

MODELOWANIE RÓŻNIC PARAMETRÓW TERMICZNYCH POWIETRZA MIERZONYCH METODAMI STANDARDOWĄ I AUTOMATYCZNĄ

Joanna Kajewska-Szkudlarek

Instytut Inżynierii Środowiska, Uniwersytet Przyrodniczy we Wrocławiu
plac Grunwaldzki 24, 50-365 Wrocław
e-mail: joanna.kajewska@up.wroc.pl

Streszczenie. W pracy analizowano szeregi czasowe dobowych różnic między wynikami standardowych i automatycznych pomiarów trzech parametrów termicznych powietrza – temperatury średniej, maksymalnej i minimalnej. Celem pracy było stworzenie modelu analizowanych szeregów czasowych z wykorzystaniem sztucznych sieci neuronowych, które posłużyły do identyfikacji pojawiających się w nich wzorców oraz ich powtarzalności. Wykorzystano wyniki badań prowadzonych w okresie 2000-2009 na terenie Obserwatorium Uniwersytetu Przyrodniczego Wrocław-Swojec. Do realizacji założonego celu wykorzystano sieci perceptronowe o pojedynczej warstwie ukrytej, stworzone w programie MATLAB (Neural Network Toolbox) oraz STATISTICA 10. Analizowano architekturę opracowanych sieci, liczbę cykli w procesie uczenia, zmiany wartości błędu średniokwadratowego i zależności między wartościami parametrów uzyskanych z pomiarów za pomocą przyrządów meteorologicznych oraz prognozowanych przez sieci. Pomimo wielu prób nie uzyskano modelu o zadowalającej jakości. Stwierdzono, że szeregi czasowe miały charakter białego szumu, czyli występowanie różnic między obiema metodami pomiaru temperatury powietrza cechowała losowość i brak wyraźnej cykliczności oraz trendu.

Słowa kluczowe: metoda standardowa, parametry termiczne powietrza, sieci neuronowe, stacja automatyczna

Wykaz oznaczeń:

ANN – sztuczne sieci neuronowe, Artificial Neural Networks;

MLP – perceptron wielowarstwowy, Multilayer Perceptron;

MSE – średni błąd kwadratowy, Mean Squared Error;

T_m – średnia dobową temperaturą powietrza, daily mean air temperature;

T_{max} – maksymalna temperatura powietrza, maximum air temperature;

T_{min} – minimalna temperatura powietrza, minimum air temperature.

WSTĘP

Doskonalenie metod pomiaru elementów meteorologicznych poprzez systematyczne zastępowanie stacji standardowych automatycznymi jest związane z uzasadnioną obawą o zachowanie homogeniczności wieloletnich ciągów danych obserwacyjnych. Często na stacjach meteorologicznych funkcjonują nadal dwie metody pomiaru – dane z pomiarów automatycznych są wykorzystywane do analiz, natomiast instrumenty standardowe służą do monitorowania i kontrolowania pracy systemu automatycznego. Wynika to z braku metod służących do homogenizacji wieloletnich ciągów pomiarowych mierzonych różnymi technikami, która jest niezbędna w przypadku całkowitej rezygnacji z pomiarów standardowych na rzecz automatycznych.

Duża ilość danych powstających przy okazji prowadzenia pomiarów meteorologicznych z wykorzystaniem stacji automatycznych jest trudna do zarchiwizowania i późniejszego opracowania, dlatego poszukiwanie powtarzalnych wzorców może ułatwić wyselekcjonowanie nie tylko najczęściej zachodzących, ale i ekstremalnych zjawisk. Przydatnym narzędziem do tego typu analiz są sztuczne sieci neuronowe. W badaniach zakłada się, że w analizowanych danych występują nieznanne zależności (wzorce), a zadaniem sieci neuronowych jest ich wykrycie i stworzenie modelu, który w przybliżony sposób odzwierciedli rzeczywistość. Wyniki otrzymane z wykorzystaniem ANN mogą służyć do przewidywania wielkości parametrów z dowolnie ustalonym krokiem czasowym (Lazzus 2014, Shank i in. 2008, Silverman i Dracup 2000, Tabari i in. 2015). Umożliwi to racjonalną modernizację działających stacji meteorologicznych, optymalizację ich pracy, zmniejszenie kosztów eksploatacji oraz zwiększenie trwałości przyrządów poprzez minimalizację obciążenia data loggerów.

Sztuczne sieci neuronowe należą do tzw. metod *data mining*, czyli metod pozwalających na eksplorację wielkich baz danych. Inspiracją do ich powstania była naturalna struktura ludzkiego mózgu. Sieć składa się z powiązanych ze sobą komórek zwanych neuronami, które przesyłają i przetwarzają sygnały (Ustaoglu i in. 2008).

Największą popularnością cieszą się bazujące na perceptronie wielowarstwowym struktury neuronowe jednokierunkowe, które mają zdolność odwzorowywania różnorodnych zależności o skomplikowanych algorytmach (Mihalakakou i in. 1998, Reusch i Alley 2002). Są one jednym z rodzajów sieci neuronowych, w których sygnał przepływa w jednym kierunku, tj. od wejścia do wyjścia, a warstwy ukryte pośredniczą w jego przekazywaniu. Ich zaletą jest to, że nie wymagają wiedzy na temat zachodzących w analizowanym modelu związków, ani czy takie związki w ogóle istnieją (Demuth i Beale 2000).

Celem badań było stworzenie modelu szeregów czasowych różnic parametrów termicznych powietrza mierzonych dwiema metodami. Model ten może

posłużyć do opracowania metody takiego przekształcania ciągów obserwacyjnych otrzymanych różnymi technikami i łączenia ich w jedną, homogeniczną serię danych, aby mogła stanowić bazę do badań klimatologicznych.

Do realizacji zamierzonego celu wykorzystano sztuczne sieci neuronowe, których zadaniem było poszukiwanie powtarzających się wzorców w szeregach czasowych różnic parametrów termicznych powietrza, mierzonych metodami standardową i automatyczną. Za ich pomocą stworzono modele analizowanych szeregów czasowych, które następnie porównano z rzeczywistym przebiegiem różnic parametrów termicznych powietrza i oceniono, na ile są one objaśniane przez skonstruowany model.

Badania oparto na założeniu, że na podstawie danych wejściowych skonstruowane sieci będą odtwarzać najczęściej pojawiające się wzorce, posiadać zdolność uczenia się na przykładach wprowadzanych danych oraz umiejętność uogólniania zjawisk i znajdowania powiązań między nimi.

Niniejsza praca stanowi kontynuację oraz pogłębienie badań autorki dotyczących porównania standardowych i automatycznych sposobów pomiaru podstawowych parametrów meteorologicznych (Kajewska i Rojek 2010, Kajewska-Szkudlarek 2012, Kajewska-Szkudlarek i Rojek 2015).

MATERIAŁ I METODY

Pomiary temperatury powietrza prowadzone były w latach 2000-2009 na terenie Obserwatorium Agro- i Hydrometeorologii Uniwersytetu Przyrodniczego Wrocław-Swojec. Dane obejmowały okres od 1 stycznia 2000 do 31 grudnia 2009. Liczebność plików wejściowych wynosiła 3653, czyli liczbę dni w tym dziesięcioleciu. Pomiary metodą klasyczną wykonywano za pomocą termometrów cieczowych: rtęciowego termometru stacyjnego (temperatura średnia) oraz termometrów ekstremalnych (temperatura minimalna i maksymalna), natomiast metodą automatyczną za pomocą elektronicznego czujnika MP100A Rotronic, wchodzącego w skład automatycznej stacji meteorologicznej Campbell Ltd. Średnią dobową temperaturę powietrza T_m z obserwacji klasycznych obliczano na podstawie czterech pomiarów terminowych: o godzinie 1 (wartość odczytywana z termohigrogramu dobowego), 7, 13 i 19, natomiast temperatura maksymalna T_{max} i temperatura minimalna T_{min} pochodziły z odczytów termometrów ekstremalnych. Metodą automatyczną średnią dobową temperaturę powietrza obliczano na podstawie 24 wartości godzinnych. Ponadto, stację automatyczną zaprogramowano na zapisywanie T_{max} i T_{min} wraz z terminem ich wystąpienia. Zarówno klasyczne termometry manualne (termometr stacyjny oraz termometry ekstremalne), jak i elektroniczny czujnik MP 100A Rotronic były umieszczone w klatce meteorologicznej, 2 m ponad powierzchnią terenu.

Analizowane szeregi czasowe różnic dobowych wartości trzech parametrów termicznych powietrza: temperatury średniej (T_m), maksymalnej (T_{max}) i minimalnej (T_{min}), mierzonych obiema metodami, utworzono w ten sposób, że od danych klasycznych odejmowano wartości automatyczne.

Do realizacji założonego celu wykorzystano sieci perceptronowe o pojedynczej warstwie ukrytej. W praktyce są one często stosowane do modelowania zagadnień z zakresu meteorologii i klimatologii, ponieważ charakteryzują się łatwością budowania i uczenia z użyciem prostego algorytmu propagacji wstecznej (Mihalakakou i in. 2002, Oliveira i in. 2006, Voyant i in. 2014). Sieci stworzone dla szeregów czasowych różnic analizowanych parametrów składały się z warstwy wejściowej, ukrytej i wyjściowej. Liczba neuronów w warstwie wejściowej i wyjściowej była zdeterminowana ilością zmiennych na wejściu i na wyjściu – wynosiła 1 we wszystkich przypadkach. Zgodnie z naturą szeregu czasowego ta jedna zmienna była zarówno zmienną wejściową, jak i wyjściową - pomierzone wartości posłużyły do ich estymowania za pomocą sieci neuronowych. Liczba neuronów w warstwie ukrytej była wynikiem poszukiwania najlepszego dopasowania modelu do danych rzeczywistych. Jako funkcję aktywacji sieci w warstwie ukrytej zastosowano tangens hiperboliczny, natomiast w warstwie wyjściowej funkcję liniową.

Miarą jakości modeli były wartości współczynników korelacji Pearsona między szeregami prognozowanymi za pomocą sieci neuronowych a rzeczywistymi. Z szeregu przetestowanych sieci dla każdego parametru meteorologicznego wybrano jedną, która charakteryzowała się najwyższą wartością współczynnika korelacji oraz najniższą średniego kwadratowego błędu MSE. Szeregi czasowe T_m , T_{max} i T_{min} podzielono na trzy podzbiory: uczenie sieci – training obejmujący 70% wszystkich wartości, testowanie – test (kontrola procesu uczenia) – 15% oraz walidację – validation (końcowa weryfikacja i wybór najlepszej sieci) – 15%. Podział został dokonany w sposób losowy bez zakłócania ciągłości szeregów. Dokonuje się go w celu wyeliminowania zjawiska przeuczenia sieci, zwanego też nadmiernym dopasowaniem. Polega ono na tym, że w procesie uczenia sieć bardzo dobrze odwzorowuje zależności, które zachodzą w danych wejściowych, przez co traci zdolność do ich uogólniania, a stworzony model osiąga zdecydowanie słabszą jakość dla danych niezależnych. Wydzielenie próby testowej pozwala ocenić, jaki jest postęp sieci w modelowaniu i wprowadzić technikę wczesnego zatrzymania. Błąd dla danych uczących systematycznie maleje, natomiast błąd dla danych testowych, które nie brały udziału w procesie uczenia, w pewnym momencie zaczyna rosnąć i jest to najlepszy czas, by zakończyć uczenie sieci (Demuth i Beale 2000). Drugi zestaw niezależnych danych – walidacyjny – służy do weryfikacji dokładności sieci. Jeśli błąd w tej próbie jest porównywalny z błędem w próbie testowej, to uznaje się, że model dobrze odwzorowuje

rzeczywistość i będzie działał dla innych danych. Wszystkie prezentowane w pracy rysunki dotyczą procesu uczenia.

W pracy analizowano architekturę opracowanych sieci (czyli układ poszczególnych warstw sieci oraz powiązań między nimi), liczbę cykli w procesie uczenia, zmiany wartości średniego błędu kwadratowego i zależności między wartościami parametrów uzyskanych z pomiarów za pomocą przyrządów meteorologicznych oraz prognozowanych przez sieci dla trzech podzbiorów.

Pierwszym krokiem było zastosowanie powyższej procedury dla nieprzekształconych danych – czyli dla dobowych różnic między obiema metodami. W celu poprawienia jakości modeli dane poddano dwóm transformacjom – standaryzacji oraz wygładzeniu wykładniczemu. W wyniku standaryzacji w obrębie zbioru danych otrzymano średnią równą zero i wariancję równą jeden. Uznaje się ją za korzystną dla procesu uczenia i funkcjonowania sieci perceptronowych (Demuth i Beale 2000). W celu wyeliminowania z danych szumu, który maskował naturę zjawiska, przeprowadzono wyrównanie danych z wykorzystaniem wygładzania wykładniczego. Parametr wygładzania α wynosił 0,06 dla T_m , natomiast dla T_{max} i T_{min} był równy 0,01. Na podstawie danych szacowano go w ten sposób, aby uzyskać jak najmniejszy średni kwadratowy błąd MSE. Dla tak przygotowanych danych powtórzono analizę.

Wszystkie analizy wykonano w programie MATLAB (*Neural Network Toolbox*) oraz STATISTICA 10.

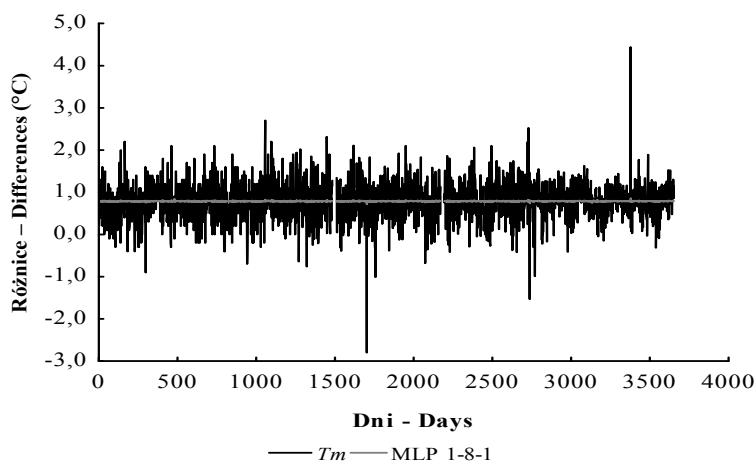
Ze względu na ograniczoną objętość pracy zamieszczono tylko wybrane rysunki.

WYNIKI

Analizowane szeregi czasowe wszystkich trzech parametrów termicznych powietrza pozbawione są regularności i nie podlegają systematycznym zmianom (Kajewska-Szkudlarek 2012). Średnia różnica między wartościami z pomiarów standardowych i automatycznych nie wykazywała trendu i wynosiła $0,8^{\circ}\text{C}$ (T_m), $0,9^{\circ}\text{C}$ (T_{max}) oraz $1,1^{\circ}\text{C}$ (T_{min}). W przypadku T_m największe różnice wystąpiły w 2009 ($+4,4^{\circ}\text{C}$) i 2004 roku ($-2,8^{\circ}\text{C}$). Zakres zmienności różnic dla obu temperatur ekstremalnych był zdecydowanie większy. Zawierały się one w przedziale od $-5,5^{\circ}\text{C}$ w 2001 r. do $12,5^{\circ}\text{C}$ w roku 2006 (T_{max}) oraz od $-5,9^{\circ}\text{C}$ w 2003 r. do $10,5^{\circ}\text{C}$ w ostatnim roku badań – 2009 (T_{min}). Tak wysokie wartości różnic zdarzały się jednak incydentalnie (kilka razy na 3653) i były to pojedyncze przypadki, co wskazuje na błąd instrumentalny. Najprawdopodobniej wynikają z błędu obserwatora, jednak nie zostało to potwierdzone, dlatego dane te nie zostały wyeliminowane.

Stworzenie modelu oddającego przebieg nieprzekształconych różnic między T_m , T_{max} i T_{min} mierzonych obiema metodami nie przyniosło pozytywnych

rezultatów (rys. 1). Żadna z przetestowanych sieci neuronowych nie odnalazła w danych powtarzalnych wzorców (sezonowość, cykliczność itp.). Sieć o największym r i najmniejszym MSE wynosiła w warstwie ukrytej 8 neuronów dla T_m i 2 neuronów dla T_{max} i T_{min} .



Rys. 1. Szereg czasowy różnic średniej temperatury powietrza (°C) mierzonej metodami standardową i automatyczną – rzeczywisty (T_m) i prognozowany (MLP 1-8-1)

Fig. 1. Time series of differences between mean daily air temperature (°C) measured with standard and automatic method – actual (T_m) and predicted (MLP 1-8-1)

Otrzymane dla danych nieprzekształconych współczynniki korelacji były bardzo niskie – od 0,004 dla temperatury średniej do 0,179 dla temperatury maksymalnej w próbach testowych (tab. 1). Tak małe wartości nie wskazują na słabą jakość sieci, lecz odzwierciedlają duże zaszumienie danych, z którymi sieć radzi sobie najlepiej, jak to jest możliwe.


Tabela 1. Podsumowanie uczenia sieci neuronowych dla danych nieprzekształconych

Table 1. Summary of neural network training for non-transformed data

Różnice Differences	Architektura Architecture	Liczba cykli Number of cycles	Uczenie Learning		Testowanie Test		Walidacja Validation	
			r	MSE	r	MSE	r	MSE
T_m	1-8-1	6	0,061	0,097	0,004	0,091	0,078	0,080
T_{max}	1-2-1	68	0,102	0,514	0,179	0,428	0,030	0,348
T_{min}	1-2-1	15	0,046	0,632	0,059	0,650	0,043	0,545

Wyniki uzyskano po 6 (T_m), 68 (T_{max}) i 15 (T_{min}) cyklach uczenia. W trakcie procesu uczenia sieci, dla którego największy gradient spadku notowano w pierwszych 5 cyklach, sukcesywnie zmniejszały się wartości MSE.

Przeprowadzenie standaryzacji danych nie wpłynęło znacząco na poprawę jakości modeli. Wprawdzie sieci zaczęły odwzorowywać fluktuacje analizowanych szeregów czasowych, jednak różnice między danymi rzeczywistymi a modelami nadal były bardzo duże (rys. 2), pomimo zdecydowanego zwiększenia liczby cykli uczenia: $Tm - 126$, $Tmax - 92$ i $Tmin - 57$.



Rys. 2. Szereg czasowy różnic średniej temperatury powietrza (°C) mierzonej metodami standardową i automatyczną - standaryzowany (Tm) i prognozowany (MLP 1-8-1)

Fig. 2. Time series of differences between mean daily air temperature (°C) measured with standard and automatic method - standardised (Tm) and predicted (MLP 1-8-1)

Potwierdzają to również współczynniki korelacji, których wartości były porównywalne z otrzymanymi dla danych nieprzekształconych i wynosiły od 0,017 w przypadku temperatury maksymalnej w próbie walidacyjnej do 0,196 w próbie testowej.

Wartości błędów średniokwadratowych dla analizowanych parametrów we wszystkich trzech próbach były zbliżone (tab. 2).

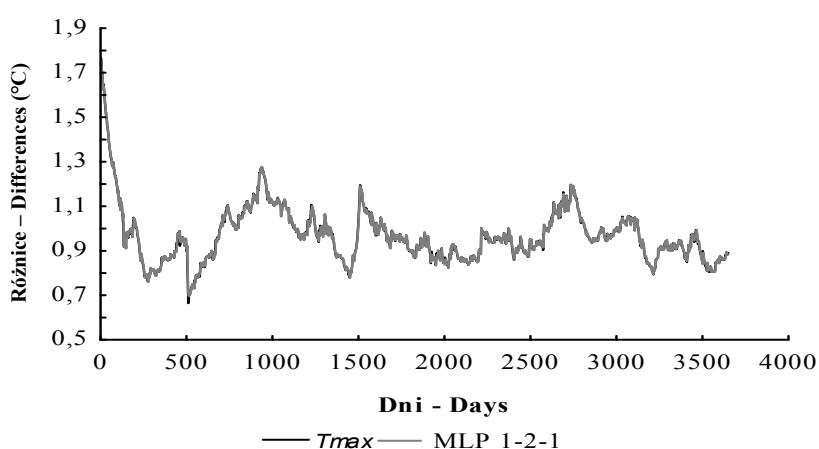
Tabela 2. Podsumowanie uczenia sieci neuronowych dla danych standaryzowanych

Table 2. Summary of neural network training for standardized data

Różnice Differences	Architektura Architecture	Liczba cykli Number of cycles	Uczenie Learning		Testowanie Test		Walidacja Validation	
			r	MSE	r	MSE	r	MSE
Tm	1-8-1	126	0,109	0,499	0,081	0,392	0,024	0,543
$Tmax$	1-2-1	92	0,092	0,528	0,196	0,437	0,017	0,356
$Tmin$	1-2-1	57	0,069	0,517	0,076	0,433	0,030	0,431

Szum zawarty w danych uniemożliwił identyfikację struktury szeregów czasowych różnic między standardowymi i automatycznymi pomiarami temperatury powietrza oraz modelowanie zmian, ponieważ przesłania relacje, które w nich zachodzą. Dlatego następnym krokiem było wygładzenie danych i powtórzenie analiz.

Zdecydowanie lepsze dopasowanie modelu do danych uzyskano w przypadku szeregów wyrównanych wykładniczo. Objasniał on około 98% zmienności danych, co wskazuje na to, że prawie całkowicie wyeliminowano z danych szum (rys. 3).



Rys. 3. Szereg czasowy różnic maksymalnej temperatury powietrza (°C) mierzonej metodami standardową i automatyczną - wyrównany wykładniczo (T_{max}) i prognozowany (MLP 1-2-1)

Fig. 3. Time series of differences between maximum air temperature (°C) measured with standard and automatic method – exponentially smoothed (T_{max}) and predicted (MLP 1-2-1)

Jakość stworzonych modeli była bardzo wysoka – świadczące o niej wartości współczynników korelacji były bliskie jedności: 0,99 dla temperatur ekstremalnych oraz 0,98 dla temperatury średniej. Sieci powstały po 5 (T_m), 37 (T_{max}) i 174 (T_{min}) cyklach uczenia. Błędy walidacyjne nie odbiegały od błędów w próbach testowych i uczących, co wskazuje na dobrą generalizację struktury danych przez sieci (tab. 3).


Tabela 3. Podsumowanie uczenia sieci neuronowych dla danych wygładzonych wykładniczo

Table 3. Summary of neural network training for exponentially smoothed data

Różnice Differences	Architektura Architecture	Liczba cykli Number of cycles	Uczenie Learning		Testowanie Test		Walidacja Validation	
			r	MSE	r	MSE	r	MSE
T_m	1-8-1	5	0,982	0,000	0,982	0,000	0,981	0,000
T_{max}	1-2-1	37	0,997	0,000	0,997	0,000	0,996	0,000
T_{min}	1-2-1	174	0,997	0,000	0,997	0,000	0,995	0,000

Na wykresach rozrzutu przedstawiono graficznie, w jaki sposób sieć odzwierciedlała rzeczywistą wartość zmiennej (rys. 4a). Obserwację ułatwia podana na wykresie linia $y = x$ wizualizująca idealne dopasowanie danych do modelu. Punkty leżały wzdłuż prostej we wszystkich trzech przypadkach, jednak nie dokładnie na niej. Powodem jest nadal występujący w danych lekki szum, który sieć prawidłowo rozpoznała, nie dopasowując się do niego.

Na rysunku 4b zaprezentowano rozkłady reszt, czyli różnic między szeregami wygładzonymi a ich predykcją. Dla trzech analizowanych parametrów histogramy wskazują, że reszty są rozłożone mniej więcej normalnie wokół zera, co jest zgodne z ogólnym założeniem normalności szumu zawartego w danych. W około 1200 (T_m), 500 (T_{max}) oraz 400 (T_{min}) na ponad 3650 przypadków wartości modelowane nie różniły się od rzeczywistych.



Rys. 4. Wykres rozrzutu (a), histogram reszt (b) dla szeregów czasowych różnic T_{max} wyrównanych wykładniczo i prognozowanych ($^{\circ}\text{C}$)

Fig. 4. Scatter plot (a), residues histogram (b) for time series of exponentially smoothed and predicted T_{max} differences ($^{\circ}\text{C}$)

WNIOSKI

1. Stworzone za pomocą sieci neuronowych modele nieprzekształconych szeregów czasowych dobowych różnic między średnią, maksymalną i minimalną temperaturą powietrza mierzoną metodą standardową i czujnikami elektronicznymi nie charakteryzują się zadowalającą jakością.

2. Sztuczne sieci neuronowe nie odnalazły powtarzających się wzorców w analizowanych szeregach czasowych różnic.

3. Przeprowadzenie standaryzacji danych, polecane przy wykorzystaniu perceptronu wielowarstwowego, nie miało wpływu na jakość modeli.

4. Proste sieci perceptronowe o pojedynczej warstwie ukrytej są przydatnym narzędziem do modelowania wygładzonych wykładniczo szeregów czasowych różnic między wartościami temperatury mierzonej metodami standardową i automatyczną.

PIŚMIENNICTWO

- Demuth H., Beale M., 2000. Neural network toolbox for use with MATLAB. Users Guide Version 4. The MathWorks Inc. Natic, Maine.
- Kajewska J., 2011. Ocena wybranych parametrów agrometeorologicznych mierzonych przyrządami klasycznymi i za pomocą stacji automatycznej. Rozprawa doktorska. Maszynopis. Dostępny w Bibliotece Głównej Uniwersytetu Przyrodniczego we Wrocławiu ss. 158.
- Kajewska J., Rojek M., 2010. Statistical analysis of relative air humidity and saturation deficit measurement results according to standard and automatic methods in Wrocław-Swojec Observatory from the period 2000-2009. *Acta Agroph.*, Rozprawy i Monografie, (5), 184, 66-81.
- Kajewska-Szkudlarek J., 2012. Wykorzystanie szeregów czasowych do oceny różnic temperatury powietrza mierzonej metodą klasyczną i automatyczną. *Woda-Środowisko-Obszary Wiejskie*, 12, 4(40), 151-162.
- Kajewska-Szkudlarek J., Rojek M., 2015. Mean daily values of bare soil temperature measured and calculated with the standard and automatic methods. *Geogr. Pol.*, 88(3), 455-465, doi: <http://dx.doi.org/10.7163/GPol.0028>.
- Lazzus J.A., 2014. Estimation of surface soil temperature based on neural network modeling, *Ital. J. Agrometeorol.*, 19(2), 5-12.
- Mihalakakou G., Flocas H.A., Santamouris M., Helmis C.G., 2002. Application of Neural Networks to the Simulation of the Heat Island over Athens, Greece, Using Synoptic Types as a Predictor. *J. Appl. Meteorol.*, 41, 519-527, doi: [http://dx.doi.org/10.1175/1520-0450\(2002\)041<0519:AONNTT>2.0.CO;2](http://dx.doi.org/10.1175/1520-0450(2002)041<0519:AONNTT>2.0.CO;2).
- Mihalakakou G., Santamouris M., Asimakopoulos D., 1998. Modeling ambient air temperature time series using neural networks. *J. Geophys. Res.*, 103(D16), 19509-19517, doi: 10.1029/98JD02002.
- Oliveira A.P., Soares J., Boznar M.Z., Mlakar P., Escobedo J.F., 2006. An Application of Neural Network Technique to Correct the Dome Temperature Effects on Pyrgeometer Measurements. *J. Atmos. Ocean. Tech.*, 23, 80-89, doi: <http://dx.doi.org/10.1175/JTECH1829.1>.
- Reusch D.B., Alley R.B., 2002. Automatic Weather Stations and Artificial Neural Networks: Improving the Instrumental Record in West Antarctica. *Mon. Weather Rev.*, 130, 3037-3053, doi: [http://dx.doi.org/10.1175/1520-0493\(2002\)130<3037:AWSAAN>2.0.CO;2](http://dx.doi.org/10.1175/1520-0493(2002)130<3037:AWSAAN>2.0.CO;2).
- Shank D.B., Hoogenboom G., McClendon R.W., 2008. Dewpoint Temperature Prediction Using Artificial Neural Networks. *J. Appl. Meteorol. Climatol.*, 47, 1757-1769, doi: <http://dx.doi.org/10.1175/2007JAMC1693.1>.
- Silverman D., Dracup J.A., 2000. Artificial Neural Networks and Long-Range Precipitation Prediction in California. *J. Appl. Meteorol.*, 39, 57-66, doi: [http://dx.doi.org/10.1175/1520-0450\(2000\)039<0057:ANNALR>2.0.CO;2](http://dx.doi.org/10.1175/1520-0450(2000)039<0057:ANNALR>2.0.CO;2).
- Tabari H., Hosseinzadeh Talaei P., Willems P., 2015. Short-term forecasting of soil temperature using artificial neural network. *Meteorol. Appl.*, 22, 576-585, doi: 10.1002/met.1489.
- Ustaoglu B., Cigizoglu H.K., Karaca M., 2008. Forecast of daily mean, maximum and minimum temperature time series by three artificial neural network methods, *Meteorol. Appl.*, 15, 431-445, doi: 10.1002/met.83.
- Voyant C., Randimbivololona P., Nivet M.L., Paoli C., Muselli M., 2014. Twenty four hours ahead global irradiation forecasting using multi-layer perceptron. *Meteorol. Appl.*, 21, 644-655, doi: 10.1002/met.1387.

NEURAL NETWORK MODELLING OF AIR TEMPERATURE DIFFERENCES
MEASURED WITH STANDARD AND AUTOMATIC METHOD

Joanna Kajewska-Szkudlarek

Institute of Environmental Engineering, Wrocław University of Environmental and Life Sciences
Grunwaldzki Square 24, 50-365 Wrocław, Poland
e-mail: joanna.kajewska@up.wroc.pl

Abstract. The paper presents an analysis of time series concerning diurnal differences between standard and automatic results of measurements of three air thermal parameters – mean (T_m), maximum (T_{max}) and minimum (T_{min}) temperature. By means of artificial neural networks an attempt at identification of the occurring patterns and their repetition was made. The study was conducted in the period of 2000-2009 on the site of Agro- and Hydrometeorology Observatory Wrocław-Swojec which belongs to the Wrocław University of Environmental and Life Sciences. In order to achieve the intended aim, single-layer perceptron networks were used, created in MATLAB (Neural Network Toolbox) and STATISTICA 10. The following aspects were subjected to the analysis: the architecture of the developed networks, the number of cycles in the learning process, the changes in Mean Squared Error (MSE), and the correlations between the values of the parameters obtained by means of meteorological instruments and the ones prognosticated by the networks. Despite multiple attempts, no model of satisfying quality was obtained. It was concluded that the nature of the time series was that of white noise, meaning that the occurrence of differences between both air temperature measurement methods were characterised by randomness and a lack of visible circularity and trend.

Key words: air thermal parameters, automatic station, neural networks, standard method