

Jerzy Merkisz¹, Arkadiusz Barczak², Jacek Pielecha³
Instytut Silników Spalinowych i Transportu Politechniki Poznańskiej

Rozpoznawanie wzorców emisji spalin w pomiarach PEMS za pomocą sieci Kohonena (SOM)

1. WPROWADZENIE

Ograniczanie negatywnego wpływu przemysłu na środowisko naturalne jest podstawowym czynnikiem rozwoju techniki i technologii we wszystkich dziedzinach. Ze względu na ograniczanie emisji szkodliwych składników spalin transport jest zaliczany do zmieniających się bardzo dynamicznie dziedzin. Nadal jednak dużym zagrożeniem jest emisja związków toksycznych (gazowych) i dwutlenku węgla oraz cząstek stałych – stanowiąca barierę rozwoju współczesnych silników spalinowych, w szczególności silników o zapłonie samoczynnym i iskrowym z bezpośrednim wtryskiem benzyny. Istotnym wyzwaniem dla producentów samochodów jest spełnienie wymagań normy Euro 6, w której poziomy emisji związków gazowych i cząstek stałych są wielokrotnie niższe od dotychczasowych.

Konieczność ochrony środowiska stała się czynnikiem mającym bezpośredni wpływ na konstrukcję silników współczesnych pojazdów. Determinantem ich rozwoju, a równocześnie wyznacznikiem postępu technicznego w tej dziedzinie, jest zgodność z przepisami dotyczącymi emisji spalin. Do najbardziej niepożądanych związków spalin silnikowych należą tlenek węgla, węglowodory, tlenki azotu i cząstki stałe. Jednoczesne zmniejszenie zawartości dwóch ostatnich z wymienionych związków jest zadaniem bardzo trudnym ze względu na ich przeciwstawne właściwości.

Obecnie zauważalna jest wyraźna tendencja do globalnego traktowania zagrożeń środowiska ze strony motoryzacji. Przepisy zezwalające na dopuszczenie pojazdów do użytkowania (badania homologacyjne i zgodności produkcji), okresowe badania kontroli stanu technicznego oraz akty prawne związane bezpośrednio i pośrednio z produkcją, użytkowaniem i zagospodarowaniem zużytych wytworów cywilizacji, traktują zagadnienia ochrony środowiska w sposób kompleksowy. W ubiegłych latach, w poszczególnych państwach stosowano różne systemy badań i kontroli emisji spalin z silników samochodowych, jednak od pewnego czasu następuje w tym zakresie daleko posunięta unifikacja.

Wdrożenie w ostatnich latach norm toksyczności spalin (a w szczególności norm dotyczących emisji cząstek stałych) miało na celu zmniejszenie rzeczywistej emisji cząstek stałych z pojazdów osobowych (zarówno z silnikami ZS, jak i ZI), ciężarowych oraz z silników pojazdów pozadrogowych.

Europejskie przepisy o emisji zanieczyszczeń podlegają ciągłym i częstym zmianom. Dyrektywa 70/220/EWG dla pojazdów lekkich od wejścia w życie na początku lat siedemdziesiątych XX w. była znowelizowana dziesięćkrotnie. Unia Europejska przygotowała obecnie pakiet nowych przepisów dotyczących emisji zanieczyszczeń z pojazdów samochodowych – wymagania Euro 5 i Euro 6. Opublikowany, pierwszy z dokumentów tego pakietu, rozporządzenie 2007/46/WE Parlamentu Europejskiego i Rady, zawiera postanowienia dotyczące możliwości kontroli emisji z wykorzystaniem pokładowych systemów diagnostycznych. Zawarto w nim również zalecenia pozwalające w większym stopniu kontrolować emisję w warunkach rzeczywistych (poza testami homologacyjnymi) dzięki wykorzystaniu mobilnych analizatorów spalin PEMS (*Portable Emissions Measurement Systems*) z silników spalinowych ze wszystkich rodzajów transportu.

Badania ekologiczności pojazdów mają szczególne znaczenie przy pomiarach zanieczyszczeń w dynamicznych warunkach pracy. Warunki te, przyjmowane w dynamicznych testach badawczych, nie odzwierciedlają warunków eksploatacji różnych typów pojazdów. Rozwój technik badawczych

¹ jerzy.merkisz@put.poznan.pl

² arkadiusz.barczak@put.poznan.pl

³ jacek.pielecha@put.poznan.pl

ukierunkowany na pomiar bardzo małych stężeń zanieczyszczeń w spalinach spowodował, że w ciągu kilku ostatnich lat największy potencjał badawczy skoncentrowano na badaniach drogowych pojazdów w rzeczywistych warunkach ruchu. Badanie takie oferują możliwość opracowania wzorców emisji (w zależności od stanów pracy silnika lub pojazdu), które mogą mieć zastosowanie do optymalizacji zespołów napędowych, a jednocześnie stanowić odniesienie do działań zmierzających do ograniczenia emisji zanieczyszczeń poprzez stosowanie bardziej efektywnych układów oczyszczania spalin (ang. *Aftreatment*).

Otrzymane dane pomiarowe stanowią bardzo liczny zbiór wymagający odpowiedniej analizy w celu interpretacji. Interpretacja wyników pomiarów, na przykład emisji zanieczyszczeń, reprezentowanych w postaci bardzo licznych zbiorów różnorodnych danych wymaga przeprowadzenia złożonych analiz numerycznych. Wyrafinowane metody statystyczne są skuteczne lecz interpretacja wyników wymaga udziału eksperta o bardzo specjalistycznej wiedzy. Analizę danych pomiarowych zanieczyszczeń z zastosowaniem metody PCA przeprowadzono w [3], a z zastosowaniem metody ANOVA w [4]. Stosowanie metod data mining stwarza szerokie perspektywy i zwiększa zdecydowanie możliwości w zakresie analizy i interpretacji wyników eksperymentu przeprowadzonego w warunkach rzeczywistych. W artykule przeprowadzono badania transformacji wielolicznego zestawu uczącego uzyskanego z pomiarów do małego zestawu neuronów sieci Kohonena. Dla wyuczonej sieci Kohonena przeprowadzono badania dotyczące rozpoznawania zadanych wzorców stanu pojazdu (zatrzymanie pojazdu, przyspieszenie, jazda ze stałą prędkością, hamowanie) zmierzonych w trakcie eksperymentu drogowego.

2. SIECI KOHONENA

Sieci Kohonena [1, 2], zwane również sieciami/mapami samoorganizującymi (ang. *Self-Organizing Maps* – SOM), są specyficznym typem jedno-warstwowych sieci neuronowych. W sieciach tych stosuje się uczenie bez nadzoru, co oznacza, że dostępne są n -wymiarowe wektory uczące \mathbf{x}_i ($i = 1, 2, \dots, m$, gdzie m jest liczbą wektorów uczących), natomiast nie są dostępne wzorce uczące, które algorytm uczący samodzielnie wyznacza. Nauczona sieć Kohonena stanowi odwzorowanie wielo-wymiarowych danych uczących \mathbf{x}_i , w której zachowane zostały topologiczne właściwości przestrzeni danych wejściowych.

Każdy neuron w sieci Kohonena reprezentowany jest przez n -wymiarowy wektor wag $\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jn}]$. Neurony N_j ($j = 1, 2, \dots, k$, gdzie k jest liczbą neuronów w sieci) zorganizowane są w topologie, najczęściej dwu-wymiarowe (choć zdarzają się realizacje jedno-wymiarowe i wielo-wymiarowe). Dla każdego neuronu N_j definiowane jest jego „sąsiedztwo”, czyli zbiór neuronów, które w danej topologii znajdują się obok niego.

Algorytm uczący sieci Kohonena jest algorytmem konkurencyjnych, w ramach którego dla danej próbki uczącej modyfikacji podlegają współczynniki wybranych neuronów. Dla każdej próbki uczącej wyznaczany jest neuron „zwycięzca” (ang. *Best Matching Unit* – BMU), dla którego odległość euklidesowa od próbki uczącej jest najmniejsza:

$$\|\mathbf{x}_i - \mathbf{w}_z^i\| = \min_j \{\|\mathbf{x}_i - \mathbf{w}_j\|\} \quad (1)$$

gdzie:

\mathbf{x}_i – wektor i -tej próbki uczącej,

\mathbf{w}_z^i – wektor wag neuronu „zwycięzcy” (BMU) dla i -tej próbki uczącej.

W przypadku algorytmu „zwycięzca bierze wszystko” (ang. *Winner Takes All* – WTA) modyfikowane są wyłącznie współczynniki neuronu N_z^i „zwycięzcy” dla danej próbki uczącej \mathbf{x}_i , natomiast w przypadku algorytmu „zwycięzca bierze większość” (ang. *Winner Takes Most* – WTM), oprócz wektora wag neuronu „zwycięzcy” N_z^i modyfikowane są również wektory wag jego najbliższych sąsiadów. Uogólniona metoda uaktualniania wektora wag neuronu dla zadanej próbki \mathbf{x}_i przedstawiona jest wzorem:

$$\mathbf{w}_j(t+1) = \mathbf{w}_j(t) + \alpha(t) H_j^z(t) [\mathbf{x}_i - \mathbf{w}_j(t)] \quad (2)$$

gdzie:

t – kolejne iteracje procesu uczenia,

$\alpha(t)$ – współczynnik uczenia,

$H_j^z(t)$ – funkcja sąsiedztwa neuronu j w topologii dla neuronu z jako „zwycięscy”.

Uaktualnienie wartości wag neuronów może odbywać się po zadaniu pojedynczej próbki uczącej \mathbf{x}_i – metoda określana jako uaktualnianie sekwencyjne (ang. *sequential*), albo uaktualnienie może następować dopiero po wyznaczeniu „zwycięzców” dla wszystkich próbek uczących dla danej iteracji – metoda określana jako uaktualnianie pakietowe (ang. *batch*).

Do oceny jakości procesu uczenia sieci Kohonena stosowane są różne miary [2, 6], a podstawowe to: błąd kwantyzacji e_q :

$$e_q = \frac{1}{m} \sum_{i=1}^m \|\mathbf{x}_i - \mathbf{w}_z^i\| \quad (3)$$

oraz błąd topologicznej reprezentacji e_t :

$$e_t = \frac{1}{m} \sum_{i=1}^m u(\mathbf{x}_i) \quad (4)$$

gdzie:

$u(\mathbf{x}_i)$ – funkcja przyjmująca wartość 1 gdy „zwycięzca” i drugi najlepszy neuron nie znajdują się w topologii obok siebie, a wartość 0 w przeciwnym przypadku.

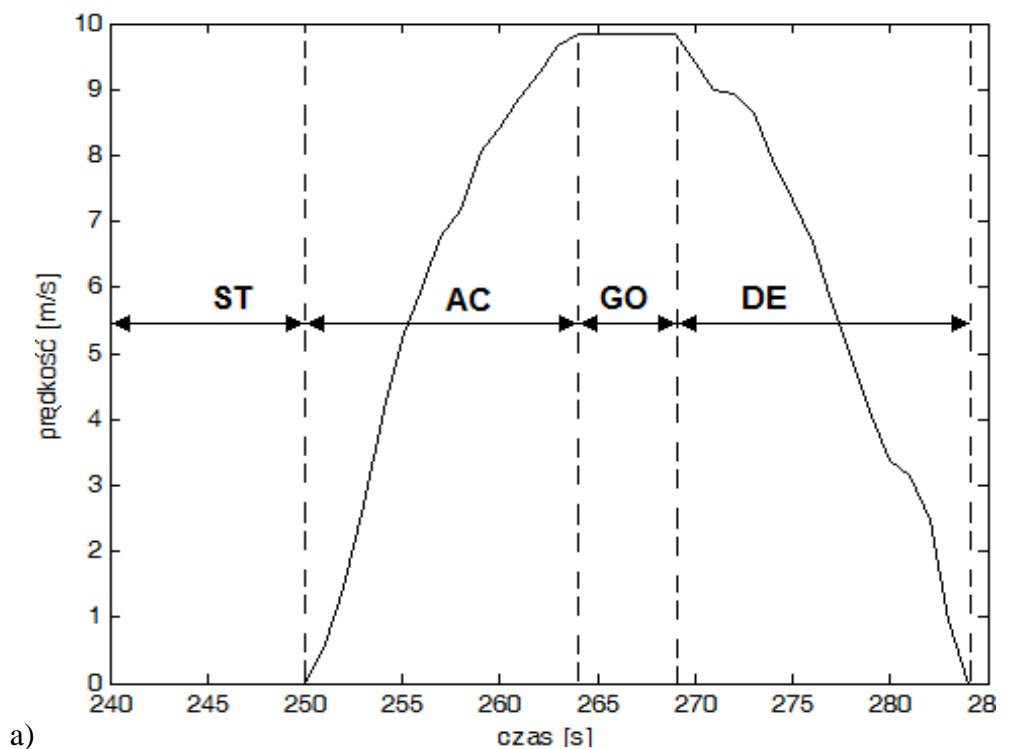
Ważnym etapem w procesie uczenia sieci Kohonena jest normalizacja danych wejściowych, której zadaniem jest zapobieżenie zdominowania odległości euklidesowej, stosowanej w ramach procesu uczenia się sieci, przez zmienne o większych wartościach bezwzględnych. Najczęściej stosowane w sieciach Kohonena metody normalizacji to:

- normalizacja do zakresu wartości [0, 1],
- normalizacja z zastosowaniem wariancji,
- normalizacja z zastosowaniem funkcji logarytmu naturalnego.


Struktura sieci Kohonena oraz zastosowanie algorytmów konkurencyjnego uczenia się powodują, że poszczególne neurony w nauczonej już sieci reprezentują zgrupowania (ang. *cluster*) wektorów próbek uczących, natomiast topologia sieci gwarantuje, że dla każdego neuronu N_j zgrupowania o podobnych właściwościach znajdują się w jego sąsiedztwie.

3. PRZYKŁAD OBLICZENIOWY

Pomiary emisyjności pojazdu (autobusu) przeprowadzono w warunkach ruchu miejskiego w Poznaniu. Obiektem badań był 18-metrowy autobus z silnikiem hybrydowym spełniającym normę EEV (*Enhanced Environmental friendly Vehicles* – pojazdy przyjazne środowisku), wyposażony w układ selektywnej redukcji katalitycznej oraz filtr cząstek stałych. Do pomiarów stężenia związków toksycznych zastosowano mobilny analizator do badań toksyczności SEMTECH DS firmy Sensors Inc, umożliwiający pomiar stężenia związków szkodliwych (w tym: CO, CO₂, HC, NO_x).



a)



b)

Rys. 1. Przebiegi a) prędkości b) emisji CO (linia ciągła) oraz NO_x (linia przerywana) dla wybranego przedziału czasu wraz z określeniem stanu pojazdu: zatrzymanie pojazdu (ST), przyspieszanie (AC), jazda ze stałą prędkością (GO) oraz hamowanie (DE)

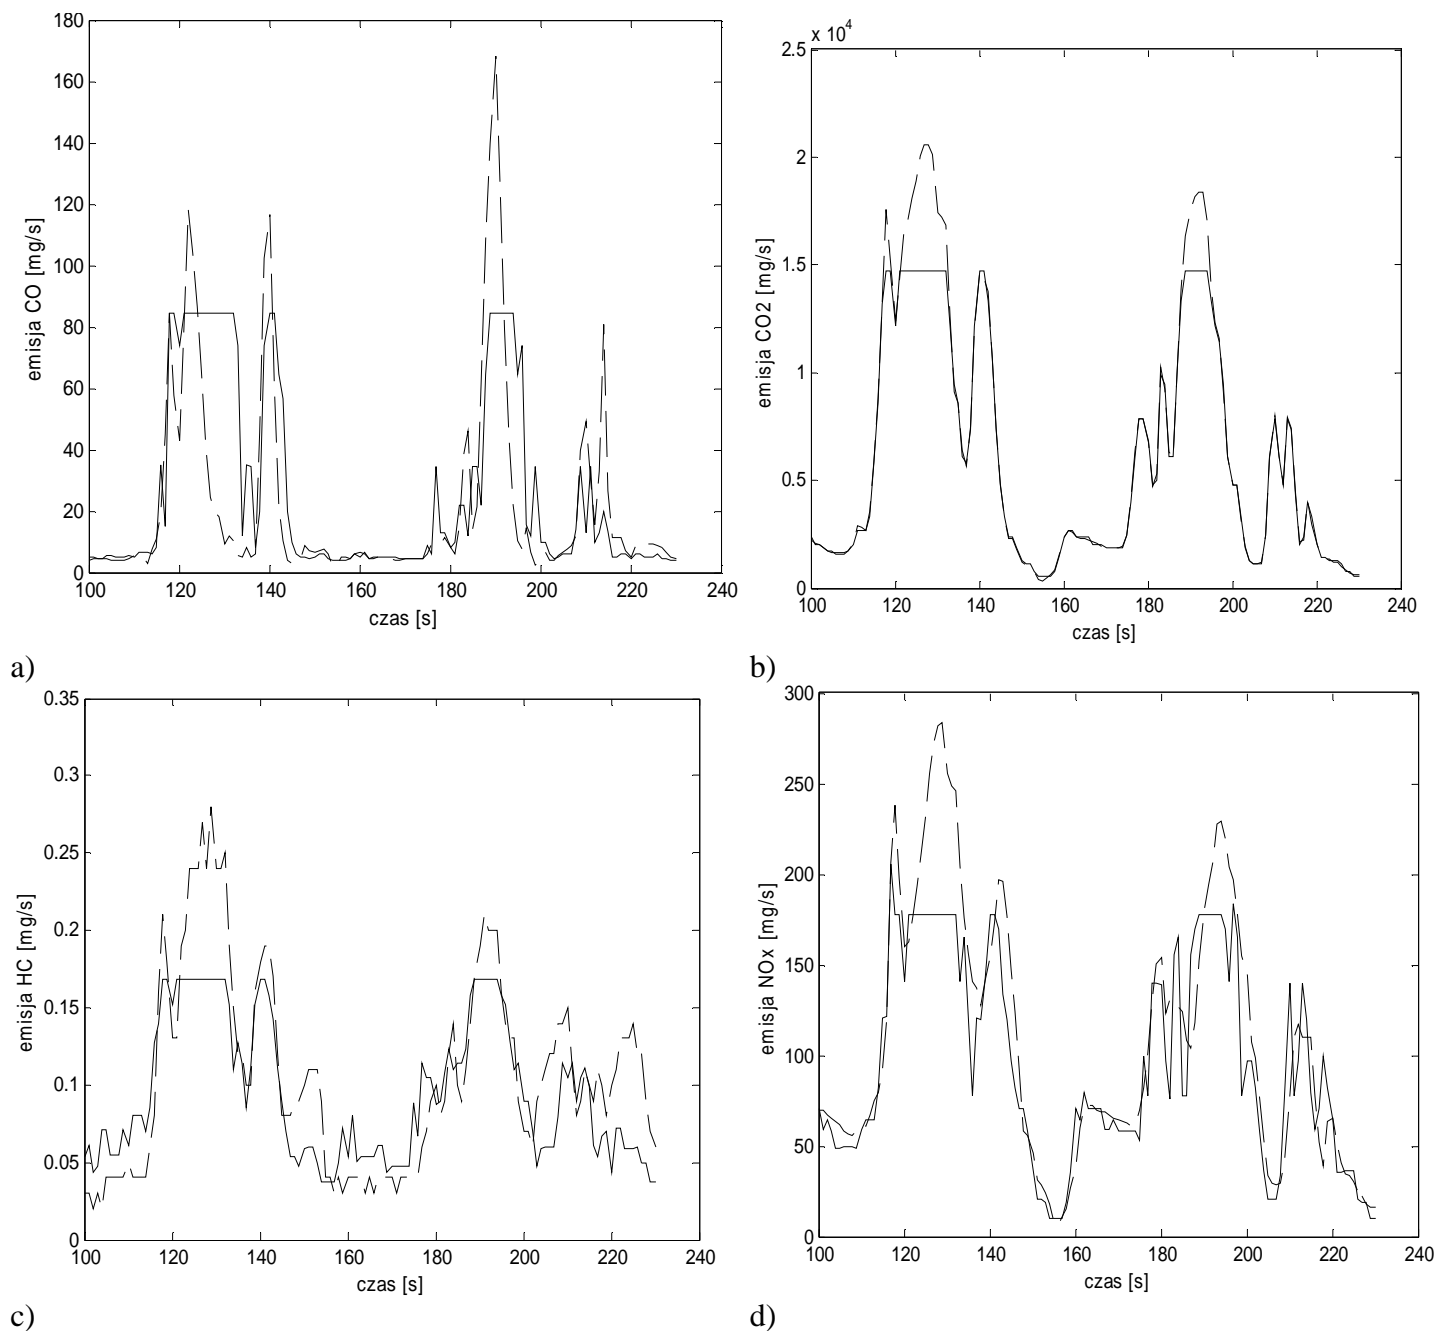
Źródło: opracowanie własne.

Cechą charakterystyczną eksperymentu drogowego prowadzonego z wykorzystaniem systemu PEMS była powtarzalność sekwencji stanów pracy pojazdu: zatrzymanie pojazdu (ST), przyspieszanie (AC), jazda ze stałą prędkością (GO) oraz hamowanie (DE). Do badań przyjęto odcinek pomiarowy reprezentowany 3686 próbkami, traktowanymi jako 4-wymiarowe wektory wartości zmierzonych emisji zanieczyszczeń CO,

CO₂, HC oraz NO_x. Wybrany fragment (46 próbek) wyników eksperymentu przebiegu prędkości wraz z odpowiadającymi przedziałami czasu dla stanów ST, AC, GO oraz DE przedstawiono na Rys. 1a, a odpowiadające przebiegi emisji zanieczyszczeń CO oraz NO_x na Rys. 1b.

Dane w postaci 3686 wektorów 4-wymiarowych stanowiły zestaw próbek uczących w procesie uczenia sieci Kohonena [5, 6] mającej na celu transformację wieloliczynowego zestawu uczącego do małoliczynowego zestawu wektorów 4-wymiarowych. Dane poddano normalizacji do zakresu [0,1]. W procesie uczenia zastosowano metodę uaktualniania pakietowego (*batch*) wektorów wagowych w_j neuronów sieci.

Przeprowadzone wstępne badania dotyczące określenia rozmiaru sieci Kohonena wykazały, że dla przyjętego zestawu próbek uczących minimalna liczba neuronów, dla których uzyskano zadowalające wyniki błędów (błąd kwantyzacji $e_q = 0,082$, błąd topologicznej reprezentacji $e_t = 0,120$) wynosi $k = 36$ neuronów, rozmieszczonych w topologii 6×6 .



Rys. 2. Przykładowe przebiegi emisji zanieczyszczeń zmierzonych (linia przerywana) oraz uzyskanych na podstawie symulacji sieci Kohonena (linia ciągła) o topologii 6×6 dla a) emisji CO, b) emisji CO₂, c) emisji HC, d) emisji NO_x

Źródło: opracowanie własne.

Zestaw neuronów nauczonej sieci Kohonena przedstawiono w Tabelcy 1, gdzie dla każdego z 36 neuronów referencyjnych podano wartości wektora wag w_j oraz liczbę przypisanych próbek uczących x_i .

Tabela 1. Zestaw neuronów sieci Kohonena dla $k = 36$ (topologia 6×6 neuronów).

Numer neuronu N_j	Liczba przypisanych próbek x_i	Składowe wektora wag w_j			
		CO [mg/s]	CO ₂ [mg/s]	HC [mg/s]	NO _x [mg/s]
1	2	3	4	5	6
1	544	3,738	524,7	0,0378	9,81
2	120	6,045	1103,2	0,0598	20,96
3	3	14,108	2458,1	0,0794	33,34
4	72	34,333	6135,6	0,1145	77,69
5	57	73,773	12138	0,1517	141,06
6	387	84,392	14761,0	0,1688	177,27
7	114	4,321	802,5	0,0496	19,15
8	197	6,044	1442,7	0,0721	35,33
9	32	11,746	2476,4	0,0882	43,50
10	55	21,994	4979,9	0,1083	76,26
11	39	56,503	10722,0	0,1427	134,01
12	55	64,232	13357,0	0,1578	169,67
13	133	4,818	1259,2	0,0593	36,36
14	166	5,511	1724,0	0,0710	48,42
15	16	8,559	2418,0	0,0882	53,20
16	60	13,488	4364,7	0,0992	79,60
17	54	34,886	8608,8	0,1273	121,38
18	19	39,902	11037	0,1382	154,62
19	275	4,805	1604,1	0,0550	49,85
20	133	5,093	2026,1	0,0609	59,21
21	73	6,803	2654,8	0,0801	64,31
22	43	9,680	4805,7	0,0893	96,69
23	67	19,823	7326,2	0,1112	119,36
24	47	21,977	9898,4	0,1232	155,87
25	176	4,616	1840,2	0,0479	58,313
26	136	4,796	2372,1	0,0534	70,349
27	110	6,118	3311,1	0,0704	82,26
28	57	8,345	5834,4	0,0852	120,93
29	73	12,922	7879,4	0,1045	139,78
30	41	15,284	11458,0	0,1287	184,03
31	68	4,3913	2020,7	0,0434	64,88
32	30	4,533	2643,8	0,0511	79,51
33	74	5,810	3968,3	0,0668	99,39
34	62	8,225	6803,7	0,0874	138,65
35	60	11,633	9470,6	0,1101	165,63
36	38	14,929	13216,1	0,1397	205,93

Źródło: opracowanie własne.

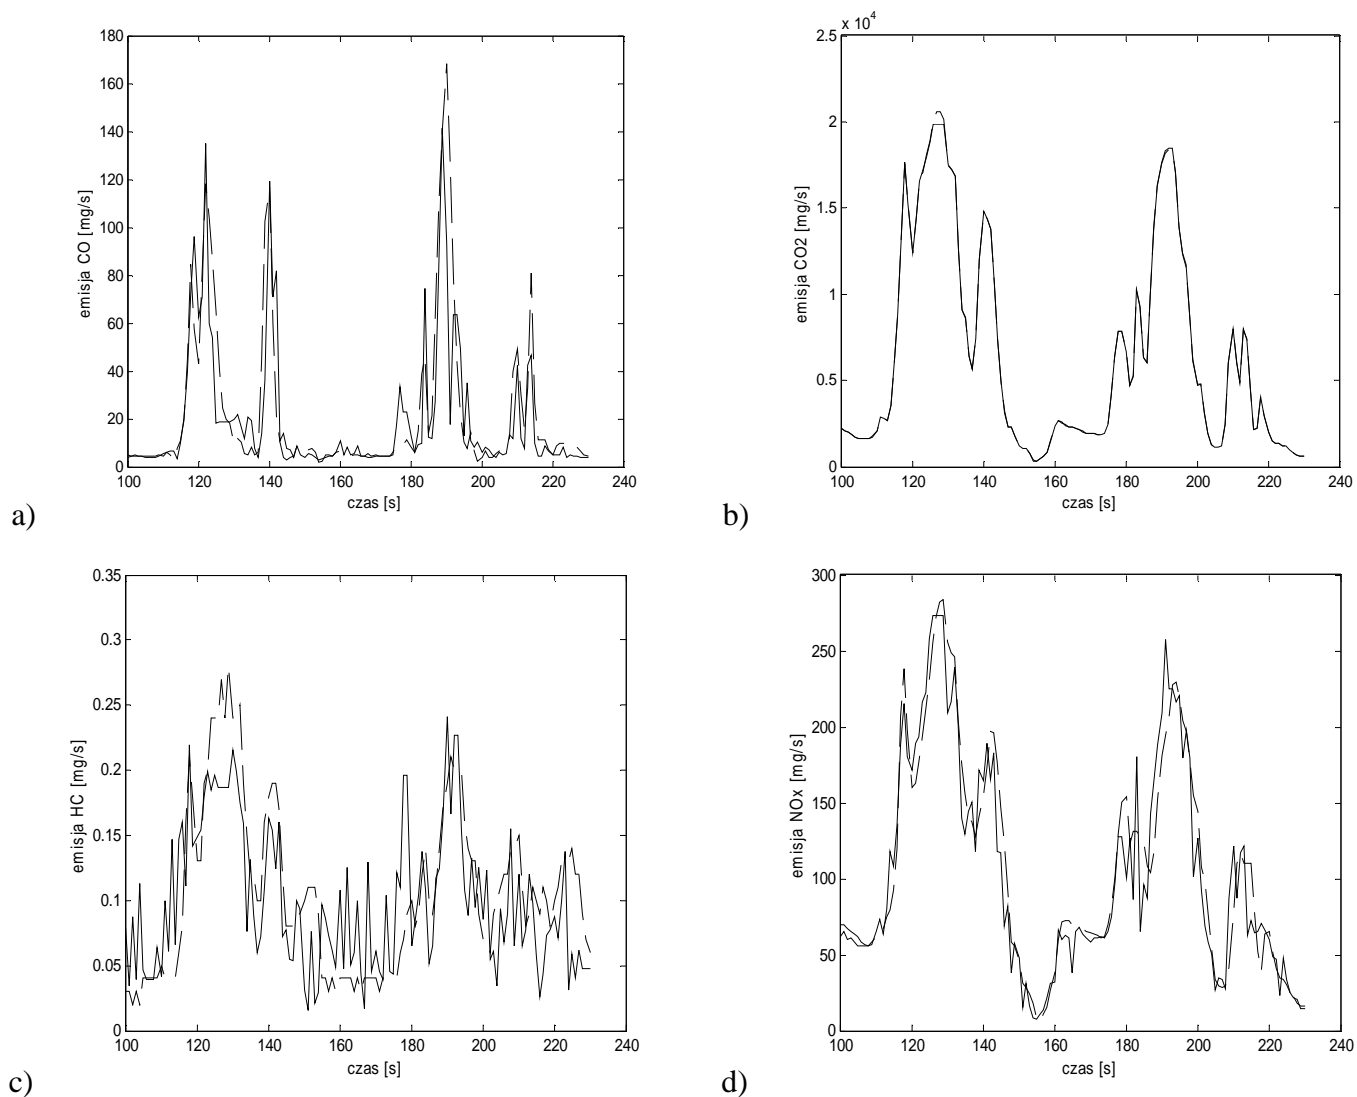
Przebiegi emisji zanieczyszczeń, dla wybranego przedziału czasu, zmierzone podczas eksperymentu drogowego oraz uzyskane w procesie symulacji z wykorzystaniem wyuczonej sieci Kohonena

przedstawiono na rys. 2. Wartości średnie oraz odchylenia standardowe dla różnic pomiędzy wartościami zmierzonymi podczas eksperymentu drogowego oraz uzyskane w procesie symulacji wyuczonej sieci Kohonena zebrano w Tabelicy 2.

Tablica 2. Wartości średnie oraz odchylenia standardowe dla różnic pomiędzy wartościami zmierzonymi oraz uzyskanymi w procesie symulacji dla $k = 36$ (topologia 6×6 neuronów).

Miara	CO [mg/s]	CO ₂ [mg/s]	HC [mg/s]	NO _x [mg/s]
1	2	3	4	5
Wartość średnia	14,644	570,970	0,031	22,537
Wartość odchylenia standardowego	21,298	1245,000	0,023	24,114

Źródło: opracowanie własne.



Rys. 3. Przykładowe przebiegi emisji zanieczyszczeń zmierzonych (linia przerywana) oraz uzyskanych na podstawie symulacji sieci Kohonena (linia ciągła) o topologii 20×20 dla a) emisji CO, b) emisji CO₂, c) emisji HC, d) emisji NO_x

Źródło: opracowanie własne.

Tablica 3. Wartości średnie oraz odchylenia standardowe dla różnic pomiędzy wartościami zmierzonymi oraz uzyskanymi w procesie symulacji dla $k = 400$ (topologia 20×20 neuronów).

Miara	CO [mg/s]	CO ₂ [mg/s]	HC [mg/s]	NO _x [mg/s]
1	2	3	4	5
Wartość średnia	10,236	42,962	0,038	15,422
Wartość odchylenia standardowego	17,497	93,148	0,028	15,758

Źródło: opracowanie własne.

Tablica 4. Wybrany zestaw neuronów sieci Kohonena dla $k = 400$ (topologia 20×20 neuronów).

Nr	Liczba próbek x_i					Składowe wektora wag w_j			
	AL	ST	AC	GO	DE	CO [mg/s]	CO ₂ [mg/s]	HC [mg/s]	NO _x [mg/s]
1	2	3	4	5	6	7	8	9	10
1	7	0	0	1	6	2,14	120,96	0,025	2,09
2	16	0	0	0	16	2,37	162,34	0,030	2,59
3	17	0	0	1	16	2,53	198,76	0,055	3,27
4	5	0	0	1	4	3,07	296,31	0,072	5,66
5	6	0	0	0	6	3,24	306,39	0,096	7,28
6	26	0	0	2	24	4,50	535,88	0,111	13,51
...
16	4	0	4	0	0	103,70	13507,23	0,157	141,97
17	15	0	15	0	0	119,03	14781,54	0,162	164,42
18	5	0	5	0	0	126,12	15828,28	0,159	183,28
19	6	0	6	0	0	141,24	16253,55	0,161	188,42
20	4	0	4	0	0	134,85	16525,91	0,179	193,44
...
101	18	0	0	0	18	3,67	547,56	0,009	10,25
102	17	0	0	4	13	4,18	762,60	0,020	16,40
103	21	0	0	1	20	3,56	639,19	0,032	18,67
104	11	0	0	2	9	4,41	916,13	0,053	27,87
105	9	0	0	0	9	4,70	964,37	0,064	29,39
...
151	1	0	0	1	0	4,57	2040,82	0,122	68,38
152	7	0	0	7	0	5,24	2851,16	0,134	84,89
153	9	0	1	7	1	8,49	3842,69	0,162	98,82
154	1	0	0	1	0	11,89	5694,82	0,171	112,53
155	10	0	2	8	0	22,67	7863,61	0,195	127,56
...
283	8	7	0	1	0	4,40	1781,25	0,043	58,68
284	12	12	0	0	0	4,45	1934,84	0,045	60,74
285	9	8	0	1	0	4,63	2005,88	0,048	59,77
286	24	15	3	2	4	4,89	2307,49	0,046	61,68
287	9	7	1	0	1	5,12	2420,84	0,050	62,69
...
396	5	0	4	1	0	10,83	11924,03	0,087	207,52
397	12	0	11	1	0	13,11	13840,23	0,107	221,05
398	6	0	6	0	0	15,99	16590,61	0,130	244,92
399	16	0	16	0	0	17,68	18300,98	0,166	257,08
400	78	0	72	6	0	18,88	19869,41	0,187	273,05

Źródło: opracowanie własne.

Na podstawie analizy przebiegów emisji zanieczyszczeń oraz wartości średnich i odchyłeń standardowych zebranych w Tablicy 2 stwierdzono, że liczba neuronów $k = 36$ dla sieci Kohonena w badanym zadaniu jest niewystarczająca.

W dalszych badaniach przyjęto sieć Kohonena o liczbie neuronów $k = 400$ rozmieszczonych w topologii 20×20 neuronów. Dla przyjętej sieci wyliczono błąd kwantyzacji $e_q = 0,038$ oraz błąd topologicznej reprezentacji $e_t = 0,077$.

Przebiegi emisji zanieczyszczeń, dla wybranego przedziału czasu, zmierzone podczas eksperymentu drogowego oraz uzyskane w procesie symulacji z wykorzystaniem wyuczonej sieci Kohonena przedstawiono na rys. 3. Wartości średnie oraz odchylenia standardowe dla różnic pomiędzy wartościami zmierzonymi podczas eksperymentu drogowego oraz uzyskane w procesie symulacji wyuczonej sieci Kohonena zebrano w tablicy 3.

Na podstawie analizy przebiegów emisji zanieczyszczeń oraz wartości średnich i odchyłeń standardowych zebranych w Tablicy 3 stwierdzono, że liczba neuronów $k = 400$ dla sieci Kohonena w badanym zadaniu jest wystarczająca.

Wyuczoną sieć Kohonena poddano testowi, sprawdzając zdolność sieci do rozpoznania zadanych, znanych przebiegów wzorcowych, odpowiadających stanom badanego pojazdu w czasie eksperymentu: zatrzymanie pojazdu (ST), przyspieszanie (AC), jazda ze stałą prędkością (GO) oraz hamowanie (DE). Wybrany zestaw neuronów nauczonej sieci Kohonena dla $k = 400$ przedstawiono w Tablicy 4, dla których podano wartości wektora wag w_j , ogólną liczbę przypisanych próbek uczących x_i (2), a w kolumnach (3), (4), (5) oraz (6) podano liczbę próbek uczących przypisanych przyjętym stanom pracy pojazdu w trakcie eksperymentu. Interpretacja wyników zaprezentowanych w Tablicy 4 pozwala stwierdzić, że przykładowo: neuronom o numerach od 1 do 6 odpowiada stan DE (hamowanie), neuronom o numerach od 16 do 20 odpowiada stan AC (przyspieszanie), neuronom o numerach od 151 do 155 odpowiada stan GO (jazda ze stałą prędkością), a neuronom o numerach od 283 do 287 odpowiada stan ST (zatrzymanie pojazdu).

W celu sprawdzenia poprawności działania sieci wyznaczono dla przyjętych stanów pracy badanego pojazdu wartości średnie i odchylenia standardowe wartości zmierzonych podczas eksperymentu oraz uzyskanych w procesie symulacji z wykorzystaniem wyuczonej sieci Kohonena. Wyniki przedstawione w Tablicy 5 potwierdzają poprawność działania wyuczonej sieci o topologii 20×20 neuronów.

Tablica 5. Wartości średnie i odchylenia standardowe emisji zanieczyszczeń zmierzonych podczas eksperymentu oraz uzyskanych w procesie symulacji z wykorzystaniem wyuczonej sieci Kohonena $k = 400$ (topologia 20×20 neuronów) dla przyjętych stanów pojazdu.

Stan	Miara	Na podstawie eksperymentu [mg/s]				Na podstawie SOM [mg/s]			
		CO	CO ₂	HC	NO _x	CO	CO ₂	HC	NO _x
1	2	3	4	5	6	7	8	9	10
STOP	Średnia	4,84	1750,8	0,059	54,52	4,90	1750,7	0,062	54,23
	Od. stand.	0,69	389,8	0,025	9,06	0,82	389,4	0,026	10,20
ACC	Średnia	36,28	11418,0	0,133	161,78	32,66	11355,0	0,133	164,56
	Od. stand.	37,55	5243,9	0,073	62,40	30,57	5134,7	0,050	59,39
GO	Średnia	15,92	5785,6	0,088	104,91	15,11	5773,0	0,093	101,35
	Od. stand.	20,53	4108,6	0,053	61,41	17,33	4050,1	0,044	53,92
DEC	Średnia	4,09	1185,7	0,054	35,23	4,13	1197,9	0,048	30,91
	Od. stand.	4,12	1358,3	0,043	39,32	2,33	1346,9	0,035	33,14

Źródło: opracowanie własne.

4. WNIOSKI

Celem artykułu było przeprowadzenie testu odnośnie przydatności i skuteczności zastosowania sieci Kohonena w analizie i interpretacji wyników pomiarów uzyskanych w trakcie eksperymentu prowadzonego w rzeczywistych warunkach eksploatacji pojazdu.

Zastosowano sieci Kohonena do transformacji wielolicezowego zestawu danych uczących uzyskanych z pomiarów do zestawu małowieliczowego. Dla danych w postaci 3686 wektorów 4-wymiarowych stanowiących zestaw próbek uczących wyuczono dwie sieci Kohonena o różnej topologii (wymiary 6×6 oraz 20×20).

Na podstawie przeprowadzonej analizy wyników stwierdzono, że sieć o topologii 20×20 działa poprawnie, co potwierdziły przeprowadzone badania dotyczące rozpoznawania zadanych wzorców stanu pojazdu w trakcie eksperymentu (zatrzymanie pojazdu, przyspieszanie, jazda ze stałą prędkością, hamowanie).

Problem rozpoznawania wzorców jest szczególnie istotny w procesie przygotowania i prowadzenia eksperymentu emisji zanieczyszczeń z pojazdu na stanowisku badawczym dla oceny zgodności z wynikami eksperymentu prowadzonego w warunkach rzeczywistych.

Streszczenie

Rozwój technik pomiarowych PEMS sprzyja badaniom ekologiczności pojazdów w rzeczywistych warunkach pracy. Interpretacja wyników pomiarów, na przykład emisji zanieczyszczeń, reprezentowanych bardzo licznymi zbiorami różnorodnych danych wymaga przeprowadzenia złożonych analiz numerycznych. Wyrafinowane metody statystyczne są skuteczne, lecz interpretacja wyników wymaga udziału eksperta o bardzo specjalistycznej wiedzy. Stosowanie metod data mining stwarza szerokie perspektywy i zwiększa zdecydowanie możliwości w zakresie analizy i interpretacji wyników eksperymentu. W artykule przeprowadzono badania transformacji wielolicezowego zestawu uczącego uzyskanego z pomiarów do mało licznego zestawu neuronów sieci Kohonena. Dla wyuczonej sieci Kohonena przeprowadzono badania dotyczące rozpoznawania zadanych wzorców stanu pojazdu pomierzonych w trakcie eksperymentu drogowego.

Słowa kluczowe: sieci Kohonena, emisja zanieczyszczeń, PEMS.

PEMS measured pollution emissions pattern recognition using Self-Organizing Maps (SOM)

Abstract

The improvement of PEMS enables better estimation of ecological quality of vehicles. However, interpretation of divers sort of data, e.g. exhaust emissions, gathered during on road testing requires complex numerical analyses. Advanced statistical analyses have already proven their applicability in this domain but the interpretation of the results requires the participation of experts with extended knowledge. The usage of the data mining methods brings the perspective in the ease of interpretation of obtained results. In this article, the Self-Organizing Maps were used to transform the multiplicity of data gathered during the on road experiment into the reduced set of representative data. Trained SOM was tested in the recognition of the vehicle states measured during the on road experiment.

Key words: Self-Organizing Maps, pollution emissions, PEMS.

LITERATURA

- [1] Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R. (red.): TOM 6 SIECI NEURONOWE, Seria: Biocybernetyka i inżynieria biometryczna 2000, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.
- [2] Kohonen T.: Self-Organizing Maps, Springer Series In Information Sciences, Vol. 30, Springer, Berlin, Heilderberg, New York, 2001.
- [3] Merkisz J., Barczak A., Pielecha J.: Badanie zmienności emisji zanieczyszczeń z zastosowaniem metody PCA, Instytut Logistyki i Magazynowania – Logistyka-nauka, Numer 3, 2011, str. 1835-1844.
- [4] Merkisz J., Barczak A., Pielecha J.: Pomiary emisji spalin systemem PEMS i badanie wyników eksperymentu z wykorzystaniem metod analizy wariancji, Instytut Logistyki i Magazynowania – Logistyka-nauka, Numer 4, 2011, str. 625-634.
- [5] MATLAB 7.04.
- [6] SOM Toolbox 2.0, <http://www.cis.hut.fi/projects/somtoolbox/>.

Acknowledgment

Praca częściowo finansowana w ramach grantu nr N N509 559240 realizowanego dla Narodowego Centrum Nauki w Krakowie w latach 2011-2013.