

Model neuronowy predykcji temperatury wewnętrznej w lokalach mieszkalnych budynku wielorodzinnego

Neural model for internal temperature prediction in the multi-family building premi

JAN BYLICKI, JOANNA KAJEWSKA-SZKUDLAREK, JUSTYNA STAŃCZYK, JANUSZ ŁOMOTOWSKI, PAWEŁ LICZNAR

DOI 10.36119/15.2019.9.4

Stosowane obecnie w ciepłownictwie Inteligentne Systemy Grzewcze, których obsługa odbywa się za pomocą platform SCADA (ang. *Supervisory Control and Data Acquisition*), są źródłem wielkiej ilości danych pomiarowych. Bardzo często informacje w nich zawarte są tracone, ponieważ ich analiza stwarza problemy natury metodologicznej. W niniejszym artykule przedstawiono wyniki badań nad wykorzystaniem jednej z metod eksploracji danych (ang. *Data Mining*) do predykcji temperatury powietrza w 31 lokalach mieszkalnych budynku wielorodzinnego. W tym celu za pomocą Sztucznych Sieci Neuronowych (ang. *Artificial Neural Networks – ANN*) analizowano szeregi czasowe temperatury wewnętrznej oraz dobowych sum temperatury wewnętrznej w trakcie jednego sezonu grzewczego (październik-maj). Jakość utworzonych neuronowych modeli predykcji oceniano na podstawie wartości współczynników korelacji liniowej oraz ilorazu odchyłeń standardowych pomiędzy danymi rzeczywistymi i prognozowanymi. Wykazano, że zaproponowana metoda może być stosowana jako narzędzie wspomagające naliczanie opłat za użytkowanie sieci grzewczej w przypadku krótkotrwałych awarii systemu monitoringu.

Słowa kluczowe: predykcja zapotrzebowania na ciepło, metody eksploracji danych, Sztuczne Sieci Neuronowe, Inteligentne Systemy Grzewcze, SCADA

Intelligent Heating Systems, operated by SCADA (Supervisory Control and Data Acquisition) that are used today in heating systems are a source of great amount of measurement data. Very often information contained therein is lost because data analysis creates problems of a methodological nature. This paper presents the results of research on the use of data mining methods to predict air temperature in 31 premises of a multi-family building. For this purpose, the time series of indoor temperature and daily sums of indoor temperature during one heating season (October-May) were analyzed using Artificial Neural Networks (ANN). The quality of neuron prediction models was assessed on the basis of values of linear correlation coefficients and the quotient of standard deviations between actual and predicted data. It has been shown that the proposed method can be used as a tool to support the calculation of heating fees in the case of short-term failures of the monitoring system.

Keywords: heat demand prediction, methods of data mining, Artificial Neural Networks, Intelligent Heating Systems, SCADA

Wprowadzenie

Obecnie w sektorze ciepłownictwa coraz częściej wdraża się Inteligentne Systemy Grzewcze. Podyktowane jest to względami ekonomicznymi (systematyczny wzrost kosztów ogrzewania paliwami konwencjonalnymi) i ekologicznymi (konieczność ograniczenia emisji zanieczyszczeń do atmosfery oraz ochrony zasobów paliw kopalnych) [13, 18, 20]. Nowoczesne rozwiązania pozwalają na monitoring

i zarządzanie siecią ciepłowniczą w różnej skali, od pojedynczych budynków jedno – i wielorodzinnych [3, 8], poprzez całe osiedla i aglomeracje miejskie [5, 14]. Umożliwiają racjonalne gospodarowanie wyprodukowanym ciepłem, ograniczenie jego strat, naliczanie opłat eksploatacyjnych związanych z ogrzewaniem mieszkań i zużyciem ciepła na cele przygotowywania ciepłej wody użytkowej oraz oszczędność energii. Twórcy projektu *Inteligentna Sieć Ciepłownicza*, który wdraża-

ny jest w chwili obecnej w Warszawie, szacują jakiego rzędu korzyści ekonomiczne są z nim związane. Uważają, że modernizacja sieci pozwoli na oszczędność 123 TJ rocznie z tytułu ograniczenia strat ciepła przez przenikanie oraz 112 TJ ze względu na wykorzystanie źródeł o większej efektywności ekologicznej, co łącznie spowoduje redukcję emisji dwutlenku węgla do atmosfery o 14500 ton [5].

Zarządzanie inteligentnymi systemami odbywa się za pomocą platform służących

dr inż. Jan Bylicki, dr Joanna Kajewska-Szkudlarek ORCID ID <https://orcid.org/0000-0002-0253-8133>, mgr inż. Justyna Stańczyk ORCID ID <https://orcid.org/0000-0002-5676-1787> – Szkoła Główna Gospodarstwa Wiejskiego w Warszawie
prof. dr hab. inż. Janusz Łomotowski – Uniwersytet Przyrodniczy we Wrocławiu, Instytut Inżynierii Środowiska, Wrocław,
dr hab. inż. Paweł Licznar, prof. nadzw. ORCID ID <https://orcid.org/0000-0002-2559-5296> – Politechnika Wrocławska, Katedra Wodociągów i Kanalizacji, Wrocław, pawel.licznar@pwr.edu.pl Adres do korespondencji: joanna.kajewska-szkudlarek@upwr.edu.pl

do monitoringu procesów technologicznych i ich kontroli, popularnie nazywanych SCADA (ang. *Supervisory Control and Data Acquisition*) [7, 10, 12]. Do głównych zadań tych systemów należą: pomiar i rejestracja zadanych parametrów w czasie rzeczywistym, wizualizacja pracy systemu, wybór i regulacja parametrów technologicznych, sterowanie automatyczne, zdalne sterowanie węzłami technologicznymi, alarmowanie o awariach i przekroczeniach parametrów technologicznych z jednoczesną instrukcją dla operatora.

Analogicznie, jak w przypadku innych automatycznych systemów pomiarowych, SCADA generują olbrzymie zbiory danych, a informacje, które są w nich zawarte, niejednokrotnie nie są odpowiednio wykorzystywane. Wyników pomiarów wielkości parametrów charakteryzujących systemy grzewcze używa się głównie w celu naliczenia opłat za pobór ciepła i po jego dokonaniu są one najczęściej usuwane z systemu, gdyż brakuje zarówno miejsca do ich archiwizacji, jak narzędzi ich analizy.

Analizę wielkich baz danych ułatwiają metody eksploracji danych (ang. *Data Mining*). Znajdują się wśród nich: analiza skupień (ang. *Cluster Analysis*), sieci neuronowe (ang. *Artificial Neural Networks – ANN*), zbiory i logika rozmyta (ang. *Fuzzy Sets and Fuzzy Logic*), metody bayesowskie (ang. *Bayesian Methods*), algorytmy ewolucyjne (ang. *Evolutionary Algorithms*) czy uczenie maszynowe (ang. *Machine Learning*).

Metody eksploracji danych są coraz częściej stosowane do predykcji wielkości poboru ciepła przez użytkowników sieci grzewczych. Uważa się, że kluczową rolę w konstruowaniu modeli prognostycznych odgrywa uwzględnienie dwóch zespołów czynników wpływających na wielkość zapotrzebowania na ciepło: klimatycznych oraz określających zachowanie użytkowników [15]. Spośród wymienionych metod *Data mining*, w literaturze dotyczącej ciepłownictwa, najwięcej zastosowań można znaleźć z wykorzystaniem modeli ANN [2, 19]. Cechują je dobre rezultaty prognozowania w przypadku dużych zbiorów danych eksperymentalnych, które można podzielić na podzbiory uczące i testowe. Wyniki uzyskane za ich pomocą stanowią niejednokrotnie materiał porównawczy z innymi metodami [15].

Dążenie do wykorzystania ANN o jak najprostszej strukturze sprawia, że spośród wielu stosowanych sieci neuronowych najpopularniejszymi są MLP (ang. *Multi-Layer Perceptron*). Mba i in. (2016) zastosowali je do predykcji godzinowych war-

tości temperatury i wilgotności powietrza wewnątrz budynku. Wykazali, że są one dobrym narzędziem do prognozowania parametrów określających komfort cieplny lokali mieszkalnych, gdyż korelacja wartości rzeczywistych i modelowanych była na wysokim poziomie ($r > 0,9$).

Sajjadi i in. (2016) porównali szereg modeli stworzonych z wykorzystaniem sieci neuronowych, algorytmów ewolucyjnych oraz uczenia maszynowego dla różnych horyzontów czasowych (1-24 godziny). Na podstawie jednego sezonu grzewczego 2009/2010 wykazano, że najwyższy stopień dopasowania danych prognozowanych do obserwowanych oraz zdolność generalizacji można otrzymać za pomocą ELM (ang. *Extreme Machine Learning*).

Porównanie wyników modelowania zapotrzebowania na ciepło z wykorzystaniem SVM (ang. *Support Vector Machine*), należącej do metod uczenia maszynowego, z pozostałymi metodami *Data Mining*, wskazuje, że za pomocą Maszyny Wektorów Nośnych można uzyskać lepsze rezultaty prognozowania, zwłaszcza w dłuższej perspektywie czasowej [4].

Zadawalające wyniki predykcji otrzymywane są również za pomocą rozwiązań stanowiących połączenie kilku metod *Data mining*. Shamshirband i in. (2015) do prognozowania zapotrzebowania na ciepło używali hybrydy sieci neuronowych i logiki rozmytej; Protic i in. (2015) połączyli metodę SVM z analizą falkową (ang. *Wavelet*); Chou i Bui (2015) metodę SVR (ang. *Support Vector Regression*) z ANN; Ahn i in. (2017) logikę rozmytą oraz sieci neuronowe.

Celem pracy było stworzenie neuronowego modelu predykcji zmian temperatury wewnętrznej w 31 lokalach mieszkalnych budynku wielorodzinnego. Do badań wykorzystano zarchiwizowane szeregi czasowe temperatury, pochodzące z monitoringu systemu w sezonie grzewczym (okres od października do maja). Wyniki badań mogą mieć szereg zastosowań praktycznych: do przewidywania parametrów dla systemu grzewczego na określony horyzont czasowy, racjonalnej modernizacji instalacji ogrzewania, optymalizacji pracy sterowników kotłowych i uproszczenia ich obsługi, poprawy sprawności i efektywności procesów wytwarzania ciepła, zmniejszenia emisji zanieczyszczeń do atmosfery, zmniejszenia kosztów eksploatacji oraz zwiększenia trwałości urządzeń oraz diagnostyki układu grzewczego.

Niniejsza praca stanowi kontynuację badań autorów nad oceną indywidualnych cech zachowania mieszkańców podczas eksploatacji instalacji ciepłowniczej.

Metodyka badań

Analizom z wykorzystaniem sieci neuronowych poddano szeregi czasowe temperatury wewnętrznej oraz dobowych sum temperatury wewnętrznej w poszczególnych lokalach mieszkalnych budynku wielorodzinnego. Zastosowano jedno- lub dwuetapowy proces uczenia metodami ze wsteczną propagacją błędów, gradientów sprzężonych i Quasi-Newtona (BFGS), Levenberga-Marquardta i redukcję wag metodą Weigenda w celu uniknięcia zjawiska nadmiernego dopasowania do danych (ang. *Overfitting*). Polega ono na tym, że sieć doskonale działa na zbiorze uczącym, natomiast nie osiąga zadowalających rezultatów dla danych, które nie brały udziału w procesie uczenia.

W warstwie wejściowej i wyjściowej używano liniowej, natomiast w warstwach ukrytych hiperbolicznej funkcji aktywacji neuronów przy różnej liczbie epok (od 50 do 2000). Szereg czasowy podzielono na zbiór uczący (50% ogólnej ilości obserwacji), walidacyjny i testowy (odpowiednio po 25%). Modelowania dokonano dla różnej liczby wejść (1-10), różnej architektury sieci w zakresie liczby neuronów w warstwie ukrytej (2-10) oraz różnego przesunięcia czasowego wielkości wejściowych w stosunku do wielkości prognozowanej (1-24). Dla celów pracy przeanalizowano dziesiątki wariantów architektury sieci SSN, dla szeregu wielkości wejściowych i opóźnień.

W pracy jakość modeli oceniano na podstawie wartości ilorazu odchyłań standardowych oraz współczynnika korelacji liniowej Pearsona r . Najlepiej dopasowany model charakteryzowała najniższa wartość ξ oraz najwyższa wartość r .

Ocenę poprawności doboru zmiennych wejściowych do modelu przeprowadzono za pomocą kryterium informacyjnego Akaike AIC (ang. *Akaike Information Criterion*) na podstawie złożoności modelu określanej liczbą estymowanych parametrów. Za najbardziej optymalny model uważano ten, dla którego wartość AIC była najmniejsza. Obliczano ją z zależności:

$$AIC = N \cdot \ln\left(\frac{SSE}{N}\right) + 2 \cdot L_p, \quad (1)$$

gdzie:

L_p – liczba estymowanych parametrów modelu;

N – liczebność zbioru danych;

SSE – suma kwadratów błędów predykcji.

W ciepłownictwie, do prognozowania zapotrzebowania na ciepło, stosuje się umowną wartość stopniodnia $SD_i [^{\circ}C \cdot d]$,

która jest różnicą między średnią temperaturą powietrza wewnętrznego i zewnętrznego w i -tej dobie sezonu grzewczego [11]:

$$SD_i = T_{ws_i} - T_{zsi'} \quad (2)$$

gdzie:

T_{ws} – średnia temperatura powietrza wewnętrznego;

T_{wz} – średnia temperatura powietrza zewnętrznego.

Przy prognozowaniu zapotrzebowania na paliwo (energię cieplną) wykorzystuje się sumy stopniodni dla całego okresu ogrzewania:

$$SD_{sezon} = \sum_{i=1}^n SD_{i'} \quad (3)$$

gdzie:

SD_{sezon} – suma stopniodni dla sezonu grzewczego z wielolecia;

n – liczba dni trwania sezonu grzewczego z wielolecia.

W niniejszej pracy, oprócz szeregów czasowych temperatury wewnętrznej w lokalach, poddano również analizie szeregi dobowych sum temperatury wewnętrznej, zarówno w poszczególnych mieszkaniach, jak i w całym budynku. Sumy dobowe temperatury wewnętrznej ST_{lokj}^n wyliczono z zależności:

$$ST_{lokj}^n = \sum_{i=1}^{i=24} T_{lokj,i}^n \quad (4)$$

gdzie:

$T_{lokj,i}^n$ – średnia temperatura wewnętrzna, w °C, w i -tej godzinie ($i = 1, 2, \dots, 24$) w j -tym dniu obserwacji, n -tego lokalu mieszkalnego ($i = 1, 2, \dots, 31$).

Na podstawie obliczonych wartości ST_{lokj}^n wyznaczono szereg czasowy dobowych sum temperatury wewnętrznej w obiekcie:

$$ST_{obiekj} = \sum_{n=1}^{n=31} T_{lokj}^n \quad (5)$$

Analizę szeregów czasowych temperatury wewnętrznej za pomocą sieci neuronowych przeprowadzono z wykorzystaniem programu komputerowego STATISTICA.

Wyniki badań

Model predykcji temperatury wewnętrznej

Pierwszym etapem badań była próba ustalenia architektury sieci typu MLP do prognozowania temperatury w lokalach mieszkalnych. Może ono znaleźć zastosowanie przy naliczaniu opłat za ogrzewanie w przypadku krótkotrwałych awarii systemu rejestrującego zużycie ciepła w budynku.

Na podstawie kryterium AIC wykazano, że najbardziej optymalna sieć do prognozowania temperatury w lokalach miała architekturę MLP 4: 4-3-1 :1. Warstwa wejściowa składała się z czterech neuronów, które obejmowały temperaturę przesuniętą o 1, 2, 3, 4 godziny wstecz liczone od wartości prognozowanej. Na

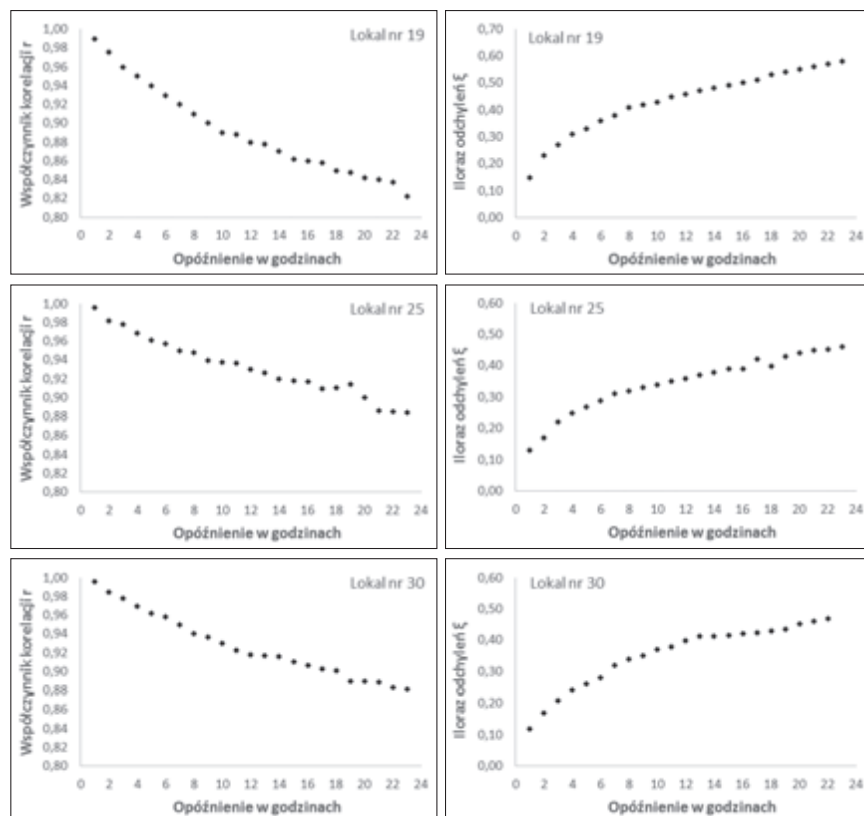
podstawie przeprowadzonych badań stwierdzono, że ilość wejść do modelu oraz liczba neuronów w warstwie ukrytej miały niewielki wpływ na jakość predykcji ($r > 0,97$). Wyniki otrzymane dla wybranego lokalu 3 przedstawiono w tabeli 1.

Do realizacji celu kolejnego etapu prac – ustalenia wpływu sposobu użytkowania

Tabela 1. Charakterystyka sieci neuronowych typu MLP do prognozowania temperatury wewnętrznej w lokalu 3

Table 1. Characteristics of MLP neural networks for forecasting indoor temperature in apartment 3

Opis sieci i danych wejściowych			Suma kwadratów błędów SSE	Liczba estymowanych parametrów modelu L_p	Kryterium AIC	Współczynnik korelacji r Pearsona	Iloraz odchyleń standardowych ξ
Ilość wejść	Ilość neuronów w warstwie ukrytej	Dane wejściowe określające przesunięcie wstecz liczone od wartości prognozowanej					
5	7	1, 2, 3, 4, 5	244,66	50	-12369,22	0,9779	0,2090
5	6	1, 2, 3, 4, 5	230,95	43	-12633,20	0,9792	0,2029
5	5	1, 2, 3, 4, 5	227,77	36	-12707,48	0,9795	0,2014
5	4	1, 2, 3, 4, 5	230,74	29	-12665,17	0,9792	0,2028
4	6	1, 2, 3, 4	227,96	37	-12701,73	0,9791	0,2034
4	5	1, 2, 3, 4	226,58	31	-12740,06	0,9796	0,2008
4	4	1, 2, 3, 4	233,71	25	-12617,83	0,9789	0,2041
4	3	1, 2, 3, 4	227,76	19	-12741,67	0,9795	0,2014
4	2	1, 2, 3, 4	234,98	13	-12618,35	0,9788	0,2047
3	5	1, 2, 3	260,42	26	-12146,47	0,9763	0,2159
3	4	1, 2, 3	239,20	21	-12525,09	0,9784	0,2066
3	3	1, 2, 3	232,69	16	-12654,73	0,9790	0,2036
2	4	1, 2	243,33	17	-12458,90	0,9780	0,2084
2	3	1, 2	238,09	13	-12561,29	0,9781	0,2079
2	2	1, 2	238,71	9	-12558,03	0,9770	0,2132



Rys. 1. Wartości współczynników korelacji liniowej między danymi obserwowanymi a prognozowanymi oraz ilorazu odchyleń dla poszczególnych opóźnień wartości wejściowych
Fig. 1. Linear correlation coefficients between observed and predicted data, standard deviations quotients for individual input delays

lokali przez mieszkańców na możliwość predykcji temperatury wewnętrznej – wykorzystano SSN o architekturze MLP 2: 2-3-1 :1. Dane wejściowe stanowiły wartości temperatury w pomieszczeniu w godzinie określonej opóźnieniem w stosunku do wartości prognozowanej oraz temperatura je poprzedzająca.

We wszystkich lokalach wraz ze wzrostem wielkości opóźnienia spadała wartość współczynnika korelacji liniowej r między wielkościami obserwowanymi a prognozowanymi, natomiast wyraźnie rosła wartość ilorazu odchyłań, co wskazuje na pogorszenie jakości modelu prognostycznego (rys. 1).

W przypadku lokali numer 1, 2, 9, 13, 14, 18 i 24, które łącznie stanowią 25,81% wszystkich mieszkań w budynku, wykazano, że istnieje możliwość prognozowania temperatury wewnętrznej z 24-godzinnym horyzontem czasowym. W 12,90% mieszkań (lokale nr 12, 19, 26 oraz 27) prognozowano temperaturę z perspektywą 8 godziną. Jakość modelu predykcji temperatury w lokalach mieszkalnych uznawano za dobrą, gdy wartość współczynnika korelacji zawierała się w przedziale od 0,85 do 0,95 oraz ilorazu odchyłań w zakresie od 0,1 do 0,4. Przyjęcie niższego kryterium oceny ($r \in [0,80; 0,85]$) oraz $\xi \in (0,40, 0,60]$) sprawiło, że aż w 87,10% badanych lokali mieszkalnych predykcja była możliwa na 24 godziny do przodu (tab. 2).

W lokalach 5 i 6 ANN umożliwiają predykcję temperatury jedynie w bardzo krótkim horyzoncie czasowym (1, 2 godziny). Na podstawie przeprowadzonej wizji lokal-

nej, stwierdzono, że ich mieszkańcy stosują w urządzeniach klimatyzacyjne (tab. 2).

Model predykcji sum dobowych temperatury wewnętrznej

Predykcji sum dobowych temperatury wewnętrznej za pomocą ANN dokonano analogicznie, jak w przypadku prognozowania temperatury w poszczególnych lokalach. Rezultaty ustalania architektury sieci typu MLP dla przykładowego lokalu nr 3 przedstawiono w tabeli 3. Analiza wielkości kryterium AIC wskazała, że najlepszą ANN do prognozowania sum dobowych temperatury wewnętrznej była sieć o architekturze MLP 2: 2-2-1 :1, w której wejścia stanowiły temperatury o 1 i 2 godziny poprzedzające wartość prognozowaną.

Na podstawie przeprowadzonych badań stwierdzono, że wartość kryterium AIC rośnie wprost proporcjonalnie do liczby neuronów w warstwie ukrytej oraz ilości wejść, co jest głównie wynikiem wzrostu złożoności modelu, określonej liczbą estymowanych parametrów.

Ze względu na ograniczoną objętość pracy nie zamieszczono wyników predykcji dobowych sum temperatury w poszczególnych lokalach dla różnych opóźnień z wykorzystaniem MLP 2: 2-2-1 :1. Jako dane wejściowe przyjęto sumy dobowe temperatury w 31 mieszkaniach w dobie określonej opóźnieniem w stosunku do wartości prognozowanej oraz w dobie ją poprzedzającej. Wykonano obliczenia dla prognoz od 1 do 6 dni. Uzyskano zadowalające prognozy ($r \in [0,80; 0,85]$

i $\xi \in (0,40; 0,60]$) na jedną dobę do przodu dla wszystkich lokali z wyjątkiem mieszkania numer 5.

Z punktu widzenia prognozowania zapotrzebowania na energię znacznie istotniejsza jest predykcja sum temperatury wewnętrznej we wszystkich lokalach mieszkalnych łącznie. Dla zarządcy/eksploatatora lokalnych źródeł ciepła stanowi ważne źródło informacji oraz ogólny pogląd na wielkość zapotrzebowania na ciepło budynku. Prognozy dokonano z wykorzystaniem sieci perceptronowych MLP 2: 2-3-1 :1 oraz sieci o radialnych funkcjach bazowych RBF 2: 2-9-1 :1 (tab. 4).

Model predykcyjny, oparty zarówno na sieci perceptronowej, jak i radialnych funkcjach bazowych, charakteryzował się zadowalającą jakością ($r > 0,8$) jedynie dla horyzontu czasowego jednego dnia. Współczynniki korelacji w przypadku prognoz od 2 do 3 dni do przodu wynosiły 0,6 i 0,7, natomiast dla okresu od 4-6 dni nie uzyskano modeli MLP oraz RBF o wystarczającej

Tabela 4. Zestawienie wyników prognozowania dobowych sum temperatury we wszystkich lokalach mieszkalnych

Table 4. Summary of forecasting daily temperature results in all residential premises

Liczba dni prognozy	MLP 2 :2-3-1 :1		RBF 2: 2-9-1 :1	
	R	ξ	R	ξ
1	0,82524	0,56378	0,83620	0,57700
2	0,65750	0,76350	0,73890	0,69860
3	0,60254	0,70234	0,66240	0,75950
4	0,40632	0,88966	0,19930	1,19780
5	0,30718	0,95234	0,49190	0,90900
6	0,54216	0,85038	0,53960	0,84220

Tabela 2. Zestawienie możliwości prognoz ex ante w godzinach dla temperatury wewnętrznej z zastosowaniem ANN o architekturze MLP 2: 2-3-1 :1

Table 2. Summary of ex ante forecasting possibilities in hours for indoor temperature using MLP 2: 2-3-1 :1 architecture

Czas prognozy ex ante w godzinach	Numer lokalu	Liczba lokali	Procent lokali w budynku
1	5	1	3,23
2	6	1	3,23
4	21, 31	2	6,45
7	8, 10	2	6,45
8	12, 19, 26, 27	4	12,90
9	11, 23, 29	3	9,68
10	3, 16, 20	3	9,68
11	7	1	3,23
12	15	1	3,23
13	30	1	3,23
17	25, 28	2	6,45
20	22	1	3,23
22	4	1	3,23
24	1, 2, 9, 13, 14, 18, 24	8	25,81

Tabela 3. Sieci neuronowe typu MLP do prognozowania dobowych sum temperatury wewnętrznej w lokalu 3

Table 3. MLP neural networks for forecasting daily indoor temperature in apartment 3

Opis sieci i danych wejściowych			Suma kwadratów błędów SSE	Liczba estymowanych parametrów modelu l_p	Kryterium AIC	Współczynnik korelacji r Pearsona	Iloraz odchyłań standardowych ξ
Ilość wejść	Ilość neuronów w warstwie ukrytej	Dane wejściowe określające przesunięcie wstecz liczone w dobach od wartości prognozowanej					
5	7	1, 2, 3, 4, 5	22242,66	50	933,87	0,889270	0,458535
5	6	1, 2, 3, 4, 5	25971,28	43	960,99	0,874379	0,494057
5	5	1, 2, 3, 4, 5	24356,17	36	935,76	0,880422	0,479828
5	4	1, 2, 3, 4, 5	21614,40	29	900,86	0,893342	0,449802
4	6	1, 2, 3, 4	23170,30	37	929,02	0,893021	0,468307
4	5	1, 2, 3, 4	22065,24	31	908,47	0,889866	0,456267
4	4	1, 2, 3, 4	21142,69	25	889,00	0,896481	0,443648
4	3	1, 2, 3, 4	21074,76	19	876,43	0,895351	0,446615
4	2	1, 2, 3, 4	22018,77	13	872,10	0,889994	0,456254
3	5	1, 2, 3	19927,44	26	880,64	0,900912	0,434176
3	4	1, 2, 3	22093,68	21	888,70	0,889617	0,456920
3	3	1, 2, 3	20988,63	16	869,72	0,895950	0,445602
2	4	1, 2	20592,93	17	868,39	0,897305	0,441454
2	3	1, 2	22292,88	13	874,27	0,889137	0,458039
2	2	1, 2	22307,35	9	866,38	0,890793	0,458844

dobrej zdolności prognozowania (od $r=0,1$ do $r=0,5$) dobowych sum temperatury we wszystkich lokalach mieszkalnych łącznie.

Podsumowanie i wnioski

Inteligentne systemy służące do monitoringu pracy kotłowni są źródłem olbrzymiej ilości danych pomiarowych w postaci szeregów czasowych. Stosowanie metod eksploracji danych (ang. *Data mining*) może ułatwić ich analizę i zrationalizować metody naliczania opłat za zużycie ciepła.

W niniejszej pracy do prognozowania temperatury wewnętrznej oraz dobowych sum temperatury wewnętrznej w lokalach mieszkalnych budynku wielorodzinnego zaproponowano wykorzystanie Sztucznych Sieci Neuronowych (ang. *Artificial Neural Networks – ANN*). Analizowane dane pochodziły z jednego sezonu grzewczego (okres od października do maja).

Przeprowadzone badania pozwoliły na stwierdzenie, że proste sieci perceptronowe MLP (ang. *Multi-Layer Perceptron*) o pojedynczej warstwie ukrytej mogą być z powodzeniem stosowane jako narzędzie do predykcji wewnętrznej temperatury powietrza w lokalach mieszkalnych budynku wielorodzinnego. Prognozy dokonywano na podstawie znajomości wielkości temperatury wewnętrznej w 1-24 godzinach wstecz, liczonych od wartości prognozowanej.

Wykazano, że najbardziej optymalną strukturą neuronową do prognozowania temperatury w lokalach jest sieć o architekturze MLP 4: 4-3-1 :1, w której wejścia stanowiła temperatura przesunięta o 1-4 godzin wstecz w stosunku do wartości prognozowanej. W przypadku dobowych sum temperatury wewnętrznej najlepsze rezultaty predykcji otrzymano dla architektury MLP 2: 2-2-1 :1, gdzie warstwa wejściowa obejmowała wartości temperatury w 1 i 2 godzinach przed prognozą.

W 87,10% lokali budynku wielorodzinnego otrzymano zadawalające prognozy ($r \in [0,80; 0,85]$ i $\xi \in [0,40; 0,60]$) w 24-godzinym horyzoncie czasowym.

Predykcja sum dobowych temperatury wewnętrznej we wszystkich lokalach roz-

patrywanych łącznie, istotna w prognozowaniu zapotrzebowania na energię, dostarczyła dostatecznie dobrych wyników jedynie w perspektywie jednego dnia. Zarówno sieci typu MLP, jak i RBF (ang. *Radial Basis Function*) nie umożliwiły stworzenia modelu dostatecznej jakości dla okresu od 2 do 6 dni.

Wyniki uzyskane w niniejszej pracy mogą znaleźć zastosowanie do uzupełniania szeregów czasowych temperatury wewnętrznej w przypadku krótkotrwałych awarii systemu monitoringu, co może stanowić narzędzie wspomagające w procesie naliczania opłat za użytkowanie sieci grzewczej. Planuje się prowadzenie dalszych badań w zakresie predykcji wielkości poboru ciepła z uwzględnieniem temperatury zewnętrznej w celu usprawnienia pracy lokalnej kotłowni.

BIBLIOGRAFIA

- [1] Ahn J., Cho S., Chung D., H. Analysis of energy and control efficiencies of fuzzy logic and artificial neural networks technologies in the heating energy supply system responding to the changes of user demands. *Applied Energy* 190, 2017, p. 222-231. DOI: 10.1016/j.apenergy.2016.12.155.
- [2] Aleksiejuk P.: Model prognostyczny zapotrzebowania na ciepło z wykorzystaniem struktur sztucznych sieci neuronowych. *Instal*, 2, 2016, s. 13-15.
- [3] Alibabei N., Fung A. S., Raahemifar K., Moghimi A. Effects of intelligent strategy planning models on residential HVAC system energy demand and cost during the heating and cooling seasons. *Applied Energy* 185, 2017, p. 29-43. DOI: 10.1016/j.apenergy.2016.10.062 0306-2619.
- [4] Al-Shammari E. T., Keivani K., Shamshirband S., Mostafaeipour A., Yee P. L., Petkovic D., Ch S. Prediction of heat load in district heating systems by Support Vector Machine with Firefly searching algorithm. *Energy* 95, 2016, p. 266-273. DOI: 10.1016/j.energy.2015.11.079.
- [5] Balas P., Falba Ł. Inteligentna Sieć Ciepłownicza w Warszawie – charakterystyka projektu modernizacji Warszawskiej Sieci Ciepłowniczej. *Instal* 1, 2016, p. 5-10.
- [6] Chou J.-S., Bui D.-K. Modeling cooling and heating loads by artificial intelligence for energy-efficient building design. *Energy and Buildings* 82, 2014, p. 437-446. DOI: 10.1016/j.enbuild.2014.07.036.
- [7] Figueiredo J., Sa da Costa J. A SCADA system for energy management in intelligent buildings. *Energy and Buildings* 49, 2012, p. 85-98. DOI:10.1016/j.enbuild.2012.01.041.
- [8] Lilis G., Conus G., Asadi N., Kayal M. Towards the next generation of intelligent building: An assessment study of current automation and future IoT based system with a proposal for transitional design. *Sustainable Cities and Society* 28, 2017, p. 473-481. DOI: 10.1016/j.scs.2016.08.019.
- [9] Mba L., Meukam P., Kemajou A. Application of artificial neural network for prediction hourly indoor air temperature and relative humidity in modern building in humid region. *Energy and Buildings* 121, 2016, p. 32-42. DOI: 10.1016/j.enbuild.2016.03.046.
- [10] Medved S., Babnik M., Vidrih B., Arkar C. Parametric study on the advantages of weather-predicted control algorithm of free cooling ventilation system. *Energy* 73, 2014, p. 80-87. DOI: 10.1016/j.energy.2014.05.080 0360-5442.
- [11] Mielnicki J.S. Centralne ogrzewanie. Regulacja i eksploatacja. Arkady Warszawa, 1984, pp. 697.
- [12] Nielsen H. A., Madsen H., Modelling the heat consumption in district heating systems using a grey-box approach. *Energy and Buildings* 38, 2006, p. 63-71. DOI:10.1016/j.enbuild.2005.05.002.
- [13] Pena M., Biscarri F., Guerro J. I., Monedero I., Leon C. Rule-based system to detect energy efficiency anomalies in smart buildings, a data mining approach. *Expert Systems with Applications* 56, 2016, p. 242-255. DOI: 10.1016/j.eswa.2016.03.002 0957-4174.
- [14] Petkovic D., Protic M., Shamshirband S., Akib S., Raos M., Markovic D. Evaluation of the most influential parameters of heat load in district heating systems. *Energy and buildings* 104, 2015, p. 264-274. DOI: 10.1016/j.enbuild.2015.06.074 0378-7788.
- [15] Popescu D., Ungureanu F., Hernandez-Guerrero A. Simulation models for the analysis of space heat consumption of buildings. *Energy* 34, 2009, p. 1447-1453. DOI: 10.1016/j.energy.2009.05.035.
- [16] Protic M., Shamshirband S., Petkovic D., Abbasi A., Kiah M. L. M., Unar J. A., Zivkovic L., Raos M. Forecasting of consumers heat load in district heating systems using the support vector machine with a discrete wavelet transform algorithm. *Energy* 86, 2016, p. 343-351. DOI: 10.1016/j.energy.2015.04.109.
- [17] Sajjadi S., Shamshirband S., Alizamir M., Yee P. L., Mansor Z., Manaf A. A., Altameem T. A., Mostafaeipour A. Extreme learning machine for prediction of heat load in district heating systems. *Energy and Buildings* 122, 2016, p. 222-227. DOI: 10.1016/j.enbuild.2016.04.021.
- [18] Shamshirband S., Petkovic D., Enayatifar R., Abdullah A. H., Markovic D., Lee M., Ahmad R. Heat load prediction in district heating systems with adaptive neuro-fuzzy method. *Renewable and Sustainable Energy Reviews* 48, 2015, p. 760-767. DOI: 10.1016/j.rser.2015.04.020.
- [19] Sholahudin S., Han H. Simplified dynamic neural network model to predict heating load of a building using Taguchi method. *Energy* 115, 2016, p. 1672-1678. DOI: 10.1016/j.energy.2016.03.057.
- [20] Zheng Z., Wang L., HienWong N. Intelligent Control System Integration and Optimization for Zero Energy Buildings to Mitigate Urban Heat Island. *Procedia Engineering* 169, 2016, p. 100 – 107. DOI: 10.1016/j.proeng.2016.10.012.

Rozszerzone wydanie poradnika „Pompy ciepła”

autor: dr inż. Marian Rubik
Wydanie III rozszerzone. Warszawa 2006 r. Cena 40 zł + VAT

Zamówienia przyjmuje:

Ośrodek Informacji „Technika instalacyjna w budownictwie”
02-674 Warszawa, ul. Marynarska 14, tel./fax: (22) 843-77-71
e-mail: redakcja@informacjainstal.com.pl, wydawnictwo@informacjainstal.com.pl

