

Kamil KASPRZYK
Marani Sp. z o.o.

PREDYKCJA ZAPOTRZEBOWANIA NA SPRĘŻONE POWIETRZE W ZALEŻNOŚCI OD TYPU PROWADZONEJ PRODUKCJI PRZY WYKORZYSTANIU SIECI NEURONOWYCH

Streszczenie. Publikacja dokonuje analizy zapotrzebowania na sprężone powietrze w zakładach produkcyjnych o różnej charakterystyce pracy a następnie sprawdza jak dobrana dla danego zakładu rekurencyjna sieć neuronowa sprawdziłaby się w przypadku innego zakładu o innej charakterystyce przy przewidywaniu zapotrzebowania na sprężone powietrze.

PREDICTION OF COMPRESSED AIR DEMAND DEPENDING ON THE TYPE OF PRODUCTION WITH THE USE OF NEURAL NETWORKS

Summary. The publication analyzes the demand for compressed air in production plants with different operating characteristics, and then checks how the neural network identified for a given plant would work in the case of another plant with a different needs while predicting compressed air demand.

1. Wprowadzenie

Systemy sprężonego powietrza są szeroko stosowane w zakładach przemysłowych do wytwarzania sprężonego powietrza niezbędnego do codziennej pracy obiektu. Ponieważ sprężarki powietrza zużywają większą ilość energii elektrycznej niż jakikolwiek inny typ wyposażenia obiektu (np. [1]), zoptymalizowany i efektywnie działający system sprężonego powietrza jest niezbędny dla uzyskania oszczędności energii. Zwykle można zastosować wiele podejść do poprawy wydajności systemu sprężonego powietrza. W [2] podsumowano te podejścia, są to: zminimalizuj straty energii podczas dystrybucji, zmniejszenie strat powietrza w systemie (takich jak przecieki powietrza i nadciśnienie), zoptymalizuj stronę popytową, minimalizując wymagany optymalny przepływ i ciśnienie oraz wybierz najlepszą energooszczędną sprężarkę. W pracach np. [3] zaproponowano nowe podejście do oceny wydajności energetycznej systemów sprężonego powietrza w oparciu o sześciostopniową lokalną metodologię analizy porównawczej energii. Z kolei w [4] zaproponowano nowy model symulacyjno-optymalizacyjny w celu zwiększenia efektywności energetycznej w obiekcie poprzez określenie optymalnej lokalizacji sprężarki powietrza.

W artykule zaprezentowano zastosowanie metod głębokiego uczenia oraz uczenia maszynowego umożliwiającego predykcję zapotrzebowania na sprężone powietrze

w zależności od typu prowadzonej produkcji, wykorzystując rzeczywiste dane zebrane w firmie Marani sp. z o.o.

1.1. Klasyfikacja danych pomiarowych

Do badania wybrano dane zebrane w jednakowych odstępach czasowych z 3 zakładów produkcyjnych prowadzących 3 typy działalności o różnej charakterystyce pracy w okresie 48 godzin od rozpoczęcia produkcji w danym tygodniu. Próbkę zebrano zostały w odstępach 20 sekundowych. Zakłady oznaczmy jako:

- A – zakład dysponujący 11. sprężarkami śrubowymi o łącznej mocy ok 2.6 MW,
- B – zakład dysponujący 7 sprężarkami śrubowymi o łącznej mocy 1.8 MW,
- C – zakład dysponujący 3 sprężarkami śrubowymi o łącznej mocy 0.23 MW.


Każdy zakład wyposażony jest w sterownik nadrzędny realizujący kaskadową regulację. Zadaniem każdego ze sterowników jest dobieranie odpowiedniej liczby maszyn w zależności od przekroczenia dolnej lub górnej granicy ciśnienia roboczego tak aby ciśnienie utrzymywało się w zakresie żądanego zakresu. Nie mamy informacji zwrotnej o liczbie pracujących w danym momencie urządzeń pneumatycznych podłączonych do sieci, w związku z czym sterowniki podejmują decyzje na bazie pomiaru ciśnienia w instalacji w punkcie, który odzwierciedla rzeczywiste zapotrzebowanie.

Tabela 1

Granice decyzyjne ciśnienia roboczego sterowników nadrzędnych

Lp.	Obiekt	Dolna granica ciśnienia roboczego [bar]	Górna granica ciśnienia roboczego [bar]	Rozpiętość [bar]
1	A	6.35	6.75	0.40
2	B	5.05	5.35	0.30
3	C	6.40	6.80	0.40


Każdy z zakładów również cechuje inne zapotrzebowanie na sprężone powietrze. Na rysunku 1 przedstawiony został przebieg ciśnienia w rozpatrywanym okresie, którego 90% będzie bazą dla uczenia sieci neuronowych.



Rys. 1. Charakterystyka ciśnienia obiektów, kolejno od góry A, B, C [źródło własne]

1.2. Specyfika pracy obiektów

Zakłady A oraz C charakteryzuje duża zmienność widoczna przez częste przekraczanie granic dolnego i górnego ciśnienia roboczego, kiedy sterowniki nadrzędne muszą podejmować decyzję o tłoczeniu lub zaprzestaniu dostarczania sprężonego powietrza. W zakładach tych znajduje się co najmniej jedna maszyna z przetwornicą częstotliwości, której zadaniem jest ograniczenie wahań ciśnienia oraz minimalizacja liczby pracujących maszyn. Na rysunku 2 przedstawiono godzinę pracy obiektu B. Zielony kolor oznacza, że maszyna pracowała. Żółty kolor oznacza pracę na biegu jałowym podczas którego maszyna pozostawała w gotowości na sprężanie.



Rys. 2. Przykładowa regulacja godzinowa dla obiektu B [źródło własne]

1.3. Dobór sieci neuronowej

Obserwując przebieg ciśnienia możemy zauważyć, że na wartość ciśnienia w danej chwili czasu będzie miała wpływ próbka poprzednia jak również przebieg dotychczasowej charakterystyki. Zdecydowano się na wykorzystanie sieci bazującej na komórkach długiej pamięci krótkotrwałej LSTM [5]. Sieci te używane są z powodzeniem w wielu obszarach uczenia głębokiego m.in. do identyfikacji obrazów oraz rozpoznawania mowy. Do analizy przyjęto uczenie na zbiorze 90% zebranych danych dla danego obiektu a następnie wykonano predykcję na ostatnich 10%, co odpowiada horyzontowi ok. 5 godzin. Do wytrenowania sieci użyto algorytmu optymalizacji stochastycznej ADAM i uczenie wykonywano przez okres 250 epok.

Wyniki będziemy rozpatrywać w dwóch przypadkach:


- I. – gdy jako dane wejściowe rekurencyjnej sieci neuronowej będziemy używać kolejnych próbek z predykcji i wykorzystywać je do przewidywania przyszłości w horyzoncie czasowym zbioru testowego,
- II. – gdy jako dane wejściowe rekurencyjnej sieci neuronowej użyjemy rzeczywistych próbek (taka sytuacja odpowiadałaby rzeczywistemu zastosowaniu sieci neuronowej w przemyśle).

Za punkt odniesienia, w przypadku wszystkich badań, przyjmujemy pierwiastek błędu średniokwadratowego, który obliczony został dla sieci neuronowej dla danego obiektu. Zwrócimy również uwagę na inne cechy w bazie zebranych próbek, które mogły wpływać na wynik oraz przedstawimy ciekawsze przypadki z rozpatrzonych.

2. Predykcja zapotrzebowania

2.1. Obiekt A

Obiekt A jest jedynym obiektem, który w zbiorze danych testowych był dwukrotnie zatrzymany co powinno przełożyć się na reakcję sieci. Zbiór danych testowych, którego dotyczyła predykcja był w momencie badania zatrzymany.



Rys. 3. Predykcja typu I dla obiektu A [źródło własne]

Na rysunku 3 możemy zaobserwować, że sieć neuronowa przewiduje wystąpienie podciśnienia w układzie, ale moglibyśmy to rozpatrywać jako sytuację w której z pewnością maszyny nie będą pracować. Sieci neuronowe nauczone na pracującym układzie mają zrozumiałą trudność z przewidzeniem zatrzymania, które w ich wypadku nie występuje.


Tabela 2

RMSE Sieci neuronowych różnych typów obiektów dla obiektu A


Lp.	Sieć neuronowa	Predykcja typu I RMSE	Predykcja typu II RMSE
1	A	1.4081	0.071762
2	B	7.5381	0.10211
3	C	4.6636	4.7826

2.2. Obiekt B

Na rysunku 4 przedstawiono przewidywaną charakterystykę dla obiektu B. Mamy tutaj do czynienia z sytuacją, gdy ciśnienie przez większość czasu utrzymuje się poniżej zadanej dolnej granicy ciśnienia a jego zmiany spowodowane są przez drobne zmiany w zapotrzebowaniu. W przeciwieństwie do innych obiektów nie dochodzi do przekroczenia górnej granicy ciśnienia a zatem nie pojawia się charakterystyczna „piła” poboru ciśnienia.



Rys. 4. Predykcja typu I dla obiektu B [źródło własne]



Rys. 5. Predykcja typu II dla obiektu B [źródło własne]


Tabela 3

RMSE Sieci neuronowych różnych typów obiektów dla obiektu B


Lp.	Sieć neuronowa	Predykcja typu I RMSE	Predykcja typu II RMSE
1	A	0.12919	0.066176
2	B	0.08242	0.005581
3	C	0.27448	0.175130

2.3. Obiekt C

Obiekt C charakteryzuje duża zmienność ciśnienia. W tym przypadku pojawiają się dość duże odchyłki natomiast np. w przypadku predykcji typu I możemy stwierdzić, że przewidywane ciśnienie będzie utrzymywać się w zadanych granicach, jednak obarczone będzie dość dużym błędem. W przypadku predykcji typu II uzyskamy znaczną poprawę, jednak duża zmienność dalej będzie powodowała pewną nieprzewidywalność przebiegu.



Rys. 6. Predykcja typu I dla obiektu C [źródło własne]



Rys. 7. Predykcja typu II dla obiektu C [źródło własne]

Tabela 4

RMSE Sieci neuronowych różnych typów obiektów dla obiektu C

Lp.	Sieć neuronowa	Predykcja typu I RMSE	Predykcja typu II RMSE
1	A	0.17323	0.167870
2	B	0.23768	0.144180
3	C	0.15152	0.050472

3. Podsumowanie

Sieć LSTM dobrze sprawdziła się przy identyfikacji rozpatrywanych charakterystyk ciśnienia, umożliwiając modelowanie długofalowe oferując przy tym niewielki błąd. Jeżeli odchyłka przewidywanego ciśnienia nie przekraczała 0.15 bar podejmowana decyzja wpłynęłaby korzystnie na efektywność energetyczną układu umożliwiając ograniczenie liczby pracujących maszyn. Predykcję wystarczyłoby rozpatrywać w zakresie np. 10 minutowym aktualizując próbki danych wejściowych.

W przypadku predykcji długofalowej typu I okazuje się, że możemy otrzymać akceptowalne wyniki z niewielkimi odchyłkami, w przypadku każdej z nauczonych sieci neuronowych poza przypadkiem zatrzymania układu.

Dla predykcji typu II, gdy na bieżąco aktualizowaliśmy dane pomiarowe najlepiej sprawdzały się w większości przypadków sieci zdefiniowane dla danego obiektu.

W rozpatrywanych przykładach zawsze najlepsze wyniki oferowała dedykowana sieć.

Podsumowując, użycie rekurencyjnej sieci LSTM wraz z aktualizacją sieci w oparciu o bieżące dane pomiarowe dałoby wystarczający margines błędu zapewniający wsparcie sterowników nadrzędnych w zakresie podejmowania decyzji odnośnie sterowania maszyn pomiędzy granicami ciśnienia roboczego. Kolejnym krokiem analizy powinno być sprawdzenie działania sieci na rzeczywistych obiektach.

LITERATURA

1. Bei Zhang, Mingsheng Liu, Yunhua Li, Lixia Wu: Optimization of an Industrial Air Compressor System, October 2013, Energy Engineering: Journal of the Association of Energy Engineers 110(6), p. 52-64.
2. A Dharma, N Budiarsa, N Watiniasih and N G Antara: No Cost – Low Cost Compressed Air System Optimization in Industry, J. Phys.: Conf. Ser., 2018.
3. Juan Jose Cabello Eras, Alexis Sagastume, Vladimir Sousa Santos, Mario Cabello Ulloa: Energy management of compressed air systems. Assessing the production and use of compressed air in industry, September 2020, Energy 213:118662.
4. Joel Zahlan, Shihab S. Asfour: A multi-objective approach for determining optimal air compressor location in a manufacturing facility, April 2015, Journal of Manufacturing Systems 35, p. 176-190.
5. Sebastian Raschka, Vahid Mirjalili: Python Machine learning i deep learning Biblioteki scikit-learn i TensorFlow 2. Wydanie III, Tłumaczenie: Krzysztof Sawka, 2021 by Helion SA, str. 533-576.