

ZASTOSOWANIE SIECI NEURONOWYCH W DIAGNOSTYCE APARATURY PALIWOWEJ SILNIKÓW O ZAPŁONIE SAMOCZYNNYM

Streszczenie

W celu wspomagania wykrywania usterek w układach paliwowych silników o zapłonie samoczynnym zbudowano model oparty na wykorzystaniu sieci neuronowej. Zmiennymi wejściowymi są symptomy zaobserwowane przez użytkownika, wskazujące na złą pracę silnika oraz sprawdzenia i pomiary wykonane przez mechanika. Zmienną wyjściową jest usterka. Zgromadzono ponad 1000 przypadków usterek i odpowiadających im symptomów, sprawdzeń i wartości pomiarowych, które zaobserwowano w zakładzie naprawy aparatury paliwowej. Porównano wiele rodzajów sieci. Najlepszą jakością wykazywały sieci probabilistyczne.

Słowa kluczowe: aparatura paliwowa, diagnostyka, sieci neuronowe, silniki o zapłonie samoczynnym

Wprowadzenie

Pojazdy rolnicze w większości wyposażone są w silniki o zapłonie samoczynnym. Aparatura paliwowa takich silników jest bardzo skomplikowana. Niedostateczna znajomość klasycznych układów paliwowych z pompami wtryskowymi z regulacją mechaniczną, hydrauliczną lub pneumatyczną powoduje obniżenie jakości napraw pojazdów wyposażonych w takie układy. Badania eksploatacyjne [Bocheński i in. 2002] zużycia aparatury paliwowej wykazały, że często usterki są błędnie diagnozowane i pociągają za sobą niepotrzebnie szeroki zakres naprawy silnika.

Obecnie stosowane zestawy diagnostyczne nie zawsze pozwalają na wykrycie wszystkich niedomagań silnika bez przeprowadzenia, choć częściowego demontażu. Dodatkowe informacje, pozwalające wykryć uszkodzenie, można uzyskać wykorzystując metody organoleptyczne. Ocenia się wtedy takie parametry towarzyszące pracy silnika, jak kolor spalin, hałas i inne. W diagnozowaniu usterek aparatury paliwowej mogą znaleźć zastosowanie sztuczne sieci neuronowe, które umożliwiają

przetwarzanie informacji uzyskanych za pomocą pomiarów oraz w wyniku badań organoleptycznych. [Korbicz i in., 1994] uważają, że typowy sposób wykorzystania sieci neuronowych w diagnostyce sprowadza się do budowy neuronowego klasyfikatora stanów obiektu na podstawie obserwacji (pomiarów) sygnałów obiektu. Sieci neuronowe szeroko stosowane są w diagnostyce sieci elektroenergetycznych [Helt i in. 2000].

Sieci neuronowe w diagnostyce maszyn rolniczych stosował między innymi [Langman 1999]. [Mruk 2000] w diagnostyce ciągników i maszyn rolniczych stosował systemy rozmyte i sieci neuronowe, uzyskując podobne wyniki. Zastosowanie sieci neuronowej może zwiększyć efektywność systemów ekspertowych, takich jak np. „DIESEL 1”, w którym baza wiedzy oparta była na doświadczeniu specjalistów [Klimkiewicz 1998].

Celem pracy jest utworzenie modelu opartego na sieci neuronowej, pozwalającego na podstawie danych wejściowych określić usterkę aparatury paliwowej silnika o zapłonie samoczynnym.

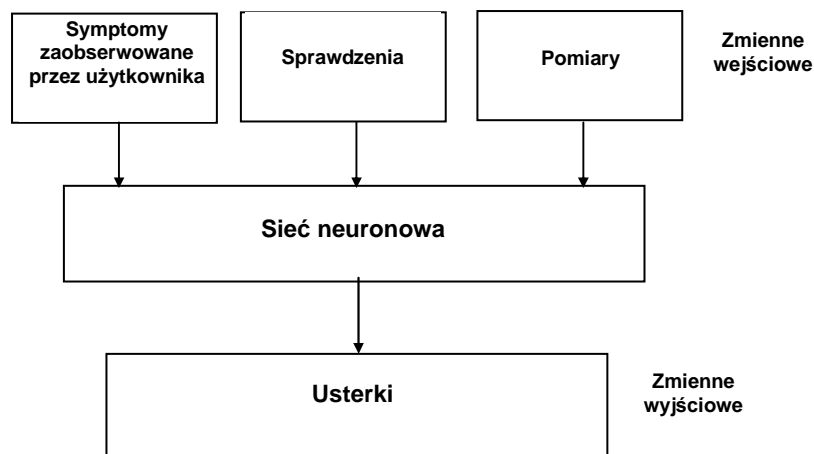
Budowa modelu

Przypadki służące do konstruowania sieci neuronowej i jej uczenia rejestrowane były w zakładzie naprawy aparatury paliwowej oraz pochodzą z konsultacji, jakiej autor artykułu udzielał mechanikom w przypadkach, w których trudno było zlokalizować usterkę silnika. Ze względu na różnice konstrukcyjne celowa jest budowa oddzielnych modeli neuronowych dla pojazdów wyposażonych w pompy rzędowe i rozdzielaczowe.

Przedstawione badania dotyczą pojazdów z silnikami o zapłonie samoczynnym wyposażonych w pompy rozdzielaczowe. Jako zmienne wejściowe wybrano te symptomy, pomiary i sprawdzenia na podstawie, których eksperci ustalają usterki aparatury paliwowej.

Zaproponowany model przedstawiono na rysunku 1. Pierwszą zmienną wejściową jest zmienna symptom – jest to zmienna przyjmująca 10 wartości. Zmienna ta reprezentowana jest za pomocą techniki jeden z – n, gdyż jeden neuron odpowiada tylko jednej z – n możliwych wartości rozpatrywanej zmiennej. Zmienną symptom wraz z jej wartościami (kodami) przedstawiono w tabeli 1. Następne zmienne związane są ze sprawdzeniami i pomiarami przeprowadzanymi na silniku pojazdu. Sprawdzenia przedstawione są za pomocą zmiennych nominalnych reprezentowanych za pomocą techniki dwustanowej. Zmiennym tym przyporządkowano wartości logiczne „T”, gdy sprawdzenia stwierdzały stany prawidłowe i wartości logiczne „N”, gdy sprawdzenia wykazywały

stany nieprawidłowe. Pomiary dotyczą ciśnienia sprężania w poszczególnych cylindrach. Posłużono się w tym przypadku zmiennymi przyjmującymi wartości liczbowe. Zmienna wyjściowa jest zmienną nominalną przyjmującą 17 wartości. Poszczególnym zmiennym wprowadzanym do modelu oraz ich wartościom nadano krótkie nazwy, które przedstawiono w tabelach 1-3.



Rys. 1. Model wspomagania wykrywania usterek aparatury paliwowej
 Fig. 1. Model of computer-aided diagnostic of faults in fuel injection system

Tabela 1. Wartości zmiennej wejściowej SYMPTOM
 Table 1. Values of the SYMPTOM input variable

Lp.	Symptomy	Wartości zmiennej SYMPTOM
1	Trudny rozruch silnika	ROZRUCH
2	Silnika nie można uruchomić	URUCHOM
3	Nadmierne dymienie	DYMIENIE
4	Zbyt mała moc silnika	MOC
5	Nadmierny hałas	HALAS
6	Nierównomierna praca silnika	NIEROW-P
7	Niewłaściwa maksymalna prędkość obrotowa	MAKSYM
8	Nadmierne zużycie paliwa	ZUZ-PAL
9	Silnik zbyt wolno schodzi z wysokiej prędkości obrotowej	SCHOD-PR
10	Silnika nie można wyłączyć	WYLACZ

Tabela 2. Nazwy zmiennych wejściowych: sprawdzenia i pomiary
Table 2. Names of input variables: checks and measurements

Lp.	Sprawdzenia i pomiary	Nazwy zmiennych
1	Czy silnik uruchamia się po wyjęciu rdzenia z zaworka elektromagnetycznego?	ZAW-EL
2	Czy brak pęcherzyków powietrza w przezroczystym przewodzie doprowadzającym paliwo do pompy?	PE-PO
3	Czy ręczna pompka podaje paliwo?	RECZ-POM
4	Czy brak zapachu benzyny w paliwie?	ZAP-BENZ
5	Czy akumulator w odpowiednim stanie?	AKUMUL
6	Czy świece żarowe sprawne?	SW-ZAR
7	Czy kąt początku tłoczenia ustawiony prawidłowo?	KAT-TL
8	Czy podczas napędu silnika rozrusznikiem z króćca przelewowego wypływa paliwo?	KR-PAL
9	Ciśnienie sprężania - 1	SPR-1
10	Ciśnienie sprężania - 2	SPR-2
11	Ciśnienie sprężania - 3	SPR-3
12	Ciśnienie sprężania - 4	SPR-4
13	Czy drożny jest układ dolotowy powietrza?	DROZ-DOL
14	Czy drożny jest układ wydechowy?	DROZ-WYD
15	Czy wtryskiwacze są w dobrym stanie?	WTRYSKIW
16	Czy kolejność połączenia przewodów wysokiego ciśnienia jest właściwa?	PRZ-WTR
17	Czy regulacja zderzaka śruby zapobiegającej zgaśnięciu silnika jest prawidłowa?	SR-GAS
18	Czy prawidłowo wyregulowana jest maksymalna prędkość obrotowa silnika?	SR-MAKS

Tabela 3. Wartości zmiennej wyjściowej
Table 3. Values of output variables

Lp.	Usterki	Wartości zmiennej USTERKA
1	Uszkodzony zawór elektromagnetyczny	ELEK-ZAW
2	Zapowietrzony układ doprowadzający paliwo do pompy	ZAPOW-UP
3	Niedrożność układu paliwowego	ZABL-UP
4	Olej napędowy zawiera benzynę	BENZ
5	Niesprawny akumulator	AKUMUL
6	Niesprawne świece żarowe	SWIECE-Z
7	Niewłaściwie ustawiony kąt wyprzedzenia wtrysku paliwa	KAT-WTR
8	Niskie ciśnienie sprężania	CIS-SPR
9	Niedrożność układu dolotowego powietrza	ZABL-PO
10	Niedrożność układu wydechowego	ZABL-UW
11	Zużyte rozpylacze	WTRYSK
12	Niewłaściwa kolejność połączenia przewodów wysokiego ciśnienia	KOL-PRZ
13	Niewłaściwa regulacja śruby zderzaka zapobiegającego gaśnięciu silnika	SR-ZDERZ
14	Niewłaściwa regulacja maksymalnej prędkości obrotowej	MAKS-PR
15	Nie dokręcone śruby mocujące pompę wtryskową	NIEDOK-P
16	Uszkodzona pompa wtryskowa	POMPA
17	Inna usterka silnika	USTER-SI

Wybór sieci neuronowej i uczenie sieci

Do budowy sieci pozwalającej wykryć usterki aparatury paliwowej użyto 19 zmiennych wejściowych i jedną zmienną wyjściową. Zbudowano i przeanalizowano wiele sieci za pomocą różnych algorytmów uczenia. Zbiór danych najpierw podzielono na podzbiory przypadków uczących, walidacyjnych i testowych w stosunku 2:1:1. Ponieważ uzyskano podobnie małe błędy sieci dla zbiorów uczącego, walidacyjnego i testowego, w następnych próbach zrezygnowano ze zbioru testowego i sieć była uczona na podzbiórach uczącym i walidacyjnym o stosunku przypadków 3 : 1. Przy uczeniu sieci przyjęto poziom akceptacji równy 0,7, a poziom odrzucenia 0,3. Najlepszą jakość sieci uzyskiwano przy wykorzystaniu sieci probabilistycznych.

Wskaźnikiem jakości sieci klasyfikujących jest odsetek poprawnie zakwalifikowanych przypadków. Dla zbioru walidacyjnego wybranej sieci probabilistycznej uzyskano jakość klasyfikacji powyżej 0,9. Podobne wartości błędów sieci, uzyskane dla zbioru uczącego i walidacyjnego, oznaczają, że sieć ma dobre właściwości generalizujące. Sieć składa się z trzech warstw. Warstwa wejściowa składa się z neuronów liniowych. Warstwa ukryta zawiera neurony radialne. W tej warstwie szacuje się gęstość prawdopodobieństwa za pomocą tzw. funkcji jądrowych. Są to krzywe Gaussa ustawiane nad każdym wektorem uczącym. Istnienie pewnego przypadku w przestrzeni oznacza dużą gęstość prawdopodobieństwa. W warstwie wyjściowej następuje sumowanie gęstości i oszacowanie prawdopodobieństwa przynależności do poszczególnych klas. Uczenie probabilistycznych sieci neuronowych odbywa się przez kopiowanie przypadków uczących do neuronów radialnych i dobór współczynnika wygładzania.

Analiza sieci neuronowej

Analiza wrażliwości sieci pozwala porównać wyniki uzyskane przy doborze zmiennych wejściowych. Wskaźnikiem przydatności poszczególnych zmiennych do klasyfikacji wykonywanej przez sieć jest stosunek (iloraz) błędu sieci otrzymanej bez użycia danej zmiennej do błędu tzw. bazowego, to jest błędu sieci otrzymanego z użyciem wszystkich zmiennych. Wysoka wartość ilorazu uzyskana dla badanej zmiennej świadczy o jej przydatności do budowy modelu i dlatego przydziela się jej wysoką rangę. Iloraz mniejszy od jednościi wskazuje na to, że odrzucenie zmiennej może polepszyć jakość sieci. Dla wszystkich zmiennych wejściowych badanej sieci iloraz błędu przyjmuje wartości powyżej jednościi (Tab. 4), co oznacza, że wszystkie zmienne wnoszą istotne informacje o stanie aparatury paliwowej.

Ocenę jakości zaklasyfikowania dokonaną przez sieć można ocenić przy wykorzystaniu statystyki klasyfikacyjnej przedstawionej w tabeli 5. Sieć ma za zadanie określić 17 rodzajów usterek. Sieć klasyfikuje jednoznacznie wszystkie przypadki oprócz usterki - POMPA (1,7% przypadków niezaklasyfikowanych), 12 rodzajów usterek identyfikuje poprawnie w 100% i cztery usterki poprawnie w zakresie od ok. 39% do ok. 98%.

Do ustalenia uszkodzeń nawzajem źle zakwalifikowanych można wykorzystać macierz pomyłek. Analiza macierzy pomyłek, przeprowadzona dla analizowanego modelu, pokazała, że np. usterka silnika może zostać niepoprawnie zaklasyfikowana, jako uszkodzenie zaworka elektromagnetycznego pompy wtryskowej. Dobrana architektura sieci neuronowej zapewnia bardzo dobrą jakość przeprowadzanej klasyfikacji, pozwalając diagnozować uszkodzenia aparatury paliwowej pojazdów z silnikami o zapłonie samoczynnym.

Sieć neuronową do wspomagania diagnozy można wykorzystać bezpośrednio wprowadzając symptomy, sprawdzenia i wyniki pomiarów do nauczonej sieci. Można też kod źródłowy odpowiadający nauczonej sieci, kompilować z własnym programem, tworząc system ekspertowy bardziej przyjazny dla użytkownika.

Empiryczna weryfikacja modelu

Model neuronowy wypróbowano w serwisie aparatury paliwowej. Nie dokonano ilościowej oceny poprawności trafnych klasyfikacji, gdyż z programu korzystano tylko w przypadkach, gdy doświadczenie pracowników nie pozwalało szybko wykryć usterki. Z relacji pracowników wynika, że często już przy wprowadzaniu danych wejściowych do modelu stwierdzano, że nie dokonano wszystkich sprawdzeń i niezależnie od programu, po dokonaniu dodatkowego sprawdzenia, prawidłowo typowano usterkę. Program między innymi pomógł wykryć takie usterki, jak: nieprawidłowa kolejność zamontowania przewodów wtryskowych, zawartość benzyny w oleju napędowym, niskie ciśnienie sprężania, niedrożny układ wydechowy, zapowietrzenie układu paliwowego.

Wnioski

1. Zastosowanie sieci neuronowej pozwala prawidłowo wykrywać usterki aparatury paliwowej silników o zapłonie samoczynnym.
2. Najlepszą jakość klasyfikacji usterek aparatury paliwowej uzyskano stosując sieci probabilistyczne.

Tabela 4. Analiza wrażliwości zmiennych modelu
Table 4. Analysis of sensitivity model variable

Wskaźniki	Zmienne wejściowe																	
	SYMPT	ZAW-EL	PE-PO	RECZ-POM	ZAP-BENZ	AKUM-UL	SW-ZAR	KAT-TL	KR-PAL	SPR-1	SPR-2	SPR-3	SPR-4	DROZ-DOL	WTRY-SKIW	PRZE-W-WT	SR-GAS	SR-MAKS
Iloraz	2,60	1,27	2,50	1,61	1,34	1,57	2,17	2,61	1,43	1,12	1,27	1,11	1,10	1,93	3,41	1,53	1,33	1,21
Ranga	3	13	4	7	11	8	5	2	10	16	14	17	18	6	1,00	9,00	12,00	15,00

Tabela 5. Ocena klasyfikacji wykonanej przez sieć
Table 5. Assessment of network classification

Wskaźniki	Wartości zmiennej wyjściowej																
	CS-SPR	ZAPO-W-UP	SWE-CE-Z	AKU-M	KAT-WTR	BENZ	KOL-PRZ	USTE-R-SI	ELEK-ZAW	ZABL-UP	POM-PA	ZABL-PO	WTR-YSK	ZABL-UW	MAK-S-PR	KAT-TL	SR-MAKS
Wszystk.	77,0	83,0	60,0	24,0	379,0	12,0	21,0	18,0	17,0	25,0	60,0	43,0	175,0	6,0	7,0	60,0	10,0
Popraw.	74,0	83,0	60,0	24,0	379,0	12,0	21,0	7,0	17,0	25,0	59,0	43,0	175,0	5,0	6,0	60,0	10,0
Niepopr.	3,0	0,0	0,0	0,0	0,0	0,0	0,0	11,0	0,0	0,0	0,0	0,0	0,0	1,0	1,0	0,0	0,0
Nieznane	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,0	0,0	0,0	0,0	0,0	0,0	0,0
Popraw.(%)	96,1	100,0	100,0	100,0	100,0	100,0	100,0	38,9	100,0	100,0	98,3	100,0	100,0	83,3	85,7	100,0	100,0
Niepopr.(%)	3,9	0,0	0,0	0,0	0,0	0,0	0,0	61,1	0,0	0,0	0,0	0,0	0,0	16,7	14,3	0,0	0,0
Nieznane(%)	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,7	0,0	0,0	0,0	0,0	0,0	0,0

Bibliografia

Bocheński C. i in. (Kier. projektu bad.). 2002. *Badania wpływu właściwości fizykochemicznych paliwa do silników wysokoprężnych na charakterystykę wtrysku i trwałości elementów układu paliwowego konwencjonalnego i Common Rail. Projekt badawczy KBN nr 9T12D00716. Maszynopis, cz. II s. 128*

Helt P., Parol M., Piotrowski P. 2000. *Metody sztucznej inteligencji w elektroenergetyce. Of. Wyd. Pol. War., Warszawa, s. 241*

Klimkiewicz M. 1998. *Zastosowanie systemu ekspertowego w diagnostyce silników o zapłonie samoczynnym. VI Międz. Konf. Nauk-Tech. AUTOPROGRES '98 Pojazdy Samochodowe, Problemy rozwoju jakości eksploatacji. Mat. Konf. Tom 3. Jachranka, ss. 119–126*

Korbicz J., Obuchowicz A., Uciński D. 1994. *Sztuczne sieci neuronowe, Podstawy i zastosowania. Ak. Oficyna Wyd. PLJ, Warszawa, s. 251*

Langman J. 1998. *Diagnozowanie maszyn rolniczych. Wyd. AR, Kraków, s. 76*

Mruk R. 2002. *Metody komputerowej oceny stanu technicznego wybranych zespołów ciągników i maszyn rolniczych. Rozprawa doktorska. SGGW, Warszawa, s. 99*

APPLICATION OF THE NEURAL NETWORKS TO DIAGNOSTICS OF FUEL INJECTION SYSTEM IN DIESEL ENGINES

Summary

In order to aiding the detection of faults in fuel injection system of diesel engines, a model based on using the neural networks was developed. The symptoms indicating wrong engine action observed by the user as well as the inspections and measurements done by a mechanic, were the input variables. The output variable was fault of fuel injection system. The set of data was collected including above 1000 cases of faults and associated symptoms, inspections and measurements observed in fuel injection service workshop. From among numerous network structures compared, the best usability revealed the probabilistic neural network.

Key words: diesel engine, fuel injection system, diagnostics, neural networks

Recenzent – Jerzy Langman