

Kamil KASPRZYK^{1,2}, Adam GAŁUSZKA², Łukasz ANTCZAK¹

¹Marani Sp. z o.o.

²Politechnika Śląska

REDUKCJA ZUŻYCIA ENERGII ELEKTRYCZNEJ W PRZEMYSŁOWYCH UKŁADACH SPRĘŻONEGO POWIETRZA Z WYKORZYSTANIEM UCZENIA GŁĘBOKIEGO — DOŚWIADCZENIA Z WDROŻEŃ

Streszczenie. W publikacji przedstawiono metodologię predykcji stanów obciążenia sprężarek śrubowych bez przetwornic częstotliwości z wykorzystaniem dwukierunkowych rekurencyjnych sieci BiLSTM oraz autorskiej funkcji straty uwzględniającej zarówno przebieg trendu ciśnienia, jak i stanów binarnych sprężarek. Zaproponowano metryki oceny oparte na zdarzeniach tranzycji odciążenia, umożliwiające ocenę adekwatności wsparcia lokalnych sterowników nadrzędnych sprężarkowni. Wprowadzono również metryki umożliwiające ocenę ryzyka zachwiania dostaw sprężonego powietrza. Metodologię zweryfikowano na rzeczywistym obiekcie przemysłowym, uzyskując redukcję czasu biegu jałowego z ok. 30% do średniego czasu poniżej 12%, co przy przyjętych założeniach modelowych odpowiada oszczędności około 5298 kWh w analizowanym 3-miesięcznym okresie. Zaproponowana metodologia wywodzi się z wdrożeń przeprowadzonych w firmie Marani Sp. z o.o.

ELECTRICAL ENERGY CONSUMPTION REDUCTION IN INDUSTRIAL COMPRESSED AIR SYSTEMS USING DEEP LEARNING — LESSONS FROM DEPLOYMENTS

Summary. This paper presents a methodology for predicting load states of fixed-speed screw compressors using Bidirectional Recurrent Neural Networks (BiLSTM) and a custom loss function incorporating both pressure trend and binary compressor states. Evaluation metrics based on unload transition events are proposed, enabling assessment of the adequacy of support provided to local supervisory controllers of compressor stations. Additional metrics are introduced to assess the risk of compressed air supply disruption. The methodology was validated on a real industrial installation, achieving a reduction of idle running time from approximately 30% to an average below 12%, which under the adopted model assumptions corresponds to savings of approximately 5298 kWh over the analysed 3-month period. The proposed methodology originates from deployments carried out at Marani Sp. z o.o.

1. Wstęp

Sprężone powietrze jest jednym z czterech fundamentalnych mediów energetycznych w przemyśle, obok energii elektrycznej, wody oraz gazu ziemnego [18]. Całkowita energia elektryczna zużywana w przemyśle w Unii Europejskiej w 2023 roku stanowiła 24,6% całkowitego zużycia energii elektrycznej [1], z czego na sprężone powietrze szacuje się, że przypadało ok 10%.

Dyrektywa Parlamentu Europejskiego i Rady (UE) 2023/1791 [6] określa cele m.in. w zakresie efektywności energetycznej, wymagając od państw członkowskich zmniejszenia zużycia energii do roku 2030 o co najmniej 11,7% w porównaniu z prognozą z 2020 roku. Wytyczne dotyczące efektywnego zarządzania energią można spotkać w normie ISO 50001 [5] dotyczącej systemów zarządzania energią, a aby mieć odpowiednie narzędzia do oceny efektywności energetycznej pojawiają się opcjonalne normy ISO 50002 [3] oraz EN 16247-1 [4] definiujące metodologiczne postępowanie dla audytów energetycznych. Sektor małych i średnich przedsiębiorstw jest zachęcany do poddawania się audytom energetycznym [7], które pozwolą na określenie obszarów, które wymagają poprawy efektywności energetycznej. Norma ISO 11011:2013 [2] definiuje wymagania dla systemów sprężonego powietrza, podając również zalecenia dla budowania nadrzędnych systemów sterowania, które są niezbędne dla efektywnego zarządzania sprężonym powietrzem.

Wraz z rozwojem sztucznej inteligencji i uczenia maszynowego zagadnienie predykcji zużycia energii elektrycznej staje się coraz bardziej popularne, jednak w tym wypadku, najlepiej sprawdzają się narzędzia bazujące na licznikach energii elektrycznej [9] lub licznikach zużycia sprężonego powietrza [8] starając się znaleźć powtarzalność wzorca w ramach cyklu pracy całego układu sprężonego powietrza. Rozpatrywane publikacje bazują głównie na analizie statystycznej historycznych wzorców zużycia [9], nie wspierając bezpośrednio decyzji operacyjnych podejmowanych w czasie rzeczywistym. W przypadku błędnej decyzji operacyjnej np. wyłączenia istotnej sprężarki, może dojść do poważnych strat czy nawet zatrzymania produkcji. Utrzymywanie sprężarki na biegu jałowym, które jest w tym momencie najbezpieczniejszym rozwiązaniem, również może prowadzić do strat energetycznych. Zdecydowanie widoczna jest potrzeba wdrożenia systemów predykcyjnych, które będą wybiegać poza klasyczne rozwiązania oferując przewidywanie stanu sprężarek w określonym horyzoncie czasowym, minimalizując ryzyko błędnych decyzji systemu sterowania nadrzędnego.

Układ sprężonego powietrza różni się w zależności od rozpatrywanego obiektu i ma różny charakter w związku z czym doświadczenia zdobyte w przypadku jednego układu nie zawsze będą się przenosić do innych [12] (choć podstawowa zasada działania układu pozostaje wspólna), w niniejszej publikacji przedstawiono wybrane doświadczenia związane z wdrożeniem systemu predykcyjnego dla rzeczywistego obiektu przemysłowego, oceniając stosowalność metody w praktyce. Aspekty wykorzystania sieci neuronowych w tym przypadku są bardzo szerokie oraz będą rozwijane w kolejnych latach wraz z rozwojem sztucznej inteligencji, jednak niniejsza publikacja przedstawia fragment metodologii oraz badań, jakie zostały przeprowadzone oraz wdrożone na rzeczywistych obiektach przemysłowych u klientów firmy Marani Sp. z o.o.

2. Obszar optymalizacji

Przytoczone wcześniej normy ISO 50001 [5], ISO 50002 [3] oraz EN 16247-1 [4] zalecają wprowadzenie systemu monitoringu oraz archiwizacji danych z zakresu energii elektrycznej (liczniki) oraz produkowanych mediów (licznik wyprodukowanego sprężonego powietrza), co pozwala na precyzyjne określenie kosztów związanych z produkcją sprężonego powietrza, jak i innych istotnych parametrów produkcyjnych gdzie energia elektryczna jest dużym kosztem. W praktyce przemysłowej często dane zużycia dostępne są tylko od strony klienckiej, a dla nadrzędnego systemu sterowania sprężarkownią pozostają niezidentyfikowane. Niektórzy producenci sterowników nadrzędnych sprężarkowni wprowadzają własne liczniki energii elektrycznej i sprężonego powietrza, jednak licznik taki pozostaje w obszarze teoretycznym i dostarcza informacji o pracy w warunkach idealnych. Tylko rzeczywisty pomiar energii pozwala np. zidentyfikować sytuacje, gdy np. doszło do uszkodzenia cewki elektrozaworu obciążenia maszyny i gdy ta tłocząc, zużywa 30% energii elektrycznej, co dla liczników teoretycznych jest niewykrywalne.

Publikacje pozostają zgodne [16] co do potrzeby wprowadzenia sterownika nadrzędnego, który nadzoruje pracę wielu sprężarek śrubowych. Niewłaściwa praca układu przynosi znaczne straty energetyczne i sama poprawa parametrów systemu może przynieść znaczne oszczędności. W klasycznych systemach sterowania nadrzędnego spotkamy deterministyczne reguły regulacji gdzie maszyny uruchamiane są na zasadach sekwencyjnych na bazie określonych priorytetów.

Dysponując niepełnymi danymi, w niniejszej pracy proponuje się podejście, które zostało zaimplementowane na rzeczywistych instalacjach a bazuje na sieciach rekurencyjnych typu LSTM [10] oraz ich dwukierunkowym rozszerzeniu BiLSTM [17]. Sieci te często pojawiają się w kontekście szeregów czasowych np. bazujących na liczniku sprężonego powietrza [8] a ich dalsze zastosowanie pojawia się w zastosowaniu predykcyjnym utrzymania ruchu [15]. Jednocześnie wsparcie to nie polega na bezpośrednim wsparciu decyzji operacyjnych systemów sterowania (co też jest poniekąd zrozumiałe, bo wymagałoby przejęcia funkcji sterownika nadrzędnego, który bywa dostarczany z zakupionymi urządzeniami). Zaproponowane podejście łączy predykcję binarnych stanów obciążenia urządzeń z asymetryczną oceną kosztów błędów, co stanowi nowe podejście stosowalne przy braku innych istotnych danych zużycia mediów.

Sprężarkownia często jest projektowana na bazie największego zapotrzebowania, co może prowadzić do nieefektywnego wykorzystania maszyn w okresach o zmniejszonym zapotrzebowaniu. W przemyśle można się spotkać z następującymi niekorzystnymi czynnikami:

- przewymiarowanie układu, gdzie zbyt wydajne sprężarki nie będą w stanie pracować w optymalnym punkcie pracy,
- zbyt wysokie ciśnienie robocze związane z nieprawidłowym projektem instalacji dystrybucyjnej,
- nieszczelności w sieci dystrybucyjnej, które mogą wymuszać ciągłą pracę maszyn w okresach przestojów,
- nieprawidłowy układ sekwencyjny pracy sprężarek, który może prowadzić do pracy w nieefektywnych punktach pracy,

- niewłaściwe wykorzystanie sprężarek z przetwornicą częstotliwości.

W związku z doświadczeniem zdobytym podczas wdrożeń, aby zapewnić odpowiednie warunki do uczenia dla sieci neuronowej należy najpierw spełnić następujące warunki:

- wszystkie maszyny muszą być prawidłowo skonfigurowane oraz wprowadzone do systemu sterowania nadrzędnego,
- sekwencja pracy sprężarek musi być dostosowana do optymalnego, uniwersalnego zachowania całego układu,
- sprężarki z przetwornicami częstotliwości muszą pracować w optymalnym punkcie pracy lub adaptować się dynamicznie do zmiennego zapotrzebowania.

Przy spełnieniu powyższych warunków, możliwe jest nauczanie sieci, która będzie w stanie wyszukać pewne wzorce zachowania układu decydując o dopasowaniu liczby pracujących maszyn do zmiennego poboru.

3. Metodologia oraz studium przypadku

3.1. Założenia

Oszczędność energii w rozpatrywanym aspekcie będzie osiągana przez ograniczenie liczby pracujących maszyn w sposób neutralny dla systemu sterowania przez predykcję nadchodzących stanów pracy maszyn. Sprężarka pracująca na biegu jałowym (stan bez tłoczenia powietrza) zużywa do 30% swojej energii nominalnej. Ponieważ pobór sprężonego powietrza modelowany będzie w oparciu o ograniczone dane wejściowe celem będzie takie przewidywanie przyszłych stanów obciążenia sprężarek (stan gdy sprężarka tłoczy powietrze), które umożliwi określenie czy dana maszyna faktycznie będzie potrzebna. W związku ze zmiennością poboru, często sprężarki utrzymywane są na biegu jałowym przez długi czas by kompensować nieprzewidywalność zapotrzebowania na sprężone powietrze.

Do badań wybrany został obiekt, który składa się z trzech maszyn o zbliżonej mocy, które potrzebują po zatrzymaniu 90s na rozprężenie jednak zgodnie z zaleceniami producenta nie wolno przekraczać 8 startów na godzinę.

W publikacjach [12, 13, 14] zaproponowano sposób sekwencjonowania danych pomiarowych oraz funkcję straty, która niesie w sobie informacje o charakterystyce układu zawierając człon analogowy (pomiar ciśnienia względnego) oraz binarny (stan obciążenia) [11]. Zaproponowano wówczas wykorzystanie klasycznych klasyfikatorów binarnych do oceny efektywności wsparcia systemów sterowania, jednak doświadczenie wdrożeniowe doprowadziło do ich naturalnej ewolucji usprawniającej zarówno ocenę stosowalności metody jak i potencjalne korzyści.

Dane wejściowe z rozpatrywanego obiektu zostały zebrane w równych 20s odstępach (tutaj wypada zaznaczyć, że okres próbkowania jest kluczowy dla właściwego modelowania i przy zbyt długim okresie próbkowania modelowanie nie będzie możliwe, należy wówczas zwiększyć częstotliwość obserwacji). Zdecydowano również o ograniczeniu danych wejściowych do pomiaru ciśnienia oraz stanów obciążenia sprężarek. Dane również musiały zostać zebrane podczas prawidłowej pracy układu, gdy wszystkie maszyny były dostępne i nie występowały sytuacje awaryjne destabilizujące

działanie układu. Następnie zgodnie z publikacją [14] zostały utworzone zbiory uczące oraz sekwencje z przestrzeni 4 tygodni danych przy zachowaniu 75% dla uczenia oraz 25% dla predykcji.

3.2. Architektura systemu

Dotychczas posługiwano się jednokierunkową architekturą LSTM, jednak odkryto, że przy wprowadzeniu sieci dwukierunkowej uzyskuje się niewielką poprawę, którą warto wykorzystać dla potrzeb uczenia. Horyzont predykcji będzie zależał od charakterystyki obiektu w związku z czym jest dobierany indywidualnie dla każdego obiektu. Przyjęto założenie, że horyzont musi zapewnić odpowiedni czas rozprężania maszyny (po zatrzymaniu sprężarka potrzebuje np. 30–90s postoju przed kolejnym rozruchem w zależności od zaleceń producenta i poziomu zaawansowania jej konstrukcji). Sieć neuronowa otrzymując okno poprzedniego stanu np. 3 minutowego, ma za zadanie przewidzieć kolejne 3 minuty. Nowsza konstrukcja maszyn będzie pozwalała na większe możliwości, starsza na mniejsze.

Dla rozpatrywanego obiektu, w związku z krótkim czasem rozprężania wybrano 2 minutowy horyzont predykcji. Wsparcie decyzyjności sterownika nadrzędnego będzie zrealizowane przez wcześniejsze wyłączenie danej sprężarki na bazie predykcji stanu obciążenia wykonanego po wykryciu stanu odciążenia. Również w związku z okresem próbkowania należy być świadomym, że otrzymując informację o odciążeniu, system sprężonego powietrza niesie w sobie informację o aktualnym trendzie zapotrzebowania. W rozpatrywanym obiekcie nie było potrzeby zmian w tym zakresie, ale w przypadkach obiektów o dużej zmienności gdzie próbkowanie miałoby miejsce co 5s, niezbędnym jest zachowanie 20s na obserwację charakterystyki ciśnienia.

3.3. Asymetryczna funkcja straty

Projektując funkcję straty dla problemu badawczego można wprowadzić dodatkowe człony, których zadaniem będzie obserwacja cech, których waga będzie się przekładać na adekwatniejszą predykcję. W rozpatrywanym przypadku zdecydowano się na pozostanie przy zaproponowanej we wcześniejszych publikacjach funkcji straty [11], której człony niosą w sobie informację o stanie ciśnienia (człon błędu średniokwadratowego) oraz niezmienności obiektu (człon binarny entropii krzyżowej BCE) (1).

$$f_{\text{straty}}(y_a, y_b) = w_{\text{MSE}} \cdot \text{MSE}(y_a, y_{p_a}) + w_{\text{BCE}} \cdot \text{BCE}(y_b, y_{p_b}) \quad (1)$$

gdzie y_a oznacza rzeczywistą wartość analogową ciśnienia, y_b rzeczywisty stan binarny sprężarki, y_{p_a} predykcję wartości ciśnienia, y_{p_b} predykcję stanu binarnego, natomiast w_{MSE} oraz w_{BCE} to wagi składowej regresyjnej i klasyfikacyjnej funkcji straty.

Użyta sieć neuronowa BiLSTM składa się z dwóch warstw odpowiednio 100 oraz 50 neuronów, przewidziano współczynnik zapominania (ang. dropout) na poziomie 0,2, rozmiar partii (ang. batch size) na poziomie 4096, współczynnik uczenia przyjęto na poziomie 0,1 użyto również algorytmu optymalizacji stochastycznej Adam.

3.4. Metryki ewaluacji

Doświadczenie wskazuje, że najbardziej efektywną metodą ewaluacji nie jest rozpatrywanie metryk dla całego zbioru (choć popularne RMSE niesie w sobie informację o śledzeniu zdarzeń, może być niewystarczające dla decyzji sterujących) tylko precyzyjne odniesienie się do momentów decyzyjnych. W związku z tym wprowadzono następujące założenia:

- dla ewaluacji użyto 4 tygodni danych historycznych, bezpośrednio po 4 tygodniach danych uczących, czyli przyjęto tezę, że miesięczna charakterystyka jest wystarczająca dla potrzeb predykcji,
- rozpatrywane zdarzenia dotyczą tylko tych momentów, gdy potrzebna jest decyzja, gdy nastąpiło odciążenie maszyny,
- przy wykryciu zdarzenia odciążenia, następuje uruchomienie predykcji, następnie rzeczywiste stany zostają porównane z predykcyjnymi,
- przewidywany jest stan obciążenia na bazie którego podejmowana jest decyzja,
- odchyłka RMSE jest traktowana jako ocena nadążania charakterystyki rzeczywistej za predykcyjną jednak jest mniej ważna niż ocena adekwatności stanów obciążenia,
- w związku z różną wagą dla oceny adekwatności zdarzeń użyto znanych powszechnie klasyfikatorów binarnych ze skupieniem się na minimalizacji tych wskaźników, które są najbardziej niebezpieczne dla systemu sterowania (przede wszystkim zdarzenia fałszywie negatywne FN ang. *False Negative*),
- użyte wskaźniki odnoszą się do decyzji w ramach jednego rozpatrywanego zbioru, a nie wszystkich próbek w ramach okna sekwencji, czyli decyzja FN oznacza, że sieć rekomendowała wyłączenie maszyny, podczas gdy rzeczywistość wskazała na konieczność jej uruchomienia.

Wskaźniki FP (ang. *False Positive* fałszywie pozytywne) oraz FN są doskonałymi wskaźnikami oceny efektywności predykcji, ponieważ niosą w sobie informację o rzeczywistych negatywnych kosztach, z jakimi wiążą się błędne decyzje systemu sterowania. Rzeczywista kara za zdarzenia FN jest wyższa niż w przypadku FP, ponieważ dla zdarzenia FN następuje rekomendacja wyłączenia sprężarki, która w rzeczywistości jest potrzebna, co może prowadzić do spadku ciśnienia w sieci mogącego skutkować zatrzymaniem lub chwilowym przyblokowaniem produkcji. W przypadku zdarzenia FP, sprężarka zostaje utrzymywana na biegu jałowym, co niesie w sobie stratę energetyczną, pozostając w rezerwie dla systemu sterowania, nie niosąc ryzyka wstrzymania produkcji.

Wprowadzono również dodatkowe wskaźniki informujące o bezpieczeństwie, które oznaczono literą *S* i wyrażono w procentach, które lepiej informują o efektywności predykcji w kontekście bezpieczeństwa systemu sterowania niż same klasyfikatory binarne. Wskaźniki te zostały zdefiniowane w następujący sposób:

$$S = \frac{TP + TN}{TP + TN + FP + FN} \cdot 100\% \quad (2)$$

$$S_{FN} = \frac{FN}{TP + FN} \cdot 100\% \quad (3)$$

$$S_{FP} = \frac{FP}{TP + TN + FP + FN} \cdot 100\% \quad (4)$$

gdzie *TP* (prawdziwie pozytywne, ang. *True Positive*) oznacza liczbę trafnych predykcji obciążenia, *TN* (prawdziwie negatywne, ang. *True Negative*) trafnych predykcji biegu jałowego czyli bez obciążenia, *FP* błędnych predykcji obciążenia, a *FN*

— błędnych predykcji biegu jałowego czyli najgroźniejszym rodzajem błędu o którym już wspomniano.

Wskaźnik S wyraża ogólną skuteczność predykcji w oknie tranzycji — wartość 100% oznacza, że model bezbłędnie przewidział wszystkie stany w analizowanym oknie, natomiast wartości poniżej 100% wskazują na występowanie błędnych predykcji.

Wskaźnik S_{FN} jest warunkową miarą ryzyka — informuje o odsetku niewykrytych powrotów obciążenia, czyli sytuacji, w których model rekomendował możliwość wyłączenia sprężarki, podczas gdy w oknie decyzyjnym okazała się ona ponownie potrzebna. Wartość 0% jest stanem idealnym, oznaczającym, że żadna rekomendacja wyłączenia nie naraziła układu na spadek ciśnienia. Wartość 100% oznacza, że model nie wykrył żadnego z występujących powrotów obciążenia — rekomendacje wyłączeń dla takiej maszyny nie mogą stanowić samodzielnej podstawy decyzji (przypadek charakterystyczny m.in. dla sprężarek wiodących, których powroty do obciążenia są zdarzeniami rzadkimi i trudnymi do przewidzenia). Wyniki na poziomie np. 60% wskazują, że blisko 60% powrotów obciążenia pozostało niewykrytych, co wymaga wprowadzenia regulowych zabezpieczeń po stronie sterownika nadrzędnego.

Wskaźnik S_{FP} określa odsetek decyzji nadmiarowo ostrożnych — sytuacji, w których model przewidział powrót obciążenia, który w oknie decyzyjnym nie nastąpił, przez co sprężarka pozostała utrzymana w gotowości, mimo że mogła zostać wyłączona. Wartość bliska 0% oznacza pełne wykorzystanie dostępnych możliwości oszczędności energii. Wzrost tego wskaźnika nie zagraża bezpieczeństwu dostaw sprężonego powietrza, obniża natomiast efektywność energetyczną systemu.

Uzupełniając wprowadzono dwie metryki dopasowania dokładnego, wyznaczone osobno dla dwóch populacji zdarzeń — tranzycji odciążenia ($1 \rightarrow 0$) oraz tranzycji obciążenia ($0 \rightarrow 1$) — które odzwierciedlają wierność odwzorowania pełnego przebiegu stanów wokół tych zdarzeń:

$$M_U = \frac{N_U^{dop}}{N_U} \cdot 100\% \quad (5)$$

$$M_L = \frac{N_L^{dop}}{N_L} \cdot 100\% \quad (6)$$

gdzie N_U i N_L oznaczają liczbę wykrytych tranzycji odpowiednio odciążenia i obciążenia, a N_U^{dop} , N_L^{dop} — liczbę tych tranzycji, dla których przewidziana sekwencja stanów w całym oknie horyzontu jest identyczna z rzeczywistą. W odróżnieniu od wskaźników S , oceniających trafność zagregowanej decyzji w oknie, metryki M_U i M_L oceniają zgodność przebiegu próbka po próbce.

Wskaźnik M_U informuje o jakości odwzorowania zachowania układu wokół tranzycji odciążenia — wartość 100% oznacza, że każda przewidziana sekwencja idealnie pokrywa się z rzeczywistym przebiegiem stanów.

Wskaźnik M_L ocenia analogicznie odwzorowanie przebiegów wokół tranzycji obciążenia — niska wartość wskazuje, że model ma trudności z wiernym odwzorowaniem momentu wznowienia tłoczenia, co jest spójne z podwyższonym S_{FN} dla maszyn o trudno przewidywalnych powrotach obciążenia.

3.5. Wynik ewaluacji

Dla rozpatrywanego obiektu sprawdzono następnie poszczególne wagi funkcji straty w zakresie od 0,1 do 0,9 z krokiem 0,1, przy zachowaniu warunku $w_{MSE} + w_{BCE} = 1$. Dla każdej kombinacji wag w_{MSE} oraz w_{BCE} przeprowadzono ewaluację na tym samym zbiorze danych testowych. Uzyskane wyniki przedstawiono w tabeli 1. Należy zwrócić uwagę, że kolumna FN podaje liczbę zdarzeń fałszywie negatywnych na poziomie pojedynczych próbek — jest to kryterium optymalizacji wybrane przy przeszukiwaniu. Wskaźniki S , S_{FN} i S_{FP} wyznaczane są z kolei na poziomie okien decyzyjnych tranzycji. Metryki M_U i M_L wyznaczane są na poziomie dopasowania dokładnego sekwencji, jako średnie arytmetyczne wartości dla poszczególnych sprężarek. Mianownik wskaźnika S_{FN} stanowi łączna liczba okien decyzyjnych, w których wystąpił powrót obciążenia; po zsumowaniu zdarzeń TP oraz FN wszystkich sprężarek rozpatrywanego układu (tabela 2) wynosi ona 73. Wartość ta zależy wyłącznie od charakterystyki zbioru danych, a nie od konfiguracji modelu, dlatego pozostaje wspólna dla wszystkich wariantów zestawionych w tabeli 1.

Tabela 1

Wyniki wyszukiwania współczynników wagi — kryterium
 S_{FN} [%] rosnąco

nr	w_{MSE}	w_{BCE}	FN	S [%]	S_{FN} [%]	S_{FP} [%]	$RMSE$	M_U [%]	M_L [%]
1	0,20	0,80	66	98,96	61,64	0,20	0,0535	95,23	67,46
2	0,30	0,70	66	98,75	61,64	0,41	0,0542	94,19	65,73
3	0,60	0,40	67	98,79	63,01	0,35	0,0533	94,30	65,35
4	0,40	0,60	70	98,75	63,01	0,39	0,0540	94,10	65,37
5	0,90	0,10	73	98,73	64,38	0,39	0,0531	93,93	66,73
6	0,80	0,20	74	98,66	64,38	0,47	0,0524	93,65	65,65
7	0,70	0,30	74	98,85	65,75	0,26	0,0528	94,47	61,82
8	0,10	0,90	69	98,96	67,12	0,13	0,0538	95,40	65,26
9	0,50	0,50	75	98,86	67,12	0,22	0,0534	94,65	65,86

Dla wybranej sieci (numer 1) składowe cząstkowe przedstawiono w tabeli 2.

Tabela 2

Wyniki ewaluacji wybranego modelu dla sprężarek SP_n

	N_T	TP	TN	FP	FN	S [%]	S_{FN} [%]	S_{FP} [%]	M_U [%]	M_L [%]
SP_1	361	25	299	10	27	89,75	51,92	2,77	86,70	69,81
SP_2	1429	0	1418	1	10	99,23	100,00	0,07	99,23	51,15
SP_3	3584	3	3573	0	8	99,78	72,73	0,00	99,75	81,41

Liczba N_T oznacza liczbę tranzycji odciążenia, które zostały wykryte w rozpatrywanym zbiorze danych testowych. Należy zwrócić uwagę, że sieć neuronowa przewiduje działanie systemu sterowania w odpowiedzi na zmienne zapotrzebowanie zakładając elementy wiodące — sprężarka SP_2 charakteryzuje się wysoką wartością $S_{FN} = 100\%$, co oznacza, że model nie wykrył żadnego z jej powrotów obciążenia następujących po tranzycji odciążenia (w zbiorze testowym wystąpiło 10 takich zdarzeń na 1429 analizowanych tranzycji). Jest to zachowanie charakterystyczne dla maszyny bazowej, która pokrywa podstawowe zapotrzebowanie — jej powroty pod obciążenie są zdarzeniami rzadkimi względem wzorca pracy ciągłej, przez co model nie znajduje w historii sygnału pozwalającego na ich przewidzenie. W praktyce rekomendacje wyłączenia maszyny

bazowej nie powinny być realizowane bez dodatkowych zabezpieczeń programowych. Model uczy się wzorców sterowania wynikających z historii pracy układu, a nie jedynie z chwilowego pomiaru ciśnienia.

Warto również zauważyć, że przestrzeń poszukiwań współczynników wagi charakteryzuje się stosunkowo płaską charakterystyką — wyniki dla poszczególnych kombinacji w_{MSE} i w_{BCE} nieznacznie od siebie odbiegają (Tab. 1). Świadczy to o adekwatności przyjętej architektury sieci BiLSTM, która nie wykazuje nadmiernej wrażliwości na dobór wag funkcji straty, co eliminuje potrzebę kosztownej obliczeniowo optymalizacji bayesowskiej. W przypadku gdyby wyniki były niejednoznaczne, na bazie doświadczenia wdrożeniowego, w takim przypadku proponuje się zastosowanie optymalizacji bayesowskiej w celu znalezienia najlepszego zestawu wag funkcji straty.

3.6. Wyniki wdrożenia

Dobrany powyżej model został wdrożony na rzeczywistym obiekcie przemysłowym. Co tydzień model był douczany na bazie nowych danych, przy zachowaniu 4 tygodniowego okna. Ponieważ dysponujemy ograniczonymi danymi wejściowymi, trudno odnieść się co do poprawy porównując miesiąc przed i po, ponieważ w rozpatrywanych okresach będzie występowała różna zmienność zapotrzebowania. Wskaźnikiem poprawy będzie procent biegu jałowego dla całej rozpatrywanej stacji sprężonego powietrza P_{BJ} wyrażony wzorem 7.

$$P_{BJ} = \frac{t_{BJ}}{t_{sum}} \cdot 100\% \quad (7)$$

gdzie t_{BJ} oznacza czas pracy (liczba godzin) sprężarki na biegu jałowym, a t_{sum} całkowity czas pracy (liczba godzin) sprężarki w analizowanym okresie.

Tabela 3 przedstawia procentowy udział biegu jałowego w analogicznych miesiącach przed i po wdrożeniu systemu predykcyjnego. Ponieważ dane zostały zanonimizowane, przyjęto następujące założenie modelowe: układ składa się z 3 sprężarek bez przetwornicy częstotliwości o mocy 75 kW każda, przy czym na biegu jałowym każda zużywa 30% energii nominalnej, a wszystkie maszyny sumarycznie przepracowują 1500 h miesięcznie. Przy powyższych założeniach szacowana oszczędność energii elektrycznej wyniosła odpowiednio 2288 kWh, 1448 kWh oraz 1562 kWh w kolejnych miesiącach po wdrożeniu, co łącznie daje około **5298 kWh** w analizowanym okresie.

Tabela 3

Udział biegu jałowego P_{BJ} [%] oraz szacowana oszczędność energii w kolejnych miesiącach

	Miesiąc 1	Miesiąc 2	Miesiąc 3
Przed wdrożeniem [%]	30,3	29,7	27,9
Po wdrożeniu [%]	7,7	15,4	12,5
Redukcja [%]	22,6	14,3	15,4
Oszczędność [kWh]	2288	1448	1562

4. Podsumowanie

Wypada podkreślić, że każdy przypadek powinien być rozpatrywany indywidualnie, ponieważ charakterystyka danego układu sprężonego powietrza jest często unikalna

i mimo podobnych zasad, niekoniecznie będzie przenosić się na inne obiekty. Obiekty wyposażone w przetwornice częstotliwości wymagają innego podejścia i polem do optymalizacji może być np. efektywne dynamiczne dobieranie wartości zadanej lokalnego ciśnienia takiej sprężarki w stosunku do zmiennego zapotrzebowania całego układu.

Kluczowym warunkiem skuteczności proponowanego podejścia jest odpowiednia charakterystyka obiektu — metoda przynosi wymierne korzyści energetyczne w układach, gdzie czas trwania biegu jałowego jest długi w związku z nieznajomością trendu ciśnienia. W obiektach o krótkich i nieregularnych cyklach produkcyjnych pole do optymalizacji może być ograniczone lub niedostępne, co należy zweryfikować przed wdrożeniem.

W celu uzyskania największych oszczędności energetycznych najlepiej byłoby korzystać z najefektywniejszych sprężarek, mieć w układzie przynajmniej jedną maszynę z przetwornicą częstotliwości jak i układ, który nie byłby przewymiarowany. W praktyce jednak, nie zawsze dla danego zakładu będzie opłacalna kosztowna wymiana sprężarek. Wprowadzenie systemu predykcyjnego pozwala na ograniczenie liczby pracujących maszyn w sposób neutralny dla systemu sterowania. W całym rozpatrywanym okresie nie doprowadzono do przerw produkcji ani znaczących spadków ciśnienia w sieci przy czym udało się znacząco skrócić czas pracy sprężarek na biegu jałowym.

Proponowana metoda dobrze sprawdza się w układach, które zbudowane są ze sprężarek bez przetwornic częstotliwości i pozwala na uzyskanie korzyści energetycznych, które z czasem mogą przyczynić się do zakupu bardziej efektywnych sprężarek wyposażonych w przetwornice częstotliwości.

Różne problemy w układach sprężonego powietrza wymagają różnych podejść, pole wykorzystania sieci neuronowych w tym przypadku jest szersze niż przytoczone w poniższej publikacji i będzie rozwijane w kolejnych latach wraz z rozwojem sztucznej inteligencji. Niniejsza publikacja przedstawia fragment metodologii oraz badań, jakie zostały przeprowadzone oraz wdrożone na rzeczywistych obiektach przemysłowych będących klientami firmy Marani Sp. z o.o.

LITERATURA

1. Final energy consumption in industry - detailed statistics. Dostępne online: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Final_energy_consumption_in_industry_-_detailed_statistics.
2. ISO 11011:2013. Dostępne online: <https://www.iso.org/standard/46580.html>.
3. ISO 50002-1:2025. Dostępne online: <https://www.iso.org/standard/83645.html>.
4. PN-EN 16247-1:2012 - wersja polska. Dostępne online: <https://sklep.pkn.pl/pn-en-16247-1-2012p.html>.
5. ISO - ISO 50001 — Energy management 2023. Dostępne online: <https://www.iso.org/iso-50001-energy-management.html>.
6. Dyrektywa Parlamentu Europejskiego i Rady (UE) 2023/1791 z dnia 13 września 2023 r. w sprawie efektywności energetycznej oraz zmieniająca rozporządzenie

- (UE) 2023/955 (wersja przekształcona) (Tekst mający znaczenie dla EOG) 2023-09-13, 2023-09.
7. Zalecenie Komisji (UE) 2024/2002 z dnia 24 lipca 2024 r. ustanawiające wytyczne dotyczące interpretacji art. 11 dyrektywy Parlamentu Europejskiego i Rady (UE) 2023/1791 w odniesieniu do systemów zarządzania energią i audytów energetycznych (notyfikowana jako dokument nr C(2024) 5155). Technical report 2024-07-24, 2024-07.
 8. Bezold V., Weckerlein N., Schnell F., Sauer A.: Data-Efficient Forecasting for Compressed Air Systems: Retraining Instead of More Data, In: *2025 6th International Conference on Clean and Green Energy Engineering (CGEE)* Zagreb, Croatia 2025, p. 95–99. IEEE.
 9. Cabello Eras J. J., Sagastume Gutiérrez A., Sousa Santos V., Cabello Ulloa M. J.: Energy management of compressed air systems. assessing the production and use of compressed air in industry, *Energy*, 2020, vol. 213 p. 118662.
 10. Hochreiter S., Schmidhuber J.: Long Short-Term Memory, *Neural Computation*, 1997, vol. 9(8) p. 1735–1780.
 11. Kasprzyk K., Antczak Ł.: Predykcja stanów sprężarek śrubowych z użyciem sieci LSTM w celu wsparcia nadrzędnych systemów sterowania nowoczesnych przemysłowych układów sprężonego powietrza, In: *Automatyzacja Procesów Dyskretnych. Teoria i Zastosowania*, 2024, p. 133–144.
 12. Kasprzyk K., Gałuszka A.: Advances in Science and Technology Research Journal, Prediction of compressed air demand depending on the type of production with the use of neural networks, 2023, vol. 17(3) p. 154–159.
 13. Kasprzyk K., Gałuszka A.: Frequency driven screw compressors state prediction in modern air control system, In: *Modelling and Simulation 2024. The 2024 European Simulation and Modelling Conference*. EUROSIS-ETI, 2024, p. 252–258.
 14. Kasprzyk K., Gałuszka A.: Frequency driven screw compressors unload state prediction in modern air control system, In: *23rd Industrial Simulation Conference 2025* Skövde, Szwecja 3–2025, p. 61–65. EUROSIS-ETI.
 15. Khan U., Cheng D. S., Setti F., Fummi F., Cristani M., Capogrosso L.: A Comprehensive Survey on Deep Learning-based Predictive Maintenance, *ACM Transactions on Embedded Computing Systems*, Marzec 2, 2026, vol. 25(2) p. 25:1–25:43.
 16. Salomone-González D. Advanced strategies for the efficient optimization and control of industrial compressed air systems, *Results in Engineering*, vol. 26 p. 105429.
 17. Schuster M., Paliwal K.: Bidirectional recurrent neural networks, *IEEE Transactions on Signal Processing*, 1997, vol. 45(11) p. 2673–2681.
 18. U.S. Department of Energy . Improving Compressed Air System Performance: A Sourcebook for Industry 2016.