

Zbigniew Plutecki, Politechnika Opolska, Opole
Janusz Lichota, Politechnika Wroclawska, Wroclaw

PROGNOZOWANIE PROCESU STARZENIA SIĘ IZOLACJI MASZYN ELEKTRYCZNYCH NA PODSTAWIE POMIARU *WNZ*

THE AGING PROCESS PREDICTION OF WINDING INSULATION IN ELECTRICAL MACHINES ONE THE BASIS OF MEASUREMENT *PD*

Streszczenie: W artykule pokazano sposób konstrukcji sztucznej sieci neuronowej służącej do prognozowania zachowania się obiektu. Obiektem badań był silnik elektryczny wysokiego napięcia; celem badań było określenie przydatności sztucznych sieci neuronowych do prognozowania emisji wyładowań niepełnych pojawiających się w uzwojeniach izolacji silnika. Zmiennymi wejściowymi do modelu były wielkości pomiarowe: temperatura otoczenia silnika, wilgotność względna i bezwzględna powietrza, natężenie prądu i jego częstotliwość. Uzyskane wyniki badań wskazują, że zaproponowany model neuronowy wykazuje się odchyleniem standardowym wynoszącym $\pm 5\%$ lub $\pm 3\%$ w zależności od wprowadzonych zmiennych. W artykule pokazano również wpływ jakości pomiarów na wynik uczenia sztucznej sieci neuronowej. Ponadto opisano możliwość implementacji zaproponowanego algorytmu w systemach eksperckich służących do monitorowania pracy maszyn elektrycznych krytycznych dla danego obiektu.

Abstract: The article shows how to design artificial neural network for solving a task of prediction of the dynamic behaviour of the process. The process of the research was the high voltage electric motor; the purpose of the research was determination of the usefulness of artificial neural networks to the prediction of partial discharge emissions occurring between motor windings isolation. Input variables to the model were following measurements: an ambient temperature, relative and absolute air humidity, current and its frequency. The obtained results indicate that the proposed neural model has a standard deviation of $\pm 5\%$ or $\pm 3\%$ depending on input variables. The article also shows the influence of the quality of measurements on the result of learning of artificial neural network. The implementation of the proposed algorithm in expert systems serving for monitoring of the work of the critical drives were additionally described.

Słowa kluczowe: *maszyny elektryczne, izolacja uzwojeń, sztuczna sieć neuronowa, prognoza emisji wyładowań niepełnych*

Keywords: *electrical machines, winding insulation, artificial neural network, prediction of partial discharge*

1. Wstęp

Intensywnie rozwijająca się technika stwarza możliwości dla rozwoju systemów monitorowania urządzeń podczas ich normalnej pracy [4, 5, 6, 9]. Obecnie w eksploatacji znajduje się kilka rozwiązań opartych na pomiarze emisji *wnz* realizowanych w sposób ciągły podczas pracy maszyn [9,10]. Systemy te pełnią funkcję diagnostyczną, których głównym celem jest śledzenie zmian stanu izolacji uzwojeń. Prowadzony w ten sposób monitoring ułatwia zarządzanie tymi urządzeniami i zmniejsza ryzyko występowania awarii oraz podejmowaniu decyzji wyłączenia maszyny i skierowania jej do remontu.

W skład każdego systemu diagnostycznego do monitorowania wyładowań niepełnych, oprócz urządzeń pomiarowych, wchodzi oprogramowanie komputerowe, za pomocą którego można obserwować wyniki pomiarów, zarzą-

dząć nimi oraz dokonywać analiz. Poziom zaawansowania dostępnych funkcji analitycznych związany jest z oceną zmian właściwości obserwowanej izolacji. Dokonuje się tego na podstawie przebiegów czasowych badanych wielkości, obserwacji położenia i wielkości impulsów *wnz* z uwzględnieniem zmian polaryzacji wyładowań na tle przebiegów rozdzielczo – fazowych napięcia probierczego. Oprogramowanie oferuje również możliwość wyznaczania współczynników korelacji wzajemnej między parametrami eksploatacyjnymi silnika a emisją *wnz*. Dla służb technicznych najważniejszym jednak parametrem kontrolnym jest poziom przyjętych wartości alarmowych. Na obecną chwilę brak jest jasnych kryteriów dla przyjmowania konkretnych wartości alarmowych, natomiast za kluczowe uznaje się rozwiązanie problemu prognozowania emisji *wnz*, a tym

samym procesie starzenia się izolacji uzwojeń w wyniku przemysłowej eksploatacji maszyn elektrycznych na podstawie znajomości obecnego stanu technicznego izolacji oraz przebiegu tych zmian jakie obserwowano w okresie minionym. Biorąc pod uwagę ilość zmiennych parametrów zewnętrznych mających wpływ na procesy starzenia się izolacji oraz brak jednoznacznych zależności opisujących te wpływy na proces starzenia, prognozowanie emisji *wnz* można realizować jedynie metodami przybliżonymi [7, 8, 9, 10].

Wpływ na aktywność *wnz* ma wiele czynników. Do najważniejszych należy zaliczyć m.in. napięcie U , prąd I , częstotliwość f , obciążenie, drgania mechaniczne, temperaturę otoczenia silnika T , wilgotność względną φ i bezwzględną x powietrza, a także przebieg czasowy t wymienionych wyżej zmiennych [7, 8, 9, 10]. Temperatura T oraz wilgotność powietrza φ , x jest wynikiem wymiany ciepła i masy jaka dokonuje się między pracującą maszyną elektryczną, a otaczającym ją środowiskiem. Natężenie prądu I wynika z obciążenia napędu. Z kolei częstotliwość f jest zakłóceniem wnoszonym przez zewnętrzną sieć elektroenergetyczną. Drgania mechaniczne są nieodzowną cechą pracy maszyn wirujących i świadczą o oddziaływaniach dynamicznych jakie powstają w obrębie maszyny i jej posadowienia.

Istnieje możliwość predykcji stanu izolacji uzwojeń silnika poprzez prognozę aktywności *wnz*, zakładając rozkład prawdopodobieństwa zakłóceń z jakimi mamy do czynienia przy badaniu wpływu poszczególnych zmiennych. Do modelowania własności dynamicznych silnika zastosowano sigmoidalne sztuczne sieci neuronowe [1] ze względu na ich zdolność do odtwarzania dowolnej funkcji ciągłej [2].

2. Obiekt badań

Do badań wybrano silnik elektryczny wysokiego napięcia (6kV), prądu przemiennego o mocy 9.0 MW, prądzie 881A przy częstotliwości 50Hz. Klasa izolacji – F, wykonana w technologii *VPI*. Silnik ma konstrukcję zamkniętą z chłodzeniem pośrednim. Pierwszy stopień chłodzenia stanowi powietrze zamknięte w przestrzeni wirnika i stojana, a następnie jest kierowane do lamelowego wymiennika ciepła typu powietrze / woda. Woda chłodząca wymiennik przepływa w sposób wymuszony przez pompy i kierowana jest do chłodnicy wentylato-

rowej, w której następuje rozproszenie energii do otoczenia zewnętrznego.

Silnik pracuje w hali maszyn, w której jest zabudowanych 5 podobnych napędów elektrycznych. Hala jest wyposażona w system wentylacji mechanicznej. W hali jest brak instalacji grzewczej. Wszystkie silniki są chłodzone wodą w układzie zcentralizowanym. Rozpraszanie ciepła następuje w chłodni wentylatorowej zlokalizowanej na zewnątrz budynku.

3. Neuronowy model obiektu

Ilościowy wpływ poszczególnych sygnałów wejściowych \mathbf{u} na sygnały wyjściowe \mathbf{y} opisano funkcją:

$$\mathbf{y} = f(\mathbf{u}) \quad (1)$$

którą można ocenić badając funkcję f w całej dziedzinie U

$$f(\mathbf{u}), \mathbf{u} \in U \quad (2)$$

i wyznaczając pochodną tej funkcji

$$\frac{\partial f}{\partial u_i} \quad (3)$$

Względną „siłę” sygnału wyraża stosunek pochodnych

$$\frac{\partial f}{\partial u_i} : \frac{\partial f}{\partial u_j} \quad (4)$$

który oznacza sygnał wejściowy statyczny \mathbf{u} lub dynamiczny opisany funkcją czasu $\mathbf{u}(t)$. Model obiektu $f(\mathbf{u})$ oparty o sztuczne sieci neuronowe ma postać

$$\mathbf{y}_2 = \Gamma_2(\mathbf{W}_2 \Gamma_1(\mathbf{W}_1 \mathbf{u}_o + \mathbf{b}_1) + \mathbf{b}_2) \quad (5)$$

i jest on uzyskiwany w wyniku eksperymentu biernego lub czynnego [3]. Macierze i wektory w równaniu (5) są rozumiane następująco :

- macierze *sigmoidalnych* funkcji aktywacji $S_{1,2}(\cdot)$ warstwy 1, 2 neuronów przyjmujących ważoną sumę wejść $r_{1,2}$ mają postać

$$\Gamma_{1,2}(\cdot) = \begin{bmatrix} S_{1,2}(\cdot) & 0 & \dots & 0 \\ 0 & S_{1,2}(\cdot) & \dots & 0 \\ 0 & 0 & \dots & 0 \\ 0 & 0 & \dots & S_{1,2}(\cdot) \end{bmatrix} \quad (6)$$

$S_1(r_1) = \arctan(r_1)$, $S_2(r_2) = r_2$,

- ważone sumy wejść $r_{1,2}$ są tworzone w oparciu o macierze wag \mathbf{W}_1 , \mathbf{W}_2 i wektory \mathbf{b}_1 , \mathbf{b}_2 przesunięć sygnałów wyjściowych z neuronów poprzedniej warstwy,

- wektor wyjścia y_2 zawiera w sobie informację o emisji wyładowań niezupełnych,
- wektor wejść do sieci neuronowej u_0 składa się z sygnałów pomiarowych.

Zwykle nie zachodzi równość pomiędzy własnościami obiektu i jego modelem

$$f(\mathbf{u}) \neq \mathbf{y} \quad (7)$$

dlatego, że nie ma wszystkich zmiennych u wpływających na obiekt w postaci dostępnej pomiarowo, są natomiast zmienne tworzące pewien podzbiór właściwy zbioru U wszystkich zmiennych rozpinających przestrzeń wektorową sterowań obiektu

$$\tilde{U} \subset U \quad (8)$$

Wymiar przestrzeni \tilde{U} jest wówczas mniejszy niż wymiar przestrzeni U

$$\text{rank } \tilde{U} < \text{rank } U \quad (9)$$

Jakość uzyskanego modelu neuronowego obiektu dla sygnałów $\mathbf{u} \in \tilde{U}$ może być oceniana przez

$$J = \frac{1}{2} \boldsymbol{\varepsilon}^T \boldsymbol{\varepsilon} = \frac{1}{2} (\mathbf{y}^T \mathbf{y} - 2\mathbf{y}^T \mathbf{f} + \mathbf{f}^T \mathbf{f}) < \boldsymbol{\varepsilon}_0 \quad (10)$$

przy czym błąd uczenia $\boldsymbol{\varepsilon}$ jest różnicą pomiędzy sygnałem wyjściowym z sieci neuronowej $\mathbf{y} = S(\mathbf{r})$, a sygnałem nauczyciela $\mathbf{f}(\mathbf{u})$

$$\boldsymbol{\varepsilon} = \mathbf{y} - \mathbf{f} \quad (11)$$

Kryterium musi posiadać założoną dokładność $\boldsymbol{\varepsilon}_0$ dla zastosowań praktycznych. Jeżeli zachodzi warunek

$$J > \boldsymbol{\varepsilon}_0 \quad (12)$$

to wówczas zachodzi korekcja macierzy \mathbf{W} i wektora \mathbf{b} . Ma to miejsce w przypadku zmian własności obiektu np. starzenia się izolacji silnika. Sztuczna sieć neuronowa modelująca silnik adaptuje się do nowych własności obiektu korygując swoje wagi.

4. Wyniki badań i ich analiza


Pomiaru emisji *wnz* oraz wybranych wielkości mikroklimatu dokonano z wykorzystaniem systemu monitorowania *on-line*, w skład którego wchodzi: moduł pomiarowy, 3 kondensatory sprzęgające o pojemności 80pF każdy, 6 czujników RTD współpracujących z termorezystorami Pt100 zamontowanymi w uzwojeniach stojanów oraz 1 czujnik temperatury powietrza i 1 czujnik wilgotności względnej powietrza

[9]. Urządzenie pomiarowe posiada ponadto 1 kanał szumów i 2 dodatkowe kanały, które wykorzystano do pomiaru natężenia prądu i napięcia. Wszystkie kanały są izolowane, posiadają zabezpieczenia przepięciowe oraz filtry górnych częstotliwości. Przyrząd rejestruje impulsy o częstotliwości w zakresie 1MHz ÷ 20MHz [9, 10].

System pomiarowy pozwolił na pomiar następujących parametrów wyładowań niezupełnych: aktywności wyładowań przy danej polaryzacji impulsów zorientowanej w przebiegu fazowym napięcia, intensywności wyładowań (PDI), amplitudy wyładowań (Q_{\max}), liczby impulsów wyładowań w ciągu 1 sekundy (PPS).

Za kluczowe dla bezawaryjnej pracy silnika uznaje się rozwiązanie problemu prognozowania emisji *wnz*, a tym samym procesu starzenia się izolacji uzwojeń, w wyniku przemysłowej eksploatacji maszyn elektrycznych na podstawie znajomości obecnego stanu technicznego izolacji oraz przebiegu tych zmian jakie obserwowano w okresie minionym. Biorąc pod uwagę ilość zmiennych parametrów zewnętrznych mających wpływ na procesy starzenia się izolacji oraz brak jednoznacznych zależności opisujących te wpływy na proces starzenia, prognozowanie emisji *wnz* można realizować jedynie metodami przybliżonymi [9]. Dokonując przeglądu metod, które mogą realizować tak określone zadanie oraz wykorzystując własne doświadczenia, proponuje się wykorzystać do tego celu sztuczne sieci neuronowe (SSN).

Ilość wyładowań niezupełnych w silniku została zamodelowana jednokierunkową siecią neuronową składającą się z trzech warstw: wejściowej, ukrytej i wyjściowej na podstawie danych rejestrowanych co 6 godzin. Strukturę sieci neuronowej przedstawiono na rysunku 1.



Rys. 1. Struktura SSN – jednokierunkowa, wielowarstwowa u_1 - czas t , u_2 - temperatura T , u_3 - prąd I (obciążenie silnika), u_4 - wilgotność względna φ , u_5 - wilgotność x , u_6 - częstotliwość f

Sieć ma 19 neuronów wejściowych służących jedynie do wprowadzenia sygnałów, 6 neuronów w warstwie ukrytej z funkcją aktywacji $S(\cdot) = \arctan(\cdot)$ i 1 neuron liniowy w warstwie

wyjściowej. Wektor sygnałów wejściowych zawiera pomiary z bieżącej chwili t

$$u_i(t), i=1...6,$$

oraz pomiary pochodzące z dwóch poprzednich chwil czasu $t-1$, $t-2$

$$u_i(t-1), u_i(t-2), i=1...6, t-1 = 6h, t-2 = 12h.$$

Dodatkowo w wektorze sygnałów wejściowych znajduje się liczba emisji w_{nz} z poprzedniej chwili czasu $y(t-1)$ tj. sprzed 6 godzin. Powodem umieszczenia tej zmiennej w wektorze wejściowym jest to, że zawiera ona wszystkie zmienne wpływające na proces, także te które nie są mierzone. Pierwszy etap tworzenia modelu polegał na uczeniu sieci neuronowej. Wykorzystano do tego celu część zgromadzonych 4-letnich wyników pomiarowych pochodzących z badań emisji w_{nz} silnika. Liczba próbek uczących wynosiła 1000, co odpowiada 6000 h lub 250 dni. Uczenie prowadzono w kilku wariantach. Warstwa wejściowa miała zmienną liczbę sygnałów wynoszącą 6 lub 7, co posłużyło do sprawdzenia, które z tych sygnałów najbardziej wpływają na model silnika. W pierwszej kolejności uwzględniono wyniki pomiarów temperatury $u_2=T$, wilgotności względnej powietrza $u_4=\varphi$, wilgotności bezwzględnej $u_5=x$ oraz obciążenia silnika $u_3=I$. Struktura wektora wejściowego była następująca

$$\mathbf{u}=[u_1(i) \ u_2(i) \ u_3(i) \ u_4(i) \ u_5(i) \ y(t-1)]; i=t, t-1, t-2 \quad (1)$$

W kolejnej wersji obliczeń powiększono liczbę neuronów wejściowych o częstotliwość napięcia $f=u_6$ uzyskując wektor

$$\mathbf{u} = [u_1(i) \ u_2(i) \ u_3(i) \ u_4(i) \ u_5(i) \ u_6(i) \ y(j)] \quad (2)$$

W warstwie wyjściowej zdefiniowano jeden neuron $y(t)$ odpowiadający wskaźnikowi liczby wyładowań niepełnych Q_{max} . Liczba neuronów w warstwie ukrytej została dobrana metodą prób i błędów, gdyż niestety nie ma łatwej metody na dobranie optymalnej liczby neuronów. Zawsze istnieje możliwość, że zastosowana liczba neuronów może prowadzić do zbyt daleko idących uproszczeń, gdy liczba neuronów jest za mała, lub nastąpi uzyskanie efektu „przeuczenia” sieci, gdy neuronów jest zbyt dużo. Ta ostatnia sytuacja może prowadzić do tego, że SSN zostanie wyuczona do rozpoznawania specyficznych cech właściwych tylko dla tych konkretnych danych. Ostatecznie do dalszych badań przyjęto sześć neuronów w war-

stwie ukrytej. Sam proces uczenia sieci polega na ciągłym dobieraniu współczynników wag tak, aby wartości y na wyjściu SSN odpowiadały wartościom wyjściowym z pliku uczącego zawierającego pomiary czyli funkcję $f(\mathbf{u})$. Sieć była uczona metodą *Levenberga-Marquarta*. Po zakończeniu procesu uczenia otrzymano macierze współczynników wag dla pierwszej \mathbf{W}_1 (6x19), \mathbf{b}_1 (6x1) i drugiej warstwy \mathbf{W}_2 (1x6), \mathbf{b}_2 (1x1). Obliczenia wykonano z wykorzystaniem pakietu *SimulinkMatlab*. Macierze wag sztucznej sieci neuronowej tworzące parametry najlepszego modelu (5) dającego błędy +/- 3% pokazano poniżej.

Przykładowe wyniki obliczeń uzyskane w procesie uczenia SSN na danych historycznych oraz wynik testu działania SNN na 400 wektorach danych niewidzianych przez SNN przedstawiono na rysunku 2. Linią niebieską oznaczono wyniki pomiarów, a zielonymi kropkami wartości uzyskane na drodze obliczeń SSN. Dla porównania przedstawiono dwa warianty obliczeń, wykonane przy 5 i 6 parametrach wejściowych. W celu oceny jakościowej działania SSN podano dla nich wykresy uśrednionego błędu kwadratowego, który wyznaczono jako wartość średnią z kwadratów różnic pomiędzy wartością wygenerowaną przez SSN, a rzeczywistą pochodzącą z pomiarów. Uzyskane wyniki w obu wariantach są zadowalające. W pierwszym przypadku średni błąd kwadratowy wynosił przeciętnie +/-5% dla danych z wektora (13), w drugim +/-3% dla innej struktury sieci dla danych z wektora (14). Wartości obliczone w pierwszym wariantcie są nieco gorsze. Ilość zielonych punktów (odpowiedź sieci) nie pokrywających się z przebiegiem wartości zmierzonych jest większa. Uwzględnienie na wejściu SSN dodatkowego parametru – częstotliwości f , mimo bardzo niewielkich zmian częstotliwości, pozwoliło znacznie poprawić efekt prognozowania. Poprawa jakości prognozowania wskaźnika Q_{max} nie jest jednak w stanie zagwarantować poprawności działania w sytuacjach ponadstandardowych. Zakreślony na rysunku 6d obszar oznaczony literą A dowodzi o istnieniu innych przyczyn wyładowań niepełnych aniżeli te, które wykorzystano w procesie uczenia. W świetle już wcześniej przedstawianych analiz, bardzo jest prawdopodobne, że przyczyną wystąpienia różnic jest brak pomiaru któregoś z parametrów drgań mechanicznych.

$$\mathbf{W}_1^T = \begin{bmatrix} -0.66 & -9.09 & -0.05 & -0.5 & 3.91 & 4.24 \\ 8.79 & -8.58 & 0.69 & 0.53 & -5.76 & -6.12 \\ 39.7 & 4.7 & 2.3 & 2.78 & 0.49 & 0.41 \\ -49.8 & -5.74 & -1.46 & 1.4 & -3.23 & -0.11 \\ -25.9 & -9.84 & 3.85 & -0.42 & -11.1 & -15.8 \\ -8.48 & 0.36 & 0.23 & 1.72 & 1.51 & 1.71 \\ 31.2 & 1.99 & -0.05 & -1.95 & 1.07 & 1.24 \\ 11.6 & 19.6 & 0.45 & 6.94 & 5.74 & 5.98 \\ 4.01 & -15.3 & -1.57 & -9.78 & 13.5 & 14.5 \\ -6.72 & 12.7 & 1.73 & 7.76 & 7.99 & 4.11 \\ 13.4 & -41.6 & -4.15 & -23.3 & -5.12 & 1.88 \\ -5.32 & -3.84 & -0.05 & -0.57 & 1.12 & 1.15 \\ -28.8 & -2.06 & -0.38 & -2.01 & 1.43 & 1.54 \\ 13.9 & 3.65 & -0.47 & -3.33 & -0.01 & -0.24 \\ -1.08 & -4.49 & 0.78 & 6.61 & -7.73 & -7.81 \\ 80.2 & 41.7 & 1.44 & 12.2 & 11.5 & 9.94 \\ 42.9 & -34.4 & -2.16 & -16.7 & 2.64 & 4.48 \\ 2.23 & 0.42 & -0.07 & -0.37 & -0.89 & -0.87 \\ 26.8 & 0 & -0.29 & 5.64 & 3.33 & 3.54 \end{bmatrix}$$

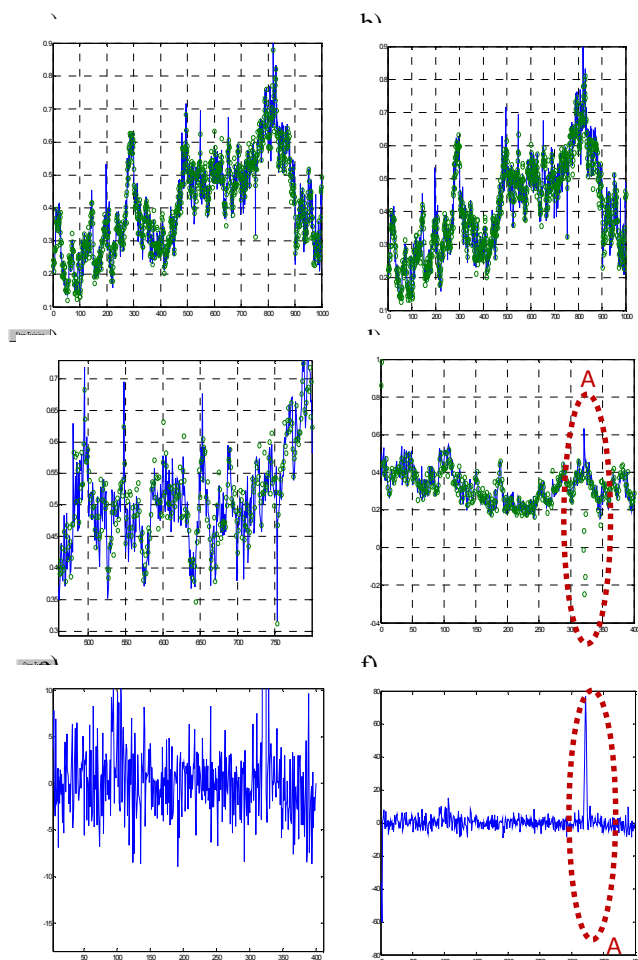
$$\mathbf{b}_1 = \begin{bmatrix} -66.95 \\ 19.61 \\ -1.56 \\ -0.17 \\ -7.99 \\ -9.05 \end{bmatrix} \quad \mathbf{W}_2^T = \begin{bmatrix} 0.05 \\ -0.10 \\ -0.61 \\ 0.08 \\ -7.42 \\ 7.15 \end{bmatrix}$$

$$\mathbf{b}_2 = \begin{bmatrix} 0.55 \end{bmatrix}$$

5. Koncepcja rozbudowy systemów do monitorowania aktywności wnz

Na podstawie zgromadzonej wiedzy z zakresu funkcjonowania istniejących systemów do monitorowania emisji wnz oraz doświadczeń zdobytych podczas realizacji własnych badań [9], można sugerować rozbudowę obecnych systemów o nowe elementy. Pierwszym elementem jest rozbudowa infrastruktury pomiarowej. Zdaniem autorów powinna ona objąć:

- czujniki do pomiaru temperatury i wilgotności powietrza w ilości pozwalającej na śledzenie zmian mikroklimatu w pomieszczeniu pracujących maszyn;
- czujniki do pomiaru temperatury, wilgotności i prędkości powietrza przewidziane do zabudowy w kanałach wentylacyjnych w celu wyznaczania i kontrolowania skuteczności działania układu chłodzenia;
- czujniki do pomiaru drgań mechanicznych obudowy stojana; pomiar ten pozwoli śledzić w dłuższym horyzoncie czasowym wpływy wibracji na aktywność wnz.



Rys. 2. Ocena działania SSN: a) i b) wyniki procesu uczenia SSN na danych historycznych przy 6 i 7 parametrach wejściowych, c) i d) wynik testu działania SNN na danych niewidzianych przez SNN dla obu przypadków, e) i f) wykres błędów.

Realne zwiększenie liczebności czujników pomiarowych w systemie winno wynikać z warunkowań techniczno-ekonomicznych określonych dla konkretnego obiektu indywidualnie.

Drugim elementem jest rozszerzenie funkcji analitycznych oprogramowania komputerowego o narzędzia do oceny wpływu mikroklimatu na emisję wnz. Funkcje te powinny umożliwiać przede wszystkim:

- wyznaczanie optymalnych warunków mikroklimatycznych dla komfortowej pracy maszyn elektrycznych z uwzględnieniem postępującego procesu starzenia się izolacji,
- wyznaczanie krzywych starzenia się izolacji dla uzwojeń każdej z faz oddzielnie, z uwzględnieniem poprawki wynikającej ze zmian mikroklimatu,

- prognozowanie przebiegu procesu starzenia się izolacji w oparciu o gromadzoną bazę danych i uzupełnianą na bieżąco bazę wiedzy oraz poprzez zastosowanie modułu wnioskującego, posiadającego procedury objaśniające.

Współczesna aplikacja diagnostyczna winna zawierać moduły funkcjonalne pozwalające na:

- szerszą niż obecnie interpretację danych pomiarowych;
- dokonywanie prognozy zdarzeń w najbliższej i dłuższej perspektywie czasowej;
- ocenę diagnostyczną w zakresie wykrywania uszkodzeń i utrzymywania zdolności produkcyjnej;
- planowanie rutynowych czynności serwisowych oraz okresowych napraw i remontów;
- monitorowanie procesów w sposób ciągły z dynamicznym doborem częstotliwości dokonywania pomiarów;
- sterowanie urządzeniami pomocniczymi mających wpływ na pracę danej maszyny;
- instruowanie obsługi w zakresie podejmowania czynności i decyzji.

6. Podsumowanie

W artykule pokazano sposób tworzenia modelu wyładowań niezupełnych silnika elektrycznego w oparciu o sztuczne sieci neuronowe. Model został utworzony mając czteroletnie dane z eksperymentu biernego obejmujące między innymi pomiar temperatury otoczenia silnika, wilgotności względnej powietrza, prądu, częstotliwości prądu oraz liczbę wyładowań niezupełnych. Rejestrowany był również czas pomiaru. Średni błąd popełniany przez model wynosi $\pm 3\%$.

Opracowany i przetestowany model można zastosować do przewidywania liczby wyładowań niezupełnych w izolacji uzwojeń stojana silnika i dzięki temu wykorzystać do sterowania parametrami powietrza w pomieszczeniu tak, aby zminimalizować emisję wzn i ochronić w ten sposób silnik przed awarią, a przede wszystkim wydłużyć czas jego pracy.

7. Literatura

- [1]. Żurada J., Barski M., Jędruch W. : *Sztuczne sieci neuronowe*, Wydawnictwo Naukowe PWN, Warszawa 1996.
- [2]. Cybenko., G., *Approximations by superpositions of sigmoidal functions*, *Mathematics of Control, Signals, and Systems*, 2 (4), 303-314, (1989)
- [3]. Budnicki Z.: *Identyfikacja obiektów sterowania*, PWN, Warszawa 1974.

[4]. Budzianowski W. M., *Experimental and numerical study of recuperative heat recirculation*, *Heat Transfer Engineering*, 33:8, 712-721, 2012.

[5]. Halicka K., *Wykorzystanie sztucznych sieci neuronowych do prognozowania cen na giełdzie energii*, *Rynek Energii* nr 1/2010.

[6]. Chmielnicki W. J., *Algorytmy wykorzystujące sieci neuronowe do regulacji węzłów ciepłowniczych*, *Rynek Energii*, 12/2010.

[7]. Plutecki Z., Szymaniec S.: *Pomiary i monitoring stanu izolacji uzwojeń maszyn elektrycznych w przemyśle - doświadczenia własne*. *Zeszyty Problemowe - Maszyny Elektryczne*, Nr 89 (1/2011), 2011, s. 33-38.

[8]. Plutecki Z.: *Analiza zjawisk cieplno-przepływowych kształtujących się w otoczeniu pracujących maszyn elektrycznych*, *Zeszyty Problemowe - Maszyny Elektryczne*, Nr 96 (3/2012), 2012 r., s.19-24.

[9]. Plutecki Z.: *Analiza wpływu mikroklimatu na emisję wyładowań niezupełnych maszyn elektrycznych w warunkach przemysłowej eksploatacji*. *Studia i Monografie z.325*. Wydawnictwo Politechniki Opolskiej, Opole 2012.

[10]. Szymaniec S.: *Diagnostyka stanu izolacji uzwojeń i stanu łożysk silników indukcyjnych klatkowych w warunkach przemysłowej eksploatacji*. *Studia i Monografie z. 193*, Wydawnictwo Politechniki Opolskiej, Opole 2006.

Autorzy

dr inż. Zbigniew Plutecki
Politechnika Opolska
Wydział Elektrotechniki, Automatyki
i Informatyki. Instytut Elektrotechniki Przemysłowej i Diagnostyki, 45-758 Opole
ul. Prószkowska 76, z.plutecki@po.opole.pl

dr inż. Janusz Lichota
Politechnika Wrocławska
Wydział Mechaniczno-Energetyczny
Instytut Inżynierii Lotniczej, Procesowej i Maszyn Energetycznych, 50-370 Wrocław
ul. Wybrzeże Wyspiańskiego 27
janusz.lichota@pwr.wroc.pl