

ZASTOSOWANIE SAMOORGANIZUJĄCYCH SIĘ MAP CECH W DIAGNOSTYCE SILNIKÓW O ZAPŁONIE SAMOCZYNNYM

Marek Klimkiewicz

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

Streszczenie. Wykorzystano właściwości samoorganizujących się map cech w wykrywaniu uszkodzeń silników z zapłonem samoczynnym. Zbudowano model, w którym zmiennymi wejściowymi są symptomy zaobserwowane przez użytkownika wskazujące na niewłaściwą pracę silnika oraz sprawdzenia i pomiary wykonane przez mechanika. Za pomocą mapy topologicznej zlokalizowano podobne skupienia przypadków. Neuronom radialnym mapy nadano etykiety zgodne z nazwami mogących się pojawić usterek.

Słowa kluczowe: silnik o zapłonie samoczynnym, diagnostyka, samoorganizująca się mapa cech, sieć Kohonena

Wprowadzenie i cel pracy

W badaniach związanych z wykrywaniem usterek w silnikach spalinowych o zapłonie samoczynnym autor z powodzeniem stosował modele indukcyjne budowane z wykorzystaniem sieci neuronowych. Sieci były budowane na podstawie przypadków rejestrowanych w serwisach aparatury paliwowej silników. Do uczenia sieci używane były przypadki pochodzące od doświadczonych pracowników, a zmienną wyjściową używaną do uczenia było zawsze uszkodzenie ustalone w trakcie naprawy [Klimkiewicz 2005].

Postanowiono sprawdzić jakie wyniki można uzyskać, gdy sieć uczona będzie tylko na podstawie zmiennych wejściowych, czyli uczenie będzie nienadzorowane. Odpowiadało by to badaniom przeprowadzanym przez niedoświadczonych pracowników, którzy muszą określić rodzaj uszkodzenia lub też działaniom pracowników z dużym doświadczeniem, ale naprawiającym nowy typ urządzenia. Model zbudowany został za pomocą sieci Kohonena.

Przy uczeniu bez nauczyciela sieć musi odkrywać sama dla siebie wzorce, właściwości, regularności, kategorie w danych wejściowych i kodować je w celu otrzymania wyjścia. Jednostki i połączenia muszą zatem okazywać pewien poziom samoorganizacji [Hertz i in. 1995]. Idea systemu samoorganizującego pojawiła się w latach 50-tych. Sam termin był definiowany jako system, który zmienia swą podstawową strukturę na podstawie informacji docierającej do niego z otoczenia, bądź jako szersze pojęcie obejmujące zarówno złożony obiekt (organizm) jak i jego otoczenie [Duch i in. 2000]. W klasycznym algorytmie Kohonena inicjalizuje się sieć, przyporządkowując neuronom określone miejsce w przestrzeni i łącząc je na stałe z sąsiadami. W momencie wyłonienia zwycięzcy uaktualniają się nie tylko jego wagi, ale również wagi jego sąsiadów, pozostających w najbliższym

sąsiedztwie Ossowski 2000]. Sieć Kohonena [Kohonen 1989] została zaprojektowana do uczenia w trybie bez nauczyciela. Jest to sieć samoorganizująca się na zasadzie współzawodnictwa (metoda „wygrywający bierze wszystko”). Sieć posiada dwie warstwy: wejściową liniową i wyjściową radialną, zwaną jako „tworzącą mapę topologiczną”.

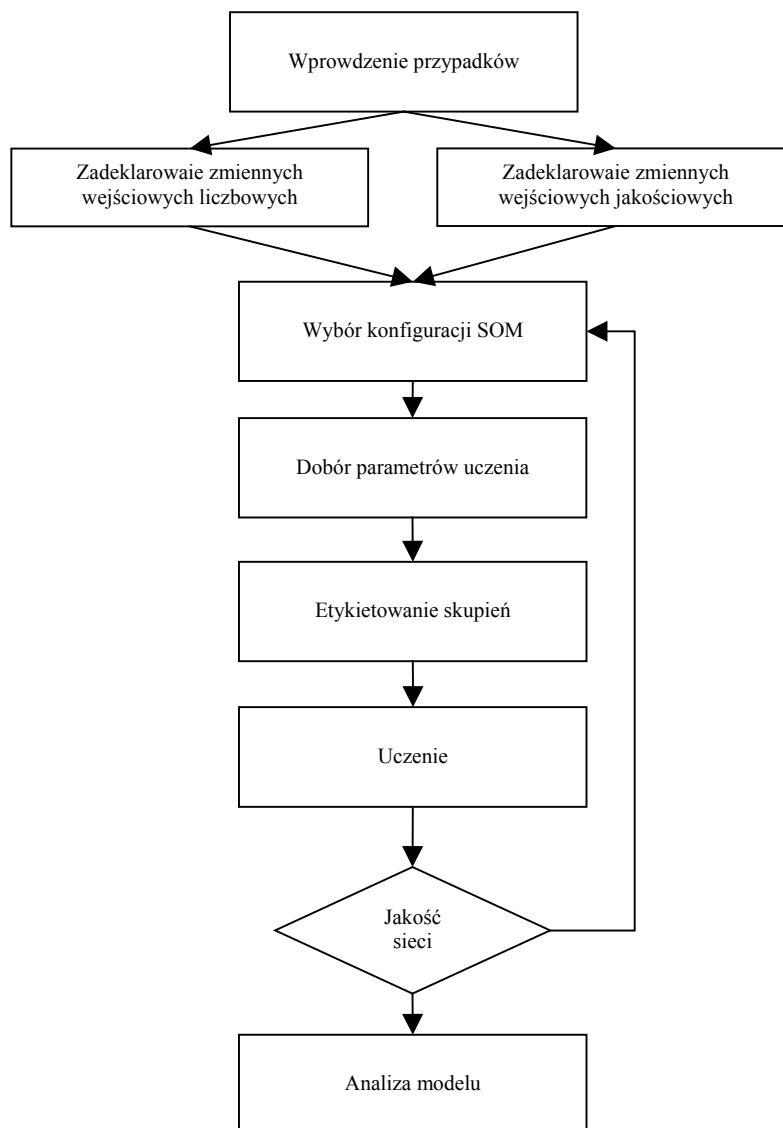
Algorytm iteracyjny, rozpoczynając od początkowych wybranych w sposób losowy centrów radialnych, stopniowo modyfikuje je, aby odzwierciedlić skupienia występujące w danych uczących. Może równocześnie nauczyć się kojarzyć razem podobne klasy danych, bez względu na to, jakie są kryteria podobieństwa danych. Sąsiedztwo neuronów w sieci odpowiada bliskości sygnałów w przestrzeni wejść sieci, a to na ogół oznacza także podobieństwo obiektów opisywanych tymi sygnałami.

Mapa topologiczna umożliwia wizualizować skupienia. Przy pomocy mapy topologicznej użytkownik może lepiej zrozumieć dane, co umożliwia ulepszenie procesu ich dalszej analizy i wykorzystania, np. po rozpoznaniu skupień można nadać im nazwy. Błąd zdefiniowany przez sieć obliczany jest jako suma, po wszystkich przykładach, odległości pomiędzy przykładem a najbliższym mu wektorem wag neuronu w warstwie wyjściowej.

Budowa modelu

Zbudowano model diagnostyczny, w którym zmiennymi wejściowymi są symptomy zaobserwowane przez użytkownika wskazujące na złą pracę silnika oraz sprawdzenia i pomiary wykonane przez mechanika. Przypadki uszkodzeń i odpowiadające im symptomy, sprawdzenia oraz wartości pomiarowe rejestrowano w serwisie specjalizującym się w naprawie aparatury paliwowej. Zgromadzono 1117 takich przypadków. Badania wykonano przy użyciu programu STATISTICA Sieci Neuronowe firmy StatSoft. Na rysunku 1 przedstawiono schematycznie sposób budowy modelu. W tabeli 1 przedstawiono zmienne wejściowe i wartości jakie mogą przyjmować. Zmienne oznaczające sprawdzenia A_1 - A_{11} mogą przyjmować wartość T – jeżeli spełniają wymagania lub N – jeżeli ich nie spełniają. Pomiary A_{12} - A_{15} są zmiennymi liczbowymi. Zmienna wejściowa oznaczająca symptomy zaobserwowane przez użytkownika A_{16} jest zmienną jakościową, która przyjmuje dziewięć wartości.

Wybraną konfigurację sieci przedstawiono na rysunku 2. Zbudowana sieć Kohonena składa się z dwóch warstw – z warstwy wejściowej, w której liczba neuronów wynika ze struktury zbioru danych oraz warstwy wyjściowej, w której liczba neuronów określana jest przez użytkownika. W tym wypadku zastosowano sieć o 30 neuronach w warstwie wyjściowej. Wchodzące w skład warstwy wyjściowej neurony rozmieszczone są na płaszczyźnie, ale struktura sieci jest taka, że neurony nie są w warstwie wyjściowej połączone ze sobą, natomiast między warstwami mają charakter każdy z każdym. Uczenie sieci przeprowadzono w dwóch fazach. W trakcie pierwszej fazy uczenia wartości współczynnika uczenia i promienia sąsiedztwa zmniejszono w kolejnych etapach.

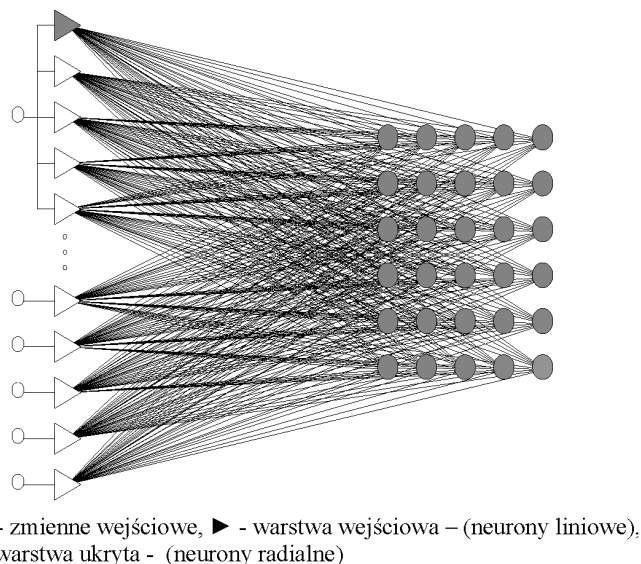


Rys. 1. Schemat budowy modelu
Fig. 1. Model construction diagram

Tabela 1. Nazwy zmiennych wejściowych
Table 1. Names of input variables

Lp.	Sprawdzenia i pomiary		Nazwy zmiennych	Wartości zmiennych
1.	Czy silnik uruchamia się po wyjęciu rdzenia z zaworka elektromagnetycznego?		A_1	<i>T/N</i>
2.	Czy brak pęcherzyków powietrza w przezroczystym przewodzie doprowadzającym paliwo do pompy?		A_2	<i>T/N</i>
3.	Czy ręczna pompka podaje paliwo?		A_3	<i>T/N</i>
4.	Czy świece żarowe sprawne?		A_4	<i>T/N</i>
5.	Czy kąt początku tłoczenia ustawiony prawidłowo?		A_5	<i>T/N</i>
6.	Czy podczas napędu silnika rozrusznikiem z króćca przelewowego wypływa paliwo?		A_6	<i>T/N</i>
7.	Czy drożny jest układ wydechowy?		A_7	<i>T/N</i>
8.	Czy wtryskiwacze są w dobrym stanie?		A_8	<i>T/N</i>
9.	Czy regulacja zderzaka śruby zapobiegającej zgaśnięciu silnika jest prawidłowa?		A_9	<i>T/N</i>
10.	Czy prawidłowo wyregulowana jest maksymalna prędkość obrotowa silnika?		A_{10}	<i>T/N</i>
11.	Czy drożny jest układ dolotowy powietrza?		A_{11}	<i>T/N</i>
12.	Ciśnienie sprężania - 1		A_{12}	Wartość liczbowa
13.	Ciśnienie sprężania - 2		A_{13}	Wartość liczbowa
14.	Ciśnienie sprężania - 3		A_{14}	Wartość liczbowa
15.	Ciśnienie sprężania - 4		A_{15}	Wartość liczbowa
16.	Symptomy obserwowane przez użytkownika	Silnika nie można uruchomić	A_{16}	<i>URUCHOM</i>
		Nadmierne dymienie		<i>DYMIENIE</i>
		Zbyt mała moc silnika		<i>MOC</i>
		Nadmierny hałas		<i>HAŁAS</i>
		Nierównomierna praca silnika		<i>NIERÓW-P</i>
		Niewłaściwa maksymalna prędkość obrotowa		<i>MAKSYM</i>
		Nadmierne zużycie paliwa		<i>ZUZ-PAL</i>
		Silnik zbyt wolno schodzi z wysokiej prędkości obrotowej		<i>SCHOD-PR</i>
		Silnika nie można wyłączyć		<i>WYŁĄCZ</i>

Źródło: opracowanie własne autora



Rys. 2. Architektura zbudowanej sieci Kohonen
Fig. 2. The architecture of built Kohonen network

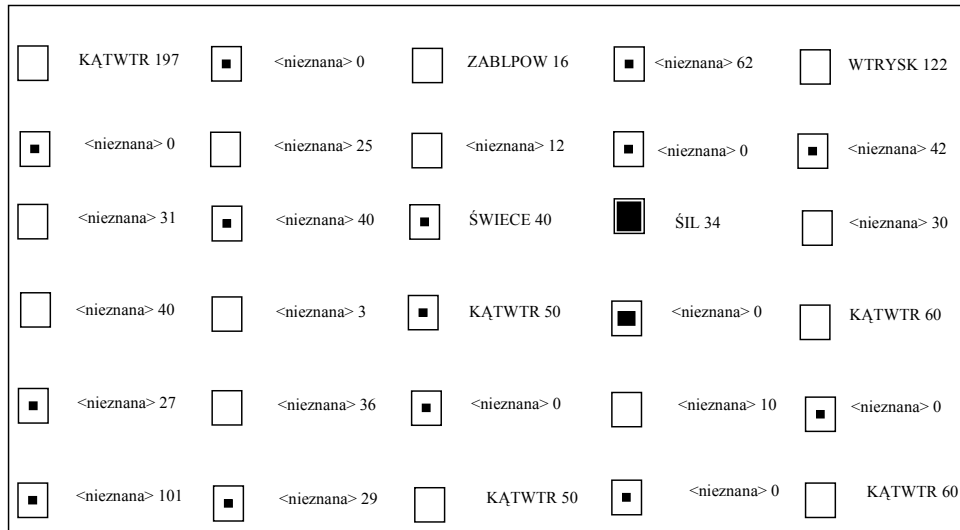
W drugiej fazie uczenia przyjęto bardzo małą wartość i bardzo mały promień sąsiedztwa. W ten sposób mapa topologiczna była dostosowywana do tego, aby pojedyncze neurony odpowiadały niewielkim skupieniom podobnych do siebie przypadków wejściowych, tworząc w ten sposób pewne klasy podobieństwa wśród wejściowych danych. W celu przetestowania sieci należy uruchomić ją dla poszczególnych przypadków zawartych w ciągu uczącym i obejrzeć na mapie topologicznej, jak poszczególne neurony odpowiadają na kolejne przykłady z podzbioru uczącego. Następnie należy zapoznać się ze statystyką współzawodnictwa przez poszczególne neurony (częstość zwycięstw) – jaką liczbę razy każdy z neuronów zwyciężył podczas wprowadzania danych uczących. Analiza częstości zwycięstw może służyć do sprawdzenia, czy na mapie Kohonena uformowane zostały już wystarczająco wyraźne skupienia. Sprawdza się, czy sieć jest już wystarczająco nauczona. Dalej należy zaobserwować jak grupują się przykłady i czy powstałym skupieniom można przypisać jakieś znaczenie. Ustalenie związków między skupieniami, a znaczeniami wymaga odwołania się do dziedziny, której dotyczą przypadki. W tym przypadku neuronom radialnym mapy nadano etykiety zgodne z nazwami mogących się pojawić uszkodzeń. Znaczenie etykiet opisano w tabeli 2. Mapę topologiczną przedstawiono na rysunku 3. Mapa topologiczna pozwala na identyfikację neuronu zwycięskiego. Stopień wypełnienia kwadratów symbolizujących neurony jest proporcjonalny do podobieństwa wektora wejściowego i wektora wag neuronów wyjściowych. Mapa topologiczna pozwala wizualizować skupienia, których zrozumienie w inny sposób byłoby niemożliwe.

Tabela 2. Etykiety nadane neuronom radialnym SOM zgodne z nazwami uszkodzeń
 Table. 2. Labels given to the SOM radial neurons, consistent with names of defects

Etykiety	Znaczenie etykiet
ELEKZAW	Uszkodzony zawór elektromagnetyczny
KĄTWTR	Niewłaściwie ustawiony kąt wyprzedzenia wtrysku paliwa
POMPA	Uszkodzona pompa wtryskowa
SIL	Niskie ciśnienie sprężania Niedrożność układu wydechowego Inna usterka silnika
REGOBR	Niewłaściwa regulacja śruby zderzaka zapobiegającego gaśnięciu silnika Niewłaściwa regulacja maksymalnej prędkości obrotowej
ŚWIECE	Niesprawne świece żarowe
WTRYSK	Zużyte rozpylacze
ZABLPOW	Niedrożność układu dolotowego powietrza
ZABLUP	Niedrożność układu paliwowego
ZAPOWUP	Zapowietrzony układ doprowadzający paliwo do pompy

Źródło: opracowanie własne autora

Mapę topologiczną przedstawiono na rysunku 3.



Źródło: obliczenia własne autora na podstawie STATISTICA Sieci Neuronowe

Rys. 3. Mapa topologiczna

Fig. 3. Topological map

Analiza modelu i podsumowanie

Opisany model budowano z przeznaczeniem do wykorzystania w diagnostyce silników z zapłonem samoczynnym na podstawie symptomów niedomagań silnika zaobserwowanych przez użytkownika oraz sprawdzeń i pomiarów wykonanych przez mechanika. Celem budowy modelu było sprawdzenie czy sieć Kohonena będzie w stanie pogrupować dane wejściowe w ten sposób, aby można było skupieniom przypisać uszkodzenia silnika. W opisanej sytuacji model neuronowy oparty na samoorganizującej się mapie cech mającej zdolność do wykrywania zależności w danych i ułatwiającej klasyfikację może być bardzo przydatny. Model może pomóc znaleźć w danych pewne związki (zależności) - może rozpoznać strukturę danych, a zależności te może rozpatrzeć specjalista. Posługując się statystyką współzawodnictwa (wygrywania) przez poszczególne neurony podczas prezentacji danych uczących neuronom radialnym mapy topologicznej nadano etykiety zgodne z nazwami mogących się pojawić uszkodzeń. Otrzymany model charakteryzował się stosunkowo niską jakością klasyfikacji – około 0,6 i dlatego wymaga dodatkowego dopracowania zgodnie ze schematem przedstawionym na rysunku 2. Model zbudowany na podstawie probabilistycznych sieci neuronowych z uczeniem nadzorowanym charakteryzował się znacznie lepszą jakością klasyfikacją – powyżej 0,95 [Klimkiewicz 2005].

Bibliografia

- Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.** (redaktorzy tomu) 2000. Biocybernetyka i Inżynieria Biomedyczna 2000. Tom 6. Sieci Neuronowe. Ak. Of. Wyd. ELIT. Warszawa. ISBN 83-87674-18-4.
- Hertz J., Krogh A., Palmer R.G.** 1995. Wstęp do teorii obliczeń neuronowych. WNT. Warszawa. ISBN 83-204-1900-X.
- Klimkiewicz M.** 2005. Zastosowanie sieci neuronowych w diagnostyce aparatury paliwowej silników o zapłonem samoczynnym. Inżynieria Rolnicza. Nr 2(68). s. 153-160.
- Kohonen T.** 1989. Self-Organization and Associative Memory. (3rd ed.). Spring-Verlag, Berlin.
- Osowski S.** 2000. Sieci neuronowe do przetwarzania informacji. Oficyna Wyd. Politechniki Warszawskiej. ISBN 83-7207-187-X.

APPLICATION OF SELF-ORGANIZING MAPS OF CHARACTERISTICS IN THE DIAGNOSTICS OF SELF-IGNITION ENGINES

Abstract. The researchers made use of self-organizing properties of maps of characteristics in detecting defects of self-ignition engines. A model was developed with the following input variables: the symptoms observed by user that indicate abnormal engine work, and checks and measurements carried out by a mechanic. Similar concentrations of clusters were located using a topological map. Radial neurons in the map were marked with labels consistent with names of defects, which may possibly occur.

Key words: diesel engine, diagnostics, self-organizing map, Kohonen map

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