

dr hab. inż. Bartłomiej Śnieżyński<sup>1\*)</sup>

ORCID: 0000-0002-4206-9052

mgr Paweł Gajewski<sup>1)</sup>

ORCID: 0000-0003-0931-2476

dr inż. Piotr Stepień<sup>2)</sup>

ORCID: 0000-0001-7340-6704

dr inż. Wojciech K. Roszczyński<sup>3)</sup>

ORCID: 0009-0009-7096-4116

dr inż. Paulina Golonka<sup>3)</sup>

ORCID: 0009-0000-4823-5114

mgr inż. Grzegorz Wolski<sup>3)</sup>

ORCID: 0000-0002-5721-0186

# Wykorzystanie sieci neuronowych do modelowania pracy młyna kulowego w Cementowni WARTA S.A.

*The use of neural networks to model the operation of a ball mill in Cementownia WARTA S.A.*

DOI: 10.15199/33.2023.08.03

**Streszczenie.** Zastosowanie Sztucznych Sieci Neuronowych (SSN) do sterowania procesem przemiału cementu jest w pełni uzasadnione ze względu na złożoność procesu mielenia oraz nieliniowość charakteryzujących go parametrów. Stabilna praca młyna uzyskana przy wsparciu samouczących się SSN może przełożyć się na minimalizację jednostkowego zużycia energii przy utrzymaniu właściwego stopnia rozdrobnienia. Jako dane wejściowe zasilające algorytm SSN wykorzystano wybrane parametry technologiczne monitorowane podczas pracy młyna kulowego pracującego w warunkach przemysłowych. Eksperymenty wykazały, że mały błąd predykcji dają modele uwzględniające małą liczbę parametrów, biorące pod uwagę dane wejściowe z krótszego okna czasowego i 30-minutowym oknem wygładzania danych wejściowych. Najlepsze konfiguracje sieci neuronowej pozwalają na predykcję parametrów pracy młyna ze średnim bezwzględnym błędem procentowym poniżej 5% dla horyzontu czasowego 10 min oraz poniżej 7% dla horyzontu czasowego 15 min.

**Słowa kluczowe:** modelowanie pracy młyna; proces mielenia; Sztuczne Sieci Neuronowe.

**Abstract.** The use of Artificial Neural Networks (ANNs) to control the cement grinding process is fully justified, taking into account the complexity of the grinding process and the non-linearity of its parameters. Stable operation of the mill, obtained with the support of self-learning ANNs, may translate into minimization of unit energy consumption while maintaining the desired degree of fragmentation. As input data powering the ANN algorithm, selected technological parameters monitored during the operation of the ball mill in an industrial setting were used. Experiments have shown that models with a smaller number of parameters, taking into account input data from a shorter time window and a 30-minute input smoothing window, yield a smaller prediction error. The best configurations of the neural network allow for the prediction of the mill operation parameters with an average absolute percentage error of less than 5% for the time horizon of 10 minutes and less than 7% for the time horizon of 15 minutes.

**Keywords:** mill modeling; grinding process; Artificial Neural Networks.

W ostatnich latach zwiększyło się tempo wdrażania cyfryzacji w firmach, co prowadzi do stałego wzrostu liczby danych pochodzących z procesów produkcyjnych. Zarejestrowane dane zawierają dużo informacji, które można wykorzystać do analizy procesów, zwiększenia produktywności i przewidywania jakości produktu finalnego. W celu prawidłowego wykorzystania informacji znajdujących się

w zbiorach danych procesowych, coraz większego znaczenia nabiera podejście analityczne wykorzystujące algorytmy bazujące na Sztucznej Inteligencji i Uczniu Maszynowym (Przemysł 4.0). Pozwalają one na poznanie wzajemnych powiązań i korelacji w obrębie pozyskanych danych oraz umożliwiają wykorzystanie zdobytej wiedzy w celu opracowania bardziej korzystnych metod sterowania procesami technologicznymi.

W przemyśle mineralnych materiałów budowlanych, szczególnie cementowym, istotne znaczenie mają procesy przemiału, charakteryzujące się dużym zapotrzebowaniem na energię elektryczną. Ze względu na energochłonność przemiału cementu, stanowiącą ok. 30%

całkowitego zużycia energii elektrycznej na wyprodukowanie 1 Mg cementu (ok. 32 kWh/Mg cementu [1]), poszukuje się nowych rozwiązań technicznych, prowadzących do zmniejszenia poboru energii elektrycznej w procesie mielenia. Jednym z możliwych podejść jest modernizacja algorytmów sterowania istniejącymi układami mielącymi, pracującymi najczęściej w układzie zamkniętym z wykorzystaniem separatorów powietrznych. W tym celu wykorzystuje się techniki modelowania numerycznego procesów przemysłowych.

Podstawą sterowania dowolnym obiektem dynamicznym jest opracowanie jego odpowiedniego modelu matematycznego. W przypadku złożonych obiektów, jakimi są układy przemiału

<sup>1)</sup> AGH Akademia Górniczo-Hutnicza, Wydział Informatyki, Elektroniki i Telekomunikacji; Instytut Informatyki

<sup>2)</sup> AGH Akademia Górniczo-Hutnicza, Wydział Inżynierii Materiałowej i Ceramiki, Katedra Technologii Materiałów Budowlanych

<sup>3)</sup> Eurocement Consulting Group

\*) Adres do korespondencji: bartlomiej.snieszynski@agh.edu.pl

we, matematyczne odzwierciedlenie wszystkich praw fizycznych rządzących nimi jest wręcz niemożliwe. W tej sytuacji alternatywą pozostaje proces identyfikacji, mający na celu opracowanie wiarygodnego modelu obiektu w drodze badań eksperymentalnych, na podstawie znajomości jego sygnałów wejściowych, wyjściowych i zakłóceń mierzalnych [2]. W literaturze znane są próby identyfikacji i opisu matematycznego zjawisk zachodzących w młynie kulowym [3 ÷ 5], ale zbyt duży stopień złożoności nie pozwala na efektywne ich wykorzystanie w realizacji sterowania [2].

Warunkiem opracowania sterowników bardzo dobrej jakości, będących w stanie prowadzić produkcję w sposób zrównoważony pod kątem technologiczno-ekonomicznym, jest zbudowanie odpowiednio precyzyjnego modelu młyna. Pierwszy opis wykorzystania sterowania predykcyjnego (ang. MPC – *Model Predictive Control*) do sterowania procesami przedstawił w latach siedemdziesiątych XX w. Jacques Richelet. W tamtym czasie możliwości obróbki i wykorzystania dużej liczby danych procesowych były jednak technicznie mocno ograniczone.

Pierwsze praktyczne próby sterowania procesem przemiału cementu polegały na wykorzystaniu regulatorów PID [6] oraz wielowymiarowych regulatorów liniowo-kwadratowych [7]. Inne strategie sterowania kontrolują przepływ wsadu na podstawie Fuzzy Logic [8]. Architektura systemu sterowania (CSA) składa się wówczas ze sterownika rozmytego, programowalnych sterowników logicznych (PLC) oraz serwera systemu sterującego OPC (ang. *Object Linking Embedded for Process Control*). W literaturze opisane są również prace badające łączne wykorzystanie dwóch rodzajów sterowników o dwuwarstwowej budowie hierarchicznej [9]. Na podstawie algorytmów wnioskowania rozmytego i bazującego na regułach (RBR), inteligentna warstwa ustawień optymalnych generuje wartości zadane pętli podstawowej warstwy sterowania, a te ostatnie mogą korygować swoje nastawy za pomocą zdecentralizowanych algorytmów opartych na regulatorach PID.


W pracy Topalova i Kaynaka [10] użyto Sztucznych Sieci Neuronowych (SSN) do sterowania procesem przemiału

łu. Zastosowano uczenie w czasie działania systemu oparte na modelu sterowania ślizgowego (ang. *on-line learning algorithm based on sliding mode control*). Pozwoliło to na radzenie sobie z niedopasowaniami, niepewnościami i zmianami parametrów w modelu młyna. SSN przewidywała tempo produkcji oraz wypełnienie młyna. Kontroler sterował nadawą oraz prędkością obrotów separatora. Celem było utrzymanie poziomu produkcji i wypełnienia młyna na zadanym poziomie oraz zabezpieczenie przed nadmiernym wypełnieniem młyna materiałem.

Podobne prace realizowane były w Polsce [11]. Sieć neuronowa została użyta do predykcji powierzchni właściwej oraz wypełnienia młyna. Regulator neuronowy sterował nadawą wejściową oraz obrotami separatora. W eksperymentach badano zgodność sterowania z trendami realizowanymi przez operatorów. **W badaniach skoncentrowano się na analizie modelu rzeczywistego układu mielącego cementy, pracującego w Cementowni WARTA S.A.** Brano pod uwagę różne zestawy sygnałów wejściowych i wyjściowych, sprawdzono wpływ szerokości okna czasowego oraz wygładzania sygnałów wejściowych. Zmierzone dokładność predykcji w przypadku horyzontów różnej długości. Ze względu na rozwój sprzętu i możliwość prowadzenia obliczeń z użyciem kart graficznych w opisywanych badaniach można było użyć bardziej złożonych modeli niż w cytowanych pracach i przeprowadzić systematyczne przeszukiwanie przestrzeni metaparametrów przy użyciu środowiska optymalizującego.

## Metoda modelowania procesu przemiału

Na rysunku 1 przedstawiono schemat procesu przemiału cementu w młynie kulowym w cyklu zamkniętym. Separator odpowiedzialny jest za klasyfikację ziaren na produkt końcowy oraz nadziarno wracające do młyna. Z punktu widzenia modelowania procesu najważniejszymi parametrami są sygnały sterowania, takie jak obroty separatora, ilość świeżej nadawy, obroty wentylatora obiegowego i obroty wentylatora aspiracji oraz sygnały zwrotne:



Rys. 1. Schemat procesu przemiału cementu w młynie kulowym w cyklu zamkniętym  
Fig. 1. Diagram of the cement grinding process in a ball mill in a closed cycle

powierzchnia właściwa cementu; zwrot z młyna (ilość nadziarna); wypełnienie pierwszej i drugiej komory młyna; zawartość ziaren poniżej 5  $\mu\text{m}$  oraz powyżej 100  $\mu\text{m}$  w gotowym produkcie.

Sztuczne sieci neuronowe są obecnie standardowym narzędziem służącym do rozwiązywania wielu problemów uczenia maszynowego, takich jak klasyfikacja, regresja, rozpoznawanie obrazów i przetwarzanie sygnałów. Budowa i zasada działania tych sieci są inspirowane ich biologicznymi odpowiednikami. Podstawowym elementem budowy SSN jest sztuczny neuron. Na wejściu otrzymuje sygnał w postaci wektora liczb rzeczywistych  $X = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ , a na wyjściu zwraca sygnał  $\hat{y} \in \mathbb{R}$ , będący liczbą rzeczywistą. W celu poprawy jakości działania sieci neuronowej, wartości wejść i wyjść skaluje się w taki sposób, aby sprowadzić średnią do wartości 0, a wariancję do wartości 1 (standardyzacja).

Z każdym elementem wektora wejściowego  $x_i$  powiązana jest waga tego elementu  $w_i \in \mathbb{R}$ . Wyjście obliczane jest ze wzoru:


$$\hat{y} = \varphi(e) \quad (1)$$

gdzie:

$\varphi: \mathbb{R} \rightarrow \mathbb{R}$  jest funkcją aktywacji (np. tanh), nieliniowo przekształcającą wzbudzenie neuronu  $e$ , obliczane na podstawie wejść i wag:

$$e = \sum_{i=1}^n x_i w_i + w_0 \quad (2)$$

Dodatkowa waga  $w_0 \in \mathbb{R}$  pozwala na modyfikację wzbudzenia o ustaloną wartość, niezależną od wejścia. W związku z tym, że pojedynczy neuron ma niewielkie możliwości, w praktyce używa się wielu neuronów, układanych w warstwy, które tworzą sieć. W przypadku perceptronu wielowarstwowego wyjście każdego neuronu warstwy poprzedniej jest wejściem każdego neuronu warstwy następnej (rysunek 2). Uży-




**Rys. 2. Sztuczna sieć neuronowa o dwóch warstwach ukrytych, n sygnałach wejściowych i m sygnałach wyjściowych**

Fig. 2. Artificial Neural Network with two hidden layers, n input signals and m output signals

wając sieci, można dla zadanego wejścia  $X \in \mathbb{R}^n$  policzyć sygnały wyjściowe  $\hat{Y} = (\hat{y}_1, \hat{y}_2, \dots, \hat{y}_m) \in \mathbb{R}^m$ .

Kluczowym zagadnieniem jest uczenie SSN, pozwalające na wyznaczenie wag połączeń, aby w przypadku danego wejścia wartość wyjścia była prawidłowa. Do tego potrzebne są dane uczące  $D = \{X, Y\} \in \mathbb{R}^n \times \mathbb{R}^m$  będące parami sygnałów wejściowych i oczekiwanych sygnałów wyjściowych. Algorytm uczenia pobiera fragmenty danych uczących, tzw. paczki (ang. *batch*) o ustalonym rozmiarze (ang. *batch size*) i modyfikuje wagi połączeń, aby zminimalizować różnicę pomiędzy  $\hat{Y}$  oraz  $Y$  w przypadku danych z paczki. Typową metodą uczenia jest algorytm wstecznej propagacji błędów (ang. *Backpropagation of Errors*) [12].

Opracowano wiele modyfikacji budowy neuronów i wiele typów architektur SSN. Do modelowania systemów używa się m.in. sieci rekurencyjnych, LSTM i splotowych. Dzięki uwzględnieniu upływu czasu, pozwalają one na predykcję zmieniających się parametrów. Do takich celów można również użyć perceptronu wielowarstwowego z oknem czasowym (rysunek 3). W tym rozwiązaniu wejściem sieci jest lista sygnałów wejściowych  $X_{t-1}, X_{t-2}, \dots, X_{t-w}$ , z okna czasowego o szerokości  $w \in \mathbb{N}$  poprzedzającego chwilę  $t$ . Zadaniem sieci jest predykcja wartości  $x_t$ . Przy użyciu tego podejścia można dokonywać predykcji wiele kroków do przodu. W tym celu obliczone wyjście sieci  $\hat{Y}_t$  należy podać na wejście jako wartość z ostatniej chwili czasowej, a pozostałe wartości trzeba przesunąć o jeden krok.



**Rys. 3. Perceptron wielowarstwow z oknem czasowym**

Fig. 3. Multilayer perceptron with time window

Dzięki temu można obliczyć wartość  $\hat{Y}_{t+1}$ , a powtarzając te czynności, wartości kolejne. Architektury tej można użyć do modelowania młyna. W przypadku złożonych urządzeń, jakimi są młyny, należy jednak dodatkowo uwzględnić wartości nastaw, którymi sterują operatorzy lub systemy kontroli. W tym celu, oprócz omawianych do tej pory sygnałów zwrotnych, reprezentujących wybrane, mierzone parametry opisujące stan urządzenia, które są tożsame z wyjściem sieci, należy brać pod uwagę sygnały zewnętrzne, które reprezentują sygnały sterowania. Rozróżnienie to jest kluczowe podczas predykcji. Wówczas sygnały (parametry) sterowania reprezentujące nastawy są dostarczane do modelu, natomiast sygnały (parametry) zwrotne są podawane z wyjścia na wejście w kolejnym kroku i stanowią sprzężenie zwrotne. Jest to tzw. architektura NARX (ang. *Nonlinear Autoregressive Network with Exogenous Inputs*) [13], zastosowana również w omawianych pracach [10, 11] i prezentowanych badaniach.

W związku z tym, że pomiary parametrów obciążone są błędami, można je wygładzić, aby zniwelować nagłe skoki, będące rezultatem błędnych pomiarów. W eksperymentach zastosowano filtr Savitzky'ego-Golaya [14], który jest bardzo czuły i elastyczny [15]. Chcąc sprawdzić dokładność modelu, można porównać przewidziane wartości parametrów z wartościami rzeczywistymi (zmierzonymi). Należy więc zdefiniować odpowiednią metrykę. W eksperymentach opisanych w kolejnej sekcji, używana będzie metryka średniokwadratowa – MSE (ang. *Mean Square Error*):

$$MSE = 1/T \sum_{t=1}^T (\hat{Y}_t - Y_t)^2 \quad (3)$$

oraz średni bezwzględny błąd procentowy MAPE (ang. *Mean Absolute Percentage Error*):

$$MAPE = 1/T \sum_{t=1}^T |\hat{Y}_t - Y_t / Y_t| \cdot 100\% \quad (4)$$

Metryka ta obliczana jest w przypadku zbioru danych testowych  $\{(X_t, Y_t)\}_{t=1, \dots, T}$ , które nie były używane do uczenia sieci. Dokładność takiego modelu zależy od wielu czynników. Są to: zbiory parametrów sterowania i zwrotnych; szerokość okna czasowego; sposób wygładzania wartości parametrów; konfiguracja sieci (liczba warstw i neuronów w poszczególnych warstwach); rodzaje funkcji aktywacji i parametry algorytmu uczenia. Ich wartości nazywane są metaparametrami.

## Wyniki eksperymentów

W eksperymentach przetestowano wpływ zbiorów parametrów wejściowych, szerokość okna czasowego i szerokości okna wygładzania wartości parametrów na dokładność modelu. W tym celu zgromadzono dane pomiarowe pochodzące z młyna cementu pracującego w warunkach przemysłowych. Do badań wykorzystano młyn kulowy, dwukomorowy pracujący w układzie zamkniętym, wyposażony w separator dynamiczny. Dane rejestrowane były co minutę i obejmują 26785 punktów pomiarowych. Chcąc uniezależnić wyniki od wyboru danych testowych, użyto dziesięciokrotnej walidacji krzyżowej. Obliczenia realizowane były z użyciem biblioteki PyTorch [16], na karcie graficznej Nvidia GeForce RTX 2080 Ti, posiadającej 4352 rdzenie obliczeniowe.

**Eksperyment 1. Wpływ parametrów uwzględnionych w modelach.** W pierwszym eksperymencie zdefiniowano 3 zestawy sygnałów sterowania i zwrotnych przedstawiających parametry pracy młyna (tabela 1). W eksperymencie przetestowano szerokość okna czasowego  $w = 30$  min i brak wygładzania.

W przypadku zestawu 2, przy użyciu pakietu Optuna [17], przeprowadzono przeszukiwanie przestrzeni wartości meta-parametrów reprezentujących liczbę warstw ukrytych (od 1 do 5), liczbę neuronów w warstwach ukrytych

Tabela 1. Zestaw parametrów uwzględnionych w modelach

Table 1. Set of parameters used in the models

Sygnały sterowania			
Parametr	Zestaw 1	Zestaw 2	Zestaw 3
Obroty separatora	x	x	x
Świeża nadawa	x	x	x
Obroty wentylatora obiegowego		x	x
Obroty wentylatora aspiracji		x	x
Sygnały zwrotne			
Parametr	Zestaw 1	Zestaw 2	Zestaw 3
Powierzchnia właściwa	x	x	x
Zwrot z młyna	x	x	x
Wypełnienie pierwszej komory	x	x	x
Wypełnienie drugiej komory	x	x	x
Procent ziaren powyżej 100 $\mu\text{m}$			x
Procent ziaren poniżej 5 $\mu\text{m}$			x

(256, 512 i 1024), rodzaje funkcji aktywacji (*sigmoid, tanh, gelu, relu*) oraz parametry algorytmu uczenia: rozmiar paczki danych (64, 256, 512 i 2048) i współczynnik uczenia (ang. *learning rate*, 0.0001, 0.001, 0.01). Najlepsze znalezione wartości przedstawiono w tabeli 2. Ze względu na dużą czasochłonność procesu przeszukiwania (obliczenia trwały trzy dni), te same wartości metaparametrów zostały użyte podczas uczenia pozostałych modeli.

Wartość metryki średniokwadratowej (3), obliczanej w walidacji krzyżowej w przypadku wyjść po standaryzacji wyniosła dla: Zestawu 1 – 0,023; Zestawu 2 – 0,033, a Zestawu 3 – 0,034. W tabeli 3 przedstawiono średni bezwzględny błąd procentowy (4) w przypadku zdefiniowanych zestawów parametrów. Prognozowanie

Tabela 2. Najlepsze znalezione wartości metaparametrów

Table 2. Best metaparameter values found

Nazwa	Wartość
Liczba warstw ukrytych	3
Rozmiar warstw ukrytych	512
Funkcja aktywacji	sigmoid
Współczynnik uczenia	0,001
Wielkość paczki	256

Tabela 3. Wartości średniego bezwzględnego błędu procentowego w przypadku wybranych zestawów parametrów po 1, 5, 10 i 15 min

Table 3. Values of mean absolute percentage error for chosen parameter sets after 1, 5, 10 and 15 minutes

Parametr	Zestaw 1				Zestaw 2				Zestaw 3			
	horyzont [min]				horyzont [min]				horyzont [min]			
	1	5	10	15	1	5	10	15	1	5	10	15
Powierzchnia właściwa	2,49 ± 0,34	2,73 ± 0,68	3,50 ± 2,00	4,32 ± 3,26	2,50 ± 0,33	2,95 ± 0,57	3,72 ± 1,27	4,20 ± 1,83	2,51 ± 0,34	3,22 ± 0,92	4,49 ± 1,92	5,28 ± 2,25
Zwrot z młyna	11,18 ± 3,13	11,02 ± 3,13	11,93 ± 2,89	13,69 ± 2,67	11,29 ± 2,86	11,69 ± 2,98	14,37 ± 5,60	18,44 ± 9,84	11,22 ± 3,14	12,26 ± 5,73	13,76 ± 7,47	16,03 ± 9,21
Wypełnienie pierwszej komory	3,91 ± 1,07	4,20 ± 1,20	5,06 ± 1,67	5,83 ± 1,92	3,90 ± 1,07	4,46 ± 1,32	5,72 ± 2,65	6,78 ± 3,87	4,02 ± 1,31	5,29 ± 4,06	6,28 ± 5,41	6,62 ± 5,27
Wypełnienie drugiej komory	2,35 ± 0,28	2,52 ± 0,44	3,00 ± 0,81	3,69 ± 1,14	2,39 ± 0,30	2,82 ± 0,57	3,85 ± 1,32	5,08 ± 2,28	2,37 ± 0,28	2,70 ± 0,39	3,52 ± 0,95	4,22 ± 1,15
Wszystkie sygnały wyjściowe	4,98 ± 1,20	5,12 ± 1,36	5,87 ± 1,84	6,88 ± 2,25	5,02 ± 1,14	5,48 ± 1,36	6,91 ± 2,71	8,63 ± 4,46	5,03 ± 1,27	5,87 ± 2,78	7,01 ± 3,94	8,04 ± 4,47

dotyczyło czterech horyzontów czasowych: 1, 5, 10 i 15 min. Wartości sygnałów sterowania w kolejnych krokach predykcji były rzeczywiste tzn. pochodziły z danych testowych.

Na rysunku 4 przedstawiono rzeczywiste wartości wybranych parametrów oraz wyniki predykcji w przypadku wszystkich zestawów. Chwila  $t = 1$  na osi OX to 30 min danych testowych.

**Eksperyment 2. Wpływ szerokości okna czasowego.** W drugim eksperymencie zbadano wpływ szerokości okna czasowego na dokładność przewidywania modelu. Uwzględniono czas: 15; 30 i 45 min. W sieci użyto parametrów z Zestawu 2. Sygnały nie były wygładzane. Wartość MSE w przypadku Okna 15 wyniosła 0,030, Okna 30 – 0,033, a Okna 45 – 0,029. Wyniki MAPE przedstawiono w tabeli 4.

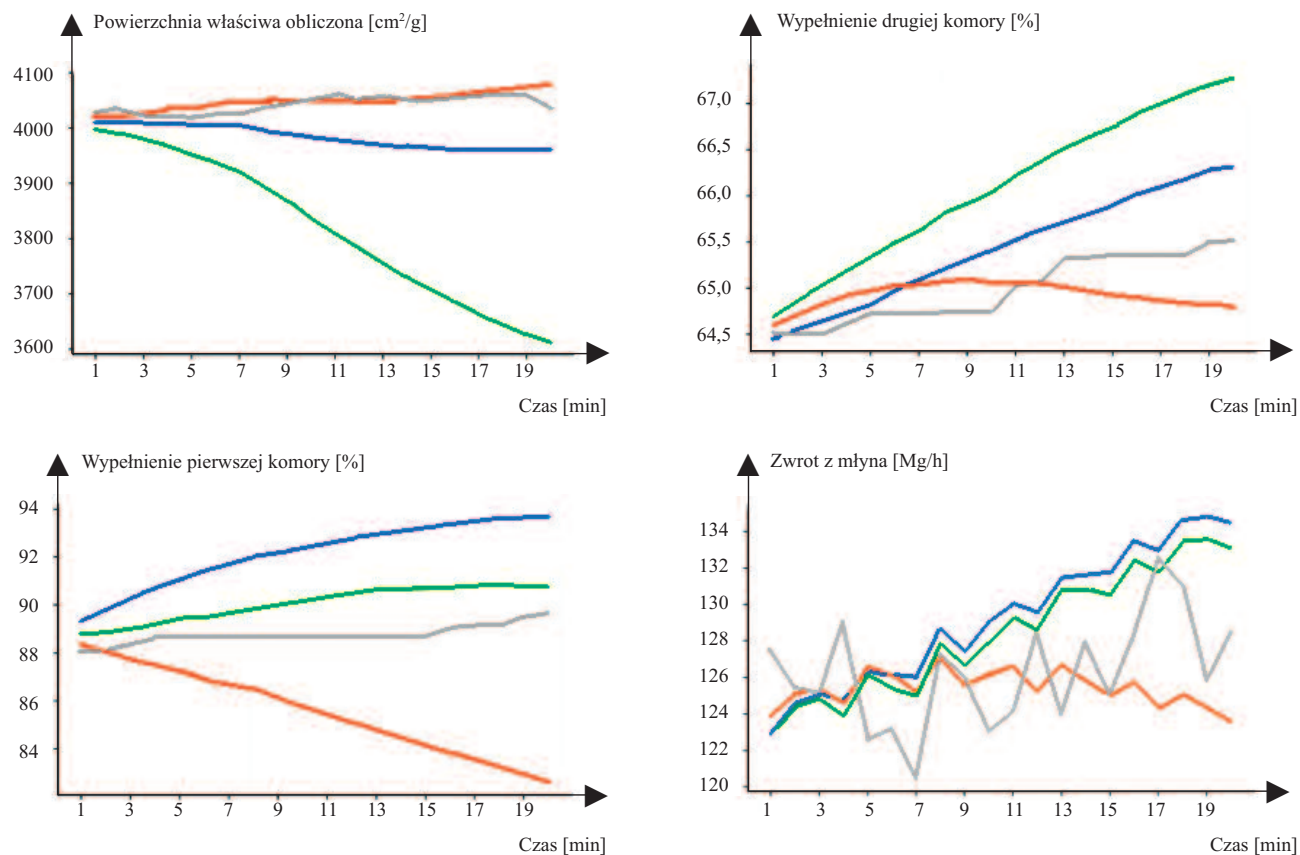
**Eksperyment 3. Wpływ sposobu wygładzania danych.** W tabeli 5 przedstawiono dokładność modeli bez wygładzania oraz z wygładzaniem przy użyciu filtra Savitzky'ego-Golaya dla stopnia wielomianu 3 oraz szerokości okna wygładzania 10; 20 i 30. Wartość metryki średniokwadratowej bez wygładzania wynosi 0,033, w przypadku Okna 10 jest to 0,010, a Okien 20 i 30 – 0,008.

### Omówienie wyników

W **Eksperymencie 1.** najlepsze wyniki predykcji otrzymano w przypadku Zestawu 1. Błąd średniokwadratowy

jest znacznie mniejszy niż pozostałych zestawów. Podobnie średni bezwzględny błąd procentowy wszystkich sygnałów jest najmniejszy dla wszystkich horyzontów i wynosi od ok. 5% do niecałych 7%. W przypadku zestawu drugiego błędy w przypadku horyzontów 1 i 5 min są podobne, 10 min o 1%, a 15 min o prawie 2% większe. W przypadku Zestawu 3 średnie błędy wszystkich sygnałów są podobne jak w Zestawie 2. Warto zwrócić uwagę na parametr przedstawiający powierzchnię właściwą, który używając Zestawu 2 udaje się przewidzieć w horyzoncie 15 min z błędem mniejszym niż Zestawu 1. Prawdopodobnie wynika to z uwzględnienia na wejściu obrotów wentylatorów obiegowego i aspiracji, które mają wpływ na ten parametr. Różnica jest jednak bardzo niewielka (0,12%), szczególnie że uwzględnienie dodatkowych parametrów pogarsza predykcję pozostałych parametrów. Im się przetwarza mniej sygnałów, tym mniejszy jest średni błąd.

**Wyniki Eksperymentu 2.** wskazują, że najmniejsze wartości błędu średniokwadratowego w przypadku wszystkich sygnałów dotyczą Okna 45, ale Okna 15 są jedynie o 0,001 gorsze (3%). Biorąc więc pod uwagę, że dla Okna 15 średni bezwzględny błąd procentowy wszystkich sygnałów jest najmniejszy we wszystkich horyzontach, taka szerokość okna jest najkorzystniejsza. Zwiększe-



— wartość rzeczywista; — zestaw param. 1; — zestaw param. 2; — zestaw param. 3

**Rys. 4. Rzeczywiste wartości wybranych parametrów oraz wyniki predykcji z użyciem sieci neuronowych przetwarzających wybrane zestawy sygnałów; chwila  $t = 1$  na osi OX to 30 minuta danych testowych**

*Fig. 4. Real values of selected parameters and results of prediction with neural network processing selected sets of signals; time  $t = 1$  on the OX axis is 30 minute of test data*

**Tabela 4. Wartości średniego bezwzględnego błędu procentowego w przypadku wybranych szerokości okna czasowego po 1, 5, 10 i 15 min**

*Table 4. Values of mean absolute percentage error for chosen time window widths after 1, 5, 10 and 15 minutes*

Parametr	Okno 15 horyzont [min]				Okno 30 horyzont [min]				Okno 45 horyzont [min]			
	1	5	10	15	1	5	10	15	1	5	10	15
Powierzchnia właściwa	2,49 ± 0,34	2,73 ± 0,68	3,50 ± 2,00	4,32 ± 3,26	2,50 ± 0,33	2,95 ± 0,57	3,72 ± 1,27	4,20 ± 1,83	2,51 ± 0,34	3,22 ± 0,92	4,49 ± 1,92	5,28 ± 2,25
Zwrot z młyna	11,18 ± 3,13	11,02 ± 3,13	11,93 ± 2,89	13,69 ± 2,67	11,29 ± 2,86	11,69 ± 2,98	14,37 ± 5,60	18,44 ± 9,84	11,22 ± 3,14	12,26 ± 5,73	13,76 ± 7,47	16,03 ± 9,21
Wypełnienie pierwszej komory	3,91 ± 1,07	4,20 ± 1,20	5,06 ± 1,67	5,83 ± 1,92	3,90 ± 1,07	4,46 ± 1,32	5,72 ± 2,65	6,78 ± 3,87	4,02 ± 1,31	5,29 ± 4,06	6,28 ± 5,41	6,62 ± 5,27
Wypełnienie drugiej komory	2,35 ± 0,28	2,52 ± 0,44	3,00 ± 0,81	3,69 ± 1,14	2,39 ± 0,30	2,82 ± 0,57	3,85 ± 1,32	5,08 ± 2,28	2,37 ± 0,28	2,70 ± 0,39	3,52 ± 0,95	4,22 ± 1,15
Wszystkie sygnały wyjściowe	4,98 ± 1,20	5,12 ± 1,36	5,87 ± 1,84	6,88 ± 2,25	5,02 ± 1,14	5,48 ± 1,36	6,91 ± 2,71	8,63 ± 4,46	5,03 ± 1,27	5,87 ± 2,78	7,01 ± 3,94	8,04 ± 4,47

nie okna czasowego nieznacznie pogarsza wyniki predykcji mierzone przez MAPE, ponieważ sieć musi przetwarzać znacznie więcej sygnałów i trudniej jest jej wychwycić istotne zależności.

**W Eksperymentcie 3.** najmniejszy błąd średniokwadratowy, w przypadku wszystkich sygnałów, dotyczy Okna wygładzania 20 i 30, a Okna 10 jest o 20% większy. Biorąc pod uwagę, że

średni bezwzględny błąd procentowy wszystkich sygnałów jest mniejszy w przypadku Okna 20 w krótszym horyzontie (1 i 5 min), a Okna 30 w dłuższym (10 i 15), to Okno 30 wypada lepiej. Średnia z tych błędów Okna 20 wynosi 6,48, a Okna 30 – 6,18, co również wskazuje na przewagę wygładzania z dłuższym oknem. Chcąc zobrazować, jak wyglądają sygnały po wygładzaniu, na rysunku 5 przedstawiono rzeczywiste wartości wybranych parametrów oraz wyniki predykcji w przypadku różnej szerokości okna wygładzania sygnałów. Chwila  $t = 1$  na osi OX to 30. minuta danych testowych.


**Wnioski**

Przeprowadzone prace badawcze wykazały, że modelowanie pracy młyna kulowego do produkcji cementu przy użyciu sieci neuronowych jest możliwe. Najlepsze konfiguracje sieci neuronowej pozwalają na predykcję

Tabela 5. Wartości średniego bezwzględnego błędu procentowego w przypadku wybranej szerokości okna wygładzania i bez wygładzania po 1, 5, 10 i po 15 min

Table 5. Values of mean absolute percentage error for chosen smoothing window sizes and without smoothing after 1, 5, 10 and 15 minutes

Parametr	Brak wygładzania				Okno wygładzania 10				Okno wygładzania 20				Okno wygładzania 30			
	horyzont [min]				horyzont [min]				horyzont [min]				horyzont [min]			
	1	5	10	15	1	5	10	15	1	5	10	15	1	5	10	15
Powierzchnia właściwa	2,50 ± 0,33	2,95 ± 0,57	3,72 ± 1,27	4,20 ± 1,83	2,49 ± 0,34	2,70 ± 0,47	3,50 ± 0,95	4,35 ± 1,32	2,44 ± 0,34	2,54 ± 0,39	3,34 ± 0,87	4,38 ± 1,38	2,39 ± 0,32	2,49 ± 0,35	3,28 ± 0,83	4,64 ± 1,63
Zwrot z młyna	11,29 ± 2,86	11,69 ± 2,98	14,37 ± 5,60	18,44 ± 9,84	9,94 ± 2,24	10,24 ± 2,06	12,38 ± 3,05	15,69 ± 4,91	9,61 ± 1,98	10,12 ± 2,46	13,96 ± 6,00	20,53 ± 13,66	11,42 ± 7,79	11,40 ± 8,34	13,58 ± 8,16	17,51 ± 5,91
Wypełnienie pierwszej komory	3,90 ± 1,07	4,46 ± 1,32	5,72 ± 2,65	6,78 ± 3,87	3,89 ± 1,07	4,52 ± 1,24	5,79 ± 2,10	6,57 ± 2,35	3,81 ± 1,08	4,29 ± 1,24	6,67 ± 2,93	9,26 ± 5,02	3,70 ± 1,03	3,81 ± 1,02	5,08 ± 1,21	6,99 ± 1,96
Wypełnienie drugiej komory	2,39 ± 0,30	2,82 ± 0,57	3,85 ± 1,32	5,08 ± 2,28	2,33 ± 0,27	2,58 ± 0,22	3,39 ± 0,56	4,39 ± 1,06	2,33 ± 0,29	2,52 ± 0,34	3,30 ± 0,69	4,53 ± 1,47	2,30 ± 0,27	2,45 ± 0,33	3,19 ± 0,83	4,67 ± 1,55
Wszystkie sygnały wyjściowe	5,02 ± 1,14	5,48 ± 1,36	6,91 ± 2,71	8,63 ± 4,46	4,66 ± 0,98	5,01 ± 1,00	6,26 ± 1,66	7,75 ± 2,41	4,55 ± 0,92	4,87 ± 1,11	6,82 ± 2,62	9,68 ± 5,38	4,95 ± 2,35	5,04 ± 2,51	6,28 ± 2,76	8,45 ± 2,76



— wartości rzeczywiste; — szerokość wygładzania 10; — szerokość wygładzania 25; — szerokość wygładzania 50

Rys. 5. Rzeczywiste wartości zwrotu z młyna oraz wyniki predykcji z użyciem sieci neuronowych dla różnych szerokości okna wygładzania sygnałów; chwila  $t = 1$  na osi OX to 30 minuta danych testowych

Fig. 5. Real values of the return from the mill and results of prediction with neural network for selected smoothing window values; time  $t = 1$  on the OX axis is 30 minute of test data

parametrów pracy młyna ze średnim bezwzględnym błędem procentowym mniejszym od 5% w przypadku horyzontu czasowego 10 min oraz mniejszym od 7% dla horyzontu czasowego 15 min. Biorąc pod uwagę, że modelowany system mielący cechuje się dużym stopniem nieliniowości i niepewności, jest to wynik zadowalający. Planowane jest również sprawdzenie skuteczności modeli bazujących na bardziej zaawansowanych architekturach sieci, takich jak LSTM i sieci spłotowe. Opracowany model zostanie użyty m.in. w sterowniku typu MPC.

Celem długofalowym prac, dzięki modelowi pracy młyna bazującemu na uczeniu maszynowym, jest uzyskanie stabilnych procesów produkcji ce-

mentu, ograniczenie zużycia energii, poprawa wydajności i utrzymanie bardzo dobrej jakości produktu finalnego.

#### Literatura

[1] Sitkowska J, Duda J, Duczkowska-Kądział A, Wasilewski M. Optymalizacja Procesu Przemiału Cementu na Przykładzie CEMENTOWNI ODRA S.A. 2015.

[2] Bursy G. Sterowanie neuronowe procesem przemiału cementu, Część 1 – Identyfikacja układu przemiałowego na przykładzie młyna pracującego w układzie zamkniętym z separatorem powietrznym, Prace Instytutu Szkła, Ceramiki, Materiałów Ogniotrwałych i Budowlanych. 2009; Tom R. 2, nr 3.

[3] Auer A. Model i identyfikacja procesów klasyfikacji i mielenia. „Zeszyty Naukowe Wyższej Szkoły Inżynierskiej w Opolu”, nr 26 „Elektryka”. 1978; 4.

[4] Rojek R. Model matematyczny procesu mielenia ciągłego w młynach bębnowych dla celów sterowania, Instytut Cybernetyki Technicznej Politechniki Wrocławskiej, praca doktorska. Wrocław. 1976.

[5] Wrzuszczak J. Badania identyfikacyjne i ocena efektywności algorytmów sterowania adaptacyjnego obiektem z opóźnieniem na przykładzie młyna kulowego cementu, praca doktorska, Politechnika Wroclawska, Wrocław. 1998.

[6] Tsamatoulis DC. Optimising the control system of cement milling: Process modeling and controller tuning based on loop shaping procedures and process simulations. Braz. J. Chem. Eng. 2014; 31: 155 – 170.

[7] Van Breusegem V, Chen L, Werbrout V, Bastin G, Wertz V. Multivariable linear quadratic control of a cement mill: An industrial application. Control Eng. Pract. 1994; 2: 605 – 611.

[8] Costea CR, Silaghi HM, Zmaranda D, Silaghi MA. Control system architecture for a cement mill based on fuzzy logic. Int. J. Comput. Commun. Control. 2015; 10: 165 – 173.

[9] Zhao D, Chai T. Intelligent optimal control system for ball mill grinding process. J. Control Theory Appl. 2013; 11: 454 – 462.

[10] Topalov AV, Kaynak O. Neural network modeling and control of cement mills using a variable structure systems theory based on-line learning mechanism. J. Process Control. 2004; 14: 581 – 589.

[11] Rojek R, Bursy G. Pewne aspekty wykorzystania sztucznych sieci neuronowych dla identyfikacji i sterowania procesem przemiału cementu, Pomiary Automatyka Kontrola. 2011; R. 57, nr 2.

[12] Goodfellow I, Bengio Y, Courville A. 6.5 Back-Propagation and Other Differentiation Algorithms. Deep Learning. MIT Press. 2016; pp. 200 – 220.

[13] Lin T, Horne BG, Tino P & Giles CL Learning long-term dependencies in NARX recurrent neural networks. IEEE Transactions on Neural Networks. 1996; 7 (6): 1329 – 1338.

[14] Niedźwiecki M, Ciołek M. Generalized Savitzky-Golay filters for identification of nonstationary systems. Automatica. 2019; vol. 108, paper no. 108477.

[15] Le Thi, Nhung & Männel, Benjamin & Nartas, Randa & Sakic, Pierre & Deng, Zhiguo & Schuh, Harald. Apply noise filters for better forecast performance in Machine Learning. 2022; 10.5194/egusphere-egu22-4039.

[16] Paszke A, Gross S, Massa F, Lerer A, Bradbury J, Chanan G,... & Chintala S, PyTorch. An imperative style, high-performance deep learning library. Advances in neural information processing systems. 2019; 32.

[17] Akiba T, et al. Optuna: A next-generation hyperparameter optimization framework. Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining. 2019.

Badania współfinansowane przez Narodowe Centrum Badań i Rozwoju w ramach projektu „Opracowanie autorskiej technologii wytwarzania cementu w celu uzyskania produktu o ulepszonych parametrach jakościowych” w ramach działania 1.1 „Projekty B+R przedsiębiorstw” poddziałanie 1.1.1 „Badania przemysłowe i prace rozwojowe realizowane przez przedsiębiorstwa” Programu Operacyjnego Inteligentny Rozwój na lata 2014-2020, współfinansowanego z Europejskiego Funduszu Rozwoju Regionalnego, numer umowy POIR. 01.01.01-00-0263/19/00.

Przyjęto do druku: 20.07.2023 r.