

Przegląd obecnie istniejących instalacji LNG na świecie, aspekty techniczne pojedynczej stacji oraz prognozowanie zużycia gazu. Część 2 – obliczenia

Overview of currently existing LNG facilities worldwide, technical aspects of an individual station, and forecasting gas consumption. Part 2. – calculations

Tomasz Cieślík, Piotr Narloch, Andrzej Żero*

Słowa kluczowe: przesył gazu ziemnego, dystrybucja gazu ziemnego, prognozowanie, instalacja LNG, rynek gazu ziemnego, gazyfikacja, LNG, sztuczne sieci neuronowe.

Streszczenie

Jednym z warunków prawidłowego zarządzania pracą sieci wyspowej zasilanej z stacji regazyfikacji LNG jest planowanie dostaw opartych o prognozy zużycia. Na podstawie zgromadzonych danych atmosferycznych oraz zużycia gazu z wybranej stacji na przestrzeni dwóch lat określono wpływ czynników atmosferycznych na konsumpcję gazu ziemnego za pomocą sztucznych sieci neuronowych. Wyznaczono wpływ miesiąca oraz dnia (parametr sztuczny) na konsumpcję gazu. Wyznaczono model sieci neuronowych dający najlepsze dopasowania za pomocą współczynnika korelacji.

Keywords: natural gas transmission, natural gas distribution, LNG installations, forecasting, natural gas market, gasification, LNG, artificial neural networks.

Abstract

One of the conditions for proper management of the islanded network supplied by LNG regasification stations is planning deliveries based on consumption forecasts. Based on collected meteorological data and gas consumption from a selected station over a two-year period, the impact of atmospheric factors on natural gas consumption was determined using artificial neural networks. The influence of the month and day (artificial parameter) on gas consumption was identified. A neural network model was developed to achieve the best fits using correlation coefficients.

1 Rola prognozy

W chwili obecnej prognozy pełnią fundamentalną rolę w zarządzaniu infrastrukturą krytyczną jaką są sieci gazowe [18]. Gaz ziemny wykorzystywany jest m.in.: do ogrzewania mieszkań, wytwarzania energii elektrycznej, podgrzewania wody oraz przygotowania posiłków, jest ważnym surowcem w zrównoważonej gospodarce co potwierdza jego rosnące znaczenie w czasie transformacji energetycznej jako paliwo przejściowe [8, 29]. W tym kontekście ważne są prace nad opracowywaniem precyzyjnych prognoz, które pozwalają na przewidzenie zapotrzebowania na gaz ze strony przemysłu i odbiorców komunalnych oraz podejmowanych politycznych decyzji [8, 22]. Kolejnym ważnym czynnikiem skłaniającym do podejmowania prac nad udoskonaleniem modeli prognostycznych zużycia gazu jest fakt, iż dokładne prognozy mogą pomóc prowadzić zarządzanie siecią gazową w sposób ekonomiczny i ciągły, gdyż mają wpływ funkcjonowanie sieci gazowej oraz na jej niezawodne dostarczanie paliwa. W chwili obecnej nie

istnieją gotowe rozwiązania opisujące zapotrzebowanie na gaz, dlatego tym bardziej należy podejmować próby znalezienia i zdefiniowania jak najlepszych metod [2, 6]. Określenie zużycia gazu w nadchodzącym czasie pozwoli na podjęcie decyzji planistycznych dotyczących zakupu surowca przez krajowe i lokalne spółki dystrybucyjne, z uwzględnieniem przepustowości gazociągów, planowanych remontów i inwestycji związanych z bieżącą eksploatacją sieci jak i zagwarantowanie bezpieczeństwa pracy infrastruktury gazowej [4, 7, 20, 3]. W związku z tym, przeprowadzono szereg analiz literaturowych odwołujących się do obecnego stanu wiedzy na temat prognozowania zużycia gazu [24, 12]. W dostępnych źródłach można zetknąć się z informacją, że najczęściej wykorzystywaną daną do prognozowania zużycia gaz dla obszaru miejskiego w funkcji czasu jest temperatura [2, 13, 27, 11, 19]. Poza temperaturą w modelach stosowana jest również prędkość wiatru [20, 11, 15]. W celu poprawy jakości modeli wykorzystywano dane sztuczne np. dni tygodnia [20, 11].

***Tomasz Cieślík** – Politechnika Krakowska im. Tadeusza Kościuszki, Wydział Inżynierii Środowiska i Energetyki, Katedra Procesów Ciepłych, Ochrony Powietrza i Utylizacji Odpadów, Instytut Fizyki Jądrowej im. Henryka Niewodniczańskiego Polskiej Akademii Nauk, **Piotr Narloch** – AGH Akademia Górniczo-Hutnicza, Wydział Wiernictwa Nafty i Gazu, Katedra Inżynierii Gazowniczej, Polska Spółka Gazownictwa sp. z o.o., **Andrzej Żero** – Polska Spółka Gazownictwa sp. z o.o., Państwowa Akademia Nauk Stosowanych im. Ignacego Mościckiego, Wydział Inżynierii i Ekonomii, andrzej.zero@pansim.edu.pl


Przywołane opracowania dotyczą odbioru gazu z sieci gazowej, natomiast zauważa się brak informacji dotyczących tzw. wyspowych sieci gazowych zasilanych ze stacji regazyfikacji LNG. Modelowanie zapotrzebowania na gaz dla małych sieci obciążone jest większym ryzykiem niepewności. Prognozowanie zapotrzebowania na gaz w przypadku małej sieci gazowej (mała liczba odbiorców, ale z możliwą dużą różnorodnością profili odbiorców) wymaga zatem zastosowania bardziej zaawansowanych narzędzi prognostycznych niż proste prognozowanie na podstawie zapotrzebowania historycznego. Niniejsze opracowanie ma za zadanie przybliżyć pracę takiej sieci oraz pokazać metodę prognozowania zużycia gazu, która jest bardzo istotna w kontekście planowania łańcucha dostaw.

2. Opis przypadku

Analizie podano stację LNG, która zlokalizowana jest w północno-wschodniej Polsce i zasila zarówno odbiorców komunalno-bytowych jak i firmy. Stacja regazyfikacji LNG poddana analizie posiada dwa zespoły parownic atmosferycznych (AAV – ambient air vaporizes) każdy o przepustowości 1200 m³/h oraz wyposażona jest w dwa zbiorniki kriogeniczne o pojemności wodnej 60 m³. Z analizy zużycia gazu można wywnioskować, iż odbiorcami są przede wszystkim gospodarstwa domowe. Wynika to z dużej zmienności poboru gazu między okresem letnim, a zimowym co jest charakterystyczne dla odbiorców indywidualnych, którzy gaz wykorzystują w celach komunalnych. W okresie zimowym wzrasta zużycie gazu natomiast w okresie letnim maleje (od czerwca do połowy września) i utrzymuje się na minimalnym poziomie. Minimalne zużycie gazu jakie występuje w okresie letnim przede wszystkim wykorzystywane jest do podgrzewania wody użytkowej oraz przygotowania posiłków (Rys. 1). Również dostrzega się mniejsze zużycie gazu w sobotę i niedzielę względem pozostałych dni tygodnia (Rys 2).

3. Metoda wykorzystywana do obliczeń

Sieć neuronowa zbudowana jest z jednej warstwy wejściowej, warstwy lub kilku warstw ukrytych oraz jednej warstwy wyjściowej. Podstawowym elementem składowym warstwy jest neuron. Sztuczny neuron występujący w warstwie poprzedzającej połączony jest ze wszystkimi sztucznymi neuronami kolejnej warstwy. W chwili obecnej nie ma optymalnej metody na dobór liczby neuronów SSN (*Sztucznej Sieci Neuronowej*). Gdy ich liczba jest za duża to obliczenia wydłużają się, a sieć może ulec przecuczeniu i utracić najważniejszą swoją zaletę, czyli zdolność uogólniania. Również zbyt duża liczba neuronów (lub warstw) może spowodować,




Rys. 2. Zużycie gazu z badanej stacji LNG w zależności do dni tygodnia (opracowanie własne)

Fig. 2. Gas consumption from the tested LNG station depending on the days of the week. Axis y – gas consumption m³/day (own study)

wać, że sieć nie będzie mogła być obsługiwana na standardowych procesorach. Każdy neuron występujący w danej warstwie posiada określoną liczbę wejść (sygnałów) przemnożonych przez odpowiednie wagi (w_n) [28]).

Zasadę działania sztucznych neuronów można porównywać do ich biologicznych wzorców [17] (Rys. 3).

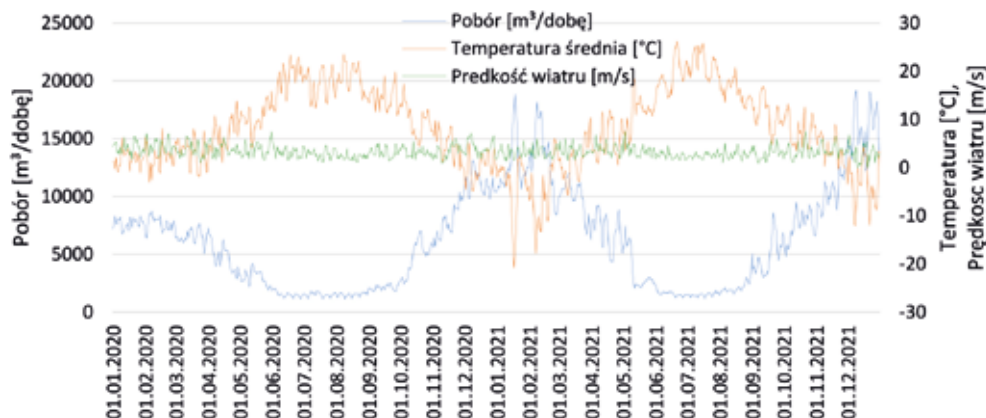


Rys. 3. Model blokowy sztucznego neuronu (opracowanie własne na podstawie: [10])

Fig. 3. A block model of an artificial neuron own study based on [10]

gdzie:

- $u_1 \dots u_n$ – wejścia – to dendryty, lub ściślej sygnały przez nie nadchodzące,
- $w_1 \dots w_n$ – wagi – są to odpowiedniki synaps,
- Σ – blok sumacyjny – odpowiednik jądra,
- ϕ – blok aktywacji – to odpowiednik wzgórka aksonu,
- y – wyjście – to odpowiednik aksonu. Sztuczny neuron zbiera sygnały, które do niego docierają mnożąc je poprzez wagi przypisane



Rys. 1. Charakterystyka poboru gazu z badanej stacji LNG w zależności od warunków pogodowych (opracowanie własne)

Fig. 1. Characteristics of gas consumption from the tested LNG station depending on weather conditions (own study)

każdemu sygnałowi, a następnie kierowane są do bloku sumującego, który odpowiada za pobudzenie neuronu. Pobudzone sygnały kierowane są do nieliniowej funkcji aktywacji, gdzie generowany jest sygnał [23] Obecnie najczęściej wykorzystywane są sieci wielowarstwowe. Warstwa wejściowa (pierwsza) przyjmuje sygnał, ale nie zmienia go. Następnie ma miejsce aktywacja neuronów w pierwszej warstwie ukrytej, gdzie wykonywana jest większa część obliczeń. Warstwa ukryta przetwarza sygnał i tworzy model związany ściśle z analizowanym procesem. Po przeanalizowaniu sygnałów w warstwie ukrytej generowane są sygnały pośrednie do wszystkich neuronów warstwy wyjściowej. Warstwa wyjściowa generuje sygnał wyjściowy [23, 28].

W badanym przypadku wejściami są informacje dotyczące pogody, czyli temperatura, prędkość wiatru oraz wilgotność jak również dane sztuczne (opisane w kolejnym rozdziale). Wyjściem natomiast jest zużycie gazu ziemnego.

Można wyróżnić dwie metody uczenia sieci neuronowych. Z nauczycielem (najczęściej stosowane), poprzez dobranie wag dzięki podawanym na wejściu wzorcowych sygnałów w celu najlepszego odwzorowania sygnału na wyjściu. Innymi słowy, sieć dobiera sobie do posiadanych wyników wagi w celu jak najlepszego odwzorowania. Metoda bez nauczyciela polega na tym, że sieć odbiera sygnał na wejściu i generuje sygnał na wyjściu bez podawania danych wyjściowych. W przypadku, gdy nie można zastosować sygnałów wejście/wyjście, stosuje się wzmocnienie. Wzmocnienie dostarczane do układu interpretowane jest jako negatywny lub pozytywny sygnał [23, 9, 14, 16, 26, 31].

4. Obliczenia

Założeniem wykonywanych obliczeń było znalezienie jak najlepszego dopasowania wyników modelu do rzeczywistych wartości. Dla warstwy wejściowej i wyjściowej sztucznych sieci neuronowych wykorzystano funkcje aktywacji: liniową, logistyczną, tangensoidalną oraz wykładniczą. Do obliczeń wykorzystano algorytm BFGS (ang. Broyden–Fletcher–Goldfarb–Shanno) [1, 21, 5]. Na początku przeprowadzono analizę wpływu liczby neuronów oraz ilości stopni iteracji na jakość modelu. Do budowy modelu wykorzystano tylko temperaturę i prędkość wiatru. Wyniki pokazują, że im bardziej model jest rozbudowany (sztuczna sieć neuronowa posiada dużą ilość neuronów w warstwie ukrytej) oraz im większej liczbie iteracji (cykli uczenia) został podany to współczynnik korelacji Pearsona maleje (Rys. 4).

Współczynnik korelacji liniowej Pearsona jest najczęściej stosowanym miernikiem współzależności między dwiema cechami mierzalnymi i przyjmuje wartość z przedziału [-1,1] [25].

Siłę korelacji można określać na następujących poziomach (Tab. 1):

Do przeprowadzenia obliczeń prognozujących zużycie gazu wykorzystano temperaturę: średniodobową, średnią z ośmiu godzin oraz średnią godzinową. Do prowadzenia obliczeń wykorzystywano również dane dodatkowe: prędkość wiatru, wilgotność,

Tabela 1. Stopnie zależności dwóch cech określających siłę związku (25. Stanisław 2006)

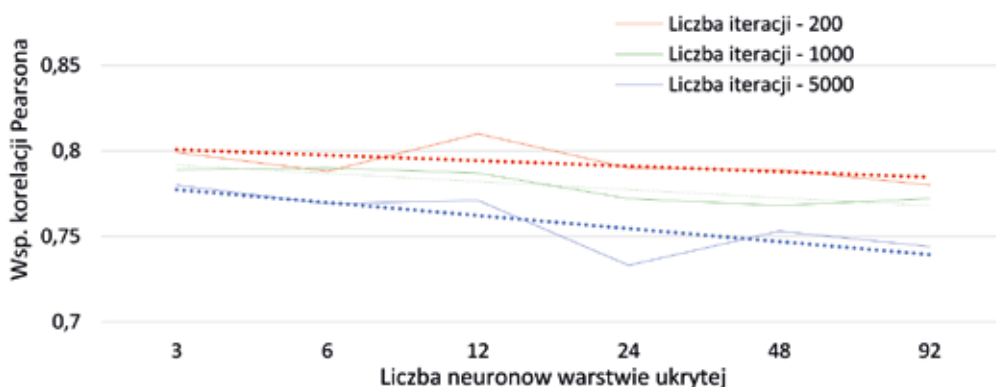
Wartość wsp. Pearsona	Typ korelacji
$ r =0$	zmienne nie są skorelowane
$0< r <0,1$	nikła
$0,1\leq r <0,3$	słaba
$0,3\leq r <0,5$	przeciętna
$0,5\leq r <0,7$	wysoka
$0,7\leq r <0,9$	bardzo wysoka
$0,9\leq r <1$	prawie pełna

a także nasłonecznienie. Również zostały utworzone modele wykorzystujące dane historyczne (od jednego do 6 dni wstecz). Dane historyczne dotyczyły wszystkich danych atmosferycznych. Zasada wykorzystania danych wstecz polega na tym, że poza informacjami o temperaturze i prędkości wiatru, które mogą mieć wpływ na zużycie gazu w danym dniu, wykorzystano wartości temperatury i prędkość wiatru jakie wystąpiły w przeszłości. Na podstawie tych danych nowa sieć neuronowa uczyła się w celu znalezienia najlepszego modelu. Dla obliczeń sztucznej sieci neuronowej wykorzystywano w przypadku temperatury średniodobowej 16 konfiguracji oraz 8 konfiguracji przy temperaturze średnio ośmiogodzinowej i średnio godzinowej. Natomiast w przypadku wykorzystania dni wstecz dla temperatury średniodobowej było to 12 konfiguracji, a dla temperatury średnio ośmiogodzinowych i średnio godzinowych po 64 różne konfiguracje.

5. Wyniki

W oparciu o tabelę 1 przeprowadzono analizę uzyskanych wyników. Tabele 2-5 prezentują różne wyniki współczynników korelacji, które zostały otrzymane poprzez wykorzystanie różnych modeli sieci neuronowych w zależności od danych uczących oraz od struktury sieci (różna liczba neuronów w warstwie ukrytej).

Modele wykorzystujące średniodobowe informacje o warunkach atmosferycznych osiągały współczynnik korelacji poniżej 0,8 z wyjątkiem modelu nr 2 (Tab. 2), który uzyskał współczynnik korelacji 0,800 (nr modelu 2). Model ten wykorzystywał podczas procesu trenowania informacje o temperaturze i prędkości wiatru. W celu poprawy dopasowania do procesu uczenia dołożono dane sztuczne dotyczące informacji o zużyciu gazu w danych miesiącu i dniu tygodnia. Otrzymano dopasowanie na poziomie wsp. korelacji 0,891 (korelacja bardzo wysoka) w modelu nr 10 (Tab. 2), który poza wspomnianymi zmiennymi sztucznymi wykorzystywał również temperaturę i prędkość wiatru. W przypadku zwiększenia częstotliwości danych do średnio ośmiogodzinowych tylko model nr 20 (Tab. 3) wykorzystujący temperaturę, prędkość wiatru i wilgotność, bez użycia danych sztucznych osiągnął wsp. korelacji w wysokości 0,867. Dla danych pogodowych mierzonych co godzinę najlepszy wynik (wsp. korelacji równy 0,861), osiągnięto w przypadku modelu nr 25 (Tab. 4), bez danych sztucznych i wykorzystujący tylko informacje o temperaturze. Dopasowanie najlepszych modeli zaprezentowano na Rys. 5.



Rys. 4. Wpływ liczby neuronów oraz stopni iteracji na współczynnik korelacji. Linia przerywana jest linią trendu (źródło: opracowanie własne)

Fig. 4. The influence of the number of neurons and the degrees of iteration on the correlation coefficient. The dashed line is the trend line (own study)

Tabela 2. Wyniki uzyskane dla różnych konfiguracji modeli sztucznych sieci neuronowych przy wykorzystaniu temperatury średnio dobowej. Dane wykorzystywane do uczenia: A – Temperatura [C], B – prędkość wiatru [m/s], C – wilgotność [%], D-Nasłonecznie [h], E-dane sztuczne (opracowanie własne)

Table 2 Results obtained for various configurations of artificial neural network models using average daily temperature. Data used for teaching: A – temperature [C], B – wind speed [m/s], C – humidity [%], D-sunshine [h], E-artificial data (own study)

Nr. modelu	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Dane	A	A, B	A, C	A, B, C	A, D	A, B, D	A, C, D	A, B, C, D	A, E	A, B, E	A, C, E	A, B, C, E	A, D, E	A, B, D, E	A, C, D, E	A, B, C, D, E
Wsp korelacji	0,732	0,800	0,706	0,778	0,752	0,786	0,724	0,794	0,811	0,891	0,786	0,839	0,812	0,835	0,792	0,835

Tabela 3. Wyniki uzyskane dla różnych konfiguracji modeli sztucznych sieci neuronowych przy wykorzystaniu temperatury średnio ośmiogodzinnej. Dane wykorzystywane do uczenia: A – Temperatura [C], B – prędkość wiatru [m/s], C – wilgotność [%], E-dane sztuczne (opracowanie własne)

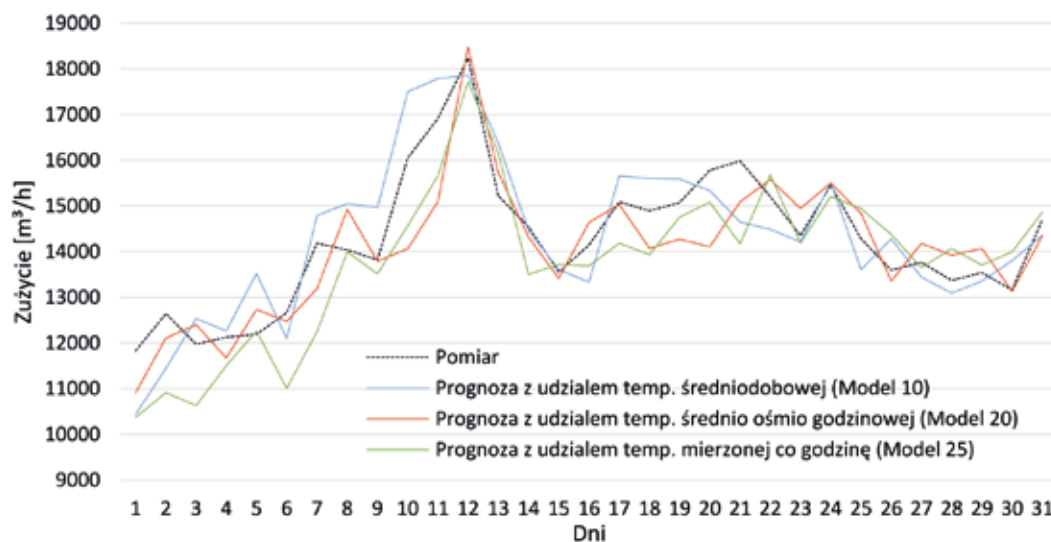
Table 3 Results obtained for various configurations of artificial neural network models using an average eight-hour temperature Data used for teaching : A – temperature [C], B – wind speed [m/s], C – humidity [%], E-artificial data (own study)

Nr. modelu	17	18	19	20	21	22	23	24
Dane	A	A, B	A, C	A, B, C	A, E	A, B, E	A, C, E	A, B, C, E
Wsp korelacji	0,633	0,590	0,755	0,867	0,771	0,717	0,773	0,751

Tabela 4. Wyniki uzyskane dla różnych konfiguracji modeli sztucznych sieci neuronowych przy wykorzystaniu temperatury średnio godzinowej. Dane wykorzystywane do uczenia: A – Temperatura [C], B – prędkość wiatru [m/s], C – wilgotność [%], E-dane sztuczne (opracowanie własne)

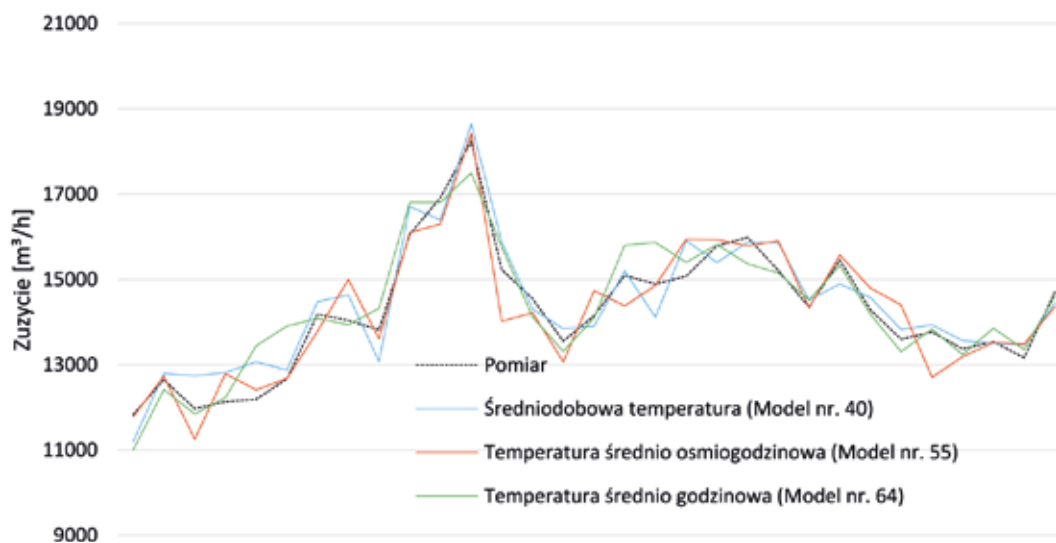
Table 4 Results obtained for various configurations of artificial neural network models using average hourly temperature. Data used for teaching: A – temperature [C], B – wind speed [m/s], C – humidity [%], E-artificial data (own study)

Nr. modelu	25	26	27	28	29	30	31	32
Dane	A	A, B	A, C	A, B, C	A, E	A, B, E	A, C, E	A, B, C, E
Wsp korelacji	0,861	0,775	0,745	0,774	0,808	0,775	0,791	0,783



Rys. 5. Dopasowanie najlepszych modeli do rzeczywistego zużycia gazu (opracowanie własne)

Fig. 5. Matching the best models to the actual gas consumption (own study)



Rys. 6. Dopasowanie najlepszych modeli wykorzystujących dane wstecz do rzeczywistego zużycia gazu (opracowanie własne)

Fig. 6. Matching the best models using backward data and actual gas consumption (own study)

Tabela 5. Wyniki uzyskane dla różnych konfiguracji modeli sztucznych sieci neuronowych przy wykorzystaniu danych wstecz. Dane wykorzystywane do uczenia: A – temperatura [C], B – prędkość wiatru [m/s], C – wilgotność [%], E – dane sztuczne (opracowanie własne)

Table 5. Results obtained for various configurations of artificial neural network models using backward data. Data used for teaching: A – temperature [C], B – wind speed [m/s], C – humidity [%], E – artificial data (own study)

Częstotliwość pomiaru temperatury		Liczba dni wstecz					
		1	2	3	4	5	6
Średniodobowa temperatura	Nr. modelu	33	34	35	36	37	38
	dane	A,B	A,B	A,B	A,B	A,B	A,B
	Wsp. korelacji	0,875	0,889	0,883	0,886	0,888	0,901
	Nr. modelu	39	40	41	42	43	44
	dane	A, B, E	A, B, E	A, B, E	A, B, E	A, B, E	A, B, E
	Wsp. korelacji	0,892	0,948	0,902	0,889	0,894	0,874
Średnio ośmiogodzinowa temperatura	Nr. modelu	45	46	47	48	49	50
	dane	A,C	A,C	A,C	A,C	A	A
	Wsp. korelacji	0,843	0,834	0,844	0,873	0,908	0,870
	Nr. modelu	51	52	53	54	55	56
	dane	A, C, E	A, E	A, E	A, B, E	A, B, E	A, B, E
	Wsp. korelacji	0,8159	0,86744	0,891	0,899	0,936	0,911
Średnio godzinowa temperatura	Nr. modelu	57	58	59	60	61	62
	dane	A,B,C	A	A	A	A,B,C	A
	Wsp. korelacji	0,847	0,869	0,856	0,864	0,834	0,845
	Nr. modelu	63	64	65	66	67	68
	dane	A, B, E	A, B, C, E	A, B, C, E	A, B, C, E	A, E	A, E
	Wsp. korelacji	0,816	0,941	0,896	0,894	0,872	0,892

W celu poprawienia dopasowania modelu wykorzystano dni wstecz (Tab. 5). Dla modelu zbudowanego z wykorzystaniem temperatury średniej, wykonano obliczenia z wykorzystaniem konfiguracji z temperaturą i prędkością wiatru wstecz. Można zauważyć, że wraz ze wzrostem liczby dni wstecz dla modelu bez danych sztucznych, pojawia się trend wzrostowy współczynnika korelacji, natomiast dla modelu z danymi sztucznymi osiąga on najwyższą wartość przy dwóch dniach (model nr 40 – wsp. korelacji 0,948 – korelacja pełna) i następnie spada do poziomu poniżej 0,9.

Dla modeli wykorzystujących temperaturę średnio ośmiogodzinową zauważa się wzrost wsp. korelacji wraz ze wzrostem liczby dni wstecz aż do pięciu dni, a następnie spadek. Najwyższy wynik jaki osiągnięto to wsp. korelacji 0,936 dla modelu nr. 55

W przypadku modeli wykorzystujących temperaturę mierzoną co godzinę, występuje sytuacja, gdzie do dwóch dni wstecz następuje wzrost współczynnika korelacji, a następnie jego spadek. Najlepsze dopasowanie to 0,941 (korelacja pełna) dla modelu nr 64. We wszystkich przypadkach dostrzega się lepsze dopasowanie modeli wykorzystujących dane sztuczne. Najwyższe dopasowanie wynosiło 0,948 wsp. korelacji (korelacja pełna) (Rys. 6).

6. Wnioski

Analizie poddano zużycie gazu z wybranej stacji LNG w okresie od stycznia 2020 r. do grudnia 2021 r., a prognozę wykonano dla stycznia 2022 r. Można zauważyć, że zużycie gazu jest silnie skorelowane z temperaturą atmosferyczną; przy jej wzroście ma miejsce spadek zużycia gazu, a w przypadku ochłodzenia zapotrzebowanie na gaz rośnie. Dzięki wykorzystaniu danych sztucznych takich jak zużycie gazu w określonym dniu tygodnia oraz miesiąca udało się poprawić jakość modeli prognozy.

Model nr 10 wykorzystujący temperaturę średniodobową, wiatr i dane sztuczne osiągnął najwyższą wartość współczynnika korelacji wynoszącą 0,891 wśród modeli bez danych wstecz. Należy wspomnieć iż zwiększenie częstotliwości danych pogodowych nie wpłynęło poprawie jakości modelu.

Dodanie danych sztucznych poprawiało jakość modeli prognozy, co świadczy o wpływie nie tylko miesiąca, ale także danego dnia w tygodniu na zużycie gazu. Rozbudowanie modelu o dane temperaturowe dni poprzednich skutkowało wzrostem wsp. korelacji do wartości 0,948 wsp. korelacji (korelacja pełna). Najwyższa wartość dopasowania była dla modelu z dwoma dniami wstecz. Wykorzystanie dni wstecz może być użyte do określenia bezwładności termicznej budynków (okres wychładzania) w okresie zimowym. Należy kontynuować badania prognoz w oparciu o godzinowe zużycie gazu i godzinowe zmiany pogody co będzie miało wpływ na wielkość modelu (liczbę danych uczących).

Z punktu widzenia operatorów systemu dystrybucyjnego niezwykle istotne jest, aby zapewnić ciągłość dostaw LNG do wyspowych stacji. W okresie letnim ze względu na specyfikę badanego przypadku nie występuje duże zużycie gazu. W okresie zimowym pobór wzrasta ponad 4-krotnie i występują duże amplitudy zużycia gazu w poszczególnych dniach.

Przedstawione w pracy modele mogą posłużyć do zarządzania systemem dostaw gazu do stacji LNG w oparciu o prognozy zużycia gazu w zależności od warunków atmosferycznych. Prawidłowe prognozowanie zapotrzebowania na paliwo gazowe ma również znaczenie z punktu widzenia optymalizacji pracy brygad nadzorujących proces tankowania. Możliwość zaplanowania pracy brygad obsługujących proces tankowania oraz powiązanie tego procesu z innymi czynnościami obsługowymi może wpływać na koszty wewnętrzne operatora np. poprzez unikanie dodatkowych wyjazdów na obiekty stacji regazyfikacji LNG w niewielkich odstępach czasowych [32].

LITERATURA

- [1] Asrul Hery Bin Ibrahim M., Mamat M. T. and June Leong W. 2014. "BFGS Method: A New Search Direction" *Sains Malaysiana* 43(10): 1593-1599.
- [2] Bai Y. and Li C. 2016. "Daily natural gas consumption forecasting based on a structure calibrated support vector regression approach". *Energy Build* (127): 571-579. <https://doi.org/10.1016/j.enbuild.2016.06.020>.
- [3] Baldacci L., Golfarelli M., Lombardi D. and Sami F. 2016. "Natural gas consumption forecasting for anomaly detection". *Expert Systems with Applications* (62): 190-201. <https://doi.org/10.1016/j.eswa.2016.06.013>.
- [4] Bartnicki G. i Nowak B. 2018. "Model ARIMA w prognozowaniu zużycia gazu w cyklach miesięcznych". *Zeszyty Naukowe Instytutu Gospodarki Surowcami Mineralnymi i Energią Polskiej Akademii Nauk* (103): 145-158. doi: 10.24425/123712.
- [5] Blelly A., Felipe-Gomes M., Auger A. and Brockhoff D. 2018. "Stopping criteria, initialization, and implementations of BFGS and their effect on the BB0B test suite". *GECCO 18: Proceedings of the Genetic and Evolutionary Computation Conference Companion, Kyoto: 1513-1517*. <https://doi.org/10.1145/3205651.3208303>.
- [6] Brown R. H. et al. 2017. "Improving Daily Natural Gas Forecasting by Tracking and Combining Models". 37th. International Symposium on Forecasting, Australia. Available at: http://works.bepress.com/george_corliss/11/.
- [7] Dagoumas A. S. and Panapakidis I. P. 2017. "Day-ahead natural gas demand forecasting based on the combination of wavelet transform and ANFIS/genetic algorithm/ neural network model". *Energy* (118): 231-245. <https://doi.org/10.1016/j.energy.2016.12.033>.
- [8] Ervural B. F., Beyca O. F. and Zaim. S. 2016. "Model estimation of ARMA using genetic algorithms: A case study of forecasting natural gas consumption". *Procedia – Social and Behavioral Sciences* (235): 537-545. <https://doi.org/10.1016/j.sbspro.2016.11.066>.
- [9] Gallo C. 2015. "Artificial neural network: tutorial; Encyclopedia of Information Science and Technology". In *Encyclopedia of Information Science and Technology*: DOI: 10.4018/978-1-4666-5888-2.ch626.
- [10] Golda A. and Sanocki Ł. 2020. "Wstęp do sieci neuronowych". <http://galaxy.uci.agh.edu.pl/~vlsi/Al/wstep/>. [data dostępu 02-03.2022].
- [11] Hribar R., Potocnik. P., Silc J. and Papa G. 2019. "A comparison of model for forecasting the residential natural gas demand of an urban area". *Energy* (167): 511-522. <https://doi.org/10.1016/j.energy.2018.10.175>
- [12] Jinyuan L., Nan W., Shouxi W., Xi Chi., Hanyu X. and W. Jie. 2021. "Natural gas consumption forecasting: A discussion on forecasting history and future challenges" *Journal of Natural Gas Science and Engineering*, 90. <https://doi.org/10.1016/j.jngse.2021.103930>
- [13] Kizilaslan R. and Karlik B. 2008. "Comparison neural networks models for short term forecasting of natural gas consumption in Istanbul". Ostrava: 2008. First International Conference on the Applications of Digital Information and Web Technologies (ICADIWT).
- [14] Kogut K. 2007. "Analiza możliwości modelowania sieci przesyłowej gazu ziemnego." Kraków: AGH.
- [15] Lu Azimi. and Isel.ey T. 2019. "Short-term load forecasting of urban gas using a hybrid model based on improved fruit fly optimization algorithm and support vector machine". *Energy Reports* (5): 666-677. <https://doi.org/10.1016/j.egy.2019.06.003>
- [16] Maciejasz M. 2005. "Zastosowanie sieci neuronowych do analizy pracy sieci przesyłowych". Praca Magisterka AGH. Kraków.
- [17] Mohamed Z. E. 2019. "Using the artificial neural networks for prediction and validating solar radiation" *Journal of the Egyptian Mathematical Society* (47): 1-13. DOI: 10.1186/s42787-019-0043-8
- [18] Nan W., Li Chi., Peng X., Li Z. and Fanhua. Z. 2019. "Daily natural gas consumption forecasting via the application of a novel hybrid model". *Applied Energy* (250): 358-368. <https://doi.org/10.1016/j.apenergy.2019.05.023>
- [19] Oliver R., Duffy A., Enright B. and O'Connor R. 2017. "Forecasting peak-day consumption for year-ahead management of natural gas networks". *Utilities Policy* (44): 1-11. <https://doi.org/10.1016/j.jup.2016.10.006>
- [20] Ozmen A., Yilmaz Y. and Weber G-W. 2018. "Natural gas consumption forecast with MARS and CMARS models for residential users". *Energy Economics* (70):357-381. <https://doi.org/10.1016/j.eneco.2018.01.022>
- [21] Sadeghi M., Pashaie M. and Jafarian A. 2016. "RBF Neural Networks Based on BFGS Optimization Method for Solving Integral Equations". *Advances in Applied Mathematical Biosciences* (7): 1-22.
- [22] Shaikh F. and Ji Q. 2016. "Forecasting natural gas demand in China: Logistic modelling analysis" *Electrical Power and Energy Systems* (77): 25-32. <https://doi.org/10.1016/j.ijepes.2015.11.013>
- [23] Silva N. I. 2017 "Artificial Neural Network Architectures and Training Processes". Chap. 2 in *Artificial Neural Networks*, by Silva N. I., Hermene D., Andrade F., Alves S. and Liboni Bartocci S., Szwajcaria: Springer International Publishing. DOI: 10.1007/978-3-319-43162-8_2.
- [24] Soldo B. 2012. "Forecasting natural gas consumption". *Applied Energy* (92):26-37.
- [25] Stanisław A. 2006. "Przystępny kurs statystyki z zastosowaniem Statistica PL na przykładach z medycyny". Kraków: Stasoft.
- [26] Stefanowski J. "Wykłady". 2020. <http://www.cs.put.poznan.pl/jstefanowski/PSE.html> [Data dostępu 02-07.2023].
- [27] Szoplik J. 2015. "Forecasting of natural gas consumption with artificial neural networks" *Energy* (85):208-220.
- [28] Tadeusiewicz R., Gąciarz T., Borowik B. and Leper B. 2007 „Odkrywanie własności sieci neuronowych.” Kraków: Polska Akademia Umiejętności.
- [29] Voudouris V., Matsumoto K., Sedgwick J., Rigby R., Stasinopolus D. and Jeffers M. 2014. "Exploring the production of natural gas through the lenses of the ACEGRS model". *Energy Policy* (64): 124-133.
- [30] Wang S-CH. 2003. "Interdisciplinary computing in java programming". Nowy Jork: Library of Congress Cataloging in Publication.
- [31] Wójcik M. 2005. "Model sieci gazowniczej oparty o sztuczne sieci neuronowe". Praca Magisterska. Kraków AGH.
- [32] Żero A. 2022. „Stacja regazyfikacji skroplonego gazu ziemnego LNG – obiekt automatyczny czy bezobsługowy?” *Gaz, Woda I Technika Sanitarna* (1): 11-15. Doi 10.15199/17.2022.11.2.