

Krzysztof BRZOZOWSKI¹
Łukasz DRĄG²

MODELOWANIE NATĘŻENIA EMISJI ZWIĄZKÓW SZKODLIWYCH Z SILNIKA ZI POJAZDU SAMOCHODOWEGO W WARUNKACH RUCHU MIEJSKIEGO

W pracy przedstawiono problem modelowania natężenia emisji związków szkodliwych spalin w warunkach ruchu miejskiego, charakteryzowanego wartościami chwilowej prędkości i przyspieszenia, z wykorzystaniem sztucznych sieci neuronowych. Analizowano natężenie emisji związków szkodliwych spalin, takich jak: tlenek węgla, tlenki azotu oraz węglowodory. Do predykcji natężenia emisji zaproponowano wykorzystanie jednokierunkowych wielowarstwowych sieci neuronowych. Proces uczenia sieci przeprowadzono na podstawie danych eksperymentalnych zarejestrowanych w warunkach trakcyjnych.

EXHAUST EMISSION MODELLING FOR A CAR WITH SI ENGINE AND CITY TRAFFIC CONDITIONS

The paper concerns with emission intensity modeling in a city traffic conditions by means of an artificial neural networks. Instantaneous vehicle velocity and acceleration are used in order to describe the traffic. The emission intensity is calculated for a three exhaust gas components such as: carbon monoxide, nitrogen oxides and hydrocarbon. A multilayer feed-forward artificial networks are applied for calculation of the emission intensity. The trainee process of neural networks was performed using the measurement data obtained in a real traffic conditions.

1. WSTĘP

Transport drogowy w obszarach miejskich stanowi główną przyczynę zanieczyszczenia powietrza atmosferycznego i generowania, często nadmiernego, hałasu. Wobec

¹ Akademia Techniczno-Humanistyczna, Wydział Zarządzania i Informatyki; 43-309 Bielsko-Biała; ul. Willowa 2; tel: +48 338-279-289, fax: +48 338-279-289, e-mail: kbrzozowski@ath.eu

² Akademia Techniczno-Humanistyczna, Wydział Zarządzania i Informatyki; 43-309 Bielsko-Biała; ul. Willowa 2; tel: +48 338-279-269, fax: +48 338-279-289, e-mail: ldrag@ath.eu

powyższego, działania związane ze zmianą organizacji ruchu czy też dotyczące rozbudowy istniejącej infrastruktury powinny być poprzedzone oceną wpływu proponowanych rozwiązań na jakość powietrza. Ocenę oddziaływania przeprowadza się bądź na podstawie bilansowania emisji i modelowania bądź pomiaru stężeń zanieczyszczeń. Pierwszym z wymienionych sposobów jest z oczywistych względów jednocześnie jedynym możliwym do zastosowania na etapie projektowania. Podstawę bilansowania stanowi przy tym informacja uzyskana z modelu emisji uwzględniającego udział poszczególnych kategorii pojazdów w ruchu.

Prace badawcze obejmujące modelowanie emisji związków szkodliwych w spalinach pojazdów prowadzi się od lat 70. XX wieku [1]. W wyniku tych prac formułowane są modele emisji, które można podzielić według przyjmowanej zależności pomiędzy emisją a wielkościami charakteryzującymi sposób eksploatacji pojazdu. Wśród najbardziej popularnych modeli wyróżnić można modele modalne, determinujące natężenie emisji. Do tej grupy modeli zaliczane są trzy podtypy modeli. Pierwszy podtyp stanowią proste modele, opisujące natężenie emisji danego składnika dla danej kategorii pojazdów jako stałe w ramach trwania poszczególnych faz ruchu. Stąd w najprostszych modelach modalnych wyróżniane są tylko podstawowe fazy ruchu, takie jak: przyspieszanie, zwalnianie, bieg jałowy oraz jazda ze stałą prędkością. Pozostałe dwa podtypy stanowią modele chwilowego natężenia emisji, w których przyjmuje się, że emisja jest stała w krótkim okresie czasu, a wewnętrzny podział wynika z przyjętych parametrów niezależnych, charakteryzujących warunki eksploatacji pojazdu [2].

W pracy zaproponowano modelowanie natężenia emisji związków szkodliwych spalin w zależności od dwóch podstawowych parametrów charakteryzujących eksploatację trakcyjną pojazdów osobowych tj. od chwilowej prędkości i przyspieszenia pojazdu. Przedstawiona metoda bazuje przy tym na wynikach badań drogowych natężenia emisji w trakcie jazdy miejskiej zgromadzonych w tzw. macierzy emisji. Problematyka tworzenia wiarygodnych macierzy emisji, związana z koniecznością zapewnienia ciągłego pomiaru emisji o wysokim stopniu precyzji, wyeliminowania bądź ograniczenia niepewności związanej z opóźnieniem sygnału o emisji w stosunku do rejestrowanych parametrów ruchu była przed kilku laty przedmiotem wielu badań, których wyniki przedstawiono między innymi w [3, 4]. Macierz emisji jest jednak tylko etapem pośrednim prezentowanej metody – bowiem do modelowania, a więc predykcji natężenia emisji poszczególnych związków szkodliwych spalin, takich jak: tlenek węgla, tlenki azotu oraz węglowodory zaproponowano wykorzystanie sztucznych sieci neuronowych.


2. BADANIA DROGOWE

Budowę modelu emisji zazwyczaj wykonuje się w oparciu o dane zgromadzone na hamowni podwoziowej lub w warunkach rzeczywistej eksploatacji trakcyjnej. W pracy do konstrukcji modelu emisji wykorzystano dane zarejestrowane w trakcie badań drogowych. Badania przeprowadzono dla samochodu osobowego segmentu handlowego M wyposażonego w silnik o zapłonie iskrowym o objętości skokowej silnika 2 dm^3 i mocy 110 KW. Pojazd spełniał limit emisji EURO 3. Pomiar obejmował rejestrację parametrów dynamiki ruchu badanego pojazdu oraz emisji wybranych związków szkodliwych spalin. W ramach badań wykonano dwie serie pomiarowe (M1, M2), które

zostały przeprowadzone w warunkach jazdy miejskiej [5]. Przebiegi prędkości i przyspieszenia pojazdu zarejestrowane w trakcie obu pomiarów przedstawiono na rys. 1., a wartości natężenia emisji tlenku węgla, tlenków azotu oraz węglowodorów na rys. 2. Pomiary wykonano z częstotliwością 10 Hz, co pozwoliło precyzyjnie zarejestrować również krótkotrwałe epizody zwiększonej emisji w stanach nieustalonych, w których emitowana jest większość masy zanieczyszczeń podczas eksploatacji nowoczesnych pojazdów [3]. Dane charakteryzujące ruch pojazdu podczas serii pomiarowych M1 i M2 zamieszczono w tab. 1.

Tab. 1. Dane charakteryzujące ruch pojazdu podczas serii pomiarowych – M1, M2

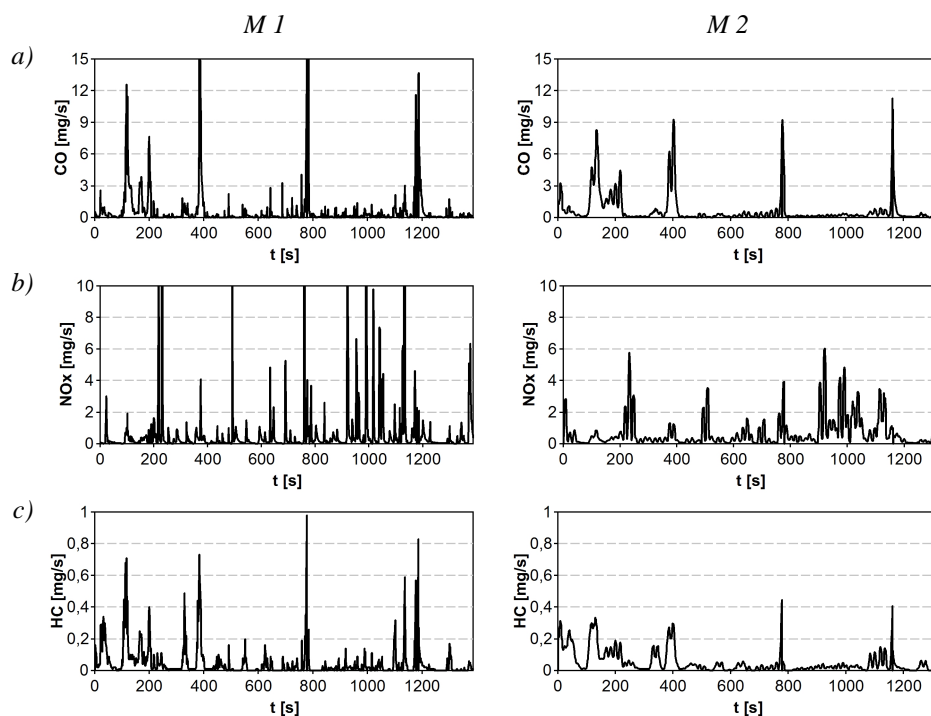
| Parametr | M1 | M2 |
|---|-------|-------|
| maksymalna prędkość pojazdu [km/h] | 102,3 | 107,5 |
| minimalna prędkość pojazdu [km/h] | 0 | 0 |
| maksymalne przyspieszenie pojazdu [m/s^2] | 1,39 | 2,26 |
| minimalne przyspieszenie pojazdu [m/s^2] | -2,06 | -2,41 |
| średnia prędkość przejazdu [km/h] | 38,61 | 39,26 |
| czas pomiaru [s] | 1387 | 1316 |




Rys. 1. Przebieg a) prędkości v [km/h] i b) przyspieszeń a [m/s²] według pomiarów drogowych dla samochodu osobowego – seria pomiarowa M1 i M2

Z kolei, na rys. 3 przedstawiono częstość zarejestrowanych stanów dynamicznych pojazdu (przyspieszanie $a > 0$, jazda ze stałą prędkością $a = 0$, hamowanie $a < 0$). Jak można zauważyć dynamika ruchu pojazdu w trakcie serii pomiarowej M1 znacznie różni się od tej rejestrowanej w ramach serii pomiarowej M2. Zmiany prędkości ruchu pojazdu w serii M1 zanotowano w 79,1% czasu, a w przypadku serii pomiarowej M2 w 89,4% czasu.

Pierwszym etapem przygotowania danych pomiarowych było uśrednienie wyników badań uzyskanych dla obu serii pomiarowych dla pewnych dyskretnych przedziałów wartości chwilowej prędkości i przyspieszenia pojazdu. Wartości natężenia emisji poszczególnych związków szkodliwych spalin zarejestrowane w ramach obu serii pomiarowych M1 i M2 poddano uśrednieniu (osobno w ramach poszczególnych serii) dla dyskretnych przedziałów prędkości co 5 km/h od 0 do 110 km/h oraz przedziałów przyspieszenia co 0,1 m/s² w zakresie od -2,5 m/s² do 2,2 m/s².




Rys. 2. Natężenie emisji a) tlenku węgla b) tlenków azotu c) węglowodorów według pomiarów drogowych dla samochodu osobowego – seria pomiarowa M 1 i M 2

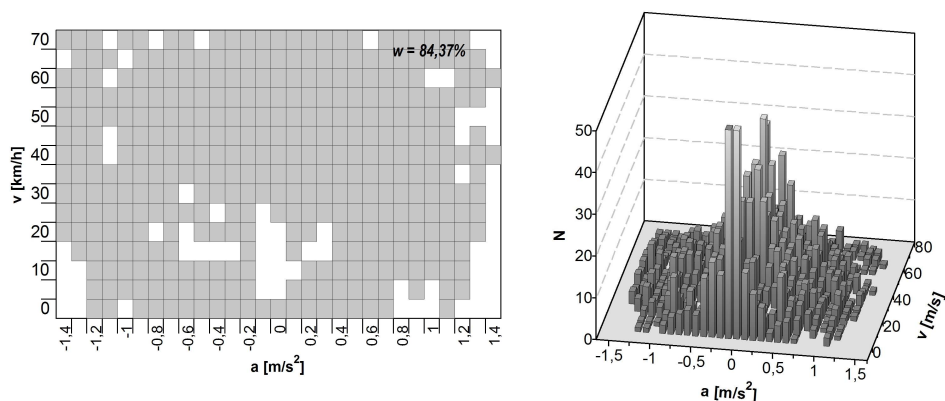


Rys. 3. Częstość występowania stanów dynamicznych w seriach pomiarowych M1 i M2

Graficzną ilustrację stopnia wypełnienia powstałych w ten sposób tzw. macierzy emisji dla obu serii pomiarowych M1 i M2 przedstawiono na rys. 4. Łatwo zauważyć, że w obu seriach pomiarowych stopień wypełnienia dla przyjętych zakresów prędkości i przyspieszeń jest poniżej 50%, i uśrednianie dla mniejszych przedziałów zarówno prędkości jak i przyspieszeń nie ma uzasadnienia. Przy założonym podziale stopień wypełnienia macierzy emisji wynosi odpowiednio, dla serii pomiarowej M1 26,89% a dla serii pomiarowej M2 42,55%. Analizując uzyskane macierze, przyjęto, że macierz wejściowa, która zostanie wykorzystana w procesie uczenia sieci neuronowych będzie macierzą powstałą w wyniku połączenia danych z obu serii pomiarowych i co istotne po ograniczeniu zakresu prędkości do przedziału $\langle 0;70 \rangle$ km/h i przyspieszeń do przedziału $\langle -1,4;1,4 \rangle$ m/s². Na rys. 5. przedstawiono graficznie stopień wypełnienia powstałej w ten sposób macierzy emisji oraz liczbę wartości N uwzględnionych w trakcie uśredniania dla poszczególnych komórek macierzy.



Rys. 4. Stopień wypełnienia macierzy natężenia emisji dla serii pomiarowych M1 i M2



Rys. 5. Stopień wypełnienia oraz liczba uśrednionych wartości N macierzy natężenia emisji po połączeniu wyników z serii pomiarowych M1 i M2

Dane o natężeniu emisji zgromadzone w trzech macierzach jak na rys. 5 (każda o wypełnieniu blisko 85%), osobno dla każdego z analizowanych związków, stanowią zbiory uczące wykorzystane w dalszym etapie prac do ustalenia architektury i przeprowadzenia procesu uczenia sztucznych sieci neuronowych. Oznacza to, że z każdą parą wartości $\{v, a\}$, wyznaczających środek każdej z komórek macierzy, związana jest uśredniona wartość natężenia emisji odpowiednio CO, NO_x i HC w ramach zakresu prędkości i przyspieszeń obejmowanych (reprezentowanych) przez daną komórkę.

3. ARCHITEKTURA I UCZENIE SIĘCI NEURONOWYCH

Modelowanie natężenia emisji związków szkodliwych spalin może być realizowane z wykorzystaniem sieci neuronowych z radialną (RBF SSN) jak i sigmoidalną (MLP SSN) funkcją aktywacji [6, 7]. W niniejszej pracy postanowiono wykorzystać jednokierunkowe sieci neuronowe o sigmoidalnej funkcji aktywacji neuronu. Funkcję aktywacji przyjęto w postaci bipolarnej:

$$f(\mathbf{w}'\mathbf{z}) = 2 \left[1 + e^{-\lambda \mathbf{w}'\mathbf{z}} \right]^{-1} - 1 \quad (1)$$

gdzie: \mathbf{w} – wektor wag połączeń wejściowych neuronu,
 \mathbf{z} – wektor sygnałów wejściowych do neuronu,
 λ – współczynnik zmieniający zakres liniowości funkcji.


Do modelowania natężenia emisji zgromadzonego w poszczególnych macierzach można wykorzystać pojedynczą sieć neuronową, która dla pary sygnałów wejściowych $\{v, a\}$ na wyjściu generuje trzy sygnały $\{E_{CO}, E_{NO_x}, E_{HC}\}$ odpowiadające kolejno natężeniu emisji CO, NO_x i HC, lub trzy osobne sieci, z których każda na wyjściu generuje

pojedynczy sygnał. Po wstępnych eksperymentach numerycznych postanowiono pozostać przy koncepcji zakładającej budowę trzech sieci neuronowych odpowiednio do predykcji natężenia emisji każdego z rozważanych w pracy związków. Oznacza to, że wartość sygnału wyjściowego pojedynczego neuronu na warstwie wyjściowej każdej z trzech sieci przy $k-1$ elementowej ostatniej warstwie ukrytej jest obliczana jako:

$$E(v, a) = f\left(\sum_{i=1}^k w_i \cdot z_i\right) \quad (2)$$

dla sieci o ogólnej strukturze jak na rys. 6.

Uczenie sieci, polegające na modyfikacji wag poszczególnych połączeń pomiędzy neuronami tworzącymi sieć, wykonywane jest zazwyczaj do momentu osiągnięcia przyjmowanej a priori wartości średniego błędu kwadratowego. Dla rozważanego w pracy problemu modelowania natężenia emisji zastosowano podejście niestandardowe polegające na uczeniu sieci do czasu, gdy średni błąd względny dla całego zbioru uczącego osiągnie wartość oczekiwaną. Ustalenie takiego kryterium stopu zapobiega zjawisku przetrenowania sieci i w konsekwencji słabej zdolności sieci do uogólniania.



Rys. 6. Ogólna architektura sieci neuronowych zastosowanych do modelowania natężenia emisji

Zgodnie z przyjętym warunkiem końca procesu uczenia, po ustaleniu architektury sieci, sieć była trenowana tak długo, aż średni błąd względny Ψ dla obliczanego natężenia emisji osiągnął wartość mniejszą niż 10%. Błąd ten został zdefiniowany jako:

$$\Psi = \frac{1}{n} \sum_{k=1}^n \frac{|E^{(k)} - F^{(k)}|}{F^{(k)}} 100\% \quad (3)$$

gdzie: $E^{(k)}$ – wartość natężenia emisji obliczona na wyjściu z sieci neuronowej dla sygnałów wejściowych $\{v^{(k)}, a^{(k)}\}$,

$F^{(k)}$ – wartość natężenia emisji, uśredniona z serii pomiarowych M1 i M2 dla k -tej komórki macierzy,

n – liczba wszystkich komórek macierzy, dla których uśredniona została wartość natężenia emisji.

Do uczenia sieci wykorzystano metodę momentum z przyrostowym uaktualnianiem wag tj., w $n+1$ kroku uczenia sieci (po prezentacji danego wzorca uczącego ze zbioru) modyfikowano wagi według następującej zależności [8, 9]:

$$\mathbf{w}^{(n+1)} = \mathbf{w}^{(n)} - \eta^{(n)} \nabla \mathcal{E}(\mathbf{w}^{(n)}) + \alpha (\mathbf{w}^{(n)} - \mathbf{w}^{(n-1)}) \quad (4)$$

gdzie: η – współczynnik uczenia,

\mathcal{E} – błąd odpowiedzi sieci w stosunku do wartości oczekiwanych dla danego wzorca uczącego, w postaci:

$$\mathcal{E} = \frac{1}{2} \sum_{k=1}^n (F^{(k)} - E^{(k)})^2 \quad (5)$$

α – współczynnik momentu.

W procesie uczenia stosowano losowy dobór wag początkowych po każdym powtórzeniu uczenia sieci oraz losowe zadawanie wzorców uczących (odpowiednich par $\{v^{(k)}, a^{(k)}, F^{(k)}\}$ ze zbioru uczącego) wcześniej przeskalowanych liniowo do przedziału wartości $\langle -1, 1 \rangle$. Jeżeli dla danej architektury sieci, po zastosowaniu wielu powtórzeń procesu uczenia nie udało się osiągnąć zakładanej wartości średniego błędu względnego Ψ , architekturę sieci modyfikowano. W każdym kroku zastosowanego algorytmu kontrolowano również zmianę wartości błędu w stosunku do kroku poprzedniego. W zależności od relacji błędu uzyskanego w (n) i $(n-1)$ kroku modyfikowano współczynnik uczenia η według zależności:

$$\eta^{(n+1)} = \begin{cases} 0,7\eta^{(n)} & \text{dla } \mathcal{E}^{(n)} (\mathcal{E}^{(n-1)})^{-1} > 1,06 \\ 1,15\eta^{(n)} & \text{w przeciwnym przypadku} \end{cases} \quad (6)$$

Jako wejściową architekturę sieci przyjęto sieć z dwoma warstwami ukrytymi a następnie testowano poszczególne architektury sieci dodając neurony na obu warstwach. W wyniku zastosowania opisanego schematu postępowania znaleziono architekturę sieci umożliwiającą modelowanie natężenia emisji z założoną dokładnością. Dla rozpatrywanych w pracy związków jest to każdorazowo sieć wymagająca dwóch warstw ukrytych. Zastosowane sieci różnią się jednak liczbą neuronów na poszczególnych warstwach bądź współczynnikiem λ zastosowanym w funkcji aktywacji neuronu. Zestawienie cech poszczególnych sieci przedstawiono w tab. 2.


Tab. 2. Dane charakteryzujące poszczególne sieci neuronowe

| Przykład | Liczba neuronów na 1 warstwie ukrytej | Liczba neuronów na 2 warstwie ukrytej | Wartość współczynnika λ |
|-----------------|---------------------------------------|---------------------------------------|---------------------------------|
| CO | 90 | 45 | 1 |
| NO _x | 60 | 30 | 0,3 |
| HC | 60 | 30 | 1 |

Na podstawie danych zebranych w tab. 2. Łatwo zauważyć, że zaproponowane w pracy sieci mają w dwóch przypadkach jednakową architekturę tj: 2-60-30-1 do predykcji natężenia NO_x i HC, jednak różnią się funkcjami aktywacji (zróżnicowane λ). Identyczną architekturę próbowano zastosować również dla sieci do predykcji natężenia emisji CO, w jednak tym przypadku dopiero architektura 2-90-45-1 pozwoliła na osiągnięcie założonej skuteczności uczenia, wyrażonej średnim błędem względnym $\Psi < 10\%$. Należy przy tym zaznaczyć, że w procesie uczenia sieci zastosowano dwie różne wartości współczynnika momentu, $\alpha = 0,1$ dla uczenia sieci do predykcji natężenia emisji CO oraz stosowaną klasycznie wartość $\alpha = 0,9$ w procesie uczenia dwóch pozostałych sieci neuronowych.

4. WNIOSKI

Posługiwanie się wyłącznie średnim błędem względnym, który stanowił kryterium końca algorytmu uczenia rozważanych w pracy sztucznych sieci neuronowych, nie daje całkowitego obrazu jakości proponowanej metody. Ważnym etapem oceny przedstawionego postępowania jest analiza dokładności odwzorowania natężenia emisji danego składnika spalin w odniesieniu do wartości parametrów niezależnych charakteryzujących sposób eksploatacji. Na rys. 7. przedstawiono rozkład błędu względnego predykcji natężenia emisji CO, NO_x i HC z wykorzystaniem sieci neuronowych w odniesieniu do chwilowej wartości prędkości i przyspieszenia.



Rys. 7. Rozkład błędu względnego predykcji natężenia emisji CO, NO_x i HC z wykorzystaniem sieci neuronowych

Analizując przedstawione na rys. 7. rozkłady można zaryzykować stwierdzenie istnienia pewnej korelacji pomiędzy wartością błędu względnego predykcji natężenia danego składnika na poziomie 10% i większym a wartościami chwilowego przyspieszenia. W przypadku błędów predykcji tlenków azotu zależność ta jest szczególnie dobrze widoczna, ponad 90% obszarów w których błąd predykcji przekracza błąd średni (a więc przekracza wartość 10%) jest związana z ujemnymi przyspieszeniami. W dwóch pozostałych przypadkach obszary w zakresie ujemnych przyspieszeń, w których błąd predykcji przekracza błąd średni stanowią 65% i 67%, odpowiednio dla natężenia emisji CO i HC. Na tej podstawie można stwierdzić, że zaproponowany sposób modelowania natężenia emisji charakteryzuje się dobrą dokładnością w zakresie dodatnich przyspieszeń i pogarszającą się precyzją opisu natężenia emisji w warunkach ujemnych przyspieszeń.

5. BIBLIOGRAFIA

- [1] Hickman A.: *Methodology for calculating transport emissions and energy consumption*. Transport Research Laboratory, Project Rep. SE/491/98, 1999.
- [2] Brzozowska L., Brzozowski K., Drąg Ł.: *Transport drogowy a jakość powietrza. Modelowanie komputerowe w mezoskali*. WKŁ, Warszawa, 2009.
- [3] Weilenmann M., Soltic P., Ajtay D.: *Describing and compensating gas transport dynamics for accurate instantaneous emission measurement*. Atmospheric Environment 37, 5137-5145, 2003.
- [4] Ajtay D., Weilenmann M., Soltic P.: *Towards accurate instantaneous emission models*. Atmospheric Environment 39, 2443-2449, 2005.
- [5] Drąg Ł.: *Wpływ modeli ruchu na obliczeniową emisję zanieczyszczeń*. Rozprawa doktorska. Akademia Techniczno-Humanistyczna w Bielsku-Białej, 2008.
- [6] Brzozowska L., Brzozowski K., Warwas K.: *Zastosowanie sztucznych sieci neuronowych do modelowania ekologicznych właściwości pojazdów*. Archiwum Motoryzacji nr 3, s. 229-247, 2005.
- [7] Brzozowski K.: *Mikroskalowe modele emisji i rozprzestrzeniania się zanieczyszczeń samochodowych*. Wydawnictwo ATH, Rozprawy Naukowe nr 18, Bielsko-Biała, 2006.
- [8] Żurada, J., Barski, M., Jędruch, W.: *Sztuczne sieci neuronowe*. PWN, Warszawa, 1996.
- [9] Osowski, S.: *Sieci neuronowe w ujęciu algorytmicznym*. WNT, Warszawa, 1996.