

Bogusław Haduch

*Instytut Nafty i Gazu – Państwowy Instytut Badawczy*

Ryszard Tadeusiewicz

*AGH Akademia Górniczo-Hutnicza*

*Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej*

# Wykorzystanie sieci neuronowych w dochodzeniach związanych z przestępczością gospodarczą na rynku paliw płynnych. Część 1

W artykule dokonano krótkiego przeglądu literatury poświęconej wykorzystaniu sieci neuronowych przy określaniu niektórych właściwości benzyn silnikowych, istotnych przy predykcji ich jakości w powiązaniu ze składem chemicznym oznaczanym metodami chromatograficznymi (GC–FID, GC–MS).

Słowa kluczowe: sieci neuronowe, benzyna silnikowa, właściwości benzyn silnikowych.

## The use of neural networks in investigations related to economic crime on the liquid fuels market. Part 1

In the article a brief review of the literature on the use of neural networks in the determination of certain properties of motor gasoline relevant for the prediction of their quality in relation to chemical compositions determined by chromatography (GC–FID, GC–MS) was done.

Key words: neural networks, motor gasoline, motor gasoline properties.

### Wstęp

W ramach swojej działalności instytucje badawcze wykonują lub mogą wykonywać szereg usług eksperckich i laboratoryjnych dla organów ścigania oraz instytucji zajmujących się monitoringiem jakości paliw, mających w efekcie poprawić bezpieczeństwo stosowania paliw ciekłych dostępnych na rynku polskim.

W walce z przestępczością gospodarczą związaną z fałszowaniem paliw ważne są dwa elementy:

- szybkie określenie składu chemicznego badanego paliwa w powiązaniu z jego właściwościami,
- wskazanie prawdopodobnego źródła pochodzenia zabezpieczonej próbki paliwa.

Trudności w szybkim i pewnym określeniu tych dwóch czynników uniemożliwiają szybką reakcję i skuteczne przeciwdziałanie zjawisku fałszowania paliw, powodującemu ol-

brzymie straty finansowe skarbu państwa. Możliwość szybkiego kojarzenia i odtwarzania całości informacji na podstawie informacji niepełnej oraz zdolność prawidłowego zinterpretowania danych zniekształconych lub niekompletnych byłaby bardzo pomocna przy rozwiązywaniu tego rodzaju problemów. Aktualnie w Polsce i w Europie w obrocie detalicznym występują benzyny silnikowe zawierające w swym składzie związki tlenowe (alkohole i etery), z których głównie stosowanymi są: etanol w ilości do 10% (V/V) oraz eter etylowo-tert-butyłowy. Paliwa te są bardzo wrażliwe na próby fałszowania. Wszelkie, nawet niewielkie zmiany w składzie komponentowym, powstające przy nieuprawnionej ingerencji, mogą spowodować zmiany właściwości paliw, wpływając negatywnie na środowisko naturalne i silniki spalinowe napędzane tym paliwem.

## Wpływ etanolu na lotność benzyny silnikowej

Lotność łączy ze sobą dwa parametry, które są istotne dla właściwej pracy silnika samochodowego o zapłonie iskrowym, tj. skład frakcyjny i prężność par [17, 28, 34, 35, 43–45].

W zakresie małych udziałów etanolu w benzynie silnikowej – do 10% (V/V) – wyraża się to nieaddytywnym pod-

wyższeniem ilości cieczy odparowującej do 70°C i drastycznym podwyższeniem prężności par. Nieodpowiednio dobrany skład węglowodorowy benzyny bazowej może być przyczyną problemów eksploatacyjnych. Parametry lotnościowe bowiem odpowiadają za właściwości rozruchowe paliwa.

## Wpływ etanolu na przebieg krzywej odparowania

Alkohole – etanol lub metanol – tworzą z benzyną silnikową mieszaniny azeotropowe wpływające na kształt krzywej odparowania [17, 28, 32, 34–36].

Ilość paliwa odparowującego do 70°C (E70) odpowiada za łatwość rozruchu zimnego silnika, nagrzewanie się silnika, emisję par i tworzenie się korków parowych. Środkowy zakres objętości paliwa odparowującego, tj. pomiędzy 70÷100°C (E100), wiąże się z szybkością rozgrzewania silnika, uzyskaniem odpowiedniego przyspieszenia i stabilną pracą silnika w warunkach zimowych [36]. Efekty mieszania objętościowego [17] etanolu z benzyną nie są odwzorowywane pro-

stym procesem (równaniem) liniowym. Proces ten jest wrażliwy na właściwości benzyny bazowej. Rozpiętość wartości przyrostów<sup>1</sup>  $\Delta E100$  była znacznie mniejsza niż w przypadku  $\Delta E70$ , zwłaszcza przy niższych stężeniach etanolu. Wyższe poziomy zawartości etanolu generowały przyrosty  $\Delta E100$  do 20% (V/V), podobnie mały przyrost  $\Delta E100$  wraz ze wzrostem E100 paliwa bazowego. Nieaddytywność parametru składu frakcyjnego benzyny zawierającej etanol jest przedmiotem badań prowadzonych w INiG – PIB od wielu lat. W czasie mieszania ze sobą frakcji węglowodorowych, a także etanolu, występują zarówno dodatnie, jak i ujemne efekty mieszania.

## Wpływ temperatur odparowania paliwa na właściwości eksploatacyjne silników o zapłonie iskrowym

Specyfikacja amerykańska benzyny ASTM określa wartości temperatur odparowania 10, 50 i 90% objętości paliwa. Limit wartości temperatury T50 podawany jest w przedziale minimum–maksimum, a dla T10 i T90 określony jest tylko limit górny. W przypadku mieszanin benzyny bazowej z różnymi alkoholami wartości te mogą zmieniać się w znacznym

stopniu [34, 35, 40]. Stosowanie mieszanin etanolu z benzyną silnikową obniża temperaturę odparowania tak powstałego paliwa, a przy stężeniach etanolu wyższych niż 10% może zmienić optymalne warunki pracy silnika, jeśli nie wprowadzi się odpowiedniej zmiany w formule benzyny bazowej wykorzystywanej do zestawiania gotowej benzyny silnikowej.

## Wpływ etanolu na prężność par

Prężność par określa łatwość uruchamiania silnika samochodowego i skłonność paliwa do tworzenia korków parowych. Parametr ten to dodatkowy wskaźnik oceny lotności paliwa i jest on powiązany z temperaturą początku destylacji oraz E70 [17, 28, 34, 35, 43–45, 48].

Benzyny silnikowe o dużej lotności odparowują bardzo szybko, co z jednej strony jest korzystne dla uruchamiania silnika w niskich temperaturach, z drugiej jednak – może powodować powstawanie korków parowych i zaburzać proces spalania, prowadząc nawet do zatrzymania silnika.

## Próby predykcji wartości niektórych parametrów jakościowych benzyny silnikowej z wykorzystaniem sieci neuronowych

Jak przedstawiono powyżej, zjawisk fizykochemicznych obserwowanych przy produkcji i użytkowaniu benzyn silnikowych nie da się opisać przez prostą aproksymację liniową, nie narażając się na błędy mogące być przyczyną strat lub awarii, zwłaszcza wówczas, gdy w zbiorniku „spotkają się” (np. w wyniku zbiegu okoliczności lub w efekcie fałszerstwa) paliwa lub komponenty dające niekorzystne dla użytkownika „efekty zmieszania”.

Właśnie w takich sytuacjach najszybszym i najwygodniejszym rozwiązaniem problemu może stać się wykorzystanie sieci neuronowych mogących opisywać zależności nieliniowe. Sieci neuronowe i układy na nich oparte umożliwiają kontrolę

<sup>1</sup> $\Delta E70$ ,  $\Delta E100$  odparowanej (oddestylowanej) objętości benzyny do temperatury 70°C i 100°C.

nad złożonym problemem wielowymiarowości, który przy stosowaniu innych metod znacząco utrudnia próby modelowania zależności nieliniowych z dużą liczbą zmiennych. Sieci neuronowe same konstruują potrzebne użytkownikowi modele i automatycznie uczą się na podanych przez niego przykładach.

Warunkiem koniecznym przy stosowaniu sieci neuronowych jest posiadanie odpowiedniej liczby serii danych i istnienie rzeczywistej zależności lub zespołu zależności. Badania przeprowadzone w ramach szeregu prac [6, 9, 13, 15, 16, 18, 25, 27, 29, 32, 34–36, 38, 42] wskazują na istnienie nieaddytywnych zależności pomiędzy właściwościami benzyn bazowych a benzyn zawierających związki tlenowe.

Przegląd literaturowy [2, 5, 8, 11, 12, 14, 30, 37, 47, 46] w zakresie wykorzystywania sieci neuronowych do predykcji właściwości benzyn silnikowych i ich składników w zależności od składu chemicznego (badanego różnymi sposobami) pokazuje, że bardzo istotne jest zgromadzenie odpowiedniej liczby serii danych (wystarczającego materiału do analizy), aby można było w pełni wykorzystać możliwości interpretacyjne sieci neuronowych. W innych przypadkach można tylko przypuszczać, że w sieciach neuronowych drzemie ogromny potencjał, ale nie do końca będzie to możliwe do wykazania.

Dla małej liczby serii danych sieci neuronowe będą odwzorowywać tylko zależności liniowe, co można osiągnąć również, kreśląc lub obliczając linie trendu.

Przykładowo na podstawie małego zbioru próbek badawczych, obejmującego zakres liczby oktanowej od 81,4 do 99,7 jedn., opisano problem przewidywania liczby oktanowej z użyciem sieci neuronowych na podstawie składu chemicznego mieszanek benzynowych [8]. Przeanalizowano 45 próbek benzyn różnej jakości, badając liczbę oktanową i całkowity skład grupowy w oparciu o metodę chromatograficzną według ASTM D5134 (oznaczenie sumy zawartości (% [m/m]): n-parafin, i-parafin, naftenów, olefin i aromatów). Zawartość (wyrażona w % [m/m]) etanolu (0÷5) oraz sumy zawartości n-parafin (4,627÷7,867), i-parafin (18,339÷52,151), naftenów (1,398÷26,275), olefin (0,029÷22,713) i aromatów (13,863÷71,990) użyto jako dane wejściowe dla sieci neuronowej obliczającej liczbę oktanową.

Wyniki pomiarów (widm) w podczerwieni (FTIR) i wyniki oznaczenia składów indywidualnych chemicznych metodą chromatografii gazowej użyto do przewidywania jakości benzyny i jej klasyfikacji.

Dane zostały przetworzone za pomocą analizy głównych składowych (PCA – *Principal Components Analysis*) i algorytmów, opartych o logikę rozmytą (FCM – *Fuzzy Cognitive Maps*), stając się danymi poddawanymi analizie i klasyfikowanymi przez sieci neuronowe i hybrydowe maszyny wektorów nośnych (SVM – *Support Vector Machine*).

Jako dane uczące wykorzystano 35 mieszanek benzyn silnikowych, a jako zbiór testowy 10 mieszanek benzyn.

Dla takiego zbioru danych jakość (dokładność) przewidywania liczby oktanowej dokonywana przy pomocy regresji wielorakiej i sieci neuronowych jest porównywalna.

W przypadku klasyfikacji benzyn silnikowych w zależności od widma IR próbek i ich składu chemicznego zauważyć można zależność nieliniową, co skłania ku szerszemu badaniu problemu w oparciu o większą liczbę próbek.

Ze zbioru 1284 próbek, pochodzących z brazylijskiego rynku paliw w roku 2001, wylosowano 180 próbek o gęstości pomiędzy 0,7400 a 0,7800 g/cm<sup>3</sup>, a spośród nich wylosowano 35 próbek benzyn, charakteryzujących się maksymalną i minimalną zawartością etanolu lub węglowodorów aromatycznych albo parafin i olefin [14]. Przyjęto, że wybrany zestaw 35 próbek jest reprezentatywny dla całego zbioru 1284 próbek.

35 wybranych próbek poddano analizie:

- składu węglowodorowego – w oparciu o metodę chromatograficzną GC–FID. Chromatogramy poddano obróbce przy pomocy specjalistycznego oprogramowania (DHA – *Detailed Hydrocarbon Analysis*) identyfikującego około 500 składników (pików chromatograficznych pochodzących od węglowodorów występujących w benzynach). Niezidentyfikowane związki stanowiły około 8% (były to związki zawierające azot, siarkę oraz olefiny i niektóre związki aromatyczne).

Warunki prowadzenia oznaczeń:

- kolumna: CP-SIL PONA CB FS 100 m × 0,25 mm (0,5), Chrompack,
- gaz nośny: hel, prędkość liniowa 30,0 do 30,2 cm/s przy 35°C,
- detektor: FID, temperatura: 300°C,
- gazy: wodór, powietrze, azot,
- dozownik: temp. 250°C, dzielnik strumienia – 200:1;
- badań według norm ASTM:
  - ciężar właściwy w 20°C,
  - prężność par (RVP), metoda mini Reid,
  - metoda destylacji atmosferycznej ASTM D86 (IBP, T10, T50, T90, FBP)<sup>2</sup>.

Ze zbioru wyników badań 35 próbek 25 zostało wykorzystanych jako zestaw szkoleniowy, a 10 jako zestaw testów dla sieci neuronowych (SSN).

Skład chemiczny benzyn oznaczano metodą chromatograficzną (węglowodory grupowano według ich głównej funkcji chemicznej). Jako dane wejściowe do sieci neuronowych wykorzystano:

<sup>2</sup>IBP – temperatura początku destylacji; T10, T50, T90 – temperatura oddestylowania odpowiednio: 10, 50 i 90% objętościowych próbek; FBP – temperatura końca destylacji.

- pełny raport, opisujący udziały objętościowe frakcji, to jest 66 grup węglowodorów:
  - parafiny (PC3, PC4, PC5, PC6, PC7, PC8, PC9, PC10, PC11, PC12, PC13, PC14, PC15, PC16); aromaty (AC6, AC7, AC8, AC9, AC10, AC11, AC12, AC13, AC14, AC15), C14+ (C14, C15); izoparafiny (IC5, IC6, IC7, IC8, IC9, IC10, IC11, IC12); olefiny (OLC4, OLC5, OLC6, OLC7, OLC8, OLC9, OLC10, OLC11, OLC12, OLC13, OLC14, OLC15, OLC16),
  - związki zawierające tlen (OX2, OX3, OX4) i niezidentyfikowane – w tym związki zawierające azot i siarkę (UC5, UC6, UC7, UC8, UC9, UC10, UC11, UC12, UC13);
- zwięzłe sprawozdanie, składające się z sumarycznie przedstawionych udziałów głównych grup węglowodorów: parafin, izoparafin, aromatów, naftenów i olefin oraz związków tlenowych i niezidentyfikowanych.

W wyniku zastosowania sieci neuronowych w obu przypadkach nie osiągnięto oczekiwanych przez badaczy wyników, tj. poprawnego przewidywania prężności par (RVP) oraz parametrów destylacji normalnej T10, T50, T90.

Spowodowane było to zbyt małą ilością danych uczących. Sieci odwzorowywały tylko zależności liniowe lub uczyły się na pamięć, co mogło być efektem zbyt małej głębokości sieci lub nieodpowiednio dobranych przykładów uczących.

Wykorzystano sieć neuronową do przewidywania liczby oktanowej badawczej benzyny silnikowej [31]. W badaniach starano się powiązać skład komponentowy mieszanin, wyrażony udziałami objętościowymi pięciu komponentów

o specyficznych właściwościach, z właściwościami powstałych mieszanek (gotowych benzyn): gęstością, prężnością par (RVP), parametrami destylacji i zawartością siarki. Właściwości mieszanki stosowanej jako dane wejściowe zmienionych w modelu obliczano jako funkcje liniowe stężeń komponentów. Odchylenie standardowe błędu predykcji mieściło się na ogół poniżej 0,8 jedn. RON/MON. Jednak stosunkowo wąski przedział zawartości składników badanej benzyny budzi wątpliwość co do możliwości ekstrapolacji wyników na benzyny o innych składach.

W literaturze przedstawiono możliwość zastosowania w warunkach produkcji w greckiej rafinerii sieci neuronowych do przewidywania liczby oktanowej badawczej (RON) produkowanych mieszanek benzyn [37]. Opracowane modele ANN wykorzystywały jako zmienne wejściowe udziały objętościowe siedmiu najczęściej stosowanych w warunkach rafinerii komponentów: strumieni z fluidalnego krakingu katalitycznego (FCC) – benzyny krakingowej, reformatu (REF), izomeryzatu (ISO), alkilatu (ALK) i dimersolu (DIM) wraz z frakcją butanową (C4) oraz eterem metyloowo-tert-butylowym (MTBE).

Algorytm służył do określania składu benzyny bazowej (pominięto stały strumień frakcji butanowej i MTBE). Uzyskana dokładność przewidywania wynosiła w warunkach rafinerijnych 0,2 jedn. dla liczby oktanowej badawczej (RON).

Stwierdzono, że w warunkach rafinerijnych możliwe jest wiarygodne przewidywanie RON mieszanek benzynowych przy zastosowaniu sieci neuronowych z dokładnością porównywalną do odpowiedniej standardowej metody ASTM.

### Możliwości interpretacyjne systemów wykorzystujących sztuczną inteligencję

Przy tworzeniu systemów wykorzystujących sztuczną inteligencję, zbierających dane i generujących wiedzę ważne jest zgromadzenie odpowiedniej liczby zmiennych niezależnych (danych różnicujących poszczególne składniki), mogących mieć wpływ na zmienne zależne (poszukiwane właściwości). Drugorzędną sprawą jest dokładna interpretacja zjawisk czy ich składników, ponieważ końcowym efektem „rozumowania maszynowego” jest konkluzja: „tak” lub „nie” („0” lub „1”). W przypadku pików chromatograficznych (chromatogramów), używanych dla uczenia sieci neuronowej nieważne jest nazwanie związku, od którego pochodzi pik, lecz jego rozróżnienie lub zróżnicowanie [20–24].

Badania [2, 5, 7, 8, 11–14, 29–31, 37, 39, 41, 46, 47] wskazują na ograniczenia interpretacyjne systemów wykorzystujących dane zagregowane. W takiej sytuacji nie można jednoznacznie wskazać, który składnik jest krytyczny w danej mieszaninie, zwłaszcza przy badaniu bardziej złożonych zjawisk. Przy agregacji danych istnieje również możliwość, że otrzymana się zależności zmieniające się w pewnym zakresie podobnie

jak wielkości poszukiwane, jednakże opisujące inne zjawisko niż badane. W przypadku próby wykorzystania tak przyjętej zależności w realnych warunkach może to skutkować całkowicie błędnymi wynikami prognoz. Rozwiązaniem tego problemu wydaje się być zastosowanie bardziej wyrafinowanych metod badawczych dających nowe informacje o analizowanym przedmiocie. Wykorzystanie metod chromatograficznych, a w szczególności metody GC–MS [1, 4, 26, 33], daje możliwość wprowadzania nowych wskaźników, które będą różnicować „piki związków” nieoznaczonych za pomocą GC–FID itp. Pozyskane dane mogą dostarczyć informacji na temat wzajemnego oddziaływania pomiędzy składnikami benzyny w mieszkankach, ujawniając charakter efektu mieszania.

Wadą systemu opartego na dużej liczbie zmiennych jest oczywiście trudność zdobycia wymaganej dużej liczby serii danych (tzw. „przekleństwo wielowymiarowości”), jednakże system taki z czasem odkrywać będzie prawdziwe (a nie pozorne) zależności w mieszaninie i wytworzy właściwą (prawdziwą) wiedzę na zadany temat.

## Podsumowanie

Niniejszy przegląd zastosowania sieci neuronowych w badaniach identyfikacyjnych próbek wskazuje na główne problemy, jakie mogą wystąpić przy próbie zastosowaniu sieci neuronowych do wykrywania przestępstw gospodarczych.

Szybkie określenie składu chemicznego badanego paliwa w powiązaniu z jego właściwościami wymaga dobrania odpowiedniego narzędzia (np. metody chromatograficzne GC-MS, GC-FID, GC-OFID), które dostarczy istotnych danych dla określenia newralgicznych parametrów benzyny silnikowej (RVP, E70, E100, RON, MON) dostępnej na polskim rynku paliw płynnych.

Przy wskazywaniu prawdopodobnego źródła pochodzenia zabezpieczonej próbki paliwa należy tak dobrać metody

identyfikacyjne i stopień agregacji danych, aby nie utracić (zatrzeć) atrybutów odróżniających próbki benzyn od siebie, przy rozsądnej, możliwej do przetworzenia przez wykorzystywany system obliczeniowy, ilości danych wejściowych.

Przedstawione w artykule przykłady danych literaturowych wskazują jedną z możliwych dróg wykorzystania potencjału sieci neuronowych dla celów identyfikacyjnych, a później śledczych w przypadku benzyn silnikowych zawierających związki tlenowe.

W kolejnym artykule pt.: *Wykorzystanie sieci neuronowych w dochodzeniach związanych z przestępczością gospodarczą. Część 2* przedstawione zostaną wyniki badań INiG – PIB, uzyskane w badaniach własnych.

Prosimy cytować jako: Nafta-Gaz 2017, nr 12, s. 974–979, DOI: 10.18668/NG.2017.12.09

Artykuł nadesłano do Redakcji 14.12.2016 r. Zatwierdzono do druku 6.10.2017 r.

Artykuł powstał na podstawie pracy statutowej pt.: *Zastosowanie sieci neuronowych w dochodzeniach śledczych INiG – PIB wykonywanych metodologią fingerprinting* – praca INiG – PIB na zlecenie MNiSW; nr zlecenia: 0075/TA/16/01, nr archiwalny: DK-4100-69/16.

## Literatura

- [1] Abdulrhman M. Dhabbah, Sultan S. Al-Jaber, Ahmad H. Al-Ghamdi, Ahmad Aqel: *Determination of Gasoline Residues on Carpets by SPME-GC-MS Technique*. Arab. J. Sci. Eng. 2014, vol. 39, nr 9, s. 6749–6756.
- [2] Achten C., Kolb A., Püttmann W.: *Sensitive method for determination of methyl tert-butyl ether (MTBE) in water by use of headspace-SPME/GC-MS*. Fresenius J. Anal. Chem. 2001, vol. 371, s. 519–525.
- [3] Adutwum L.A., Harynuk J.J.: *Unique Ion Filter: A Data Reduction Tool for GC/MS Data Preprocessing Prior to Chemometric Analysis*. Anal. Chem. 2014, vol. 86 (15), s. 7726–7733.
- [4] Ahmad Aqela, Abdulrhman M. Dhabbah, Kareem Yusufa, Nasser M. AL-Harbic, Zeid A. Al Othmana, A. Yacine Badjah-Hadj-Ahmeda: *Determination of Gasoline and Diesel Residues on Wool, Silk, Polyester and Cotton Materials by SPME-GC-MS*. Journal of Analytical Chemistry 2016, vol. 71, nr 7, s. 730–736.
- [5] Anderson J.E., Kramer U., Mueller S.A., Wallington T.J.: *Octane Numbers of Ethanol – and Methanol – Gasoline Blends Estimated from Molar Concentrations*. Energy Fuels 2010, vol. 24 (12), s. 6576–6585.
- [6] Babazadeh Shayan S., Seyedpour S.M., Omni F.: *Effect of oxygenates blending with gasoline to improve fuel properties*. Chinese Journal of Mechanical Engineering 2012, vol. 25, nr 4, s. 792–797.
- [7] Balabin R.M., Ravilya C., Safieva Z., Ekaterina C., Lomakina I.: *Universal technique for optimization of neural network training parameters: gasoline near infrared data example*. Neural Comput & Applic 2009, vol. 18, s. 557–565.
- [8] Brudzewski K., Kęsik A., Kołodziejczyk K., Zborowska U., Ulaczyk J.: *Gasoline quality prediction using gas chromatography and FTIR spectroscopy: An artificial intelligence approach*. Fuel 2006, vol. 85, s. 553–558.
- [9] Bruno T.J., Wolk A., Naydich A.: *Composition-Explicit Distillation Curves for Mixtures of Gasoline with Four-Carbon Alcohols (Butanols)*. Energy Fuels 2009, vol. 23, nr 4, s. 2295–2306, DOI: 10.1021/ef801117c.
- [10] Cartwright\_H., Curteanu S.: *Neural Networks Applied in Chemistry. II. Neuro-Evolutionary Techniques in Process Modeling and Optimization*. Ind. Eng. Chem. Res. 2013, vol. 52 (36), s. 12673–12688.
- [11] Cerda J., Pautasso P.C., Cafaro D.C.: *Optimizing gasoline recipes and blending operations using nonlinear blend models*. Ind. Eng. Chem. Res., Just Accepted Manuscript, 23.06.2016, American Chemical Society.
- [12] Cheng H., Zhong W., Qian F.: *An Application of the Particle Swarm Optimization on the Gasoline Blending Process*. [W:] Zeng D. (Ed.): ICAIC 2011, Part II, Springer-Verlag Berlin Heidelberg 2011, CCIS 225, s. 352–360.
- [13] Chopra A., Singh D., Manna R., Saravanan S., Sastry M.I.S., Patel M.B., Basu B.: *Estimation of Olefin Dimerisation Products by GC/GC-MS and IR Techniques*. Chromatographia 2014, vol. 77, s. 845–851.
- [14] Côcco L.C., Yamamoto C.I., Meien O.F.: *Study of correlations for physicochemical properties of Brazilian gasoline*. Chemometrics and Intelligent Laboratory Systems 2005, vol. 76, s. 55–63.
- [15] Danek B., Rogowska D.: *Destylacja benzyny silnikowej z zawartością do 10% (V/V) etanolu – obliczanie jej parametrów metodą addytywnych wskaźników mieszania*. Nafta-Gaz 2014, nr 3, s. 192–196.
- [16] Environmental Protection Agency [EPA-HQ-OAR-2009-0211; FRL-9258-6] Partial Grant of Clean Air Act Waiver Application Submitted by Growth Energy to Increase the Allowable Ethanol Content of Gasoline to 15 Percent. Decision of the Administrator. Federal Register, vol. 76, nr 17, Wednesday, January 26, 2011, Notices.
- [17] *Ethanol/petrol blends: volatility characterisation in the range 5-25 vol% ethanol*. TREN/D2/454-2008-SI.2.522.698 (Final Report). Brussels: EU Commission; [https://ec.europa.eu/energy/sites/ener/files/documents/2010\\_bep525\\_final\\_report.pdf](https://ec.europa.eu/energy/sites/ener/files/documents/2010_bep525_final_report.pdf) (wrzesień 2016).
- [18] Ghosh P., Hickey K.J., Jaffe S.B.: *Development of a Detailed Gasoline Composition-Based Octane Model*. Ind. Eng. Chem. Res. 2006, vol. 45 (1), s. 337–345.
- [19] *Guidelines for blending and handling motor gasoline containing*

- up to 10% v/v ethanol. Report 3/2008, CONCAWE, Brussels, April 2008.
- [20] Haduch B.: *Zastosowanie sieci neuronowych w badaniach nad stworzeniem komputerowego modelu nieliniowych właściwości benzyn silnikowych zawierających bioetanol i eter etylo-wo-tert-butylowy*. Dokumentacja INiG – PIB, nr archiwalny: DK-4100/21/12.
- [21] Haduch B.: *Zastosowanie sieci neuronowych w badaniach nad stworzeniem komputerowego modelu nieliniowych właściwości benzyn silnikowych zawierających bioetanol i eter etylo-wo-tert-butylowy*. Dokumentacja INiG – PIB, nr archiwalny: DK-4100/51/13.
- [22] Haduch B.: *Zastosowanie sieci neuronowych w badaniach nad stworzeniem komputerowego modelu nieliniowych właściwości benzyn silnikowych zawierających komponenty tlenowe*. Dokumentacja INiG – PIB, nr archiwalny DK-4100/62/1.
- [23] Haduch B.: *Zastosowanie sieci neuronowych w badaniach nad stworzeniem komputerowego modelu nieliniowych właściwości benzyn silnikowych zawierających komponenty tlenowe*. Dokumentacja INiG – PIB, nr archiwalny: DK-4100/02/15.
- [24] Haduch B.: *Zastosowanie symulacji neuronowych i algorytmów logiki rozmytej (Fuzzy Logic) dla opisu nieliniowych zależności we właściwościach benzyn silnikowych zawierających w swoim składzie bioetanol*. Dokumentacja INiG – PIB, nr archiwalny: DK-4100/77/11.
- [25] Harley R.A., Coulter-Burke S.C., Yeung T.S.: *Relating Liquid Fuel and Headspace Vapor Composition for California Reformulated Gasoline Samples Containing Ethanol*. Environ. Sci. Technol. 2000, vol. 34 (19), s. 4088–4094.
- [26] Hatanaka R., Flumignan D.L., de Oliveira J.E.: *GC Fingerprints Coupled to Pattern-Recognition Multivariate SIMCA Chemometric Analysis for Brazilian Gasoline Quality Studies*. Chromatographia 2009, vol. 70, nr 7/8, s. 1135–1142.
- [27] Joint EUCAR/JRC/CONCAWE Study on: *Effects of Gasoline Vapour Pressure and Ethanol Content on Evaporative Emissions from Modern Cars*. Institute for Environment and Sustainability 2007, EUR 22713 EN.
- [28] Kar K., Last T., Haywood C., Raine R.: *Measurement of Vapor Pressures and Enthalpies of Vaporization of Gasoline and Ethanol Blends and Their Effects on Mixture Preparation in an SI Engine*. SAE International Journal of Fuels and Lubricants 2009, vol. 1 (1), s. 132–144, DOI: 10.4271/2008-01-0317.
- [29] Liang F., Kerpen K., Kuklya A., Telgheder U.: *Fingerprint identification of volatile organic compounds in gasoline contaminated groundwater using gas chromatography differential ion mobility spectrometry*. Int. J. Ion Mobil. Spec. 2012, vol. 15, s. 169–177.
- [30] Moreira L.S., d'Avila L.A., Azevedo D.A.: *Automotive Gasoline Quality Analysis by Gas Chromatography: Study of Adulteration*. Chromatographia 2003, vol. 58, s. 501–505.
- [31] Murty B.S.N., Rao R.N.: *Global optimization for prediction of blend composition of gasolines of desired octane number and properties*. Fuel Processing Technology 2004, vol. 85, s. 1595–1602.
- [32] Muzikova Z., Pospisil M., Sebor G.: *Volatility and phase stability of petrol blends with ethanol*. Fuel 2009, vol. 88, nr 8, s. 1351–1356, DOI: 10.1016/j.fuel.2009.02.003.
- [33] Olatunji S.O., Adeleke I.A.: *An Intelligent Framework for the Classification of Premium and Regular Gasoline for Arson and Fuel Spill Investigation Based on Extreme Learning Machines, Computational Intelligence, Communication Systems and Networks (CICSyN)*. Second International Conference on Liverpool, 28–30.07.2010, s. 13–16.
- [34] Pałuchowska M., Haduch B.: *Aspekty wprowadzania średniego poziomu zawartości etanolu do benzyny silnikowej. Część 1*. Nafta-Gaz 2016, nr 2, s. 112–117, DOI: 10.18668/NG.2016.02.06.
- [35] Pałuchowska M., Haduch B.: *Aspekty wprowadzania średniego poziomu zawartości etanolu do benzyny silnikowej. Część 2*. Nafta-Gaz 2016, nr 9, s. 755–760, DOI: 10.18668/NG.2016.09.11.
- [36] Pałuchowska M., Rogowska D.: *Wpływ bioetanolu na nieaddytywne właściwości benzyny silnikowej*. Nafta-Gaz 2009, nr 1, s. 21–28.
- [37] Pasadakis N., Gaganis V., Foteinopoulos C.: *Octane number prediction for gasoline blends*. Fuel Processing Technology 2006, vol. 87, s. 505–509.
- [38] Preliminary Examination of Ethanol Fuel Effects on EPA's R-factor for Vehicle Fuel Economy. ORNL/TM-2012/198, June 2013.
- [39] Rigo T.R.M., Flumignan D.L., Boralle N., de Oliveira J.E.H.: *NMR Fingerprinting of Brazilian Commercial Gasoline: Pattern-Recognition Analyses for Origin Authentication Purposes*. Energy Fuels 2009, vol. 23 (8), s. 3954–3959.
- [40] Smith B.L., Bruno T.J.: *Improvements in the Measurement of Distillation Curves. 3. Application to Gasoline and Gasoline + Methanol Mixtures*. Industrial & Engineering Chemistry Research 2007, vol. 46, nr 1, s. 297–309, DOI: 10.1021/ie060937u.
- [41] Takayasu T., Kondo T.: *Components of gasoline and kerosene*. [W:] Suzuki O., Watanabe K. (Eds.): *Drugs and Poisons in Humans a Handbook of Practical Analysis*. Springer-Verlag Berlin Heidelberg 2005.
- [40] Takeshita E.V., Rezende R.V.P., Gueli U., de Souza S.M.A., Ulson de Souza A.A.: *Influence of solvent addition on the physicochemical properties of Brazilian gasoline*. Fuel 2008, vol. 87, nr 10–11, s. 2168–2177, DOI: 10.1016/j.fuel.2007.11.003.
- [42] West B.: *Ethanol as a Spark Ignition Engine Fuel*. Fuels, Engines and Emissions Research Center Oak Ridge National Laboratory, National Ethanol Conference, 18–19.02.2014 (dostęp: kwiecień 2015).
- [43] Woebkenberg W.: *Mid-Blend Ethanol Fuels – Implementation Perspectives*. US Fuels Technical and Regulatory Affairs. Mercedes-Benz Research & Development North America, 25.07.2013 (http: prezentacja Mercedes-Benz).
- [44] Yanowitz J., Ratcliff M., Zigler B.T., McCormick R.L.: *Appendix: Studies on the Use of E15 and E20 in Light-Duty Vehicles*. National Renewable Energy Laboratory, Ecoengineering, Inc.
- [45] Yu W., Moreno-Armendariz M.A.: *Modelling of gasoline blending via discrete-time neural networks*. Neural Networks 2004. Proceedings 2004. IEEE International Joint Conference on Budapest, 25–29.07.2004, vol. 2, s. 1291–1296.
- [46] Zhang X., Yan W., Shao H.: *Nonlinear Multivariate Quality Estimation and Prediction Based on Kernel Partial Least Squares*. Ind. Eng. Chem. Res. 2008, vol. 47 (4), s. 1120–1131.

#### Akty prawne i normatywne

- [47] *Dyrektywa Parlamentu Europejskiego i Rady 2009/28/WE z dnia 23 kwietnia 2009 r. w sprawie promowania stosowania energii ze źródeł odnawialnych*. Dz.U. UE L 09.140.16.

Mgr inż. Bogusław HADUCH  
 Starszy specjalista badawczo-techniczny, kierownik Biura Kontroli.  
 Instytut Nafty i Gazu – Państwowy Instytut Badawczy  
 ul. Lubicz 25 A  
 31-503 Kraków  
 E-mail: boguslaw.haduch@inig.pl



Prof. zw. dr hab. inż. Ryszard TADEUSIEWICZ  
 Profesor zwyczajny  
 Akademia Górniczo-Hutnicza im. Stanisława Staszica  
 w Krakowie. Wydział Elektrotechniki, Automatyki,  
 Informatyki i Inżynierii Biomedycznej  
 al. Mickiewicza 30, 30-059 Kraków  
 E-mail: rtad@agh.edu.pl