

MODEL NEURONOWY LOKALIZACJI USZKODZEŃ POMP WTRYSKOWYCH

Marek Klimkiewicz

Katedra Organizacji i Inżynierii Produkcji, Szkoła Główna Gospodarstwa Wiejskiego w Warszawie

Streszczenie. Do zoptymalizowania procesu wykrywania uszkodzonych elementów w pompach wtryskowych posłużono się metodą sztucznej inteligencji. Zastosowano model neuronowy oparty na probabilistycznych sieciach neuronowych. Za pomocą zbudowanego modelu można zmniejszyć wartość wskaźnika głębokości lokalizacji uszkodzonych elementów. Model neuronowy charakteryzował się bardzo dobrą jakością klasyfikacji uszkodzeń.

Słowa kluczowe: sieci neuronowe, pompa wtryskowa, lokalizacja uszkodzeń

Wprowadzenie i cel pracy

Prawidłowe rozwiązanie problemu lokalizacji uszkodzeń polega na odnalezieniu ścieżki optymalnej pozwalającej dotrzeć do uszkodzenia. Do skutecznego rozwiązania problemu serwisowego potrzeba różnej liczby sprawdzeń zależnie od doświadczenia i posiadanej wiedzy oraz predyspozycji psychofizycznej pracownika, jakości dokumentacji serwisowej, narzędzi diagnostycznych oraz rodzaju usterki. Do lokalizacji uszkodzonych elementów w pompach wtryskowych stosuje się zweryfikowane w praktyce programy lokalizacji, które wraz z dostępnymi na rynku urządzeniami diagnostycznymi umożliwiają diagnozę pomp z określonym wskaźnikiem głębokości lokalizacji uszkodzonych elementów. Głębokością lokalizacji uszkodzeń nazywa się moc podzbioru elementów systemu, w którym to podzbiore w procesie lokalizacji nie można rozróżnić stanu każdego elementu z osobna, a możliwe jest wyznaczenie stanu dla wszystkich elementów, należących do owego podzbioru, traktowanego łącznie [Wawrzyński 1996].

Metody sztucznej inteligencji mogą pomóc w zmniejszeniu wskaźnika głębokości lokalizacji uszkodzeń. Korbicz i in. [1994] do podstawowych zalet metod sztucznej inteligencji zaliczają ich elastyczność, uniwersalność i łatwość tworzenia aplikacji. Uważają, że takie cechy sieci neuronowych jak możliwość równoległego przetwarzania informacji, efektywna aproksymacja dowolnych nieliniowości, uczenie i douczanie sieci na podstawie obserwacji sprzyja zastosowaniu ich w diagnostyce układów technicznych. Kwaśniewski [1997] przedstawia możliwości wykorzystania sztucznej inteligencji w diagnostyce maszyn górniczych. Uważa on, że zastosowanie algorytmów sztucznej inteligencji umożliwi formalizację zastosowania w diagnostyce takich informacji jak fakty, zdarzenia oraz informacji uzyskanych drogą badań organoleptycznych (odbiór zapachów, kolorów itd.). Zastosowanie sieci neuronowej pozwala prawidłowo wykrywać usterki aparatury paliwowej silników o zapłonie samoczynnym [Klimkiewicz 2005]. Można je również z powodzeniem używać do

oceny stanu technicznego układu Common Rail [Bocheński i in. 2002]. Cieślukowski i Langman [2005] sieci neuronowe wykorzystali w module wnioskowania diagnostycznego przy budowie systemu autodiagnozy kombajnu ZO58.

Celem pracy było zbudowanie modelu opartego na sztucznych sieciach neuronowych, który korzystając z wyników urządzeń diagnostycznych oraz danych jakościowych wprowadzanych przez diagnostę usprawni proces lokalizacji uszkodzeń.

Opis metody badawczej

Obiektem badawczym była rozdzielaczowa pompa wtryskowa typu DPA. Opierając się na przeprowadzonych badaniach eksploatacyjnych określono wskaźniki głębokości lokalizacji uzyskiwane na podstawie symptomów określanych podczas badania pompy wtryskowej na stole probierczym. Okazało się, że tylko dla jednego symptomu „zbyt mały przelew zwrotny” wskaźnik głębokości lokalizacji uszkodzeń osiąga wartość 1, czyli jest to dokładna lokalizacja miejsca uszkodzenia. Dla pozostałych symptomów przyjmuje wartości od 3 do 6. Aby zmniejszyć wartość wskaźnika głębokości lokalizacji uszkodzeń zaproponowano, aby oprócz symptomów uzyskanych za pomocą pomiarów na stole probierczym, wykorzystać symptomy odbierane bezpośrednio przez zmysły człowieka (organoleptycznie) oraz pewne informacje uzyskane od użytkownika naprawianego urządzenia. Dane te posłużyły do budowy modelu opartego na sztucznych sieciach neuronowych.

Na podstawie przeglądu literatury oraz na podstawie badań eksploatacyjnych można zaproponować model semantyczny opisujący wpływ różnych czynników na uszkodzenia pompy wtryskowej oparty na 6 czynnikach o postaci:

$$U = f(S, M, P, I, O, Z) \quad (1)$$

gdzie:

- U – czynnik charakteryzujący poszukiwane usterki (uszkodzenia),
- S – symptomy niewłaściwej pracy pompy określone na stole probierczym,
- M – okres eksploatacji badanej pompy,
- P – jakość paliwa wypełniającego pompę,
- I – ingerencja użytkownika w konstrukcję pompy,
- O – objawy złej pracy silnika zaobserwowane przez użytkownika pompy,
- Z – czynnik charakteryzujący wpływ otoczenia na badane zjawisko.

Każdy z wprowadzonych czynników jest zbiorem określających go parametrów. Po wyborze czynników istotnych oraz przeprowadzonej konceptualizacji model semantyczny charakteryzujący lokalizację uszkodzonych elementów w pompie wtryskowej przyjął postać:

$$U = f(S, M, P, I) \quad (2)$$

Ten model opisowy został wykorzystany do opracowania modeli klasyfikujących uszkodzenia i wspomagających lokalizację uszkodzonych elementów.

Uszkodzenia U stanowią zmienną wyjściową w modelu. Jest to zmienna nominalna przyjmująca czternaście wartości: $u_1 - u_{14}$ związanych z uszkodzeniem grupy elementów

lub jednego elementu, np. u_1 - zużyte skrzydełka, zanieczyszczony filtr nylonowy, zatarty tłoczek zaworu, a u_{10} - zatarty tłoczek zaworu.

Symptomy S , które można określić na stole probierczym są pierwszą zmienną wejściową wprowadzaną do sieci. Jest to zmienna nominalna. Przyjmuje ona osiem wartości: s_1 - niskie ciśnienie przetłaczania, s_2 - zbyt wysokie ciśnienie przetłaczania, s_3 - zbyt mały przelew zwrotny, s_4 - zbyt mała dawka rozruchowa, s_5 - niewłaściwa dawka nominalna, s_6 - brak możliwości odcinania dopływu paliwa, s_7 - trudności z regulacją dawki przy maksymalnych obrotach pompy, s_8 - niewłaściwe działanie automatycznego przestawiacza kąta wtrysku,

Następną zmienną wejściową jest okres eksploatacji o nazwie M , która przyjmuje wartości liczbowe. Jako okres eksploatacji przyjęto wiek ciągnika.

Zmienną wejściową określającą zanieczyszczenie paliwa P jest zmienna nominalna reprezentowana za pomocą techniki dwustanowej o wartościach: p_1 - paliwo czyste i p_2 - paliwo zanieczyszczone.

Ostatnia zmienna informująca o ingerencji użytkownika w mechanizmy pompy I jest też zmienną nominalną o wartościach i_1 - ingerencja użytkownika w mechanizmy pompy oraz i_2 - brak ingerencji. Do symulacji sztucznych sieci neuronowych użyto programu STATISTICA Sieci Neuronowe (SSN) firmy StatSoft. Jako dane do budowy modelu wykorzystano 623 przypadki uszkodzeń pomp wtryskowych zarejestrowane podczas badań eksploatacyjnych.

Aby struktura sieci nie była zbyt skomplikowana, liczba zmiennych wejściowych powinna być ograniczona do niezbędnego minimum. Obiektywnie przydatność poszczególnych zmiennych można sprawdzić tylko empirycznie. Sprawdzone więc eksperymentalnie działanie sieci posługując się algorytmami: krokowym i genetycznym zaimplementowanymi w programie STATISTICA Sieci Neuronowe oraz przeprowadzono analizę wrażliwości sieci z różnym zestawem zmiennych.

Biorąc pod uwagę powyższe analizy do budowy sieci pozwalającej oceniać uszkodzenia pompy użyto tylko trzech zmiennych: S, P, I .

Wyniki badań

Dobierając architekturę sieci wybrano opcję automatycznego określenia złożoności sieci. Oznacza to, że automatyczny projektant dobierze optymalną liczbę neuronów w poszczególnych warstwach, używając różnych algorytmów dla różnych rodzajów sieci. Przykładowe badane architektury sieci przedstawiono w tabeli 1.

Najlepszą jakość modelu uzyskiwano za pomocą sieci probabilistycznych. Dlatego też do diagnostyki pompy wybrano taką architekturę sieci i model oparty na tej sieci został szczegółowo przeanalizowany. Ponieważ uzyskiwano podobne małe błędy sieci dla zbiorów uczącego, walidacyjnego i testowego w pierwszych próbach, w następnych próbach zrezygnowano ze zbioru testowego i sieć była uczona na podzbiorach uczącym i walidacyjnym o stosunku przypadków 3:1.

Tabela 1. Parametry niektórych badanych sieci neuronowych
Table 1. Parameters of some examined neural networks

Nr	Typ sieci	Jakość zbioru uczącego	Jakość zbioru walidacyjnego.	Błąd zbioru uczącego	Błąd zbioru walidacyjnego	Algorytm uczenia
1	MLP 3:11-25-14:1	0,966	0,974	0,277	0,204	BP100,CG20 ¹
2	MLP 3:11-25-14:1	0,929	0,936	0,256	0,180	BP100,CG20,
3	Liniowa 1:9-14:1	0,876	0,891	0,108	0,096	PI ²
4	RBF 1:9-11-14:1	0,876	0,891	0,108	0,096	KM,KN,PI ³
5	Liniowa 2:10-14:1	0,893	0,904	0,103	0,094	PI
6	Liniowa 3:11-14:1	0,893	0,904	0,103	0,093	PI
7	RBF 3:11-11-14:1	0,895	0,910	0,100	0,092	KM,KN,PI
8	RBF 3:11-11-14:1	0,891	0,917	0,096	0,087	KM,KN,PI
9	PNN 2:10-467-14:1	0,955	0,968	0,067	0,060	PN ⁴
10*	PNN 3:11-467-14:1	0,966	0,968	0,059	0,054	PN

Źródło: obliczenia własne autora na podstawie STATISTICA Sieci Neuronowe

¹ - Algorytm uczenia wstecznej propagacji błędów – 100 epok, algorytm uczenia gradientów sprzężonych 20 epok,

² - Algorytm uczenia pseudoinwersji (optymalizacja liniowa metodą najmniejszych kwadratów),

³ - Algorytm uczenia k-średnich, k-najbliższych sąsiadów i pseudoinwersji,

⁴ - Uczenie probabilistycznych sieci neuronowych (kopiowanie przypadków uczących do neuronów radialnych, dobór współczynnika wygładzania),


* - Sieć wybrana do diagnostyki pompy wtryskowej.

Analiza modelu

Błąd sieci uzyskany w trakcie uczenia sieci wyznaczano na podstawie wartości błędów jednostkowych, obliczonych za pomocą przyjętej funkcji błędu entropia. Błąd jest sumą iloczynów zadanych wartości oraz logarytmów błędów dla każdego neuronu wyjściowego.

Wskaźnikiem jakości sieci klasyfikujących jest odsetek poprawnie zakwalifikowanych przypadków. Nie bierze się pod uwagę przypadków, których sieć nie zaklasyfikowała do żadnej klasy.

Wybrana sieć PNN do wspomaganie lokalizacji uszkodzeń charakteryzująca się najniższym błędem zaprezentowana jest w tabeli 1 pod numerem 10. Jakość sieci jest bardzo dobra: dla zbioru uczącego wynosi 0,966, a dla zbioru walidacyjnego 0,968. Mała różnica między błędem sieci dla zbioru uczącego (0,059) i walidacyjnego (0,054) oznacza, że sieć ma dobre właściwości generalizujące. Architekturę sieci przedstawiono na rysunku 1.



Rys. 1. Architektura sieci probabilistycznej: ► – warstwa wejściowa – (neurony liniowe), ● – warstwa ukryta (neurony radialne), ■ – warstwa wyjściowa (neurony liniowe)
Fig. 1. Probabilistic network architecture: ► – input layer (linear neurons), ● – hidden layer (radial networks), ■ – output layer (linear neurons)

Empiryczna weryfikacja modelu

Przeprowadzono eksperymenty na danych nieużywanych do budowy modelu, pochodzących z dwóch zakładów naprawczych zlokalizowanych w odległych od siebie miejscowościach. Sieć neuronowa nauczona na przypadkach pomp tego samego rodzaju i pracujących w podobnych warunkach diagnozowała poprawnie 95% badanych obiektów.

Podsumowanie

Model neuronowy zastosowany do wspomaganie diagnostyki pompy wtryskowej DPA wskazuje na rodzaj uszkodzenia oraz pozwala na zmniejszenie wskaźnika głębokości lokalizacji uszkodzonych elementów. Empiryczna weryfikacja modelu wskazuje na jego praktyczną przydatność. Jeśli chce się korzystać z modelu należy zwrócić uwagę, że sieć neuronowa musi być nauczona na przypadkach pomp tego samego rodzaju i pracujących w podobnych warunkach.

Sieć neuronową do wspomaganie diagnozy wykorzystać można bezpośrednio wprowadzając dane do nauczanej sieci. Kod źródłowy, odpowiadający nauczanej sieci neuronowej, można też kompilować z własnym programem, tworząc system doradczy przyjazny dla użytkownika.

Bibliografia

- Bocheński C., Mruk R.** 2002. Metody oceny stanu technicznego układu Common Rail z wykorzystaniem systemów komputerowych. Diagnostyka, vol. 27. s 11-16.
- Cieślakowski B., Langman J.** 2005. Analiza parametru diagnostycznego zespołu przekładniowego kombajnu zbożowego z użyciem sztucznych sieci neuronowych. Inżynieria Rolnicza. Nr 8(68). s. 57-61.
- Klimkiewicz M.** 2005. Zastosowanie sieci neuronowych w diagnostyce aparatury paliwowej silników o zapłonie samoczynnym. Inżynieria Rolnicza. Nr 8(68). s. 153-160.
- Korbicz J., Obuchowicz A., Uciński D.** 1994. Sztuczne sieci neuronowe. Podstawy zastosowanie. Ak. Of. Wyd. PLJ. Warszawa. s. 828.
- Kwaśniewski J.** 1997. Analiza struktur inteligentnych systemów do diagnostyki maszyn. Wyd. AGH, Kraków. ISSN 0867-6631.
- Wawrzyński W.** 1996. Zagadnienia metodologiczne diagnostyki systemów sterowania w transporcie. Oficyna Wyd. Politechniki Warszawskiej. ISSN 1230-9265.

NEURAL MODEL ALLOWING TO LOCATE DEFECTS IN INJECTION PUMPS

Abstract. An artificial intelligence method was used to optimise the process of detecting damaged elements in injection pumps. A neural model based on probabilistic neural networks was applied. Developed model allows to reduce the value of location depth indicator for damaged elements. The neural model is distinguished by very good damage classification quality.

Key words: neural networks, injection pump, damage location

Adres do korespondencji:

Marek Klimkiewicz; e-mail: marek_klimkiewicz@sggw.pl
Katedra Organizacji i Inżynierii Rolnictwa
Szkoła Główna Gospodarstwa Wiejskiego w Warszawie
ul. Nowoursynowska 166
02-787 Warszawa