

МЕТОД ОБРАБОТКИ ИНФОРМАЦИИ ДЛЯ ПРОГНОЗИРОВАНИЯ СТЕПЕНИ ВОССТАНОВЛЕНИЯ МЕТАЛЛОВ НА ОСНОВЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

Статья посвящена проблеме обеспечения достоверности информации о качестве продукции металлургических предприятий, связанных с производством металлов. Важным индикатором качества процесса получения металла из руды является степень металлизации. В работе предложен метод прогнозирования степени металлизации в процессе восстановления металла из различных соединений, основанный на использовании нейросетевых технологий. Целью работы является разработка алгоритмов, позволяющей с высокой точностью определять степень металлизации в зависимости от значений параметров процесса восстановления. Нейронная сеть, представленная в работе, включает обработку информации с помощью стратегий стохастического градиентного спуска, адаптивной оценки момента и обратного распространения ошибки. Предложенный комбинированный подход позволяет значительно повысить точность прогнозирования степени металлизации и обеспечить достоверность информации о реальной структуре металла, восстановленного из различных соединений. Достоверность информации, получаемой с помощью разработанной нейронной сети о степени металлизации, подтверждается результатами экспериментальных исследований.

Ключевые слова: достоверность информации, нейронная сеть, обратное распространение ошибки, стохастический градиентный спуск, задача прогнозирования.

INFORMATION PROCESSING METHOD FOR FORECASTING THE DEGREE OF METAL RECOVERY BASED ON NEURAL NETWORK TECHNOLOGIES

The article is devoted to the problem of ensuring the reliability of information on the quality of products manufactured by metallurgical enterprises. An important indicator of the quality of the process of obtaining metal from ore is the degree of metallization. The article proposes a method for predicting the degree of metallization in the process of metal recovery from various compounds, based on the use of neural network technologies. The purpose of the work is to develop algorithms that allow for highly accurate prediction of the degree of metallization based on the parameters of the recovery process. The neural network presented in the work includes information processing using stochastic gradient descent, adaptive moment estimation, and backpropagation strategies. The proposed combined approach can significantly improve the accuracy of predicting the degree of metallization and ensure the reliability of information on the real structure of metal recovered from various compounds. The reliability of the information obtained using the developed neural network on the degree of metallization is confirmed by the results of experimental studies

Keywords: information reliability, neural network, error backpropagation, stochastic gradient descent, forecasting issue..

Введение

При промышленном получении металла одним из ключевых индикаторов эффективности процесса восстановления металлов из руд или других источников является степень металлизации, показывающая объем металла, который была успешно переведен из исходного сырья в целевой продукт. Достоверность информации о степени восстановления способствует повышению точности оценки качества конечного продукта и обеспечивается созданием высокоточных методов, позволяющих распознать скрытую зависимость степени металлизации от значений параметров технологического процесса.

Создание и совершенствование нейросетевых технологий для решения прикладных задач, возникающих в промышленном производстве, относится к динамически развивающимся областям исследования [1-12]. Среди работ, связанных с использованием нейрон-

ных сетей для решения практических задач металлургии, отметим работу П.И. Аверина [13], в которой предложена нейронная сеть, созданная на основе радиальных базисных функций и позволяющая определить времени разрушения металлов на основе данных вейвлет-анализа импульсов акустической эмиссии. В работе А.С. Львова [14] предложен подход, позволяющий за счет выбора оптимального метода интерполяции повысить быстродействие нейронной сети, используемой для многопараметрического контроля состояния технологического процесса в металлургии. Разработке нейронной сети, оценивающей степень влияния химического состава металла на свойства стали и предназначенной для определения химического состава легирующего комплекса в процессе получения металлических сплавов посвящена работа И.Х. Тухватулина [15]. Отметим, что в настоящий момент остается нерешенной про-

блема определения по параметрам технологического процесса количества металла в конечном продукте, получаемого по завершении процесса выделения металлической компоненты из исходного материала. Таким образом, создание метода, направленного на выявление скрытой зависимости степени металлизации от значений параметров технологического процесса восстановления металла, относится к актуальному направлению исследований.

В данной статье предложена нейронная сеть, предназначенная для прогнозирования степени металлизации в зависимости от значений параметров технологического процесса восстановления металла из различных соединений. Основные преимущества предлагаемого метода заключается в том, что он позволяет определять степень металлизации с высокой точностью, используя для этого достаточно небольшой объем вычислительных ресурсов, и исключает трудоемкую процедуру аналитического выявления зависимости степени металлизации от значений параметров процесса восстановления, сопряженную с созданием многопараметрической математической модели и разработкой сложных вычислительных алгоритмов из процесса обработки информации.

Построение нейросетевой модели

Входными параметрами для нейросетевой модели процесса восстановления металла являются значения температуры, продолжительности процесса восстановления, состава восстановителя, массы образца. Исходные данные для обучающей и тестовой выборки формируются по оптическим изображениям поверхностей шлифов. Специфика рассматриваемой задачи восстановления металла заключается в малом объеме исходных данных, возникающей в силу сложности подготовки шлифов для экспериментального исследования. При малом объеме исходных данных возможна ситуация, когда обучающая и тестовая выборка окажутся неравномерно разделенными, и тогда точность нейронной сети, достигнутая на тестовых данных, будет существенно отличаться от точности обученной модели, что неизбежно приведет к искажению информации о точности обработки реальных данных с помощью этой сети. Для решения проблемы малого объема исходных данных в предлагаемой

нейросетевой модели применяли аугментацию исходных данных.

Выборка изображений делится на 3 компонента в следующем соотношении: обучающая – 70 %, валидационная (проверочная) и тестовая – по 15 %. Обучающая выборка используется непосредственно в процессе обучения и является основной, проверочная часть датасета – для оптимизации гиперпараметров сети и исключения переобучения, тестовая – для оценки качества работы сети.

В предлагаемой нейронной сети функционирование нейрона k представлено следующими уравнениями:

$$u_k = \sum_{m=1}^m w_{km} x_m,$$

$$Y_k = \varphi(u_k + b_k),$$

где $x_1, x_2, \dots, x_m$ – значения входных параметров, $w_{k1}, w_{k2}, \dots, w_{km}$ – синаптические веса нейрона k ; u_k – линейная комбинация входных воздействий; b_k – порог; $\varphi(\cdot)$ – функция активации; Y_k – выходной сигнал нейрона.

Определения степени металлизации осуществляется на основе численных значений следующих параметров процесса восстановления металлов:

X_1 – процентная доля диоксид углерода в восстановителе;

X_2 – процентная доля монооксид углерода в восстановителе;

X_3 – процентная доля водорода в восстановителе;

X_4 – температура печи, в которой происходит восстановление металла;

X_5 – продолжительность процесса восстановления;

X_6 – масса образца до восстановления;

X_7 – масса образца после восстановления.

Параметры $X_i, i=1, \dots, 7$ определяют входные данные для нейронной сети, а выходной параметр нейронной сети Y соответствует степени восстановления металла в целевом продукте. Разработка структуры искусственной нейронной сети осуществлялась на основе экспериментальных исследований. Программная реализация проводилась на языке программирования Python с применением программных платформ Keras, TensorFlow, Pandas, Scikit-Learn.

В процессе формирования структуры сети подбирались различные комбинации значений гиперпараметров, представленных в таблице 1. В общей сложности было рассмотрено 243 различных комбинаций.

Гиперпараметры нейронной сети

Гиперпараметр	Варианты значений гиперпараметров		
Функция активации	Линейная функция	Сигмоида	ReLU
Количество эпох	5	10	35
Оптимизатор	Стохастический градиентный спуск (SGD), скорость обучения = 0.1	Адаптивная оценка момента (Adam), со скоростью обучения 0.1	Распространение среднеквадратичного значения (RMSProp) со скоростью обучения 0.1

Таким образом, для определения степени металлизации в зависимости от параметров процесса восстановления металлов предлагается многослойная нейронная сеть с последовательными слоями и полными связями между ними (модель Sequential или многослойный персептрон).

Результаты экспериментальных исследований

Формирования оптимальной структуры нейронной сети и определении набора гиперпараметров, позволяющего минимизировать значение функции потерь, осуществлялась на основе обработки оптических изображений различных проекций поверхности шлифов. В качестве функции потерь использовалась среднеквадратическая ошибка (MSE). Первый этап экспериментов связан с выбором наилучшей структуры нейронной сети. Результаты этого этапа представлены в табл. 2, 3 В табл. 2 приведены первые 7 комбинаций гиперпараметров. Комбинаций гиперпараметров с минимальными значениями функции потерь приведены в табл. 3.

В результате исследований сформирована следующая структура нейронной сети: входной слой состоит из 128 нейронов с функцией активации «ReLU», сеть включает один скрытый слой из 64 нейронов с функцией активации «ReLU», выходной слой состоит из одного нейрона с функцией активации «Linear». Оптимизатором сети является RMSProp.

Второй этап экспериментальных исследований предусматривал оценку качества работы нейронной сети, сформированной в результате первого этапа экспериментальных исследований. После проектирования и обучения искусственной нейронной сети с оптимальными параметрами на каждом слое установились веса. Основными показателями качества работы модели искусственной нейронной сети являются оценка точности работы нейронной сети и функция потерь. График функции потерь, используемой для расчета отклонений фактических результатов работы нейронной сети от ожидаемых при разном количестве эпох обучения, представлен на рисунке 1. Наименьшее значение функция

Таблица 2

Комбинаций гиперпараметров

№	Слой 1	Слой 2	Слой3	Оптимизатор	Кол-во эпох	Функция потерь при проверке
1	sigmoid	sigmoid	sigmoid	adam	5	0.99942
2	sigmoid	sigmoid	sigmoid	SGD	5	1.06434
3	sigmoid	sigmoid	sigmoid	RMSProp	5	0.99108
4	sigmoid	sigmoid	sigmoid	adam	20	0.75984
5	sigmoid	sigmoid	sigmoid	SGD	20	1.02163
6	sigmoid	sigmoid	sigmoid	RMSProp	20	0.76925
7	sigmoid	sigmoid	sigmoid	adam	35	0.68400

Оптимальные значения гиперпараметров

№	Слой 1	Слой 2	Слой3	Оптимизатор	Кол-во эпох	Значения функции потерь
233	relu	relu	linear	RMSProp	35	0.01195
231	relu	relu	linear	adam	35	0.01203
150	linear	relu	linear	adam	35	0.01334
204	relu	linear	linear	adam	35	0.01603
147	linear	relu	linear	adam	20	0.01693
201	relu	linear	linear	adam	20	0.01800
228	relu	relu	linear	adam	20	0.02032

потерь достигала к 35 эпохе обучения. Таким образом, для получения наилучшей точности разработанной нейронной сети достаточно 35 эпох обучения.

Оценка точности работы нейронной сети производилась с помощью коэффициента детерминации, максимально возможное значение которого не превосходит единицы. Для разработанной нейронной сети значение коэффициента детерминации, полученное к 35 эпохе обучения, составило 0.9915, что свидетельствует о высокой точности результатов прогнозирования степени металлизации. На рис. 2 предоставлено соотношение числа верных предсказаний прогнозируемых значений к общему числу прогнозов: чем ближе

точка расположена к прямой линии, тем точнее нейронная сеть обработала исходные данные и спрогнозировала степень металлизации.

Результаты эксперимента свидетельствуют о том, что построенная нейронная сеть обладает высокой точностью при малых значениях функции потерь и обеспечивает достоверность информации о степени металлизации в процессе восстановления металла из различных сред. Достоинство нейросетевого подхода заключается в отсутствии необходимости создавать сложные математические модели зависимости степени металлизации от параметров процесса восстановления.




Рис. 1. График функции потерь




Рис. 2. График соотношения предсказанных значений от фактических

Заключение

В работе предложен метод обработки информации, созданный на основе нейросетевых технологий и предназначенный для прогнозирования степени металлизации по значениям параметров процесса восстановления металла. Обучение нейронной сети происходит с помощью стратегий исследования.

Найдена оптимальная архитектура нейронной сети. Результаты экспериментальных исследований подтверждают высокую точность обработки информации с помощью предложенного метода и свидетельствуют о том, что нейронная сеть позволяет обеспечить достоверность информации о степени восстановления металлов из различных соединений.

Литература

1. Kohavi, R. A study of cross-validation and bootstrap for accuracy estimation and model selection / R. Kohavi // Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence. San Mateo, 1995. – Vol. 2, № 12. – P. 1137–1143.
2. Hinton G. Dropout: A Simple Way to Prevent Neural Networks from Overfitting / G. Hinton et al. // Journal of Machine Learning Research. – 2014. – Vol. 15. – P. 1929–1958.
3. Krizhevsky, A. Imagenet classification with deep convolutional neural networks / A. Krizhevsky, I. Sutskever, G. Hinton // Proceedings of the 25th International Conference on Neural Information Processing Systems, NIPS. – 2012. – P. 1097–1105.
4. Diederik, P. Kihgma. Adam: A method for Stochastic Optimization, 2014 / Diederik P. Kihgma, Jimmy Ba // Proceedings of the 3rd International Conference on Learning Representations (ICLR).
5. Goodfellow I., Bengio Y., Courville A. Deep learning. Genet Program Evolvable Mach, 2018, vol. 19, pp. 305–307. DOI: 10.1007/s10710-017-9314-z.
6. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks. Communications of the ACM, 2017, vol. 60, no. 6, pp. 84–90. DOI: 10.1145/3065386.
7. Япаров, Д. Д. оценка метода восстановления входного сигнала по зашумленным данным / Д. Д. Япаров // Вестник УрФО. Безопасность в информационной сфере. – 2022. – № 4(46). – С. 32–38. – DOI 10.14529/secur220404. – EDN ZATSLM.
8. Yaparova, N. M. Mathematical modelling and method for solving a parametric identification problem for self-test of measuring devices / N. M. Yaparova // Inverse Problems in Science and Engineering. – 2016. – Vol. 24, No. 1. – P. 77–91. – DOI 10.1080/17415977.2015.1017482. – EDN NCXSNG.
9. Russakovsky O., Deng J., Su H. et al. ImageNet large scale visual recognition challenge. Int. J. of Computer Vision, 2015, vol. 115, no. 3, pp. 211–252. DOI: 10.1007/s11263-015-0816-y.
10. Sutton R.S., Barto A.G. Reinforcement Learning: An Introduction. Cambridge, The MIT Press, 2014, 338 p. 5. Silver D., Huang A., Maddison C.J. et al. Mastering the game of Go with deep neural networks and tree search. Nature, 2016, vol. 529, no. 7587, pp. 484–489. DOI: 10.1038/nature16961.
11. Mingxing T., Quoc V.L. EfficientNet: Rethinking model scaling for convolutional neural networks. ArXiv, 2019, art. 1905.11946v5. URL: <https://arxiv.org/pdf/1905.11946.pdf> (дата обращения: 17.06.2022).
12. Abdolmaleki A., Springenberg J.T., Degraeve J. et al. Relative entropy regularized policy iteration. ArXiv, 2018, art. 1812.02256. URL: <https://arxiv.org/abs/1812.02256> (дата обращения: 18.06.2022).
13. Аверин П. И., Мельников Б. Ф. Вариант решения задачи прогнозирования признаков разрушения металлов с помощью нейронных сетей на основе данных вейвлет-анализа импульсов акустической эмиссии // Современные информационные технологии и ИТ-образование. 2011. №7.
14. Львов А. С. Повышение быстродействия в обучении нейронной сети многопараметрическому контролю процессов в металлургии на базе вычислителей низкой конфигурации / А. С. Львов, А. В. Полянский // Вестник Череповецкого государственного университета. 2010. №3.
15. Тухватулин И. Х. Оптимизация состава износостойких сплавов с помощью нейросетей / И. Х. Тухватулин, Л. Б. Долгополова, В. М. Колокольцев, Ю. П. Ланкин // Литейные процессы: Межрегиональный сб. науч. тр. Магнитогорск: МГТУ, 2000. – С. 40–43.

References

1. Kohavi, R. A study of cross-validation and bootstrap for accuracy estimation and model selection / R. Kohavi // Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence. San Mateo, 1995. – Vol. 2, № 12. – P. 1137–1143.
2. Dropout: A Simple Way to Prevent Neural Networks from Overfitting / G. Hinton et al. // Journal of Machine Learning Research. – 2014. – Vol. 15. – P. 1929–1958.
3. Krizhevsky, A. Imagenet classification with deep convolutional neural networks/ A. Krizhevsky, I. Sutskever, G. Hinton // Proceedings of the 25th International Conference on Neural Information Processing Systems, NIPS. – 2012. – P. 1097–1105.
4. Diederik, P. Kihgma. Adam: A method for Stochastic Optimization, 2014 / Diederik P. Kihgma, Jimmy Ba // Proceedings of the 3rd International Conference on Learning Representations (ICLR).
5. Goodfellow I., Bengio Y., Courville A. Deep learning. Genet Program Evolvable Mach, 2018, vol. 19, pp. 305–307. DOI: 10.1007/s10710-017-9314-z.
6. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks. Communications of the ACM, 2017, vol. 60, no. 6, pp. 84–90. DOI: 10.1145/3065386.

7. Yaparov, D. D. Ocenka metoda vosstanovleniya vkhodnogo signala po zashumlennym dannym / D. D. Yaparov // Vestnik URFO. Bezopasnost' v informacionnoj sfere. – 2022. – № 4(46). – S. 32-38. – DOI 10.14529/secur220404. – EDN ZATSLM.
8. Yaparova, N. M. Mathematical modelling and method for solving a parametric identification problem for self-test of measuring devices / N. M. Yaparova // Inverse Problems in Science and Engineering. – 2016. – Vol. 24, No. 1. – P. 77-91. – DOI 10.1080/17415977.2015.1017482. – EDN NCXSNQ.
9. Russakovsky O., Deng J., Su H. et al. ImageNet large scale visual recognition challenge. Int. J. of Computer Vision, 2015, vol. 115, no. 3, pp. 211–252. DOI: 10.1007/s11263-015-0816-y.
10. Sutton R.S., Barto A.G. Reinforcement Learning: An Introduction. Cambridge, The MIT Press, 2014, 338 p. 5. Silver D., Huang A., Maddison C.J. et al. Mastering the game of Go with deep neural networks and tree search. Nature, 2016, vol. 529, no. 7587, pp. 484–489. DOI: 10.1038/nature16961.
11. Mingxing T., Quoc V.L. EfficientNet: Rethinking model scaling for convolutional neural networks. ArXiv, 2019, art. 1905.11946v5. URL: <https://arxiv.org/pdf/1905.11946.pdf> (дата обращения: 17.06.2022).
12. Abdolmaleki A., Springenberg J.T., Degraeve J. et al. Relative entropy regularized policy iteration. ArXiv, 2018, art. 1812.02256. URL: <https://arxiv.org/abs/1812.02256> (дата обращения: 18.06.2022).
13. Averin P. I., Mel'nikov B. F. Variant resheniya zadachi prognozirovaniya priznakov razrusheniya metallov s pomoshh'yu nejronny'x setej na osnove danny'x vejvlet-analiza impul'sov akusticheskoy e'missii // Sovremennyye informacionny'e tekhnologii i IT-obrazovanie. 2011. №7.
14. L'vov A. S. Povy'shenie by'strodejstviya v obuchenii nejronnoj seti mnogopara-metriceskomu kontrolyu processov v metallurgii na baze vy'chislitelej nizkoj konfiguracii / A. S. L'vov, A. V. Polyanskij // Vestnik Cherepoveczkogo gosudarstvennogo universiteta. 2010. №3.
15. Tuxvatulin I. X. Optimizaciya sostava iznosostojkix splavov s pomoshh'yu nejrosetej / I. X. Tuxvatulin, L. B. Dolgoplova, V. M. Kolokol'cev, Yu. P. Lankin // Li-tejny'e processy: Mezhhregional'ny'j sb. nauch. tr. Magnitogorsk: MGUTU, 2000. – S. 40-43.

ЯПАРОВ Дмитрий Данилович, старший преподаватель кафедры математического обеспечения информационных технологий, ФГАОУ ВО «Южно-Уральский государственный университет (национальный исследовательский университет)». 454080, г. Челябинск, проспект Ленина, д. 76. E-mail: iaparovdd@susu.ru

КАРМАНОВ Дмитрий Евгеньевич, инженер кафедры математического обеспечения информационных технологий, ФГАОУ ВО «Южно-Уральский государственный университет (национальный исследовательский университет)». 454080, г. Челябинск, проспект Ленина, д. 76. E-mail: karmanovde@susu.ru

ЯПАРОВА Наталья Михайловна, доктор технических наук, доцент, заведующий кафедрой математического обеспечения информационных технологий ФГАОУ ВО «Южно-Уральский государственный университет (национальный исследовательский университет)». 454080, г. Челябинск, проспект Ленина, д. 76. E-mail: iaparovannm@susu.ru

YAPAROV Dmitriy Danilovich, Senior Lecturer of Mathematical Foundation of Information Technologies Department, Federal State Autonomous Educational Institution of Higher Education «South Ural State University (national research university)». 454080, Chelyabinsk, Lenin prospekt, 76. E-mail: iaparovdd@susu.ru

KARMANOV Dmitriy Danilovich, engineer of Mathematical Foundation of Information Technologies Department, Federal State Autonomous Educational Institution of Higher Education «South Ural State University (national research university)». Russia, 454080, Chelyabinsk, Lenin prospekt, 76. E-mail: karmanovde@susu.ru

YAPAROVA Natalia Mikchailovna, Dr.of Sci, Associate Professor, Head of Department of Mathematical Foundation of Information Technologies, Federal State Autonomous Educational Institution of Higher Education «South Ural State University (national research university)». Russia, 454080, Chelyabinsk, Lenin prospekt, 76. E-mail: iaparovannm@susu.ru