

Prognozowanie parametrów jakości koksu określanych testem Nippon Steel Corporation z wykorzystaniem wybranych metod statystycznych i metod uczenia maszynowego

Data wpłynięcia do Redakcji: 04/2024
Data akceptacji przez Redakcję do publikacji: 05/2024

2024, volume 13, issue 2, pp. 89-99

Jan Marcisz
Jastrzębska Spółka Węglowa S.A. Poland

Piotr Michorczyk
Politechnika Krakowska, Poland

Aleksandra Burczyk
Jastrzębska Spółka Węglowa S.A. Poland



Streszczenie: Kluczowym procesem pozwalającym zapewnić stabilność parametrów jakościowych produkowanego węgla i koksu jest proces rozpoznania złoża, pozwalający na osiągnięcie zamierzonego poziomu jakości poprzez odpowiednie harmonogramowanie ścian w aspekcie jakościowym. Jastrzębska Spółka Węglowa by sprostać wymaganiom rynku ciągle udoskonala swoje procesy w tym te związane z rozpoznaniem złoża i planowaniem produkcji. Wskaźniki reaktywności i wytrzymałości poreakcyjnej koksu są parametrami krytycznymi dla wydajnej pracy wielkiego pieca, niestety nie zawsze możliwe jest ich oznaczenie dla próbek geologicznych. W artykule omówiono możliwość zastosowania metod uczenia maszynowego w procesie prognozowania parametrów jakości koksu określanych testem Nippon Steel Corporation (NSC). W celu analizy danych i budowy modeli predykcyjnych wykorzystano oprogramowanie RapidMiner, które umożliwiło skuteczną eksplorację danych, budowę modeli oraz analizę wyników. Analiza historycznych danych geologicznych z pomocą popularnych technik uczenia maszynowego pokazała, że prace nad zastosowaniem sztucznej inteligencji w prognozowaniu jakości złoża są perspektywiczne i należy dążyć do identyfikacji najbardziej efektywnych podejść do tego zagadnienia.

Słowa kluczowe: węgiel, koks, jakość, uczenie maszynowe, sztuczna inteligencja

WSTĘP

Doskonalenie procesów produkcyjnych staje się kluczowym wyzwaniem wszystkich producentów węgla koksowego, przed którymi rynek stawia coraz to wyższe wymagania jakościowe. Jastrzębska Spółka Węglowa S.A. konsekwentnie udoskonala swoje procesy produkcyjne w zakresie sterowania i monitorowania, celem zapewnienia jak najlepszych i stabilnych parametrów jakościowych swoich produktów, zgodnie z założeniami przemysłu 4.0. Takie działania ułatwiają funkcjonowanie na trudnym i nieprzewidywalnym rynku w szczególności w czasie dynamicznych zmian warunków rynkowych. Kluczowym działaniem pozwalającym zapewnić stabilność parametrów jakościowych produkowanego węgla jest proces rozpoznania złoża pozwalający z pomocą odpowiedniego harmonogramowania ścian na osiągnięcie zamierzonego poziomu jakości. Określane w procesie rozpoznania złoża parametry pozwalają ocenić przydatność

technologiczną węgla w poszczególnych pokładach oraz tak zaplanować proces wydobywania by sprostać zarówno wymaganiom rynku węgla koksowego, jak również racjonalnie gospodarować zasobami. Wszystkie oznaczane w procesie rozpoznania parametry są w jakimś stopniu miarą jakości węgla, chociaż tylko część z nich jest parametrami cenotwórczymi. W tym kontekście oznaczenie parametrów jakości koksu określanych testem Nippon Steel Corporation (NSC) tj. reakcyjności koksu (CRI) i jego wytrzymałości mechanicznej po reakcji (CSR) staje się niezbędna dla zapewnienia odpowiedniej jakości produktu. Prognozowanie tych parametrów na wczesnym etapie planowania produkcji nie jest rzeczą łatwą. Niejednokrotnie pochodzenie próbki determinujące jej ilość nie pozwala na oznaczenie parametrów reakcyjności i wytrzymałości poreakcyjnej, które poprzedza koksowanie węgla w warunkach laboratoryjnych. Mimo znajomości znacznej liczby parametrów jakościowych węgla okazuje się, że przewidywanie właściwości koksu jest ciągle problematyczne [14]. Opisane w literaturze modele wykorzystujące sztuczną do prognozowania parametrów jakości węgla handlowego, opracowane w oparciu o dane z Jastrzębskiej Spółki Węglowej [4] nie obejmują chemii popiołu, który jest istotnym czynnikiem wpływającym na wartości wskaźników CRI i CSR [15]. Zaprezentowane w tej pracy modele jako pierwsze obejmują nie tylko analizę techniczną, własności koksotwórcze oraz petrografię ale również skład chemiczny popiołu. Poprzez analizę posiadanych historycznych danych o zasobach, dodatkowe analizy (np. petrograficzne) czy też zastosowanie algorytmów uczenia maszynowego możliwe jest ciągle doskonalenie procesu predykcji tych kluczowych parametrów co doskonale wpisuje się w ideę przemysłu 4.0.

ZNACZENIE PARAMETRÓW JAKOŚCIOWYCH KOKSU

Koks stosowany jest w wielkich piecach jako paliwo, reduktor oraz przepuszczalny nośnik wsadu [13]. Jakość koksu stosowanego w procesie wielkopieczowym jest jednym z głównych czynników, które zapewniają efektywną, stabilną i niezawodną pracę wielkiego pieca [14]. Wpływają one na wiele istotnych aspektów produkcji, od stabilności procesu po skład chemiczny stopu – tabela 1.

Parametry koksu mają istotny wpływ na efektywność i wydajność procesu wielkopieczowego. Ich odpowiednie kontrolowanie i optymalizacja są kluczowe dla uzyskania wysokiej jakości stali przy jednoczesnym minimalizowaniu zużycia energii i zanieczyszczeń środowiska. Parametry wytrzymałościowe koksu są jednymi z najważniejszych parametrów określających jego przydatność w procesach wielkopieczowych [14], spowodowane jest to faktem budowy i eksploatacji wielkich pieców o coraz większej objętości oraz stosowaniem paliw zastępczych (np.: technologia PCI).

Tabela 1 Wpływ wybranych parametrów koksu na proces wielkopiecowy

Parametr jakości koksu	Wpływ na element procesu
Zawartość popiołu	Zużycie topników
Zawartość wilgoci	Energochłonność procesu
	Ilość ścieków
Parametry wytrzymałościowe (M40, M10, CSR)	Przebieg procesu wielkopiecowego
Zawartość alkaliów	Żywotność instalacji
Zawartość chloru	Jakość ścieków
	Jakość stali
Zawartość siarki i fosforu	Wydajność procesu
	Zużycie koksu

PROGNOZOWANIE JAKOŚCI RYS HISTORYCZNY

Do połowy lat sześćdziesiątych ubiegłego stulecia większość węgla koksowego zużywanego w Europie i Ameryce Północnej czy Japonii pochodziło z krajowych kopalń, a opracowane wówczas modele były głównie regionalne, oparte na cechach lokalnych węgli [3]. W latach 60. i 70. XX wieku zrealizowano wiele badań, których efektem były modele prognozowania wskaźników wytrzymałościowych, głównie stabilności koksu wg ASTM [1] w oparciu o dane petrograficzne [5]. Były to głównie modele dla węgli z USA, Kanady czy Australii [5, 6, 10]. W Niemczech i RPA opracowano metody predykcji wytrzymałości mechanicznej Micum 40 (M40) [8, 9]. Zaproponowano wiele modeli przewidywania jakości koksu, z których większość opiera się na charakterystyce węgla i ogranicza się do tego samego pochodzenia geograficznego węgla [2].

Gdy pod koniec lat siedemdziesiątych ub. wieku, nastąpił wzrost międzynarodowego handlu węglem zaczęto poszukiwać uniwersalnego wskaźnika jakości. Wskaźniki CRI i CSR od momentu ich wprowadzenia przez Nippon Steel Co (NSC) zyskiwały na popularności by ostatecznie służyć w wymianie handlowej jako jedno z podstawowych kryteriów oceny jakości węgla koksowego. Test ten pozwala zasymulować zachowanie się koksu w wielkim piecu. W metodzie NSC oznacza się reakcyjność wobec CO₂ w temp. 1100°C oraz bębnową wytrzymałość poreakcyjną. W metodzie tej badaniom poddaje się próbkę koksu o masie 200 g i uziarnieniu ok. 20 mm, otrzymaną z przemysłowej lub doświadczalnej (np. retorta Karbotest) partii koksu [11]. Od czasu upowszechnienia testu NSC normalną praktyką w przemyśle koksowniczym jest stosowanie modeli pomagających w przewidywaniu jakości koksu. Różne dostępne obecnie modele przewidywania jakości koksu uwzględniają wybrane właściwości węgli, z których powstają mieszanki węglowe. Każda firma hutnicza stosuje modele dostosowane do jej charakterystyki operacyjnej, która zmienia się w zależności od dostępności węgla na rynku [2].

Tabela 2 Wybrane modele prognozowania wskaźnika CSR wraz z wykorzystywanymi parametrami

Firma	Petrografia	Reologia	Chemia popiołu	Inne	Rok
Nippon Steel	Inertynit [%], R_0, R_{max}	F_{max} [ddpm]	AI (Alkali Index)		1980
BCRA	Inertynit [%]	F_{max} [ddpm]	AI	O_a [%], C_a [%], Porowatość [pory/cm ²]	1982
Kobe Steel	R_0, R_{max}	F_{max} [ddpm]	AI		1985
CANMET	R_0, R_{max}		MBI (Modified Basicity Index)	Dylatacja [%]	1988
BHP	Inertynit [%]	F_{max} [ddpm]	BI (Basicity Index)	Zaw. części lotnych [%]	1989
Inland Steel		Zakres temp. plastyczności	AI	Zaw. Siarki [%]	1989
ISCOR	Witrynit [%], R_{max} , Inertynit [%]	F_{max} [ddpm]	TMO [%] (Total Metal Oxide)		1990

Źródło: [3].

Pomimo, iż na przestrzeni lat zaproponowano wiele modeli predykcji parametrów oznaczanych testem Nippon Steel Corporation, jak dotąd dla węgla koksowych niezależnie od ich pochodzenia nie znaleziono żadnego uniwersalnego [2].

ZARZĄDZANIE ZŁOŻEM I HARMONOGRAMOWANIE PRODUKCJI W JSW S.A

Jastrzębska Spółka Węglowa S.A realizując w przeciągu kilku ostatnich lat doktrynę przemysłu 4.0 przeszła cyfrową transformację w wielu obszarach swojej działalności, w tym w obszarze geologii górniczej. Jeszcze niedawno proces prognozowania jakości węgla koksowego odbywał się w sposób „ręczny”. Obecnie wdrożono system zarządzania złożem oraz planowania produkcji z wykorzystaniem cyfrowych map geologicznych, co umożliwiło długoterminowe planowanie wydobywania w sposób gwarantujący wysoką jakość i efektywne wykorzystanie złoża.

Droga do prognozy węgla handlowego składa się z kilku etapów. Pierwszym etapem jest rozpoznanie złoża, obejmuje ono zarówno odwierty, powierzchniowe, jak i dołowe oraz opróbowanie węgla pokładowego podczas prowadzonych prac udostępniających i eksploatacyjnych. Następny krok to analiza laboratoryjna obejmująca wykonanie analizy technicznej, oznaczenie parametrów koksotwórczych oraz oznaczenie parametrów jakości koksu. Otrzymane wyniki przed naniesieniem ich na mapę cyfrową poddawane są analizie eksperckiej. Etap tworzenia map cyfrowych obejmuje: kartowanie poszczególnych pokładów planowanych do eksploatacji złoża oraz budowę modeli 2D dla poszczególnych pokładów węgla. Kolejny etap to tworzenie modelu geologicznego, w ramach którego możliwe jest zarządzanie informacją

geologiczną, tworzenie modeli strukturalnych i jakościowych oraz prognoza węgla pokładowego. Etap planowania produkcji pozwala na tworzenie alternatywnych scenariuszy produkcyjnych, a w następstwie prognozę węgla handlowego wg harmonogramu biegu ścian (HBS). Sztuczna inteligencja oferuje, również dla przemysłu wydobywczego, znaczące korzyści i postępy [4]. Umożliwienie jej korzystania z dostępnego na etapie planowania produkcji zakresu danych powinno w dłuższej perspektywie przynieść efekty w postaci znaczącego postępu technologicznego w dziedzinie prognozowania jakości.

BAZA DANYCH I ANALIZY

Na potrzeby oceny przydatności różnych modeli predykcyjnych jakości węgla koksowego w procesie prognozowania parametrów jakości koksu oznaczanych testem NSC, zgromadzono dane obejmujące próby geologiczne dla wszystkich, również nieistniejących już kopalń JSW S.A. Wytypowano te, dla których zostały wyznaczone wskaźniki reakcyjności i wytrzymałości poreakcyjnej koksu wraz z innymi, zarówno technicznymi jak i koksotwórczymi parametrami węgla. Baza danych zawierająca wyniki oznaczeń CRI i CSR wraz indeksem Rogi (RI) oraz wskaźnikiem wolnego wydymania (SI) objęła ponad 5200 prób. W przypadku 3600 próbek zostały oznaczone również własności dylatometryczne (a, b, t₁, t₂, t₃) oraz badania petrograficzne (R₀, L, I, M, Vt), a dla 950 prób analizy obejmowały skład chemiczny popiołu (Na₂O, MgO, Al₂O₃, SiO₂, K₂O, CaO, TiO₂, Mn₃O₄, Fe₂O₃, P₂O₅, SO₃). Dla każdej z prób wykonano analizę techniczną obejmującą: oznaczenia zawartości wilgoci, popiołu, siarki, części lotnych. Przygotowano 3 zestawy danych, których populację próbek limitowała ilość oznaczeń składu chemicznego popiołu.

Tabela 3 Zestawy danych do analizy

Zestaw 1		Zestaw 2		Zestaw 3	
Parametr	Populacja	Parametr	Populacja	Parametr	Populacja
CRI/CSR [%]	3600 próbek	CRI/CSR [%]	950 próbek	CRI/CSR [%]	950 próbek
W _t [%]		W _t [%]		W _t [%]	
A ^d [%]		A ^d [%]		A ^d [%]	
V ^{daf} [%]		V ^{daf} [%]		V ^{daf} [%]	
SI [-]		SI [-]		SI [-]	
RI [-]		RI [-]		RI [-]	
a,b, t ₁ ,t ₂ ,t ₃		a,b, t ₁ ,t ₂ ,t ₃		a,b, t ₁ ,t ₂ ,t ₃	
R ₀ ,L,I,M,Vt		SChP		R ₀ ,L,I,M,Vt	
		SChP			

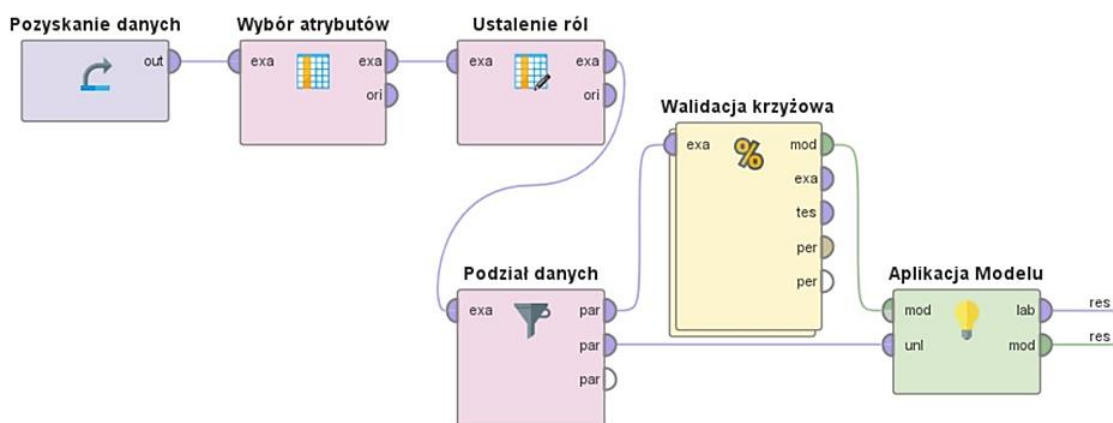
Źródło: opracowanie własne.

W celu analizy danych i budowy modeli wykorzystano oprogramowanie RapidMiner 9.10. Dla każdego zestawu danych przeprowadzono dwa doświadczenia z użyciem najpopularniejszych technik predykcji możliwych do przeprowadzenia w programie RapidMiner 9.10., były to:

- Uogólnione modele liniowe (GLM)

- Uczenie głębokie (Deep Learning)
- Drzewo decyzyjne (Decision Tree)
- Losowy las decyzyjny (Random Forest)
- Wzmocnienie gradientowe drzew (Gradient Boosted Trees)
- Maszyny wektorów nośnych (Support Vector Machine)


Model procesu analizy danych w programie RapidMiner 9.10. przedstawiono schematycznie na rys. 1, na przykładzie procesu uczenia głębokiego.



Rys. 1 Schemat modelu analizy danych za pomocą uczenia głębokiego

Po wprowadzeniu wszystkich danych z bazy następuje wskazanie, które dane powinny być analizowane (wybór atrybutów) w modelu. Kolejnym krokiem jest wskazanie roli zmiennej docelowej dla atrybutu, który chcemy prognozować oraz podział danych na zbiory służące szkoleniu i testowaniu modelu.

Wewnątrz operatora walidacji krzyżowej, którą przeprowadza się w celu oszacowania statystycznej wydajności modelu zachodzą dwa podprocesy: podproces szkolenia i podproces testowania. Podproces szkolenia służy do trenowania modelu. Wyszkolony model jest następnie stosowany w podprocesie testowania. Przedstawiono to na rys. 2.



Rys. 2 Schemat podprocesów zachodzących w operatorze walidacji krzyżowej

Celem porównania z istniejącymi modelami w Tabeli 4 porównano współczynniki korelacji liniowej dla opisanych w literaturze modeli. Wielkości te posłużyły do porównania z otrzymanymi z pomocą uczenia maszynowego modelami predykcji.

Tabela 4 Współczynniki korelacji liniowej wybranych modeli predykcji CSR i CRI

Rodzaj wsadu			Jednoskładnikowy	Mieszanka	Jednoskładnikowy i mieszanka
Laboratoryjne	CRI	Ilość modeli	7	5	6
		Zakres	0,79-0,91	0,52-0,80	0,62-0,92
		Średnia	0,88	0,69	0,82
	CSR	Ilość modeli	7	11	6
		Zakres	0,70-0,90	0,49-0,92	0,76-0,93
		Średnia	0,74	0,8	0,84
Przemysłowe	CRI	Ilość modeli		19	
		Zakres		0,20-0,94	
		Średnia		0,7	
	CSR	Ilość modeli		17	
		Zakres		0,10-0,95	
		Średnia		0,65	

Źródło: opracowanie własne na podstawie [12].

WYNIKI

Dla każdego zestawu danych analizowano możliwość predykcji zarówno parametru reakcyjności koksu (CRI), jak i wytrzymałości poreakcyjnej (CSR). Dla każdego modelu predykcji podano korelację liniową, odchylenie standardowe, a także oprócz całkowitego czasu wykonania procesu, czas potrzebny na ocenę 1000 wierszy i szkolenie modelu na 1000 wierszy.

**Tabela 5 Wyniki dla modeli predykcji
Zestaw 1**

CRI					
Model	Korelacja liniowa	Odch. standardowe	Czas [ms]	Nauka [ms]	Wyniki [ms]
Generalized Linear Model	0,65	0,031	2794,0	17,9	9,9
Deep Learning	0,71	0,045	5208,0	463,7	266,7
Decision Tree	0,56	0,026	1211,0	8,5	5,7
Random Forest	0,71	0,036	6880,0	203,3	533,3
Gradient Boosted Trees	0,65	0,035	3786,0	139,0	224,1
Support Vector Machine	0,66	0,020	55498,0	1781,9	641,8
CSR					
Model	Korelacja liniowa	Odch. standardowe	Czas [ms]	Nauka [ms]	Wyniki [ms]
Generalized Linear Model	0,67	0,052	1370,0	12,5	5,0
Deep Learning	0,69	0,054	4901,0	437,9	16,3
Decision Tree	0,61	0,033	1125,0	8,8	7,8
Random Forest	0,72	0,025	5866,0	47,1	48,2

Gradient Boosted Trees	0,67	0,042	2741,0	155,7	14,9
Support Vector Machine	0,68	0,059	67600,0	4439,0	401,4

Zestaw 2

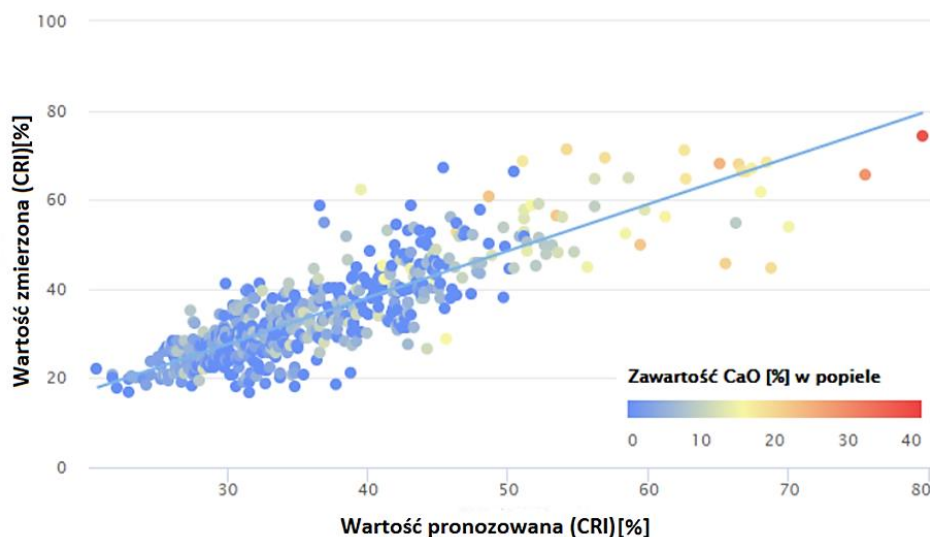
CRI					
Model	Korelacja liniowa	Odch. standardowe	Czas [ms]	Nauka [ms]	Wyniki [ms]
Generalized Linear Model	0,84	0,036	2093,0	112,7	50,0
Deep Learning	0,86	0,020	2505,0	559,1	47,7
Decision Tree	0,71	0,051	818,0	31,8	25,0
Random Forest	0,85	0,034	2110,0	254,5	72,7
Gradient Boosted Trees	0,79	0,025	4098,0	500,9	15,9
Support Vector Machine	0,85	0,033	6587,0	1000,9	202,3
CSR					
Model	Korelacja liniowa	Odch. standardowe	Czas [ms]	Nauka [ms]	Wyniki [ms]
Generalized Linear Model	0,84	0,031	425,0	31,8	22,7
Deep Learning	0,82	0,006	1643,0	470,9	27,3
Decision Tree	0,67	0,062	372,0	11,8	15,9
Random Forest	0,82	0,028	1319,0	50,9	31,8
Gradient Boosted Trees	0,75	0,023	1444,0	540,9	34,1
Support Vector Machine	0,84	0,035	4212,0	293,6	95,5

Zestaw 3

CRI					
Model	Korelacja liniowa	Odch. standardowe	Czas [ms]	Nauka [ms]	Wyniki [ms]
Generalized Linear Model	0,65	0,031	2794,0	17,9	9,9
Deep Learning	0,71	0,045	5208,0	463,7	266,7
Decision Tree	0,56	0,026	1211,0	8,5	5,7
Random Forest	0,71	0,036	6880,0	203,3	533,3
Gradient Boosted Trees	0,65	0,035	3786,0	139,0	224,1
Support Vector Machine	0,66	0,020	55498,0	1781,9	641,8
CSR					
Model	Korelacja liniowa	Odch. standardowe	Czas	Nauka	Wyniki
Generalized Linear Model	0,67	0,052	1370,0	12,5	5,0
Deep Learning	0,69	0,054	4901,0	437,9	16,3
Decision Tree	0,61	0,033	1125,0	8,8	7,8
Random Forest	0,72	0,025	5866,0	47,1	48,2
Gradient Boosted Trees	0,67	0,042	2741,0	155,7	14,9
Support Vector Machine	0,68	0,059	67600,0	4439,0	401,4

Dla parametru reakcyjności koksu (CRI), korzystając z jednego z zestawu danych, trzy spośród dostępnych algorytmów uczenia maszynowego dały modele o współczynniku korelacji liniowej przekraczającym 0,85. Były to: głębokie uczenie, losowy las decyzyjny oraz maszyna wektorów nośnych. Wspomniane algorytmy w oparciu o ten sam zestaw danych potrafiły opracować modele predykcyjne dla parametru wytrzymałości poreakcyjnej koksu (CSR) o podobnym współczynniku korelacji liniowej. Biorąc pod uwagę literaturę naukową opisującą modele prognozowania wskaźników CRI/CSR nie powinien dziwić fakt, że istotnymi zmiennymi objaśniającymi tych modeli są zawartości poszczególnych pierwiastków w popiele [14, 15].

Na rys. 3 przedstawiono przykładowy wynik predykcji parametru reakcyjności koksu (CRI) opracowany z użyciem uczenia głębokiego. Na wykresie, oprócz linii trendu, naniesiono wielkość jednej ze zmiennych objaśniających (zawartość tlenku wapnia), by na przykładzie wybranego pierwiastka zobrazować jaki wpływ ma skład chemiczny popiołu na reakcyjności koksu.



Rys. 3 Wynik predykcji parametru reakcyjności koksu (CRI) z zastosowaniem uczenia głębokiego

PODSUMOWANIE

Prognozowanie jakości węgla koksowego jest zadaniem mającym na celu zapewnienie optymalnego wykorzystania złóż, przy jednoczesnym wysokim udziale dobrej jakości węgla koksowego w produkcji. Wykorzystując algorytmy uczenia maszynowego wspomagające modelowanie predykcyjne, możliwe jest opracowanie modeli, które mogą pomóc w prognozowaniu wartości CRI i CSR na podstawie danych pochodzących z prób geologicznych. Analiza danych pokładowych pochodzących z prób geologicznych, zebranych w kopalniach Jastrzębskiej Spółki Węglowej, pozwoliła na identyfikację zależności między parametrami jakościowymi węgla, a właściwościami koksu co zaowocowało kilkoma obiecującymi modelami predykcji. Dalsze badania nad tym tematem mogą przyczynić się do usprawnienia procesów prognozowania poprzez

eksplorację historycznych danych w odniesieniu do rzeczywistego problemu przewidywania jakości węgla.

LITERATURA

- [1] ASTM, "ASTM D3402-93: Standard test method for tumbler test for coke," ASTM International, West Conshohocken, PA, (1993).
- [2] Álvarez R., Díez M.A., Barriocanal C., Díaz-Faes E., Cimadevilla J.L.G.: An approach to blast furnace coke quality prediction, *Fuel* Volume 86, Issue 14, (2007).
- [3] De Cordova M., Madias J., Barreiro J.: Review on Modeling of Coal Blends for Prediction of Coke Quality, *AISTech Proceedings* (2016), 297-309.
- [4] Dyczko A.: Real-time forecasting of key coking coal quality parameters using neural networks and artificial intelligence, *Rud.-geol.-naft. zb.*, vol. 38, no. 3, (2023), pp. 105-117.
- [5] Elliot M.: Coke stability from petrographic analysis of coal based on work of Shapiro and Gray), *Chemistry of Coal Utilization, Second Supplementary Volume*, pp. 146-154.
- [6] Gadsden R., Wilson R.: Evaluation of Australian coals and cokes for larges blast furnace, *Ironmaking Conference Proceedings*, (1981), pp 400-407
- [7] Jelonek I. , Jelonek Z.: The influence of petrographic properties of bituminous coal on the quality of metallurgical coke, *The Bulletin of The Mineral and Energy Economy Research Institute of the Polish Academy of Sciences*, (2017),100:49-65.
- [8] Jordan P.: Predicting coke quality based on coal petrography, rheology and coke petrography. Master thesis, University of the Witwatersrand, Johannesburg, South Africa, (2006).
- [9] Juranek G.: Evaluation of coals using the factor 'G', *Ironmaking Conference Proceedings*, (1979), pp. 371-384.
- [10] Leeder W.R., Gransden J.E., Price T.J., Botham J.C.: Prediction of coke quality with special reference to Canadian coals. *Ironmaking Conference Proceedings, Volume 38*, (1979), pp 385-397.
- [11] Mianowski A., Radko T., Koszorek A.: Ocena jakości wysokogatunkowego koksu wielkopieczowego w skali zintegrowanego testu reakcyjności i wytrzymałości NSC, *Przemysł Chemiczny*, vol. T. 88, nr 6, (2009), pp. 692-698.
- [12] North L., et al. : Methods of coke quality prediction: A review. *Fuel* 219, (2018), pp. 426-445.
- [13] Smędowski Ł, Krześcińska M.: Molecular oriented domains (MOD) and their effect on technological parameters within the structure of cokes produced from binary and ternary coal blends, *International Journal of Coal Geology*, Volume 111, (2013), pp. 90-97.
- [14] Ściażko M., Sobolewski A.: Prognozowanie jakości koksu : praca zbiorowa. Zabrze, Instytut Chemicznej Przeróbki Węgla, (2015), p. 243, ISBN 978-83-940055-0
- [15] Ulanovskiy M.L.: Ash basicity and the coke characteristics CRI and CSR: A review. *Coke and Chemistry* 57 (2014): pp. 91-97

Forecasting quality parameters of coke determined by Nippon Steel Corporation test using selected statistical methods and machine learning techniques

Abstract: The key process for ensuring the stability of the quality parameters of the coal and coke produced is the process of bed reconnaissance, which allows the intended level of quality to be achieved through appropriate long-wall scheduling in terms of quality. To meet coal market demands, Jastrzębska Spółka Węglowa is constantly improving its processes, including those related to deposit reconnaissance and production planning. Coke reactivity and coke strength after reaction are critical parameters for efficient blast furnace operation; unfortunately, determining them for geological samples is not always possible. This paper discusses the possibility of using machine learning methods to predict coke quality parameters determined by Nippon Steel Corporation (NSC). RapidMiner software was used to analyze the data and build predictive models, which enabled efficient data mining, model building, and analysis of the results. Analysis of historical geological data with the help of popular machine learning techniques showed that work on applying AI in bed quality prediction is promising, and efforts should be made to identify the most effective approaches to this issue.

Keywords: coal, coke, quality, machine learning, artificial intelligence

Jan Marcisz

Jastrzębska Spółka Węglowa S.A.
Aleja Jana Pawła II 4, 44-330 Jastrzębie-Zdrój, Polska
e-mail: jmarcisz@jsw.pl

Piotr Michorczyk

Wydział Inżynierii i Technologii Chemicznej
Katedra Chemii i Technologii Organicznej
Politechnika Krakowska, Polska
e-mail: piotr.michorczyk@pk.edu.pl

Aleksandra Burczyk

Jastrzębska Spółka Węglowa S.A.
Aleja Jana Pawła II 4, 44-330 Jastrzębie-Zdrój, Polska
e-mail: aburczyk@jsw.pl