

**dr n. tech. Dorota Anna OSZUTOWSKA-MAZUREK**

Wyższa Szkoła Techniczno-Ekonomiczna w Szczecinie, Wydział Transportu Samochodowego  
Higher School of Technology and Economics in Szczecin, Department of Motor Transport

## WYKORZYSTANIE SIECI NEURONOWEJ KOHONENA DO WIZUALIZACJI DANYCH MPG

### Streszczenie

**Wstęp i cel:** Zastosowanie sieci neuronowych Kohonena zapewnia zmniejszenie wielowymiarowości danych. Wizualizacja w postaci map samoorganizujących się (SOM) jest użytecznym narzędziem do wstępnego kastrowania (grupowania) danych.

**Materiał i metody:** Wizualizację przeprowadzono dla rzeczywistych danych, udostępnionych przez uniwersytet w Kalifornii za pomocą oprogramowania SNNS v.4.3. Głównym celem pracy jest zastosowanie sieci neuronowych Kohonena zapewniające zmniejszenie wielowymiarowości danych.

**Wyniki:** Otrzymano wizualizacje danych wskazujące jednoznacznie na dodatnie i ujemne korelacje danych MPG.

**Wniosek:** Mapy samoorganizujące się mogą być dedykowane wizualizacji danych wielowymiarowych jednak wyniki zależą od sposobu mapowania danych wejściowych, zwłaszcza o charakterze jakościowym, nawet jeśli stosowana jest normalizacja każdego z parametrów.

**Słowa kluczowe:** Sieć neuronowa Kohonena, samoorganizujące się mapy (SOM), wizualizacja danych, dane MPG.

(Otrzymano: 27.01.2016; Zrecenzowano: 28.01.2016; Zaakceptowano: 31.01.2016)

## USE OF KOHONEN NEURAL NETWORK IN MPG DATA VISUALISATION

### Abstract

**Introduction and aim:** The use of Kohonen neural network ensures the decrease of data multidimensionality. Visualisation called Self organized maps is useful tool for preliminary data clustering.

**Material and methods:** The visualisation of real data set was obtained with the use of program SNNS v.4.3 for real dataset from California University. The main aim of this paper is the use of Kohonen neural network to ensure the reduction of multidimensional data.

**Results:** Obtained visualisations of data indicate unambiguously positive and negative correlations for MPG data

**Conclusion:** Self organising maps could be dedicated to multidimensional data visualisation and preliminary quality assessment, but the results depend on the mapping method of input data, especially quantity type, even if normalisation of every parameter is provided

**Keywords:** Kohonen neural network, self organizing maps (SOM).

(Received: 27.01.2016; Revised: 28.01.2016; Accepted: 31.01.2016)

## 1. Wstęp i cele

Sieci neuronowe stanowią istotne rozwiązanie pozwalające na przetwarzanie oraz analizę danych. Głównym zastosowaniem sztucznych sieci neuronowych (SSN) są zadania rozpoznawania i klasyfikacji [6], [7], [10], [11]. Dane wejściowe (wektor wejściowy) mogą być wielowymiarowe a wektor wyjściowy skalarny lub wielowymiarowy, w zależności od zagadnienia. Danymi są ciągi tego samego typu (piksele obrazu lub fragment szeregu czasowego) lub różnego typu (gdzie każdy z elementów wektora wejściowego odnosi się do innej cechy). Realizowane zadania wynika z doboru wartości wag, struktury połączeń oraz typów funkcji aktywacji neuronów. W większości przypadków struktura i funkcje aktywacji dobierane są arbitralnie, podczas gdy wartości wag określane są w procesie uczenia. Istnieje możliwość wyznaczenia wartości wag za pomocą wzorów, jednak typowym podejściem jest jedna z dwóch technik uczenia - nadzorowanego (z nauczycielem) lub nienadzorowanego [11].

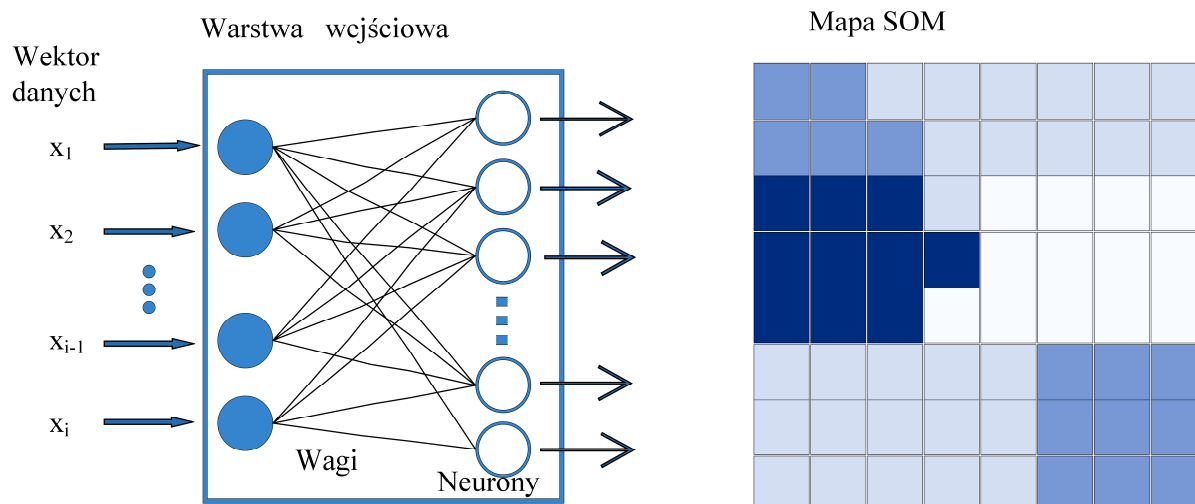
W procesie uczenia nadzorowanego prezentowane są pary wektorów: wejściowy i wyjściowy, co pozwala na porównanie odpowiedzi sieci neuronowej dla zadanego wektora wejściowego z wektorem wyjściowym, celem wyznaczenia wartości błędu. Wartość błędu następnie jest wykorzystywana przez algorytm uczenia SSN celem minimalizacji globalnego błędu. Podejście tego typu jest typowe w zadaniach przykładowo klasyfikacji.

Alternatywny rodzaj sieci neuronowych jest uczeniem nienadzorowanym, gdzie brak jest nauczyciela, a tym samym nie ma pary wektorów danych wejściowych i wyjściowych, a jedynie wektor wejściowy [4], [11]. Celem zastosowania tego typu sieci neuronowych jest takie wypracowanie wartości wyjściowych, zgodnie z przyjętym algorytmem, by uzyskać wynik o pożądanym charakterze globalnym. Sieci neuronowe w tym przypadku zwykle realizują zadania klasteryzacji, czy redukcji wymiarowości danych wejściowych. O ile istnieją alternatywne rozwiązania dla tego typu zadań, wykorzystujące metody nie neuronowe, to jest to ciekawe rozwiązanie techniczne.

Redukcja wymiarowości danych jest istotna dla danych wejściowych zarówno o tym samym jaki i różnym typie i pozwalać może na wizualizację ich dla człowieka tak by pomóc w ich analizie. O ile analiza danych jedno-, dwu- i trójwymiarowych jest osiągalna dla człowieka, to przy większej liczbie wymiarów jest to bardzo utrudnione. Można wykonać podział przestrzeni czterowymiarowej na grupę wizualizacji 3D jednak wymaga to dyskretyzacji dodatkowego wymiaru, a prezentacja danych nie jest komfortowa dla człowieka. W przypadku większej liczby wymiarów zadanie to wymaga automatycznych metod komputerowych.

Klasteryzacja polega na grupowaniu danych o podobnym charakterze. Dane (wektory) zbliżone do siebie powinny być traktowane jak jeden rodzaj o niewielkich różnicach, a dane istotnie różne jako osobne. Zadania powyższe mogą być realizowane za pomocą sztucznej sieci neuronowej Kohonena [4], [6], która w procesie uczenia nienadzorowanego pozwala na uzyskanie mapy SOM (*ang. self-organizing map*) lub SOFM (*ang. self-organising feature map*). Mapa ta jest dyskretna i zwykle wykorzystuje się mapy 2D, co przedstawiono na rysunku 1. Dyskretyzacja mapy wynika z ustalonej całkowitej liczby neuronów sieci Kohonena. Celem pracy jest analiza możliwości wykorzystania SOM do klasteryzacji danych w ramach oceny jakościowej przez człowieka.

Pozwala to na szybką ocenę danych. Szczegółowym celem jest analiza wpływu normalizacji danych na tego typu wyniki. Sieci neuronowe pozwalają na uzyskanie dowolnego odwzorowania wektorów wejściowych na wyjściowe, co może prowadzić do szeregu problemów w przypadku złej reprezentacji danych wejściowych. Dla przykładowego zbioru uczącego jest to związane z koniecznością normalizacji danych [9], a także kilku możliwych wariantów mapowania danych o charakterze jakościowym do oczekiwanej przez sieć neuronową reprezentacji ilościowej.



Rys. 1. Architektura sieci Kohonena oraz wizualizacja SOM

Źródło: Opracowanie własne oparte na [13]

Fig.1. Architecture of Kohonen network and SOM visualisation

Source: Elaboration of the Author based on [13]

Uczenie jest przeprowadzane za zasadzie uczenia kompetycyjnego. Gdy przykład trenowany jest zadawany sieci, wyznaczana jest jego odległość euklidesowa do wszystkich wag wektorów. Neuron o wadze wektora najbardziej podobnej do wejścia jest nazywany jednostką najlepszego dopasowania, BMU (*ang. best matching unit*).

Stosowane jest uczenie z rywalizacją (*ang. competitive learning*) [11]. Wagi BMU i neuronów w warstwie SOM są dostosowane przez wektor wejściowy. Wielkość zmian maleje w czasie i dystansie wewnątrz warstwy z BMU.

Wzór na neuron  $v$  z wagą wektora  $W_v(s)$  wynosi:

$$W_v(s+1) = W_v(s) + \Theta(u, v, s) \alpha(s) (D(t) - W_v(s)), \quad (1)$$

gdzie  $s$  jest indeksem kroku,  $t$  indeksem do przykładu uczącego,  $u$  jest indeksem BMU dla  $D(t)$ ,  $\alpha(s)$  jest współczynnikiem monotonicznie malejącym uczenia i  $D(t)$  jest wektorem wejściowym,  $\Theta(u, v, s)$  jest funkcją sąsiedztwa, która daje odległość między neuronem  $u$  i neuronem  $v$  w kroku.

Zależnie od implementacji,  $t$  może skanować zbiór danych systematycznie ( $t$  wynosi 0, 1, ... T-1), następnie powtarza, T będąc przykładowym rozmiarem próby [5]. SOM mają wiele zastosowań, między innymi dla baz danych dotyczących pojazdów [1]-[3], [12].

## 2. Materiały i metody

W artykule zastosowano sieć Kohonena do analizy danych udostępnionych przez Uniwersytet w Kalifornii [8]. Baza danych MPG jest zbiorem 398 rekordów dotyczących samochodów/pojazdów, zebranych z lat 1970-1982 [8]. Zawiera atrybuty takie jak nazwa samochodu, zużycie paliwa MPG (*ang. miles per gallon*), liczbę cylindrów (*ang. cylinders*), moc silnika (w koniach mechanicznych, *ang. horse power*), objętość skokowa silnika (*ang. displacement*), waga pojazdu (*ang. weight*), rok produkcji (*ang. model year*) oraz rejon produkcji (*ang. origin*): USA, Japonia, Europa, co zawarto w tablicy 1.

Z oryginalnej bazy odrzucono przypadki z niepełnymi danymi, ponadto zrezygnowano z nazwy samochodu.

W procesie uczenia wykorzystano oprogramowanie SNNS v.4.3 [14]. Baza charakteryzuje się 8 atrybutami o charakterze ciągłym jak i dyskretnym.

Tab. 1. Atrybuty bazy danych MPG

Tab. 1. MPG database attributes

<i>Nr atrybutu</i>	<i>Atrybut</i>	<i>Typ</i>
1	Zużycie paliwa MPG	Ciągły
2	Liczba cylindrów	Wielowartościowy dyskretny
3	Objętość skokowa	Ciągły
4	Moc silnika	Ciągły
5	Waga pojazdu	Ciągły
6	Przyspieszenie	Ciągły
7	Rok produkcji	Wielowartościowy dyskretny
8	Pochodzenie	Wielowartościowy dyskretny

Źródło: Opracowanie własne na podstawie [1]

Source: Elaboration of the Author based on [1]

Jednym z istotnych, jak można się domyślać z parametrów jest atrybut pochodzenie (*ang. origin*), ponieważ pojazdy samochodowe są produkowane zwykle z uwzględnieniem potrzeb lokalnego rynku. Domyślnie w bazie przyjęto mapowanie w postaci cyfr: 1 = USA; 2 = Europa; 3 = Japonia. Tego typu rozwiązanie jest proste, jednak wymusza reprezentację liczbową o charakterze ilościowym.

Nie jest to podejście właściwe w procesie analizy danych i albo ten parametr musi być pominięty (wtedy tracimy istotną informację), albo analiza musi być robiona w rozbiciu na te trzy obszary pochodzenia (zmniejsza się pula danych w każdej z osobnych analiz). Alternatywnym rozwiązaniem jest mapowanie tego parametru tak by móc go wykorzystać w ramach sieci neuronowej, ale nie w postaci liczbowej według bazy.

Sieć ma od 7 do 10 jednostek wejściowych typu logistycznego, co ogranicza wartości do zakresu 0-1 w sposób nieliniowy. Mapa ma rozmiar 20×20 jednostek, co wybrano arbitralnie na podstawie obserwacji uczenia dla różnych rozmiarów.

Zbyt mała mapa nie pozwala na samoorganizację z odwzorowaniem detali, podczas gdy zbyt duża jest nieoptymalna i wymaga dłuższego procesu uczenia. Mapowanie kolorów oznacza wartości – zielony dużą (okolice 1), niebieski małą (okolice 0). Sieć jest inicjowana wartościami losowymi, a podczas uczenia promień maleje stopniowo do zera.

### 3. Rodzaje normalizacji danych


#### 3.1. Normalizacja wszystkich 8 atrybutów z osobna

Normalizacja atrybutów jest niezbędna, ponieważ zakresy wartości wpływają na proces uczenia, gdzie dużej wartości dodatnie są ważniejsze, więc dzięki normalizacji uzyskuje się niezależność między atrybutami (są jednakowo ważne). W tym przypadku wykonywana jest normalizacja wartości atrybutów do zakresu <0-1> w sposób niezależny:

$$Dtemp(j)_i = D(j)_i / D(t) - W_v(s) \min(D(.)_i), \quad (2)$$

$$DN(j)_i = Dtemp(j)_i / \max(Dtemp(j)_i), \quad (3)$$

gdzie  $i$  jest numerem atrybutu,  $DN(j)$  jest  $j$ -tym wektorem o znormalizowanych atrybutach. Metoda ta tylko realizuje normalizację wymaganą przez sieć, natomiast pomija konieczność właściwej reprezentacji dla atrybutu pochodzenie (w tym przypadku 0 – USA; 0,5 – Europa; 1,0 – Japonia).



Rys. 2. Wizualizacje SOM po normalizacji wszystkich atrybutów z osobna  
Źródło: Opracowanie własne

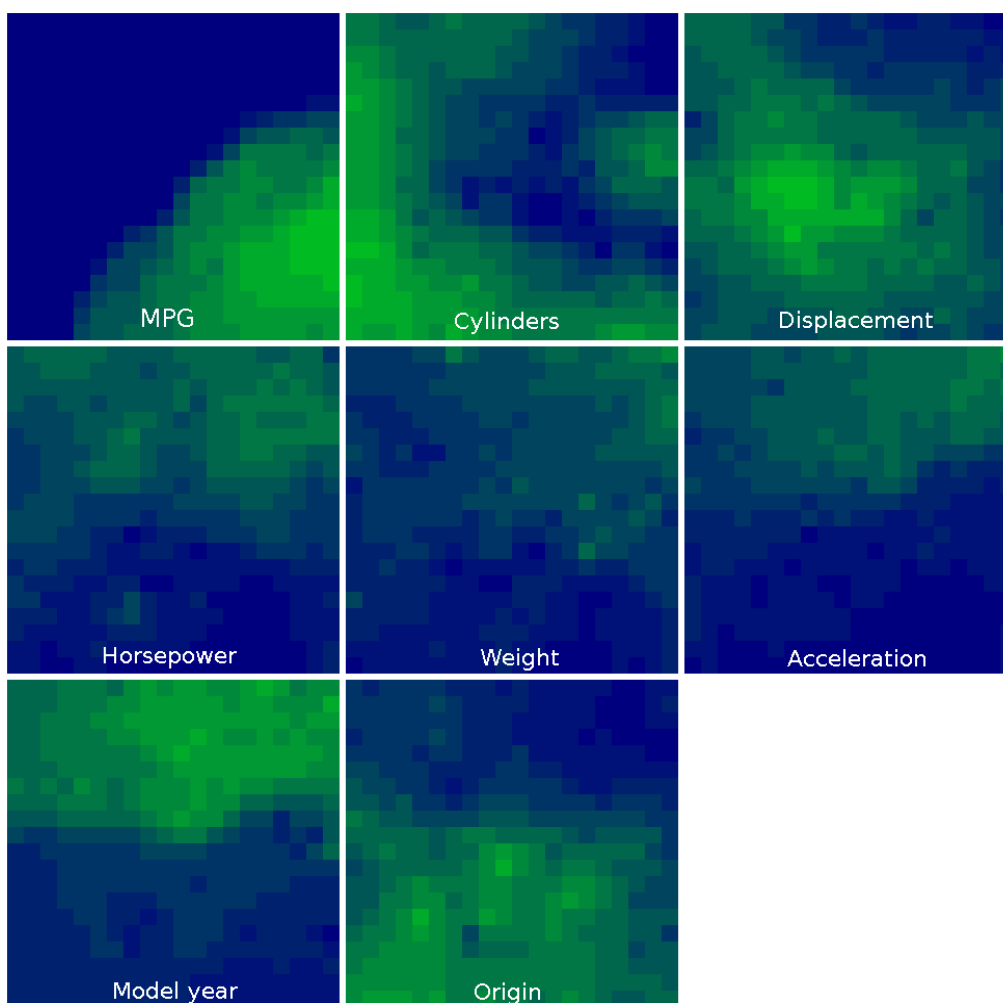
Fig. 2. SOM visualisations after normalisation of all attributes  
Source: Elaboration of the Author

Na rysunku 2 widoczna jest dodatnia korelacja między mocą silnika a wagą pojazdu i przyspieszeniem oraz rokiem produkcji. Można zaobserwować również, że występuje ujemna korelacja między pochodzeniem pojazdu a danymi odnośnie roku produkcji, mocy silnika, wagi oraz przyspieszenia. Mapa dotycząca pochodzenia pojazdu jest niejednorodna co utrudnia analizę względem tego parametru.

### 3.2. Normalizacja atrybutów z osobna, a następnie normalizacja całego wektora

Kolejne rozwiązanie realizuje zadanie normalizacji jak metodzie z 3.1, co gwarantuje zakres zmienności wartości od 0 do 1, po czym normalizowany jest cały wektor. Po normalizacji całego wektora jego długość wynosi 1, dzięki czemu uzyskuje się niezależności od wspólnej skali dla wszystkich wartości atrybutów:

$$D(j) = \text{norm}(D(j)). \quad (4)$$



Rys. 3. Wizualizacje SOM po normalizacji wszystkich atrybutów w osobna a następnie całego wektora

Źródło: Opracowanie własne

Fig. 3. SOM visualisations after normalisation of all attributes and entire vector

Source: Elaboration of the Author


Na rysunku 3 przedstawione są mapy SOM takie same jak w poprzednim przypadku, ale jedynie obrócone, wnioski są zatem takie same. Widać że proces prowadzi od losowych wartości wag początkowych do tego samego rozwiązania, więc podejście metodyczne jest prawidłowe.

Podobnie jak w przypadku poprzednim atrybut pochodzenia pojazdu jest niejednorodny na mapie, co utrudnia ocenę względem tego parametru.

### 3.3. Normalizacja siedmiu atrybutów i alternatywne mapowanie atrybutu pochodzenie

W poprzednich metodach stosowano niewłaściwe podejście względem atrybutu pochodzenie, ponieważ założone wartości liczbowe nie mają sensu. Aby móc je poprawnie wykorzystać zaproponowano mapowanie polegające na zamianie skalarą na wektor trójelementowy o wartościach ortogonalnych. Atrybut ósmy zastępowany jest wektorem:

- [0 0 1] dla USA,
- [0 1 0] dla Europy,
- [1 0 0] dla Japonii.




Rys. 4. Wizualizacje SOM po normalizacji 7 atrybutów i rozszerzeniu wektora o trzy elementy  
*Źródło: Opracowanie własne*

Fig. 4. SOM visualisations after normalisation of 7 attributes and vector extension via three elements  
*Source: Elaboration of the Author*

Na rysunku 4 widoczna jest odwrotna (ujemna) korelacja między MPG a liczbą cylindrów oraz znacząca korelacja między cylindrami oraz MPG a objętością skokową. Widoczna jest również korelacja między obszarem pochodzenia: dla Europy zaobserwowano mniejsze zużycie paliwa i mniejszą liczbę cylindrów a większą objętość skokową, dla USA podobnie. Dla modeli japońskich z kolei, większą liczbę cylindrów i większe zużycie paliwa, ponadto modele europejskie cechowała mniejsza waga.

### 3.4. Normalizacja siedmiu atrybutów i alternatywne mapowanie atrybutu pochodzenie, a następnie całego wektora

W tym rozwiązaniu wykorzystano podejście z punktu 3.3 oraz normalizację z 3.2.



Rys. 5. Normalizacja siedmiu atrybutów i alternatywne mapowanie atrybutu pochodzenie, a następnie całego wektora  
*Źródło: Opracowanie własne*


Fig. 5 Normalisation of seven attributes and alternative mapping of origin, followed by normalisation of entire vector  
*Source: Elaboration of the Author*

Na rysunku 5 zaobserwowano podobne zależności, jak na rysunku 4, ale w tym przypadku jest inna reprezentacja mapy – w innych obszarach są wysokie wartości zużycia paliwa a liczba cylindrów jest w tym samym, dlatego obrazy SOM są podobne ale nie identyczne z analogicznymi z rysunku 4. Wynika to z punktu startowego wag oraz kolejności prezentacji danych w procesie uczenia.



### 3.5. Normalizacja tylko 7 atrybutów (bez rejonu pochodzenia)

Jest to rozwiązanie polegające na odrzuceniu rejonu pochodzenia, co rozwiązuje problem mapowania wartości, jednak wprowadza silne uproszczenie wyników. Wynik będzie oczywiście poprawny w sensie średnim (pomijany parametr) ale też powoduje utratę szczegółowości wykresu. Wartości parametrów są normalizowane z osobna.



Rys. 6. Wizualizacje SOM po normalizacji 7 atrybutów (bez rejonu pochodzenia)  
*Źródło: Opracowanie własne*

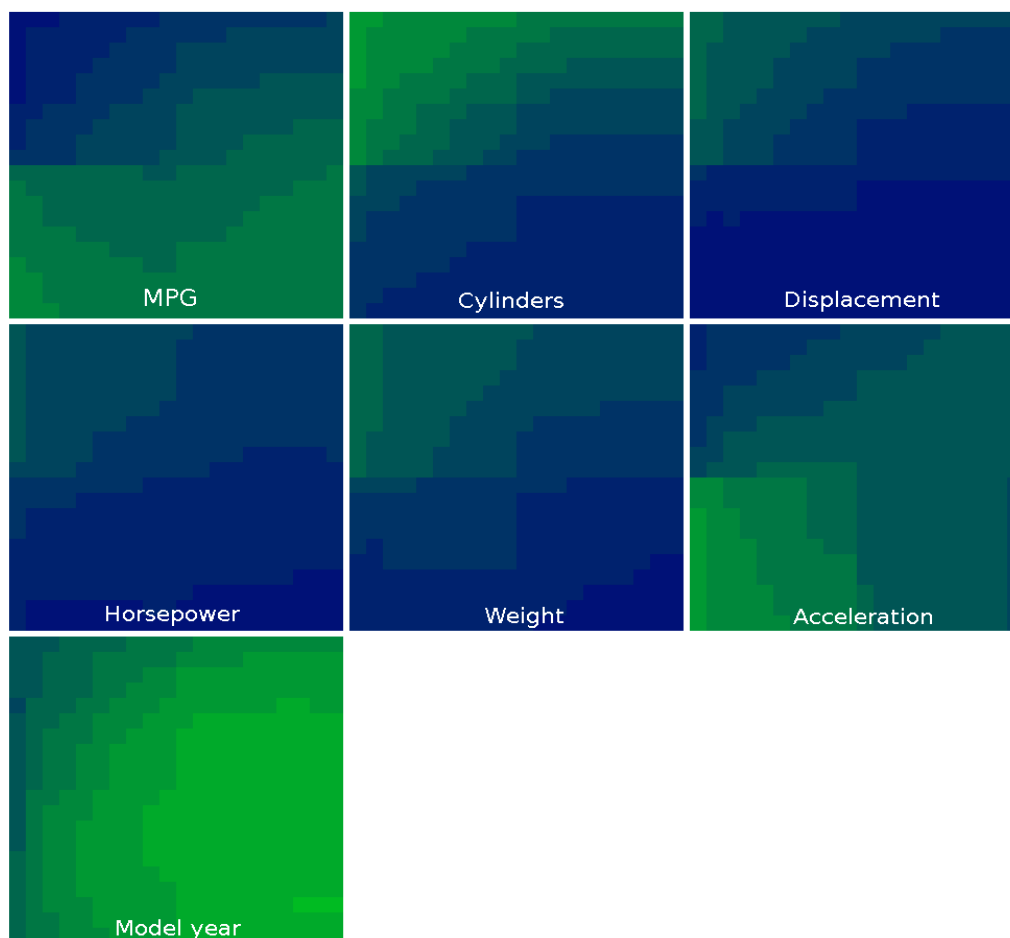
Fig. 6 . SOM visualisations after normalisation of 7 attributes (without origin)  
*Source: Elaboration of the Author*

Na rysunku 6 widoczne są zależności podobne jak na rysunku 5 oraz widoczna jest dodatkowo dodatnia korelacja między mocą silnika, wagą, objętością skokową i liczbą cylindrów, natomiast wymienione dane są w ujemnej korelacji z danymi odnośnie zużycia paliwa i roku produkcji samochodu oraz przyspieszeniem.

W tym ujęciu korelacje są bardzo widoczne. Może być ono stosowane do oceny zgrubnej, a następnie można wykorzystać bardziej szczegółową metodą 3.3 lub 3.4.

### 3.6. Normalizacja siedmiu atrybutów, a następnie normalizacja całego wektora

Jest to rozwiązanie podobne do opisanego w 3.5, jednak dodano normalizację całego wektora.



Rys. 7. Wizualizacje SOM po normalizacji 7 atrybutów a następnie całego wektora

*Źródło: Opracowanie własne*

Fig. 7. SOM visualisations after normalisation of 7 attributes followed by normalization of entire vector

*Source: Elaboration of the Author*

Na rysunku 7 wyraźnie widoczna jest ujemna korelacja między zużyciem paliwa a liczbą cylindrów, objętością skokową, mocą silnika oraz wagą pojazdu, natomiast zaobserwowano dodatnią korelację między zużyciem paliwa a przyspieszeniem. Wyniki są podobne jak w punkcie 3.5, czyli obserwowane jest mniejsze zużycie paliwa dla pojazdów o większej liczbie cylindrów, większym przyspieszeniu, większej mocy silnika, większej wadze, mniejszym przyspieszeniu. Korelacje są również wyraźnie widoczne.

## 4. Dyskusja

Podobne wyniki dla tej samej bazy uzyskano w opracowaniu [2], gdzie również uzyskano dobrze zdefiniowane klastry dla tej samej bazy danych. Również zaobserwowano na podstawie SOM, że pojazdy z większą liczbą cylindrów grupowały się w obszarach mniejszego zużycia paliwa, wyższej objętości skokowej i mocy silnika, większej wadze pojazdu, szybszym przyspieszeniu i w mniejszym stopniu z wcześniejszych lat.

Natomiast samochody z mniejszą liczbą cylindrów grupowały się przeciwnie do tych z większą liczbą cylindrów dla wszystkich wirtualnych atrybutów [2].

Wyniki podano jednak w sposób opisowy, ale tak naprawdę nie przedstawiono końcowych wizualizacji, co sprawia, że wnioski mogą być dyskusyjne.

Również można w dalszym etapie zastosować klasyfikację m.in. za pomocą sztucznej sieci neuronowej z nauczycielem, co opisano w [1], ale w tym opracowaniu nie przedstawiono wyników wstępnej analizy za pomocą SOM. W tym opracowaniu przeprowadzono normalizację siedmiu atrybutów i alternatywne mapowanie atrybutu pochodzenie, a następnie całego wektora. Opracowano klasyfikator wykorzystujący siedem parametrów (bez MPG), a zadaniem sieci było przewidywanie zakresu MPG. Dostępny atrybut MPG był wykorzystany w procesie uczenia jako parametr wyjściowy. Rejon pochodzenia był zastosowany bezpośrednio, ale normalizowano cały wektor po każdym parametrze. Zastosowano sieć z trzema wyjściami dającą klasyfikacje typu: mpg-low, mpg-average, mpg-high, dla zdefiniowanych zakresów MPG.

W pracy [12], podobnie jak [1], wynik dotyczący zużycia paliwa (*ang. mpg*) traktowano jako wyjściowy lub analogicznie dotyczący mocy silnika (*ang. horsepower*) jako wyjściowy, ale zastosowano zwykłą sieć jednokierunkową a nie SOM [1].

Z przedstawionych wyników oraz opracowań innych autorów wynika, że samoorganizujące się mapy mogą być zastosowane do oceny jakościowej danych, polegającej na klastrowaniu (grupowaniu) podobnych przypadków. Może być zatem pomocna do dalszej analizy za pomocą metod ilościowych, ale bardziej ukierunkowanej.

## 5. Wnioski

- Najważniejszym aspektem niniejszego opracowania był wybór rozwiązania dla normalizacji, który wpływał w sposób znaczny na wyniki oceny. Pominięcie atrybutu wprowadzałoby silne uśrednienie, a odczytanie wyników dla obszaru pochodzenia - Europy (wartość 0,5) w przypadku 3.1 i 3.2 jest kłopotliwe.
- Wprowadzenie rozszerzenia wektora umożliwia odniesienie do obszaru pochodzenia. Mapy są wtedy znacznie bogatsze w szczegóły. Podsumowując, lepsze rezultaty daje odrzucenie lub rozszerzenie niż pozostawienie oryginalnego podejścia. Normalizacja całego wektora nie wprowadza silnych zmian ponieważ przeprowadzana została z uwzględnieniem wszystkich atrybutów. W związku z tym, że siedem atrybutów jest takich samych, a zmianie podlega ósmy lub też rozszerzany wektor i tak w większości dotyczy tych siedmiu, zatem zmiana nie jest znacząca.
- Mapy samoorganizujące się są jednym ze sposobów wizualizacji danych oraz wstępnej oceny jakościowej, która może poprzedzać właściwą ocenę ilościową za pomocą innych metod.

## Literatura

- [1] Aliyu A., Adeshina S.: *Classifying Auto-MPG Data set using Neural Network*. 978-1-4799-4106-3 © 2014 IEEE.
- [2] Cao M.: *Applying Self-Organizing Map to Explore MPG Using the MPG dataset with SOM*. MATH 3210 - Data Mining Foundations Professor Aleshunas, 12/14/2009.
- [3] Chanc K.: *Zastosowanie techniczno - ekonomiczne sztucznych sieci neuronowych*. Praca dyplomowa inżynierska, Wyższa Szkoła Techniczno-Ekonomiczna w Szczecinie, Szczecin 2015, s 29-31.

- [4] Kohonen T.: *Self-Organized Formation of Topologically Correct Feature Maps*. Biological Cybernetics, 1982, 43 (1), pp. 59-69.
- [5] Kohonen T., Honkela T.: *Kohonen network*, Scholarpedia, 2011. Retrieved 2012-09-24.
- [6] Kolasa M., Długosz J., Figas A.: *Wpływ funkcji sąsiedztwa na efektywność uczenia sieci neuronowych Kohonena implementowanych sprzętowo*. Elektryka, Zeszyt 1, 2011.
- [7] Korbicz J., Obuchowicz A., Uciński D.: *Sztuczne sieci neuronowe Podstawy i zastosowania*. Warszawa: Akad. Oficyna Wydawnicza, 1994, s 76-81.
- [8] Lichman, M.: *UCI Machine Learning Repository* [<http://archive.ics.uci.edu/ml>]. Irvine, CA: University of California, School of Information and Computer Science, 2013.
- [9] Masters, T.: *Sieci neuronowe w praktyce: programowanie w języku C<sup>++</sup>*. Warszawa: Wyd. Naukowo-Techniczne, 1996.
- [10] Osowski S.: *Sieci neuronowe do przetwarzania informacji*. Warszawa: Oficyna Wyd. Politechniki Warszawskiej, 2006.
- [11] Tadeusiewicz R.: *Sieci neuronowe*. Warszawa: Akad. Oficyna Wydawnicza, 1993, s. 12, 40-42.
- [12] Williams Ch.: *Nonlinear Regression with Neural Networks* 2009.
- [13] <http://tex.stackexchange.com/questions/144366/draw-a-kohonen-som-feature-map> (dostęp: 20.09.2015).
- [14] <http://www.ra.cs.uni-tuebingen.de/SNNS>, (dostęp 15.08.2015).