

Jacek Dawidowicz

OBLICZANIE WSPÓŁCZYNNIKA STRAT LINIOWYCH λ ZA POMOCĄ SZTUCZNYCH SIECI NEURONOWYCH

Jacek Dawidowicz, dr inż. – Politechnika Białostocka

adres korespondencyjny:

Wydział Budownictwa i Inżynierii Środowiska

Katedra Systemów Inżynierii Środowiska

ul. Wiejska 45A, 15-351 Białystok

e-mail: j.dawidowicz@pb.edu.pl

CALCULATING LINEAR LOSSES λ RATIO USING ARTIFICIAL NEURON NET

SUMMARY: Numerical modelling of water distribution systems are used in the design, operation and decision support. In recent years, many applications require a substantial acceleration calculation. This paper attempts to use artificial neural networks to calculate the friction factor. Commonly used Colebrook-White formula requires the use of an iterative method, which extends the computation time. Properly prepared neural network can perform this task much faster.

KEY WORDS: water distribution system, artificial neural networks, friction factor

Wstęp

System dystrybucji wody jest jednym z najważniejszych i najkosztowniej-
szych elementów systemu zaopatrzenia w wodę. Podstawowym zadaniem pod-
czas projektowania sieci wodociągowych jest wykonanie obliczeń hydraulicz-
nych mających na celu ustalenie strat ciśnienia. W tym celu powszechnie stosuje
się technikę komputerową. Pierwsze programy komputerowe pojawiły się
w II połowie XX wieku¹. Od tamtego czasu nastąpił widoczny postęp w możliwo-
ściach technicznych i udogodnieniach, jakie posiadają najnowsze programy
do obliczeń systemów dystrybucji wody², które coraz częściej korzystają z możli-
wości GIS³ oraz CAD⁴. Nie zmienia to jednak faktu, że programy obecnie stosowa-
ne oparte są na klasycznych, iteracyjnych algorytmach obliczeniowych. W ostat-
nich latach nastąpił również szybki rozwój środków łączności, co umożliwia
wdrażanie zaawansowanych systemów komputerowego sterowania i wspoma-
gania decyzji do systemów rozłożonych, takich jak sieci wodociągowe. W tym
przypadku podstawową funkcją systemu komputerowego jest zapewnienie dwu-
stronnej łączności operatora z modułami telemetrycznymi oraz zapisywanie da-
nych w wyznaczonych odstępach czasowych. Z drugiej strony, operator może
wysyłać sygnały nastawcze do elementów wykonawczych w systemie⁵. W syste-
mach sterowania i wspomagania decyzji wykorzystywane są również modele
symulacji hydraulicznych, szczególnie modele dynamiczne. Biorąc pod uwagę,
że systemy sterowania często działają w czasie rzeczywistym, niezwykle ważny
jest czas realizacji obliczeń. System dystrybucji wody najczęściej składa się ze
znacznej ilości odcinków, stąd nawet niewielkie przyspieszenie obliczeń poj-
edynczego przewodu może znacznie skrócić obliczenia całego systemu. Wydaje

¹ R. Epp, A.G. Fowler, *Efficient Code for steady state Flows in Networks*, „Journal of the Hydraulics Division” 1970 t. 96, nr HY1, s. 43-56; R.W. Adams, *Distribution Analysis by Electronic Computer*, Institute of Water Engineers, 1961 t. 15, s. 415-428; L.E. Ormsbee, *The History of Water Distribution Network Analysis: The Computer Age*, 8th Annual Water Distribution Systems Analysis Symposium, ASCE, August 27-30, Cincinnati, Ohio 2006.

² S. Biedugnis, *Metody informatyczne w wodociągach i kanalizacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1998; K. Knapik, *Dynamiczne modele w badaniach sieci wodociągowych*, Wyd. Politechniki Krakowskiej, Kraków 2000; L.A. Rossman, *EPANET 2 User's manual*, EPA/600/R-00/057, National Risk Management Research Laboratory, U.S. Environmental Protection Agency, Cincinnati, OH 2000; *Pipe2010 Water Utility Modeling: A Comprehensive Guide to Hydraulic and Water Quality Modeling of Drinking Water Systems Using Pipe2010*, KyPipe, www.kypipe.com [14-02-2013]; *Pipe Flow Expert 2010 User Guide*, www.pipeflow.co.uk [10-02-2013].

³ U.M. Shamsi, *GIS applications for water, wastewater, and stormwater systems*, CRC PressINC, Taylor & Francis Group, New York 2005; S.A. Taher, J.W. Labadie, *Optimal design of water-distribution networks with GIS*, „Journal of Water Resources Planning and Management” 1996 t. 122, nr 4, s. 301-311.

⁴ M.T. Walski i in, *Advanced Water Distribution Modeling And Management*, Haestad Methods Solution Center, Haestad Press 2003.

⁵ B. Ulanicki, *Metody modelowania i optymalizacji do symulacji, sterowania i projektowania sieci dystrybucji wody*, Rozprawy Naukowe nr 20, Wyd. Politechniki Białostockiej, Białystok 1993.

się, że klasyczne algorytmy o sformalizowanym przebiegu można obecnie uzupełnić znacznie bardziej zaawansowanymi technikami obliczeniowymi, które można objąć wspólną nazwą metod inteligencji obliczeniowej (ang. *computational intelligence* – *CI*)⁶. W zakres powyższego podejścia wchodzi między innymi technika sztucznych sieci neuronowych. W niniejszej pracy podjęto próbę zastosowania sztucznych sieci neuronowych do obliczeń współczynnika strat liniowych λ . Stosowany w Polsce wzór *Colebrooka-White'a* wymaga użycia metody iteracyjnej, która wydłuża czas obliczeń. Odpowiednio sporządzona sieć neuronowa może to zadanie realizować znacznie szybciej.

Przegląd literatury z zakresu zastosowania sztucznych sieci neuronowych w obliczeniach systemów dystrybucji wody

Ogólne omówienie i postulat stosowania metod sztucznej inteligencji, w tym sztucznych sieci neuronowych, w monitoringu, sterowaniu i eksploatacji systemów zaopatrzenia w wodę i ochrony wód zamieszczono w pracy⁷.

Obliczenia współczynnika oporów liniowych za pomocą sztucznych sieci neuronowych opisano w artykule⁸. Do obliczeń współczynnika wykorzystano dane wejściowe z liczbą Reynoldsa. W niniejszej pracy również zastosowano sieć neuronową do obliczeń współczynnika strat liniowych λ , lecz zaproponowano odmienne podejście. Jako dane uczące wykorzystano zmienne opisujące odcinek obliczeniowy, bez konieczności pośredniego wyliczenia liczby Reynoldsa.

W symulacji hydraulicznej systemów dystrybucji wody sztuczne sieci neuronowe stosowane są do wspomagania tarowania modeli symulacyjnych. W pracy⁹ opisano algorytm genetyczny współpracujący ze sztuczną siecią neuronową, mający na celu usprawnienie procesu tarowania modelu systemu dystrybucji wody. Natomiast w referacie¹⁰ opisano proces tarowania modelu, oparty na metodzie prób i błędów w doborze parametrów, uzupełniony o techniki optymalizacyjne i sztucznej inteligencji, w tym sztuczne sieci neuronowe.

⁶ L. Rutkowski, *Metody i techniki sztucznej inteligencji. Inteligencja obliczeniowa*, Wyd. Naukowe PAN, Warszawa 2009; A. Konar, *Computational Intelligence: Principles, Techniques and Applications*, Springer-Verlag 2005.

⁷ E.M. Sroczan, A. Urbaniak, *Wykorzystanie metod sztucznej inteligencji w monitorowaniu, sterowaniu i eksploatacji systemów zaopatrzenia w wodę i ochrony wód*, Materiały VI Międzynarodowej Konferencji „Zaopatrzenie w Wodę Miast i Wsi”, PZiTS, Poznań 2004, s. 695-704.

⁸ W.H. Shayya, S. S. Sablani, *An artificial neural network for non-iterative calculation of the friction factor in pipeline flow*, „Computers and Electronics in Agriculture” 1998 t. 21, nr 3, s. 219-228.

⁹ S. Lingireddy, L.E. Ormsbee, *Neural Networks in Optimal Calibration of Water Distribution Systems*, w: *Artificial Neural Networks for Civil Engineers: Advanced Features and Applications*, red. I. Flood, N. Kartam, ASCE 1998, s. 53-76.

¹⁰ J. Saldarriaga, R. Gómez, D. Salas, *Artificial intelligence methods applicability on water distribution networks calibration*, Proceedings Of The 2004 World Water and Environmental Resources Congress, Salt Lake City 2004.

Moduły obliczeniowe oparte na sztucznych sieciach neuronowych wprowadzono również do metod symulacyjnych, wykorzystywanych w sterowaniu sieciami wodociągowymi w czasie rzeczywistym. Zadaniem obliczeń neuronowych jest w tym przypadku uproszczenie modelu obliczeniowego i przyspieszenie obliczeń¹¹. W pracy¹² przyjęto jako cel obliczeń symulacyjnych optymalizację ciśnienia w poszczególnych węzłach sieci z uwzględnieniem prognozowanego zapotrzebowania na wodę. Do optymalizacji nastaw zaworów regulacyjnych opracowano sztuczną sieć neuronową. Problem sterowania siecią przy różnym ustawieniu zaworów regulacyjnych z wykorzystaniem sieci neuronowych poruszono również w artykule¹³. Wykorzystując dane ze stacji roboczej realizującej zdalne sterowanie systemem zaopatrzenia w wodę (ang. *SCADA – Supervisory Control and Data Acquisition*), wytrenowano samoorganizującą się sieć Kohonena, biorąc pod uwagę wartości nastaw zaworów regulacyjnych, przepływów oraz ciśnienia. Opracowaną sieć wykorzystano jako klasyfikator do wstępnej oceny nastaw zaworów regulacyjnych w systemie zaopatrzenia w wodę miasta *Fukuoka* w Japonii¹⁴.

Zastosowanie sztucznych sieci neuronowych do weryfikacji obliczeń systemu dystrybucji wody w zakresie średnic przewodów omówiono w pracach¹⁵,

¹¹ C. Xu, F. Bouchart, I.C. Goulter, *Neural networks for hydraulic analysis of water distribution systems*, Proceedings of the Innovation in Computer Methods for Civil and Structural Engineering, Civil-Comp Press, Cambridge 1997, s. 129-136; M. Damas, M. Salmeròn, J. Ortega, *ANNs and GAs for predictive controlling of water supply networks*, Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks, t. 4, s. 365-372, Como 2000; M. Świercz, *Using neural networks to simplify mathematical models of water distribution networks. A case study*, Proceedings of the First International Symposium on Mathematical Models in Automation and Robotics, Wyd. Uczelniane Politechniki Szczecińskiej, Szczecin 1994, s. 72-77; L. Yongchao, L. Wending, *Water Supply System of Telemeter and Remote Control Based on Neural Fuzzy Control Technique*, Proceedings of the 5th International Symposium on Test and Measurement Conference ITSM 2003, s. 1269-1272.

¹² A. Bargiela, *High performance neural optimization for real time pressure control*, Proceedings of High Performance Computing Conference HPC Asia'95, Chap. AL34, Taipei 1995, s. 1-8.

¹³ H.F. Van den Boogaard, A.C.H. Kruisbrink, *Hybrid modeling by integrating neural networks and numerical models hydraulic engineering*, Proceedings of the Second International Conference on Hydroinformatics 1996 t. 2, s. 471-477.

¹⁴ A. Haytham, A. Kwamura, K. Jinno, *Applications of artificial neural networks for optimal pressure regulation in supervisory water distribution networks*, Memoirs of the Faculty of Engineering, Kyushu University, Fukuoka, Japan 2005 t. 65, s. 29-51; A. Haytham, A. Kwamura, K. Jinno, *Analysis of motor valve operations in Fukuoka City water supply network using self-organizing map*, Memoirs of the Faculty of Engineering, Kyushu University, Fukuoka, Japan 2004, t. 64, s. 63-77.

¹⁵ J. Dawidowicz, *Classification Diameters of Water-supply Pipelines at Use Neural Networks*, I International Scientific and Technical Conference on Technology, Automation and Control of Wastewater and Drinking Water Systems TIASWIK'2002, Gdansk University of Technology, International Federation of Automatic Control, Gdańsk-Sobieszewo 2002, s. 349-355; J. Dawidowicz, *Metoda oceny średnic rurociągów wodociągowych przy użyciu sztucznych sieci neuronowych*, Materiały XIII Ogólnopolskiej Konferencji Naukowo-Technicznej: „Problemy gospodarki wodno-ściekowej w regionach rolniczo-przemysłowych”, „Monografie Komitetu Inżynierii Środowiska Polskiej Akademii Nauk” 2005 nr 30, s. 345-360.

natomiast ocenę rozkładu ciśnienia w sieci wodociągowej i jej układu omówiono w artykułach¹⁶.

Obliczenia liniowych strat ciśnienia

Podczas przepływu wody w przewodzie pod ciśnieniem w wyniku tarcia wewnętrznej warstwy wody oraz tarcia wody o ścianki przewodu występują straty hydrauliczne. Straty energii wywołane oporami przy przepływie wzdłuż odcinka przewodu, czyli straty liniowe obliczane są między innymi za pomocą równania Darcy – Weisbacha w postaci¹⁷:

$$\Delta h_l = \lambda \cdot \frac{L}{D_w} \cdot \frac{V^2}{2g} \quad (1)$$

gdzie:

- Δh_l – wysokość strat ciśnienia piezometrycznego, [m H₂O],
- λ – współczynnik oporów liniowych (liniowych oporów tarcia), [-],
- L – długość przewodu, [m],
- D_w – średnica wewnętrzna przewodu, [m],
- V – średnia prędkość przepływu w przekroju poprzecznym rurociągu, [m/s],
- g – przyspieszenie ziemskie, [m/s²].

Najtrudniejszym do obliczenia składnikiem wzoru (1) jest współczynnik oporów liniowych λ . Wartość λ może być obliczana przy użyciu różnych równań¹⁸ lub odczytywana z wykresów, lecz według PN-EN 805:2002 – w rurociągach sieci wodociągowych dla strefy burzliwego przepływu współczynnik oporów liniowych λ powinien być wyznaczany za pomocą wzoru *Colebrooka-White'a*¹⁹:

¹⁶ J. Dawidowicz, *The estimation of the run of pressure line in water-pipe network by means of artificial neural networks of MLP type*, 14th conference Problems of Water and Sewage Management in Agricultural and Industrial Regions, „Polish Journal of Environmental Studies” 2007 t. 16, nr 2A, s. 119-122; J. Dawidowicz, *Metody sztucznej inteligencji w diagnostyce wysokości ciśnienia w węzłach oraz układów sieci wodociągowych w procesie obliczeń hydraulicznych*, w: *Inteligentne systemy w inżynierii i ochronie środowiska*, Polskie Zrzeszenie Inżynierów i Techników Sanitarnych, Poznań 2007, s. 85-94.

¹⁷ Cz. Grabarczyk, *Przepływy cieczy w przewodach. Metody obliczeniowe*, Envirotech, Poznań 1997; Wł. Mielcarzewicz, *Obliczanie systemów zaopatrzenia w wodę*, wyd. II, Arkady, Warszawa 2000; A. Szpindor, *Zaopatrzenie w wodę i kanalizacja wsi*, Arkady, Warszawa 1998.

¹⁸ Cz. Grabarczyk, *Przepływy cieczy...*, op. cit; Cz. Grabarczyk, *Analiza porównawcza jawnych wzorów dla współczynnika liniowych strat hydraulicznych*, Przegląd Naukowy Wydziału Melioracji i Inżynierii Środowiska, Szkoła Główna Gospodarstwa Wiejskiego, z. 8, Warszawa 1995, s. 87-95.

¹⁹ C.F. Colebrook, C.M. White, *Experiments with Fluid Friction in Roughened Pipes*, Proceedings of the Royal Society of London. Series A, Mathematical and Physical Sciences 1937 t. 161, nr 906, s. 367-381; C.F. Colebrook, C.M. White, *The reduction of carrying capacity of pipes with age*, Proceedings of the Institution of Civil Engineers, t. 7, s. 99, London 1937; C. F. Colebrook, *Turbulent flow in pipes with particular reference to the transition region between the smooth and rough pipe laws*, „Journals-Institution of Civil Engineers” 1938 t. 11, s. 133-156.

$$\frac{1}{\sqrt{\lambda}} = -2 \lg \left(\frac{2,51}{\text{Re} \sqrt{\lambda}} + \frac{k}{3,71 D_w} \right) \quad (2)$$

gdzie:

k – współczynnik chropowatości bezwzględnej wewnętrznych ścian rurociagu, [m].

Na Międzynarodowym Kongresie Zaopatrzenia w Wodę w Paryżu w 1952 roku została przedstawiona wnikliwa analiza różnych wzorów wyznaczania współczynnika λ ²⁰, w wyniku której formułę *Colebrooka-White'a* uznano za najlepiej oddającą zgodność z wynikami pomiarów w strefie przepływu burzliwego. W powyższym wzorze λ jest funkcją trzech zmiennych: liczby Reynoldsa Re , współczynnika chropowatości bezwzględnej k oraz średnicy wewnętrznej D_w :

$$\lambda = f \left(\text{Re}, \frac{k}{D_w} \right) \quad (3)$$

gdzie:

Re – liczba Reynoldsa, [-],

k, D_w – jak we wzorach (1) oraz (2).

Liczba Reynoldsa charakteryzuje rodzaj ruchu w przewodach zamkniętych i wyrażona jest wzorem²¹:

$$\text{Re} = \frac{V \cdot D_w}{\nu} \quad (4)$$

gdzie:

ν – współczynnik lepkości kinematycznej, [m²/s],

V, D_w – jak we wzorach (1) oraz (2).

Współczynnik lepkości kinematycznej ν zależy od temperatury i jego wartość odczytywana jest z tablic²². Przyjmuje się, że warunkach eksploatacji systemów dystrybucji wody zmiany gęstości oraz lepkości wody w zależności od zmian temperatury i ciśnienia są na tyle małe, że można je pominąć²³. W obliczeniach systemów dystrybucji wody przyjmuje się wartość współczynnika lepkości $\nu = 1,306 \cdot 10^{-6}$ m²/s dla temperatury 283,15 K (10°C).

Prędkość przepływu do wzorów (1) oraz (4) można ustalić na etapie doboru średnicy przewodu z równania:

$$D_w = \sqrt{\frac{4 \cdot Q_m}{\pi \cdot V}} \quad (5)$$

gdzie:

Q_m – miarodajne natężenie przepływu wody przez przewód, [m³/s].

²⁰ P.A. Lamont, *British National Report on Formulae for Pipeline Calculations*, Proceedings 2nd International Water Supply Congress, Paris 1952; P.A. Lamont, *The choice flow laws for practical use*, „Water and Water Engineering” 1969 t. 2, s. 55-63.

²¹ Cz. Grabarczyk, *Przepływy cieczy w przewodach. Metody obliczeniowe*, Envirotech, Poznań 1997.

²² J. Sobota, *Hydraulika i mechanika płynów*, Wyd. Uniwersytetu Przyrodniczego we Wrocławiu, Wrocław 2003.

²³ M. T. Walsk i in, *Advanced Water...*, op. cit.

Ostatecznie na podstawie analizy wzorów (2), (4) oraz (5) można stwierdzić, że wymaganymi zmiennymi początkowymi do obliczenia współczynnika oporów liniowych λ są:

- miarodajne natężenie przepływu przez odcinek Q_m ;
- współczynnik chropowatości bezwzględnej k ;
- średnica wewnętrzna D_w .

Powyższe zmienne zostały przyjęte jako wartości wejściowe sieci neuronowej do obliczania współczynnika oporów liniowych λ . Lepkość ν można przyjąć jako wartość stałą.

Obliczenia współczynnika oporów liniowych λ za pomocą sztucznych sieci neuronowych

Najpopularniejszym obecnie rodzajem sieci neuronowej jest perceptron wielowarstwowy (ang. *MLP – multilayer perceptron*), który składa się z neuronów ułożonych w warstwy²⁴. Neurony połączone są pomiędzy warstwami na zasadzie „każdy z każdym”, natomiast w jednej warstwie nie występują połączenia pomiędzy neuronami. Do połączeń pomiędzy neuronami przypisane są współczynniki wagowe, których wartości ustalane są w procesie uczenia sieci. Liczba warstw ukrytych i neuronów w poszczególnych warstwach wpływa na możliwości odwzorowania przez sieć zależności reprezentowanej przez zbiór danych wejściowych oraz odpowiadających im wartości wyjściowych (wartości zadanych). Sieci typu perceptron wielowarstwowy mają charakter nieliniowy, w związku z czym mogą modelować funkcje o prawie dowolnej złożoności²⁵. Sieci neuronowe były sporządzone za pomocą pakietu STATISTICA.

Dane do uczenia sieci neuronowych

Uzyskanie sieci neuronowej o pożądanym właściwościach w znacznym stopniu uzależnione jest od jakości zbioru danych uczących. Powyższy zbiór składa się z wartości zmiennych wejściowych, opisanych za pomocą wektora $[k, D_w, Q_m]^T$ oraz odpowiadających im danych wyjściowych w postaci współczynnika oporów liniowych λ . Wartość wyjściowa (zadana) λ uzyskana jest w wyniku obliczeń na podstawie danych z wektora wejściowego. Obliczenia współczynnika oporów liniowych λ wykonano dla:


- wzoru *Colebrooka-White'a* (2);

²⁴ J. Żurada, M. Barski, W. Jędruch, *Sztuczne sieci neuronowe*, Wyd. Naukowe PWN, Warszawa 1996; C. M. Bishop, *Neural Networks for Pattern Recognition*, Oxford University Press, Oxford 1995.

²⁵ K. Hornik, M. Stinchcombe, H. White, *Multilayer feedforward networks are universal approximators*, „Neural Networks” 1989 t. 2, s. 359-366.

Rysunek 1

Histogram liczebności przykładów uczących według średnic nominalnych przewodów



Źródło: opracowanie własne.


- średnic nominalnych DN90, DN110, DN160, DN225, DN250, przyjmując wartości średnic wewnętrznych dla rur PVC typoszereg PN10 SDR 26;
- zakresu współczynnika chropowatości bezwzględnej $k = 0,05 - 2,0$;
- przepływów miodrajnych $Q_m = 0,1 - 100$ l/s, przyjmując wartości zapewniające prędkości zbliżone do optymalnych dla poszczególnych średnic.

Liczebność przykładów uczących w zbiorze danych dla poszczególnych średnic pokazano na rysunku 1. W wyniku obliczeń współczynnika oporów liniowych λ dla powyższych założeń uzyskano zbiór 19 715 przykładów uczących. Obliczenia λ zrealizowano za pomocą sporządzonej procedury numerycznej. Zbiór danych w procesie uczenia sieci został podzielony na podzbiory: uczący, walidacyjny i testowy.

Charakterystyka uzyskanej sieci neuronowej


Uwzględniając właściwość sieci neuronowych, które pozwalają na modelowanie wielowymiarowych, nieliniowych zależności, podjęto próbę uzyskania sieci neuronowej umożliwiającej bezpośrednio na podstawie danych charakteryzujących odcinek obliczenie współczynnika oporów liniowych λ . Poszukiwania odpowiedniej struktury sieci neuronowej typu perceptron wielowarstwowy rozpoczęto od 2 neuronów w warstwie ukrytej. Ostatecznie przyjęto sieć z 10 neuronami z logistyczną funkcją aktywacji w warstwie ukrytej oraz jednym neuronem z liniową funkcją aktywacji w warstwie wyjściowej, odpowiedzialnym za wprowadzenie wartości z sieci (rysunek 2).

Rysunek 2
Schemat sieci neuronowej do obliczania współczynnika oporów liniowych λ



Źródło: opracowanie własne.


Rysunek 3
Rozrzut wartości λ obliczanych przez sieć neuronową względem wartości zadanych



Źródło: opracowanie własne.

Po procesie uczenia sieci obliczono współczynnik korelacji Pearsona pomiędzy wartościami zadanymi λ a obliczonymi przez sieć neuronową. Uzyskano bardzo wysoką korelację, wynoszącą odpowiednio dla podzbiorów: uczącego $r = 0,9979485$, walidacyjnego $r=0,9978741$ oraz testowego $r=0,9979538$. Wykres rozrzutu pomiędzy wartościami zadanymi i wyliczonymi przez sieć neuronową pokazano na rysunku 3. Z kolei na rysunku 4 zamieszczono histogram odchyłek wartości λ obliczonych przez sieć neuronową od odpowiednich wartości zadanych. Wyraźnie widać, że większość odchyłek mieści się w bardzo wąskim przedziale $\langle -0,001, 0,001 \rangle$.

Rysunek 4

Histogram odchyłek wartości λ obliczanych za pomocą sieci neuronowej od wartości zadanych

Źródło: opracowanie własne.

Podsumowanie

Obliczenia współczynnika oporów liniowych λ za pomocą sztucznych sieci neuronowych dają bardzo dobre rezultaty. Należy mieć jednak na uwadze, że rozwiązanie powyższe wymaga sporządzenia zbioru danych uczących o bardzo dużej liczbie przykładów opisujących zależność λ od danych wejściowych. W niniejszym artykule opisano obliczenia dla średnic przewodów z PVC w zakresie od DN90 do DN250. W dalszej pracy należy zwiększyć zakres średnic, lecz pytaniem otwartym pozostaje kwestia, czy powinna być uczona sieć neuronowa dla wszystkich średnic jednocześnie, czy przedziałami w typoszeregu. Związane to jest ze znacznym wzrostem wielkości zbioru uczącego oraz komplikacją sieci neuronowej, co znacznie utrudnia proces jej uczenia.