

MODELOWANIE NEURONOWE W OBLICZANIU WSPÓŁCZYNNIKA PRZENIKANIA CIEPŁA ORAZ WYMAGANEJ WARSTWY IZOLACJI PRZEGRODY BUDOWLANEJ

Jacek DAWIDOWICZ*, Wojciech SIDOROWICZ

Wydział Budownictwa i Inżynierii Środowiska, Politechnika Białostocka, ul. Wiejska 45 A, 15-351 Białystok

Streszczenie: W referacie przedstawiono zastosowanie sztucznych sieci neuronowych do obliczania współczynnika przenikania ciepła U oraz model odwrotny, polegający na obliczaniu grubości warstwy izolacyjnej przy zadanym współczynniku. Opisano metodykę sporządzenia zbioru uczącego sztuczne sieci neuronowe oraz opisano zbiór przetestowanych sieci neuronowych. Metody sztucznej inteligencji, w tym sztuczne sieci neuronowe, pozwalają uwzględnić w obliczeniach wiele zjawisk i procesów trudnych do opisu matematycznego ze względu na swoją nieliniowość, stąd uzyskane modele neuronowe będą uzupełniane w przyszłości o dodatkowe parametry obliczeniowe.

Słowa kluczowe: straty ciepłne, współczynnik przenikania ciepła, modelowanie neuronowe, inteligencja obliczeniowa.

1. Wprowadzenie

Obiekty budowlane są największym użytkownikiem końcowej energii. Prawie 40% światowej energii końcowej jest zużywane przez budynki, włączając w to oświetlenie, zainstalowane urządzenia i sprzęt. W związku z tym występują, znaczące i efektywne kosztowo możliwości, aby ograniczyć zużycie energii w budynkach. Obecne trendy budowlane, jak i w szerszym ujęciu polityczne, mają na celu ograniczenie zużycia energii i wytwarzania gazów cieplarnianych, a także zapewnienie zrównoważonego rozwoju społeczeństw (Boermans i Petersdorff, 2008).

Technika komputerowa stosowana jest powszechnie w zagadnieniach projektowania, wykonawstwa i eksploatacji w wielu dziedzinach. Odnosi się to również do obliczeń strat ciepłych w budownictwie. Oczekiwania w stosunku do programów komputerowych nie ograniczają się obecnie do wykonywania obliczeń. Coraz częściej dąży się do stworzenia systemów komputerowych, które będą charakteryzowały się, chociaż w niewielkim stopniu pracą kreatywną, wspomagały projektanta. W ostatnich latach mamy do czynienia z burzliwym rozwojem metod obliczeniowych, które bazują na gromadzeniu danych o problemie i odpowiednim ich przetwarzaniu. W zakres powyższego podejścia wchodzi takie metody jak sztuczne sieci neuronowe, algorytmy ewolucyjne, systemy rozmyte, systemy eksperckie. Wymienione techniki można objąć wspólną nazwą metod sztucznej inteligencji lub inteligencji obliczeniowej (Rutkowski, 2005).

W niniejszym artykule zaprezentowano wyniki

eksperymentów numerycznych, dotyczących trenowania sztucznych sieci neuronowych, pozwalających obliczać współczynnik przenikania ciepła U przez wielowarstwowe przegrody budowlane. Celem pracy było uzyskanie modeli neuronowych, które będą podstawą do dalszych prac nad zastosowaniem metod inteligencji obliczeniowej w zagadnieniach obliczeń strat ciepłych w budynkach.

2. Obliczenia strat ciepłych

Jednym z najważniejszych parametrów, który opisuje przegrody budowlane oraz określa przenikanie przez nie ciepła, jest współczynnik przenikania ciepła U . Zależny jest on od grubości i materiału z jakiego wykonana jest przegroda. Im wartość współczynnika mniejsza, tym straty ciepła są niższe i przegroda ma lepsze parametry izolacyjne.

2.1. Potrzeba dokładnych obliczeń strat ciepłych

Jedną z najistotniejszych ról podczas procesu projektowania budynków oraz charakterystyk energetycznych budynków już istniejących, stanowi obliczanie strat ciepłych. Straty ciepłne określane są przez ilość ciepła straconego przez przenikanie ciepła przez przegrody oraz ilość ciepła potrzebna do ogrzania powietrza wentylacyjnego napływającego z zewnątrz. Straty te zależą głównie od pola powierzchni przegrody, ich właściwości termoizolacyjnych (współczynnik U) oraz od różnicy temperatur. Dlatego, zwraca się szczególną uwagę aby budynki były energooszczędne i przyjazne

* Autor odpowiedzialny za korespondencję. E-mail: jacek.dawidowicz@pb.edu.pl

środowisku. Dokumentem, który określa wielkość zapotrzebowania energii niezbędnej do zaspokojenia potrzeb związanych z użytkowaniem budynku lub lokalu czyli energii na potrzeby ogrzewania, ciepłej wody, wentylacji i klimatyzacji jest świadectwo charakterystyki energetycznej – certyfikat energetyczny. Świadectwo jest źródłem oceny jakości użytkowej i wartości rynkowej budynku lub lokalu, stanowi obiektywną ocenę cech energetycznych budynków, lokali oraz wyodrębnionych części, jest również narzędziem, które pozwala na stymulowanie oszczędności energii w budynkach oraz lokalach mieszkalnych. Każdy certyfikat energetyczny powinien zawierać: podstawowe dane dotyczące budynku i wielkości energii niezbędnej do ogrzania, ciepłej wody, klimatyzacji oraz wentylacji, a dodatkowo dla budynków niemieszkalnych także energii na potrzeby oświetlenia oraz wskaźniki porównawcze. Główną cechą certyfikatu są wytyczne oraz wskazania możliwych usprawnień dla obniżenia zapotrzebowania energii. Zmniejszone wydatki na energię przyczyniają się do zmniejszenia kosztów eksploatacji budynków oraz do zmniejszenia w przyszłości zużycia energii w skali globalnej, co zmniejszy emisję gazów cieplarnianych.

2.2. Straty ciepła na zewnątrz budynku

Wartość współczynnika straty ciepła przez przenikanie z przestrzeni ogrzewanej (i) na zewnątrz (e) $H_{T,ie}$ zależy od wymiarów i cech charakterystycznych elementów budynku oddzielających przestrzeń ogrzewaną od środowiska zewnętrznego, takich jak ściany, podłogi, stropy, drzwi i okna. Według normy PN-EN 12831: 2006 do obliczeń uwzględnia się również liniowe mostki cieplne (Strzeszewski i Wereszczyński, 2007):

$$H_{T,ie} = \sum_k A_k \cdot U_k \cdot e_k + \sum_l \psi_l \cdot l_l \cdot e_l \quad [W / K] \quad (1)$$

gdzie A_k jest powierzchnią elementu budynku (k) w m^2 , U_k jest współczynnikiem przenikania ciepła przegrody (k) w W/m^2K , ψ_l jest współczynnikiem przenikania ciepła liniowego mostka cieplnego (l) w W/mK , l_l jest długością liniowego mostka cieplnego (l) między przestrzenią wewnętrzną a zewnętrzną w m, e_k , e_l oznaczają współczynniki korekcyjne ze względu na orientację, z uwzględnieniem wpływów klimatu; takich jak: różne izolacje, absorpcja wilgoci przez elementy budynku, prędkość wiatru i temperatura powietrza, w przypadku gdy wpływy te nie zostały wcześniej uwzględnione przy określaniu wartości współczynnika U_k .

Współczynnik przenikania ciepła U_k należy obliczać według:

- normy EN ISO 6946 – dla elementów nieprzezroczystych;
- normy EN ISO 10077-1 – dla drzwi i okien;
- lub na podstawie zaleceń podanych w europejskich aprobatkach technicznych.

Współczynnik przenikania ciepła liniowego mostka cieplnego ψ_l powinien być określony według normy lub w sposób przybliżony z wykorzystaniem wartości stabelaryzowanych podanych w normie.

W przypadku obliczeń metodą „pomieszczenie po pomieszczeniu”, konieczny jest podział wartości współczynnika przenikania ciepła mostka pomiędzy pomieszczenia, jeśli mostek cieplny znajduje się na granicy pomieszczeń (np. strop przecinający izolację ściany zewnętrznej). W obliczeniach nie uwzględnia się nieliniowych mostków cieplnych. Orientacyjne wartości współczynników korekcyjnych podane są w załączniku krajowym do normy PN-EN 12831: 2006.

2.3. Metodyka obliczeń współczynnika przenikania ciepła U

Współczynnik przenikania ciepła to stosunek strumienia cieplnego do powierzchni przegrody i różnicy temperatury po obu jej stronach. Oznacza się go literą U i podaje w W/m^2K . Do obliczenia wartości tego współczynnika uwzględnia się materiał z jakiego są zrobione wszystkie warstwy przegrody, grubość tych warstw oraz rodzaj samej przegrody. Bierze się także pod uwagę braki i nieszczelności izolacji, jeśli takie występują oraz ewentualne mostki termiczne – wartość współczynnika U wzrasta. Najprostszym sposobem wyznaczenia współczynnika przenikania ciepła, jest obliczenie dla najmniej skomplikowanej przegrody jaką jest ściana zewnętrzna bez otworów (okien i drzwi) oraz nie stykająca się z gruntem. Do jego wyliczenia niezbędna jest znajomość wyznaczanego doświadczalnie współczynnika przewodzenia ciepła – λ (lambda) dla wszystkich materiałów, z jakich zrobiona jest ściana. Wartości współczynnika λ można znaleźć w odpowiednich tabelach (PN-EN ISO 6946: 1999). Przyjmuje się go dla średnich warunków wilgotnościowych. Służy do wyliczenia oporu cieplnego poszczególnych warstw przegrody $R_i = d_i/\lambda_i$, gdzie d_i jest grubością warstwy w metrach. Uwzględnia się także opór przejmowania ciepła na stronie zewnętrznej (R_{se}) i wewnętrznej (R_{si}) przegrody. To również są wielkości wyznaczone i podane w tej samej normie. W praktyce $R_{si} + R_{se} = 0,17 W/m^2K$ (zakłada się poziomy przepływu strumienia cieplnego przez przegrodę). Całkowity opór cieplny przegrody to suma oporów poszczególnych warstw oraz oporu przejmowanie ciepła po stronie wewnętrznej i zewnętrznej przegrody. Współczynnik przenikania ciepła jest odwrotnością całkowitego oporu cieplnego $U = 1/R$. Obliczenia wykonuje się, zakładając pewne uproszczenia, które w zupełności wystarczające do praktycznych inżynierskich zastosowań. Zakłada się, że strumień ciepła jest stały w czasie i prostopadły do powierzchni, długość i szerokość przegrody są nieskończone, warstwy przegrody są jednorodne i izotropowe, ciepło jest przejmowane jednakowo na całej powierzchni (zewnętrznej i wewnętrznej – R_{si} i R_{se} są jednakowe na całej powierzchni). Uwzględnia się także szereg poprawek, które wynikają z niedoskonałości przegrody, np. nieszczelności, poprzez zwiększenie wartości współczynnika przenikania o określoną wartość liczbową.

2.4. Wymagane wartości współczynnika U

Przy analizowaniu izolacyjności cieplnej poszczególnych przegród można posługiwać się wartościami granicznymi współczynnika U . Współczynnik przenikania ciepła dla przegrody powinien spełniać normę, która zależy od tego, jaką temperaturę powinno mieć pomieszczenie. Określa się maksymalne współczynniki ciepła dla przegrody. W budynku jednorodinnym wymagania te według normy zamieszczono w tab. 1.

Tab. 1. Maksymalne współczynniki ciepła dla przegrody w budynku jednorodinnym

Rodzaj przegrody	Temperatura w pomieszczeniu	Współczynnik przenikania ciepła U
Ściany zewnętrzne warstwowe, stykające się z powietrzem zewnętrznym	$T_i > 16^{\circ}\text{C}$	0,30
Ściany zewnętrzne pozostałe, stykające się z powietrzem zewnętrznym	$T_i > 16^{\circ}\text{C}$	0,50
Ściany zewnętrzne, stykające się z powietrzem zewnętrznym, niezależnie od rodzaju ściany	$T_i \leq 16^{\circ}\text{C}$	0,80

T_i jest wewnętrzną temperaturą obliczeniową

Dla budynków użyteczności publicznej minimalne wartości współczynników przenikania ciepła wynoszą:

- dla ścian zewnętrznych pełnych $U = 0,45 \text{ W/m}^2 \cdot \text{K}$;
- dla ścian zewnętrznych z otworami okiennymi i drzwiowymi $U = 0,55 \text{ W/m}^2 \cdot \text{K}$;
- dla ścian zewnętrznych z otworami okiennymi i drzwiowymi oraz ze wspornikami balkonu przenikającymi ścianę $U = 0,65 \text{ W/m}^2 \cdot \text{K}$;
- dla stropu pod nie ogrzewanym poddaszem lub stropodachu $U = 0,30 \text{ W/m}^2 \cdot \text{K}$;
- dla stropu nad nieogrzewanymi piwnicami $U = 0,60 \text{ W/m}^2 \cdot \text{K}$;
- dla okien i drzwi balkonowych $U = 2,6 \text{ W/m}^2 \cdot \text{K}$.

W istniejących budynkach, których powyższe wartości współczynnika U nie są spełnione, należy dążyć, poprzez kapitalny remont, przebudowę lub modernizację, do dostosowania przegród zewnętrznych co najmniej do obecnych wymagań.

2.5. Programy komputerowe do obliczeń strat cieplnych

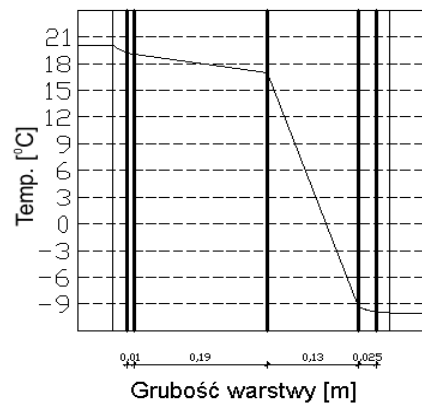
Obecnie dostępnych jest wiele programów komputerowych do obliczania strat cieplnych w budynkach oraz współczynników przenikania ciepła. Jak dotąd nie wykorzystują one technik inteligencji obliczeniowej. Jednym z takich programów jest Instal-OZC 4.7, który posłużył do zweryfikowania uzyskanych obliczeń przy użyciu sztucznych sieci neuronowych.

Program Instal-OZC 4.7 służy do wykonywania następujących obliczeń:

- współczynników przenikania U (lub oporu cieplnego R) przegród budowlanych;
- kontroli punktu rosy na wewnętrznej powierzchni

- przegród zewnętrznych;
- kontroli wykroplenia wewnątrz przegród zewnętrznych;
- strat ciepła pomieszczeń i całego budynku;
- bilansu powietrza wentylacyjnego dla mieszkań;
- sezonowego zapotrzebowania na ciepło na cele ogrzewania i wskaźnika E ;
- temperatur powietrza w pomieszczeniach nieogrzewanych na podstawie bilansu cieplnego;
- doboru grzejników konwekcyjnych centralnego ogrzewania wodnego.

Współczynnik przenikania jest liczony automatycznie. Program ponadto kreśli schematy spadku temperatury w przegrodzie (rys. 1).



Rys. 1. Przykładowy schemat spadku temperatury w przegrodzie budowlanej wielowarstwowej

3. Podstawy modelowania neuronowego

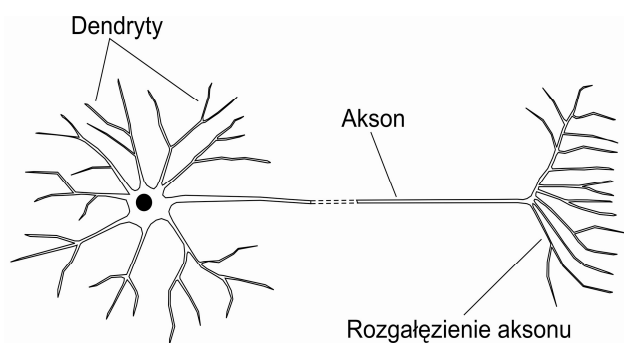
Sieci neuronowe zostały opracowane na podstawie badań, które dotyczyły budowy modeli podstawowych struktur występujących w mózgu. Stanowią próbę wykorzystania zjawisk zachodzących w systemach nerwowych przy poszukiwaniu nowych rozwiązań technologicznych. Podstawowymi składnikami sieci są połączone ze sobą elementy przetwarzające zwane neuronami. Na sposób działania sieci wpływa liczba neuronów, przyjęty model neuronu oraz struktura sieci neuronowej. Neurony grupowane są w warstwy. Podstawowym elementem dla prawidłowego funkcjonowania sieci jest prawidłowy dobór wartości parametrów neuronów, czyli wag i wartości progowych (Bishop, 1995; Żurada i in., 1996; Tadeusiewicz, 1993; Mulawka, 1991).

3.1. Neuron biologiczny a model neuronu

Można zadać sobie pytanie, skąd wziął się pomysł stworzenia narzędzia obliczeniowego w postaci sztucznych sieci neuronowych. Pod koniec XIX wieku Ramon y Cajal, hiszpański anatom, wykazał, że układ nerwowy jest strukturą złożoną z wielu, podobnych pod względem funkcjonalnym, komórek nerwowych (neuronów). Odkrycie to otworzyło nowy rozdział w badaniach i rozumieniu funkcji mózgu. Z jednej strony badano funkcjonowanie pojedynczych neuronów,

z drugiej strukturę i współdziałanie neuronów (Wróbel, 1997).

W systemach nerwowych występuje bardzo duża liczba komórek nerwowych, czyli neuronów. Podstawowym zadaniem neuronów jest przyjmowanie, przewodzenie i przekazywanie sygnałów. Neurony (rys. 2) tworzą niezwykle skomplikowane sieci informacyjne, w których sygnały przechodzą z jednego neuronu do drugiego, umożliwiając analizę i interpretowanie sygnałów dochodzących z narządów zmysłów oraz odpowiadanie na te sygnały (Alberts i in., 2005).



Rys. 2. Schemat neuronu biologicznego (Alberts i in., 2005)

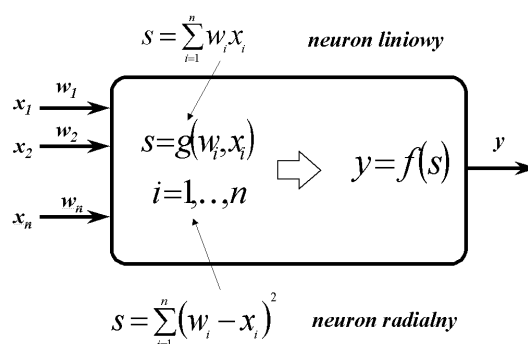
Transmisja sygnałów w systemie nerwowym jest bardzo złożonym procesem elektrochemicznym. Wychodzący sygnał z neuronu jest rozsyłany do wielu innych neuronów poprzez rozgałęzienia na końcu aksonu. Bezpośrednie połączenie rozgałęzionego aksonu jednego neuronu z dendrytami innych neuronów odbywa się za pośrednictwem biochemicznych złączy tak zwanych synaps. Działanie synaps może powodować wzmacnianie lub osłabianie sygnału, stąd część sygnałów dochodzących do neuronu może mieć charakter pobudzający, a część hamujący. W przypadku, gdy bilans pobudzeń i hamowań z poszczególnych synaps, przekroczy próg uaktywniający komórkę, wówczas sygnał wyjściowy narasta i powstaje impuls nerwowy. Przejście od stanu beczynności do stanu generacji impulsu zachodzi w typowych neuronach bardzo gwałtownie, dlatego mówi się często o „zapłonie” neuronu.

Powyższy, ogólny opis budowy i funkcjonowania neuronu biologicznego był inspiracją do stworzenia modelu matematycznego neuronu. Model neuronu (rys. 3) definiuje jego strukturę oraz opisuje sposób działania. Sztuczny neuron składa się z następujących elementów (Osowski, 1996; Korbicz i in., 1994; StatSoft Inc., 2001a):

- wejścia - służą do wprowadzenia informacji do neuronu;
- parametry: wagi związane z wejściami do neuronu, tworzące wektor wag; dodatkowym parametrem neuronu jest wartość progowa, po przekroczeniu której następuje aktywacja neuronu; proces uczenia sztucznej sieci neuronowej, polega na prawidłowym dobraniu wartości parametrów wszystkich neuronów z których jest zbudowana;
- funkcja potencjału postsynaptycznego (rys. 1) - funkcja dokonująca agregacji wektora danych wejściowych neuronu w pojedynczą wartość zwaną

zagregowaną wartością wejściową lub łącznym pobudzeniem neuronu. Sposób przeprowadzania agregacji jest uzależniony od typu zastosowanej funkcji PSP (*Post Synaptic Potential function*). Podstawowe jej rodzaje to: liniowa funkcja PSP i radialna funkcja PSP;

- funkcja aktywacji - jest to funkcja pozwalająca na wyznaczenie wartości wyjściowej neuronu na podstawie zagregowanej wartości wejściowej; najczęściej stosowane są funkcje: liniowa, logistyczna, tangensoidalna, Gaussa;
- wyjście - służy do wyprowadzenia na zewnątrz neuronu wartości wyjściowej wyznaczonej przez funkcję aktywacji.



Rys. 3. Schemat modelu neuronu

3.2. Rodzaje sieci neuronowych i uczenie nadzorowane

Modele neuronów są podstawowymi elementami składowymi sztucznych sieci neuronowych, zlokalizowanymi w węzłach sieci odpowiednio ze sobą połączonymi. Z powodu różnych sposobów połączenia neuronów i ich wzajemnego współdziałania, można wyróżnić trzy najważniejsze grupy sieci:

- sieci jednokierunkowe, o kierunku przepływu sygnału - od wejścia do wyjścia;
- sieci rekurencyjne, w strukturze których występują sprzężenia zwrotne, tzn. wyjście przynajmniej jednego neuronu jest połączone pośrednio lub bezpośrednio z jego wejściem;
- sieci komórkowe, których topologia oparta jest na dowolnej regularnej strukturze geometrycznej, najczęściej będącej płaską siatką prostokątną.

W niniejszej pracy wykorzystano następujące rodzaje jednokierunkowych sztucznych sieci neuronowych:

- liniowe (*linear network*);
- perceptron wielowarstwowy (MLP - *multilayer perceptron*).


Wiedza sieci neuronowej zgromadzona jest w wagach połączeń między neuronami, stąd bardzo ważne jest odpowiednie ustalenie ich wartości, co przeprowadzane jest w procesie uczenia. Metody uczenia sieci jednokierunkowych typu perceptron wielowarstwowy modyfikują jedynie wagi, pozostawiając architekturę sieci bez zmian. Wynika stąd, że w pierwszej kolejności należy podjąć decyzję o liczbie warstw oraz liczbie i rodzaju neuronów w każdej warstwie. Następnie w procesie uczenia ustala się wartości wag wszystkich neuronów

dążąc do minimalizacji błędu działania sieci. Zadanie to jest realizowane przez odpowiedni algorytm uczenia.

Znanych jest wiele metod uczenia sieci typu perceptron wielowarstwowy, określających kiedy i w jaki sposób zmieniają się wagi połączeń pomiędzy neuronami. W programie STATISTICA Neural Networks dostępne są m.in. następujące metody:

- wstecznej propagacji błędów;
- szybkiej propagacji błędów;
- gradientów sprzężonych;
- Quasi-Newtona (metoda zmiennej metryki BFGS).

Sieci typu perceptron wielowarstwowy uczone są przy użyciu strategii z nauczycielem. W przypadku uczenia nadzorowanego (z nauczycielem, rys. 4), sieci neuronowej prezentowany jest zbiór przykładów uczących, składających się z par w postaci wektora danych wejściowych oraz odpowiadających mu poprawnych (znanych) odpowiedzi, w postaci wartości numerycznej lub wartości nominalnej, opisującej stan, sytuację, decyzję, konkluzję, itp. Na podstawie tych danych algorytm uczący modyfikuje wartości parametrów sieci i próbuje generować wyniki sieci najbardziej zbliżone do zadanych wartości wyjściowych. Proces uczenia polega więc na wypracowaniu umiejętności generowania przez sieć neuronową poprawnych odpowiedzi. Obserwacja danych wejściowych i odpowiadających im wartości wyjściowych z sieci, pozwala ocenić proces uczenia i jego postęp. Informacja ucząca uzyskana w ten sposób określana jest mianem nauczyciela. Sieci neuronowe są jednym z rodzajów tzw. systemów uczących się. W procesie uczenia system uczący się, czyli w tym wypadku sieć neuronowa, pełni rolę ucznia (rys. 4) (Cichosz, 2000).



Rys. 4. Schemat zasady uczenia nadzorowanego (Cichosz, 2000)

3.4. Perceptron wielowarstwowy

Obecnie najczęściej stosowanym rodzajem jednokierunkowej sztucznej sieci neuronowej jest perceptron wielowarstwowy, który składa się z wielu neuronów ułożonych w warstwy. Neurony połączone są pomiędzy warstwami na zasadzie „każdy z każdym”, natomiast w jednej warstwie nie występują połączenia pomiędzy neuronami. Do każdego z połączeń przypisany jest współczynnik wagowy. Wykorzystuje się powyższy sposób połączeń, gdyż w procesie uczenia wagi nieistotnych połączeń zostaną wyzerowane, co jest jednoznaczne z brakiem połączenia. Wyróżnia się trzy podstawowe typy warstw: warstwę wejściową, wewnętrzne warstwy ukryte oraz warstwę wyjściową.

Sieci jednokierunkowe wielowarstwowe zawsze posiadają warstwę wejściową i wyjściową oraz przynajmniej jedną warstwę ukrytą. Liczba warstw ukrytych i neuronów w poszczególnych warstwach sieci tego typu wpływa na możliwości odwzorowania zależności reprezentowanej przez zbiór wektorów wejściowych oraz odpowiadających im żądanych wartości wyjściowych.

3.5. Ocena jakości jednokierunkowej sieci neuronowej

Wszystkie wymienione wyżej metody uczenia sieci jednokierunkowych, związane są z redukcją wartości funkcji błędu, która w ogólnym przypadku jest nieliniową funkcją macierzy wag. Do oceny jakości działania sieci potrzebny jest globalny błąd obliczony dla wszystkich wzorców ze zbioru uczącego. Funkcja błędu sieci neuronowej może przybierać różne formy, lecz w przypadku uczenia nadzorowanego jest to pewna miara rozbieżności pomiędzy aktualnymi wartościami sygnałów neuronów warstwy wyjściowej a wartościami zadanymi.

Podstawową funkcją błędu jest błąd wyznaczany według zasady najmniejszych kwadratów, określane jako Suma-Kwadratów (SSE – *Sum Squared Error*). Łączny błąd uczenia sieci otrzymuje się w wyniku sumowania kwadratów błędów po wszystkich wzorcach uczących T ($t = 1, \dots, T$) i wyjściach sieci M ($m = 1, \dots, M$).

$$E_{SSE} = \sum_{t=1}^T \sum_{m=1}^M (d_m^{(t)} - y_m^{(t)})^2 \quad (2)$$

Powyższa funkcja błędu występuje również z pomocniczym współczynnikiem liczbowym w postaci:

$$E = \frac{1}{2} \sum_{t=1}^T \sum_{m=1}^M (d_m^{(t)} - y_m^{(t)})^2 \quad (3)$$

4. Wybór i uczenie sieci neuronowych

Do symulacji sztucznych sieci neuronowych wykorzystano program STATISTICA Neural Networks (StatSoft Inc., 1998, 2001a, 2001b, 2001c, 2001d). Przeprowadzono doświadczenia mające na celu ustalenie właściwych struktur sieci neuronowych, określenie wpływu poszczególnych wejść na sposób działania sieci. Proces uczenia poszczególnych struktur sieci neuronowych prowadzono kilkakrotnie, w celu uniknięcia minimum lokalnego funkcji błędu.

4.1. Metodyka sporządzenia zbioru danych uczących sieci neuronowe

Zastosowanie techniki neuronowej wymaga przygotowania zbioru danych uczących oraz zapewnienia odpowiedniej ich liczby, w celu przeprowadzenia procesu uczenia sztucznej sieci neuronowej. Zbiór ten powinien być reprezentatywny, aby mógł być traktowany jako próba losowa pobrana z populacji wszystkich możliwych przykładów dla danego problemu. Do przygotowania

danych został opracowany arkusz kalkulacyjny Excel, przy użyciu którego uzyskano 4050 przykładów uczących, zawierających zmienne wejściowe i wyjściowe do sieci neuronowych. W analizowanych sieciach neuronowych, brane były pod uwagę następujące zmienne:

- współczynniki przewodności cieplnej poszczególnych warstw;
- grubości poszczególnych warstw przegrody.

Obliczenia współczynnika przenikania ciepła U przeprowadzono według metodyki zamieszczonej w PN-EN ISO 6946:1999. „Komponenty budowlane i elementy budynku. Opór cieplny i współczynnik przenikania ciepła”. Współczynniki przewodzenia ciepła λ przyjęto dla warunków średniowilgotnych.

Obliczenia wykonano dla przegrody składającej się z następujących warstw, zakresie ich grubości i wartości λ :

- tynk zewnętrzny cementowo – wapienny, grubość: 0,01 - 0,025 m, $\lambda = 0,820$ W/m·K;
- mur z cegły ceramicznej pełnej, grubość: 0,065 - 0,480 m, $\lambda = 0,770$ W/m·K;
- styropian, grubość: 0,060-0,200 m, $\lambda = 0,043$ W/m·K;
- tynk wewnętrzny, grubość: 0,005 - 0,015 m, $\lambda = 0,820$ W/m·K.

Obliczenia wykonano dla różnych kombinacji grubości warstw przegrody w celu uzyskania pełnej reprezentacji zmienności warstw i odpowiadających im wartości współczynnika przenikania ciepła do uczenia sieci neuronowej.

4.2. Model neuronowy do obliczania współczynnika przenikania ciepła U

Jakość wyników uzyskiwanych za pomocą sieci neuronowych jest w znacznym stopniu uzależniona od doboru odpowiedniej struktury sieci. Sieć wytrenowana na ograniczonym zbiorze uczącym, powinna uogólniać zdobytą wiedzę i wyznaczać poprawne wartości dla danych, które nie były używane w procesie uczenia, lecz należące do określonej populacji. Model neuronowy powinien odwzorowywać ogólną postać poszukiwanej zależności, a nie przystosowywać się wyłącznie do punktów ze zbioru uczącego. Cecha ta określana jest jako zdolność do generalizacji (uogólniania) nabytej wiedzy. W celu kontroli zdolności do generalizacji sieci w trakcie jej uczenia, zbiór danych dzielony jest na trzy części:

- zbiór uczący - wykorzystywany do uczenia sieci;
- zbiór walidacyjny - przypadki z tego zbioru nie są wykorzystywane do modyfikacji parametrów sieci w procesie uczenia, lecz do niezależnej, przeprowadzanej równoległe z procesem uczenia oceny jakości i zdolności do generalizacji;
- zbiór testowy - nie jest w ogóle wykorzystywany w trakcie uczenia, pozwala na wykonanie końcowej oceny jakości działania sieci po zakończonym procesie uczenia.

Przystępując do rozwiązania problemu przy użyciu sztucznych sieci neuronowych, w pierwszej kolejności

należy przeprowadzić uczenie sieci liniowej. Może okazać się, że stanowi ona wystarczająco dobre rozwiązanie problemu. Ogólna zasada stosowana w nauce mówi, że w przypadku, gdy istnieje możliwość wyboru pomiędzy modelem prostym i bardziej złożonym, należy preferować model prostszy, pod warunkiem, że ten drugi nie odwzorowuje znacznie lepiej szukanej zależności.

Neuronowe sieci liniowe są bardzo proste pod względem struktury, jednak w wielu przypadkach są sieciami bardzo użytecznymi. W programie ST Neural Networks sieci liniowe tworzone są z dwóch warstw: wejściowej i wyjściowej. W związku z powyższym w pierwszej kolejności został sporządzony neuronowy model liniowy (rys. 5), stanowiący poziom odniesienia dla kolejnych sieci neuronowych. Następnie przetestowano sieci typu perceptron wielowarstwowy z jedną (rys. 6) i dwoma warstwami ukrytymi (rys. 7). W tabeli 2 zamieszczono błędy uczenia przetestowanych sieci dla zbiorów: uczącego, walidacyjnego i testowego. Wszystkie warstwy posiadały 8 wejść odpowiadających grubości i współczynnikiowi λ poszczególnych warstw przegrody.

W niniejszej pracy zastosowano funkcję błędu Suma-Kwadratów, opisaną wzorem (2).

Tab. 2. Wartości błędu uczenia dla przetestowanych sieci neuronowych

Typ	W1	W2	Błąd ucz.	Błąd wal.	Błąd tst.
Lin.	-	-	0,03663	0,0357	0,03762
MLP	4	-	0,00146	0,00149	0,00145
MLP	4	4	0,00089	0,00091	0,00090

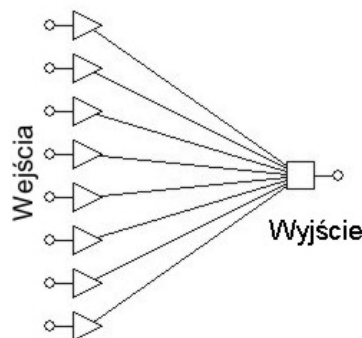
Lin. jest siecią liniową,

MLP jest perceptronem wielowarstwowym,


W1 jest liczbą neuronów w pierwszej warstwie ukrytej,

W2 jest liczbą neuronów w drugiej warstwie ukrytej.

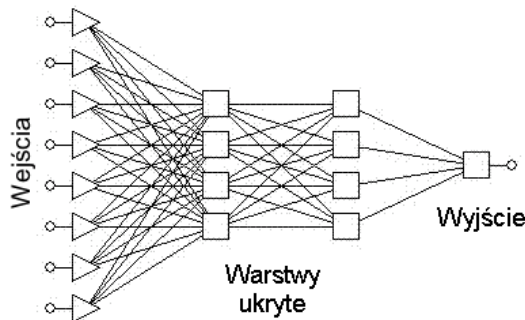
Najmniejszy błąd uczenia uzyskano w przypadku perceptronu wielowarstwowego, w którym zastosowano po 4 neurony w każdej warstwie ukrytej. Na rys. 8 zamieszczono ocenę zgodności wyników uzyskanych z dwuwarstwowej sieci typu perceptron wielowarstwowy U.MLP z odpowiednimi zadanymi wartościami współczynnika przenikania ciepła U .




Rys. 5. Schemat sieci liniowej do obliczania współczynnika przenikania ciepła U



Rys. 6. Schemat sieci neuronowej perceptronowej z jedną warstwą ukrytą



Rys. 7. Schemat sieci neuronowej perceptronowej z dwiema warstwami ukrytymi do obliczania U



Rys. 8. Ocena zgodności wyników sieci MLP z obliczonymi wartościami U

4.3. Model neuronowy do obliczania wymaganej grubości izolacji przegrody budowlanej


Kolejnym etapem badań było opracowanie modelu neuronowego do obliczania grubości warstwy izolacyjnej na podstawie zadane współczynnika przenikania ciepła. W tab. 3 zamieszczono zestawienie sieci neuronowych i błędów uczenia dla poszczególnych podzbiorów zbioru uczącego.

Tab. 3. Wartości błędu uczenia dla przetestowanych sieci neuronowych

Typ	W1	W2	Błąd ucz.	Błąd wal.	Błąd tst.
Lin.	-	-	0,01393	0,01364	0,01444
MLP	5	-	0,00048	0,00047	0,00048
MLP	7	5	0,00069	0,00069	0,00070

Lin. jest siecią liniową, MLP jest perceptronem wielowarstwowym, W1 jest liczbą neuronów w pierwszej warstwie ukrytej, W2 jest liczbą neuronów w drugiej warstwie ukrytej.

Podobnie jak w przypadku sieci neuronowej do obliczania współczynnika przenikania ciepła, do obliczania grubości izolacji (styropianu) najlepsza okazała się sieć typu perceptron wielowarstwowo z dwoma warstwami ukrytymi (rys. 9).



Rys. 9. Schemat sieci neuronowej perceptronowej z dwiema warstwami ukrytymi do obliczania grubości izolacji

5. Podsumowanie i wnioski

W referacie opisano próbę wykorzystania sieci neuronowych do obliczeń współczynnika strat ciepłych U oraz grubości izolacji przegrody budowlanej wielowarstwowo. Uzyskano bardzo wysoką zbieżność wyników z sieci neuronowej z wynikami uzyskanymi w arkuszu kalkulacyjnym oraz w programie komputerowym Instal-OZC. Zdolność sieci neuronowych do modelowania zależności nieliniowych wskazuje, że do zbiorów uczących powyższe sieci można wprowadzić dodatkowe zmienne, nie uwzględnione w dotychczasowej metodyce obliczeniowej.

Literatura

Alberts B., Bray D., Hopkin K., Johnson A., Lewis J., Raff M., Roberts K., Walter P. (2005). Podstawy biologii komórki, Część 1. Przekład zbiorowy pod red. Knity H. i Wojtaszka P. Wydawnictwo Naukowe PWN. Warszawa.
 Bishop C. M. (1995). Neural Networks for Pattern Recognition. Oxford University Press, Oxford.
 Boermans T., Petersdorff C. (2008). Wartości współczynnika przenikania ciepła U dla lepszej efektywności energetycznej

- budynków. Raport opracowany przez ECOFYS dla EURIMA. *Wydawca wersji polskiej: MIWO Stowarzyszenie Producentów Wełny Mineralnej: Szklanej i Skalnej.* Bruksela.
- Cichosz P. (2000). *Systemy Uczące się.* Wydawnictwa Naukowo-Techniczne. Warszawa.
- Korbicz J., Obuchowicz A., Uciński D. (1994). *Sztuczne Sieci Neuronowe. Podstawy i Zastosowania.* Akademicka Oficyna Wydawnicza PLJ. Warszawa.
- Mulawka J. J. (1991). *Wprowadzenie w dziedzinę sztucznych sieci neuronowych.* W: Materiały seminarium Ośrodka Informacji Naukowej PAN „Systemy Ekspertowe i Sztuczne Sieci Neuronowe”. Warszawa 1991.
- Osowski S. (1996). *Sieci Neuronowe.* Oficyna Wydawnicza Politechniki Warszawskiej. Warszawa.
- Rutkowski L. (2005). *Metody i techniki sztucznej inteligencji. Inteligencja obliczeniowa.* Wydawnictwo Naukowe PAN. Warszawa.
- Strzeszewski M., Wereszczyński P. (2007). *Norma PN-EN 12831. Nowa metoda obliczania projektowego obciążenia cieplnego.* Poradnik. Purmo. Warszawa.
- Tadeusiewicz R. (1993). *Sieci neuronowe.* Akademicka Oficyna Wydawnicza. Warszawa.
- Wróbel A. (1997). *Neuron i sieci neuronowe.* W: *Mózg a zachowanie,* pod red. Górskiej T., Grabowskiej A., Zagrodzkiej J., *Wydawnictwo Naukowe PWN.* Warszawa.
- Żurada J., Barski M., Jędruch W. (1996). *Sztuczne sieci neuronowe,* *Wydawnictwo Naukowe PWN.* Warszawa.
- STATISTICA Neural Networks. (1998). *StatSoft Inc.* Tulsa. USA.
- Wprowadzenie do sieci neuronowych. (2001a) STATISTICA Neural Networks PL, *StatSoft Inc.* 2001.
- Poradnik użytkownika. (2001b). STATISTICA Neural Networks PL, *StatSoft Inc.* Tulsa. USA.
- Przewodnik problemowy. (2001c). STATISTICA Neural Networks PL, *StatSoft Inc.* Tulsa. USA.
- Kurs użytkownika programu na przykładach. (2001d). STATISTICA Neural Networks PL, *StatSoft Inc.* Tulsa. USA.

NEURAL MODELLING FOR CALCULATING THE HEAT TRANSFER COEFFICIENT AND REQUIRED ISOLATION LAYER OF WALL BARRIER

Abstract: The report presents the usage of artificial neural networks to calculate heat transfer coefficient U and the opposite model, which consists on calculating the thickness of the isolation layer with given coefficient. The methodology of making a set teaching artificial neural networks and the set of tested neural networks were described. The methods of artificial intelligence, including neural networks, let include in calculations many phenomena and processes hard to describe mathematically because of their nonlinearity, so obtained neural models will be completed by additional computable parameters in future.

Praca naukowa sfinansowana przez Politechnikę Białostocką w ramach pracy statutowej S/WBiIŚ/22/08