

Adam Kurnicki*, Waldemar Wójcik**

Diagnostyka układów wykonawczych maszyny papierniczej z użyciem metod sztucznej inteligencji

1. Wprowadzenie

Rosnącej złożoności nowoczesnych systemów przemysłowych, urządzeń technicznych, obiektów i linii technologicznych towarzyszy stawianie coraz większych wymagań niezawodnościowych, wydajnościowych, jakościowych i bezpieczeństwa pracy [4, 5]. Wymagania te podyktowane są w głównej mierze względami ekonomicznymi.

W większości dużych przedsiębiorstwach przemysłu energetycznego i chemicznego zainstalowane zostały nowoczesne systemy automatyki takie jak: zdecentralizowane systemy sterowania DCS oraz systemy sterowania i wizualizacji SCADA. Te ostatnie, poprzez implementacje różnego rodzaju algorytmów alarmowania, wpływają w znacznym stopniu na poprawę warunków bezpieczeństwa pracy maszyn i urządzeń. Zwiększenie niezawodności oraz dalszą poprawę bezpieczeństwa uzyskuje się, wdrażając aplikacje diagnostyki procesów przemysłowych, na które w ostatnich latach stale rośnie zapotrzebowanie. Zapotrzebowanie na te układy wynika również z faktu coraz powszechniejszego stosowania przez zakłady produkcyjne układów sterowania tolerujących uszkodzenia [4], gdzie wymagane jest jak najwcześniejsze wykrycie stanów prowadzących do awarii.

We współcześnie prowadzonych pracach badawczych w dziedzinie sterowania i diagnostyki procesów przemysłowych odnotować należy ogromną (dynamicznie wzrastającą) ilość zastosowań metod sztucznej inteligencji (AI – *Artificial Intelligence*) [2, 4–6]. Do metod tych bez wątpienia zaliczyć należy systemy ekspertowe oraz logikę rozmytą, sztuczne sieci neuronowe i algorytmy genetyczne.


Autor pracy, wychodząc naprzeciw zapotrzebowaniom oraz trendom panującym w pracach badawczych, zaprojektował we współpracy z Instytutem Papiernictwa i Poligra-

* Katedra Automatyki i Metrologii, Politechnika Lubelska w Lublinie

** Katedra Elektroniki, Politechnika Lubelska w Lublinie

fii Pł, system ekspertowy do diagnostyki procesu wytwarzania papieru. Zadaniem tego systemu jest dostarczanie obsłudze informacji diagnostycznej na temat stanu technicznego najważniejszych elementów maszyny papierniczej oraz podejmowanie odpowiednich decyzji sterujących [5]. Serce systemu stanowią algorytmy detekcji i lokalizacji uszkodzeń. W grupie wykrywanych i lokalizowanych uszkodzeń, oprócz klasycznych uszkodzeń mechanicznych elementów maszyny oraz torów pomiarowych, istotne znaczenie mają uszkodzenia elementów wykonawczych układów automatyki.

Do detekcji uszkodzeń stosowane są modele opisujące diagnozowany proces w stanie normalnym (bez uszkodzeń). Umożliwiają one wyznaczenie residuów odzwierciedlających rozbieżności między obserwowanym funkcjonowaniem obiektu a zachowaniem normalnym określonym modelem. Residua r wyliczane są jako (patrz rys. 1) różnice między sygnałami wyjściowymi z rzeczywistego obiektu (mierzonymi) y i z symulowanego procesu (modelowanymi) \hat{y} .



Rys. 1. Schemat generacji residuów z użyciem modeli procesów

Wartość residuów w stanie bez uszkodzeń powinna oscylować w pobliżu zera. Odbiegające od zera wartości residuów są symptomami uszkodzeń.


W literaturze można odnaleźć wiele modeli urządzeń wykonawczych automatyki, tworzonych z myślą o syntezie układów sterowania [3, 8]. Niestety modele tworzone dla celów syntezy algorytmów sterowania są drastycznie upraszczane i linearyzowane, przez co pomija się w nich wiele cech (właściwości) fizycznych i chemicznych. Przy modelowaniu dla zadań detekcji uszkodzeń wymagana jest większa precyzja (złożoność) modelu [2]. Modele takie powinny uwzględniać nieliniowości oraz niepełność i nieprecyzyjność wiedzy o diagnozowanym obiekcie. Tworzenie modeli uwzględniających powyższe uwarunkowania jest często niezwykle trudne lub wręcz niemożliwe. Pomocne może być tutaj zastosowanie technik modelowania z użyciem metod sztucznej inteligencji, tj. logiki rozmytej i sztucznych sieci neuronowych, gdzie do budowy modelu można bezpośrednio wykorzystać wiedzę ekspertów a dostępne dane pomiarowe do jego uczenia (dostrajania).

Po etapie detekcji przeprowadzana jest lokalizacja uszkodzeń, gdzie w celu poprawy rozróżnialności uszkodzeń [4] oraz uwzględnienia niepewności modelu zastosowana może być również logika rozmyta.

2. Modelowanie układów wykonawczych dla celów detekcji uszkodzeń

Modele używane do detekcji uszkodzeń, w przeciwieństwie do modeli stosowanych do syntezy algorytmów sterowania, nie muszą obejmować całościowo obiektu (procesu) sterowania [2]. Modelowane są tutaj tylko te części procesu (modele częściowe), na zachowanie, których mogą mieć szczególny wpływ wykrywane uszkodzenia. Jako przykład modelowania wybrano układy wykonawcze maszyny papierniczej produkującej papier gazetowy. Opracowano następujące modele częściowe:

- modele zespołów wykonawczych zawór-siłownik-pozycjoner (rys. 2a) dla zaworu masowego i wypełniaczy oraz głównego zaworu pary,
- model układu regulacji szczeliny wpływowej we wlewie (rys. 2b).



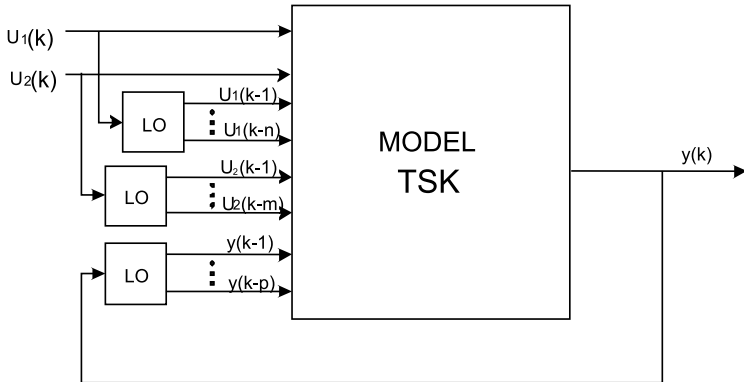
Rys. 2. Wybrane układy wykonawcze maszyny papierniczej: a) zespół zawór-siłownik-pozycjoner; b) układ regulacji szczeliny wpływowej

Przy opracowywaniu powyższych modeli ograniczono się do wykorzystania danych pomiarowych z: bezawaryjnego przebiegu procesu, eksperymentów identyfikacyjnych (tzw. „bump testów”, tj. odpowiedzi skokowych) przeprowadzanych dla celów doboru parametrów układów regulacji oraz wiedzy ekspertów (technologów). Niemożliwe było przeprowadzenie własnych (bardziej zaawansowanych) eksperymentów identyfikacyjnych ze względów ekonomicznych (koszty aparatury pomiarowej oraz straty finansowe wynikłe z produkcji złej jakości papieru i zrywów wstęgi).

2.1. Metodyka modelowania

Modelowanie poszczególnych części maszyny papierniczej przeprowadzono z wykorzystaniem środowiska Matlab-Simulink według ogólnie znanej procedury. Najpierw opracowywana jest struktura modelu. Aby wykorzystać wiedzę ekspertów o modelowanym procesie oraz dostępne dane uczące z przebiegu procesu, do modelowania użyto modełu neuronowo-rozmyte typu Takagi-Sugeno-Kanga (TSK) [7]. Dokonywany jest wybór ilości

wejść, rodzaj i wstępne rozmieszczenie funkcji przynależności dla zmiennych wejściowych oraz baza reguł na podstawie wiedzy o modelowanym procesie. Modele TSK realizują jedynie odwzorowania statyczne. W celu uwzględnienia dynamiki procesu modele te należy wyposażyć w sprzężenia zwrotne od sygnałów wyjściowych oraz linie opóźniające, jak to zostało przedstawione na rysunku 3.



Rys. 3. Modelowanie dynamiki procesów z użyciem modeli TSK

Kolejnym etapem jest przygotowanie danych pomiarowych, które ma na celu wybór odpowiedniego zbioru próbek dla uczenia modelu oraz drugiego zbioru do weryfikacji modelu. Następnie dokonywany jest wybór algorytmu uczenia (wstecznej propagacji lub hybrydowego [7]) oraz przeprowadzany proces strojenia (uczenia) parametrów modelu według schematu przedstawionego na rysunku 4. Proces modelowania kończy się weryfikacją poprawności pracy modelu na drodze symulacyjnej poprzez porównanie sygnałów wyjściowych z modelu z danymi pomiarowymi. Ilościowe określenie jakości modelowania uzyskiwane jest na drodze obliczenia średniego błędu kwadratowego *RMSE* (*Root Mean Square Error*)


$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (\hat{y}(k) - y(k))^2} \quad (1)$$

gdzie:

N – liczba próbek,

$\hat{y}(k), y(k)$ – sygnały wyjściowe odpowiednio symulowane i mierzone w chwili k .

Jeżeli wynik weryfikacji nie jest satysfakcjonujący należy zmienić strukturę modelu poprzez dodanie sygnałów wejściowych (większa liczba linii opóźniających) i zmodyfikować bazę reguł lub/i wybrać inny zbiór danych uczących.



Rys. 4. Schemat uczenia modeli neuronowo-rozmytych

2.2. Modele układów wykonawczych

W celu detekcji uszkodzeń elementów wykonawczych opracowano po trzy rodzaje modeli częściowych zjawisk zachodzących w zaworach regulacyjnych przepływu masy i wypełniaczy oraz głównym zaworze parowym:

Model 1 – model zespołu wykonawczego zawór-siłownik-pozycjoner, opisuje dynamiczne zachowanie się całego zespołu wykonawczego zawór-siłownik-pozycjoner (Z-S-P):

$$F(k+1) = f(U(k), U(k-1), F(k), F(k-1)) \quad (2)$$

$$P_{pary}(k+1) = f(U(k), U(k-1), P_{pary}(k), P_{pary}(k-1)) \quad (3)$$

gdzie:

U – sygnał wejściowy, którym jest tutaj wartość zadana przepływu (2) dla zaworów masowego i wypełniaczy) lub wartość zadana ciśnienia pary (3) dla głównego zaworu parowego,

F – sygnał wyjściowy (2) – rzeczywisty przepływ masy,

P_{pary} – sygnał wyjściowy (3) – ciśnienie pary zasilającej cylindry suszące.

Model 2 – model przemieszczenia trzpienia zaworu, opisany zależnością (4):

$$X(k+1) = f(P(k), P(k-1), X(k), X(k-1)) \quad (4)$$

gdzie:

X – przemieszczenie trzpienia zaworu,

P – ciśnienie powietrza z pozycjonera.

Model 3 – modele zaworów, opisane zależnościami (5) i (6):

$$F(k+1) = f(X(k), X(k-1), F(k), F(k-1)) \quad (5)$$

$$P_{pary}(k+1) = f(X(k), X(k-1), P_{pary}(k), P_{pary}(k-1)) \quad (6)$$

gdzie:

- X – przemieszczenie trzpienia zaworu,
- F – sygnał wyjściowy (2) – rzeczywisty przepływ masy,
- P_{pary} – sygnał wyjściowy (3) – ciśnienie pary zasilającej cylindry suszące.

Przykładowo, dla modelu 1 poddano syntezie i analizie trzy przypadki struktur modeli TSK:

- 4 reguły, po 3 funkcje przynależności dla każdej zmiennej wejściowej,
- 8 reguł, po 5 funkcji przynależności dla każdej zmiennej wejściowej,
- 81 reguł, po 3 funkcje przynależności dla każdej zmiennej wejściowej.

W wyniku przeprowadzenia procesu uczenia z użyciem zbioru ok. 9000 próbek danych pomiarowych dla struktury 1 dostrojono parametry funkcji występujących w następnikach reguł:

R_1 : **JEŻELI** $U(k)$ jest U1MF1 **I** $U(k-1)$ jest U2MF1 **I** $F(k-1)$ jest F1MF1 **I** $F(k-2)$ jest F1MF1
TO $F(k+1) = -3.5 \cdot 10^{-5} + 3.6 \cdot 10^{-4} U(k) + 1.7 U(k-1) - 0.7 F(k-1) - 2.6 \cdot 10^{-4} F(k-2)$,

R_2 : **JEŻELI** $U(k)$ jest U1MF3 **I** $U(k-1)$ jest U2MF3 **I** $F(k-1)$ jest F1MF3 **I** $F(k-2)$ jest F1MF3
TO $F(k+1) = 2.5 \cdot 10^{-4} + 6.2 \cdot 10^{-5} U(k) + 0.75 U(k-1) + 0.2 F(k-1) - 5.2 \cdot 10^{-3} F(k-2)$,

R_3 : **JEŻELI** $U(k)$ jest U1MF2 **I** $U(k-1)$ jest U2MF2 **I** $F(k-1)$ jest F1MF1 **I** $F(k-2)$ jest F1MF1
TO $F(k+1) = -2 \cdot 10^{-4} + 5.2 \cdot 10^{-4} U(k) + U(k-1) - 0.048 F(k-1) + 2.03 \cdot 10^{-5} F(k-2)$,

R_4 : **JEŻELI** $U(k)$ jest U1MF3 **I** $U(k-1)$ jest U2MF3 **I** $F(k-1)$ jest F1MF3 **I** $F(k-2)$ jest F1MF3
TO $F(k+1) = -2.3 \cdot 10^{-4} + 6.2 \cdot 10^{-4} U(k) + 0.92 U(k-1) + 0.08 F(k-1) + 3.9 \cdot 10^{-3} F(k-2)$,

Struktura trzecia złożona z 81 reguł (maks. możliwej liczby reguł w tym przypadku $3 \cdot 3 \cdot 3 = 81$) po procesie uczenia została zmniejszona do 52 reguł (w wyniku pokrywania się niektórych części następnikowych reguł). Wyniki weryfikacji (wykaz błędów średniokwadratowych) dla trzech proponowanych struktur modeli zestawiono w tabeli 1.

Tabela 1
Weryfikacja modeli. Błędy średniokwadratowe poszczególnych struktur

Struktura	RMSE	
	Dane uczące	Dane testujące
1	0,92	1,71
2	0,85	1,65
3	0,82	1,47

Jak łatwo można zauważyć, najmniejsze wartości błędu *RMSE* uzyskano dla struktury 3 (najbardziej rozbudowanej). Wartości tych błędów dla pozostałych struktur nie odbiegają jednak w sposób znaczący od struktury 3. Biorąc pod uwagę fakt, iż dla modelu o strukturze 3 czas trwania uczenia jest znacznie dłuższy niż pozostałych (ok. 12 razy więcej parametrów do strojenia niż dla struktury 1) oraz występuje znacznie dłuższy czas symulacji (w przypadku modelu implementowanego na komputerze PC) i większe koszty realizacji sprzętowej, optymalnym wydaje się zastosowanie struktury 1 do detekcji uszkodzeń zespołu Z-S-P.

3. Lokalizacja uszkodzeń

Lokalizacja uszkodzeń odbywa się na podstawie symptomów diagnostycznych otrzymywanych na podstawie oceny residuów oraz relacji pomiędzy symptomami i uszkodzeniami [4].

Zastosowano dwa typy relacji:

- 1) binarnej macierzy diagnostycznej (związanej z progową oceną residuów),
- 2) systemu informacyjnego FIS (związanego z rozmytą oceną residuów).


Relacje te zostały opracowane na podstawie wiedzy pozyskanej od ekspertów. Tabela 2 przedstawia fragment opracowanej binarnej macierzy diagnostycznej dla zespołu wykonawczego zaworu wypełniaczy.

Tabela 2
Binarna macierz diagnostyczna
dla zespołu wykonawczego zaworu wypełniaczy

		SYMPTOMY		
		S ₄	S ₅	S ₆
USZKODZENIA	f ₁₁	1	0	0
	f ₁₂	1	0	0
	f ₁₃	1	1	0
	f ₁₄	1	0	0
	f ₁₅	1	1	0
	f ₁₆	1	1	0
	f ₁₇	1	1	0

Z tabeli 2 wynika, iż uszkodzenia {f₁₁, f₁₂, f₁₄} oraz {f₁₃, f₁₅, f₁₆, f₁₇} reprezentowane są przez taką samą kombinację symptomów diagnostycznych, co oznacza że są one nie-

rozdzielalne. Poprawę rozróżnialności uzyskano tutaj wprowadzając trójwartościową rozmytą ocenę residuów (rys. 5). Relacje symptomy-uszkodzenia przedstawiono wówczas w postaci systemu informacyjnego FIS [4]. Fragmenty systemu FIS odpowiadające binarnej macierzy diagnostycznej z tabeli 2 prezentuje tabela 3.



Rys. 5. Trójwartościowa rozmyta ocena residuów

Tabela 3

System informacyjny FIS dla zespołu wykonawczego zaworu wypełniaczy

		SYMPTOMY		
		S ₄	S ₅	S ₆
USZKODZENIA	f ₁₁	N	P	P
	f ₁₂	N+	P	P
	f ₁₃	N	N	P
	f ₁₄	N+	P	P
	f ₁₅	N+	N-	P
	f ₁₆	N+	N+	P
	f ₁₇	N	N	P

Dzięki temu zabiegowi uszkodzenia {f₁₁, f₁₂} stały się tylko warunkowo nierozróżnialne, natomiast uszkodzenia {f₁₅, f₁₆} są całkowicie rozróżnialne.

4. Podsumowanie

Opracowane i przedstawione w niniejszym artykule algorytmy detekcji i lokalizacji uszkodzeń układów wykonawczych maszyny papierniczej stanowią część systemu eksperckiego do diagnostyki procesu wytwarzania papieru. Stworzone algorytmy detekcji uszkodzeń wykorzystują metodę opartą na modelu diagnozowanego procesu. Dotychczas opracowane modele układów wykonawczych maszyny papierniczej są niewystarczające dla celów diagnostycznych (zbytne uproszczenie, linearyzacja bądź niemożność symulacji w czasie rzeczywistym). Dlatego zbudowano częściowe modele neuronowo-rozmyte. Zaletą tych modeli jest możliwość połączenia wiedzy eksperckiej oraz dostępnych danych pomiarowych.

Wiedza ekspercka służy do określania struktury oraz początkowych wartości parametrów modelu. Model nie stanowi czarnej skrzynki. Jest on zbiorem reguł, które ekspert może weryfikować i interpretować. Bardzo ważny jest trafny wybór struktury modelu. Arbitralnie dla każdego z modelowanych procesów wybrano strukturę składającą się z modelu Takagi–Sugeno–Kanga i linii opóźniających dla sygnałów wejściowych (modelowanie dynamiki). Natomiast rodzaj i liczba wejść, liczba reguł i funkcji przynależności dla zmiennych wejściowych dobierane były indywidualnie na podstawie pozyskanej wiedzy dotyczącej modelowanych procesów.

Decydujące znaczenie dla późniejszego poprawnego działania modelu ma również dostarczenie odpowiedniej ilości i jakości danych uczących obejmujących cały obszar pracy obiektu. Przy lokalizacji uszkodzeń, reguły bazy wiedzy określające relacje sygnały diagnostyczne – uszkodzenia, uzyskane na podstawie wiedzy eksperckiej, zostały zapisane najpierw w postaci binarnej macierzy diagnostycznej, a następnie w postaci systemu informacyjnego FIS. W tym pierwszym przypadku zastosowano ocenę progową, a w drugim wielowartościową rozmytą ocenę residuów. Badania potwierdziły szereg zalet stosowania drugiej koncepcji.

Zaletą stosowania systemu FIS wraz z rozmytym wnioskowaniem diagnostycznym jest uzyskanie większej rozróżnialności uszkodzeń, w stosunku do algorytmów stosujących binarną macierz diagnostyczną. Zastosowanie logiki rozmytej do oceny wartości sygnałów diagnostycznych umożliwia uwzględnienie ich niepewności przy formułowaniu diagnozy. Zapewnia to większą odporność algorytmu wnioskowania na szumy pomiarowe i zakłócenia niż diagnozowanie na podstawie oceny progowej wartości residuów.

Opracowane algorytmy detekcji i lokalizacji uszkodzeń poddano testom weryfikacyjnym poprzez symulację. Przeprowadzono szereg analiz pracy tych algorytmów z udziałem danych procesowych zarejestrowanych w przypadku: wystąpienia uszkodzeń rzeczywistych, uszkodzeń symulowanych na maszynie oraz danych powstałych w wyniku symulacji uszkodzeń poprzez wprowadzanie zmian wartości zarchiwizowanych zmiennych procesowych. Wyniki tych testów potwierdziły przydatność opracowanych modeli diagnostycznych do detekcji uszkodzeń oraz systemów FIS do lokalizacji uszkodzeń.

Literatura

- [1] Frank P.M., Alcorta Garcia E., Koppen-Seliger B., *Modelling for fault detection and isolation versus modeling for control*. Mathematics and Computers in Simulation, 53, 2000, 259–271.
- [2] Frank P.M., Koppen-Seliger B., *New developments using AI in fault diagnosis*. Engineering Applications Artificial Intelligence, vol. 10, no 1, 1997, 3–14.
- [3] Hauge T.A., Lie B., *Paper machine modeling at Norske Skog Saugbrugs: A mechanistic approach*. Modeling, Identification and Control, 23(1), 2001, 27–52.
- [4] Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W., *Fault diagnosis. Models, artificial intelligence, applications*. Berlin, Springer 2004.
- [5] Kurnicki A., Zieliński T., Krolopp W., *Expert system for paper making process diagnosis*. 1st ICSCCE Conference: “From scientific computing to computational engineering”, Athene, Greece, 2004.
- [6] Piegat A., *Modelowanie i sterowanie rozmyte*. Warszawa, EXIT 1999.
- [7] Rutkowska D., Piliński M., Rutkowski L., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. Warszawa, PWN 1997.
- [8] Rao M., Xia Q., Ying Y., *Modeling and Advanced Control for Process Industries. Application to Paper Making Processes*. London, Springer-Verlag 1994.