

Zastosowanie sztucznych sieci neuronowych do predykcji rozbioru wody na potrzeby optymalizacji eksploatacji sieci

Application of Artificial Neural Networks for water demand forecasting to optimize water network operations

MACIEJ BEŁCIK, MONIKA NOWAKOWSKA

DOI: 10.17512/INSTAL.2026.07.02

Artykuł przedstawia analizę możliwości wykorzystania sztucznych sieci neuronowych do prognozowania dobowego zapotrzebowania na wodę w systemach o złożonej strukturze odbiorców. Celem badań było określenie, czy implementacja modeli neuronowych pozwala na precyzyjną predykcję rozbioru, co jest kluczowe dla optymalizacji eksploatacji sieci, w tym redukcji strat wody. Materiał do badań stanowiły dane pomiarowe z lat 2020-2025 pochodzące z systemu wodociągowego charakteryzującego się wysokim, sięgającym 40%, udziałem przemysłu. W tym okresie wydzielono dane z lat 2020-2024, na podstawie których zbudowano model, oraz dane z roku 2025, które posłużyły do jego weryfikacji. Do predykcji rozbiorów dobowych zapotrzebowania na wodę w systemie zastosowano perceptron wielowarstwowy, przy czym proces ten został podzielony na 2 etapy: w pierwszym wykorzystano dane bez kategoryzacji, natomiast w etapie drugim danym przypisano dodatkowo typ dnia tygodnia. Uzyskane analizy wskazują, że wprowadzenie zmiennej opisującej typ dnia tygodnia znacząco podnosi jakość predykcji. Najlepszą zdolność generalizacji wykazał model MLP 112-13-1, dla którego względny błąd średniokwadratowy, badany na niezależnym zbiorze testowym, wyniósł 8,40%, a pierwiastek błędu średniokwadratowego – 257,3 m³/d. Uzyskane wyniki potwierdzają deterministyczno-stochastyczny charakter zapotrzebowania na wodę oraz wysoką skuteczność sztucznych sieci neuronowych w odwzorowywaniu nieliniowych zależności zachodzących w dynamicznych systemach wodociągowych.

Słowa kluczowe: sztuczne sieci neuronowe, perceptron wielowarstwowy, prognozowanie zapotrzebowania na wodę, szeregi czasowe, inteligentne systemy wodociągowe

The article analyses the feasibility of using artificial neural networks to forecast daily water demand in systems with a complex consumer structure. The objective of the study was to investigate whether the implementation of neural models allows for precise consumption prediction, which is crucial for optimizing network operation, including the reduction of water losses. The research material consisted of measurement data from the years 2020-2025, obtained from a water supply system characterized by a high industrial share, reaching 40%. Within this period, data from 2020 to 2024 were isolated to construct the model, while data from 2025 were used for its verification. A multilayer perceptron (MLP) was applied to predict daily water demand; the process was divided into two stages: the first utilized uncategorized data, while in the second stage, a "day of the week" type was additionally assigned to the data. The conducted analyses indicate that the introduction of a variable describing the day of the week significantly improves prediction quality. The best generalization capability was demonstrated by the MLP 112-13-1 model, for which the relative mean squared error tested on an independent dataset was 8.40%, and the root mean squared error was 257.3 m³/d. The obtained results confirm the deterministic-stochastic nature of water demand and the high effectiveness of artificial neural networks in mapping non-linear relationships occurring in dynamic water supply systems.

Keywords: artificial neural networks, multilayer perceptron, water demand forecasting, time series analysis, smart water supply systems

Wstęp

Efektywne zarządzanie systemami zbiorowego zaopatrzenia w wodę w warunkach dynamicznych zmian gospodarczych i klimatycznych stanowi jedno z kluczowych wyzwań współczesnej inżynierii środowiska. Optymalizacja eksplo-

atacji sieci wodociągowej wymaga nie tylko zapewnienia ciągłości dostaw i odpowiedniego ciśnienia, ale przede wszystkim precyzyjnego prognozowania rozbioru wody [1, 4, 15, 18]. W dobie cyfryzacji tradycyjne metody statystyczne ustępują miejsca zaawansowanym algorytmom uczenia maszynowego [3]. Sztuczne sieci neuronowe

(SSN) [10, 17] wyróżniają się zdolnością do modelowania nieliniowych i niestacjonarnych zależności między zmiennymi egzogenicznymi a rzeczywistym zapotrzebowaniem, co pozwala na skuteczną redukcję błędów predykcji [2, 7] i czyni je narzędziem znacznie skuteczniejszym od klasycznych modeli regresyjnych [5, 11, 14].

Analizowany system zbiorowego zaopatrzenia w wodę stanowi specyficzny przypadek badawczy. Ujęcie wody opiera się na eksploatacji siedmiu studni głębinowych: pięciu odwiertów trzeciorzędowych o średniej głębokości 170 m oraz dwóch czwartorzędowych o głębokości ok. 40 m. Proces technologiczny uzdatniania wody opiera się wyłącznie na procesach aeracji oraz filtracji grawitacyjnej na złożach katalitycznych (4 jednostki o maksymalnej wydajności 100 m³/h każda). Zastosowanie predykcji pozwala uniknąć gwałtownych zmian prędkości filtracji, co jest kluczowe dla zachowania skuteczności usuwania związków żelaza i manganu na złożach [8].


Unikalność badanego obszaru wynika z jego struktury gospodarczej, ściśle powiązanej ze znajdującą się w pobliżu Strefą Ekonomiczną. W przeciwieństwie do typowych sieci miejskich, gdzie dominuje sektor bytowy [6, 13], w układzie zasilanym przez analizowany system wodociągowy udział przemysłu jest znaczący i wynosi ok. 35-40% zapotrzebowania na wodę. Kluczowymi odbiorcami są zakłady o wysokiej wodochłonności, których obecność radykalnie zmienia profil nierównomierności dobowej i godzinowej [12, 14]. Stała aktywność przemysłowa, zaburzana jedynie krótkimi przestojami wakacyjnymi, nakłada się na zmienne sezonowo zapotrzebowanie komunalne i rolnicze (podlewanie ogrodów, napełnianie przydomowych baseń), generując złożone profile rozbiór. Dodatkowym czynnikiem dynamizującym układ był odnotowany w 2023 roku wzrost produkcji w jednym z zakładów, wynikający z rozbudowy linii technologicznych.

Eksploatacja złożonej sieci wodociągowej o łącznej długości ok. 164 km (nie uwzględniając przyłączy), w której dominującym materiałem są przewody wykonane z PVC (107 km) i PE (40 km), przy systemie magistralnym o średnicach DN400 i DN300, wymaga precyzyjnego zarządzania ciśnieniem. Wykorzystanie SSN do predykcji rozbiór umożliwia nie tylko lepsze dopasowanie wydajności pompowni drugiego stopnia, ale również redukcję strat wody oraz optymalizację zużycia energii elektrycznej [9]. Artykuł ma na celu wykazanie, że implementacja modeli neuronowych może służyć za narzędzie do precyzyjnej predykcji zapotrzebowania na wodę w dynamicznych systemach wodociągowych [15, 16]. Przeprowadzone badania wnoszą wkład w rozwój narzędzi prognozytycznych opartych na SSN, pozwalając na głębsze zrozumienie nieliniowych zależności w procesach dystrybucji wody. Z praktycznego punktu widzenia opracowany model może stanowić realne wsparcie dla przedsiębiorstw wodociągowych

w optymalizacji zarządzania pracą sieci i minimalizacji strat energii.

Dane przyjęte do analiz

Podstawę opracowania modeli prognostycznych stanowiły dane pomiarowe dobowego zapotrzebowania na wodę pozyskane z przedsiębiorstwa wodociągowego w okresie od 1 stycznia 2020 roku do 31 grudnia 2025 roku (rys. 1).



Rys. 1. Szereg czasowy dobowego poboru wody w okresie 1.01.2020-31.12.2025

Fig. 1. Time series of daily water withdrawal from January 1, 2020, to December 31, 2025

Szereg czasowy przedstawiony na rysunku 1 cechuje się wysoką zmiennością krótkookresową oraz wyraźną strukturą sezonową i trendową [6, 12]. W analizowanych danych zaobserwowano sezonowość roczną, przejawiającą się wzrostem zapotrzebowania w okresach wiosenno-letnich oraz jego obniżeniem w miesiącach jesienno-zimowych [13, 14]. Maksymalne wartości dobowego rozbiór wody osiągają poziom przekraczający 4500-5000 m³/d (w latach 2021 oraz 2022), natomiast wartości minimalne kształtują się na poziomie około 1800-2200 m³/d (przez cały analizowany okres). Ponadto zauważalny jest umiarkowany trend wzrostowy średniego poziomu zużycia wody (od ok. 2800 m³/d w 2020 roku do ok. 3400 m³/d w 2025 roku). Zauważalny jest skokowy wzrost przeciętnego zapotrzebowania na wodę od 2023 roku. Jest to związane z uruchomieniem kolejnych linii produkcyjnych w jednym z obsługiwanych zakładów produkcyjnych o dużej wodochłonności, a co za tym idzie, intensyfikacją zużycia wody.

Struktura szeregu czasowego wskazuje na jego niestacjonarność, wynikającą zarówno z obecności trendu, jak i sezonowości [12]. Jednocześnie widoczna

jest silna komponenta losowa, przejawiająca się znacznymi wahaniami dobowymi.

W szeregu występują również wartości odstające, które są efektem incydentalnych zdarzeń eksploatacyjnych, takich jak awarie czy intensywne pobory wody w okresach upałów (zdarzenia nietypowe w pracy systemu), co generuje błędy predykcyjne wymagające specjalistycznego podejścia modelowego [2, 7].

Przeprowadzone obserwacje potwierdzają, że dobowe zapotrzebowanie na wodę jest procesem złożonym o charakterze deterministyczno-stochastycznym, uwarunkowanym zarówno czynnikami sezonowymi, jak i losowymi. Z tego względu prognozowanie rozbiór wody nie jest zagadnieniem łatwym do realizacji [1, 15].

Wybór SSN jako narzędzia prognozytycznego wynika z ich unikalnej zdolności do analizy złożonych zjawisk o charakterze deterministyczno-losowym, jakim niewątpliwie jest dobowy pobór wody [5, 11]. Metoda ta stanowi skuteczną alternatywę dla klasycznych modeli szeregów czasowych, takich jak: ARIMA, wygładzanie wykładnicze [1, 14, 18], oferując szereg zalet z punktu widzenia inżynierii środowiska. Kluczową cechą SSN jest zdolność do aproksymacji nieliniowości, co pozwala na precyzyjne odwzorowanie złożonych zależności bez konieczności definiowania ścisłych praw fizycznych opisujących badany proces [10, 17]. Proces budowy modelu ulega znaczącej automatyzacji, opierając się na eksploracji danych, prowadzącej do samodzielnego oszacowania parametrów opisujących współzależności w szeregu czasowym [3, 4]. Zaletą jest również zdolność do ciągłego uczenia się, co umożliwia bieżącą aktualizację i adaptację modelu

do dynamicznych zmian w strukturze zużycia wody [9, 16]. Efektywność metody podnosi dodatkowo mechanizm równoległego przetwarzania sygnałów wejściowych, dzięki któremu sieci neuronowe sprawnie generują predykcje dla zadanych horyzontów czasowych [10].

Opracowanie i walidacja modeli prognostycznych

Analiza struktury szeregu czasowego – wskazująca na występowanie trendu, sezonowości oraz składowej losowej [12, 14] – uzasadnia zastosowanie metod prognozowania zdolnych do odwzorowania złożonych i nieliniowych zależności pomiędzy zmiennymi wejściowymi a wielkością prognozowaną. Z uwagi na nieliniowy charakter rozpatrywanego szeregu czasowego oraz jego niestacjonarność, do prognozowania dobowego zapotrzebowania na wodę w analizowanym systemie wodociągowym przyjęto sztuczne sieci neuronowe (SSN) – typ perceptron wielowarstwowy (MLP, ang. Multilayer Perceptron) [5, 11].


Perceptron wielowarstwowy (MLP) jest siecią neuronową typu feedforward, składającą się z warstwy wejściowej, jednej lub kilku warstw ukrytych oraz warstwy wyjściowej, w której sygnał przepływa jednokierunkowo [10, 17] od wejścia do wyjścia (rys. 2).

W ujęciu ogólnym sygnały wejściowe x_i są przetwarzane sekwencyjnie przez kolejne warstwy sieci neuronowej. W każdym neuronie realizowana jest operacja liniowej agregacji sygnałów wejściowych w postaci sumy ważonej, uzupełnionej o wyraz wolny (bias), po której następuje nieliniowa transformacja za pomocą funkcji aktywacji [10]. Proces uczenia sieci polega na iteracyjnej modyfikacji wartości wag (W) oraz biasów (b) w celu minimalizacji przyjętej funkcji błędu [3].

Obliczenia wykonano w programie STATISTICA 13 przyjmując dla każdego wariantu po 20 różnych struktur MLP.

W pierwszym kroku do budowy modelu wykorzystano dane z okresu od 1 stycznia 2020 do 31 grudnia 2024. Dane pochodzące z roku 2025 wydzielono jako niezależny zbiór testowy, który posłużył do oceny zdolności generalizacji wybranych modeli, charakteryzujących się najlepszą jakością [4, 16]. Ponadto przy budowie modelu przyjęto następujące założenia:

- jedna warstwa ukryta z liczbą neuronów (h_i) od 2 do 20,
- ilość danych wejściowych wstecz przyjętych do generowania wartości wyjściowej (x_i) – 1, 7 oraz 14 [1, 18],
- możliwe funkcje aktywacji: liniowa, logistyczna, tangens hiperboliczny, wykładnicza,



Rys. 2. Przykładowy schemat sztucznej sieci neuronowej – typ perceptron wielowarstwowy (MLP)
Fig. 2. An example diagram of an artificial neural network – a multilayer perceptron (MLP)

- stosunek zbiorów: uczący – 50%, testowy – 25%, walidacyjny – 25%;
- algorytm uczenia – BFGS (Broyden-Fletcher-Goldfarb-Shanno),

Struktury sieci perceptronowych wykazujących najlepszą jakość (największy współczynnik korelacji wartości obserwowanych i przewidywanych) zestawiono w tabeli 1.

Relatywnie jakość przeanalizowanych modeli prognostycznych jest podobna, a błąd modelu pomiędzy nimi różni się nieznacznie. Z tego względu oraz z uwagi na wyrażenie zróżnicowanie poboru wody w poszczególne dni tygodnia [1, 13], w drugim kroku wprowadzono kategoryzację danych wejściowych, uwzględniając typ dnia tygodnia.

Budowę modeli prognostycznych wykonano przy analogicznych założeniach jak w kroku 1, a wyniki obliczeń zestawiono w tabeli 2.

Wprowadzenie kategoryzacji danych wejściowych względem typu dnia tygodnia polepszyło jakość przyjętych modeli w kroku 2 w porównaniu z wcześniejszymi – analizowanymi w kroku 1 (bez kategoryzacji danych wejściowych) [15, 16].


Pośród analizowanych struktur najlepsze rezultaty uzyskano dla modeli o większej liczbie neuronów oraz rozbudowanej strukturze wejściowej (np. MLP 56-19-1 oraz MLP 112-13-1), co wskazuje na istotną rolę odpowiedniego doboru architektury sieci w procesie prognozowania zapotrzebowania na wodę za pomocą SSN [4, 11].

Tabela 1. Struktury sieci perceptronowych wykazujących najlepszą jakość (krok 1)
Table 1. Perceptron network architectures with the best performance (Step 1)

Model	Jakość – zbiór uczący – zbiór testowy – zbiór walidacyjny	Algorytm uczenia (liczba epok)	Funkcja aktywacji – warstwa ukryta – warstwa wyjściowa	Pierwiastek błędu średnio- kwadratowego (RMSE)	Względny błąd średniokwadratowy (RRMSE)
				m ³ /d	%
MLP 1-3-1	0,743411 0,769960 0,779180	BFGS (15)	tangens hiperbolicz- ny wykładnicza	299,3	9,71
MLP 7-3-1	0,791893 0,805808 0,816411	BFGS (390)	wykładnicza tangens hiperboliczny	275,4	9,00
MLP 14-13-1	0,797465 0,813781 0,816398	BFGS (31)	tangens hiperbolicz- ny wykładnicza	272,7	8,89

Tabela 2. Struktury sieci perceptronowych wykazujących najlepszą jakość (krok 2)
Table 2. Perceptron network architectures with the best performance (Step 2)

Model	Jakość – zbiór uczący – zbiór testowy – zbiór walidacyjny	Algorytm uczenia (liczba epok)	Funkcja aktywacji – warstwa ukryta – warstwa wyjściowa	Pierwiastek błędu średnio- kwadratowego (RMSE)	Względny błąd średniokwadratowy (RRMSE)
				m ³ /d	%
MLP 8-13-1	0,780091 0,804905 0,813733	BFGS (15)	logistyczna liniowa	280,0	9,12
MLP 56-19-1	0,821481 0,829222 0,837915	BFGS (24)	tangens hiperbo- liczny wykładnicza	259,0	8,43
MLP 112-13-1	0,829457 0,827026 0,833746	BFGS (112)	wykładnicza tangens hiperbo- liczny	257,3	8,40



Rys. 3. Rzeczywiste i przewidywane wartości szeregu czasowego dobowego rozbioru wody — model MLP 112-13-1

Fig. 3. Actual and predicted values of the daily water withdrawal time series — MLP 112-13-1 model

Dla sieci MLP 112-13-1, wykazującej najlepsze przesłanki do generowania prognozy dobowego rozbioru wody w analizowanym systemie wodociągowym, wykonano testy na wcześniej wyodrębnionym niezależnym zbiorze danych obejmującym 2025 rok.

Na rysunku 3 przedstawiono porównanie rzeczywistych oraz prognozowanych wartości dobowego zapotrzebowania na wodę, uzyskanych z wykorzystaniem modelu MLP 112-13-1, dla niezależnego zbioru danych obejmującego rok 2025. Z przeprowadzonych analiz wynika, że dla wykonanej prognozy pierwiastek błędu średniokwadratowego (RMSE) wyniósł $257,3 \text{ m}^3/\text{d}$, natomiast względny błąd średniokwadratowy (RRMSE) jest równy 8,40%, co mieści się w granicach błędu akceptowalnego dla tego typu modeli prognostycznych [1, 15, 18].

Analiza przebiegu obu szeregów czasowych wskazuje na dobre dopasowanie wartości prognozowanych do obserwowanych, co potwierdzają uzyskane miary błędu. Model w sposób poprawny odwzorowuje zarówno ogólny poziom zapotrzebowania na wodę, jak i jego zmienność w czasie [1, 14].

Widoczna jest zgodność przebiegu krzywych, szczególnie w zakresie trendów oraz zmian sezonowych, co świadczy o zdolności modelu do uchwycenia dominujących wzorców występujących w danych [12, 18]. Jednocześnie można zauważyć lokalne rozbieżności pomiędzy wartościami rzeczywistymi i prognozowanymi, zwłaszcza w przypadku nagłych wzrostów lub spadków zapotrzebowania, co wynika z obecności składowej losowej oraz ograniczonej możliwości modelu do odwzorowania krótkookresowych fluktuacji.

Pomimo tych różnic model zachowuje stabilność predykcyjną, a uzyskane wyniki potwierdzają jego przydatność do prognozowania dobowego zapotrzebowania na wodę w analizowanym systemie wodociągowym [4, 15].

Analiza rozkładu reszt (różnic pomiędzy wartościami obserwowanymi a prognozowanymi, rys. 4) wskazuje, że są one w przybliżeniu symetryczne względem zera; większość wartości skupia się w przedziale $\pm 300 \text{ m}^3/\text{d}$ oraz średnia reszta wynosi $23,48 \text{ m}^3/\text{d}$, co wskazuje na niewielkie obciążenie modelu.

Pomimo odrzucenia hipotezy o normalności rozkładu reszt na podstawie testu Shapiro-Wilka ($p < 0,05$), ich rozkład jest zbliżony do normalnego, co – w połączeniu z brakiem istotnych odchyleń systematycznych – potwierdza poprawność działania modelu oraz jego przydatność prognostyczną. Należy podkreślić, że w przypadku modeli opartych na sztucznych sieciach neuronowych brak ścisłej normalności rozkładu reszt nie stanowi istotnego ograniczenia ich zastosowania, o ile błędy mają charakter losowy i nie wykazują struktury systematycznej [2, 7].


Wnioski

Przeprowadzone analizy potwierdziły przydatność sztucznych sieci neuronowych typu perceptron wielowarstwowy (MLP) do prognozowania dobowego zapotrzebowania na wodę. Opracowane modele charakteryzują się zbliżonym poziomem jakości, przy czym wartości błędu RMSE mieszczą się w przedziale około $257\text{--}299 \text{ m}^3/\text{d}$, natomiast względny błąd średniokwadratowy RRMSE wynosi od około 8,40% do 9,71%, co wskazuje na dobrą dokładność predykcji.

W pierwszym kroku wykazano, że zwiększenie liczby danych wejściowych (uwzględnienie wartości historycznych z kilku poprzednich dni) prowadzi do niewielkiej poprawy jakości modeli, a różnice pomiędzy analizowanymi wariantami nie są znaczące.

Zauważalną poprawę uzyskano dopiero w drugim kroku, po wprowadzeniu dodatkowej zmiennej opisującej typ dnia tygodnia (poniedziałek, wtorek, itp.). Uwzględnienie tej informacji pozwoliło na lepsze odwzorowanie zużycia wody, co przełożyło się na wzrost współczynnika dopasowania oraz obniżenie wartości błędów modelu.

Spśród 120 przeanalizowanych struktur najlepsze rezultaty uzyskano dla modelu MLP 112-13-1. Zaprognozowane wartości dobowego rozbioru wody za pomocą tego modelu na niezależnych danych testowych, obejmujących 2025 rok, umożliwiły



Rys. 4. Rozkład częstości reszt przewidywanych wartości za pomocą modelu MLP 112-13-1

Fig. 4. Frequency distribution of the residuals of the predicted values using the MLP 112-13-1 model

ocenę zdolności generalizacji modelu, potwierdzając jego użyteczność w prognozowaniu rzeczywistego zapotrzebowania na wodę.

Uzyskane wyniki potwierdzają, że dobowe zapotrzebowanie na wodę stanowi proces złożony o charakterze deterministyczno-stochastycznym, w którym istotną rolę odgrywają zarówno czynniki sezonowe i eksploatacyjne, jak i zmienność losowa. W związku z tym zastosowanie modeli zdolnych do odwzorowania nieliniowych zależności, takich jak sztuczne sieci neuronowe, do prognozowania dobowego rozbioru wody jest w pełni uzasadnione.

Literatura

- [1] Adamowski, J. F. (2008). Peak daily water demand forecast modeling using artificial neural networks. *Journal of Water Resources Planning and Management*, 134(2), 119–128. [https://doi.org/10.1061/\(ASCE\)0733-9496\(2008\)134:2\(119\)](https://doi.org/10.1061/(ASCE)0733-9496(2008)134:2(119))
- [2] Alvisi, S., & Franchini, M. (2014). Assessment of the predictive uncertainty within the framework of water demand forecasting by using the model conditional processor. *Procedia Engineering*, 89, 893–900. <https://doi.org/10.1016/j.proeng.2014.11.522>
- [3] Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- [4] Candelieri, A., Soldi, D., & Archetti, F. (2015). Layered machine learning for short-term water demand forecasting. *Environmental Engineering and Management Journal*, 14(9), 2061–2072. <https://doi.org/10.30638/eemj.2015.221>
- [5] Cieřak, W., Łomotoński, J., Siwoń, Z., Licznar, P., & Cieřak, J. (2011). Modele neuronowe w analizie i prognozowaniu rozbiorów wody. *Instal*, (7/8), 61–63.
- [6] Hołtoř, H., Głowacka, J., & Kołodziej, A. (2012). Zmienność poboru wody w systemie wodocięgowym Wrocławia. *Ochrona Środowiska*, 34(4), 23–28.
- [7] Hutton, C. J., & Kapelan, Z. (2015). A probabilistic methodology for quantifying, diagnosing and reducing model structural and predictive errors in short term water demand forecasting. *Environmental Modelling & Software*, 66, 87–97. <https://doi.org/10.1016/j.envsoft.2014.12.021>
- [8] Kowal, A. L., Świdorska-Bróż, M., & Wolska, M. (2022). *Oczyszczanie wody (T. 1–2)*. Wydawnictwo Naukowe PWN.
- [9] Licznar, P., & Łomotoński, J. (2006). Zastosowanie sztucznych sieci neuronowych Kohonena do prognozowania dobowego poboru wody. *Ochrona Środowiska*, 28(1), 45–48.
- [10] Osowski, S. (2013). *Sieci neuronowe do przetwarzania informacji*. Oficyna Wydawnicza Politechniki Warszawskiej.
- [11] Piasecki, A., Jurasz, J., & Marszelewski, W. (2016). Wykorzystanie wielowarstwowych sztucznych sieci neuronowych do średnioterminowego prognozowania poboru wody – studium przypadku. *Ochrona Środowiska*, 38(2).
- [12] Siwoń, Z., Cieřak, W., & Cieřak, J. (2006). Analiza i prognozowanie szeregów czasowych krótkotrwałego poboru wody. *Instal*, (2), 44–49.
- [13] Siwoń, Z., Cieřak, W., & Cieřak, J. (2011). Modele neuronowe szeregów czasowych godzinowego poboru wody w osiedlach mieszkaniowych. *Ochrona Środowiska*, 33(2), 23–26.
- [14] Siwoń, Z., Łomotoński, J., Cieřak, W., Licznar, P., & Cieřak, J. (2008). Analizy i prognozowanie rozbiorów wody w systemach wodocięgowych. *Polska Akademia Nauk*.
- [15] Stańczyk, J., Kajewska-Szkudlarek, J., Łomotoński, J., Lipiński, P., Rychlikowski, P., & Konieczny, T. (2018). Prognozowanie zapotrzebowania na wodę z wykorzystaniem uczenia maszynowego. *Gaz, Woda i Technika Sanitarna*, 92(10), 372–377. <https://doi.org/10.15199/17.2018.10.5>
- [16] Śmigiel, S., Stańczyk, J., Dziemińska, P., Ledziński, D., Andrysiak, T., & Licznar, P. (2023). Predykcja krótkoterminowa zużycia wody w budynkach wielorodzinnych z wykorzystaniem technik uczenia maszynowego. *Instal*, (12), 72–78. <https://doi.org/10.36119/15.2023.12.11>
- [17] Tadeusiewicz, R. (1993). *Sieci neuronowe*. Akademicka Oficyna Wydawnicza RM.
- [18] Tiwari, M. K., & Adamowski, J. F. (2015). Medium-term urban water demand forecasting with limited data using an ensemble wavelet-bootstrap machine-learning approach. *Journal of Water Resources Planning and Management*, 141(2), 1–12. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0000454](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000454)



Rok założenia 1919

POLSKIE ZRZESZENIE INŻYNIERÓW I TECHNIKÓW SANITARNYCH ODDZIAŁ W KRAKOWIE POLISH ASSOCIATION OF SANITARY ENGINEERS AND TECHNICIANS

zaprasza na

XIX OGÓLNOPOLSKĄ KONFERENCJĘ NAUKOWO-TECHNICZNĄ „WENTYLACJA • KLIMATYZACJA • OGRZEWNICTWO • ŚRODOWISKO”



I. CIEPŁOWNICTWO I OGRZEWNICTWO – DROGA DO DEKARBONIZACJI

1. Systemy IV i V generacji
2. Wieloskalowe pompy ciepła
3. Efektywność energetyczna budynków
4. Hybrydowe węzły ciepłownicze
5. Magazyny energii
6. Ciepło odpadowe



II. WENTYLACJA I KLIMATYZACJA – KOMFORT, ZDROWIE

1. Wentylacja inteligentna i hybrydowa
2. Filtracja i bezpieczeństwo zdrowotne
3. Chłodzenie pasywne
4. Jakość środowiska wewnętrznego



III. ŚRODOWISKO I GOSPODARKA OBIEGU ZAMKNIĘTEGO

1. Ślad węglowy
2. Oszczędność wody i ochrona wód
3. Retencja i błękitno-zielona infrastruktura
4. Odzysk ciepła i chłodu
5. Infrastruktura liniowa
6. Wentylacja miejska



IV. NOWOCZESNE ZARZĄDZANIE

1. Narzędzia pracy inżyniera
2. IoT w budynkach i miastach
3. Cyfrowe zarządzanie środowiskiem
4. Inteligentne opomiarowanie
5. AI w zarządzaniu energią



TRESNA, 22-23 PAŹDZIERNIKA 2026 r.

Szczegóły wydarzenia pod linkiem: <https://pzi.ts.krakow.pl/konferencja-2026/>