

# DOBÓR POMP CIEPŁA Z WYKORZYSTANIEM SZTUCZNYCH SIECI NEURONOWYCH DLA DOMÓW JEDNORODZINNYCH DLA PEŁNYCH I NIEPEŁNYCH ZBIORÓW DANYCH

Maciej Neugebauer, Piotr Sołowiej, Tomasz Himik

Katedra Elektrotechniki i Energetyki, Uniwersytet Warmińsko-Mazurski w Olsztynie

**Streszczenie.** W pracy zaproponowano sposób doboru pompy ciepła z wykorzystaniem sieci neuronowych. Dobór pomp ciepła polega na obliczeniu mocy cieplnej na podstawie parametrów danego domu. Utworzono i przetestowano kilka rodzajów sieci, z uwzględnieniem testowania na zbiorach danych pełnych (ze wszystkimi parametrami wejściowymi) i niepełnych (bez jednego lub dwóch parametrów wejściowych). Dla zbiorów danych niepełnych brakującymi parametrami były: wysokość pomieszczenia, grubość ocieplenia, temperatura wewnętrz i ukształtowanie budynku. W pracy użyto dwóch programów do symulacji sztucznych sieci neuronowych: „Statistica” i „MATLAB”.

**Slowa kluczowe:** sztuczne sieci neuronowe, dobór pompy ciepła, niepełny zbiór danych

## Wstęp

Pompy ciepła, wraz z instalacjami do pozyskiwania ciepła niskotemperaturowego, są urządzeniami względnie drogimi i dlatego decyzja o ich zastosowaniu powinna być poprzedzona wnikliwą analizą uwzględniającą wszelkie uwarunkowania zarówno energetyczne, jak i środowiskowe [Rubik 2006]. Do podstawowych elementów tej analizy zaliczamy:

- izolacyjność cieplną ogrzewanego obiektu,
- warunki lokalne i środowiskowe w aspekcie wyboru źródła ciepła niskotemperaturowego, obliczeniowej temperatury powietrza zewnętrznego (strefa klimatyczna), ochrony powietrza przed zanieczyszczeniami (strefy chronione) itd.,
- warunki energetyczne obecne i perspektywiczne: dostępność i ceny nośników ciepła i gazu przewodowego i bezprzewodowego (płynnego), oleju opałowego, ciepła sieciowego oraz energii elektrycznej (pewność dostaw i ceny).

Dobór pomp ciepła polega na obliczeniu mocy cieplnej na podstawie parametrów danego domu. Parametry domu, czyli parametry wejściowe do modelowania neuronowego to: powierzchnia, wysokość pomieszczenia, grubość ocieplenia, temperatura wewnętrz, charakter budynku, ukształtowanie budynku, ilość okien, rodzaj instalacji, teren wokół budynku. Pompy ciepła sklasyfikowano według mocy znamionowych, była to dana wyjściowa. Sieci neuronowe są dobrym narzędziem do rozwiązywania problemów klasyfikacyjnych

[Jack i in. 2002; Liao i in. 2004; Partovi i in. 2002; Wanás i in. 1999] i predykcji zdarzeń [Neugebauer i in. 2007]. W ramach badań utworzono i przetestowano kilka rodzajów sieci, z uwzględnieniem testowania na zbiorach danych pełnych (ze wszystkimi parametrami wejściowymi) i niepełnych (bez jednego lub dwóch parametrów wejściowych). Dla zbiorów danych niepełnych brakującymi parametrami były: wysokość pomieszczenia, grubość ocieplenia, temperatura wewnętrzna i ukształtowanie budynku. Przetestowane sieci to perceptron trójwarstwowy z 5, 10, 15 neuronami w warstwie ukrytej, oraz probabilistyczna sieć klasyfikacyjna. W pracy użyto dwóch programów do symulacji sztucznych sieci neuronowych: „Statistica” i „MATLAB”. W każdym z tych programów przetestowano wybrane rodzaje sieci, następnie dokonano porównania wszystkich sieci w celu wyłonienia tych, które zostaną użyte do testowania na zbiorach niepełnych. Porównywanie różnych typów sieci do rozwiązania tego samego problemu oraz różnych programów pozwala wybrać najlepszą SSN do rozwiązania konkretnego problemu [Boniecki 2002].

## Cel i zakres pracy

Celem pracy było wykorzystanie SSN w celu doboru pomp ciepła dla konkretnych domów jednorodzinnych. Jest to rozwiązanie problemu klasyfikacji – przyporządkowanie pompy ciepła o konkretnej mocy (tabela 1) do konkretnego domu jednorodzinnego opisanego zbiorem parametrów podanych w tabeli 2.

Zakres pracy obejmował:

- zebranie typoznarek gruntowych pomp ciepła różnych producentów;
- określenie parametrów charakteryzujących domy jednorodzinne pod kątem mocy potrzebnej do ogrzewania, jako parametrów wejściowych do modelowania neuronowego;
- na podstawie zebranych informacji stworzenie zbiorów uczącego i testowego dla sieci neuronowych;
- stworzenie i uczenie różnych typów sieci neuronowych;
- testowanie sieci neuronowych na zbiorach pełnych i niepełnych (testowanie sieci przeprowadzano na zbiorze testowym nie zależnym od zbioru uczącego);
- porównanie otrzymanych wyników uzyskanych w różnych programach i dla różnych sieci, z wynikami rzeczywistymi (dobór pompy ciepła dla konkretnego domu na podstawie obliczeń – przygotowane jako zbiór testowy) i wybranie najlepszej sieci.

## Klasyfikacja pomp ciepła

Aby można było lepiej przetestować sieci neuronowe, należało podzielić pompy ciepła na określone klasy. Wiąże się to z tym, że sieć neuronowa łatwiej się będzie uczyć mając dokładnie określony zbiór danych, w postaci liczb całkowitych. Moce produkowanych pomp podzielono na 20 klas – podział pokazano w tabeli nr 1. Dla poszczególnych producentów (ECO, Hibernatus, IVT Greenline, Ochsner, SOLIS, Spartec-Classic, Stiebel-Eltron, Thermia, Nibe, Viessmann) przydzielono produkowane pompy ciepła do poszczególnych klas. Poszczególne klasy pomp przedstawiono w tabeli 1.

## Dobór pomp ciepła...

Tabela 1. Wydzielone klasy produkowanych pomp ciepłą  
Table 1. Separated classes of manufactured heat pumps

Klasa / moc w kW	Klasa / moc w kW	Klasa / moc w kW	Klasa / moc w kW	Klasa / moc w kW
Klasa 1 / (0 ÷ 5)	Klasa 5 / (9 ÷ 11)	Klasa 9 / (16,5 ÷ 17)	Klasa 13 / (23 ÷ 26)	Klasa 17 / (33 ÷ 35)
Klasa 2 / (5 ÷ 7)	Klasa 6 / (11 ÷ 13)	Klasa 10 / (17 ÷ 19)	Klasa 14 / (26 ÷ 29)	Klasa 18 / (35 ÷ 39)
Klasa 3 / (7 ÷ 8)	Klasa 7 / (13 ÷ 15)	Klasa 11 / (19 ÷ 21)	Klasa 15 / (29 ÷ 30)	Klasa 19 / (39 ÷ 46)
Klasa 4 / (8 ÷ 9)	Klasa 8 / (15 ÷ 16,5)	Klasa 12 / (21 ÷ 23)	Klasa 16 / (30 ÷ 33)	Klasa 20 / (46 ÷ 51)

Źródło: obliczenia własne autora

## Zbiór uczący

Aby na podstawie parametrów budynku określić, jaka jest potrzebna pompa ciepła, należy obliczyć zapotrzebowanie na moc cieplną budynku.

Po oszacowaniu zapotrzebowania cieplnego budynku można już wstępnie dobrać konkretną pompę ciepła, której moc grzewcza odpowiada lub przekracza obliczoną moc cieplną.

Zbiór danych, który będzie wykorzystany do doboru pompy ciepła z wykorzystaniem sieci neuronowych, jest to zestaw wielkości wejściowych i wyjściowych. Jako dane wejściowe przyjęto parametry budynku – tabela 2, poszczególne wiersze tabeli oznaczają poszczególne wejścia SSN.

Tabela 2. Dane wejściowe dla SSN

Table 2. Input data for SSN

Wejście SSN		Wartość na wejściu sieci
1	Powierzchnia [m <sup>2</sup> ]	- 70÷80 – 1; - 80÷90 – 2; - 90÷100 – 3; ... - 380÷390 – 32.
2	Wysokość pomieszczeń [m] -	- 2,5 – 1; - 3 – 2;
3	Grubość ocieplenia [cm] –	- 0 – 1; - 5 – 2; - 10 – 3; - 20 – 4.
4	Żądana temperatura wewnętrz [°C]	- 20 – 1 - 25 – 2.
5	Charakter budynku	- parterowy, podpiwniczy – 1; - piętrowy, podpiwniczy – 2; - parterowy lub piętrowy niepodpiwniczy – 3.
6	Ukształtowanie budynku.	- proste – 1; - złożone – 2.
7	Ilość okien.	- 1 na pokój – 1; - więcej niż jedno na pokój – 2.
8	Rodzaj instalacji grzewczej.	- grzejnikowa – 1; - podłogowa – 2.
9	Teren na zewnątrz budynku.	- osłonięty – 1; - nieosłonięty – 2.

Źródło: obliczenia własne autora

Natomiast dane wyjściowe jest to moc cieplna, do której jest dobrana odpowiednia klasa pomp. W warstwie wejściowej utworzono 9 neuronów, natomiast w warstwie wyjściowej 1 neuron.

Do uczenia sieci neuronowej obliczono i przygotowano 300 różnych kombinacji danych wejściowych i odpowiadające im dane wyjściowe, jako zbiór uczący.

Sporządzono również kilka rodzajów zbiorów testowych. Sieci neuronowe były na nich testowane, ale, co należy podkreślić, **nie były** uczone na zbiorach testowych. Liczebność zbioru testowego wynosiła 20.

W celu określenia jak duży błąd podczas testowania uzyskała sieć, posłużono się następującym wzorem:

$$B_s = \sqrt{\frac{\sum_{i=1}^n B_i^2}{n}} \quad (1)$$

gdzie:

- $B_s$  – błąd sieci,
- $B_i$  – wielkość błędu dla pojedynczego przykładu ze zbioru testowego,
- n – liczbeność zbioru testowego.

### **Dobór pompy ciepła z wykorzystaniem programu „MATLAB” dla zbiorów pełnych**

Z uwagi na wymagania programu dla Matlab'a dokonano normalizacji danych, czyli zamianę zmiennych początkowych na zmienne z przedziału <-1;1>.

W programie tym utworzono i przetestowano 4 rodzajów sieci neuronowych (liczebność zbioru uczącego 300, testowego 20):

- Perceptron 3 - warstwowy (5, 10, 15 neuronów w warstwie ukrytej);
- Probabilistyczną sieć neuronową (100 neuronów w warstwie ukrytej).

Przykład SSN pokazano na rysunku 1.

### **Dobór pompy ciepła z wykorzystaniem programu „Statistica” dla zbiorów pełnych**

W programie tym utworzono i przetestowano 4 rodzajów sieci neuronowych (liczebność zbioru uczącego 300, testowego 20):

- Perceptron 3 - warstwowy (5, 10, 15 neuronów w warstwie ukrytej);
- Probabilistyczną sieć neuronową (50 neuronów w warstwie ukrytej).

Przykład SSN pokazano na rysunku 2.

Wyniki modelowania dla obydwu programów pokazano w tabeli 3 i na rysunku 3, błąd testowania  $B_s$  liczono wg wzoru 1.

## Dobór pomp ciepła...

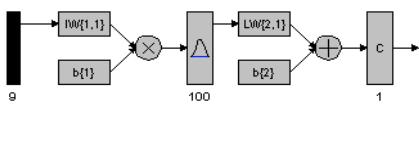
Tabela 3. Wyniki symulacji SSN w programie Statistica i Matlab dla zbiorów pełnych

Table 3. Results of the SSN simulation in Statistica and Matlab applications for complete sets

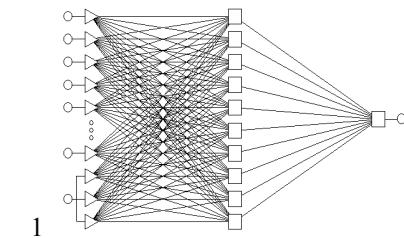
STATISTICA		MATLAB	
Typ SSN	Błąd testowania	Typ SSN	Błąd testowania
Perceptron 3 – warstwowy (5 neuronów w warstwie ukrytej)	$B_S = 4,47$	Perceptron 3 – warstwowy (5 neuronów w warstwie ukrytej)	$B_S = 0,43$
Perceptron 3 – warstwowy (10 neuronów w warstwie ukrytej)	$B_S = 1,88$	Perceptron 3 – warstwowy (10 neuronów w warstwie ukrytej)	$B_S = 0,3$
Perceptron 3 – warstwowy (15 neuronów w warstwie ukrytej)	$B_S = 5,61$	Perceptron 3 – warstwowy (15 neuronów w warstwie ukrytej)	$B_S = 0,00$
Probabilistyczna sieć neuronowa (50 neuronów)	$B_S = 1,91$	Probabilistyczna sieć neuronowa (100 neuronów)	$B_S = 0,00$

Źródło: Obliczenia własne autora

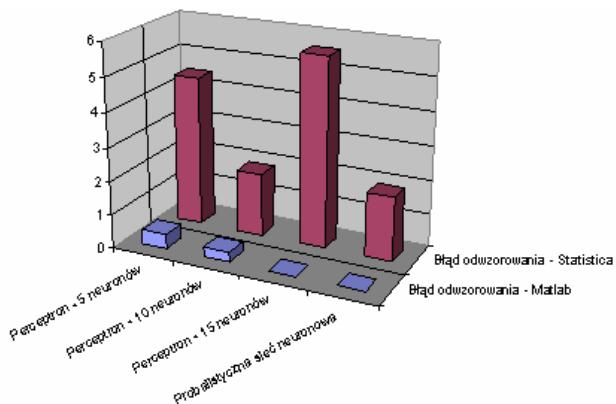
10



Rys. 1. Probabilistyczna sieć neuronowa (100 neuronów w warstwie ukrytej), Matlab  
Fig. 1. Probabilistic neural network (100 neurons in hidden layer), Matlab



Rys. 2. Wizualizacja sieci neuronowej (10 neuronów w warstwie ukrytej), Statistica  
Fig. 2. Neural network visualisation (10 neurons in hidden layer), Statistica



Rys 3. Wyniki symulacji SSN w programie Matlab i Statistica – błędy doboru pompy  
Fig. 3. Results of the SSN simulation in Matlab and Statistica applications – pump selection errors

### Testowanie sieci neuronowych na zbiorach niepełnych

Do badań wybrano najlepszy perceptron i sieć probabilistyczną dla każdego programu (Matlab" i „Statistica"). W przypadku programu „Matlab” najlepszym perceptronem okazał się: Perceptron 3 - warstwowy z 15 neuronami w warstwie ukrytej. W programie „Statistica” najlepszym perceptronem okazał się: Perceptron 3 - warstwowy z 10 neuronami w warstwie ukrytej.

Zbiory testujące podzielono na dwie grupy:

- do pierwszej grupy zalicza się zbiory pierwszy, drugi, trzeci i czwarty, w których brakuje odpowiednio następujących parametrów: wysokość pomieszczenia, grubość ocienia, temperatura wewnętrz i ukształtowanie budynku,
- w drugiej grupie jest zbiór piąty, w którym brakuje dwóch parametrów. Parametry te zostały określone na podstawie testowania przeprowadzonego na zbiorach z pierwszej grupy. Wybrano te dwa parametry, które uzyskały najmniejszy błąd w ramach testowania na zbiorach nr I - IV.

Wyniki pokazano w tabeli 5

Tabela 5. Uzyskane wyniki dla testowania przy zbiorach niepełnych  
Table 5. Results obtained for testing with incomplete sets

MATLAB			STATISTICA		
Typ SSN	Zbiór danych	Błąd testowania	Typ SSN	Zbiór danych	Błąd testowania
Perceptron 3 warstwowy (15 neuronów w warstwie ukrytej)	I	8,40	Perceptron 3 warstwowy (10 neuronów w warstwie ukrytej)	I	5,42
	II	6,39		II	6,08
	III	7,15		III	6,23
	IV	9,22		IV	3,50
	V	7,14		V	7,14
Probabilistyczna sieć klasyfikacyjna (100 neuronów w warstwie ukrytej)	I	0,00	Probabilistyczna sieć klasyfikacyjna (50 neuronów w warstwie ukrytej)	I	3,44
	II	2,04		II	3,44
	III	7,35		III	3,44
	IV	0,00		IV	3,44
	V	1,21		V	3,44

### Podsumowanie i wnioski

#### „Statistica”

- Z przeprowadzonych badań wynika, że najlepiej zadanie rozwiązał perceptron z 10 neuronami w warstwie ukrytej,  $B_S=1,88$ . Wyniki uzyskane przy pomocy probabilistycznej sieci neuronowej, na zbiorze pełnym, można również uznać za dobre,  $B_S=1,91$ .
- Niepowodzeniem zakończyła się próba wykonania testów sieci na zbiorze niepełnym, wyniki były zupełnie różne od oczekiwanych. Dla perceptronu, testowanego na zbiorze z dwoma brakującymi parametrami, błąd sieci wynosił  $B_S=7,14$ . W przypadku sieci

probabilistycznej, za każdym razem był taki sam wynik,  $B_S=3,44$ . Stąd wniosek, że sieci nie poradziły sobie z tym zadaniem.

#### „Matlab”

- W programie tym przeprowadzono testy na 5 typach sieci. Najmniejszy błąd testowania perceptronu trójwarstwowego uzyskano dla 15 neuronów w warstwie ukrytej,  $B_S=0,00$ . W tym przypadku można zaobserwować pewną prawidłowość, że im więcej neuronów w warstwie ukrytej tym wyniki są lepsze. Taki sam wynik uzyskano w czasie testowania probabilistycznej sieci neuronowej.
- Podczas próby testowania sieci typu perceptron, na zbiorze niepełnym uzyskane wyniki w niektórych przypadkach bardzo odbiegały od wyników rzeczywistych,  $B_S=9,22$  (błąd maksymalny). Stąd wniosek, że ten rodzaj sieci nie jest odpowiedni do rozwiązywania tego typu zadań klasyfikacyjnych.
- W przypadku sieci probabilistycznej podczas testowania na pierwszym i czwartym zbiorze niepełnym, uzyskano wyniki,  $B_S=0$ . Przy próbie testowania na drugim i trzecim zbiorze niepełnym wyniki były niezadowalające,  $B_S=7,35$  i  $B_S=2,04$ . Testowanie na zbiorze piątym, dało bardzo dobry wynik,  $B_S=1,21$ . Stąd wniosek, że w przypadku, braku mniej znaczących parametrów sieć udziela prawidłowe odpowiedzi.

SSN utworzone w programie Matlab nadają się do szybkiego doboru pomp ciepła dla domów jednorodzinnych o mocy odpowiadającej potrzebom konkretnego domu.

## Bibliografia

- Boniecki P.** 2002. The Comparison of Multilayer Perceptron Networks and Radial Networks with Regard to Their Use as Prediction Instruments in Agricultural Engineering Problems Journal of Research and Applications in Agricultural Engineering 3. s.38-45.
- Jack F.R., Steel G.M.** 2002. Modelling the sensory characteristics of Scotch whisky using neural networks – a novel tool for generic protection, Food Quality and Preference 13. s. 163.
- Liao Y., Fang S. C. Nuttle H.L.W.** 2004. A neural network model with bounded-weights for pattern classification, Computers & Operations Research 31. s. 1411.
- Neugebauer M., Nalepa K., Solowiej P.** 2007. Sieci neuronowe jako narzędzie umożliwiające prognozowanie zapotrzebowania na wodę w uprawach rolnych, Inżynieria Rolnicza nr 2(90). s. 205. Kraków.
- Partovi F.Y., Anandarajan M.** 2002. Classifying inventory using an artificial neural network approach, Computers & Industrial Engineering 41. s. 389.
- Rubik M.** 2006. Pompy ciepła. Poradnik. Wyd. Instal (TIB). ISBN 83-88695-19-3.
- Wanas N., Kamel M.S., Auda G., Karray F.** 1999. Feature-based decision aggregation in modular neural network classifiers. Pattern Recognition Letters 20. s. 1353.
- Materiały reklamowe firm produkujących pompy ciepła: ECO, Hibernatus, IVT Greenline, Ochsner, SOLIS, Spartec-Classic, Stiebel-Eltron, Thermia, Nibe, Viessmann.

## **SELECTION OF HEAT PUMPS SUPPORTED BY ARTIFICIAL NEURAL NETWORKS FOR SINGLE-FAMILY HOUSES FOR COMPLETE AND INCOMPLETE DATA SETS**

**Abstract.** The paper proposes a method allowing to select heat pumps using neural networks. Selection of heat pumps consists in calculating thermal power depending on parameters of a given house. The researchers created and tested several network types, taking into account testing on complete data sets (with all input parameters) and incomplete data sets (without one or two input parameters). The following parameters were missing for incomplete data sets: room height, thermal insulation thickness, inside temperature, and building configuration. The research involved using two applications for simulation of artificial neural networks: "Statistica" and "MATLAB".

**Key words:** artificial neural networks, heat pump selection, incomplete data set

**Adres do korespondencji:**

Maciej Neugebauer; e-mail: mak@uwm.edu.pl  
Katedra Elektrotechniki i Energetyki  
Uniwersytet Warmińsko-Mazurski w Olsztynie  
ul. Oczapowskiego 11  
10-736 Olsztyn