

Identyfikacja profilu osobowego na podstawie analizy neuronowej parametrów środowiskowych w inteligentnym budynku

Streszczenie. Dla potrzeb takiej identyfikacji osób przebywających w pomieszczeniach budynku, opracowany został algorytm profilowania i identyfikacji osobowej z zastosowaniem sztucznych sieci neuronowych – neuronową identyfikacją organicznego profilu osobowego (NIOPO – ang. Neural identification of an organic personal profile NIOPP). Identyfikacja neuronowa, wykorzystuje pomiary koncentracji gazów, których proporcje oraz skład są cechą indywidualną dla każdego człowieka.

Abstract. For the purpose of such identification of people staying in the building's premises, a profiling and personal identification algorithm was developed with the use of artificial neural networks - neural identification of the organic personal profile (NIOPP). Neural identification, uses measurements of gas concentrations whose proportions and composition are an individual feature for every human being. (Identification of a personal profile based on neural analysis of environmental parameters in a smart building).

Słowa kluczowe: sztuczne sieci neuronowe, szeregi czasowe, pomiary parametrów środowiskowych, inteligentne budynki.
Keywords: artificial neural networks, time series, measurements of environmental parameters, intelligent buildings.

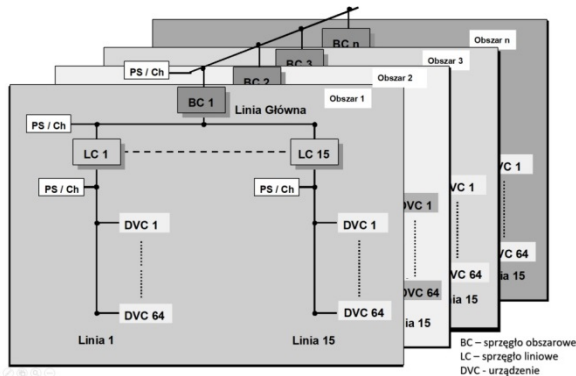
Wstęp

W inteligentnym budynku archiwizowanych jest bardzo wiele parametrów. Np. są to pomiary temperatury, wilgotności, jasności prędkości wiatru, energii, stężenia różnych gazów itp. Na część z tych parametrów możliwy jest wpływ za pomocą istniejącej infrastruktury budynku, np. zmieniając temperaturę i wilgotność pomieszczeń, jednak inne można tylko mierzyć i analizować. Parametry te są niezależne od oddziaływania urządzeń technicznych i nosią wiele ciekawych informacji o budynku i przebywających w nim ludziach.

Odpowiednie wyodrębnienie i analiza informacji pomiarowych [1], pochodzących z czujników stosowanych w automatyce budynkowej umożliwia opracowanie wzorców osobowych, a na tej podstawie, identyfikację osób przebywających w pomieszczeniach. Ponieważ w rzeczywistych obiektach, dane pomiarowe pochodzą od wielu użytkowników pomieszczeń, którzy przebywają w nich sporadycznie lub też stale, mechanizm analizy informacji pomiarowych musi posiadać możliwości autoadaptacyjne. Takimi cechami charakteryzują się algorytmy wykorzystujące sztuczne sieci neuronowe. Poddanie wyników pomiarów analizie neuronowej, pozwala na bieżącą adaptację całego systemu do aktualnych warunków, jakie mają miejsce w budynku [2].

Charakterystyka aparatury pomiarowej

Układ pomiarowy zbudowany został w oparciu o rozproszony automatyki budynkowej – KNX.

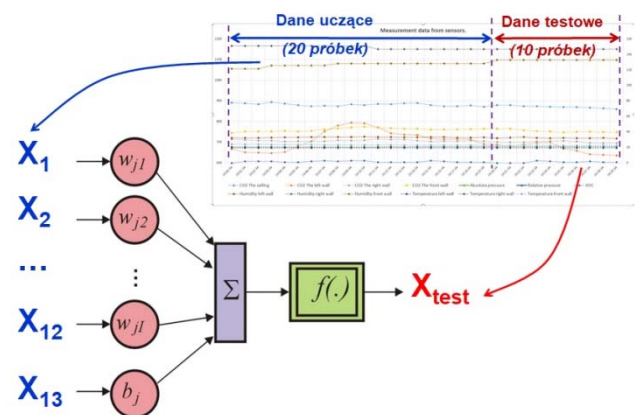


Rys.1. Topologia systemu KNX

System ten, umożliwia integrację ze sobą ponad pięćdziesięciu sześciu tysięcy urządzeń sensorycznych i wykonawczych, realizujących zadania automatyki budynkowej. Topologia systemu z linii połączonych w obszary (rys. 1).

Dzięki takiej architekturze, możliwe jest połączenie okablowaniem komunikacyjnym urządzeń, nawet w bardzo rozległych budynkach. Urządzenia wchodzące w skład systemu automatyki, mogą pochodzić od ponad 450 producentów z całego świata i są ze sobą kompatybilne na poziomie komunikacji. Gwarantuje to weryfikacja urządzeń przez nadrzędną instytucję o nazwie KNX Association.

Dla potrzeb eksperymentu, system został uproszczony do jednej linii, w której znajdowały się urządzenia pomiarowe oraz element archiwizacji danych, które po odpowiednim przetworzeniu, poddane zostały analizie neuronowej. Idea układu analizy, przedstawiona została na rysunku 2.



Rys.2. Idea budowy neuronowej identyfikacji profilu osobowego

Dla potrzeb pomiaru zastosowano następujące parametry środowiskowe:

- lotne związki organiczne (VOC),
- stężenie dwutlenku węgla,
- ciśnienie atmosferyczne,
- wilgotność względna
- temperatura.

Dla potrzeb pomiaru zastosowano następujące urządzenia:

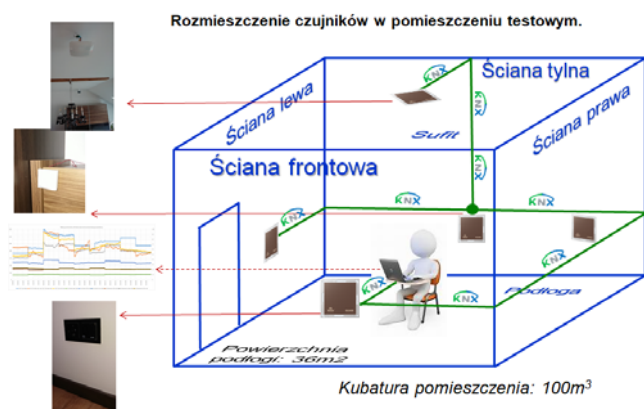
- Czujnik jakości powietrza „Amun” firmy Theben,
- Czujnik obecności „True Presence” firmy Steinel Professional,
- Czujnik jakości powietrza 2178 firmy Jung,
- Sterownik PLC z modułem archiwizacji danych firmy WAGO,

Jako narzędzie analizy neuronowej wykorzystana została aplikacja napisana w pakiecie Matlab firmy MathWorks.

Wszystkie urządzenia pomiarowe oraz archiwizacja [3] danych, komunikowały się pomiędzy sobą za pomocą protokołu KNX.

Środowisko pomiarowe i przebieg eksperymentu

Eksperymenty neuronowej identyfikacji osób, wykonane zostały w pomieszczeniu testowym o powierzchni 36 [m²] i kubaturze 100 [m³]. Pomieszczenie, pokój testowy wraz z czujnikami, zobrazowane zostało na rysunku 3.



Rys.3. Praktyczne rozmieszczenie elementów pomiarowych wewnętrznych parametrów środowiskowych budynku dla potrzeb eksperymentu

Na ścianach oraz suficie rozmieszczone zostały czujniki pomiarowe [4], [10], połączone magistralą komunikacyjną z serwerem archiwizacji danych. Dane pomiarowe, odzwierciedlające dziewięć sytuacji, przedstawionych na rysunku nr 4.

Pomiary wykonane zostały za pomocą multi-czujników pracujących w systemie KNX, a analizie poddane zostały następujące parametry:

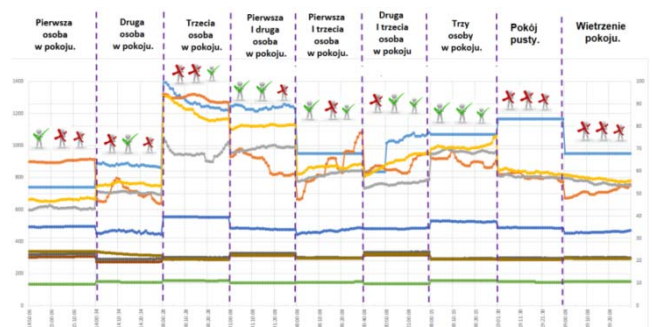
- 4 pomiary stężenia CO² (na suficie, na lewej, prawej oraz frontowej ścianie),
- 2 pomiary ciśnienia atmosferycznego (względne oraz bezwzględne),
- 3 pomiary wilgotności (na lewej, prawej oraz frontowej ścianie),
- 3 pomiary temperatury (na lewej, prawej oraz frontowej ścianie),
- 1 pomiar stężenia lotnych związków organicznych (pod sufitem).

W eksperymencie uczestniczyły trzy osoby. Każda z nich, osobno i w połączeniu z pozostałymi osobami, przebywała w pokoju testowym. Ponadto pobrano dane pomiarowe z pustego oraz wietrzonego pokoju [10].

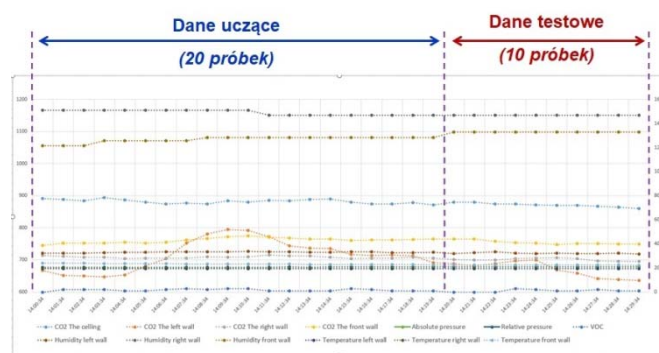
Z każdej sytuacji pobrano dane pomiarowe trwające 30 minut z interwałem pomiarowym 1 minuty. W ten sposób, dla każdej sytuacji uzyskano wektor składający się z 13 pomiarowych szeregów czasowych. Dla potrzeb analizy neuronowej, wektor ten podzielony został na dwie części: dane uczące (20 próbek) oraz dane testowe (10 próbek) [9]. Zestaw wektora pomiarowego przedstawiony został na rysunku nr 5.

W trakcie analizy neuronowej, sztucznej sieci

neuronowej typu feed-forward z propagacją wsteczną, prezentowano kolejno dane testowe w powiązaniu z daną sytuacją obecności poszczególnych zestawów osobowych. Po czym sieć identyfikowała daną sytuację przy prezentacji na jej wejściach danych testowych (idea zaprezentowana została na rysunku 2).



Rys.4. Przykładowe dane pomiarowe poszczególnych profili osobowych w kolejnych sytuacjach.



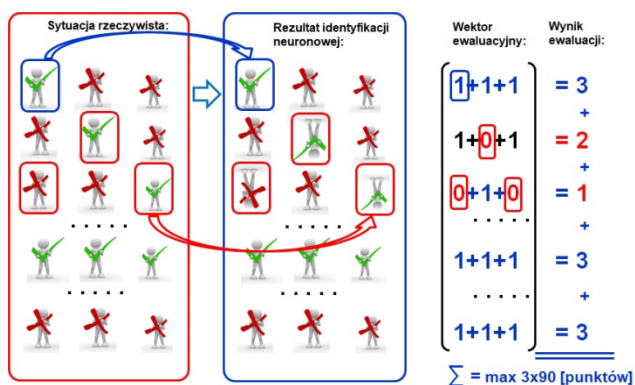
Rys.5. Podział danych pomiarowych przekazywanych na wejścia sieci neuronowej

Analiza wyników badań

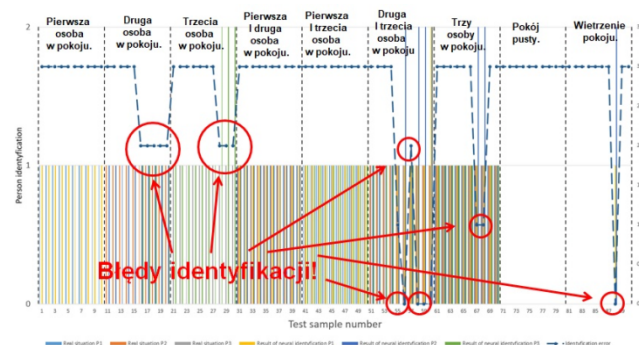
Przedmiotem badań była identyfikacja poszczególnych osób, przebywających w pomieszczeniu testowym, na podstawie parametrów środowiskowych, pochodzących z pomiarów multi-czujników wykorzystywanych w automatyce budynkowej oraz ich analizy z zastosowanie sztucznej sieci neuronowych. Zadaniem zaproponowanego systemu neuronowego było nauczenie się wzorca pomiaru wszystkich osób pojedynczo oraz w grupach, tworząc wszystkie możliwe kombinacje oraz sytuacji dodatkowych: pomieszczenia pustego i wentylowanego. Sztuczna sieć neuronowa, na podstawie wcześniej prezentowanych wzorców pochodzących z pomiarów, identyfikowała daną sytuację [5]. Dane na podstawie których identyfikowany były poszczególne osoby podzielone zostały na dwie części: dane uczące – 20 próbek oraz dane testowe 10 próbek. Założeniem budowy systemu identyfikacji profilu osobowego, była jego autoadaptacja do warunków pomiarowych. Z uwagi na długi czas oczekiwania pomiędzy poszczególnymi pomiarami (1 minuta), konieczne było zmniejszenie ilości próbek przedstawianych na wejściu sieci zarówno podczas jej uczenia (20 próbek uczących) oraz samego procesu identyfikacji (10 próbek testowych). Wyniki poprawności identyfikacji jakie osiągnięto podczas eksperymentów, pozwalają zaakceptować taką minimalizację danych prezentowanych sieci neuronowej.

Podczas testów, dla każdej z dziewięciu sytuacji (rys. 5), zaprezentowanych zostało po dziesięć próbek testowych, z których sieć neuronowa identyfikowała osoby przebywające w pomieszczeniu.

W celu oceny wyników badań, przygotowany został algorytm przypisujący wartość „jeden” dla sytuacji poprawnie zidentyfikowanej osoby oraz „zero” jako kara za błędną identyfikację [6]. Dla sytuacji poprawnej identyfikacji wszystkich trzech osób (lub ich braku), maksymalną wartością jest trzy. Natomiast przy błędnej identyfikacji wszystkich osób, sumą jest zero (rysunek nr 6). Test powtórzone zostały dziesięciokrotnie dla każdej sytuacji i wyniki zsumowano. Wyniki identyfikacji poszczególnych osób, przedstawione zostały na rysunku 7. Spośród wszystkich 90 prób testowych, poprawnie zidentyfikowanych zostało 78 sytuacji (87%). Najwięcej błędów identyfikacji zaobserwowano w przypadku przebywania samodzielnie w pomieszczeniu testowym drugiej (5 na 10 prób) oraz trzeciej (3 na 10 prób) osoby. Pozostałe, znacząco wpływające na wynik błędy, dotyczyły identyfikacji jednocześnie przebywających osób drugiej i trzeciej w pomieszczeniu.



Rys.6. Algorytm wagi dla poprawnej i niepoprawnej identyfikacji profilu osobowego



Rys.7. Wyniki neuronowej identyfikacji profilu osobowego

Podsumowanie

Ponieważ podstawą analizy identyfikacji, były dane pomiarowe wewnętrznych parametrów środowiskowych budynku takich jak temperatura, wilgotność, stężenie CO₂, VOC, można wyciągnąć wnioski, iż osoby o podobnym oddziaływaniu na środowisko, np. wydychające podobną ilość CO₂, będą gorzej rozpoznawalne przez neuronowy

system identyfikacji profilu osobowego. Identyfikacja na poziomie 50%, przy najgorzej zidentyfikowanej sytuacji, daje jednak możliwość poprawienia wyniku poprzez zwiększenie ciągu danych uczących, lub też modyfikację parametrów wewnętrznych sztucznej sieci neuronowej [7]. Należy również pamiętać, iż do badań użyte zostały standardowe czujniki pomiaru podstawowych parametrów środowiskowych [8]. Ich odpowiedni dobór lub implementacja nowszej generacji elementów pomiarowych (o dużo większej dokładności i dynamice pomiaru) znacząco poprawi precyzję otrzymanych wyników identyfikacji.

Autorzy: mgr inż. Andrzej Stachno, Politechnika Wroclawska, Wydział Elektroniki, Katedra Automatyki, Mechatroniki i Systemów Sterowania, Wybrzeże Wyspiańskiego 27, 50-370 Wrocław, E-mail: andrzej.stachno@pwr.edu.pl; dr inż. Marek Suproniuk, Wojskowa Akademia Techniczna, Wydział Elektroniki, Instytut Systemów Elektronicznych, ul. Gen. Sylwestra Kaliskiego 2, 00-908 Warszawa, E-mail: marek.suproniuk@wat.edu.pl; dr inż. Zbigniew Skibko, Politechnika Białostocka, Wydział Elektryczny, ul. Wiejska 45D, 15-351 Białystok; E-mail: z.skibko@pb.edu.pl

LITERATURA

- [1] Stanley N., Eugene H.: An Introduction to Econophysics. Correlations and Complexity in Finance, PWN, 2001.
- [2] Peitgen H.O., Jurgens H., Saupe D.: Introduction to Fractals and Chaos, PWN, 2002.
- [3] Technical Analysis of the Financial Markets, WIG PRESS, 1999.
- [4] Jabłoński A.: Intelligent buildings as distributed information systems. CASYS: International Journal of Computing Anticipatory Systems. vol. 21, s. 385-394, Liege, 2008.
- [5] Stachno Andrzej, Jabłoński Andrzej: Hybrid method for forecasting next values of time series for intelligent building control / Andrzej Stachno and Andrzej Jabłoński [i in.]. W: Computer aided systems theory - EUROCAST 2015: 15th International Conference, Las Palmas de Gran Canaria, Spain, February 8-13, 2015 : revised selected papers. Pt. 1 / Roberto Moreno-Díaz, Franz Pichler, Alexis Quesada-Arencibia (eds.). Berlin; Heidelberg: Springer, cop. 2015. s. 822-829.
- [6] M. Pawłowski, M. Suproniuk: The effect of model adequacy error of the correlation method for studies of defect centres by photoinduced transient spectroscopy, *Przegląd Elektrotechniczny*, Volume 87, Issue 10, 2011, Pages 230-235.
- [7] A. Stachno, M. Suproniuk: Environmental performance measurement system designed for forecasting in intelligent buildings *Przegląd Elektrotechniczny*, Volume 89, Issue 9, September 2013, Pages 152-155
- [8] A. Stachno: The methods of measurement and control lighting in an intelligent building. *Zeszyty Naukowe Uczelni Warszawskiej im. Marii Skłodowskiej-Curie*. 2016, nr 4 (54), s. 31-38.
- [9] A. Stachno, M. Suproniuk, M. Pawłowski: The use of trigonometric functions as input to the neural network for forecasting. *Zeszyty Naukowe Uczelni Warszawskiej im. Marii Skłodowskiej-Curie*. 2016, nr 4 (54), s. 63-75.
- [10] A. Stachno, M. Suproniuk: Układ do diagnostyki automatyki budynkowej w systemie KNX. *Pomiary, Automatyka, Kontrola*. 2014, vol. 60, nr 9, s. 780-783.