

Jolanta SZOPLIK

e-mail: jolanta.szoplik@zut.edu.pl

Instytut Inżynierii Chemicznej i Procesów Ochrony Środowiska, Wydział Technologii i Inżynierii Chemicznej, Zachodniopomorski Uniwersytet Technologiczny, Szczecin

Zastosowanie metody sztucznych sieci neuronowych do prognozowania obciążenia sieci rurociągów do transportu gazu ziemnego

Wstęp

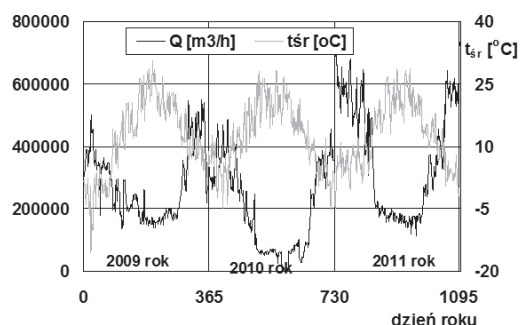
Transport gazu ziemnego od miejsca wydobycia do odbiorcy odbywa się siecią rurociągów, których podstawowe parametry techniczne określone są na podstawie prognozowanego obciążenia gazociągów, zależnego od zapotrzebowania na gaz przez odbiorców. Przygotowanie odpowiedniej prognozy zapotrzebowania na gaz jest realizowane przy uwzględnieniu różnych czynników oraz w oparciu o różne modele prognostyczne. Przegląd najczęściej stosowanych metod i narzędzi prognozowania zapotrzebowania na gaz zamieszczono w pracy [Soldo, 2012].

Przygotowanie dobrej prognozy ilości gazu, który będzie przesyłany siecią rurociągów może przyczynić się do obniżenia kosztów jego transportu. Przyjmując, że na cenę gazu składa się opłata za paliwo i opłata za transport można przypuszczać, że rozwój metod i technik wydobywania gazu ziemnego w przyszłości przyczyni się do obniżenia ceny za paliwo, natomiast opłatę za transport można obniżyć tylko wtedy, gdy zmniejszą się koszty transportu. Jedną ze składowych kosztów transportu gazu jest zamawianie u producenta (właściciela) odpowiedniej ilości paliwa gazowego, którą uzyskuje się na przykład za pomocą prognozy. Znajomość prognozy może być także wykorzystana do sterowania przepływem gazu w sieci i odpowiedniego wykorzystania pojemności magazynowej sieci gazociągów w celu wyrównywania chwilowych nierównomierności zużycia gazu przez odbiorców.

Celem niniejszej pracy jest opracowanie modelu z zastosowaniem metody sztucznych sieci neuronowych (SSN) do prognozowania obciążenia sieci rurociągów, spowodowanego pobieraniem gazu z sieci przez odbiorców komunalnych oraz drobnego przemysłu, usytuowanych w jednym z polskich miast. Model będzie uwzględniał wpływ czynników pogodowych oraz kalendarzowych na wielkość obciążenia sieci gazowej. Modelowanie będzie przeprowadzone na podstawie danych rzeczywistych, przedstawiających obciążenie sieci gazowej w przykładowym mieście w Polsce i rzeczywistych danych pogodowych. Przyjęto, że obciążenie sieci gazowej (będące zmienną wyjściową ilościową) zależy od wartości 5 zmiennych wejściowych, wśród których wydzielono 3 zmienne wejściowe ilościowe (dzień miesiąca, godzina, temperatura), oraz 2 zmienne wejściowe jakościowe (dzień tygodnia, miesiąc).

Zmienność obciążenia sieci gazowej w czasie


Przykładowy wykres zmienności w czasie obciążenia sieci gazowej, zasilającej grupę 132 tys. odbiorców jednego z polskich miast w kolejnych dniach w latach 2009 – 2011 przedstawiono na rys. 1. Dodatkowo na zamieszczono tam wyniki w postaci średniej dobowej temperatury powietrza danego dnia.



Rys. 1. Zmienność obciążenia sieci gazowej w kolejnych dniach 2009–2011 roku

Łatwo zauważyć okresową zmienność obciążenia sieci gazowej, zależną od temperatury powietrza. Wysokie temperatury powietrza w miesiącach letnich powodują, że mniejsze jest obciążenie sieci w tych miesiącach, natomiast niskie temperatury powietrza wpływają na wzrost zapotrzebowania na gaz, który na tym obszarze głównie jest stosowany do ogrzewania pomieszczeń.

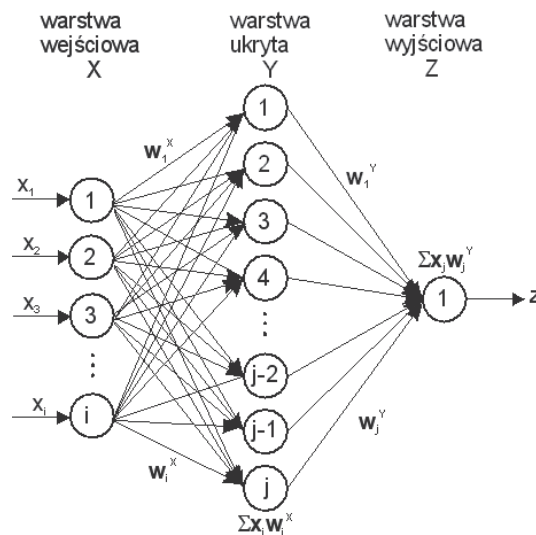
Innym czynnikiem, mającym wpływ na zmienność obciążenia sieci jest zróżnicowane zużycie gazu przez odbiorców w kolejnych godzinach doby (Rys. 2). Mniejsze zapotrzebowanie na gaz przez odbiorców jest obserwowane w godzinach nocnych niż w godzinach dziennych. Okresy zwiększonego, a następnie mniejszego obciążenia sieci, powtarzane są w kolejnych dniach oraz sezonach w kolejnych latach, dlatego też można próbować je przewidywać.



Rys. 2. Zmienność obciążenia sieci gazowej w kolejnych godzinach doby

Projektowanie i trenowanie sztucznych sieci neuronowych

Sztuczna sieć neuronowa (SSN) jest dobrym narzędziem generowania prognoz i może być cennym uzupełnieniem innych metod matematycznego modelowania procesów. Budowa neuronu i działanie sieci neuronowej oparte są na działaniu biologicznych komórek nerwowych. Perceptron wielowarstwowy MLP, przedstawiony na rys. 3, jest jednym z bardziej znanych modeli i szeroko stosowanym w praktyce [Daponte i Grimaldi, 1998].



Rys. 3. Przykładowy schemat sieci MLP z jedną warstwą ukrytą

Początkiem działania sieci neuronowej (Rys. 3) jest pojawienie się na jej wejściu sygnałów niosących zadanie do rozwiązania. Z warstwy wejściowej sygnały x_i rozsyłane są do wszystkich neuronów warstwy ukrytej Y . Każdy neuron warstwy ukrytej posiada określoną liczbę wejść, a z każdym wejściem powiązana jest waga w_i^x . Wewnątrz neuronów warstwy ukrytej, na podstawie informacji z neuronów warstwy wejściowej x_i oraz wag w_i^x , obliczana jest zagregowana wartość wejściowa, która jest sumą ważonych wejść $\sum x_i w_i^x$. Natomiast funkcje aktywacji neuronów pozwalają wyznaczyć wartości wyjściowe neuronów warstwy ukrytej y_i oraz wartości wyjściowe neuronów warstwy wyjściowej z_i .

W pracy zastosowano tangensoidalną funkcję aktywacji dla neuronów warstwy ukrytej natomiast dla neuronów warstwy wyjściowej zastosowano funkcję wykładniczą. Wielkości wag sygnałów wejściowych neuronów warstwy ukrytej w_i^x oraz sygnałów wejściowych neuronów warstwy wyjściowej w_j^y wyznaczano w procesie uczenia sieci metodą zmiennej metryki *Broydena-Fletcher-Goldfarba-Shanno* (BFGS). Proces uczenia sieci realizowano przy zastosowaniu dostępnego zbioru danych. Podczas uczenia na wejścia sieci wprowadzano, losowo wybrane, wartości ze zbioru uczącego i obserwowano wartości pojawiające się na wyjściu sieci. Jeśli wartości oszacowane przez sieć różniły się od wartości rzeczywistych zgromadzonych w zbiorze uczącym, to modyfikowano wagi w_i neuronów. Zbiór uczący, liczący 70% przypadków całego zbioru danych stosowano tylko do modyfikacji wag neuronów, natomiast do bieżącego monitorowania procesu uczenia stosowano zbiór testowy, który stanowił 20% przypadków zbioru danych. Pozostałe 10% wyników dostępnego zbioru danych to zbiór walidacyjny, zastosowany do oceny jakości sieci po zakończeniu procesu uczenia. Cały proces uczenia powtarzano do momentu uzyskania wartości wyjściowych z sieci porównywalnych z wartościami rzeczywistymi. Błąd sieci wyznaczano jako zagregowaną miarę różnic pomiędzy rzeczywistymi wartościami wyjściowymi i wartościami obliczonymi za pomocą sieci.

Z powodu braku jednoznacznej reguły, ułatwiającej dobór optymalnej liczby neuronów do ukrytej warstwy sieci MLP przy danej liczności zbioru danych wejściowych, liczba ta została w pracy dobrana eksperymentalnie. Zaprojektowano i wytrenowano 9 różnych struktur sieci MLP posiadających jedną warstwę wejściową, jedną warstwę wyjściową oraz jedną warstwę ukrytą. Liczby neuronów w warstwie wejściowej i wyjściowej były stałe i wynosiły odpowiednio 22 neurony dla warstwy wejściowej oraz 1 neuron dla warstwy wyjściowej. Natomiast liczbę neuronów warstwy ukrytej zmieniano w zakresie od 5 do 40.

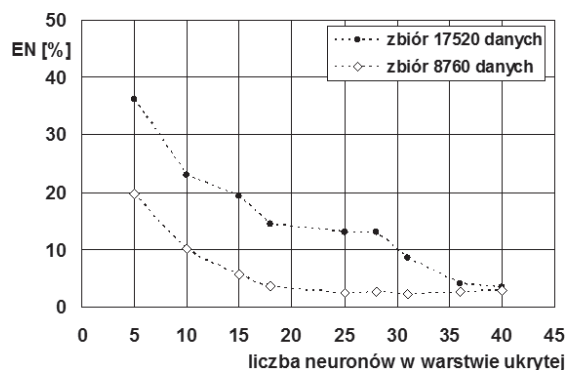
Projektowanie i trenowanie sieci neuronowych wykonano w programie *Statistica Automated Neural Network 8.0*. Łącznie zaprojektowano 9 typów sieci MLP, różniących się liczbą neuronów w warstwie ukrytej, które trenowano na dwóch zbiorach danych wejściowych o różnej liczności.

W pierwszym przypadku zaprojektowano i wytrenowano sieci, wykorzystując zbiór liczący 8760 danych, w postaci wielkości godzinowego obciążenia sieci w kolejnych godzinach w 2009 roku.

Natomiast w drugim przypadku sieci trenowano na zbiorze o liczności 17520 danych opisujących obciążenie sieci w kolejnych godzinach w latach 2009–2010. Najlepszej jakości, czyli charakteryzujące się najmniejszym błędem EN, sieci sprawdzono następnie w procesie prognozowania obciążenia sieci w zależności od temperatury powietrza oraz godziny doby w 2011 roku. Dane z 2011 roku nie były wcześniej stosowane w procesie uczenia, testowania lub walidacji sieci.

Obliczenia wykonywano indywidualnie dla każdego zbioru danych, a wyniki w postaci błędów uczenia, zostały zamieszczone na rys. 4. Wzrost liczby neuronów w warstwie ukrytej sieci MLP wpływa na zmniejszenie błędów sieci, niezależnie od liczności zbioru danych. Wyraźne są różnice pomiędzy wartościami błędów uczenia sieci o takiej samej liczbie neuronów, lecz trenowanych na zbiorach o różnej liczności (8760 lub 17520 danych).

Przyjmując taką samą liczbę neuronów, z zakresu od 5 do 30 neuronów w warstwie ukrytej, prawie dwa razy większy jest błąd uczenia sieci, gdy trenowana była na liczniejszym zbiorze danych. Dlatego też za najlepszą strukturę sieci uznano taką, dla której dalszy wzrost liczby neuronów warstwy ukrytej nie wpływa już istotnie na zmniejszenie błędów uczenia sieci. W przypadku sieci trenowanej na zbiorze 17520




Rys. 4. Zależność błędów uczenia sieci EN od liczby neuronów w warstwie ukrytej

danych przyjęto, że sieć o 36 neuronach będzie najlepsza, natomiast sieć z 25 neuronami okazała się najlepsza w przypadku trenowania jej na zbiorze o liczności 8760 danych. W obydwu przypadkach błąd sieci jest mniejszy niż $EN < 5\%$.

Wyniki

W dalszej części pracy zostaną zaprezentowane wyniki prognoz obciążenia sieci gazowej, uzyskane za pomocą sieci MLP 22-25-1 lub MLP 22-36-1, posiadających odpowiednio 25 lub 36 neuronów w warstwie ukrytej oraz 22 neurony w warstwie wejściowej i 1 neuron w warstwie wyjściowej. Sieci trenowane były na zbiorze liczącym 8760 lub 17520 danych wejściowych.

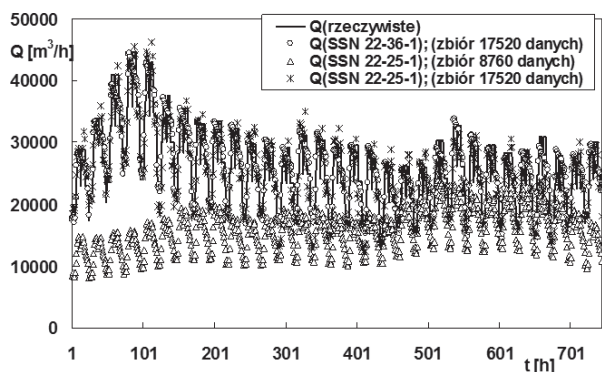
Wielkość średniego względnego błędów predykcji obciążenia sieci w kolejnych miesiącach roku 2009 pokazano na rys. 5. Porównanie wyników z wykazało, że większe wartości względnego średniego miesięcznego błędów predykcji są charakterystyczne dla sieci MLP 22-36-1 trenowanej na zbiorze 17520 danych. Ponadto, większe różnice pomiędzy wartościami obciążenia sieci, uzyskanymi za pomocą sieci oraz rzeczywistymi występują w miesiącach o wyższych temperaturach powietrza (od IV do VIII). Natomiast mniejszy średnioroczny błąd predykcji oraz mniejsze zróżnicowanie wielkości średniego miesięcznego błędów predykcji w zależności od miesiąca roku charakteryzuje sieć MLP 22-25-1. Średnioroczny względny błąd prognozy obciążenia sieci gazowej, przewidywanego przez sieć MLP 22-36-1 wynosi około 8%, natomiast dla sieci MLP 22-25-1 wynosi około 6%.



Rys. 5. Porównanie średnich względnych miesięcznych błędów predykcji obciążenia sieci gazowej przez SSN o różnej strukturze i trenowanych na zbiorach o różnej liczności


Przykład praktycznego zastosowania wytrenowanej sieci SSN do przewidywania obciążenia sieci gazowej w danym miesiącu dla warunków innych niż te, dla których trenowano sieci MLP 22-25-1 oraz MLP 22-36-1 przedstawiono na rys. 6. Wyniki zamieszczone w postaci Q (rzeczywiste) – rzeczywistego obciążenia sieci gazowej w kolejnych godzinach w miesiącu styczniu 2011 roku oraz $Q(SSN)$ – wielkości przewidywane przez sieć neuronową SSN o 25 lub 36 neuronach w warstwie ukrytej i trenowanych wcześniej na zbiorach liczących 8760 (dane z 2009 roku) lub 17520 (dane z lat 2009–2010) danych wejściowych.

Dokładne porównanie rzeczywistego obciążenia sieci gazowej w kolejnych godzinach doby oraz przewidywanego przez 3 typy sieci SSN



Rys. 6. Wyniki predykcji obciążenia sieci gazowej, uzyskane za pomocą SSN o różnej strukturze oraz trenowanych na zbiorach o różnej licznosci: MLP 22-36-1 (zbiór 17520), MLP 22-25-1 (zbiór 17520) lub MLP 22-25-1 (zbiór 8760); wyniki uzyskane dla stycznia 2011

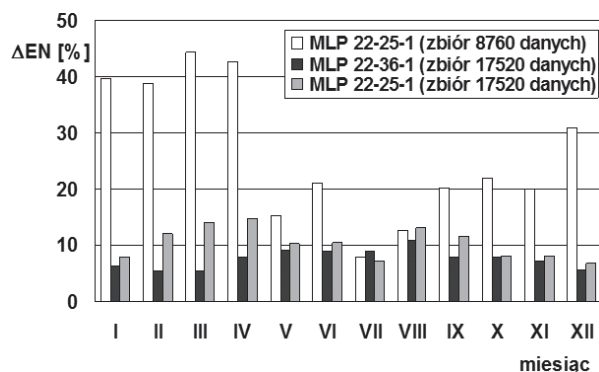
w przykładowym dniu stycznia oraz sierpnia 2011 roku przedstawiono na rys. 7. Można zauważyć, że w przypadku przygotowywania prognozy dla sezonu zimowego (Rys. 7b), gdy strumienie gazu są większe niż w okresie letnim, sieć MLP 22-25-1 trenowana na zbiorze 8760 danych, nie potrafi poprawnie przewidywać wielkości obciążenia sieci dla innych danych wejściowych niż te, które stosowano w procesie uczenia.



Rys. 7. Wyniki predykcji obciążenia sieci gazowej, uzyskane za pomocą trzech sieci SSN o różnej strukturze oraz trenowanych na różnych zbiorach: MLP 22-36-1 (17520 danych), MLP 22-25-1 (17520 danych) lub MLP 22-25-1 (8760 danych); a) wyniki dla 8.08.2011; b) wyniki dla 2.01.2011

Natomiast poprawne są prognozy uzyskiwane dla dni letnich (Rys. 7a), w których obserwuje się małe obciążenie sieci gazowej. Ponadto nie stwierdzono zależności pomiędzy jakością prognozy, a godziną doby. Sieci SSN, niezależnie od struktury oraz licznosci zbioru danych stosowanych w procesie uczenia, potrafią poprawnie odzwierciedlać dobową zmienność obciążenia sieci.

Na rys. 8 przedstawiono wielkość miesięcznego średniego względnego błędu predykcji dla trzech sieci SSN różniących się strukturą lub



Rys. 8. Porównanie średnich miesięcznych względnych błędów predykcji godzinowego obciążenia sieci gazowej uzyskanych przez 3 typy sieci MLP; dane dla 2011 roku

licznością zbioru danych stosowanych w procesie uczenia. Różnice pomiędzy wartościami średniego miesięcznego błędu predykcji w kolejnych miesiącach roku są szczególnie wyraźne w przypadku sieci MLP 22-25-1.

W miesiącach zimowych (od października do kwietnia) wielkości obciążenia sieci gazowej, prognozowane przez sieć MLP 22-25-1 są nawet dwukrotnie mniejsze od wielkości rzeczywistych. Fakt występowania tak dużych różnic pomiędzy danymi rzeczywistymi oraz uzyskanymi za pomocą sieci w miesiącach zimowych można wyjaśnić tym, że różne były średnie temperatury powietrza w okresie zimowym w 2009 oraz 2011 roku. Sieć MLP 22-25-1 trenowana była na zbiorze 8760 danych, które obejmowały dane wejściowe zarejestrowane tylko w 2009 roku. Średnia temperatura powietrza w miesiącu styczniu 2009 roku wynosiła (-5°C), natomiast średnia temperatura w analogicznym okresie 2011 roku wynosiła (+3°C).

Na podstawie danych na rys. 8 można przypuszczać, że na jakość przygotowywanej prognozy większy wpływ ma licznosc zbioru danych stosowanych w procesie uczenia sieci SSN niż jej struktura, czyli np. większa liczba neuronów w warstwie ukrytej.

Wnioski

Porównanie wyników wszystkich prognoz, uzyskanych za pomocą sieci Q(SSN) oraz rzeczywistych Q(rzeczywiste) wielkości obciążenia sieci gazowej przykładowego miasta w 2011 roku wykazało, że:

1. Sieci MLP 22-25-1 oraz MLP 22-36-1 trenowane na zbiorach o różnej licznosci różniły się błędem uczenia sieci. Największy błąd uczenia sieci (około 13%) odpowiada sieci MLP 22-25-1 trenowanej na zbiorze 17520 danych, natomiast najmniejszy błąd uczenia sieci (około 3%) charakteryzuje sieć MLP 22-25-1, trenowaną na zbiorze 8760 danych. Jeśli jednak sieci MLP zostaną zastosowane do przygotowania prognozy dla innych danych wejściowych (np. dla 2011 roku) to zaobserwowano, że sieci MLP 22-25-1 lub MLP 22-36-1 trenowane na zbiorze 17520 danych mają większą zdolność przewidywania poprawnych wielkości (najmniejszy błąd predykcji) niż sieć MLP 22-25-1 trenowana na zbiorze o licznosci 8760 danych.
2. Najmniejszy błąd prognozy obciążenia sieci rurociągów gazowych, uzyskano dla sieci neuronowej zawierającej 36 neuronów w warstwie ukrytej i trenowanej na zbiorze 17520 danych. Średni błąd predykcji sieci MLP 22-36-1 dla nowego zbioru danych wejściowych (dane z 2011 roku) wynosi około 8%. Sieć ta może być z powodzeniem stosowana w dalszych badaniach.

LITERATURA

- Daponte P., Grimaldi D., 1998. Artificial neural network in measurements. *Measurements*, **23**, 93-115. DOI: 10.1016/S0263-2241(98)00013-X
- Soldo B., 2012. Forecasting natural gas consumption. *Appl. Energy*, **92**, 26-37. DOI: 10.1016/j.apenergy.2011.11.003