

Wybrane aspekty zastosowania sztucznej sieci neuronowej w systemie sterowania oświetleniem ulicznym

Streszczenie. Dynamiczne dostosowywanieysterowania systemu oświetlenia ulicznego do aktualnych warunków atmosferycznych wymaga odczytu wielu danych, najczęściej meteorologicznych, takich jak np.: zachmurzenie, opady, zamglenie, wilgotność, temperatura itd. Rozwiązanie to jest kosztowne biorąc pod uwagę liczbę koniecznych do użycia czujników. Autorzy zaproponowali rozwiązanie prognozujące stopieńysterowania systemu oświetlenia ulicznego z wykorzystaniem sztucznej sieci neuronowej oraz prognoz pogody dostępnych w serwisach meteorologicznych.

Abstract. Dynamically adjusting of the street lighting control system to the current weather conditions requires to read multiple meteorological data such as cloudy, rain, fog, humidity, temperature, etc. This solution is expensive taking into account the required number of the used sensors. The authors have proposed the solution that predicts the level of street lighting system intensity with using artificial neural network and weather forecasts available at the meteorological services. (Analysis of the possibility of applying artificial neural network in the system of street lighting control).

Słowa kluczowe: sztuczna sieć neuronowa, sterowanie oświetleniem ulicznym, dane meteorologiczne.

Keywords: artificial neural network, street lighting control, meteorological data.

Wstęp

Projektowanie i realizacja systemów oświetlenia ulicznego jest zagadnieniem coraz częściej poruszonym w szczególności w zakresie zwiększania bezpieczeństwa na drodze, a także w związku z coraz częściej wykonywanymi modernizacjami oświetlenia ulicznego głównie na oświetlenie tyłu LED. Zaletą oświetlenia typu LED jest znacznie mniejsze zużycie energii elektrycznej w porównaniu z oprawami z zainstalowanymi źródłami wyladowniczymi oraz możliwość sterowania strumieniem świetlnym tych źródeł. Wymienione wyżej własności wpływają na dynamiczny rozwój systemów sterowania oświetleniem ulicznym takich jak np. rozwiązania firmy ALLANDO, OWLET, RABBIT, APANET, MICROMEX czy PHILIPS. Wśród w/w systemów wyróżnić można także systemy tzw. inteligentne, które pozwalają na dynamiczne dostosowywanie strumienia świetlnego poszczególnych lub zestawu opraw oświetlenia drogowego do warunków meteorologicznych czy warunków panujących na drodze. Istnieją także systemy, w których systemy sterowania bazują na rozwiązaniach sztucznej inteligencji np. [1-4].

Norma dotycząca oświetlenia dróg [5-8] opisuje wiele aspektów technicznych, w tym dotyczących klas dróg i wymagań co do ich oświetlenia, obliczenia parametrów oświetleniowych oraz metod pomiarów parametrów oświetlenia. Głównym parametrem fotometrycznym, który brany jest pod uwagę podczas projektowania oświetlenia ulicznego, jest luminancja jezdni. Dla niektórych typów dróg stosuje się także inny parametr – natężenie oświetlenia.

Jak wspomniano wcześniej, głównym zadaniem inteligentnych systemów sterowania oświetleniem ulicznym jest dynamiczne sterowanie strumieniem świetlnym opraw w celu uzyskania odpowiednich parametrów fotometrycznych drogi podczas zmieniających się na niej warunków atmosferycznych, bądź natężenia ruchu pojazdów czy pieszych. Zwykle do tego celu wykorzystuje się zestawy różnego typu czujników instalowanych w otoczeniu drogi czy dróg np. czujniki natężenia ruchu pojazdów, natężenia oświetlenia, luminancji, opadów czy zamglenia. To rozwiązanie jest kosztowne ze względu na ilość i znaczną cenę tychże czujników. Pośrednim rozwiązaniem może być zastosowanie metod sztucznej inteligencji np. sztucznych sieci neuronowych (SSN) wykorzystujących dane prognozowane i pomiarowe do wspomagania systemów sterowania oświetleniem ulicznym. Takie rozwiązania są już rozpatrywane i testowane np. w pracach [1, 2].

W artykule przedstawiono propozycję wykorzystania SSN, która prognozuje stopieńysterowania ulicznych opraw oświetleniowych w zależności od warunków meteorologicznych panujących na danym obszarze oraz zaprezentowano wyniki badań laboratoryjnych takiego systemu. Stopieńysterowania oprawy jest wielkością wyrażaną w procentach, określającą pożądaną wartość mocy oprawy w odniesieniu do jej mocy nominalnej.

Koncepcja systemu sterowania oświetleniem opartego o prognozy meteorologiczne

Jak wspomniano powyżej zastosowanie sztucznych sieci neuronowych do wspomagania sterowania oświetleniem ulicznym jest znane i opisywane w wielu publikacjach np. [1, 2]. Jednakże, zastosowanie koncepcji opartej na wykorzystaniu prognoz meteorologicznych nie zostało dostatecznie zbadane i zweryfikowane.

Jednym z podstawowych problemów pojawiających się przy realizacji zaproponowanego rozwiązania jest pobieranie prognoz i bieżących danych meteorologicznych. Sposobów na pozyskanie danych meteorologicznych jest kilka, a pod rozważę można wziąć dwa. Pierwsza możliwość to skorzystanie z komercyjnych serwisów meteorologicznych takich jak np. imgw.pl. Zaletą takiego rozwiązania jest to, że dane można pobierać zwykle w dowolnej ilości i częstotliwości. Innym sposobem jest wykorzystanie darmowych serwisów meteorologicznych. W tym przypadku, zwykle zasady odczytu informacji są ograniczone, to znaczy: odczyt może zostać zrealizowany tylko raz na godzinę lub można pobrać określoną liczbę danych. Ponadto, prognozy tworzone są dla pewnego obszaru geograficznego, dlatego dobrym rozwiązaniem jest weryfikacja danych prognostycznych przez rzeczywiste urządzenia pomiarowe. Rzeczywiste dane meteorologiczne można uzyskać z istniejących stacji meteorologicznych funkcjonujących na wybranym obszarze geograficznym.

Przykładem inteligentnego systemu sterowania oświetleniem ulicznym, w którym można zrealizować koncepcję wspomagania podejmowania decyzji przy zastosowaniu SSN i danych meteorologicznych jest system powstały w ramach badawczo-wdrożeniowego projektu NCBiR GEKON o nazwie „Projekt Inteligentnego Systemu Sterowania Oświetleniem Ulicznym (ISSOU)”, w którym brali udział autorzy niniejszej publikacji. System ten doposażony jest w dodatkowy Moduł Inteligentnego Wspomagania Sterowania Oświetleniem Ulicznym (MIWSOU), który na podstawie prognoz meteorologicznych,

oraz bieżących danych pomiarowych – jeśli takie są, prognozuje stopień występowania awarii oświetleniowych. Celem ustalenia stopnia występowania ma być zapewnienie odpowiedniej, wg normy [5-8], luminancji jezdni oraz natężenia oświetlenia. Wstępne badania autorów przedstawione w [9] ujawniły, że dane takie jak: data (miesiąc, dzień), czas (godzina, minuta), temperatura otoczenia (stopnie Celsjusza), opady (mm), wilgotność (%), prędkość wiatru (m/s) i kierunek wiatru (kąt w °) nie są wystarczające by umożliwić realizację dokładnych prognoz harmonogramów występowania awarii oświetleniowych przez SSN.

Uzupełnieniem propozycji systemu opisanego w [9] jest podanie na wejście SSN dodatkowych informacji np. o klasie drogi, typie jej nawierzchni, miejscu usytuowania awarii (np. oświetlenie drogi, chodnika, parkingu, ścieżki rowerowej), typie zastosowanego oświetlenia a także informacji o zamgleniu, zachmurzeniu czy fazie księżyca, która w powiązaniu z brakiem zachmurzenia wpływa na wartość luminancji drogi.

W niniejszej pracy, ze względu na wstępny charakter badań, autorzy przedstawiają wyniki badań związane z praktyczną implementacją SSN i realizowaniem przez ISSOU harmonogramów występowania awarii oświetlenia ulicznego tworzonych przez SSN. SSN prognozuje stopień występowania awarii na podstawie 9 danych wejściowych (miesiąc, dzień, godzina, minuta, temperatura otoczenia, opady, wilgotność, prędkość wiatru i kierunek wiatru). Ponadto w artykule zaprezentowano wybrane wyniki badań laboratoryjnych, które przeprowadzono z wykorzystaniem trzech awarii oświetleniowych sterowanych z wykorzystaniem MIWSOU opracowanego przez autorów.

Sztuczna sieć neuronowa w sterowaniu oświetleniem ulicznym

SSN są sposobem modelowania oraz analizy procesów i zjawisk, które poprzez nieliniowość lub niestacjonarność są trudne do badań za pomocą klasycznych systemów klasyfikacji oraz sterowania. Działanie SSN opiera się na działaniu biologicznego systemu nerwowego człowieka. Stanowią one bardzo uproszczony model takiego systemu. Dzięki możliwości zdobywania wiedzy w wyniku procesu uczenia się są one w stanie rozwiązywać liczne problemy z wielu różnych dziedzin nauki [1, 2, 10, 11]. SSN posiadają zdolność do generalizacji zdobytej wiedzy oraz równoległego przetwarzania informacji, co jest ich znaczącą zaletą w porównaniu do klasycznych metod modelowania. Sztuczne sieci neuronowe znalazły także swoje zastosowanie w procesie sterowania oświetleniem ulicznym [1, 2]. Istnieje wiele typów SSN oraz metod ich implementacji [12]. Jednym z kryteriów klasyfikacji takich sieci jest sposób ich uczenia. Rozróżniamy metody uczenia nadzorowanego oraz bez nadzoru. W prezentowanej pracy do wspomaganie procesu oświetlenia ulicznego z użyciem SSN wybrano algorytm nadzorowanego uczenia wielowarstwowych sieci neuronowych metodą wstecznej propagacji błędów ze współczynnikiem momentum, jako iż jest to jeden z najpowszechniej wykorzystywanych algorytmów w zadaniach związanych ze sterowaniem [1, 2].

Programowy model wielowarstwowej, jednokierunkowej sieci neuronowej zrealizowany został w języku C++. W sieci tej przepływ informacji pomiędzy warstwami odbywa się tylko w jedną stronę - od warstwy wejściowej przez kolejne warstwy neuronów (warstwy ukryte) aż do warstwy wyjściowej. Wartości wyjściowe z kolejnej warstwy neuronów wprowadzane są jako wejścia dla następnej warstwy. Wynik obliczeń warstwy wyjściowej sieci traktowany jest jako odpowiedź całej sieci neuronowej. Algorytm wstecznej propagacji błędów określa sposób

doboru wag w sieci wielowarstwowej korzystając z gradientowych metod optymalizacji. Celem procesu uczenia jest minimalizacja funkcji błędów przy wykorzystaniu metody największego spadku. Aktualizacja wag odbywa się w kierunku ujemnego gradientu funkcji celu. Każdy neuron po otrzymaniu sygnałów wejściowych wyznacza swój sygnał wyjściowy, y , w oparciu o posiadaną wiedzę, która zapisana jest w jego współczynnikach wagowych. Sygnał wyjściowy neuronu jest sumą wartości sygnałów wejściowych pomnożonych przez odpowiednie współczynniki wagowe, który zostaje poddany przekształceniu wynikającemu z obecności odpowiedniej funkcji aktywacji. Wartość sygnału wyjściowego neuronu znajdującego się w warstwie wyjściowej porównywana jest z wartością wzorcową podaną przez nauczyciela. Następnie neuron wyznacza różnicę pomiędzy otrzymanym przez niego sygnałem wyjściowym, a oczekiwaną wartością tego sygnału, którą podaje nauczyciel. Nazwa tego algorytmu wynika z kolejności obliczania sygnałów błędów w poszczególnych warstwach sieci, która przebiega w kierunku odwrotnym niż przechodzenie sygnału przez sieć. W pierwszej kolejności, na podstawie sygnałów wyjściowych oraz wzorcowych, obliczane są błędy w warstwie wyjściowej. Błąd dla neuronów w dowolnej warstwie wcześniejszej (w warstwach ukrytych) obliczany jest jako pewna funkcja błędów neuronów warstwy następnej. Sygnał błędów jest propagowany wstecz od warstwy ostatniej, aż do warstwy wejściowej.

W kolejnym kroku następuje korekcja wartości współczynników wag, W , poszczególnych neuronów. Przykładowo dla sigmoidalnej funkcji aktywacji korekcja wag neuronu warstwy wyjściowej przebiega zgodnie z zależnością (1).

$$(1) \quad W_i(l+1) = W_i(l) + \eta \cdot (d_i - y_i) \cdot y_i \cdot (1 - y_i) \cdot Y^H + \beta \cdot (W_i(l) - W_i(l-1))$$

gdzie: W_i jest wektorem wag i -tego neuronu, η jest współczynnikiem uczenia, natomiast β współczynnikiem momentum, Y^H jest wektorem wyjściowym z warstwy ukrytej sieci neuronowej, y_i to uzyskana, a d_i oczekiwana odpowiedź sieci na wzorec uczący X .

Funkcja celu zdefiniowana jest zależnością (2).

$$(2) \quad Q_{err} = \sqrt{\frac{1}{L_{WU}} \sum_{j=1}^{L_{WU}} \sum_{i=1}^{L_O} (y_{i,j} - d_{i,j})^2}$$

gdzie: L_{WU} jest liczbą wzorców uczących, L_H jest liczbą neuronów w warstwie ukrytej, natomiast L_O jest liczbą neuronów w warstwie wyjściowej SSN. Pozostałe zmienne definiowane są w sposób następujący:

X - wektor uczący: $X = [x_1, \dots, x_M]$,

Y^H - wektor wyjściowy z warstwy ukrytej: $Y^H = [y_1^H, \dots, y_{L_H}^H]$, będący jednocześnie wektorem wejściowym warstwy wyjściowej,

Y - odpowiedź warstwy wyjściowej sieci: $Y = [y_1, \dots, y_{L_O}]$,

D - wektor oczekiwanej odpowiedzi sieci: $D = [d_1, \dots, d_{L_O}]$,

W - wektor wag danego i -tego neuronu $W = [w_{i,1}, \dots, w_{i,R}]$.

Głównym zadaniem SSN jest tworzenie dobrych profili występowania lamp ulicznych znajdujących się w określonym ciągu liniowym w zależności od prognozowanych oraz bieżących warunków meteorologicznych. Zbiór uczący SSN, na potrzeby realizacji niniejszej pracy, utworzony został w oparciu o dane archiwalne za rok 2014 uzyskane ze stacji pogodowej umieszczonej przed budynkiem kampusu uniwersyteckiego UTP w Bydgoszczy w Fordonie. Składał się on z 8756 wektorów uczących, z których każdy zawierał 9 danych

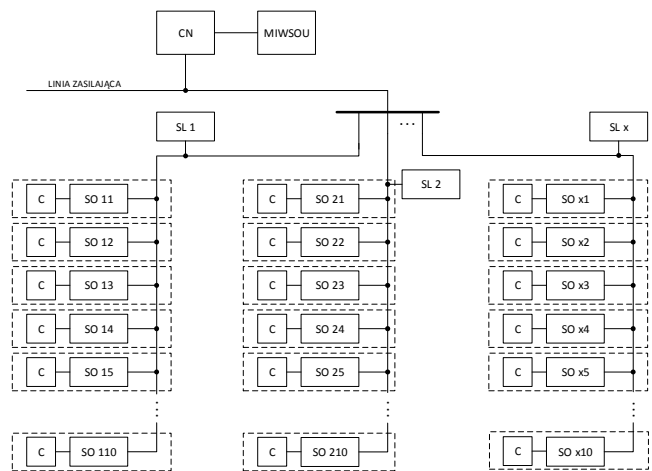
związanych z wejściami sieci: dzień, miesiąc, godzina, minuta, temperatura otoczenia, opady, wilgotność, prędkość wiatru, kierunek wiatru oraz jedną daną związaną z wyjściem sieci: natężenie oświetlenia, którego wartość decydowała o poziomie wysterowania opraw. Zależność pomiędzy poziomem wysterowania a natężeniem oświetlenia została wyznaczona eksperymentalnie dla poszczególnych opraw. Zbiór uczący podzielony został na trzy podzbiory: uczący, walidacyjny oraz testowy w następujących proporcjach: 75%, 10% oraz 15%.

Opracowany i zaimplementowany przez autorów MIWSOU składa się z trzech współpracujących ze sobą bloków:


- bloku odpowiadającego za pobór danych meteorologicznych z centrum nadzoru systemu ISSOU (CN),
- bloku złożonego z SSN, która na swoim wyjściu prognozuje wartość natężenia oświetlenia dla danych warunków meteorologicznych współpracującej z generatorem dobowych harmonogramów wysterowania opraw,
- bloku odpowiadającego za przesłanie wygenerowanych harmonogramów (w formacie XML) do CN.

Wygenerowane harmonogramy wysyłane są z CN do odpowiednich sterowników liniowych (SL) – sterujących całym ciągiem liniowym oświetlenia, a następnie


sterowników obiektowych (SO), które umiejscowione są już bezpośrednio w poszczególnych oprawach (rysunek 1).



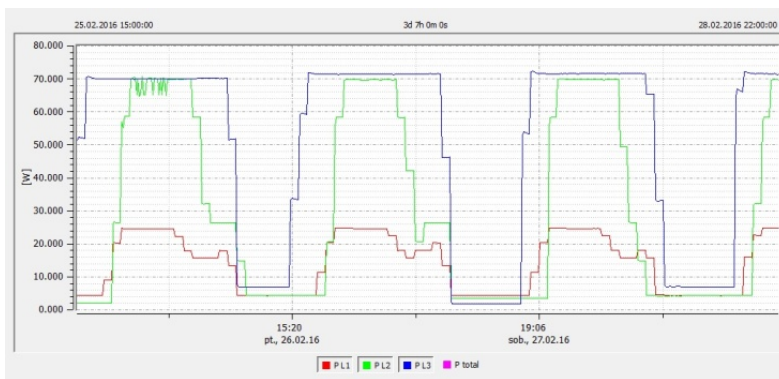
Rys.1. Schemat blokowy ISSOU [9]



Rys. 2. Przykładowy przebieg czasowy harmonogramu wraz z jego realizacją przez sterowaną nim oprawę



Rys. 3. Zmiany w prognozach stopnia wysterowania opraw oświetleniowych wynikające ze zmieniających się warunków atmosferycznych



Rys. 4. Moc pobierana przez oprawy dla trzech wariantów wag SSN oraz trzech różnych opraw

Badania eksperymentalne

Badania eksperymentalne składały się z dwóch części. W części pierwszej, utworzona i nauczona została SSN, której zadaniem było tworzenie 24 godzinnych harmonogramów wysterowania opraw oświetleniowych z godzinnym interwałem czasowym. W części drugiej badań, do linii zasilających podłączone zostały oprawy oświetleniowe, których strumień świetlny zmieniany był zgodnie z opracowanym harmonogramem wysterowania utworzonym przez SSN. Harmonogram przesyłany był do SO oprawy z CN za pomocą standardu PLC (ang. *Power Line Communications*). Do realizacji badań wykorzystano system zaprojektowany i zbudowany w ramach projektu ISSOU, którego uproszczony schemat blokowy przedstawia rys. 1.

Ilość warstw sieci neuronowej oraz liczba neuronów w poszczególnych warstwach została dobrana eksperymentalnie. Zmieniając liczbę epok uczących, liczbę warstw SSN, liczbę neuronów w poszczególnych warstwach, wartość współczynnika uczenia oraz współczynnika momentum szukano przypadku, który da najmniejszą wartość funkcji celu, nie tracąc przy tym zdolności do generalizacji zdobytej wiedzy. Proces uczenia zatrzymywany był w punkcie, w którym wartość błędu dla zbioru walidacyjnego miała najmniejszą wartość. Ostatecznie do badań wybrano architekturę sieci z jedną warstwą ukrytą złożoną z 16-tu neuronów, natomiast wartość współczynnika uczenia oraz współczynnika momentum wynosiła odpowiednio 0.1 oraz 0.8. Początkowe wartości wag przyjmowały za każdym razem wartości losowe bliskie zeru.

Do tworzenia 24-godzinnych prognoz SSN pobiera prognostyczne dane meteorologiczne z interwałami godzinnymi z różnych serwisów meteorologicznych np. openweathermap.org czy forecast.io, które są umieszczone w CN na serwerze projektu ISSOU. Następnie, dane z serwera pobierane są w formacie XML i sukcesywnie wprowadzane są na wejścia SSN. W wyniku przetworzenia informacji przez SSN, otrzymywane są wyniki 24-godzinnej prognozy (z interwałem godzinnym) poziomu wysterowania opraw. Dobowy harmonogram wysterowania generowany jest sekwencyjnie przez SSN dla każdej godziny z osobna (interwał godzinny) i zapisywany jest do pliku w formacie XML. Następnie, tak utworzona prognoza wysyłana jest na serwer ISSOU do CN. Przykładowy przebieg czasowy harmonogramu wysterowania opraw wraz z przebiegiem jego realizacji przez oprawę przedstawia rysunek 2. Warto zaznaczyć, że utworzony harmonogram jest na bieżąco korygowany (co godzinę) na podstawie odczytanych danych meteorologicznych z serwera, które ulegają modyfikacji zależnie od występujących zmian w pogodzie. Rysunek 3 przedstawia korekty w prognozach wysterowania opraw ulicznych, które wynikają z różnic pomiędzy aktualnie panującymi warunkami meteorologicznymi w stosunku do wcześniejszej ich prognozy.

Do realizacji drugiej części badań, zbudowano układ testowy, w którym do linii zasilających podłączono trzy oprawy oświetleniowe. Do fazy L1 podłączono oprawę PHILIPS BGS451 LXML/WW, do fazy L2 oprawę ELGO ACRON 100L1 oraz do fazy L3 oprawę ELGO ADQUEN OU-105GR4. Użyte do badań oprawy zostały zmodyfikowane. Usunięto z nich oryginalną część układu zasilającego źródło LED i zastąpiono je nowym układem zbudowanym w ramach projektu NCBiR „GEKON”, który jest elementem ISSOU i umożliwia komunikację poszczególnych opraw, zawartych w nich SO z CN poprzez SL. Moce znamionowe poszczególnych opraw wynosiły odpowiednio: 25W, 70W, 105W (ograniczona programowo do 70W). W celu przeprowadzenia badań

eksperymentalnych w CN uruchomiono trzy niezależnie działające SSN tworzące prognozy 24-godzinne dla trzech różnych zestawów wag poszczególnych neuronów, które uzyskano po przeprowadzonym procesie uczenia. Poszczególne SSN sterują niezależnymi oprawami.

Na rysunku 4 przedstawiono przebieg czasowy mocy pobieranej przez każdą z trzech opraw sterowanych harmonogramami tworzonymi przez SSN. Pomiary zostały przeprowadzone analizatorem sieci PQ-Box 100 firmy A-eberle.

Podsumowanie

Badania eksperymentalne, które przedstawiono w niniejszej pracy dowodzą, że można przygotować harmonogramy wysterowania opraw oświetlenia ulicznego na podstawie prognoz meteorologicznych oraz SSN. Dokładność tych harmonogramów zależy od właściwego przygotowania danych uczących SSN. Stąd też konieczne jest uwzględnienie większej liczby parametrów wejściowych takich jak np. zamglenie, typ oświetlenia, czy rozmieszczenie opraw. Ponadto, należy opracować model SSN prognozujący luminancję drogi, uwzględniający jej dynamiczne zmiany w przypadku zmiany warunków atmosferycznych występujących na obszarze, gdzie zlokalizowany jest ciąg opraw oświetleniowych. Takie podejście pozwoli urealnić stosowanie SSN w systemach wspomagających sterowanie oświetleniem ulicznym.

Autorzy: dr inż. Marta Kolasa, dr inż. Marcin Drechny, Uniwersytet Technologiczno-Przyrodniczy w Bydgoszczy, Instytut Inżynierii Elektrycznej, al. Prof. S. Kaliskiego 7, 85-796 Bydgoszcz, e-mail: marta.kolasa@utp.edu.pl, marcin.drechny@utp.edu.pl.

LITERATURA

- [1] Lavric A., Popa V., A Traffic Prediction Algorithm for Street Lighting Control Efficiency, *Journal of Applied Computer Science & Mathematics*, 15 (2013), 13-17
- [2] Pizzuti F., Moretti F., Annunziato M., Panzieri S., Advanced Street Lighting Control through Neural Network Ensembling, *The Second International Conference on Smart Systems, Devices and Technologies*, (2013), 76-81
- [3] Ramadhani F., Bakar K.A., Shafer M.G., Optimization of Standalone Street Light System with Consideration of Lighting Control, *International Conference on Technological Advances in Electrical, Electronics and Computer Engineering*, (2013), Konya, 583-588
- [4] Saravanan K., Fuzzy Controller Design of Lighting Control System By Using VI Package, *International Journal of Artificial Intelligence*, 1 (2012), nr 2, 73-78
- [5] PKN-CEN/TR 13201-1:2016-02, Oświetlenie dróg – Część 1: Wytyczne dotyczące wyboru klas oświetlenia, (2016), PKN, Warszawa
- [6] PN-EN 13201-2:2007, Oświetlenie dróg - Część 2: Wymagania oświetleniowe, (2007), PKN, Warszawa
- [7] PN-EN 13201-3:2007, Oświetlenie dróg - Część 3: Obliczenia parametrów oświetleniowych, (2007), PKN, Warszawa
- [8] PN-EN 13201-4:2007, Oświetlenie dróg - Część 4: Metody pomiarów parametrów oświetlenia, (2007), PKN, Warszawa 2
- [9] Drechny M., Kolasa M., Sztuczna Sieć Neuronowa wspomagająca sterowanie Oświetleniem Ulicznym, *Rynek Energii*, 2 (2016), nr 123, 173-178
- [10] Gała M., Zastosowanie sztucznych sieci neuronowych do oceny wpływu pracy odbiorników nieliniowych na jakość energii elektrycznej, *Przegląd Elektrotechniczny*, 6 (2011), 42-46
- [11] Hou C.I., Traffic Flow Forecasting in Leisure Farm Areas Using Artificial Neural Networks, *Przegląd Elektrotechniczny*, nr. 89 (2013), nr 1b/2013, 205-207
- [12] Kolasa M., Długosz R., Pedrycz W., Szulc M., Programmable Triangular Neighborhood Function for Kohonen Self-Organizing Map Implemented on Chip, *Neural Networks*, Elsevier, 25 (2012), 146-160