

**Оригинальная статья**

УДК 54.062:004.032.26.

DOI: 10.57070/2304-4497-2022-4(42)-27-32

**ИССЛЕДОВАНИЕ АНОМАЛЬНЫХ ПОКАЗАТЕЛЕЙ ПРОЦЕССА КОКСОВАНИЯ  
УГЛЕЙ НА ОСНОВЕ МАШИННОГО ОБУЧЕНИЯ**

© 2022 г. А. Д. Байдалин

АО «ЕВРАЗ Объединенный Западно-Сибирский металлургический комбинат» (Россия, 654043, Кемеровская область – Кузбасс, Новокузнецк, шоссе Космическое, 16)

**Аннотация.** На основе компьютерного моделирования и методов машинного обучения был составлен алгоритм подготовки и обучения. Данные взяты из технологических баз и журналов подготовки сырья для производства кокса. После проведения статистического анализа сделаны выводы, которые были приняты на производстве в реализацию. В условиях непрерывного производственного процесса возможность своевременно выявлять дефекты в оборудовании и логистике напрямую влияет на экономический эффект. Любые области в современном мире имеют тенденцию в развитии технологий искусственного интеллекта и машинного обучения. Предприятия Новокузнецка (в том числе металлургические) активно ведут разработку роботов – подсказчиков и систем прогнозирования качества продукции. Искусственный интеллект связан с задачей использования компьютеров для понимания человеческого интеллекта. Это важное направление в построении человекоподобных систем. На рассматриваемом этапе развития машинного обучения стали использовать ряд алгоритмов и программных систем, отличительным свойством которых является то, что они могут решать задачи, так как это делал бы размышляющий над их решением человек. Относительно активно развивающихся систем информационных технологий металлургические процессы живут намного дольше, соответственно поиск решений для объединения знаний и опыта технологов и искусственного интеллекта является трудной, но интересной задачей для поиска возможных проблем на производстве. Выявление внештатных отклонений помогает избежать незапланированных простоев (экономических потерь). Статья является демонстрацией пути, который был пройден для объединения информационных технологий в области искусственного интеллекта и металлургии, а именно получение коксующихся углей на основе технологических показателей коксохимического производства.

**Ключевые слова:** коксохимическое производство, коксовая батарея, уголь, машинное обучение, большие данные, коксовыткатыватель, нейронные сети, искусственный интеллект

**Для цитирования:** Байдалин А.Д. Исследование аномальных показателей процесса коксования углей на основе машинного обучения // Вестник Сибирского государственного индустриального университета. 2022. № 4 (42). С. 27 – 32. [https://doi.org/10.57070/2304-4497-2022-4\(42\)-27-32](https://doi.org/10.57070/2304-4497-2022-4(42)-27-32)

**Original article**

**STUDY OF ABNORMAL INDICATORS OF COAL COKING PROCESS ON THE  
BASIS OF MACHINE LEARNING**

© 2022 A. D. Baydalin

JSC “EVRAZ – Joint West Siberian Metallurgical Plant” (16 Kosmicheskoe Route, Novokuznetsk, Kemerovo Region – Kuzbass 654043, Russian Federation)

**Abstract.** On the basis of computer modeling and machine learning methods, an algorithm for preparing and training data taken from technological databases and journals for the preparation of raw materials for coke production was compiled. After statistical analysis, conclusions were drawn, which were accepted in production for implementation. In a continuous production process, the ability to timely detect defects in

equipment and logistics directly affects the economic effect. Any field in the modern world tends to develop artificial intelligence and machine learning technologies. Novokuznetsk enterprises, including metallurgical ones, are also actively developing robots - prompters and systems for predicting product quality. Artificial intelligence is concerned with the task of using computers to understand human intelligence. This is an important direction in the construction of human-like systems. At this stage in the development of machine learning, a number of algorithms and software systems began to be attributed to it, the distinguishing feature of which is that they can solve some problems in the same way as a person thinking about their solution would do. But with respect to actively developing information technology systems, metallurgical processes live much longer, so finding solutions to combine the knowledge and experience of technologists and artificial intelligence is a difficult but interesting task for finding possible problems in production. Identification of abnormal deviations helps to avoid unplanned downtime, and, accordingly, avoid economic losses. This article is a demonstration of the path that has been taken to combine information technologies in the field of artificial intelligence and metallurgy, namely the production of coking coal, based on the technological indicators of coke production.

**Keywords:** coke production, coke oven battery, coal, machine learning, big data, coke pusher, neural networks, artificial intelligence

**For citation:** Baydalin A.D. Study of abnormal indicators of coal coking process on the basis of machine learning. *Bulletin of the Siberian State Industrial University*. 2022, no. 4 (42), pp. 27 – 32. (In Russ.). [https://doi.org/10.57070/2304-4497-2022-4\(42\)-27-32](https://doi.org/10.57070/2304-4497-2022-4(42)-27-32)

### Введение

Коксохимическая промышленность – отрасль черной металлургии, занимающаяся переработкой каменного угля методом коксования [1].

Основная продукция коксохимической промышленности: 76 – 78 % каменноугольного кокса; 14 – 15 % коксового газа; 5 – 6 % химических продуктов (бензола, толуола, этилена, различных смол, масел и пр.).

Каменноугольный кокс используется в металлургии в качестве топлива в доменных и литейных производствах. Коксовый газ и другие продукты коксования служат сырьем для химических производств. На их основе выпускают различные полимеры, азотные удобрения, синтетические моющие средства, пестициды, лекарственные препараты и многое другое [2].

Каменноугольный кокс применяют для выплавки чугуна (доменный кокс) как высококачественное бездымное топливо, восстановитель железной руды, разрыхлитель шихтовых материалов. Кокс используют также как ваграночное топливо в литейном производстве (литейный кокс), для бытовых целей (бытовой кокс), в химической и ферросплавной отраслях промышленности (специальные виды кокса).

### Основная часть

Доменный кокс должен иметь размеры кусков не менее 25 – 40 мм при ограниченном содержании кусков менее 25 мм (не более 3 %) и более 80 мм. В нижней части доменной печи кокс является единственным шихтовым материалом, находящимся в твердом состоянии, выполняя роль пористой коксовой насадки. Каменноугольный кокс является наиболее распространенным твердым топ-

ливом, используемым для выплавки чугуна в доменных и других шахтных печах.

Литейный кокс по размерам кусков крупнее доменного. Наиболее пригоден продукт, в котором присутствуют куски менее 60 – 80 мм. Главное отличие литейного кокса от доменного – малое содержание серы, которое не должно превышать 1 % (в доменном коксе до 2 %) [3].

При производстве ферросплавов используют мелкий кокс (фракции 10 – 25 мм), при этом в отличие от доменного и литейного производств предпочитают применять продукт с большей реакционной способностью. Требования по прочности к бытовому коксу менее жесткие, чем к доменному и литейному. Во всех производствах лучшее сырье – наиболее прочный малозольный и малосернистый кокс, содержащий небольшое количество мелких фракций. Современное мировое производство каменноугольного кокса составляет около 550 – 650 млн т/год (от 60 до 70 % мирового производства осуществляется в КНР) [4].

Физико-химические свойства каменноугольного кокса определяются его структурой, приближающейся к гексагональной слоистой структуре графита. Структура кокса характеризуется неполной упорядоченностью. Отдельные фрагменты (слои), связанные Ван-дер-Ваальсовыми силами, статистически занимают несколько возможных положений (накладываются один на другой). Наряду с атомами углерода в пространственной решетке кокса (особенно в ее периферийной части) могут располагаться гетероатомы (S, N, O) [5].

Строение и свойства каменноугольного кокса зависят от состава угольной шихты, конечной температуры и скорости нагрева коксующей массы. С увеличением содержания в шихте газовых и других углей, характеризующихся малой сте-




Рис. 1. Схема коксовой батареи  
Fig. 1. Scheme of coke oven battery

пению метаморфизма, понижением конечной температуры коксования и уменьшением выдержки при этой температуре, реакционная способность и горючесть получаемого кокса увеличивается. При повышении содержания газовых углей в шихте прочность и средняя крупность кусков кокса уменьшаются, а пористость его возрастает. Повышение конечной температуры коксования способствует увеличению прочности каменноугольного кокса, особенно к истиранию. При удлинении периода коксования и снижении скорости нагрева коксуемой массы средняя крупность кусков кокса увеличивается.

Коксовыталкиватель – это машина коксовой батареи предназначена для выталкивания кокса из печи.

Разрушения в кладке камер коксования, возникающие в процессе эксплуатации и не поддающиеся профилактическим ремонтам, приводят к утяжелению хода коксового пирога при его выдаче из печей; это устанавливается по возрастанию силы тока (ампеража), потребляемого мотором штанги коксовыталкивателя против нормативов, установленных для рассматриваемой конструкции печей (рис. 1).

Для контроля за выполнением графика выдачи ведется запись производственных показателей в реляционную базу данных: заданная норма выдачи, то есть число печей, из которых должен быть выдан кокс за смену; заданное и фактическое время выдачи кокса из каждой печи; масса шихты и время ее загрузки в каждую камеру; температура; позиция штанги и ампераж при выдаче [6].

Тугой ход коксового пирога сокращает срок службы печей, снижает их производительность, усложняет работу цеха. Своевременное выявление причин повышенного ампеража при выдаче кокса из камер является необходимым условием устранения возможности забуривания коксового пирога.

Чтобы выявить причины высоких показателей силы тока, необходимо разработать алго-

ритм, который соберет значения из разных баз данных производства и сделает как статистический анализ, так и графический.

Python — высокоуровневый язык программирования общего назначения с динамической строгой типизацией и автоматическим управлением памятью, ориентированный на повышение производительности разработчика, читаемости кода и его качества, а также на обеспечение переносимости написанных на нем программ [7].

Сначала на языке Python прописывается класс, при вызове которого будет создаваться связь с серверами и выгружаться необходимая информация (рис. 2).

Таким образом сохраняются показания датчиков и времени спекания коксового пирога. Следующим этапом идет подготовка нескольких миллионов записей и около десятка технологических признаков. Большое количество записей обусловлено высокой частотой фиксации состояния коксовой батареи [8].

Также не стоит забывать об одной из самых важных характеристик, от которой зависит качество получаемого продукта: марка угля, которую использовали для производства шихты. Отличие от других типов каменных углей, коксующиеся угли при нагревании без доступа воздуха становятся пластичными и подвергаются спеканию [9].

Коксующиеся угли имеют зольность менее 10 % и относительно низкое содержание серы (менее 3,5 %), выход летучих веществ ( $V_{daf}$ ) составляет 15 – 37 %. По способности к коксообразованию коксующиеся угли подразделяются на пять категорий (коксовые, жирные, отошенные коксовые, газовые, слабоспекающиеся) [10]. Для получения интересующих данных необходимо выгрузить журналы технологов коксохимического производства, в которых фиксируются марки угля. Они используются для получения более

```

class Dataload:
    def __init__(self, server, db, data_map):
        self.conn = pyodbc.connect(f'Driver=SQL Server;Server={server};Database={db};Trusted_Connection=yes;')
        self.data_map = data_map
        self.data = {}

    def load_table(self, table):
        data = pd.read_sql(f'SELECT * from {table}', con = self.conn)
        return data

    def load(self):
        for param in self.data_map:
            print('='*30)
            print(param)
            print(self.data_map[param])
            self.data[param] = self.load_table(table=self.data_map[param])
            print(self.data[param].columns)
            print(self.data[param].shape)
        return None

    def save(self, path):
        for param in self.data:
            self.data[param].to_feather(f'{path}{param}.feather')

```

Рис. 2. Подключение к базам данных  
Fig. 2. Connection to databases

подробных характеристик (процента зольности, влажности, выхода летучих веществ).

Для подготовки данных использовали средства языка Python и дополнительные пакеты программ (библиотеки) [11]. После прохождения основных этапов подготовки данных (замена или удаление выбросов, работа с пропусками данных, объединение большого количества матриц в одну общую, переименование признаков для удобства воспроизведения модели), был проведен так называемый процесс конструирования признаков (feature engineering) [12], а также рассчитан процент участия в коксовании тех или иных марок угля. Как правило, этот процент не меняется, но иногда происходят сбои. В связи с этим одной из задач является выявление таких сбоев [13].

Основные используемые методы при решении этой задачи относятся к разделу машинного обучения. Это класс методов искусственного интеллекта, характерной чертой которых является обучение за счет применения решений множества сходных задач [14]. Для построения таких методов используются средства математической статистики, численных методов, математического анализа, методов оптимизации, теории вероятностей, теории графов, различные техники работы с данными в цифровой форме. Различают два типа обучения [15]:

1 – обучение по прецедентам или индуктивное обучение, основанное на выявлении эмпирических закономерностей в данных;

2 – дедуктивное обучение (предполагает формализацию знаний экспертов и их перенос в компьютер в виде базы знаний).

Дедуктивное обучение принято относить к области экспертных систем, поэтому термины

машинное обучение и обучение по прецедентам можно считать синонимами.

При решении поставленной задачи в равной степени использовали оба типа обучения.

Многие методы индуктивного обучения разрабатывали как альтернативу классическим статистическим подходам. Многие методы тесно связаны с извлечением информации (англ. information extraction, information retrieval), интеллектуальным анализом данных (data mining).

Основу методов data mining составляют всевозможные методы классификации, моделирования и прогнозирования, основанные на применении деревьев решений, искусственных нейронных сетей, генетических алгоритмов, эволюционного программирования, ассоциативной памяти, нечеткой логики [16]. К методам data mining нередко относят статистические методы (дескриптивный, корреляционный и регрессионный, факторный, дисперсионный, компонентный, дискриминантный анализы, анализы временных рядов, выживаемости, связей). Такие методы предполагают некоторые априорные представления об анализируемых данных, что несколько расходится с целями data mining (обнаружение ранее неизвестных нетривиальных и практически полезных знаний) [17].

После выполнения всех вышеизложенных действий была получена следующая таблица (рис. 3, дата и время удалены для соблюдения правил безопасности предприятия).

На выходе получили таблицу (рис. 4) с размерами 66228 записи и 38 признаков. Для принятия каких-либо решений стоит также обратиться к статистике и рассчитать медианы, средние, максимальные и минимальные значе-

amper	position	full_time_in_minutes	temp_left	temp_right	концентрат	к кхп	кс кхп	ос кхп	флото-конц-т	...	A, %	Апл, %	V, %	S, %	X, мм	Y, мм	сит 6	сит 3-6
131.0	5.0	1113.0	1300.0	811.3	0	4	19.1	0	17	...	9	9.0	24.7	0.40	36.0	16.0	8.9	11.9
121.0	31.0	1113.0	1300.0	811.3	0	4	19.1	0	17	...	9	9.0	24.7	0.40	36.0	16.0	8.9	11.9
98.0	74.0	1113.0	1300.0	811.3	0	4	19.1	0	17	...	9	9.0	24.7	0.40	36.0	16.0	8.9	11.9
96.0	119.0	1113.0	1300.0	811.3	0	4	19.1	0	17	...	9	9.0	24.7	0.40	36.0	16.0	8.9	11.9
97.0	211.0	1113.0	1300.0	811.3	0	4	19.1	0	17	...	9	9.0	24.7	0.40	36.0	16.0	8.9	11.9

Рис. 3. Производственные характеристики  
Fig. 3. Production characteristics

ния. Удобным отображением является график box-plot («ящик с усами») [18].

Необходимо обратить внимание, что большая часть записей лежит в диапазоне от 100 до 120 А. Следовательно для решения поставленной задачи необходимо отфильтровать значения в нормальном диапазоне от завышенных. После этого следует проанализировать характеристики угля и показатели коксовой батареи [19].

После проведения всех манипуляций с данными было обращено внимание на следующий важный аспект: примерно 40 % всех аномалий приходились на один месяц в году. Были подняты все журналы с записями технологов и выяснилось, что это происходило после добавления угля одной определенной шахты. После полученных результатов все выводы были переданы компетентным сотрудникам углеподготовительного цеха [20].

### Выводы

Результатом объединения усилий технологов коксохимического производства и современных

методов обработки данных можно исследовать весь процесс изготовления продукции и находить нетривиальные проблемы в работе предприятия.

### СПИСОК ЛИТЕРАТУРЫ

1. Вегман Е.Ф., Жеребин Б.Н., Похвиснев А.Н. и др. *Металлургия чугуна* / под ред. Ю.С. Юсфина. 3-е изд., перераб. и доп. Москва: ИКЦ «Академкнига», 2004. 774 с.
2. *Начала металлургии* / под ред. В. И. Коротича. Екатеринбург: УГТУ, 2000. 392 с.
3. Vasant Dhar. *Data Science and Prediction // Communications of the ACM*. 2013. Vol. 56. No. 12. P. 64–73.
4. Cox David R. Some procedures connected with the logistic qualitative response curve. *Research Papers in Probability and Statistics (Festschrift for J. Neyman)*. London: Wiley, 1966. P. 55–71.
5. Бабарькин Н.Н. *Теория и технология доменного процесса*. Магнитогорск: ИЦ МГТУ, 2009. 257 с.
6. Скляр М.Г. *Интенсификация коксования и качество кокса*. Москва: Металлургия, 1976. 256 с.
7. Журавлев Ю.И., Рязанов В.В., Сенько О.В. *Распознавание. Математические методы. Программная система. Практические применения*. Москва: Фазис, 2006.
8. Загоруйко Н.Г. *Прикладные методы анализа данных и знаний*. Новосибирск: ИМ СО РАН, 1999.
9. *Анализ данных и процессов* / А.А. Барсегян, С. Куприянов, И.И. Холод, М.Д. Тесс, С.И. Елизаров. Санкт-Петербург: БХВ-Петербург, 2009. 512 с.
10. Кацко И.А., Паклин Н.Б. *Практикум по анализу данных на компьютере*. Москва: КолосС, 2009. 278 с.
11. Бринк Х., Ричардс Д., Феверолф М. *Машинное обучение*. Санкт-Петербург: Питер, 2017. 336 с.

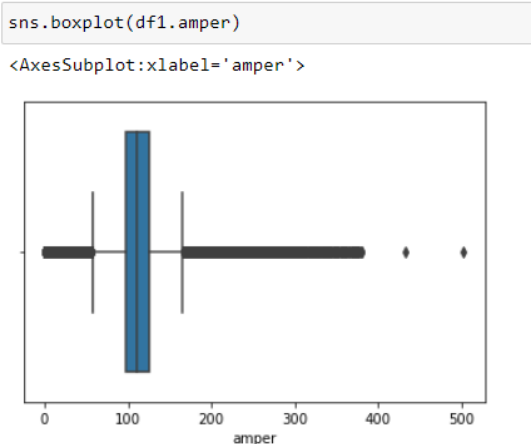


Рис. 4. Вох-plot (сила тока)  
Fig. 4. Вох-plot (amperage)

12. Шарден Б., Массарон Л., Боскетти А. Крупномасштабное машинное обучение вместе с Python. Санкт-Петербург: Питер, 2018, 180 с.
13. Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer-Verlag, 2009. 746 p.
14. Mitchell T. *Machine Learning*. McGraw-Hill Science/Engineering/Math, 1997.
15. Vapnik V.N. *Statistical learning theory*. N.Y.: John Wiley & Sons, Inc., 1998.
16. Bernhard Schölkopf, Alexander J. Smola *Learning with Kernels. Support Vector Machines, Regularization, Optimization, and Beyond*. MIT Press, Cambridge, MA, 2002.
17. Witten I.H., Frank E. *Data Mining: Practical Machine Learning Tools and Techniques (Second Edition)*. Morgan Kaufmann, 2005.
18. Liang Wang, Li Cheng, Guoying Zhao. *Machine Learning for Human Motion Analysis*. IGI Global, 2009. 318 p.
19. Witten I.H., Frank E., Hall M.A. *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann, 2011.
20. Smith F.J. Data Science as An Academic Discipline // *Data Science Journal*. 2006. Vol. 5. No. 19. P. 163–164.
10. Katsko I.A., Paklin N.B. *A workshop on data analysis on a computer*. Moscow: KolosS, 2009. 278 s. (In Russ.).
11. Brink Kh., Richards D., Feverolf M. *Machine learning*. St. Petersburg: Piter, 2017, 336 p. (In Russ.).
12. Sharden B., Massaron L., Bosketti A. *Large-scale machine learning with Python*. St. Petersburg: Piter, 2018, 180 p. (In Russ.).
13. Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer-Verlag, 2009. 746 p.
14. Mitchell T. *Machine Learning*. McGraw-Hill Science/Engineering/Math, 1997.
15. Vapnik V.N. *Statistical learning theory*. N.Y.: John Wiley & Sons, Inc., 1998.
16. Bernhard Schölkopf, Alexander J. Smola *Learning with Kernels. Support Vector Machines, Regularization, Optimization, and Beyond*. MIT Press, Cambridge, MA, 2002.
17. Witten I.H., Frank E. *Data Mining: Practical Machine Learning Tools and Techniques (Second Edition)*. Morgan Kaufmann, 2005.
18. Liang Wang, Li Cheng, Guoying Zhao. *Machine Learning for Human Motion Analysis*. IGI Global, 2009. 318 p.
19. Witten I.H., Frank E., Hall M.A. *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann, 2011.
20. Smith F.J. Data Science as An Academic Discipline. *Data Science Journal*. 2006, vol. 5, no. 19, pp. 163–164.

#### REFERENCES

1. Vegman E.F., Zherebin B.N., Pokhvisnev A.N. et al.; Yusfin Yu.S. ed. *Metallurgy of pig iron. 3rd ed., reprint. and add.* Moscow: IKTs «Akademkniga», 2004, 774 p. (In Russ.).
2. Korotich V.I. ed. *The beginnings of metallurgy*. Ekaterinburg: UGTU, 2000, 392 p. (In Russ.).
3. Vasant Dhar. Data Science and Prediction. *Communications of the ACM*. 2013, vol. 56, no. 12, pp. 64–73.
4. Cox David R. *Some procedures connected with the logistic qualitative response curve. Research Papers in Probability and Statistics (Festschrift for J. Neyman)*. London: Wiley, 1966, pp. 55–71.
5. Babarykin N.N. *Theory and technology of the domain process*. Magnitogorsk: ITs MGTU, 2009, 257 p. (In Russ.).
6. Sklyar M.G. *Intensification of coking and coke quality*. Moscow: Metallurgiya, 1976, 256 p. (In Russ.).
7. Zhuravlev Yu.I., Ryazanov V.V., Sen'ko O.V. *Recognition. Mathematical methods. Software system. Practical applications*. Moscow: Fazis, 2006. (In Russ.).
8. Zagoruiko N.G. *Applied methods of data and knowledge analysis*. Novosibirsk: IM SO RAN, 1999. (In Russ.).
9. Barsegyan A.A., Kupriyanov S., Kholod I.I., Tess M.D., Elizarov S.I. *Analysis of data and processes*. St. Petersburg: BKhV-Peterburg, 2009, 512 p. (In Russ.).

#### Сведения об авторах

**Александр Дмитриевич Байдалин**, ведущий инженер, АО «ЕВРАЗ Объединенный Западно-Сибирский металлургический комбинат»  
**E-mail:** alexander.baydalin@gmail.com

#### Information about the authors

**A.D. Baidalin**, traveling engineer, JSC "EVRAZ United West Siberian Metallurgical Combine"  
**E-mail:** alexander.baydalin@gmail.com

*Авторы заявляют об отсутствии конфликта интересов.  
 The authors declare that there is no conflict of interest.*

Поступила в редакцию 17.10.2022  
 После доработки 21.10.2022  
 Принята к публикации 27.10.2022

Received 17.10.2022  
 Revised 21.10.2022  
 Accepted 27.10.2022