

Bogusław Haduch

Institut Nafty i Gazu

Zastosowanie sieci neuronowych w badaniach nad stworzeniem komputerowego modelu nieliniowych właściwości benzyn silnikowych zawierających bioetanol i eter etylowo-tert butylowy

W artykule przedstawiono możliwość wykorzystania sieci neuronowych przy predykcji właściwości mieszanin paliw węglowodorowych (benzyn silnikowych) zawierających takie związki tlenowe jak etanol czy etery. Zastosowanie do badania tych zależności i tworzenie modelu dodatkowych danych uzyskanych przy pomocy metody chromatograficznej może wyraźnie wskazać czynniki wpływające na nieliniowość zachowań właściwości benzyn silnikowych. W przedstawionym projekcie przebadano szereg próbek paliw, o różnym składzie, mieszczącym się w zakresie składów benzyn dostępnych na rynku paliw. Wykorzystano dane doświadczalne pochodzące z badań właściwości szeregu mieszanek benzyn zestawionych w laboratorium, zawierających w swoim składzie eter etylowo-tert-butylowy (EETB) w ilości do 22% (V/V) i/lub etanol w ilości do 11% (V/V). Wyniki przeprowadzonych badań, w których wykorzystano niezagregowane dane i obliczenia przy użyciu sieci neuronowych, są zachęcające. Wskazują one jednocześnie, że szacowanie istotnych właściwości benzyny silnikowej E10 tą metodą może być użyteczne i pomocne producentom tego gatunku paliwa.

Słowa kluczowe: sieci neuronowe, benzyny silnikowe, predykcja właściwości.

Application of neural networks in research on the development of a computer model of nonlinear properties of motor fuels containing bio-ethanol and ethyl-tert-butyl ether

Neural network modeling techniques commonly used in researching complex phenomena, including chemical processes are not possible to be unambiguously described using parametric formulas. These problems are common when predicting the properties of mixtures of hydrocarbon fuel (petrol) containing such components of oxygenates as ethanol or ethers. Application to the study of these relationships and creating a model of additional data obtained by chromatographic methods may indicate more clearly the factors that affect the behavior of nonlinear petrol properties. In the design presented in the article, a number of fuel samples were tested from various sources (of various compositions) ranging from compositions of commercially available petrol fuels. The experimental data used came from the tested properties of a range of petrol compounds juxtaposed in a laboratory containing in their composition ethyl-tert-butyl ether (ETBE) in an amount up to 22%, or ethanol (ETOH) in an amount up to 11%. The results of the tests and calculations are encouraging and indicate that estimating material, properties, petrol E10 using neural networks can be a useful tool to assist the producer of this type of fuel.

Key words: neural network, petrol, prediction of properties.

Wstęp

Techniki modelowania sieciami neuronowymi są używane powszechnie w badaniach skomplikowanych zjawisk, w tym procesów chemicznych niemożliwych do jednoznacznego

opisania z zastosowaniem formuł parametrycznych. Problemy te ujawniają się przy predykcji właściwości mieszanin paliw węglowodorowych (benzyn silnikowych) zawierają-

cych jako składniki związki tlenowe, np. etanol czy etery. Zastosowanie do badania tych zależności i tworzenie modelu dodatkowych danych uzyskanych przy pomocy metody chromatograficznej może wyraźnie wskazać czynniki wpływające na nieliniowość zachowań właściwości benzyn silnikowych. W przedstawionym projekcie przebadano zbiór próbek paliw, o różnym składzie, mieszczących się w zakresie składów benzyn dostępnych na rynku paliw. Wykorzystano również dane doświadczalne pochodzące z badań właściwości

szeregu mieszanek benzyn zestawionych w laboratorium, zawierających eter etylowo-tert-butylowy (EETB) w ilości do 22% (V/V) i/lub etanol w ilości do 11% (V/V). Wyniki przeprowadzonych badań i obliczeń są zachęcające oraz wskazują, że szacowanie z użyciem sieci neuronowych istotnych właściwości benzyny silnikowej E10, przy wykorzystaniu niezagregowanych danych (zmiennych niezależnych), może być użytecznym narzędziem pomocnym producentowi tego gatunku paliwa.

Problem nieaddytywności właściwości w benzynach silnikowych zawierających biokomponenty

Paliwa do silników o zapłonie iskrowym powinny spełnić wysokie wymagania użytkowe i eksploatacyjne, jakie stawiają przed nimi nowoczesne silniki spalinowe i ich elementy, np. wielopunktowe systemy wtrysku paliwa oraz katalityczne wielofunkcyjne układy oczyszczania spalin. Właściwości i jakość takich paliw równoważą wypadkowe wymagań postawionych przez konstruktorów silników, producentów paliw oraz ich możliwości technologicznych, a także wymaganej minimalizacji degradacji środowiska naturalnego [5, 7].

Wymogi te będą coraz bardziej restrykcyjne wraz ze wzrostem wymagań ochrony środowiska, doskonałości konstrukcji silników samochodowych i systemów oczyszczania spalin.

Wraz z wprowadzeniem do składu benzyn silnikowych związków tlenowych powstaje problem nieaddytywności

niektórych właściwości fizykochemicznych [2, 3, 4]. Zjawisko to pojawia się w wyniku zmieszania ze sobą frakcji węglowodorowych o różnym składzie grupowym. Zmieszanie ze sobą różnych węglowodorów w dowolnych proporcjach powoduje, że badana właściwość mieszaniny jest inna niż spodziewana, którą otrzymano by poprzez proste wyliczenie – jako sumę iloczynów udziałów poszczególnych frakcji i wartości ich właściwości. Powoduje to zazwyczaj konieczność korekty właściwości benzyny bazowej, przygotowywanej jako komponent finalnego paliwa silnikowego.

Do takich nieaddytywnych parametrów zaliczane są: liczby oktanowe oraz właściwości lotnościowe mieszanin związków tlenowych (np. etanol i etery) z frakcjami węglowodorowymi czy z bazową benzyną silnikową.

Część doświadczalna

Badaniem objęto próbki benzyny silnikowej zawierającej biokomponenty (etanol i EETB). Zakres udziałów procentowych (V/V) komponentów przedstawiono w tabelicy 1.

Tablica 1. Zakres udziałów procentowych (V/V) komponentów w mieszankach benzyn silnikowych, będących przedmiotem badań

Komponent	Udział procentowy [% (V/V)]	Niepewność odtwarzalności pomiaru objętości [% (V/V)]
Frakcje izoparafinowe C ₈	do 10,7	0,05
Frakcje aromatyczno-parafinowe	do 37	0,05
Frakcje benzynowe z krakingu katalitycznego	do 48	0,05
Frakcje benzynowe z hydrokrakingu	do 8,3	0,05
Frakcja C ₅	do 10,7	0,05
Frakcja C ₄	do 4,0	0,05
Frakcje izoparafinowe C ₅ –C ₆	do 26	0,05
Frakcja aromatyczna C ₈ –C ₉	do 8	0,05
Etanol	do 11	0,05
EETB	do 22	0,05

Niepewność metod badawczych stosowanych przy oznaczaniu właściwości benzyn silnikowych stanowiących dane wejściowe do obliczeń

W tabelicy 2 zestawiono niepewność odtwarzalności metod badawczych stosowanych przy określaniu właściwości

mieszanek paliwowych będących podstawą do zestawienia zbioru danych wejściowych.

Tablica 2. Niepewność metod badawczych

Badana właściwość	Metoda oznaczenia według normy	Niepewność metody
Liczba oktanowa motorowa, LOM	PN-EN ISO 5163	$\pm 0,5$ jedn.
Liczba oktanowa badawcza, LOB	PN-EN ISO 5164	$\pm 0,4$ jedn.
Prężność par DVPE	PN-EN 13016-1	$\pm 1,5$ kPa
Zawartość etanolu	PN-EN 1601	$\pm 0,2\%$ (V/V)
Zawartość EETB	PN-EN 1601	$\pm 0,6\%$ (V/V)
Destylacja normalna:		
– E70	PN-EN ISO 3405	$\pm 3,9\%$ (V/V)
– E100	PN-EN ISO 3405	$\pm 2,1\%$ (V/V)
Identyfikacja i zawartość węglowodorów	ASTM D 5134	$\pm 0,01\%$ (m/m)

Przygotowanie zbioru danych wejściowych

Z komponentów wymienionych w tablicy 1, dla których oznaczono zawartości poszczególnych węglowodorów metodą chromatograficzną, zestawiono szereg mieszanek benzynowych. W wyniku oznaczenia zawartości węglowodorów dla każdego z komponentów uzyskano dane o ich składzie masowym (mieszanki od 1 do 419 węglowodorów). Dla każdej mieszanki (benzyny silnikowej), zestawionej z komponentów według tablicy 1, oznaczono: LOB, LOM, DVPE, E70 i E100.

Otrzymane wyniki zgromadzono w tabeli zbiorczej, w której dla każdej mieszanki (benzyny silnikowej) zestawionej laboratoryjnie zebrano następujące dane:

- skład węglowodorowy (1÷419 węglowodorów w procentach masowych),
- oznaczone właściwości E70, E100, DVPE, LOM, LOB.

Tak otrzymany zbiór surowych danych poddano filtracji z użyciem drzew klasyfikacyjnych, w celu oddzielenia danych istotnych od zbędnych.

W wyniku wstępnych przygotowań tablice danych ograniczono do:

- składu węglowodorowego (1÷290 węglowodorów w procentach masowych) – zmienne niezależne,
- oznaczonych właściwości E70, E100, DVPE, LOM i LOB – zmienne zależne.

Ze zbioru danych wydzielono też próbki testowe i walidacyjne, których użyto przy sprawdzeniu poprawności działania wybranych modeli rozwiązań.

Ponadto wydzielono próbki, które później użyto do sprawdzenia trafności przewidywania rozwiązań otrzymywanych dla danych wprowadzanych na wejścia wdrożonych sieci.

Obliczenia i wdrożenie przyjętych rozwiązań

Po wczycaniu zbioru uczącego (danych doświadczalnych) do programu *Statistica: Automatyczne sieci neuronowe* dokonano analizy danych.

Wybrano zmienne wyjściowe i wejściowe, po czym podzielono zbiór danych na części: uczącą (70%), testową (15%) i walidującą (15%).

W kolejnym kroku wybrano: typ poszukiwanej sieci (w tym przypadku MLP lub RBF), liczbę uczonych sieci (20 000) i zachowanych najlepszych sieci (5). Wstępnie przyjęto logistyczną funkcję aktywacji dla neuronów ukrytych i wyjściowych sieci MLP oraz liczbę neuronów ukrytych dla obu rodzajów sieci (MLP i RBF) w ilości od 4 do 50. Założono też wstępnie ilość neuronów wyjściowych od 1 do 2 – każda badana właściwość gotowej benzyny silnikowej pojedynczo (np. E70, E100, DVPE, LOM, LOB) lub parami (np. E70 i E100 lub LOM i LOB).

W celu uniknięcia przeuczenia sieci, poddawanej następnie wdrożeniu, przeprowadzono minimalizację liczby neuronów w warstwach ukrytych, przy zachowaniu założonej dokładności predykcji sieci. Otrzymane modele przetestowano dodatkowo na szeregu próbek benzyn silnikowych pochodzących z polskiego rynku paliw, dla których oznaczono skład indywidualny metodą chromatograficzną oraz wykonano analizę parametrów E70, E100, DVPE, LOM i LOB. Interesujące wyniki, ze względu na dokładność przewidywania, otrzymano dla sieci MLP posiadających jedno wyjście.

W tablicy 3 zaprezentowano wybrane sieci neuronowe, dla których zestawiono jakość uczenia, testowania i walidacji wraz z ich błędami.

W tablicach 4–6 zestawiono przykładowe dokładności przewidywania rozwiązań osiągniętych przy pomocy sieci

Tablica 3. Wybrane sieci neuronowe z jakością uczenia, testowania, walidacji i ich błędami

Nr sieci	Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Błąd (uczenie)	Błąd (testowanie)	Błąd (walidacja)
Podsumowanie aktywnych sieci dla E70 i danych zawartych w pliku (danech_d12małeE70E100.sta)							
1	MLP 290-37-1	0,996	0,998	0,994	0,119	0,097	0,650
2	MLP 290-15-1	0,997	0,982	0,997	0,102	0,367	0,386
3	MLP 290-14-1	0,996	0,988	0,997	0,118	0,231	0,561
4	MLP 290-8-1	0,993	0,979	0,991	0,214	0,563	1,028
5	MLP 290-28-1	0,990	0,976	0,996	0,315	0,446	1,925
Podsumowanie aktywnych sieci dla E100 i danych zawartych w pliku (danech_d12małeE70E100.sta)							
1	MLP 290-49-1	0,983	0,995	0,995	0,770	0,559	0,233
2	MLP 290-35-1	0,980	0,995	0,997	0,906	0,503	0,501
3	MLP 290-35-1	0,981	0,994	0,995	0,892	0,536	0,465
4	MLP 290-8-1	0,990	0,998	0,996	0,462	0,319	0,078
5	MLP 290-32-1	0,988	0,995	0,997	0,530	0,378	0,189
Podsumowanie aktywnych sieci dla DVPE i danych zawartych w pliku (danech_d12małe_RVP.sta)							
1	MLP 290-8-1	0,991	0,987	0,996	1,094	2,115	0,541
2	MLP 290-23-1	0,999	0,967	0,979	0,131	5,010	2,404
3	MLP 290-36-1	0,981	0,984	0,978	2,232	1,703	2,750
4	MLP 290-9-1	1,000	0,985	0,981	0,012	2,113	2,667
5	MLP 290-19-1	0,998	0,975	0,981	0,259	2,576	2,204
Podsumowanie aktywnych sieci dla LOB i danych zawartych w pliku (danech_d12małe_LOB.sta)							
1	MLP 290-14-1	0,993	0,982	0,934	0,006	0,025	0,046
2	MLP 290-25-1	0,992	0,994	0,916	0,006	0,024	0,091
3	MLP 290-44-1	0,910	0,980	0,918	0,069	0,046	0,030
4	MLP 290-25-1	0,978	0,964	0,908	0,017	0,054	0,030
5	MLP 290-47-1	0,985	0,975	0,985	0,011	0,030	0,013
Podsumowanie aktywnych sieci dla LOM i danych zawartych w pliku (danech_d12małe_LOM.sta)							
1	MLP 290-27-1	0,976	0,969	0,995	0,033	0,051	0,061
2	MLP 290-47-1	0,975	0,902	0,998	0,038	0,065	0,075
3	MLP 290-47-1	0,985	0,921	0,996	0,022	0,047	0,049
4	MLP 290-13-1	0,985	0,928	0,998	0,022	0,071	0,016
5	MLP 290-21-1	0,983	0,917	0,996	0,024	0,059	0,050

neuronowych dla sieci o najmniejszej złożoności spośród wytypowanych:

- dla parametru E70 zależności między składnikami opisano za pomocą sieci neuronowej MLP o 290 neuronach wejściowych, 14 neuronach w warstwie ukrytej i jednym neuronie wyjściowym (MLP 290-14-1),
- dla parametru E100 zależności między składnikami opisano za pomocą sieci neuronowej MLP o 290 neuronach wejściowych, 8 neuronach w warstwie ukrytej i jednym neuronie wyjściowym (MLP 290-8-1),
- dla parametru DVPE zależności między składnikami opi-

- sano za pomocą sieci neuronowej MLP o 290 neuronach wejściowych, 8 neuronach w warstwie ukrytej i jednym neuronie wyjściowym (MLP 290-8-1),
- dla parametru LOB zależności między składnikami opisano za pomocą sieci neuronowej MLP o 290 neuronach wejściowych, 14 neuronach w warstwie ukrytej i jednym neuronie wyjściowym (MLP 290-14-1),
- dla parametru LOM zależności między składnikami opisano za pomocą sieci neuronowej MLP o 290 neuronach wejściowych, 13 neuronach w warstwie ukrytej i jednym neuronie wyjściowym (MLP 290-13-1).

Tablica 4. Przykładowe dokładności przewidywania rozwiązań osiągniętych przy pomocy sieci neuronowych dla E70 i E100

E70 Zm. zal.*	E70 – Wyjście – 3. MLP 290-14-1	E70 – Reszty – 3. MLP 290-14-1	Niepewność metody ozna- czenia E70	E100 Zm. zal.*	E100 – Wyjście – 4. MLP 290-8-1	E100 – Reszty – 4. MLP 290-8-1	Niepewność metody ozna- czenia E100
38,10	39,65	1,545	± 3,9	51,3	51,1	0,18	± 2,1
39,20	39,25	0,050	± 3,9	52,8	52,5	0,26	± 2,1
36,60	37,51	0,915	± 3,9	50,0	50,6	0,60	± 2,1
41,50	42,25	0,754	± 3,9	51,7	52,6	0,91	± 2,1
42,80	43,88	1,075	± 3,9	53,0	53,0	0,04	± 2,1
41,50	42,67	1,175	± 3,9	51,7	52,2	0,53	± 2,1
45,00	44,40	0,597	± 3,9	54,5	53,6	0,88	± 2,1
49,40	49,81	0,414	± 3,9	55,5	55,9	0,38	± 2,1
42,70	44,26	1,557	± 3,9	52,5	52,2	0,26	± 2,1
30,50	29,56	0,938	± 3,9	57,7	57,6	0,10	± 2,1

* Dane uzyskane doświadczalnie.

Tablica 5. Przykładowe dokładności przewidywania rozwiązań osiągniętych przy pomocy sieci neuronowych dla LOB i LOM

LOB – Zm. zal.*	LOB – Wyjście – 1. MLP 290-14-1	LOB – Reszty – 1. MLP 290-14-1	Niepewność metody ozna- czenia LOB	LOM – Zm. zal.*	LOM – Wyjście – 4. MLP 290-13-1	LOM – Reszty – 4. MLP 290-13-1	Niepewność metody ozna- czenia LOM
97,9	97,9	0,006	± 0,4	86,30	86,54	0,240	± 0,5
97,3	96,9	0,393	± 0,4	86,40	86,61	0,213	± 0,5
97,7	97,9	0,223	± 0,4	86,10	86,38	0,281	± 0,5
98,1	98,3	0,245	± 0,4	86,00	86,37	0,372	± 0,5
97,7	97,3	0,391	± 0,4	86,10	85,95	0,151	± 0,5
97,7	98,0	0,327	± 0,4	86,20	86,39	0,187	± 0,5
98,6	98,8	0,246	± 0,4	85,80	86,00	0,197	± 0,5
99,2	98,9	0,276	± 0,4	86,70	86,25	0,454	± 0,5
98,4	98,2	0,205	± 0,4	86,80	86,87	0,073	± 0,5
100,6	100,7	0,098	± 0,4	88,00	88,50	0,500	± 0,5

* Dane uzyskane doświadczalnie.

Tablica 6. Przykładowe dokładności przewidywania rozwiązań osiągniętych przy pomocy sieci neuronowych dla DVPE

DVPE – Zm. zal.*	DVPE – Wyjście – 1. MLP 290-8-1	DVPE – Reszty – 1. MLP 290-8-1	Niepewność metody ozna- czenia DVPE	DVPE – Zm. zal.*	DVPE – Wyjście – 1. MLP 290-8-1	DVPE – Reszty – 1. MLP 290-8-1	Niepewność metody ozna- czenia DVPE
55,60	54,89	0,709	± 1,5	59,50	60,42	0,921	± 1,5
57,00	57,34	0,336	± 1,5	54,70	54,30	0,403	± 1,5
57,00	56,52	0,477	± 1,5	57,00	56,52	0,477	± 1,5
57,80	56,39	1,414	± 1,5	57,70	58,52	0,821	± 1,5
56,60	56,55	0,046	± 1,5	57,80	56,39	1,414	± 1,5
80,40	79,25	1,145	± 1,5	56,60	56,55	0,046	± 1,5
71,40	71,77	0,368	± 1,5	56,60	56,55	0,046	± 1,5
53,80	53,75	0,049	± 1,5	90,70	91,99	1,292	± 1,5
61,10	59,70	1,403	± 1,5	75,40	75,62	0,218	± 1,5

* Dane uzyskane doświadczalnie.

Obliczono również:

- wartość średniego błędu bezwzględnego MAE, według wzoru:

$$MAE = \frac{1}{m} \sum_{\tau=1}^m |y_{\tau} - y_{\tau}^p|$$

gdzie:

y_{τ} – wartość rzeczywista (wynik badań, pomiaru),

y_{τ}^p – wartość przewidywana (obliczona),

m – liczba prognoz wartości zmiennej;

- wartość średniego błędu predykcji *ex post* RMSE odpowiadającego pierwiastkowi błędu średniokwadratowego, według wzoru:

$$RMSE = \sqrt{\frac{1}{m} \sum_{\tau=1}^m (y_{\tau} - y_{\tau}^p)^2}$$

gdzie:

y_{τ} – wartość rzeczywista (wynik badań, pomiaru),

y_{τ}^p – wartość przewidywana (obliczona),

m – liczba prognoz wartości zmiennej.

Podobne obliczenia wykonano dla danych zagregowanych, a parametry charakteryzujące jakość predykcji przedstawiono w tabelicy 7.

Analiza wartości MAE i RMSE dla danych zawartych w tabelicach 4–6, a przedstawionych w tabelicy 7, oraz porównanie wartości modułów reszt (obliczanych jako moduł różnicy między wartością będącą wynikiem badań doświadczalnych a wartością przewidywaną) wskazuje, że w badanym zakresie, dla wszystkich przewidywanych właściwości benzyn silnikowych z zawartością EETB i/lub etanolu (E70, E100, DVPE, LOM, LOB) zastosowanie rozwiązań używających sieci neuronowe daje zadowalające i bardziej precyzyjne wyniki dla sieci, w których na wejścia podawane są jako zmienne niezależne dane niezagregowane (wyniki otrzymane metodą badań chromatograficznych). Mniej korzystne wyniki uzyskuje się w wypadku sieci używających danych zagregowanych (na wejścia podawane są jako zmienne niezależne, udział komponentów benzyn silnikowych w mieszance).

Nadal zostaje zachowana zależność pomiędzy ilością wyjść a precyzją predykcji; modele sieci zawierające pojedyncze wyjścia charakteryzują się większą dokładnością predykcji od sieci posiadających kilka wyjść (opisujące grupowo poszukiwane parametry – na wyjściu sieci jednocześnie kilku poszukiwanych parametrów, np. E70, E100, LOM, LOB). Wynika to z mniejszych wymagań takich rozwiązań w odróżnieniu od wymaganej do zgromadzenia liczby danych (serii danych).

Tabela 7. Różnica między wartością zbadaną a obliczoną dla wyników kalkulacji właściwości benzyn silnikowych z etanolem i/lub EETB

Rodzaj danych	Parametry charakteryzujące jakość predykcji	ΔE70	ΔE100	ΔDVPE	ΔLOB	ΔLOM
Dane zagregowane	max odchylenie	2,20	1,10	4,90	0,90	0,90
	MAE	0,86	0,49	4,60	0,24	0,23
	RMSE	1,03	0,58	2,60	0,49	0,48
	RMSE – MAE	0,17	0,09	-2,00	0,25	0,25
Dane niezagregowane	max odchylenie	1,56	0,91	1,41	0,39	0,50
	MAE	0,90	0,41	0,64	0,24	0,27
	RMSE	1,01	0,51	0,81	0,27	0,30
	RMSE – MAE	0,11	0,09	0,17	0,03	0,03

Podsumowanie

W artykule zaprezentowano uzyskane efekty dotyczące badań możliwości zastosowania sieci neuronowych do modelowania nieliniowych zależności pomiędzy składem chemicznym benzyn silnikowych zawierających biokomponenty (w szczególności bioetanol) a ich właściwościami.

Jak wykazano w tabelicach 4–7, sieci neuronowe i modele uzyskiwane przy ich pomocy mogą być przydatnym oraz sku-

tecznym narzędziem w badaniach właściwości paliw ciekłych i przy opracowywaniu w tym zakresie nowych technologii.

Już przy skromnej liczbie serii danych doświadczalnych (obejmujących cały obszar przewidywanych właściwości benzyn silnikowych) uzyskane modele wykazują dobre właściwości predykcyjne poszukiwanych parametrów benzyn silnikowych – lepsze w przypadku wprowadzenia (jako danych wejściowych)

indywidualnego składu chemicznego benzyn silnikowych niż składników zagregowanych jako komponenty – i mieszczą się w zakresie niepewności znormalizowanych metod badawczych stosowanych przy oznaczaniu tych właściwości.

Modele opracowane na bazie sieci neuronowych dają oczekiwaną dokładność w przewidywaniu wartości właściwo-

ści wykazujących nieliniową zależność od składu chemicznego benzyn silnikowych, dla których opracowano te modele.

Przeprowadzone badania zachęcają do dalszych prac nad zastosowaniem sieci neuronowych do identyfikacji składu komponentowego benzyn silnikowych na podstawie indywidualnego składu chemicznego benzyny silnikowej.

Prosimy cytować jako: Nafta-Gaz 2013, nr 8, s. 619–625

Artykuł powstał na podstawie dokumentacji INiG DK-4100-21/12 (0021/XX/12), pt.: *Zastosowanie sieci neuronowych w badaniach nad stworzeniem komputerowego modelu nieliniowych właściwości benzyn silnikowych zawierających bioetanol i eter etylowo-tert butylowy*, która została zrealizowana w ramach działalności statutowej.

Literatura

- [1] Aczel A. D.: *Statystyka w zarządzaniu*. PWN. Warszawa 2000.
- [2] Commission Staff Working Document; Impact Assessment of a Proposal for a Directive of the European Parliament and of the Council modifying Directive 98/70/EC relating to the quality of petrol and diesel fuels; SEC(2007)55; Bruksela. 31.01.2007.
- [3] Komunikat Komisji do Rady i Parlamentu Europejskiego: *Wyniki przeglądu wspólnotowej strategii na rzecz zmniejszenia emisji CO₂ pochodzących z samochodów osobowych i lekkich pojazdów dostawczych* COM(2007)19, z dn. 7.02.2007.
- [4] Marshall E. L., Owen K.: *Motor Gasoline; The Royal Society of Chemistry*. UK, 1995.
- [5] Pałuchowska M., Rogowska D.: *Wpływ bioetanolu na nieaddytywne właściwości benzyny silnikowej*. Nafta-Gaz 2009, nr 1, s. 21–28.
- [6] Radziukiewicz M.: *Ocena dokładności i trafności prognoz*. Wykłady.
- [7] Rogowska D.: *Problem nieaddytywnych efektów mieszania dla parametru „prężność par” w trakcie blendingu biopaliwa E85*. Nafta-Gaz 2009, nr 3, s. 211–215.

Mgr inż. Bogusław HADUCH

Starszy specjalista badawczo-techniczny, kierownik Biura Kontroli.

Instytut Nafty i Gazu

ul. Lubicz 25A

31-503 Kraków

E-mail: haduch@inig.pl

ZAKŁAD ANALIZ NAFTOWYCH

Zakres działania:

- kompleksowa analiza rop naftowych;
- badanie składu chemicznego i ocena jakości produktów naftowych, biokomponentów, biopaliw, paliw alternatywnych;
- ocena potencjalnej kancerogenności produktów naftowych, w tym test DAB-10;
- oznaczanie metali ciężkich w produktach naftowych świeżych i zużytych oraz w odpadach;
- identyfikacja substancji pochodzących z degradacji produktów naftowych;
- usługi: monitorowania jakości paliw ciekłych i biopaliw, monitorowania jakości LPG, monitorowania stopnia zużycia olejów silnikowych w pojazdach;
- opracowywanie nowych metod analitycznych dla produktów naftowych i pokrewnych: świeżych, w eksploatacji i zużytych;
- identyfikacja i oznaczanie toksycznych związków emitowanych z silników wysokoprężnych (WWA w cząstkach stałych PM);
- usługi eksperckie i rzeczoznawcze w zakresie: orzecznictwa o jakości paliw silnikowych, analityki produktów naftowych, problemów związanych z eksploatacją produktów naftowych i produktów pokrewnych;
- badania i doradztwo w zakresie klasyfikacji surowców i produktów naftowych w odniesieniu do Nomenklatury Scalonej (CN);

Kierownik: dr inż. Beata Altkorn

Adres: ul. Łukasiewicza 1, 31-429 Kraków

Telefon: 12 617-76-00

Faks: 12 617-76-80, 12 617-75-22

E-mail: beata.altkorn@inig.pl