

Piotr Łętkowski, Adam Pańko, Andrzej Gołąbek
Instytut Nafty i Gazu, Oddział Krosno

Prognozowanie ciśnień dennych podziemnego magazynu gazu przy wykorzystaniu sztucznych sieci neuronowych

Wstęp

Obecnie obowiązujące standardy zarządzania i sterowania pracą podziemnych magazynów gazu (PMG) obejmują wykorzystanie zestawu najnowszych narzędzi i metod do ciągłej analizy i prognozowania pracy PMG. Jednym z tych narzędzi są sieci neuronowe, dotychczas w Polsce nie wykorzystywane w procesie prognozowania pracy PMG.

W niniejszym artykule opisano próbę wykorzystania możliwości sztucznych sieci neuronowych (SSN) do prognozowania ciśnień dennych; zarówno dla całego

magazynu (średnie ciśnienie), jak i dla poszczególnych odwiertów. W tym celu przygotowano trzy zbiory danych wejściowych: zbiór uczący, walidacyjny i testowy oraz zbudowano kilkanaście modeli sieci neuronowych. Następnie, w oparciu o przygotowane dane przeprowadzono proces „uczenia”. W efekcie wybrano optymalne architektury sieci, które wykorzystano w procesie prognozowania; zarówno średniego ciśnienia PMG, jak również ciśnień dennych w poszczególnych odwiertach.

Wybór danych wejściowych

Jako parametry wejściowe wykorzystano dane pochodzące z jednego z krajowych, podziemnych magazynów gazu. Przeprowadzona analiza obejmowała dopasowanie ciśnień dennych w okresie historycznym oraz prognozę ciśnienia średniego dla jednego cyklu pracy magazynu, a także ciśnień dennych dla sześciu reprezentatywnych odwiertów.

Jako zmienne wejścia/wyjścia wybrano następujące parametry pracy magazynu:

- **zmienne wejściowe** – czas, ilość gazu zatłoczonego/odebranego w poszczególnych cyklach, stan magazynu,

- **zmienne wyjściowe** – średnie ciśnienie w magazynie, ciśnienie denne w odwiercie.

Jako dane historyczne w procesie uczenia sieci wykorzystano wyniki symulacji złożowych. Krok czasowy symulacji złożowych nie przekracza zwykle 10 dni, co pozwoliło na wykorzystanie zbiorów danych zawierających około 2000 pomiarów. Dla porównania, pomiary ciśnienia dennego w odwiertach są zazwyczaj wykonywane raz na cykl pracy magazynu, co daje zbiór danych pomiarowych zdecydowanie niewystarczający dla uzyskania akceptowalnej zbieżności procesu „uczenia” sieci.

Prognozowanie średniego ciśnienia w magazynie

W procesie konstruowania i „uczenia” sieci wykorzystano projektanta sieci neuronowych – programu ST Neural Network (pakiet Statistica), po uprzednim unormowaniu danych wejściowych i wyjściowych. Testowano pięć typów

sieci, o zróżnicowanej architekturze tzn. różnej liczbie warstw ukrytych, różnej liczbie neuronów w warstwie:

- perceptron wielowarstwowy (MLP) – dwie architektury sieci,

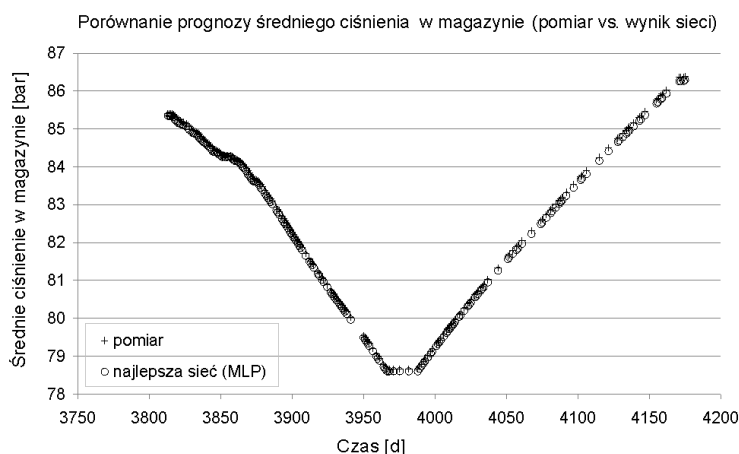
- sieć o radialnych funkcjach bazowych (RBF),
- sieć realizującą uogólnioną regresję (GRNN),
- sieć liniową.

Wykorzystując przygotowane wcześniej dane wejściowe i wyjściowe przeprowadzono proces „uczenia”, przy czym każdy rodzaj sieci był „uczony” przy wykorzystaniu odpowiednich dla niego algorytmów uczenia. Przykładowo, dla perceptronu wielowarstwowego (MLP) proces ten przebiegał dwuetapowo. W pierwszym etapie zastosowano algorytm wstecznej propagacji błędów, natomiast w drugim wykorzystano algorytm gradientów sprzężonych.

Do końcowej oceny efektywności „uczenia” sieci neuronowej wykorzystywano dwa parametry: jakość „uczenia” oraz błąd dla podzbioru walidacyjnego. Dla zmierzających ciągłych jakość „uczenia” jest zdefiniowana jako iloraz odchyłeń standardowych, natomiast błąd dla podzbioru walidacyjnego rozumiany jest jako znormalizowany średni błąd kwadratowy. W oparciu o wartości tych parametrów wybrano najlepszą sieć. W tabelicy 1 przedstawiono raport podsumowujący, zawierający między innymi jakość „uczenia” i błąd dla podzbioru walidacyjnego dla testowanych sieci neuronowych. Najlepsze wyniki uzyskano dla sieci MLP 4:4-4-1:1 (oznaczenia kolejno: MLP – rodzaj sieci neuronowej, 4 – ilość zmiennych wejściowych, 4 – ilość neuronów w warstwie wejściowej, 4 – ilość neuronów w warstwie ukrytej, 1 – ilość neuronów w warstwie wyjściowej, 1 – ilość zmiennych wyj-

ściowych), dla której aż około 900 przypadków pokrywa się z wynikami pomiarów. Dla sieci tej uzyskano współczynnik korelacji pomiędzy danymi pomiarowymi, a wynikami „uczenia” sieci, na poziomie 0,99 – co świadczy o niemal idealnej zgodności porównywanych serii danych.

Prognoza średniego ciśnienia w magazynie została wykonana przy wykorzystaniu najlepiej „nauczonej” sieci, czyli MLP 4:4-4-1:1. Do wykonania prognozy posłużono się danymi pochodzącymi z symulatora złożowego, z ostatniego zrealizowanego cyklu pracy magazynu (faza zatłaczania i odbioru gazu). Na rysunku 1 zaprezentowano porównanie prognoz ciśnienia (wyniki sieci neuronowej) w magazynie, z wynikami otrzymanymi z symulatora złożowego.



Rys. 1. Porównanie średniego ciśnienia w magazynie z prognozami sieci neuronowej

Tabela 1. Raport podsumowujący proces uczenia sieci

Typ sieci	Jakość uczenia	Jakość walidacji	Jakość – test	Błąd uczenia	Błąd walidacji	Błąd testu	Uczenie	Wejść
RBF 4:4-1-1:1	0,996423	1,001303	1,005816	0,157854	0,15054	0,156771	KM, KN, PI	4
GRNN 4:4-1212-2-1:1	0,015127	0,048269	0,045668	0,002397	0,007208	0,007083	SS	4
Liniowa 4:4-1:1	0,013427	0,013429	0,012945	0,0034	0,003206	0,003209	PI	4
MLP 4:4-3-1:1	0,006918	0,007132	0,006808	0,001752	0,001702	0,001688	BP100, CG69b	4
MLP 4:4-4-1:1	0,004516	0,004845	0,004495	0,001146	0,00116	0,001115	BP100, CG52b	4

Prognozowanie ciśnienia dennego w odwiercie

Dla prognoz ciśnienia dennego w odwiertach wykorzystano analogiczny, jak dla średniego ciśnienia, zbiór zmiennych wejściowych. Jako zmienne wyjściowe posłużyły ciśnienia denne w każdym z sześciu wybranych odwiertów (sześć zmiennych wyjściowych). Testowano kilkanaście sieci, o różnych architekturach. Wyniki dla ostatecznie wytypowanych i poddanych powtórnemu „uczeniu” sieci przedstawiono w tabelicy 2.

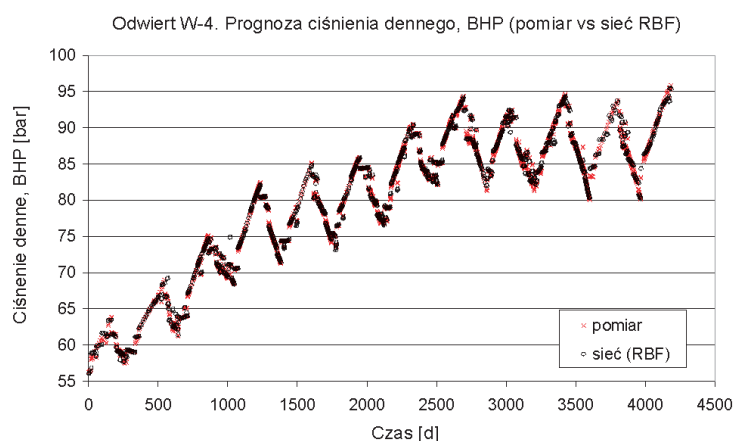
Najlepsze wyniki uzyskano dla ostatniej z wytypowanych sieci (RBF 20:20-214-6:6), dla której otrzymano współczynnik korelacji na poziomie 0,998 – co podobnie jak w przypadku średnich ciśnień pozwala twierdzić o idealnej zgodności porównywanych serii danych.

Do wykonania prognoz i wyciągnięcia wniosków co do zdolności generalizujących posłużyły dane z ostatniego zrealizowanego cyklu pracy magazynu oraz sieć, dla której

Tablica 2. Raport podsumowujący wyniki uczenia sieci.

Typ sieci	Jakość uczenia	Jakość walidacji	Jakość – test	Błąd uczenia	Błąd walidacji	Błąd testu	Uczenie	Wejść
RBF 20:20–209–6:6	0,013557	0,017511	0,021981	0,002463	0,003749	0,003619	SS, KN, PI	20
RBF 20:20–218–6:6	0,013006	0,023791	0,023244	0,00239	0,003726	0,00372	SS, KN, PI	20
RBF 20:20–214–6:6	0,013949	0,018716	0,020895	0,002458	0,003675	0,00377	SS, KN, PI	20

uzyskano najlepszą zgodność z danymi historycznymi. Otrzymano dobrą zgodność prognoz z rzeczywistymi wynikami. Przykładowe porównanie wyników otrzymanych przy użyciu sieci neuronowej z danymi pomiarowymi zaprezentowano na rysunku 2. Podobnie jak w przypadku średniego ciśnienia w magazynie, można mówić o dobrych zdolnościach generalizujących sieci i możliwości ich zastosowania do prognozowania ciśnienia dennego w poszczególnych odwiertach, dla kolejnych cykli pracy magazynu.



Rys. 2. Przykładowe porównanie zmierzonych ciśnień dennych, z prognozami sieci neuronowej

Podsumowanie i wnioski

W niniejszym artykule zaprezentowano możliwości wykorzystania sieci neuronowych do prognozowania średniego ciśnienia w magazynie oraz ciśnienia dennego w odwiertach.

Zaprezentowano niezbędny zestaw danych wejściowych dla sieci neuronowych, wykorzystywany w procesie uczenia i późniejszego prognozowania ciśnień w całym magazynie i w poszczególnych odwiertach, w kolejnych cyklach pracy magazynu.

Otrzymane wyniki pozwalają na wyciągnięcie następujących wniosków:

1. Wytypowane sieci neuronowe (zarówno dla całego magazynu, jak i dla poszczególnych odwiertów) mają bardzo dobre zdolności generalizujące i mogą być z powodzeniem wykorzystane w procesie prognozowania ciśnień dennych w kolejnych cyklach pracy podziemnego magazynu gazu. Należy jednak zwrócić uwagę na fakt, że możliwości uczenia się sieci neuronowej zależą w dużym stopniu od wielkości uczącego zbioru danych. Uzyskane wyniki wskazują na bardzo duże możliwości

generalizowania wskazanych typów sztucznych sieci neuronowych, o ile dysponujemy dostatecznie dużym zbiorem danych uczących. Ze względu na częstotliwość wykonywania pomiarów ciśnień w magazynie, warunek ten może być trudny do spełnienia – o ile nie wykorzystamy symulacji złożowych.

2. Konstruowanie, proces uczenia i prognozowania jest znacznie szybszy i mniej kosztowny, w porównaniu z wykonaniem symulacji złożowych przy wykorzystaniu symulatorów komercyjnych.
3. Wadą sieci neuronowych mogą być stosunkowo słabe własności ekstrapolacyjne, tzn. że jeżeli w prognozach pojawią się dane wejściowe z poza zakresu danych, na których dana sieć była „uczona”, to z dużym prawdopodobieństwem można stwierdzić, że otrzymane prognozy będą mało wiarygodne.
4. Pomimo powyższej wady oraz zastrzeżenia poczynionego w punkcie 1, sztuczne sieci neuronowe wydają się być obiecującym narzędziem wspomagającym proces zarządzania i sterowania podziemnym magazynem gazu.

Literatura

- [1] Hertz J., Krough A., Palmer R.G.: *Wstęp do teorii obliczeń neuronowych*. Wydawnictwo Naukowo-Techniczne, Warszawa 1993.
- [2] Korbisz J., Obuchowicz A., Uciński D.: *Sztuczne sieci neuronowe podstawy i zastosowania*. Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.
- [3] Masters T.: *Sieci neuronowe w praktyce*. Wydawnictwo Naukowo-Techniczne, Warszawa 1993.
- [4] *Statistica Neural Network PL*. StatSoft Polska, Kraków 2001.
- [5] Tadeusiewicz R.: *Sieci neuronowe*. Akademicka Oficyna Wydawnicza, Warszawa 1993.
- [6] Żurada J., Barski M., Jędruch W.: *Sztuczne sieci neuronowe*. Wydawnictwo Naukowe PWN, Warszawa 1996.



Mgr inż. Adam PAŃKO – asystent w Zakładzie Symulacji Złóż Węglowodorów i Podziemnych Magazynów Gazu INiG. Absolwent AGH Kraków. Zajmuje się głównie tematyką związaną z numerycznym modelowaniem złóż węglowodorów i podziemnych magazynów gazu. Autor wielu prac naukowych i licznych opracowań głównie – z zakresu symulacji złożowych.



Dr inż. Piotr ŁĘTKOWSKI – absolwent Wydziału Mechanicznego Politechniki Krakowskiej; adiunkt w Zakładzie Symulacji Złóż Węglowodorów i Podziemnych Magazynów Gazu INiG Oddział Krosno. Zajmuje się między innymi problemami modelowania i symulacji złóż oraz projektowaniem systemów baz danych dla potrzeb górnictwa naftowego.



Mgr inż. Andrzej GOŁĄBEK – absolwent Wydziału Elektrotechniki i Informatyki Politechniki Rzeszowskiej. Od 2008 r. pracownik Zakładu Symulacji Złóż Węglowodorów i PMG Instytutu Nafty i Gazu. Zajmuje się różnorodnymi zagadnieniami z zakresu symulacji złóż i informatyki.

ZAKŁAD SYMULACJI ZŁÓŻ WĘGLOWODORÓW I PMG

Zakres działania:

- sporządzanie ilościowych charakterystyk złóż naftowych (konstruowanie map cyfrowych dla podstawowych wielkości złożowych);
- analizy geostatystyczne dla potrzeb projektowania modeli złóż naftowych, w tym PMG i obliczeń wolumetrycznych wielowymiarowych i wielofazowych;
- konstruowanie kompletnych symulacyjnych modeli złóż;
- wszechstronne badania symulacyjne dla potrzeb:
 - weryfikacji zasobów płynów złożowych,
 - wtórnych metod zwiększania wydobycia (zatłaczanie gazu lub wody; procesy WAG, procesy wypierania mieszającego; oddziaływanie chemiczne),
 - optymalizacji rozwiercania i udostępniania złóż,
 - prognozowania złożowych i hydraulicznych (w tym termalnych) charakterystyk odwiertów (w szczególności poziomych), dla celów optymalnego ich projektowania,
 - sekwestracji CO₂.
- projektowanie, realizacja i wdrażanie systemów baz danych dla potrzeb górnictwa naftowego.

Kierownik: dr Wiesław Szott

Adres: ul. Armii Krajowej 3, 38-400 Krosno

Telefon: 13 436-89-41 wew. 104

Faks: 13 436-79-71

E-mail: wieslaw.szott@inig.pl

