

Kamil KASPRZYK<sup>1,2</sup>, Łukasz ANTCZAK<sup>1</sup>

<sup>1</sup> Marani Sp. z o.o.

<sup>2</sup> Politechnika Śląska

## **PREDYKCJA STANÓW SPRĘŻAREK ŚRUBOWYCH Z UŻYCIEM SIECI LSTM W CELU WSPARCIA NADRZĘDNYCH SYSTEMÓW STEROWANIA NOWOCZESNYCH PRZEMYSŁOWYCH UKŁADÓW SPRĘŻONEGO POWIETRZA**

**Streszczenie.** Przeprowadzono badanie sprawdzające możliwości wsparcia nadrzędnego systemu sterowania nowoczesnej sprężarkowni, zbudowanej z trzech sprężarek śrubowych, wyposażonych w silniki magnetyczne z przetwornicami częstotliwości o szerokim zakresie pracy. Dane zebrane zostały na przestrzeni roku a charakterystyka pracy przez cały okres, w odniesieniu miesiąc do miesiąca, była zmienna. Zaproponowano sposób postępowania oraz kryteria oceny poprawności przewidywań sieci neuronowych, które pozwoliły znaleźć najbardziej efektywny model sieci. Wprowadzono specjalną funkcję straty oraz sieć neuronową o dwóch warstwach LSTM, mając na uwadze jak najmniejsze zaangażowanie mocy obliczeniowych. Nie wszystkie uzyskane wyniki nadawałyby się do podejmowania decyzji o wcześniejszym wyłączeniu maszyn, jednak w przypadku niektórych urządzeń uzyskano bezpieczne rozwiązania. Mniej skomplikowany oraz bardziej powtarzalny pobór sprężonego powietrza prowadzi do łatwiejszego i bardziej adekwatnego przewidywania przyszłych stanów.

## **PREDICTION OF SCREW COMPRESSORS STATES WITH LSTM IN SUPPORT OF SUPERVISORY CONTROL SYSTEMS IN COMPRESSED AIR INDUSTRIAL SYSTEMS**

**Summary.** A study was carried out to test the possibility of supporting the supervisory control system of a modern compressor room containing three screw compressors equipped with magnetic motors with frequency converters offering a wide operating range. Data was collected over the course of a year and the operating characteristics varied month to month throughout the period. A methodology for proceeding, and criteria for assessing the correctness of the neural network predictions, were proposed to find the most effective network model. A dedicated loss function and a neural network with two layers of LSTM were introduced with a view to involve as little computing power as possible. Not all of the obtained results would be suitable for making decisions about the early shutdown of compressors, but for some devices, safe solutions were achieved. Less complex and more reproducible compressed air intake leads to easier and more adequate prediction of future states.

## 1. Wprowadzenie

W przemyśle ciężkim (kopalniach, odlewniach, kuźniach), zaawansowanych liniach technologicznych (przemysł samochodowy, przemysł drzewny) oraz wielu innych zastosowaniach sprężone powietrze jest efektywnym, popularnym medium. Koszt energii [12] zużytej na produkcję sprężonego powietrza stanowi często największy koszt związany z produkcją danego zakładu przemysłowego. Z dnia na dzień pojawiają się coraz nowsze konstrukcje sprężarek, oferując korzystną adaptację do poboru, przy zapewnieniu odbiorcy zoptymalizowanego nadrzędnego systemu sterowania.

W sektorze sprężonego powietrza pojawia się stopniowe odejście od silników asynchronicznych w kierunku wydajnych silników z magnesami trwałymi [9]. Takie rozwiązanie pozwala na pozbycie się ograniczenia godzinowej liczby startów silnika, oferując większą gotowość do szybkiego uruchomienia i wysoką energooszczędność [9]. Wykorzystanie silników wyposażonych w przetwornicę częstotliwości, pozwala na znalezienie punktu pracy przy danym zapotrzebowaniu i ograniczeniu liczby pracujących maszyn do minimum. Jednocześnie o ile najkorzystniejszym mogłoby wydawać się wymienienie parku maszynowego na jak najbardziej wydajne energetycznie urządzenia, związane jest to z kosztem, który może nie zwrócić się wystarczająco w pożądanym przez klienta horyzoncie czasowym. W publikacjach związanych z sektorem sprężonego powietrza pojawiają się często metody ewaluacji identyfikowanych charakterystyk bazujących na statystycznych metodach odchyłki od danego punktu pracy takich jak MAE (błąd średniokwadratowy) [3], RMSE (pierwiastek błędu średniokwadratowego) [10] lub np.  $R^2$  (współczynnik R kwadrat) [10], [1], często również mowa jest o układach o stosunkowo łatwo przewidywalnym poborze, gdzie nawet statystyczne metody oceny (jak wykorzystanie sumy kumulatywnej CUSUM) [1] pozwalają efektywnie przewidywać pobór. Poprawnie dobrany system sprężonego powietrza pozwoli na największe oszczędności. Dobrymi praktykami w tym zakresie są minimalizacje straty energii podczas dystrybucji, zmniejszenie strat powietrza w systemie (takich jak przecieki powietrza i nadciśnienie), optymalizacja strony popytowej, minimalizacja wymaganego przepływu oraz ciśnienia. Należy również rozważyć lokalizację sprężarek [11], przy czym często spotykamy się z centralnym systemem sterowania, gdzie maszyny znajdują się również w odległych, newralgicznych punktach kompensując starty ciśnienia na rurociągu. Przy prowadzeniu badań w celu sprawdzenia możliwych oszczędności energii przy wykorzystaniu technik uczenia głębokiego [4] zauważono, że sieć neuronowa jest w stanie znaleźć pewne zależności w pracy układu i wykryć jego nieprawidłową konfigurację, jednak w przypadku nowoczesnych układów korzyści z sieci były niewielkie. Wyniki przedstawione w niniejszej publikacji są efektem już trwających badań, przez co nastąpiło odrzuceniem dróg, które na samym wstępie okazały się nieprawidłowe, bazując również na badaniach [4], [5], [6]. Dziedzina sieci neuronowych wiąże się z dużymi wymaganiami mocy obliczeniowej, dlatego starano się zaproponować takie rozwiązanie, które umożliwiłoby łatwą implementację i nie wymagało do obliczeń superkomputerów. Zaprezentowane wyniki bazują na rzeczywistych danych zebranych w firmie Marani sp. z o.o. we współpracy z Politechniką Śląską.

### 1.1. Klasyfikacja danych pomiarowych

Do uczenia wybrano dane zebrane w jednakowych 20-sekundowych odstępach czasowych z zakładu produkcyjnego prowadzącego określony typ działalności o różnej charakterystyce pracy, bazując na różnych granicach ciśnienia na przestrzeni roku. W danym dniu nie było wiadomo w jaki sposób powietrze zostanie wykorzystane, przez co charakterystyka poboru mogła się znacząco różnić, a fakt ten pozostaje czynnikiem nieprzewidywalnym i nieopomiarowanym (brak informacji zwrotnej od strony popytowej). Rozpatrywany obiekt dysponuje trzema sprężarkami śrubowymi o identycznej mocy a każda z nich jest wyposażona w przetwornicę częstotliwości oraz silnik z magnesami trwałymi. Regulacja każdej ze sprężarek odbywa się na bazie pomiaru ciśnienia oraz regulatora PI (proporcjonalno całkującego).


Kaskadowa regulacja w zależności od zapotrzebowania na sprężone powietrze realizowana jest przez sterownik nadrzędny. W przypadku przekroczeń dolnej lub górnej granicy ciśnienia roboczego dobierana jest jak najmniejsza liczba maszyn, tak aby ciśnienie utrzymywało się w zakresie żądanego zakresu. Pomiar ciśnienia wyjściowego dla regulacji umieszczony jest w punkcie odzwierciedlającym rzeczywiste zapotrzebowanie. Wspominany obiekt pracuje na różnych, zmiennych charakterystykach ciśnienia, jak również jest okresowo wyłączany. W tabeli 1 przedstawiono przykładowe granice pracy.

Tabela 1

Granice ciśnienia roboczego dla podejmowania decyzji

Lp.	Dolna granica ciśnienia roboczego [bar]	Górna granica ciśnienia roboczego [bar]	Rozpiętość [bar]
1	6.20	6.60	0.40
2	6.60	7.00	0.40
3	6.50	6.90	0.40

W tygodniu przedstawionym na rysunku 1 praca odbywała się w jednych granicach ciśnienia, ale w kolejnym tygodniu mogła już odbywać się w innych. Produkcja odbywa się w cyklach tygodniowych, jednak granice ciśnienia mogą być przez obsługę modyfikowane w zależności od aktualnych wymagań produkcji.

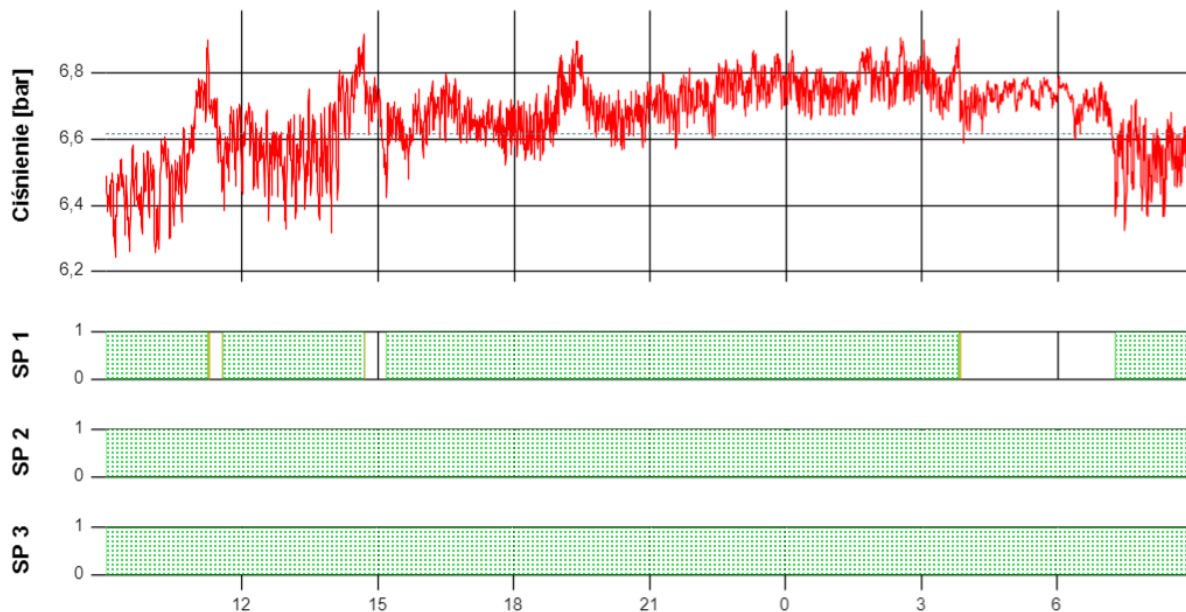


Rys. 1. Przykładowy cykl pracy rozpatrywanego obiektu [źródło własne]

### 1.2. Specyfika pracy


Podczas produkcji charakterystyczna jest pewna regularność, ciśnienie utrzymuje się w granicach pracy dzięki użyciu regulatora PI odpowiadającego za adaptację do

zmiennego poboru co można zauważyć na rysunku 2. Oznaczenie  $SP_n$  oznacza sprężarkę o numerze  $n$ . Na wykresach oznaczono stan pracy, gdy tłoczone jest powietrze jako obciążenie (wzór punktowy), a stan pracy, gdy silnik sprężarki pracuje, ale powietrze nie jest tłoczone (bieg jałowy), przedstawiono za pomocą wzoru jednolitego.



Rys. 2. Adaptacja przebiegu regulacji ciśnienia dla granic od 6.3bar do 6.8bar  
[źródło własne]

Losowo występuje zmienne zapotrzebowanie widoczne na rysunku 3. Potrafi wtedy pojawić się duża liczba załączeń jak i problem ze znalezieniem punktu pracy (na minimalnych obrotach maszyna daje za dużo powietrza i ciśnienie rośnie, następnie przy odciążeniu spada, przy dojściu do granicy musi nastąpić załączenie).



Rys. 3. Nieprzewidywalna zmienność charakterystyki [źródło własne]

### 1.3. Założenia architektury sieci

W publikacji [5] analizowano krótkofalowe przewidywanie zapotrzebowania na sprężone powietrze oraz ograniczono się do próby znalezienia rozwiązania oddającego najlepiej zapotrzebowanie na sprężone powietrze. Z kolei w publikacji [4] podjęto próbę znalezienia algorytmu mogącego wspomagać decyzyjność sterowników nadrzędnych sprężarkowni. Wprowadzono tam zarys algorytmu sterowania jak również podejście, które mogłoby pomóc w przewidywaniu również stanu maszyn. Każda podjęta decyzja wiązała się z pewnym ryzykiem nieprawidłowości, która może być katastrofalna w skutkach. W związku z charakterem rozpatrywanego problemu jako ciągu czasowego przyjęto założenie, że zostanie użyta rekurencyjna sieć neuronowa LSTM [10] o różnych hiperparametrach. Następnie nastąpi zbadanie wpływu modyfikacji wybranych parametrów na efektywność wyników. Użycie sieci LSTM [11] pojawia się obecnie w literaturze zarówno w przypadku przewidywania awarii komponentów [3] jak i samych systemów sprężonego powietrza [10].

Żeby przewidzieć zapotrzebowanie na sprężone powietrze, należy ograniczyć dane uczące do minimum odzwierciedlającego wpływ pracujących maszyn na działanie układu [10]. W związku z tym przyjęto, następujące założenia:

- przewidywanie będzie dotyczyło wartości ciśnienia wyjściowego (pomiar na bazie, którego sterownik nadrzędny prowadzi regulację w punkcie instalacji odzwierciedlającym żądane zapotrzebowanie) w nadchodzących chwilach oraz stanów obciążenia maszyn, pozostałe sygnały zostają pominięte,
- uwzględnione tylko te próbki, gdy system sterowania był aktywny, nie odbywał się serwis danej maszyny i wszystkie maszyny były obecne w systemie,
- wartość ciśnienia w następującej chwili będzie zależała od poprzedniej chwili w związku z tym cały zbiór treningowy oraz testowy będą przesunięte względem siebie o jedną próbkę,
- na bazie wspomnianych wyżej wartości zostaną utworzone sekwencje dla zbiorów treningowych oraz testowych, które będą przekazywane do uczenia,
- normalizacji poddano tylko wektor danych analogowych dołączając do niego wartości binarne nieznormalizowane,
- wprowadzono mechanizm szybkiego zatrzymania obserwujący proces uczenia sieci, który oczekuje w czasie 25 epok poprawę deltę starty walidacyjnej na poziomie 0,01,
- przyjęto uczenie na zbiorze 75% zebranych danych a predykcję wykonano na następujących 25%,
- wykorzystano algorytmu optymalizacji stochastycznej ADAM, a punktem wyjścia dla obliczeń została strata walidacyjna.
- wszystkie obliczenia wykonane zostały przy użyciu bibliotek TensorFlow oraz Keras w wersji 2.15.0.

## 2. Predykcja zapotrzebowania

### 2.1. Metody oceny

Celem badań jest sprawdzenie, czy w sposób bezpieczny da się przewidzieć przyszłe stany obciążeń na bazie których sterownik nadrzędny będzie podejmował decyzje o wcześniejszym wyłączeniu maszyn (sprawdzenie czy maszyna będzie potrzebna w rozpatrywanym horyzoncie czasowym). Mimo, że problem nie dotyczy klasyfikacji jako takiej, wskaźniki używane przy jej ocenie w tym wypadku sprawdzają się dobrze. Do oceny zostaną użyte:

- standardowe wskaźniki klasyfikacji (TN – prawdziwie negatywne, FP – fałszywie pozytywne, FN – fałszywie negatywne, TP – prawdziwie pozytywne),
- precyzja – pozwala ocenić jak dużym ryzykiem jest objęta podejmowana decyzja, jak najlepszy wskaźnik tutaj pozwoli podejmować decyzję z minimalnym ryzykiem,
- czułość – informuje jak wiele wysokich stanów udało się zakwalifikować prawidłowo (wykrywalność),
- dokładność – odzwierciedla jak dużo wartości TP oraz TN udało się prawidłowo przewidzieć w całym zbiorze.

Dla wspomnianych ocen, będzie sprawdzane 6 predykowanych próbek (czyli okres 120 s) odpowiadających czasowi, w trakcie którego maszyna po wyłączeniu nie będzie zdolna do ponownego rozruchu (odbywa się zrzut ciśnienia), co będzie kluczowe dla systemu sterowania oraz wsparcia decyzyjności sterownika nadrzędnego.

### 2.2. Funkcja straty

Problem dotyczy domeny ciągów czasowych, gdzie stan ciśnienia oraz aktywnych urządzeń wpływa na siebie nawzajem, dlatego zaproponowano wykorzystanie dopasowanej funkcji straty, składającej się z dwóch członów. Dla wartości analogowej zostanie użyte  $MSE$  (1), czyli

$$MSE(y_a, y_{p,a}) = \frac{1}{N} \sum_{i=1}^N (y_{a,i} - y_{p,a,i})^2 \quad (1)$$

gdzie:  $y_a$  to wartość wyjściowa analogowa, a  $y_{p,a}$  predykowana wartość analogowa.

Natomiast dla wartości binarnej (2) użyta zostanie entropia krzyżowa  $BCE$ :

$$BCE(y_b, y_{p,b}) = -\frac{1}{N} \sum_{i=1}^N (y_{b,i} \log(y_{p,b,i}) + (1 - y_{b,i}) \log(1 - y_{p,b,i})) \quad (2)$$

gdzie:  $y_b$  to wartość wyjściowa binarna obciążenia, a  $y_{p,b}$  predykowana wartość binarna obciążenia.

Następnie na podstawie tych dwóch wartości zbudowana zostanie dedykowana funkcja straty (3) przedstawiona jako:

$$f_{straty}(y_a, y_b) = 0.3 \cdot MSE(y_a, y_{p,a}) + 0.7 \cdot BCE(y_b, y_{p,b}) \quad (3)$$

Użyte wagi będą przedmiotem dalszych badań.

W związku z użytą funkcją przewidziano również użycie odpowiadających im odpowiednich funkcji, dla wartości  $y_{p_a}$  użyto funkcji liniowej aktywacji, dla  $y_{p_b}$  użyto aktywacji sigmoid. Spodziewając się również dodatkowych ukrytych zależności za punkt wyjścia przyjęto dwie warstwy LSTM (pierwsza o wielkości 100 jednostek a druga o wielkości 50 jednostek).

### 2.3. Horyzont predykcji

Sprężarka śrubowa po zatrzymaniu potrzebuje ok 60 s na tzw. zrzut ciśnienia, czyli rozprężenie ciśnienia nagromadzonego podczas sprężania do takiego stopnia by kolejny rozruch nie wiązał się ze zbyt wysokim prądem rozruchowym. W związku z tym podjęcie nieprawidłowej decyzji o wyłączeniu maszyny będzie powodowało, że nie będzie ona gotowa do załączenia przez wspomniany czas. Przyjęto założenie, że absolutnym minimum dla predykcji będzie horyzont czasowy 6 próbek odpowiadający czasowi 2 minut.

Pierwszy rozpatrzony zakład przemysłowy będzie oznaczony jako A. Rozpatrywany okres podzielono na dwanaście miesięcy a następnie ze współczynnikiem uczenia na poziomie 0,01 wykonano trenowanie. Tabela 2 przedstawia epokę oraz stratę walidacyjną jaką otrzymano. W tabeli wprowadzono również informacje o liczbie sytuacji, gdy nastąpiło obciążenie maszyny, czyli przejście ze stanu 0 na 1. Na początku możemy odrzucić sytuacje, gdy tych obciążeń jest niewiele (mniej niż 200) ponieważ oznacza to, że układ był w stanie znaleźć punkt pracy, i tutaj korzyść z użycia sieci byłaby niewielka. Zdecydowano, że do dalszych badań zostanie wykorzystany miesiąc, który ma największą stratę walidacyjną (miesiąc oznaczony jako 12).

Tabela 2

Ocena adekwatności – w skali roku – obiekt A [źródło własne]

Miesiąc	1	2	3	4	5	6
Epoka	23	40	43	15	19	36
Strata w.	0,45209	0,49473	0,06944	0,08588	0,22036	0,12648
Liczba zmian	11989	11885	15	160	70	55
Miesiąc	7	8	9	10	11	12
Epoka	49	33	31	26	31	46
Strata w.	0,33522	0,15808	0,35308	0,34800	0,37649	<b>0,51275</b>
Liczba zmian	880	880	1775	3405	3145	<b>9877</b>

### 2.4. Współczynnik uczenia

Dla wspomnianego zbioru sprawdzono cztery poziomy tempa uczenia 0,1, 0,01, 0,001, 0,0001 oraz skorzystano również z implementacji algorytmu [8] w języku python [2] doboru poziomu uczenia dla zakresu 0,0001 do 2,0 dla 200 epok (ostatnia kolumna przedstawia wyliczony współczynnik). Wyniki przedstawione w tabeli 3 pokazały, że najlepsze minimum osiąga sieć wyliczona wg algorytmu jednak jest tylko minimalne

lepsza od wartości użytej referencyjnie. Od teraz obliczenia będą odnosić się do najlepszego współczynnika uczenia (ostatnia pozycja tabeli 3).

Tabela 3

Współczynnik uczenia – obiekt A [źródło własne]

Wsp. u.	0,1	0,01	0,001	0,0001	0,01466
Epoka	45	43	49	50	36
Strata w.	0,51979	0,51472	0,54814	0,65826	<b>0,51409</b>

## 2.5. Wpływ wag funkcji straty

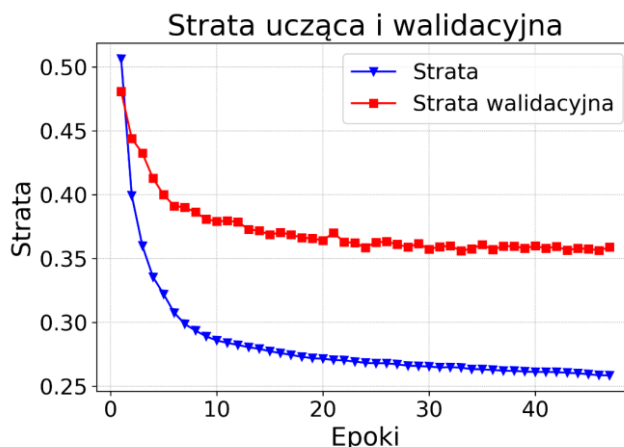
Wagi przyjętej funkcji straty mają umożliwić zbadanie, czy na przewidywanie stanów maszyn bardziej wpływa zmienność przebiegu ciśnienia, czy istnieje silniejsza korelacja wzajemnych stanów pracy maszyn mniej zależna od zapotrzebowania na sprężone powietrze. Poniższa tabela przedstawia obliczenia dla skrajnych przypadków współczynników funkcji straty oraz przeciwnych do obecnych (0,3 dla MSE i 0,7 dla BCE).

Tabela 4

Wagi funkcji straty – obiekt A [źródło własne]

MSE	0,01	0,30	0,70	0,99
BCE	0,99	0,70	0,30	0,01
Epoka	34	29	36	24
Strata w.	<b>0,35468</b>	0,51399	0,51409	0,88690

Zmienność poboru oraz zachowań maszyn jest tak duża, że wpływ sieci zbudowanej na błędzie MSE wydaje się być minimalny a ważniejsze wydają się być poprzedzające stany maszyn. Rysunek 4 przedstawia przebieg procesu uczenia. Na bazie jego wydaje się, że nie ma potrzeby zwiększać liczby epok do uczenia i uczenie odbywa się w okolicach minimum. Tutaj też wypada podkreślić, że widoczna jest zbieżność dzięki odpowiedniemu dopasowaniu architektury sieci.



Rys. 4. Przebieg procesu uczenia najbardziej dopasowanej sieci – obiekt A [źródło własne]



## 2.6. Ewaluacja wyników

Do chwili obecnej rozpatrzono proces uczenia dla sieci, która domyślnie miała najgorsze dopasowanie do zaproponowanej funkcji straty. Tabela 4 przedstawia wyniki poprawności przewidywania próbek.

Tabela 5

Ocena poprawności decyzyjności – obiekt A [źródło własne]

Sprężarka	TN	FP	FN	TP	Dokładność	Precyzja	Czułość
1	98854	2348	9814	1700	<b>0,892101</b>	0,419960	0,147646
2	65512	13834	12035	21335	0,770494	0,606642	0,639347
3	12567	10521	4599	85029	0,865858	<b>0,889890</b>	<b>0,948688</b>

Warto zwrócić uwagę, że sprężarka nr 1 w dużym stopniu okazała się nieprzewidywalna, najmniejsza czułość ze wszystkich wskazuje na trudności z wykrywaniem zdarzeń, również precyzja w jej wypadku informuje, że podejmowane decyzje są obciążone ryzykiem, mimo to, gdy dochodzi do klasyfikacji zdarzeń TP oraz TN otrzymano wysokie wartości poprawności. W przypadku wszystkich sprężarek dokładność jest na wysokim poziomie, jednak precyzja informuje o tym, że dla sprężarki nr 3 mamy wysokie prawdopodobieństwo poprawnych decyzji, w przypadku sprężarki nr 2 błędnych decyzji będzie więcej a najgorzej wypada sprężarka nr 1. Na bazie tych informacji pośrednio uzyskano informację o sposobie regulacji układu, gdzie zachowanie np. maszyny 3 jest dużo bardziej przewidywalne niż maszyn 1.

## 3. Metodyka postępowania

Rozpatrywany przypadek wykazał dużą nieregularność w sieci odbiorczej oraz działaniu maszyn a jego bezpieczeństwo wsparcia decyzji, o wcześniejszym wyłączeniu urządzeń w wyniku braku konieczności obciążenia, było najwyższe w przypadku sprężarki numer 3. W związku z tym zaproponowano rozpatrzenie użycia zaproponowanego algorytmu dla dwóch wybranych losowo obiektów o innej konfiguracji jednak w podobnym okresie. Za punkt wyjścia do dalszych badań przyjęte zostały:

- dane z okresu miesiąca, nie zwracając uwagi na zmienność,
- współczynnik uczenia określony na bazie algorytmu [8] z czasem uczenia 200 epok,
- funkcja straty z wagami 0,3 dla MSE oraz 0,7 dla entropii krzyżowej,
- czas uczenia 50 epok, z mechanizmem wczesnego zatrzymania przez okres 25 epok, z deltą na poziomie 0,01,
- 2 warstwy sieci LSTM o liczbie 100 oraz 50 neuronów.

### 3.1. Ocena – obiekt B

Obiekt B składa się z trzech maszyn o identycznej mocy, z których jedna maszyna jest wyposażona w przetwornicę częstotliwości.

W okresie rozpatrywanego miesiąca pracował w sposób, który charakteryzowała mała zmienność, podczas którego podjęto tylko 100 decyzji (wpływ przetwornicy

częstotliwości) w których mogłaby być potrzeba użycia sieci neuronowych. Najlepszy współczynnik straty walidacyjnej otrzymano na poziomie 0,01050 dla 25 epoki. Współczynnik uczenia wyznaczony został na poziomie 0,017726. Jak pokazuje tabela 5 sieć nauczyła się charakterystyki pracy obiektu, jednak jej użyteczność będzie znikoma, ponieważ sytuacji zmian występowało niewiele więc bezpiecznym założeniem jest, że maszyny pracują w stały sposób.

Tabela 6

Ocena poprawności decyzyjności – obiekt B [źródło własne]

Sprężarka	TN	FP	FN	TP	Dokładność	Precyzja	Czułość
1	141728	220	2005	53873	0,988753	0,995933	0,964118
2	151115	451	437	45823	0,995511	0,990254	0,990553
3	152078	148	153	45447	<b>0,998478</b>	<b>0,996754</b>	<b>0,996645</b>

Wyniki w tabeli 6 pokazują, że uzyskano zarówno wysoką wykrywalność jak i trafność podejmowania decyzji, jednak samych decyzji jest niewiele.

### 3.2. Ocena – obiekt C

Obiekt C składa się trzech maszyn stałobrotowych o identycznej mocy, gdzie jedna maszyna nie pracowała w rozpatrywanym okresie. Podczas pracy podjęto 18990 decyzji, najlepsza epoka, na której zakończono uczenie to 28 a osiągnięto poziom straty walidacyjnej na poziomie 0,24525 przy obliczonym współczynniku uczenia na poziomie 0,02226. Tabela 6 przedstawia zebrane wyniki. Sieć nie miała problemu z przewidzeniem, która maszyna jest zatrzymana, jednak przewidzenie stanu maszyny dobijającej było trudne. Osiągnięto wysokie współczynniki dokładności, jednak wykryto niewielki stopień interesujących zmian dla sprężarki 1 co sugerowałoby dalsze prace nad optymalizacją architektury sieci np. zmiana wag w proponowanej funkcji straty.

Tabela 7

Ocena poprawności decyzyjności – obiekt B [źródło własne]

Sprężarka	TN	FP	FN	TP	Dokładność	Precyzja	Czułość
1	194413	1547	2688	216	0,978704	0,122518	0,074380
2	13845	22352	6300	156367	0,855922	0,874932	0,961271
3	198864	0	0	0	1,000000	1,000000	1,000000

## 4. Podsumowanie

Na podstawie przeprowadzonej analizy nasuwa się wiele wniosków. Przede wszystkim pobór jest zmienny i zależy od charakteru pracy danego układu. W przypadku niewielkiej liczby zmian decyzji w skali miesiąca (poniżej 200) można uzyskać bardziej adekwatne wyniki jednak użyteczność ich w takim wypadku jest niewielka tzn. uzyskane korzyści są niewielkie w stosunku do kosztów związanych z wprowadzeniem inteligentnego sterowania.

Przy zmienności zapotrzebowania w przypadku niektórych maszyn decyzje byłyby obarczone niewielkim ryzykiem pomyłki w przeciwieństwie do innych. Uzyskanie poprawy nawet dla jednej maszyny przekładałoby się na oszczędności energii elektrycznej sprężarkowni.

Charakter pracy w rozpatrywanym układzie różni się w skali roku – oznacza to, że wymagane jest okresowe uczenie sieci oraz wprowadzenie przy wdrożeniu mechanizmu monitoringu trafności podejmowania decyzji.

Niniejsza publikacja proponuje inne kryteria oceny adekwatności przewidywania stanów urządzeń powiązanych silnie z przebiegami czasowymi odbiegających od popularnego RMSE. Dzięki współczynnikom własnej funkcji straty można stosunkowo łatwo znaleźć rozwiązanie lepiej dopasowane dla danego zakładu.

Bardzo duża zmienność poboru i jego „nieprzewidywalność” sugerowałaby wykorzystanie innych, niż sieci neuronowe, algorytmów predykcji przewidujących krótkotrwałe zapotrzebowanie. Również większa liczba danych, która w uczeniu maszynowym prowadzi do lepszych wyników, tutaj potrafi działać przeciwnie co prowadzi do wniosku, by w kolejnych publikacjach rozpatrzeć inne horyzonty czasowe uwzględniając np. zmienność zakładu.

Z proponowaną metodą udało uniknąć się sytuacji przeuczenia sieci, sieci podejmowały decyzje na bieżąco, były w stanie śledzić ciśnienie, jednak uzyskane wyniki w wielu wypadkach obarczone były dużym ryzykiem. Na bazie wyników wyraźnie widać tendencję, że każdy przypadek wymaga indywidualnego rozpatrzenia by dostosować najbardziej niezawodne rozwiązanie.

## LITERATURA

1. Cabello Eras J.J., Sagastume A., Santos V.S., Ulloa M.C.: Energy management of compressed air systems. Assessing the production and use of compressed air in industry. *Energy*, 2020, Vol.213, p.118662.
2. <https://pypi.org/project/torch-lr-finder/>, 2020, v 0.2.1.
3. Jeon S.H., Yoo S., Yoo Y.-S., Lee I.-W.: ML- and LSTM-Based Radiator Predictive Maintenance for Energy Saving in Compressed Air Systems. *Energies*, 2024, Vol.17, p.1428.
4. Kasprzyk K., Gałuszka A.: Energy savings possibilities gained from neural network application in compressed air supervisory control systems. 27th International Conference on Methods and Models in Automation and Robotics (MMAR), 2023, p.279-285.
5. Kasprzyk K., Gałuszka A.: Prediction of Compressed Air Demand Depending on the Type of Production with the Use of Neural Networks. *Advances in Science and Technology Research Journal*, 2023, Vol.17(3), p.154-159.
6. Kasprzyk K.: Predykcja zapotrzebowania na sprężone powietrze w zależności od typu prowadzonej produkcji przy wykorzystaniu sieci neuronowych. Krajowa Konferencja Automatyzacji Procesów Dyskretnych XXII (KKAPD), 2022, s.97-102.
7. Raschka S., Mirjalili V.: *Python Machine learning i deep learning*, 2021, s.533-576.

8. Smith L. N.: Cyclical Learning Rates for Training Neural Networks. IEEE Winter Conference on Applications of Computer Vision (WACV), 2017, p.464-472. -> 10
9. Souza D.F., Silva P.P.F., Sauer I.L., Almeida A.T., Tatizawa H.: Life cycle assessment of electric motors - A systematic literature review. Journal of Cleaner Production, 2024, Vol.456, p.142366.
10. Wu D.C., Asl B.B., Razban A., Chen J.: Air compressor load forecasting using artificial neural network. Expert Systems with Applications, 2021, Vol.168, p.114209.
11. Zahlan J., Asfour S.S.: A multi-objective approach for determining optimal air compressor location in a manufacturing facility. Journal of Manufacturing Systems, 2015, Vol.35, p.176-190.
12. Zhang B., Liu M., Li Y., Wu L.: Optimization of an Industrial Air Compressor System. Energy Engineering: Journal of the Association of Energy Engineers, 2013, Vol.110(6), p.52-64.