

УДК 004.932.2:004.622

DOI 10.24412/2413-7383-68-78

Р. В. Ковальчик

ФГБОУ ВО «Приазовский государственный технический университет»,
287642, Российская Федерация, Донецкая Народная Республика,
г. Мариуполь, ул. Университетская, 7

РАЗРАБОТКА МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ ПРОГНОЗИРОВАНИЯ ВЫСОКОТЕМПЕРАТУРНЫХ МЕТАЛЛУРГИЧЕСКИХ СВОЙСТВ КОКСА

R. V. Kovalchik

Federal State Budgetary Educational Institution of Higher Education "Priazovsky State Technical University"
Russian Federation, DPR, Mariupol, Russia,
287642, Donetsk People's Republic, Mariupol, Universitetskaya Street, 7.

DEVELOPMENT OF MACHINE LEARNING MODEL OF PREDICTION HIGH-TEMPERATURE METALLURGICAL PROPERTIES OF COKE

Представлены результаты разработанных автором моделей прогнозирования высокотемпературных металлургических свойств кокса. Выбрана оптимальная модель машинного обучения, которая позволила достичь наибольшей точности предсказания целевого показателя, в качестве которого применен индекс реакционной способности кокса CRI. Особенностью моделей является использование марочного состава угольной шихты в качестве входных значений. Предложенный подход не требует дополнительных лабораторных исследований физико-химических свойств угольной шихты для производства кокса.

Ключевые слова: машинное обучение, нейронные сети, оптимизаторы, металлургический кокс, прогнозирование.

The results of coke high-temperature metallurgical properties prediction models developed by the author are presented. The optimal model of machine learning was selected, which allowed to achieve the highest accuracy of prediction of the target index, as which the coke reactivity index CRI is used. The peculiarity of the models is the use of coal charge grade composition as input values. The proposed approach does not require additional laboratory studies of physicochemical properties of coal charge for coke production.

Keywords: machine learning, neural networks, optimizers, metallurgical coke, forecasting.

Известно, что высокотемпературные металлургические свойства кокса являются одним из основных факторов эффективной работы доменных печей [1], [2]. Кокс внутри печного пространства выполняет не только функцию основного топлива, но и служит каркасом, через который осуществляется дренаж жидких продуктов плавки в горн доменной печи [3]. В связи с этим мероприятия, направленные на повышение его прочностных характеристик, представляют собой первоочередную и приоритетную задачу.

В настоящее время существуют различные статистические математические модели, которые позволяют прогнозировать металлургические свойства кокса и его влияние на показатели доменной плавки [4-6]. Относительно новым направлением в развитии теоретических и прикладных основ моделирования высокотемпературных свойств кокса является использование искусственных нейронных сетей (ИНС), посредством которых возможно реализовать, в том числе, и регрессионные задачи.

Применение ИНС открывает новые возможности для решения задач оптимизации ключевых параметров технологических процессов производства металлопродукции еще на стадии получения металлургического кокса, где закладывается эффективность работы доменных печей. Это является предпосылкой создания современных интеллектуальных систем управления и оптимизации технологических процессов на металлургических предприятиях, включающих коксохимическое производство.

Предложены модели машинного обучения, в том числе и модели глубокого обучения, позволяющие наиболее эффективно реализовать задачу прогнозирования высокотемпературных металлургических свойств кокса в зависимости от исходных характеристик каменноугольной шихты для его производства.

Отличительной особенностью предложенных моделей является использование марочного состава угольной шихты в качестве входных параметров (набора признаков). Такой подход не требует проведения специальных лабораторных исследований для определения химико-технологических свойств углей для коксования, таких, как например коэффициент отражения витринита, содержания фюзенизированных компонентов, объемная доля интернита и т.д.

В настоящее время принято считать, что наиболее эффективно высокотемпературные металлургические свойства кокса характеризуются показателями CRI (*Coke Reactivity Index*) – индексом реакционной способности и CSR (*Coke Strength after Reaction*) – индексом прочности кокса после взаимодействия с CO₂.

Ранее было установлено [7], что между показателями CSR и CRI существует линейная связь (коэффициент корреляции $r = -0,83$) определяемая по формуле:

$$CSR = -1,70CRI + 101,85, \quad (1)$$

т.е. с уменьшением реакционной способности увеличивается горячая прочность кокса CSR (в соответствии с рисунком 1).




Рисунок 1 – Связь реакционной способности CRI и горячей прочности CSR кокса

Аналогичная зависимость, демонстрирующая связь между показателями CRI и CSR, получена и в других работах [2].

Поэтому в качестве параметра предсказания и оптимизации был выбран индекс CRI, а показатель CSR рассчитывался затем по известной (1) зависимости.

Для реализации моделей были использованы данные о марочном составе угольной шихты для производства кокса и соответствующие им показатели CRI и CSR выполненные на лабораторной установке коксохимического производства металлургического комбината «Азовсталь». Марочный состав для производства кокса включал следующий состав угольной шихты: Г, ГЖ, ГЖЖ, Ж, КО, К, ОС, С, КОС, КСК. Всего десять марок.

Подготовка данных для обучения. Исходные данные для обучения и тестирования находятся в Excel файле с расширением Comma Separated Value (CSV). Данные включали в себя результаты анализа 165 проб кокса по показателям CSR и CRI, выполненных на лабораторной установке коксохимического производства металлургического комбината «Азовсталь» и соответствующие им марочные составы шихт для коксования.

Разработка и подбор оптимальной модели прогнозирования качества кокса выполнена в среде Google Colaboratory – бесплатной среде для разработки и выполнения программного кода в облаке.




Рисунок 2 – Загрузка исходных данных для обучения модели

Загрузка исходных данных в проект и их последующая подготовка реализована с использованием библиотеки Pandas. Исходные данные содержат пустые ячейки для тех марочных составов, в которых соответствующая марка угля в шихте не используется. Поэтому первым этапом подготовки данных было заполнение нулями пустых ячеек в таблице Pandas. На рисунке 2 приведен фрагмент программного кода, при помощи которого реализована описанная выше задача.

```
X = df.iloc[:, :10]
y = df["CRI, %"]
```

Рисунок 3 – Разделение данных на входные значения (X) и целевой параметр y

В переменной X будет содержаться набор входных значений (признаков), которыми в предложенной методике построения модели машинного обучения будет выступать марочный состав угольной шихты, а значением целевого показателя y будет являться показатель реакционной способности кокса CRI в процентах (в соответствии с рисунком 3).

В качестве подходов к реализации поставленной задачи были рассмотрены модель случайного леса (Random Forest Regression), для которой выполнен поиск оптимальных параметров, а также предложены различные архитектуры искусственных нейронных сетей.

Модель случайного леса

Random Forest Regression является одним из алгоритмов машинного обучения, который использует ансамбль деревьев решений для предсказания непрерывных целевых переменных. В качестве целевой переменной был использован показатель CRI. В основе модели случайного леса лежит подход создания множества деревьев решений и объединения их результатов для получения более точного прогноза.

```
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import mean_squared_error, mean_absolute_error

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

model = RandomForestRegressor(n_estimators=100, random_state=42)

# Обучение модели
model.fit(X_train, y_train)

# Прогнозируемая величина реакционной способности кокса
y_pred = model.predict(X_test)

# Оценка точности работы модели
mae = mean_absolute_error(y_test, y_pred)
print(f"Mean Absolute Error: {mae}")
mse = mean_squared_error(y_test, y_pred)
print(f"Mean Squared Error: {mse}")
```

```
Mean Absolute Error: 1.8402770134747495
Mean Squared Error: 5.846791299350948
```

Рисунок 4 – Реализация модели Random Forest Regression

Для реализации поставленной задачи был использован фреймворк Tensorflow версии 2.17.1, библиотека scikitlearn и библиотека Matplotlib для визуализации результатов обучения моделей. В качестве матрицы ошибки использовалась MAE (Абсолютное среднее отклонение). Для данной модели результаты обучения по показателю MAE, при количестве деревьев 100, составили 1,84%. Изменение количества деревьев с 50 до 700 не привело к ощутимому изменению точности предсказания.

С целью оптимизации предложенной выше модели к варьируемому параметру (количество деревьев в лесу) были добавлены такие параметры как максимальный уровень (глубину) каждого дерева (`max_depth`), минимальное количество выборок, необходимых для разделения внутреннего конечного узла (`min_samples_split`) и минимальное количество элементов выборки, которые могут находиться в листовой вершине дерева (`min_samples_leaf`).

```

#Разбиение на тестовую и обучающую выборки
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Гиперпараметры модели
n_estimators = 100
max_depth = 20
min_samples_split = 5
min_samples_leaf = 2

model = RandomForestRegressor(n_estimators=n_estimators,
                             max_depth=max_depth,
                             min_samples_split=min_samples_split,
                             min_samples_leaf=min_samples_leaf,
                             random_state=42)

# Обучение модели
model.fit(X_train, y_train)

# Прогнозируемая величина реакционной способности кокса
y_pred = model.predict(X_test)

# Оценка точности работы модели
mae = mean_absolute_error(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
print(f"Mean Absolute Error: {mae}")

```

Mean Absolute Error: 1.6689677208313587

Рисунок 5 – Реализация модифицированной модели Random Forest Regression

Подбор оптимальных значений по указанным параметрам позволил повысить точность работы модели по показателю MAE до 1,67% (рис. 5).

Модель искусственной нейронной сети

Следующим подходом реализации поставленной задачи явилась разработка искусственной нейронной сети. Также, как и для модели случайного леса, нейросетевая модель была реализована с использованием фреймворка Tensorflow версии 2.17.1, библиотек scikitlearn, Matplotlib и Pandas.

Для разработки искусственной нейронной сети была использована полносвязная архитектура, в которой применялась нормализация данных между внутренними слоями сети, а также заморозка обучения нейронов при помощи класса Dropout(). Доля таких нейронов варьировалась от 10% до 40%. Подобный подход был призван улучшить точность работы моделей. Архитектура строилась на основе последовательного подхода, который в Tensorflow реализуется посредством создания объекта класса Sequential.

Обучение выполнялось на 100 эпохах с размером батча 16 и оптимизатором «adam». Гиперпараметры модели представлены на рисунке 6.

Model: "sequential_1"

Layer (type)	Output Shape	Param #
dense_6 (Dense)	(None, 64)	704
dense_7 (Dense)	(None, 64)	4,160
dense_8 (Dense)	(None, 64)	4,160
dense_9 (Dense)	(None, 64)	4,160
dense_10 (Dense)	(None, 32)	2,080
dense_11 (Dense)	(None, 1)	33

Total params: 45,893 (179.27 KB)
 Trainable params: 15,297 (59.75 KB)
 Non-trainable params: 0 (0.00 B)
 Optimizer params: 30,596 (119.52 KB)

Рисунок 6 – Гиперпараметры нейросетевой модели

Обучение реализовано на 150 эпохах с оптимизатором Adam и шагом обучения 0,01.

Total params: 45893 - общее количество параметров в сети, занимающих 179,27 KB памяти. Trainable params: 15,297 - параметры, которые обновляются во время обучения (веса и смещения), занимают 59,75 KB. Non-trainable params: 0 - параметры, которые остаются неизменными при обучении (их нет в данной модели). Optimizer params: 30596 - параметры оптимизатора, занимают 119,52 KB. В сумме trainable и optimizer params дают около 45893 параметров, что является полным размером модели.

Динамика обучения модели представлена графиками на **рисунке 7**.

В качестве критерия точности модели был также использован показатель Mean Absolute Error (MAE), который характеризует среднюю абсолютную ошибку.




Рисунок 7 – Динамика обучения нейросетевой модели предсказания реакционной способности кокса

Для увеличения точности предсказания нейросетевой модели был предложен способ предварительной подготовки данных, использующий RobustScaler. RobustScaler — это метод масштабирования, предоставляемый в библиотеке scikit-learn, который устойчив к выбросам. В отличие от стандартного масштабирования (среднее значение = 0, стандартное отклонение = 1), он масштабирует признаки на основе их медианы и межквартильного размаха (IQR). Такой подход призван подготовить данные, на которых обучается модель и повысить ее точность.

В основу работы масштабирования RobustScaler положена зависимость:

$$x_{\text{масшт}} = \frac{x - \text{median}(x)}{IQR(x)}, \quad (2)$$

где $\text{median}(x)$ – среднее значение в наборе данных входных признаков;

IQR – межквартильный размах, который представляет собой статистическую величину, количественно определяющую разброс средних 50% набора данных. Она используется для измерения изменчивости, будучи устойчивой к выбросам.

Величина IQR рассчитывается по следующей формуле:

$$IQR = Q_3 - Q_1, \quad (3)$$

где Q_1 - (1-й квартиль или 25-й процентиль): значение, ниже которого лежит 25% данных; Q_3 - (3-й квартиль или 75-й процентиль): значение, ниже которого лежит 75% данных.

Таким образом, показатель *IQR* охватывает диапазон средних 50% данных. Преимущество данного подхода состоит в том, что *IQR* устойчив к выбросам, поскольку фокусируется на центральной части данных, игнорируя их экстремальные значения.

Также для увеличения точности работы модели были выполнены исследования применения различных оптимизаторов весов искусственной нейронной сети. Оптимизаторы играют ключевую роль в обучении, поскольку их задачей является соответствующая корректировка весов по достижению их оптимальных значений. Под оптимальными значениями понимаются такие, при которых расчётный целевой показатель будет максимально приближен к фактическому.

В ходе исследования были опробованы следующие оптимизаторы:

- - стохастический градиентный спуск (SGD);
- - оптимизатор импульса (Momentum);
- - среднеквадратичное распространение (RMSProp);
- - адаптивная оценка момента (Adam);
- - адаптивный градиентный оптимизатор (Adagrad).

```
from sklearn.preprocessing import StandardScaler, RobustScaler
from tensorflow.keras.optimizers import SGD, Adam, RMSprop, Adagrad, Adadelta, Nadam, Ftrl
scaler = RobustScaler()
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)
model = Sequential()
model.add(Dense(64, activation='relu', input_shape=(X_train.shape[1],)))
model.add(Dense(64, activation='tanh'))
BatchNormalization(),
Dropout(0.4),
model.add(Dense(64, activation='relu'))
BatchNormalization(),
Dropout(0.2),
model.add(Dense(64, activation='tanh'))
BatchNormalization(),
model.add(Dense(32, activation='relu'))
model.add(Dense(1, activation='elu'))
#Компиляция модели
model.compile(optimizer = Adagrad(learning_rate=0.01), loss='mae', metrics=['mse'])
#Обучение модели
history = model.fit(X_train, y_train, epochs=350, batch_size=16, validation_split=0.2)
# Оценка адекватности модели
loss = model.evaluate(X_test, y_test)
print(f"Mean Absolut Error on Test Set: {loss}")
```

Рисунок 8 – Реализация оптимальной архитектуры искусственной нейронной сети.

Установлено, что наибольшая эффективность обучения модели была достигнута при использовании адаптивного градиентного оптимизатора (Adagrad). Особенностью данного оптимизатора является автоматическая регулировка скорости обучения для каждого параметра, что делает его эффективным для разреженных данных. Поэтому данный вид оптимизатора наиболее подходит для задач, где признаки разрежены и требуют больше обновлений для редких параметров.

В качестве функций активации внутренних слоев использованы функции ReLU и гиперболический тангенс (tanh). Архитектура предложенной нейросетевой модели представлена на **рисунке 8**.

Модель обучалась на 350 эпохах с размером батча 16 и шагом обучения 0,01. Для валидации было использовано 20% исходных данных. В качестве критерия оценки точности модели был использован показатель Mean Absolute Error (MAE). Несмотря на достаточно ограниченный набор данных для обучения (dataset), сам подход к реализации поставленной задачи с использованием искусственных нейронных сетей показал хорошие результаты.

Реализация модели и подбор ее гиперпараметров позволили достичь точности предсказания индекса реакционной способности кокса CRI по показателю MAE на уровне 1,57% на тестовой выборке. При среднем значении реакционной способности CRI на уровне 33,54% погрешность прогнозирования составила 4,68% от среднего значения, что является хорошим результатом работы модели.

После модификации кода итоговые гиперпараметры искусственной нейронной сети представлены на рисунке 9.

Total params: 30,596 - общее количество параметров в сети, занимающих 119.52 KB памяти. Trainable params: 15,297 - параметры, которые обновляются во время обучения (веса и смещения), занимают 59.75 KB. Non-trainable params: 0 - параметры, которые остаются неизменными при обучении (их нет в данной модели). Optimizer params: 15,299 - параметры оптимизатора, занимают 59.77 KB. В сумме trainable и optimizer params дают около 30,596 параметров - это полный размер модели.

Model: "sequential_81"

Layer (type)	Output Shape	Param #
dense_503 (Dense)	(None, 64)	704
dense_504 (Dense)	(None, 64)	4,160
dense_505 (Dense)	(None, 64)	4,160
dense_506 (Dense)	(None, 64)	4,160
dense_507 (Dense)	(None, 32)	2,080
dense_508 (Dense)	(None, 1)	33

Total params: 30,596 (119.52 KB)
 Trainable params: 15,297 (59.75 KB)
 Non-trainable params: 0 (0.00 B)
 Optimizer params: 15,299 (59.77 KB)

Рисунок 9 – Гиперпараметры оптимальной нейросетевой модели прогнозирования индекса CRI

Как следует из рисунка 8 модель состоит из шести полносвязных слоев, то есть слоев, в которых каждый нейрон предыдущего скрытого слоя связан со всеми нейронами последующего слоя. На вход нейронной сети подается информация о марочном составе угольной шихты. Выходной слой содержит один нейрон с информацией о прогнозируемом значении реакционной способности кокса CRI.

Полученные результаты поиска оптимальных моделей прогнозирования индекса реакционной способности металлургического кокса приведены в таблице 1.

Таблица 1 – Результат поиска оптимальных моделей прогнозирования индекса CRI

№п/п	Наименование модели	Точность работы по показателю MAE, %	Разность абсолютная точности работы моделей, %	Относительная разность точности работы моделей, %
1	Модель случайного леса	1,67	0,1	6,02
2	Искусственная нейронная сеть	1,57		

Из результатов работы следует, что разработанные модели случайного леса и нейросетевая модель демонстрируют схожие результаты предсказания индекса реакционной способности CRI. При это погрешность прогнозирования по абсолютному значению составляет около 5% от среднего значения целевого показателя, что указывает на достаточно высокую точность работы моделей.

Представленный подход к реализации моделей предсказания качественных характеристик металлургического кокса на основе подбора марочного состава угольной шихты для коксования, а также известные зависимости влияния прочностных свойств кокса на технико-экономические показатели доменной плавки, позволяют реализовать задачу снижения себестоимости металлопродукции еще на стадии коксохимического производства.

Выводы

1. Разработаны и протестированы модели случайного леса и нейросетевая модель прогнозирования высокотемпературных металлургических свойств кокса, которые позволяют оптимизировать качественные характеристики кокса путем оптимального формирования марочного состава угольной шихты для его производства.

2. С учетом влияния показателя CSR на технико-экономические показатели доменной плавки, в первую очередь на удельный расход кокса при производстве чугуна, подход, выполненный в работе, открывает возможность снижения себестоимости металлопродукции на комбинатах с полным металлургическим циклом.

3. Разработаны оптимальные модели искусственной нейронной сети с полносвязной архитектурой, и модель случайного леса, которые позволяют достичь точности предсказания индекса CRI с абсолютной средней ошибкой (MAE) на уровне 1,57% и 1,67% соответственно, что составляет около 5% от среднего значения показателя CRI.

4. Разработанные модели могут являться составляющей системы искусственного интеллекта управления и оптимизации технологических процессов производства металлопродукции и быть интегрированы в программное обеспечение интеллектуальных систем.

Список литературы

1. Улучшение качества доменного кокса с помощью спецреагентов / В.А.Тамко, И.В.Золотарев, Е.И.Збыковский и др. // Углекхимический журнал. – 2009. – № 5. – С. 13-20.
2. Оценка качества доменного кокса / А.С. Афанасьев, Ю.В. Коновалова, С.Г. Гагарин и др. https://www.researchgate.net/publication/293525211_Estimation_of_metallurgical_coke_quality
3. Ковальчик Р.В. Изменение интенсивности доменной плавки при использовании кокса с различной горячей прочностью / Р.В. Ковальчик, А.А. Томаш, Ю.А. Зинченко // Металл и литье Украины. – 2008. – № 7–8. – С. 27–30.
4. Дороганов В. С., Суханова Е. Ю. Прогнозирование характеристик кокса на основе показателей шихты // Труды Всероссийской молодежной школы-семинара «Анализ, геометрия и топология». Барнаул: АлтГУ, 2013. С. 46 – 50.
5. Станкевич А. С., Гилязетдинов Р. Р., Попова Н. К., Кошкарров Д. А. Модель прогноза показателей CSR и CRI кокса на основе химико-петрографических параметров угольных шихт и условий их коксования // Кокс и химия. 2008. № 9. С. 37 – 44.
6. Влияние реакционной способности и «горячей» прочности кокса на технико-экономические показатели доменной плавки в условиях ОАО «МК «Азовсталь» / А.А. Томаш, В.П. Тарасов, Р.В. Ковальчик [и др.] // Вестник Приазовского государственного технического университета. – 2007. – № 17. – С. 9–13.
7. Ковальчик Р. В., Томаш А.А. Теоретическая оценка влияния горячей прочности кокса CSR на его удельный расход в доменной плавке // Вестник Приазовского государственного технического университета. Серия: Технические науки. – 2008. – № 18. – С. 15-18.
8. Афанасьев В. В. Теория вероятностей в вопросах и задачах. Режим доступа: <http://citoweb.yspu.org/link1/metod/theory/node42.html>, свободный.

References

1. Improvement of blast furnace coke quality by means of special reagents / V.A.Tamko, I.V.Zolotarev, E.I.Zbykovsky et al. // Uglekhimicheskiy Zhurnal. - 2009. - № 5. - С. 13-20.

2. Blast-furnace coke quality estimation / A.S. Afanasyev, Yu.V. Konovalova, S.G. Gagarin et al. https://www.researchgate.net/publication/293525211_Estimation_of_metallurgical_coke_quality
3. Kovalchik, R.V. Variation of the blast furnace smelting intensity when using coke with different hot strength (in Russian) / R.V. Kovalchik, A.A. Tomash, Yu.A. Zinchenko // Metal and casting of Ukraine. - 2008. - № 7-8. - С. 27-30.
4. Doroganov, V. S.; Sukhanova, E. Yu. Forecasting of the coke characteristics on the basis of the charge indicators (in Russian) // Proceedings of the All-Russian youth school-seminar "Analysis, geometry and topology". Barnaul: AltSU, 2013. С. 46 - 50.
5. Stankevich A. S., Gilyazetdinov R. R. R., Popova N. K., Koshkarov D. A. Model for prediction of coke CSR and CRI indicators on the basis of chemical and petrographic parameters of coal charge and conditions of their coking // Coke and Chemistry. 2008. № 9. С. 37 - 44.
6. Influence of reactivity and "hot" strength of coke on technical and economic indicators of blast furnace melting in conditions of JSC "AZOVSTAL IRON & STEEL WORKS" / A.A. Tomash, V.P. Tarasov, R.V. Kovalchik [et al.] // Bulletin of Priazov State Technical University. - 2007. - № 17. - С. 9-13.
7. Kovalchik, R.V.; Tomash, A.A. Theoretical evaluation of the influence of hot strength of coke CSR on its specific consumption in blast furnace melting (in Russian) // Vestnik of Priazov State Technical University. Series: Technical sciences. - 2008. - № 18. - С. 15-18.
8. Afanasyev V. V. Probability theory in questions and tasks.
Access mode: <http://cito-web.yspu.org/link1/metod/theory/node42.html>, free.

RESUME

R. V. Kovalchik

Development Of The Machine Learning Model For The Prediction Of The High Temperature Properties Of Coke

The improvement of coke quality has been the focus of numerous studies, primarily emphasizing the influence of the chemical composition of the initial coal blend on the strength characteristics of the produced coke. Various mathematical models exist for predicting coke properties; however, the use of artificial neural networks opens new opportunities for regression-based forecasting tasks. An important aspect is the ability to predict the coke reactivity index (CRI) based on the coal blend composition without conducting additional laboratory studies.

Machine learning models, including random forest and artificial neural networks, were developed to predict coke CRI based on coal blend characteristics. The model selection process was conducted by comparing performance indicators, including mean absolute error (MAE). The effectiveness of different optimization algorithms and network architectures was evaluated.

The developed models demonstrated high accuracy in predicting the CRI index. The best-performing ANN model achieved an MAE of 1.57%, while the random forest model reached 1.67%. The absolute prediction error was approximately 5% of the target value, confirming the models' reliability.

The proposed approach allows for optimizing coke quality through machine learning-based coal blend composition selection. The developed models can be integrated into intelligent control systems for metallurgical production, enabling cost reduction at the coking stage of the blast furnace process.

РЕЗЮМЕ

Р. В. Ковальчик

Разработка модели машинного обучения для прогнозирования высокотемпературных металлургических свойств кокса

Вопросам повышения качества кокса посвящено ряд работ, в основном делающие акцент на влиянии химического состава исходной шихты для производства кокса на его прочностные характеристики. Существуют различные математические модели для прогнозирования свойств кокса, однако использование искусственных нейронных

сетей открывает новые возможности для регрессионных задач прогнозирования. Важным аспектом является возможность предсказания индекса реакционной способности кокса (CRI) на основе марочного состава угольной шихты без проведения дополнительных лабораторных исследований.

Разработаны модели машинного обучения, включая случайный лес и искусственные нейронные сети, для предсказания индекса CRI по характеристикам угольной шихты. Произведен сравнительный анализ моделей по показателю MAE. Исследовано влияние различных оптимизаторов и архитектур нейросетей на точность прогнозирования.

Разработанные модели показали высокую точность предсказания индекса CRI. Лучшая нейросетевая модель достигла MAE = 1,57%, модель случайного леса — 1,67%. Абсолютная погрешность прогнозирования составила около 5% от среднего значения целевого показателя, что подтверждает надежность моделей.

Предложенный подход позволяет оптимизировать качественные характеристики кокса за счет подбора марочного состава угольной шихты с использованием методов машинного обучения. Разработанные модели могут быть интегрированы в интеллектуальные системы управления металлургическим производством, снижая себестоимость продукции на этапе коксования.

Ковальчик Роман Владиславович - кандидат технических наук, заведующий кафедрой информатики и вычислительной техники ФГБОУ ВО «Приазовский государственный технический университет», Российская Федерация, ДНР, г. Мариуполь.

E-mail: kovalchyrv@yandex.ru

Область научных интересов: системный анализ, математическое моделирование, искусственный интеллект, автоматизация технологических процессов черной металлургии.

Статья поступила в редакцию 19.01.2025.