

Bartłomiej Ufnalski, Lech M. Grzesiak  
Politechnika Warszawska, Instytut Sterowania i Elektroniki Przemysłowej

## NEURONOWY ESTYMATOR STRUMIENIA MAGNETYCZNEGO MASZYNY NAPĘDOWEJ DLA SAMOCHODU ELEKTRYCZNEGO

**Streszczenie:** W artykule przedstawiono metody syntezy estymatora strumienia stojana maszyny indukcyjnej wykorzystujące sztuczne sieci neuronowe (SSN). Wymagania dotyczące charakterystyk regulacyjnych stawiane przed konstruktorami napędów samochodów elektrycznych wymuszają stosowanie algorytmów sterowania pozwalających na kształtowanie odpowiedzi momentu elektromagnetycznego wytwarzanego w maszynie napędowej. Stosowane metody regulacji FOC (Field Oriented Control), DTC (Direct Torque Control) i DTC-SVM (Space Vector Modulated DTC) wykorzystują informacje o położeniu strumieni magnetycznych maszyny. Jednym ze sposobów estymacji tych strumieni jest budowa modelu matematycznego bazującego na metodach sztucznej inteligencji. Opublikowane ostatnio propozycje nowych metod tworzenia bazy sygnałów wejściowych dla takiego aproksymatora skłoniły autorów do porównania ich skuteczności w odniesieniu do konkretnego układu sterowania. Na przykładzie układu DTC-SVM porównano algorytmy wykorzystujące linie opóźnień, filtry eksperckie [2] oraz metodę ortogonalizującą sygnały wejściowe SSN [4].

**Słowa kluczowe:** napędy prądu przemiennego, estymacja zmiennych stanu, sztuczne sieci neuronowe, przetwarzanie sygnałów


### 1. WSTĘP

Rosnące obecnie zainteresowanie samochodami o napędzie elektrycznym lub hybrydowym stwarza nowe obszary masowego wykorzystania napędów o regulowanej prędkości. Wymagania dotyczące właściwości dynamicznych przy zachowaniu dużej niezawodności, kompaktowości i niskiej ceny, stawiają przed projektantami i konstruktorami nowe wyzwania. Jednocześnie udoskonalane są algorytmy sterowania dla silników różnych typów. Synteza współczesnych układów sterowania dla napędów przekształtnikowych wymaga często informacji o położeniu wektora strumienia magnetycznego maszyny. W maszynie indukcyjnej o wykonaniu standardowym wielkość ta nie jest mierzona i wymaga implementowania algorytmu jej odtwarzania. Przykładami produkowanych seryjnie indukcyjnych napędów trakcyjnych dla samochodów są m.in. REVA, AC Propulsion (tzero) i Tesla Motors.

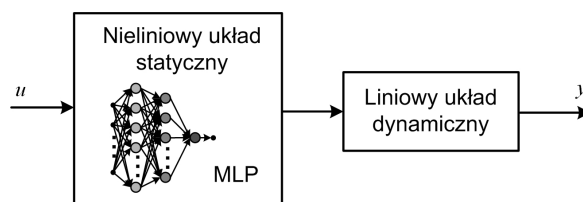
Algorytmy odtwarzania zmiennych stanu umożliwiające realizację układów napędowych z bezpośrednim sterowaniem momentem (DTC) czy sterowaniem polowozorientowanym (FOC) są nieustannym przedmiotem badań. Szereg proponowanych rozwiązań wykorzystuje algorytmy z dziedziny sztucznej inteligencji. Jedną z grup rozwiązań stanowią estymatory bazujące na perceptronie wielowarstwowym jako uniwersalnym aproksymatorze funkcji nieliniowej (MLP – Multi-Layer Perceptron, FFNN – Feed-Forward Neural Network).

## 2. MODELOWANIE DYNAMIKI PRZY UŻYCIU SZTUCZNEJ SIECI NEURONOWEJ

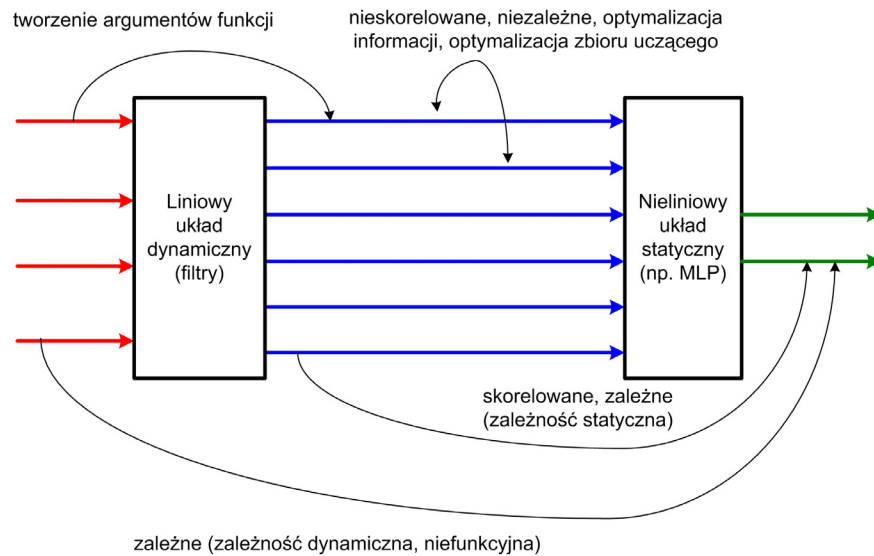
Odtwarzanie zmiennych stanu procesu wiąże się zazwyczaj z koniecznością modelowania dynamiki. Modelowanie to można wykonać algorytmami zakładającymi stosunkowo dobrą znajomość modelu matematycznego obiektu oraz w miarę precyzyjną identyfikację parametrów tego obiektu, a w przypadku obiektu niestacjonarnego, tj. o parametrach zmiennych w czasie, dodatkowo istotna jest budowa modelu zmian tych parametrów. Są to rozwiązania z grupy white-box (np. obserwator Luenbergera, filtr Kalmana). Z kolei sztuczne sieci neuronowe są wykorzystywane w rozwiązaniach z grupy black-box, które często zakładają brak znajomości zjawisk fizycznych kształtujących zależności pomiędzy sygnałami odtwarzanymi a sygnałami wejściowymi projektowanego estymatora. Modelowanie dynamiki przy użyciu SSN można zrealizować wykorzystując sieci zawierające w swej strukturze dynamikę (np. Recurrent Neural Network – RNN) lub wykorzystując sieci jednokierunkowe z odpowiednim wstępnym przetwarzaniem dynamicznym sygnałów (model Wienera) (Rys. 1.) [1, 9]. Możliwe też jest realizowanie takich modeli w topologii Hammersteina (Rys. 2.), w której nieliniowy układ statyczny znajduje się przed liniowym układem dynamicznym, jednak w przypadku sieci neuronowych uczonych w trybie z nauczycielem oznaczałoby to potrzebę budowania modelu odwrotnego liniowego układu dynamicznego.



Rys. 1. Schemat identyfikacji Wienera z częścią nieliniową zrealizowaną przy użyciu perceptronu



Rys. 2. Schemat identyfikacji Hammersteina z częścią nieliniową zrealizowaną przy użyciu perceptronu



Rys. 3. Wymagania dotyczące sygnałów tworzonych przy użyciu filtrów stanowiących bazę dla aproksymatora neuronowego

### 3. PRZEKSZTAŁCANIE ZAGADNIENIA MODELOWANIA NIEFUNKCYJNEGO (DYNAMICZNEGO) W ZAGADNIENIE FUNKCYJNE (STATYCZNE)

Odtwarzanie strumienia magnetycznego stojana maszyny indukcyjnej na podstawie prądów i napięć na zaciskach maszyny jest zagadnieniem modelowania zależności dynamicznej. Zazwyczaj, z uwagi na nieliniowość obwodu magnetycznego oraz temperaturowe zmiany rezystancji uzwojeń jest to zależność nieliniowa nie inwariantna czasowo. Brak znajomości warunków początkowych oraz występowanie składowej stałej w sygnałach pomiarowych dodatkowo utrudnia estymowanie wektora strumienia. Istnieje szereg metod pozwalających na praktyczną implementację estymatora odpornego na wybrane z wymienionych powyżej zjawisk [7]. Jednym z nich jest zaproponowany kilka lat temu przez autorów estymator neuronowy z dynamicznym wstępnym przetwarzaniem sygnałów [2, 6]. Filtry realizujące wstępne przetwarzanie były dobierane przez autorów metodą ekspercką. Opublikowane ostatnio w [4] metody algorytmicznego dobierania nastaw filtrów wejściowych skłoniły autorów do przetestowania tej metodologii postępowania w przypadku projektowania estymatora strumienia stojana dla napędu DTC-SVM (Space Vector Modulated Direct Torque Control). Porównano skuteczność różnych metod dynamicznego przekształcania sygnałów, tak aby otrzymana baza sygnałów pozwalała na modelowanie procesu przy użyciu aproksymatora funkcji. Poniżej przedstawiamy trzy zbadane metody:

- linię opóźnień (TDL, Tapped Delay Line),
- filtry eksperckie (połączenie równoległe i szeregowo),
- filtry ortogonalizujące bazę sygnałów dla perceptronu.


Zadaniem każdego z tych przetwarzań jest zbudowanie takiej bazy sygnałów, aby zależność między nimi a modelowaną wielkością (w badanym przypadku, strumieniem stojana maszyny indukcyjnej) była zależnością funkcyjną (statyczną). Dodatkowo budowana baza sygnałów powinna możliwie najbardziej ułatwiać modelowanie zależności pomiędzy tymi sygnałami a wielkością odtwarzaną. Wymagania odnośnie poszczególnych sygnałów przedstawiono na Rys. 3.

#### 4. LINIA OPÓZNIEN

Dyskretne modelowanie procesu dynamicznego można sprowadzić do znalezienia funkcji  $f$ , takiej, że

$$y(k+1) = f(u(k-n_1), u(k-n_1+1), \dots, u(k), u(k+1), y(k-n_2), y(k-n_2+1), \dots, y(k)), \quad (1)$$

gdzie:  $u$  – wektor sygnałów wejściowych,  $y$  – wektor sygnałów wyjściowych,  $k$  – numer próbki (chwila czasowa),  $n_1$  i  $n_2$  – horyzonty czasowe (głębokości historii próbek niezbędne do aproksymowania aktualnego stanu obiektu z zadowalającą dokładnością).



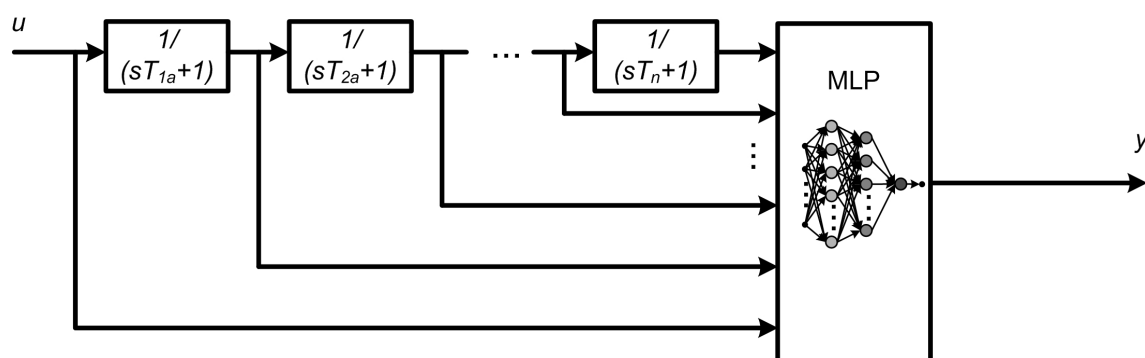
Rys. 4. Wstępne przetwarzanie dynamiczne przy użyciu linii opóźnień

Schemat neuronowego modelu procesu z linią opóźnień przedstawiono na Rys. 4. Sieci te określane są skrótem TDNN (Tapped-Delay Neural Network). Projektowanie takiej sieci polega przede wszystkim na wyborze liczby opóźnień i czasu pojedynczego opóźnienia. Jeżeli zostaną one dobrane prawidłowo, to proces modelowania neuronowego sprowadza się do aproksymacji funkcji, którą można zrealizować przy użyciu MLP o odpowiedniej liczbie neuronów o nieliniowej funkcji aktywacji. Brak jednoznacznych metod doboru parametrów linii opóźnień oznacza zazwyczaj konieczność postępowania metodą prób i błędów. Zbyt duże opóźnienie pojedynczego członu stwarza ryzyko pominięcia istotnych detali dynamiki. Zbyt krótka linia opóźnień (zbyt krótki horyzont czasowy wstecz) uniemożliwi wystarczająco dokładne modelowanie zjawisk o mniejszej dynamice. W obu tych przypadkach zależność pomiędzy sygnałami przetworzonymi przy użyciu TDL a sygnałem odtwarzanym nie będzie statyczna z zadowalającą dokładnością i zadania odtwarzania nie uda się zrealizować za pomocą MLP. Z kolei, zbyt małe opóźnienie pojedynczego członu spowoduje nierozróżnialność wektorów uczących (z uwagi na szумы systemowe i pomiarowe), zbędny wzrost liczebności zbioru uczącego, gorsze uwarunkowanie numeryczne procesu uczenia. Za długa linia opóźnień, szczególnie w przypadku okresowych sygnałów wejściowych, wprowadza liniowe zależności w

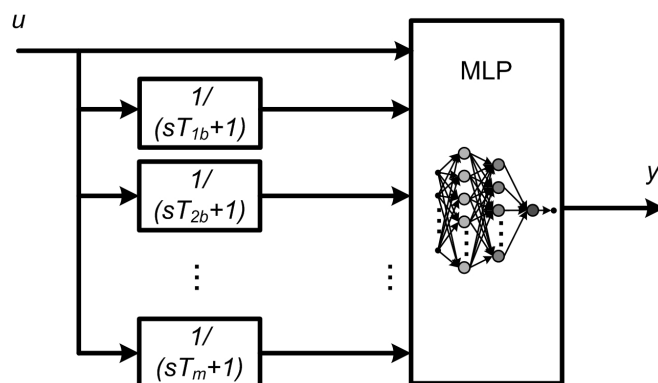
zbiorze uczącym. Efektem tego jest gorsze uwarunkowanie problemu oraz niepotrzebny wzrost liczby operacji numerycznych wykonywanych w czasie rzeczywistym w trybie odtwarzania.

## 5. FILTRY „EKSPERCKIE”

Szczególnie w dziedzinie syntezy regulatorów istnieje szereg rozwiązań wykorzystujących wiedzę ekspercką. Przykładem może być tabela reguł, tworzona na bazie lingwistycznego opisu procesu dostarczanego przez ekspertów, wykorzystywana przy syntezie regulatora rozmytego [3]. Modelowanie neuronowe stwarza wiele możliwości na wykorzystanie wiedzy eksperckiej o odtwarzanym procesie. Pozwala na stosunkowo łatwe wykorzystanie wiedzy o procesie przedstawionej za pomocą opisu lingwistycznego. Przykładem mogą być tutaj sieci neuronowe z interfejsem rozmytym. Z kolei nasza propozycja zakłada wykorzystanie interfejsu w postaci filtrów dobieranych na podstawie wiedzy eksperckiej o modelowanym procesie. Przykładowo, związki pomiędzy wielkościami elektrycznymi a magnetycznymi i mechanicznymi w silniku często przybierają postać odpowiednio połączonych inercji pierwszego rzędu. W oparciu o takie założenie zaprojektowano neuronowy estymator strumienia stojana składający się ze wstępnego przetwarzania dynamicznego (filtry inercyjne pierwszego rzędu) oraz nieliniowego aproksymatora funkcji zrealizowanego przy użyciu MLP [1, 2]. Filtry te mogą być łączone szeregowo (Rys. 5.) lub równolegle (Rys. 6.). Ich stałe czasowe dobierane są w oparciu o bardzo przybliżony (często ekspercki, lingwistyczny) model procesu. Okazuje się, że zazwyczaj wystarczający jest opis lingwistyczny typu: mała, średnia, duża stała czasowa, a określenia te mogą być interpretowane z dokładnością co do rzędu wielkości.



Rys. 5. Wstępne przetwarzanie dynamiczne przy użyciu filtrów eksperckich połączonych szeregowo



Rys. 6. Wstępne przetwarzanie dynamiczne przy użyciu filtrów eksperymentalnych połączonych równolegle

## 6. FILTRY ORTOGONALIZUJĄCE

### 6.1. Wybór wskaźnika jakości

Zarówno linia opóźnień jak i filtry dobierane metodą ekspercką nie optymalizują bazy sygnałów dla perceptronu pod kątem niezależności informacji zawartej w tych sygnałach. Nadmiarowa informacja zawarta w sygnałach utrudnia proces uczenia i zazwyczaj pogarsza generalizację (tj. odtwarzanie dla wektorów spoza zbioru uczącego). Optymalizacja informacji może dotyczyć dwóch obszarów:

- optymalizacji sygnałów wejściowych perceptronu zakładającej minimalizację nadmiarowej informacji,
- optymalizacji sygnałów wejściowych perceptronu pod kątem związków przyczynowo-skutkowych z sygnałem odtwarzanym.

Postać bazy rozważanego aproksymatora zależy od zastosowanego wstępnego przetwarzania dynamicznego oraz ewentualnych dodatkowych (zazwyczaj liniowych) przekształceń optymalizujących wybraną cechę tej bazy. Przykładem może być tutaj przetwarzanie liniowe typu PCA (Principal Component Analysis, Analiza Składowych Głównych) lub ICA (Independent Component Analysis, Analiza Składowych Niezależnych). Algorytm PCA maksymalizuje wariancję kolejnych sygnałów tworzących bazę, przy jednoczesnym ortogonalizowaniu tej bazy. Algorytm ICA maksymalizuje statystyczną niezależność sygnałów tworzących bazę. Algorytm ICA działa prawidłowo przy założeniu, że przetwarzane sygnały są liniową kombinacją sygnałów statystycznie niezależnych. Sytuacja taka jest niezmiernie rzadka w zagadnieniach inżynierskich, bo oznaczałaby ona brak związku przyczynowo-skutkowego pomiędzy analizowanymi sygnałami. W rozważanym przypadku estymatora strumienia, wejściowe sygnały prądów i napięć nie są niezależne. Dodatkowo metody oceny statystycznej niezależności sygnałów rzeczywistych są obliczeniowo ciężkie i są metodami przybliżonymi. Algorytm PCA jest stosunkowo prosty w implementacji i jest algorytmem dokładnym, bo funkcja celu wykorzystuje współczynnik korelacji liniowej Pearsona (analogiczny do iloczynu skalarnego wektorów), który przyjmuje wartość zerową dla sygnałów nieskorelowanych liniowo. Algorytm ten jest używany m.in. do ortogonalizacji bazy aproksymatora z

jednoczesną optymalizacją liczby wymiarów przestrzeni wygenerowanej metodami eksperckimi [6].

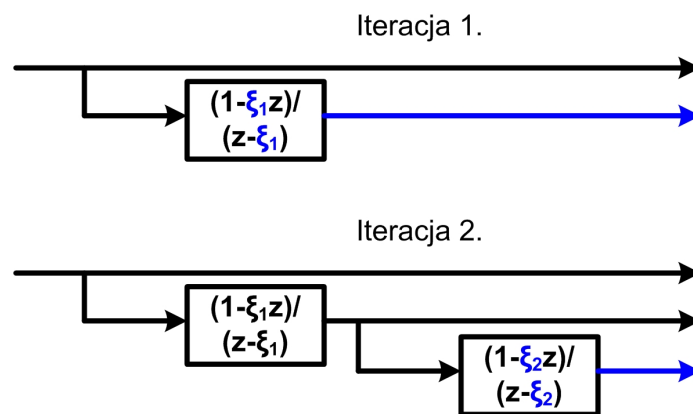
W pracy [4] zaproponowano odmienny sposób postępowania. Ortogonalizacja bazy odbywa się już na etapie dobierania parametrów filtrów. Parametry filtru są tak dobierane, aby sygnał wyjściowy filtru był ortogonalny do sygnałów już obecnych w bazie. Jako jednostkę przetwarzającą zaproponowano filtr *all-pass* będący uogólnieniem członu opóźniającego. Dyskretna transmitancja tego filtru to:

$$G(z) = \frac{1 - \xi z}{z - \xi} \quad (2)$$

Bieguny  $\xi$  kolejnych filtrów są dobierane tak, aby minimalizowały normę rzutu tworzonego sygnału na hiperpłaszczyznę rozpiętą na dotychczasowych sygnałach. Wskaźnik jakości został zdefiniowany następująco:

$$J_1(\xi) = \left\| \sum_{i=1}^{n-1} u_i \langle u_i, u_n(\xi) \rangle \right\|^2 \quad (3)$$

gdzie:  $u_n(\xi)$ - sygnał projektowany,  $u_i$ - sygnały zaprojektowane w poprzednich iteracjach,  $\langle \bullet, \bullet \rangle$  - iloczyn skalarny. Opisuje on kwadrat długości rzutu wektora na hiperpłaszczyznę rozpiętą na wektorach ortonormalnych. W procesie iteracyjnym (liczba iteracji jest równa liczbie projektowanych filtrów), dobierane są kolejne  $G(z)$  minimalizujące  $J_1(\xi)$ .



Rys. 7. Przebieg iteracyjnego procesu dobierania parametrów filtrów

Przebieg tego procesu ilustruje Rys. 7. W praktyce w zasadzie nie zdarza się, aby wskaźnik jakości spadł w każdej iteracji do zera. Oznacza, to że kolejne sygnały są prawie-ortogonalne do już zaprojektowanych w poprzednich iteracjach. Jeżeli sygnały z iteracji  $k$ -tej nie są ortogonalne, to rzut ortogonalny sygnału  $k+1$  na hiperpłaszczyznę nie może być wyznaczany jako suma rzutów ortogonalnych na prawie-ortogonalne wektory

bazy. Przy „prawie” ortogonalnych wektorach bazy może się nawet zdarzyć, że wskaźnik jakości (3) dla wektora jednostkowego przyjmuje wartości większe od 1, a jego definicja zakładająca ortogonalność bazy implikuje zawieranie się w przedziale  $[0,1]$ . Ewolucyjne metody optymalizacji (np. algorytm genetyczny, algorytm roju cząstek), w odróżnieniu od algorytmów gradientowych, pozwalają na efektywne poszukiwanie suboptymalnych rozwiązań nawet, gdy funkcja celu zawiera infimum otoczone szeregiem minimów lokalnych. Algorytmy te stosunkowo dobrze radzą sobie z funkcjami nieciągłymi. Oznacza to, że przy proponowaniu funkcji celu nie jesteśmy istotnie ograniczani możliwościami optymalizatora. W sytuacji, gdy wektory (sygnały) są znacząco nieortogonalne nie sposób zaproponować funkcję celu skutecznie opisującą jakość projektowanego sygnału. Przykładowo, zbadano skuteczność metody dobierania filtrów w oparciu o minimalizację funkcji celu danej wzorem:

$$J_2(\xi) = \sum_{i=1}^{n-1} \|u_i \langle u_i, u_n(\xi) \rangle\| \quad (4)$$

W interpretacji geometrycznej, wartość funkcji (4) jest sumą norm rzutów nowoprojektowanego wektora (sygnału) na sygnały zaprojektowane w poprzednich iteracjach.

## 6.2. Wybór jednostki przetwarzającej

Skuteczność metody ortogonalizującej zależy przede wszystkim od efektywności zastosowanych jednostek przetwarzających. Miarą tej efektywności jest zdolność do przeszukiwania hiperprzestrzeni pod kątem niewykorzystanych kierunków ortogonalnych. Nie istnieją jednoznaczne metody doboru struktury jednostki przetwarzającej. Zazwyczaj postępujemy w tym przypadku metodą prób i błędów wspieraną wiedzą ekspercką. Zauważmy, że dla sygnału dyskretnego składającego się z  $p$  próbek i rozważanego jako wektor w przestrzeni  $p$ -wymiarowej, istnieje teoretycznie  $p-1$  sygnałów ortogonalnych, które potencjalnie można wygenerować z tego sygnału przy użyciu odpowiednich filtrów. W badanym przypadku odtwarzania strumienia przyjęto  $p=50\,001$ . Zastosowano filtr *all-pass* (2) zaproponowany w [4]. Wyniki minimalizacji funkcji celu już w pierwszej iteracji (czyli dla pierwszego członu przetwarzającego) wskazywały na małą efektywność tego filtru w badanym zagadnieniu odtwarzania strumienia stojana (pomimo  $p-1=50\,000$  niewykorzystanych potencjalnych kierunków ortogonalnych). Podjęto zatem próbę zastąpienia filtrów *all-pass* członami inercyjnymi pierwszego rzędu, które wykazywały dużą skuteczność podczas rozwiązywania problemu metodą ekspercką. Zaobserwowano, że stałe czasowe filtrów dobierane metodą ortogonalizującą dążyły do nieskończoności. Algorytm ortogonalizacji starał się zastąpić człony inercyjne członami całkującymi, a tego właśnie chcieliśmy uniknąć. Idealne całkowanie sygnału rzeczywistego bez dodatkowego algorytmu korekcji powoduje całkowity brak odporności estymatora na składową stałą wprowadzaną do sygnału przez układy pomiarowe oraz zakłócenia o niezerowej wartości średniej. Trudności z doбором jednostki przetwarzającej dla algorytmu ortogonalizującego mogą też wynikać ze złego uwarunkowania problemu.



### 6.3. Złe uwarunkowanie problemu

Zauważmy, że w rozważanym przypadku istnieją pary sygnałów podstawowych (podawanych na wejście estymatora), które w stanie ustalonym napędu są prawie-ortogonalne i mają przebiegi zbliżone do sinusoidalnych, np.  $(i_{s\alpha}, i_{s\beta})$  a zastosowany filtr *all-pass* ma płaską charakterystykę amplitudową. Efektem tego jest brak możliwości generowania sygnałów ortogonalnych do już istniejących. Jednocześnie przetwarzanie dynamiczne jest potrzebne, aby przekształcić zagadnienie modelowania niefunkcyjnego w funkcyjne. Algorytm ortogonalizujący wygenerował w badanym przypadku zestaw filtrów pozwalający na zwiększenie stopnia statyczności zależności, ale otrzymana baza była daleka od bazy ortogonalnej.

## 7. NORMALIZACJA SYGNAŁÓW DLA MLP

Odpowiednia normalizacja sygnałów dla MLP może przyspieszyć proces uczenia i polepszyć generalizację. Typowym postępowaniem jest normalizacja tych sygnałów do przedziału  $[-1,1]$  (5). Jednocześnie przy określaniu współczynnika korelacji liniowej dokonuje się standaryzacji sygnału poprzez odjęcie wartości średniej i podzielenie przez odchylenie standardowe (czasem dodatkowo odrzuca się na początku wartości skrajne) (6). Z kolei normalizacja wektora polega na dzieleniu przez jego normę (długość) (7).

$$u_{norm} = \frac{u}{\max(\text{abs}(u))} \quad (5)$$

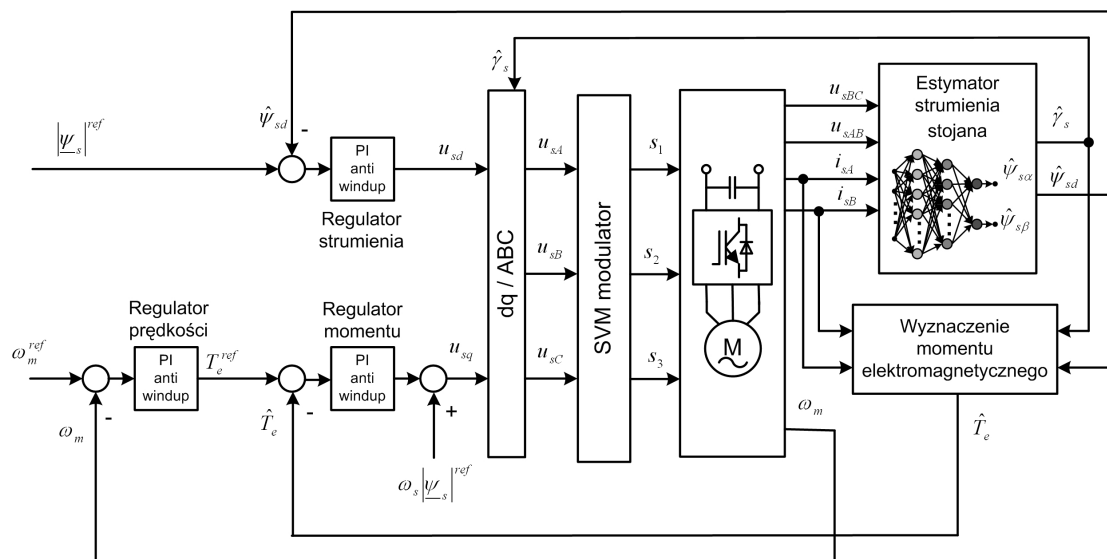
$$u_{norm} = \frac{u - \mu}{\sigma} \quad \left| \begin{array}{l} \mu = \frac{1}{N} \sum_{k=1}^N u_k \\ \sigma = \sqrt{\frac{\sum_{k=1}^N (u_k - \mu)^2}{N}} = \frac{1}{\sqrt{N}} \sqrt{\langle u - \mu, u - \mu \rangle} \end{array} \right. \quad (6)$$

$$u_{norm} = \frac{u}{\|u\|} = \frac{u}{\sqrt{\langle u, u \rangle}} \quad (7)$$

Powstaje zatem pytanie, czy wybór sposobu normalizacji wpływa w istotny sposób na efekty uczenia. Stwierdzono eksperymentalnie, że w badanym przypadku typ zastosowanej normalizacji nie miał istotnego wpływu na błąd uczenia.

## 8. BADANIA PORÓWNAWCZE

Skuteczność poszczególnych rozwiązań porównano na przykładzie estymatora strumienia magnetycznego stojana maszyny indukcyjnej pracującej w układzie DTC-SVM [8]. Topologię wykorzystanego układu regulacji przedstawiono na Rys. 8.



Rys. 8. Schemat układu sterowania DTC-SVM

Przyjęto, że we wszystkich badanych rozwiązaniach sieć będzie miała 12 wejść (składowe  $\alpha\beta$  prądów i napięć stojana oraz sygnały powstałe w wyniku dynamicznego przetwarzania tych składowych) oraz 2 wyjścia (składowe  $\alpha\beta$  strumienia stojana). Porównano skuteczność następujących bloków przetwarzania dynamicznego:

- linia opóźnień,
- człony inercyjne połączone szeregowo (filtry eksperckie),
- człony inercyjne połączone równolegle (filtry eksperckie),
- jednostki *all-pass* dobierane metodą ortogonalizującą (wskaźnik jakości jako norma rzutu na hiperpłaszczyne),
- jednostki *all-pass* dobierane metodą ortogonalizującą (wskaźnik jakości jako suma norm rzutów na wektory).

W pierwszych trzech rozwiązaniach parametry jednostek przetwarzających dobierane były iteracyjnie metodą prób i błędów, tak aby uzyskiwany wynik był możliwie najlepszy. Liczbę neuronów w warstwach ukrytych MLP (12-7-3-2) dobrano tak, aby jej dalsze zwiększanie nie powodowało istotnego spadku błędu uczenia. Można zatem przyjąć uzyskany błąd uczenia sieci (MSE) za miarę skuteczności zaproponowanego przetwarzania dynamicznego. Wyniki zebrano w Tab. I.

Tablica I

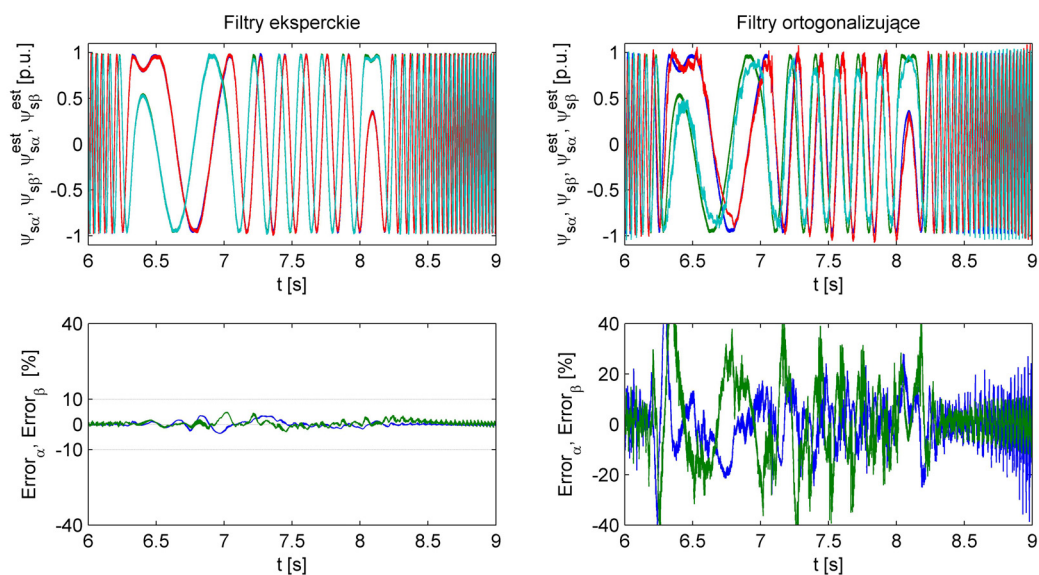
**Błędy uczenia dla wybranych metod przetwarzania dynamicznego**

Blok przetwarzający	Błąd uczenia (MSE)
TDL	0.006
człony inercyjne połączone szeregowo	0.0005
<b>człony inercyjne połączone równolegle</b>	<b>0.0003</b>
jednostki <i>all-pass</i> minimalizujące wsk. (3)	0.004
jednostki <i>all-pass</i> minimalizujące wsk. (4)	0.003

Wyniki porównania pokazują, że w badanym przypadku projektowanie przetwarzania w oparciu o filtry eksperckie jest skuteczniejsze od wprowadzania linii opóźnień lub filtrów typu *all-pass* (o płaskiej charakterystyce amplitudowej). Przykładowe przebiegi uzyskane dla filtrów eksperckich i jednostek przetwarzających *all-pass* przedstawiono na Rys. 9.

## 9. WNIOSKI

Sieć jednokierunkowa jest chętnie wykorzystywana jako część nieliniowa w schemacie Wienera modelowania układu dynamicznego. Zbadane przez autorów metody projektowania liniowego przetwarzania dynamicznego wskazują na dobrą skuteczność filtrów dobieranych metodą ekspercką. Metoda ta z powodzeniem została wykorzystana również w [5] do budowy neuronowego estymatora momentu oporowego. Próba zalgorytmizowania tego procesu przy użyciu metody ortogonalizującej pokazała ograniczenia tego algorytmu w przypadku odtwarzania strumienia na podstawie prądów i napięć stojana maszyny indukcyjnej. Obecnie autorzy starają się zaproponować postać jednostki przetwarzającej pozwalającej na efektywne generowanie kierunków ortogonalnych w rozważanym estymatorze. Jednocześnie testowane są różne pomysły na ocenianie przydatności sygnałów w procesie odtwarzania na podstawie transformaty falkowej i analizy wielorozdzielczej poprzez poszukiwanie związków przyczynowo-skutkowych pomiędzy danym potencjalnym sygnałem wejściowym a sygnałami wyjściowymi.



Rys. 9. Przykładowe przebiegi uzyskane przy użyciu estymatora z filtrami eksperckimi i filtrami ortogonalizującymi

## PODZIĘKOWANIA

Praca współfinansowana ze środków projektu ECO-MOBILNOŚĆ realizowanego w ramach środków EUROPEJSKIEGO FUNDUSZU ROZWOJU REGIONALNEGO w ramach PROGRAMU OPERACYJNEGO INNOWACYJNA GOSPODARKA.

### Bibliografia

1. Grzesiak L.M., Ufnalski B.: Neural stator flux estimator with dynamical signal preprocessing. IEEE AFRICON 2004.
2. Grzesiak L.M., Ufnalski B.: DTC drive with ANN-based stator flux estimator. IEEE EPE 2005.
3. Kazmierkowski M.P., Krishnan R., Blaabjerg F., Irwin J.D.: Control in power electronics – selected problems. Academic Press 2002.
4. Kubowicz K.: Przekształcenia statyczne i dynamiczne w modelowaniu sygnałów i układów wykorzystującym dane eksperymentalne. Rozprawa doktorska. Politechnika Warszawska 2009.
5. Tarczewski T.: Sterowanie serwonapedu z silnikiem synchronicznym o magnesach trwałych ze sprzężeniem od stanu i estymowanego momentu oporowego. Rozprawa doktorska. Politechnika Warszawska 2009.
6. Ufnalski B.: Zastosowanie sieci neuronowych do odtwarzania prędkości kątowej wirnika oraz strumienia stojana w układzie napędowym z silnikiem klatkowym. Rozprawa doktorska. Politechnika Warszawska 2004.
7. Ufnalski B., Grzesiak L.M.: Selected methods in flux estimation for induction motor drives. Rozdział w monografii „Power electronics and electrical drives – selected problems” pod redakcją T. Orłowskiej-Kowalskiej, Oficyna Wydawnicza Politechniki Wrocławskiej 2007.
8. Zelechowski M., Kazmierkowski M.P., Blaabjerg F.: Controller design for Direct Torque Controlled Space Vector Modulated (DTC-SVM) induction motor drives. IEEE ISIE 2005.
9. Zhao J., Bose B.K.: Neural-network-based waveform processing and delayless filtering in power electronics and AC drives, IEEE Transactions on Industrial Electronics, vol. 51, no. 5, October 2004.

## NEURAL-NETWORK-BASED MAGNETIC FLUX ESTIMATOR FOR ELECTRIC CAR DRIVE

**Abstract:** This paper compares selected methods of flux estimation in induction motor drives. The paper focuses on artificial-neural-network-based solutions to mentioned problem. Many applications (including battery electric vehicles) demand drive systems with high performance torque control loop. This requirement can be fulfilled with the help of flux-oriented control. Among other flux estimation methods, there are models that employ artificial neural networks (ANNs), e.g. a feed-forward neural network also known as a perceptron. New methods of creating approximation space for the perceptron have been published recently [4]. This inspired us to test them and compare them to previously elaborated ANN-based flux estimators with signal dynamical preprocessing [2]. A DTC-SVM (Space Vector Modulated Direct Torque Control) drive was chosen as a benchmark system bed. Five different approaches to signal dynamical preprocessing for the perceptron were tested and compared, including tapped delay lines, expert filters and orthogonalizing filters [4].

**Keywords:** variable speed AC drives, state variables estimation, artificial neural networks, signal preprocessing