

ZASTOSOWANIE METOD SZTUCZNEJ INTELIGENCJI DO OCENY ZJAWISK ZAKŁÓCENIOWYCH W SIECIACH ELEKTROENERGETYCZNYCH

W referacie przedstawiono zastosowanie sztucznej inteligencji do klasyfikacji zakłóceń występujących w sieciach elektroenergetycznych z wykorzystaniem sieci neuronowej typu SVM (Support Vector Machine) i RBF (Radial Basis Function). Omówiono przyczyny zainteresowania jakością energii, opisano podstawowe klasy zakłóceń. Wprowadzono sieci SVM i przedstawiono wyniki klasyfikacji zakłóceń symulowanych komputerowo, potwierdzające przydatność metody, szczególnie w porównaniu do wyników uzyskanych przez sieć RBF.

1 WSTĘP

Zainteresowanie problematyką jakości energii w ostatnim czasie wzrasta, można wymienić kilka najważniejszych powodów [1].

- Deregulacja rynku energii w Unii Europejskiej, w Polsce,
- Rosnąca potrzeba standaryzacji dostaw energii [11],
- Generowanie zakłóceń przez odbiorniki [4],
- Wrażliwość odbiorników na zakłócenia [2, 6].

Coraz większa liczba układów automatyki i elektroniki przemysłowej w przypadku wystąpienia zakłóceń może pracować niepoprawnie [14], co prowadzi do zaburzenia lub przerwania procesu technologicznego [7]. Efektem końcowym są wysokie straty finansowe. Ogólnie, wiele elementów systemu elektroenergetycznego może być zarówno źródłem zakłóceń, jak i elementem zagrożonym [3].

Idealne napięcie w publicznej sieci trójfazowej powinno spełniać następujące warunki:

- przebieg o kształcie czystej sinusoidy,
- stała częstotliwość odpowiadająca częstotliwości sieciowej,
- identyczna amplituda w każdej fazie odpowiednia dla danego poziomu napięcia,
- zdefiniowana kolejność faz i przesunięcie kątowe (120°).
-

¹ Politechnika Wrocławska, Wydział Elektryczny, Instytut Podstaw Elektrotechniki i Elektrotechnologii, Wybrzeże Wyspiańskiego 27, 50-370 Wrocław, tel. 0713202901, e-mail: przemyslaw.janik@pwr.wroc.pl

Wszystkie zjawiska, które powodują, że sygnał napięciowy nie spełnia powyższych założeń będą postrzegane jako zakłócenia jakości energii.

Coraz większa ilość gromadzonych danych pomiarowych obciąża do poszukiwania nowych i udoskonalania istniejących zastosowań metod sztucznej inteligencji do automatycznej klasyfikacji zakłóceń.

2 SIECI NEURNOWE TYPU SVM

Sieci neuronowe SVM są innowacyjną metodą rozwiązania problemu uczenia sieci neuronowej z nauczycielem. Jednym z ważniejszych problemów uczenia tego rodzaju sieci jest taki dobór wag, który gwarantuje osiągnięcie minimum globalnego funkcji celu a jednocześnie pozwala sterować stopniem złożoności sieci dla osiągnięcia lepszych własności generalizacyjnych. Metoda zaproponowana po raz pierwszy przez Vapnika [13], sprowadza problem uczenia do zagadnienia programowania kwadratowego z ograniczeniami liniowymi i gwarantuje uzyskanie minimum globalnego funkcji.

Metoda uczenia sieci SVM polega na maksymalizowaniu marginesu pomiędzy danymi (1) należącymi do dwóch różnych klas

$$(x_i, d_i)$$

gdzie x_i - wektor wejściowy, d_i - wartość zadana (klasa).

Sieci SVM należą do grupy sieci jednokierunkowych, posiadają dwie warstwy, wykorzystują różne funkcje aktywacji: wielomianową, liniową, radialną, sigmoidalną

Dla par (1), separowalnych liniowo, hiperpłaszczyzna separująca ma postać [9]

$$g(x) = w^T x + b = 0$$

Hiperpłaszczyznę separującą uważa się za optymalną, gdy margines separacji pomiędzy dwoma grupami jest największy (spełnia warunek (3))

$$\min_w \phi(w) = \frac{1}{2} w^T w$$

przy uwzględnieniu

$$d_i (w^T x_i + b) \geq 1$$

Jest to problem programowania kwadratowego z liniowymi ograniczeniami względem wag. Rozwiązanie jego można otrzymać metodą mnożników Lagrange'a, przez minimalizację tzw. funkcji Lagrange'a.

$$J(w, b, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^p \alpha_i [d_i (w^T x_i + b) - 1]$$

Jeżeli dwie klasy nie są liniowo separowalne, to wzory (3) oraz (4) mają inną postać

$$\min_w \phi(w, \xi) = \frac{1}{2} w^T w + C \sum_{i=1}^p \xi_i, \quad \xi_i > 0$$

$$d_i (w^T x_i + b) \geq 1 - \xi_i$$

gdzie ξ jest tak zwaną zmienną wypełniającą.

W tym przypadku sieć SVM przenosi wektory wejściowe do przestrzeni o większej liczbie wymiarów, za pomocą przekształcenia nieliniowego. Tam konstruowana jest optymalna hiperpłaszczyzna.

Na dobre właściwości sieci SVM jako klasyfikatora wskazują wyniki wcześniejszych badań [10, 12].

3 SIECI RBF

Sieci neuronowe o radialnych funkcjach bazowych (radial basis function networks) cechują dobre właściwości klasyfikacyjne potwierdzone wynikami klasyfikacji różnych wzorców [5]. Dokonują one podziału przestrzeni za pomocą hipersfer, a nie płaszczyzny, jak w przypadku sieci klasycznych z propagacją wsteczną błędów. Wyniki otrzymane za pomocą sieci SVM zostały porównane z wynikami klasyfikatora opartego na sieci RBF.

4 PODSTAWOWE KLASY ZAKŁÓCEŃ

Trenowanie i testowanie klasyfikatora wymagało użycia sygnałów napięciowych, trójfazowych, charakterystycznych dla poszczególnych klas zakłóceń. Wykonano badania parametryczne, pozwalające na stopniowe zmiany parametrów danego zakłócenia. Badania obejmowały sześć kategorii zakłóceń: czysta sinusoida, zapad napięcia, przepięcie, sygnał z harmonicznymi, migotanie napięcia oraz drgania oscylacyjne. Klasy zakłóceń, opisane równaniami parametrycznymi, zebrane zostały w tabeli 1.

Tab. 1. Równania opisujące sygnały zakłócone (jedna faza)

Zjawisko	Równanie
Czysta sinusoida	$v(t) = \sin(\omega t)$
Zapad napięcia	$v(t) = A(1 - \alpha(u(t_1) - u(t_2))) \sin(\omega t)$
Przepięcie	$v(t) = A(1 + \alpha(u(t_1) - u(t_2))) \sin(\omega t)$
Harmoniczne	$v(t) = A \left(\begin{array}{l} \alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) \dots \\ \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t) \end{array} \right)$
Migotanie napięcia	$v(t) = A(1 + \alpha \sin(\beta \omega t)) \sin(\omega t)$
Drgania oscylacyjne	$v(t) = A \left(\sin(\omega t) + \alpha \exp^{-(t-t_1)/\tau} \sin(\omega_n(t-t_1)) \right)$

W czasie badań parametry zakłóceń zamieniane były w szerokim zakresie, zakresy zmian przedstawia tabela 2.

Tab. 2. Zakres zmian parametrów symulowanych przebiegów

Zjawisko	Zmiany parametrów
<i>Czysta sinusoida</i>	<i>wszystkie parametry stałe</i>
<i>Zapad napięcia</i>	<i>długość 0-9T, amplituda 0.3,-0.8 pu</i>
<i>Przepięcie</i>	<i>długość 0-8T, amplituda 0.3,-0.7 pu</i>
<i>Harmoniczne</i>	<i>rzęd - 3,5,7, amplituda 0-0.9 pu</i>
<i>Migotanie napięcia</i>	<i>częstotliwość 0.1-0.2 pu, amplituda 0.1-0.2 pu</i>
<i>Drgania oscylacyjne</i>	<i>stała czasowa 0.008-0.04 s, okres 0.5-0.125 pu</i>

Sygnal trójfazowy poddawany był przekształceniu do postaci wektora przestrzennego wirującego i w takiej formie podawany na wejście klasyfikatora.


5 WYNIKI BADAŃ SYMULACYJNYCH

Wszystkie sygnały wykorzystane w badaniach miały znormalizowaną amplitudę – 1 pu (per unit). Częstotliwość sygnału wynosiła 50 Hz. Długość okna pomiarowego, to 9 okresów. Sygnal był próbkowany z częstotliwością 5 kHz, co odpowiada 100 próbkom w okresie. W ten sposób utworzono wektor wejściowy zawierający 900 próbek.

Dla każdej klasy zakłóceń zostało wygenerowanych 50 różnych przebiegów (wektorów). Dziesięć z nich, wybranych losowo, służyło do trenowania klasyfikatora SVM, pozostałe były użyte do testowania.

W celu uzyskania wyraźniejszego wzorca dla każdej z klas sygnał trójfazowy został przekształcony do postaci wektora przestrzennego [8].

Rys. 1a przedstawia przykładowo drgania oscylacyjne o okresie 8 ms i stałej czasowej zanikania 11,2 ms. Drgania oscylacyjne są również wyraźnie widoczne na trajektorii wektora przestrzennego, przedstawionej na rys. 1b. Klasyczną przyczyną powstawania drgań oscylacyjnych jest załączanie baterii kondensatorów kompensujących.



Rys. 1. Drgania oscylacyjne (a) i trajektoria wektora przestrzennego (b)

Tabele 3 i 4 przedstawiają wyniki klasyfikacji sieci RBF i SVM. Ukazują przypadek, dla którego 10 spośród wygenerowanych 50 wektorów było wektorami treningowymi, pozostałe testowymi. Zakres zmian parametrów generowanych sygnałów zawarty jest w tabeli 2. Sygnał treningowy i testowy zawierał 5% szumu.

Wyniki z poniższej tabeli powinny być interpretowane następująco. Kolumna oznacza daną klasę. Jeżeli została ona przez klasyfikator rozpoznana bezbłędnie, to w wierszu o tej samej nazwie pojawia się 1. W przypadku błędnej klasyfikacji danej klasy (wiersza), kolejne liczby w wierszu wyrażają, do jakich innych klas zostały przyporządkowane wektory. Jest to ułamek wyrażający stosunek liczby wektorów błędnie zakwalifikowanych do danej klasy, do całkowitej liczby wektorów testowych.

Tab. 3. Wyniki klasyfikacji zakłóceń dla sieci typu SVM i RBF

	Sieć SVM						Sieć RBF					
	SIN	PRZ	FLI	HAR	OSC	ZAP	SIN	PRZ	FLI	HAR	OSC	ZAP
SIN	1.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0
PRZ	0.025	0.975	0.0	0.0	0.0	0.0	0.300	0.700	0.0	0.0	0.0	0.0
FLI	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0
HAR	0.025	0.0	0.0	0.975	0.0	0.0	0.025	0.0	0.0	0.975	0.0	0.0
OSC	0.0	0.0	0.0	0.0	1.0	0.0	0.375	0.0	0.0	0.0	0.625	0.0
ZAP	0.025	0.0	0.0	0.0	0.0	0.975	0.28	0.0	0.0	0.0	0.0	0.72

6 PODSUMOWANIE

Klasyfikator oparty na sieci neuronowej typu SVM, zastosowany do klasyfikacji zakłóceń sygnałów elektrycznych, wykonał postawione przed nim zadanie poprawnie. Wyniki klasyfikacji różnych zakłóceń są nieco lepsze niż dla sieci RBF.

Poprawne wyniki uzyskane dla sygnałów generowanych na podstawie równań matematycznych zachęcają do przeprowadzenia badań z sygnałami pochodzącymi z symulacji wybranych fragmentów systemu elektroenergetycznego.

Duża szybkość algorytmu klasyfikacji pozawala rozważać jego implementację na procesorze sygnałowym.

7 LITERATURA

- 1 Boolean M., H., J.: *Understanding power quality problems: voltage sags and interruptions*, IEEE Press, New York 1999
- 2 Couvreur M.: *Improving the immunity of industrial power electronics against voltage dips*, 11th Int. Conf. on Electricity Distribution (CIRED), 22-26 April 1991. Liege, Belgium
- 3 Englert H.: *Automatische Störereigniserkennung elektrischen Energieversorgungsnetzen* (Dissertation), Shaker Verlag, Aachen 2002
- 4 IEC std., *Voltage dips, short interruptions and voltage variations immunity tests*, IEC Std. 61000-4-11
- 5 Janik P., Łobos T.: Wilbert J. *Application of radial basis function network for identification of radar signal sources*, IC-SPETO 2001, Gliwice-Ustroń, 23-26.05.2001. s. 561-564
- 6 Key T. S.: *Diagnosing power-quality related computer problems*, IEEE Transactions on Industry Application, vol. 15, no. 4, July 1979, pp.381-393
- 7 Lamoree J.: Mueller D., Vinett P. *Voltage sags analysis case studs*, IEEE Transactions on Industrial Applications, vol. 30, no. 4, July 1994, pp.1083-1089
- 8 Łobos T.: *Fast estimation of symmetrical components in real time*, IEE Proceedings-C, 1992, Vol. 139, No. 1, str. 27-30
- 9 Osowski S.: *Sieci neuronowe typu SVM w zastosowaniu do klasyfikacji wzorców*, Przegląd Elektrotechniczny, Nr 2, luty 2002, str 29-36
- 10 Sałat R.: *Zastosowanie sieci neuronowych do diagnostyki układów elektrycznych elektrycznych elektroenergetycznych*, rozprawa doktorska, Warszawa 2002
- 11 Smith J.C., Lamoore J., Vinett P., Duffy T., Klein M.: *The impact of voltage sags on industrial plant loads*, Int. Conf. Power Quality: End-use applications and perspectives (PQA-91), pp. 171-178
- 12 Starzyński J., Osowski S.: Wincenciak S. *Optimal Design in Electromagnetics by Means of Support Vector Machines*, IC SPETO, Gliwice-Niedzica 28-31.05.2003, tom II, str. 489-492

- 13 Vapnik, V. *Statistical learning theory*, Wiley, New York, USA, 1998
- 14 Wang F., Bollen M., H.: J. *Quantifying the potential impacts of Disturbances on Power System Protection*, Developments in Power System Protection, 7th Int. Conf., Amsterdam, 9-12 April 2001, pp. 262-265

APPLICATION OF ARTIFICIAL INTELIGENCE METHODS FOR EVALUATION OF DISTURBANCES IN SUPPLY NETWORKS

This paper presents a new method of disturbance classification using Support Vector Machines (SVM). The growing interest for power quality issues, disturbances sources and end user related topics are described. The idea of space phasor is exploited to extract distinguishing features from three phase voltage signal. Classification results obtained using SVM and RBF neural network are presented and compared. The SVM network turned out to show better classification rates than RBF classifier.