypočtených věrohodností se vybere nejvhodnější model a jeho výstupy se stanou výstupy hybridního estimátoru a jsou použity jako vstupy pro vektorové řízení.

2 Výběr optimálního modelu

V případě přepínání mezi rozšířeným Kalmanovým filtrem a oběma injektážními estimátory lze problém interpretovat jako problematiku výběru nejlepšího modelu, kde nachází uplatnění bayesovský přístup. Máme-li modely $M_t \in \{m_1, m_2, m_3\}$, pak je aposteriorní pravděpodobnost modelů určena jako:

$$p(M_t | y_{1:t}) = \frac{p(y_t | M_t) p(M_t)}{\sum_{i=1}^n p(y_t | M_t) p(M_t)}. \quad (1)$$



Obr. 1: Principiální diagram hybridního estimátoru s bayesovským výběrem optimálního modelu

Pokud má model neznámé parametry, například z_t , pak člen $p(y_t | M_t = m_i)$ může být obecně vyjádřen jako [VPB:81]:

$$p(y_t | M_t = m_i) = \int p(y_t, z_t | M_t = m_i) dz_t. \quad (2)$$

V dalším textu bude používáno následující názvosloví pro jednotlivé členy:

$p(y_t M_t)$	marginální pravděpodobnost pozorování pro případ, že model M_t je pravdivý
$p(M_t y_{1:t})$	aposteriorní pravděpodobnost modelu M_t
$p(M_t)$	apriorní pravděpodobnost modelu M_t

Výpočtem rovnice (1) získáme pro každý partikulární model aposteriorní pravděpodobnosti. Existuje několik způsobů, jak z výsledných aposteriorních pravděpodobností určovat výstupy celého hybridního estimátoru. V našem případě používáme nejjednodušší způsob a tím je výběr modelu, který má pravděpodobnost nejvyšší. Ten vezmeme v daný okamžik za jediný správný a výstupy tohoto modelu se stanou výstupy celého hybridního estimátoru.

2.1 Určení apriorní pravděpodobnosti modelů

Určení apriorní pravděpodobnosti modelů, tedy členu $p(M_t)$ v rovnici (1) spočívá v určení třech hodnot. Pro náš případ výběru modelů, byly tyto pravděpodobnosti určeny experimentálně:

$$p(M_t) = \begin{cases} m_1 & : 0,95 \\ m_2 & : 1 \\ m_3 & : 1 \end{cases} \quad (3)$$

Preference obou injektážních modelů je stejná, protože nelze určit, který z nich je pravděpodobnější. Z přehledu konstant (3) je možno vysledovat, že byla zvolena vyšší preference injektážních algoritmů. Protěžování injektážních modelů jde proti očekávanému předpokladu. Z empirických znalostí algoritmů lze říci, že EKF je v daleko širším spektru provozních stavů přesnějším, stabilnějším estimátorem než injektážní algoritmus. V oblasti nulových a nízkých otáček se však výsledné logaritmy pravděpodobností pro všechny modely neliší podstatně a proto z důvodu vyšší spolehlivosti, byla úmyslně snížena preference EKF algoritmu. Celkový součet pravděpodobností pro všechny algoritmy je větší než 1, což může být na první pohled nesmyslné. Zde jsou tyto pravděpodobnosti chápány spíše jako váhy (míra protěžování jednotlivých algoritmů).

2.2 Marginální pravděpodobnost pozorování modelu s EKF

Pro odvození $p(y_t | M_t = m_1)$ pro EKF ze vztahu (1) se vyjde z následující predikční hustoty EKF:

$$p(y_t | M_t = m_1) \sim N(\hat{y}_t, \mathbf{S}_t). \quad (4)$$

Tedy předpokladem je, že pravděpodobnost dat za podmínky, že model m_1 je správný, má normální rozdělení se střední hodnotou danou výstupy estimátoru a variancí danou kovarianční maticí $\mathbf{S}_t$ definovanou dle 8. Aplikací obecného vztahu ¹ (5) na (4) dostaneme:

$$p(y_t | M_t = m_1) \propto \frac{1}{\sqrt{|\mathbf{S}_t|}} \exp\left(-\frac{1}{2}(y_t - \hat{y}_t)^T \mathbf{S}_t^{-1}(y_t - \hat{y}_t)\right), \quad (6)$$

kde

$$\hat{y}_t = h(\hat{x}, u_t), \quad (7)$$

¹Obecně má normální rozdělení sdruženou hustotu pravděpodobnosti:

$$f(x_1, x_2, \dots, x_s) = \frac{1}{\sqrt{(2\pi)^s |\mathbf{S}_t|}} \exp\left(-\frac{1}{2}(x - \mu)^T \mathbf{S}_t^{-1}(x - \mu)\right). \quad (5)$$

$$\mathbf{S}_t = \mathbf{H}\mathbf{P}_t\mathbf{H}^T + \mathbf{R}, \quad (8)$$

kde $\hat{y}_t$, jsou predikované hodnoty měření z EKF, $\mathbf{H}$ je linearizační matice predikčního modelu $h(x)$, $\mathbf{P}_t$ je kovarianční matice estimace a $\mathbf{R}$ je kovarianční matice pozorování. Pohledem na vztah (6) je vidět, že výpočet marginální pravděpodobnosti pro EKF je výpočetně velmi jednoduchý, protože část výpočtu (matice $\mathbf{S}_t^{-1}$ a $(y_t - \hat{y}_t)$) se provádí již v rámci výpočtu samotného EKF algoritmu.

2.3 Marginální pravděpodobnost pozorování modelů založených na injektážní metodě

Výpočet marginální pravděpodobnosti pro model založený na injektážní metodě představuje komplikovanější problém. Byly zvažovány dvě možnosti výpočtu podle toho, která z variant detekce magnetické anisotropie se použije: (i) detekce anisotropie pomocí EKF, (ii) detekce anisotropie pomocí klasického PLL. První zvažovaný případ byl zavržen z důvodu, že u něj nelze jednoduše ověřovat možnost, že byla špatně vyhodnocena magnetická polarita, což bylo jedním z prioritních cílů pro návrh tohoto hybridního estimátoru. Z tohoto důvodu jsme se přiklonili ke druhé variantě vycházející z detekce magnetické anisotropie pomocí klasického PLL. Z principu funkce PLL se nejedná o stochastický algoritmus a výpočet marginální pravděpodobnosti pro injektážní metodu tak představuje komplikovanější a hlavně výpočetně náročnější problém. Základní filosofií je udělat výpočet obdobně, jako je tomu u výpočtu marginální pravděpodobnosti algoritmu u EKF (6), tedy aby se marginální pravděpodobnost vypočítávala také podle vztahu (6). Tedy je potřeba určit hodnoty residuí $(y_\tau - \hat{y}_\tau)$ a matice $\mathbf{S}_\tau$. Stejně jako tomu bylo u EKF, residua se počítají ze změřených a predikovaných proudů v kartézském stojícím souřadném systému, tedy i_α a i_β . Problém je, že u injektážní metody se predikuje pouze poloha toku permanentních magnetů a elektrická rotorová rychlost. Tyto predikované proudy je tedy nutno si dopočítat. Lze využít stejný matematický model jako u EKF s tím, že se do něj dosadí za elektrickou rotorovou rychlost a polohu toku permanentních magnetů hodnoty,

kteřé jsou výstupem fázového závěsu injektážní metody. Dostaneme tak rovnice:

$$\hat{i}_{s\alpha inj}(k) = \left(1 - \frac{R_s}{L_s}T\right) \hat{i}_{s\alpha inj}(k-1) \quad (9)$$

$$+ \frac{T\psi_{PM}}{L_s} \sin(\hat{\vartheta}_{e_{inj}}) \hat{\omega}_{me_{inj}}(k-1) + \frac{T}{L_s} u_{s\alpha}(k-1),$$

$$\hat{i}_{s\beta inj}(k) = \left(1 - \frac{R_s}{L_s}T\right) \hat{i}_{s\beta inj}(k-1) \quad (10)$$

$$- \frac{T\psi_{PM}}{L_s} \cos(\hat{\vartheta}_{me}) \hat{\omega}_{me_{inj}}(k-1) + \frac{T}{L_s} u_{s\beta}(k-1).$$

Pro výsledek estimace mají zásadní význam hlavně druhé členy na pravých stranách, které počítají s výstupy injektážního algoritmu a jsou úměrné chybě estimace injektážním algoritmem. Jedním ze stanovených hlavních cílů pro návrh hybridního estimátoru je i zahrnutí možnosti, kdy injektážní metoda špatně odhadne magnetickou polaritu a $\hat{\vartheta}_{e_{inj}}$ je o π posunuta, do pravděpodobnostního rozhodování o výběru optimálního estimačního algoritmu (modelu) v daném pracovním bodě. Z tohoto důvodu se rovnice pro estimaci složek vektoru statorového proudu počítají ještě jednou s tím, že se za polohu rotoru dosadí poloha z výstupu injektážní metody posunuta o π :

$$\hat{i}_{s\alpha inj-\pi}(k) = \left(1 - \frac{R_s}{L_s}T\right) \hat{i}_{s\alpha inj-\pi}(k-1) \quad (11)$$

$$+ \frac{T\psi_{PM}}{L_s} \sin(\hat{\vartheta}_{e_{inj}} + \pi) \hat{\omega}_{me_{inj}}(k-1) + \frac{T}{L_s} u_{s\alpha}(k-1),$$

$$\hat{i}_{s\beta inj-\pi}(k) = \left(1 - \frac{R_s}{L_s}T\right) \hat{i}_{s\beta inj-\pi}(k-1) \quad (12)$$

$$- \frac{T\psi_{PM}}{L_s} \cos(\hat{\vartheta}_{e_{inj}} + \pi) \hat{\omega}_{me_{inj}}(k-1) + \frac{T}{L_s} u_{s\beta}(k-1).$$

Dále je nutné určit matici $\mathbf{S}_{r_{inj}}$. Jedná se o čtvercovou kovarianční matici, takže na hlavní diagonále budou variance pro jednotlivé složky proudu a na vedlejší diagonále jejich kovariance. Při odvození variancí lze vyjít z předpokladu:

$$y \sim N(\hat{y}, \sigma^2), \quad (13)$$

což lze upravit:

$$(y - \hat{y}) \sim N(0, \sigma^2). \quad (14)$$

Výsledná variance je pak:

$$\sigma = \left(\sum_t (y_t - \hat{y}_t)^2 - 0^2 \right) \frac{1}{n}. \quad (15)$$

Obdobně se dá určit kovariance. Výsledná matice $\mathbf{S}_{\tau_{inj}}$ je pak:

$$\mathbf{S}_{\tau_{inj}} = \begin{pmatrix} var(i_{s\alpha} - \hat{i}_{s\alpha inj})^2 & cov(i_{s\alpha} - \hat{i}_{s\alpha inj})(i_{s\beta} - \hat{i}_{s\beta inj}) \\ cov(i_{s\alpha} - \hat{i}_{s\alpha inj})(i_{s\beta} - \hat{i}_{s\beta inj}) & var(i_{s\beta} - \hat{i}_{s\beta inj})^2 \end{pmatrix}. \quad (16)$$

Stejným způsobem se musí tato matice vypočítávat pro model s posunutou polohou o π :

$$\mathbf{S}_{\tau_{inj_}\pi} = \begin{pmatrix} var(i_{s\alpha} - \hat{i}_{s\alpha inj_}\pi)^2 & cov(i_{s\alpha} - \hat{i}_{s\alpha inj_}\pi)(i_{s\beta} - \hat{i}_{s\beta inj_}\pi) \\ cov(i_{s\alpha} - \hat{i}_{s\alpha inj_}\pi)(i_{s\beta} - \hat{i}_{s\beta inj_}\pi) & var(i_{s\beta} - \hat{i}_{s\beta inj_}\pi)^2 \end{pmatrix}. \quad (17)$$

3 Dynamický výběr modelů-zapomínání

Dalším důležitým aspektem výpočtu, je volba na jakých datech se bude pravděpodobnost vypočítávat. Z praktických zkušeností s oběma partikulárními algoritmy se dá usuzovat, že pokud by se hodnoty marginální pravděpodobností pro jednotlivé algoritmy počítali pouze pomocí vztahu (6), byly by průběhy pravděpodobností velmi zvlňené, což by minimálně v oblasti přechodů mezi modely působilo problémy s nechtěnými přepínáními. Z tohoto důvodu je lepší počítat na datech, která budou zahrnovat několik posledních stavů. Jako nejjednodušší byl vybrán způsob, kdy se data filtrují na okně délky l . Délka okna samozřejmě ovlivňuje chování celého výpočtu aposteriorní pravděpodobnosti a je nutno ho pečlivě volit. Pokud se pravděpodobnost $p(y_t | M_t = m_i)$ počítá na okně délky l , pak vztah (6) lze počítat analyticky jako:

$$p(y_{t-l:t} | M_t = m_i) \propto \prod_{\tau=t-l}^t \frac{1}{\sqrt{|S_\tau|}} \exp\left(-\frac{1}{2}(y_\tau - \hat{y}_\tau)^T \mathbf{S}_\tau^{-1}(y_\tau - \hat{y}_\tau)\right). \quad (18)$$

Vztah (18) není příliš vhodný pro implementaci do DSP a pro výpočty v reálném čase, protože výpočet exponenciální funkce je příliš výpočetně náročný, z tohoto důvodu je vhodné provést následující zjednodušení. Jelikož cílem algoritmu není přesný výpočet pravděpodobností, ale pouze vzájemné porovnání pro jednotlivé algoritmy, je možno vztah (18) zlogaritmovat:

$$\ln p(y_{t-l:t} | M_t = m_i) \propto -\frac{1}{2} \sum_{\tau=t-l}^t \ln |S_\tau| + (y_\tau - \hat{y}_\tau)^T \mathbf{S}_\tau^{-1}(y_\tau - \hat{y}_\tau). \quad (19)$$

Zavedením tohoto zjednodušení je nutno přeformulovat i rovnici (1):

$$\ln p(M_t | y_{1:t}) = \ln p(y_{t-l:t} | M_t) + \ln p(M_t | y_{1:t-l}) - \ln \left(\sum_{i=1}^n (p(y_{t-l:t} | M_t = m_i) \cdot P(M_t = m_i | y_{1:t-l})) \right). \quad (20)$$

Z pohledu implementace je možno výpočet sumy v rovnici (19) na okně udělat na principu filtru s exponenciálním zapomínáním:

$$\ln p(y_{1:t} | M_t) = -\frac{1}{2} f_t, \quad (21)$$

$$f_t = \phi f_{t-1} + \ln |\mathbf{S}_\tau| + (y_\tau - \hat{y}_\tau)^T \mathbf{S}_\tau^{-1} (y_\tau - \hat{y}_\tau). \quad (22)$$

Filtr s exponenciálním zapomínáním, neboli klouzavý průměr s exponenciálním zapomínáním, je filtr, který počítá průměr z několika posledních hodnot (dáno velikostí okna), jejichž váhy exponenciálně klesají se vzdáleností od posledního vzorku (nejstarší vzorek má nejmenší váhu). Velikost parametru ϕ pak závisí na délce okna l :

$$\phi = \frac{l-1}{l}. \quad (23)$$

V našem případě byla délka l zvolena 256 vzorků (32 ms).


Navržený algoritmus byl implementován do řídicího DSP TMS320f2812. V průběhu ladění byly zjištěny potíže v podobě samovolného nechtěného přepínání mezi oběma injektážními modely. K tomu může docházet v oblasti velmi nízkých otáček a pro stojící rotor. Vysvětlení lze nalézt v rovnicích (9) až (12) v členech obsahující ϑ_{inj} a $\omega_{inj}(k-1)$. V těchto členech je v součinu elektrická rotorová rychlost, která je v oblasti velmi nízkých otáček nulová, a tedy i celý součin se blíží k nule. To má za následek, že aposteriorní pravděpodobnosti pro oba injektážní modely se od sebe prakticky neliší a vede to ke zmíněným nechtěným přepínáním. Pro zamezení těmto nechtěným přepínáním bylo zavedeno omezení pro přepínání. Toto omezení je znázorněno na Obr. 2. V zelené oblasti je možno přepínat mezi libovolnými modely bez omezení. V červené oblasti je možno přepínat pouze mezi EKF a posledním vybraným modelem s injektážním algoritmem. Přepnutí mezi injektážními modely není v této oblasti možné. Šířka ohraničeného červeného regionu byla volena co nejmenší, konkrétně ± 7 Hz. Start pohonu probíhá tak, že je počáteční správná poloha (včetně správné polarity toku permanentních magnetů) nalezena pomocí injektážní metody včetně aplikování napěťových pulsů a poté je pohon již rozbíhán

s informací o poloze a elektrické rotorové rychlosti dle statisticky optimálního výběrového algoritmu, který je blokově znázorněn na Obr. 3.




Obr. 2: Kandidáti pro pravděpodobnostní výběr modelů


Algoritmus z Obr. 3 byl testován na laboratorním prototypu pohonu PMSM stejného výkonu jako u předchozích algoritmů. Pro otestování byl vybrán lichoběžníkový řídicí profil rychlosti, tak aby otestoval zejména přepínání mezi modely a problematickou oblast velmi nízkých otáček. Tento test je zachycen na Obr. 4. Z celkového zobrazení přechodového děje je vidět, že přepnutí proběhlo bez větších obtíží. Detailním pohledem Obr. 4(c) je vidět, že k přepnutí mezi algoritmy došlo vícenásobně. První přepnutí je vidět na levé straně oscilogramu, kdy na cca 20 ms došlo k přepnutí z EKF na injektáž, během tohoto přepnutí se estimátor dopustil chyby přibližně 25° elektrických. Při dalším přepnutí, už konečném, byla chyba v jednotkách stupňů elektrických. Přestože je první přepnutí nechtěné, lze říci, že i když k takovému přepnutí dojde, nemá chyba v poloze dramatický rozměr. Z principu by u všech nechtěných přepnutí nemělo docházet k velkým chybám z důvodu, že takováto přepnutí nastávají v okamžicích, kdy jsou aposteriorní pravděpodobnosti, které se porovnávají, velmi blízké, a tedy i výstupy jednotlivých algoritmů musí být praktické stejné. Při opačném přepínání (injektážní estimátor-EKF) zachyceném na Obr. 4(b) lze detailní analýzou dobře vyzorovat, jak se v posledních okamžicích před přepnutím zvětšovala chyba v poloze u injektážního algoritmu, až v určitém okamžiku došlo k přepnutí na EKF, čímž se chyba v poloze znatelně zmenšila. Z těchto přechodových dějů se potvrzuje ten samý fakt jako u hysterézního přepínání, že obecně problematictější je přechod z EKF na injektážní algoritmus. To je dáno tím, že ve vysokých otáčkách fázový závěs injektážního algoritmu dynamicky nestíhá sledovat polohu a jeho zpětné zavěšení může způsobovat problémy. Oscilogramy na Obr. 5 jsou pořízeny pro stejné přechodové děje, jako tomu bylo u předchozího. Zachycují průběh aposteriorních pravděpodobností pro jednotlivé algoritmy, na základě kterých se vybírá výstup hybridního estimátoru. Je zde dobře vidět, že tyto pravděpodobnosti se dle očekávání mění v závislosti na rychlosti pohonu. Ve velmi malých otáčkách je nejlepší jeden z injektážních algoritmů a v malých, středních a vysokých otáčkách jednoznačně EKF. Z průběhu pravděpodobnosti pro injektáž s posunutou polohou o π lze vysledovat, že v oblasti nulových otáček (nulová derivace polohy) poklesává




Obr. 3: Blokové schéma hybridního estimátoru s bayesovským výběrem optimálního modelu



(a) reverzace




(b) detail přechodu injektážní metoda - EKF




(c) detail přechodu EKF - injektážní metoda

Obr. 4: Přechodový děj – otevřená smyčka, lichoběžníkový řídicí profil rychlosti, požadovaná el. rychlost rotoru ± 40 Hz, CH1-poloha rotoru ARC čidlo (72 deg/V), CH2-poloha rotoru hybridní estimátor (72 deg/V), CH3-el. rychlost rotoru ARC čidlo (55 Hz/V), CH4-el. rychlost rotoru hybridní estimátor (55 Hz/V)

i aposteriorní pravděpodobnost, to není způsobeno tím, že by nějak rostla chyba estimace, ale je to způsobeno spíše metodou vyhodnocování. Za určitých podmínek se může i stát, že se pravděpodobnosti obou injektážních modelů přiblíží natolik, že by mohlo docházet k přepínání mezi oběma modely, což by ve výsledku způsobilo chybu estimace π . Toto je nepřipustné a je ošetřeno necitlivostí v oblasti nulových otáček (Obr. 2). Přechodové děje Obr. 6 zachycují start algoritmu. a to pro obě možnosti počátečního nalezení magnetické polarity. Je vidět, že start pohonu je bezproblémový. Na oscilogramu Obr. 7 jsou zachyceny přechodové děje pro proměnné požadavky elektrické rotorové rychlosti. Rychlost 20 Hz byla volena záměrně, protože se nachází v blízkosti hranice, kdy dochází k přepínání mezi algoritmy.



(a) Aposteriorní pravděpodobnosti přesazeny přes sebe




(b) Aposteriorní pravděpodobnosti nad sebou


Obr. 5: Přechodový děj – otevřená smyčka, lichoběžníkový řídicí profil rychlosti, požadovaná el. rychlost rotoru ± 40 Hz, CH1-poloha rotoru ARC čidlo (72 deg/V), CH2-aposteriorní pravděpodobnost injektážní metoda $+\pi$, CH3-aposteriorní pravděpodobnost injektážní metoda, CH4-aposteriorní pravděpodobnost EKF

4 Dynamický výběr modelů-Markovský model

Skryté Markovské Modely jsou známou a dobře publikovanou technikou [VPB:81, Russell]. Problematika výběru optimálního modelu lze interpretovat jako odhadování skrytých stavů (modelů), které jsou odhadovány nepřímo na základě pozorování proměnných, ze kterých lze tyto stavy odhadnout. Struktura HMM modelů je znázorněna na Obr. (8). Stavy $M_0 \dots M_n$ jsou stavy (modely) ve skryté vrstvě, které jsou odhadovány, dále $y_1 \dots y_n$ jsou pozorování v daný časový okamžik. Šipky pak vyjadřují vazby, které jsou v modelu definovány. Svislé vazby vyjadřují vazby mezi stavem a jeho pozorováním, které jsou vyjádřeny observačním modelem, který je v každém kroku stejný. Podélné vazby pak vyjadřují vztah mezi skrytými stavy ve dvou po sobě jdoucích časových okamžicích (diskrétní časové okamžiky). Tyto vazby jsou vyjádřeny predikčním modelem. Algoritmus lze rozdělit do dvou kroků, predikce a korekce [Russell].



(a) Špatně nalezená počáteční magnetická polarita toku perm. magnetů



(b) Správně nalezená počáteční magnetická polarita toku perm. magnetů

Obr. 6: Přechodový děj - start pohonu , požadovaná el. rychlost rotoru ± 40 Hz, CH1-poloha rotoru ARC čidlo (72 deg/V), CH2-poloha rotoru hybridní estimátor (72 deg/V), CH3-el. rychlost rotoru ARC čidlo (55 Hz/V) , CH4-el. rychlost rotoru hybridní estimátor (55 Hz/V)

Predikce

Predikční krok spočívá v určení $p(M_t | y_{1:t-1})$, tedy pravděpodobnosti, že systém přejde do stavu M_t za předpokladu pozorování $y_{1:t-1}$. Odvození vztahu pro tuto pravděpodobnost je v rovnici (24) :

$$\begin{aligned}
 p(M_t | y_{1:t-1}) &= \int p(M_t, M_{t-1} | y_{1:t-1}) dM_{t-1}, \\
 &= \sum_{i=1}^n p(M_t | M_{t-1} = m_i, y_{1:t-1}) P(M_{t-1} = m_i | y_{1:t-1}), \\
 &= \sum_{i=1}^n p(M_t | M_{t-1} = m_i) P(M_{t-1} = m_i | y_{1:t-1}), \tag{24}
 \end{aligned}$$

kde $p(M_t | M_{t-1})$ vyjadřuje pravděpodobnosti přechodu mezi jednotlivými skrytými stavy.


Korekce

Korekční krok spočívá v určení $p(M_t | y_{1:t})$, tedy pravděpodobnosti, že systém přejde do stavu M_t za předpokladu nového pozorování $y_{1:t}$.


$$p(M_t | y_{1:t}) = p(M_t | y_t, y_{1:t-1}), \tag{25}$$

$$= \frac{p(y_t | M_t, y_{1:t-1}) p(M_t | y_{1:t-1})}{p(y_t | y_{1:t-1})}, \tag{26}$$

$$= \frac{p(y_t | M_t) p(M_t | y_{1:t-1})}{p(y_t | y_{1:t-1})}, \tag{27}$$



Obr. 7: Přechodový děj - profil rychlosti s postupnou změnou požadované el. rychlosti 0 Hz, 20 Hz, 40 Hz, 0 Hz, CH1-poloha rotoru ARC čidlo (72 deg/V), CH2-poloha rotoru hybridní estimátor (72 deg/V), CH3-el. rychlost rotoru ARC čidlo (55 Hz/V) , CH4-el. rychlost rotoru hybridní estimátor (55 Hz/V)




Obr. 8: Struktura HMM modelu

V kapitole 2 byl popsán jednoduchý způsob pravděpodobnostního výběru nejlepšího z algoritmů. Tento algoritmus považoval apriorní pravděpodobnosti jednotlivých modelů za konstantní v čase. V případě HMM je vývoj znalosti systému (přes pravděpodobnosti) dán predikčním krokem algoritmu popsáný rovnicí 24. Tento vztah vyjadřuje jakého stavu bude nabývat systém v následujícím kroku. Pro výpočet je použit předchozí stav systému $P(M_{t-1} = m_i | y_{1:t-1})$ a přechodová matice (28). Tato matice vyjadřuje, jak se bude měnit stav v následujícím kroku v závislosti na předchozím kroku. Může být přehledně vyjádřena i graficky Obr. 9.

$$P(M_t = m_i | M_{t-1} = m_j) = t_{i,j}, \quad i, j = 1, 2, 3, \quad (28)$$

$$0 \leq t_{i,j} \leq 1 \quad \sum_{i=1}^n t_{i,j} = 1.$$


Volba prvků matice přechodu se provádí na základě empirických znalostí algoritmů a na základě ladění na konkrétním pohonu. Vhodnou volbou členů, vyjadřujících přechod mezi injektážním




Obr. 9: Grafická interpretace přechodové matice (přepínání mezi estimačními modely)

algoritmem a injeztážním algoritmem posunutým o π lze zamezit problémům s přepínáním v oblasti nulových otáček, které bylo popsáno v kapitole 2 a muselo být řešeno speciální necitlivostí v kritické oblasti otáček. Takto upravený algoritmus byl implementován do DSP TMS320f2812 a testován na laboratorním prototypu pohonu s PMSM o jmenovitém výkonu 10,7 kW. Algoritmus byl testován jak v otevřené, tak uzavřené regulační smyčce. Přechodový děj v otevřené smyčce je zachycen na Obr. 10. Přepnutí je v případě přechodu z EKF na injeztážní metodu bezproblémové, v opačném případě se při přepnutí dopouští přepínací algoritmus chyby cca patnáct stupňů elektrických. V oscilogramu 10(b) je dobře vidět, že v okamžicích přepnutí z jednoho algoritmu na druhý dochází k rychlé změně aposteriorních pravděpodobností u všech algoritmů. Díky těmto rychlým změnám se hodnoty aposteriorních pravděpodobností pro algoritmy, ze kterého se přepíná a na který se přepíná, od sebe více odlišují a nedochází tak k několikanásobnému přepnutí jako v případě algoritmu dle kapitoly 2. Na obrázku 11 je znázorněn stejný přechodový děj jako u předchozího obrázku, ale s rozdílem, že se jedná o uzavřenou regulační smyčku, tedy výstup z hybridního estimátoru je zaveden do regulační smyčky vektorového řízení pohonu. Pro tento přechodový děj ovšem bylo sníženo zesílení rychlostního regulátoru, protože dynamické vlastnosti injeztážního algoritmu zatím nevykazují uspokojivé výsledky a při vyšším zesílení v regulační smyčce docházelo k selhání estimátoru. Při vyšším mo-


mentu setrvačnosti motoru, nebo při zatížení momentem by k tomuto problému nedocházelo. Přechodový děj dle Obr. 11 vykazuje podobné vlastnosti jako tomu bylo u otevřené smyčky.




(a) reverzace




(b) reverzace




(c) detail přechodu injektážní metoda - EKF



(d) detail přechodu injektážní metoda - EKF




(e) detail přechodu EKF- injektážní metoda




(f) detail přechodu EKF - injektážní metoda


Obr. 10: Přechodový děj – otevřená smyčka, lichoběžníkový řídicí profil rychlosti, požadovaná el. rychlost rotoru ± 40 Hz, Obrázky a, c, e: CH1-poloha rotoru ARC čidlo (72 deg/V), CH2-poloha rotoru hybridní estimátor (72 deg/V), CH3-el. rychlost rotoru ARC čidlo (55 Hz/V), CH4-el. rychlost rotoru hybridní estimátor (55 Hz/V), Obrázky b, d, f: CH1-poloha rotoru ARC čidlo (72 deg/V), CH2-aposteriorní pravděpodobnost injektážní metoda $+\pi$, CH3-aposteriorní pravděpodobnost injektážní metoda, CH4-aposteriorní pravděpodobnost EKF




(a) reverzace




(b) reverzace




(c) detail přechodu injektážní metoda - EKF



(d) detail přechodu injektážní metoda - EKF



(e) detail přechodu EKF- injektážní metoda



(f) detail přechodu EKF - injektážní metoda

Obr. 11: Přechodový děj – uzavřená smyčka, lichoběžníkový řídicí profil rychlosti, požadovaná el. rychlost rotoru ± 40 Hz, Obrázky a, c, e: CH1-poloha rotoru ARC čidlo (72 deg/V), CH2-poloha rotoru hybridní estimátor (72 deg/V), CH3-el. rychlost rotoru ARC čidlo (55 Hz/V), CH4-el. rychlost rotoru hybridní estimátor (55 Hz/V), Obrázky b, d, f: CH1-poloha rotoru ARC čidlo (72 deg/V), CH2-aposteriorní pravděpodobnost injektážní metoda $+\pi$, CH3-aposteriorní pravděpodobnost injektážní metoda, CH4-aposteriorní pravděpodobnost EKF

Z průběhů aposteriorních pravděpodobností u jednotlivých algoritmů lze vypožorovat, že přepínací algoritmus vybírá správně injecktážní algoritmus se správnou polaritou vektoru magnetického toku permanentních magnetů.

5 Závěr

Hybridní estimátory představují spojení několika estimačních algoritmů, které jako celek umožňují odhadovat polohu a rychlost otáčení rotoru PMSM v celém spektru provozních otáček pohonu, včetně nulové rychlosti. V této zprávě bylo představeno spojení injecktážní metody a EKF, mezi kterými se přepíná. Toto přepínání je děláno statisticky optimálně pomocí Bayesovského přístupu. K přepínání nedochází v pevných okamžicích, ale v okamžicích závislých na aktuálních výsledcích estimací z jednotlivých algoritmů a jsou zohledněna případná selhání EKF či injecktážní metody. Tento algoritmus navíc ověřuje i možnost, že injecktážní algoritmus špatně vyhodnotil problematickou polaritu magnetického toku a tak roste provozní spolehlivost celého hybridního estimátoru. Maximální chyby, které se dosáhlo tímto způsobem bylo cca 15 stupňů elektrických, a to v okamžiku přepnutí z injecktážního algoritmu na EKF. Problémem ještě zůstává chování v uzavřené smyčce v systému s malým momentem setrvačnosti a velkým zesílením v rychlostní smyčce, a to z důvodu selhávání injecktážního algoritmu. Závěrem lze říci, že pravděpodobnostní způsob přepínání představuje robustní způsob přepínání, který by mohl najít využití v reálném pohonu, a to minimálně v aplikaci, která sleduje případné selhání pohonu s čidlem na rotoru a v případě jeho selhání převede pohon do bezpečného stavu. Dále je to algoritmus, který minimalizuje vliv nepřesnosti určení parametrů. Odolnost vůči špatně určené magnetické polaritě a odolnost vůči špatně určeným parametrům pohonu je jednoznačně velkou výhodou oproti konkurenčním hybridním estimačním technikám, které byly v odborné komunitě publikovány.

Příloha - parametry pohonu

$2p$	8
R_s	0,28 Ω
L_s	3,456 mH
ψ_{PM}	0,1989 Wb
P	10,7 kW
M_n	38 Nm
I_{max}	77 A