

УДК 621.745.56:666.9.012

АНАЛИЗ И КЛАССИФИКАЦИЯ ЗАМЕРОВ ТЕМПЕРАТУРЫ, ВЫПОЛНЕННЫХ В ПРОЦЕССЕ ПЛАВКИ И РАЗЛИВКИ СПЛАВОВ С ПРИМЕНЕНИЕМ НЕЙРОННЫХ СЕТЕЙ

Федосов А.В.^{1,2}, к.т.н., доцент кафедры «Технологии формообразования
и художественная обработка материалов» (fedosov-sol@mail.ru)

Чумаченко Г.В.¹, к.т.н., доцент, заведующий кафедрой «Технологии формообразования
и художественная обработка материалов» (gchumachenko@dstu.edu.ru)

¹ Донской государственный технический университет
(344010, Россия, Ростов-на-Дону, пл. Гагарина, 1)

² ООО «Ростовский литейный завод»
(344029, Россия, Ростов-на-Дону, ул. Менжинского, 2)

Аннотация. Рассмотрены вопросы организации мониторинга тепловых режимов выплавки и разлива сплавов для литейных предприятий.

Отмечено, что наиболее надежным является способ, когда проведение замеров и фиксирование температуры возлагается на рабочего. С другой стороны, полностью автоматический подход не всегда доступен для небольших литейных предприятий. В связи с этим, показана целесообразность применения автоматизированного подхода, при котором проведение замеров возлагается на рабочего, а фиксирование значений производится автоматически. Такой способ предполагает реализацию алгоритма автоматической классификации температурных замеров на основе сквозного массива данных, полученных в производственном потоке. Решение поставленной задачи разделено на три этапа. На первом этапе производится подготовка исходных данных к процессу классификации. На втором этапе решается задача классификации замеров с использованием принципов искусственных нейронных сетей. Анализ результатов работы искусственной нейронной сети показал ее высокую эффективность и степень соответствия результатов анализа с фактической ситуацией на рабочей площадке. Так же отмечается, что применение принципов искусственных нейронных сетей позволяет сделать процесс классификации гибким, благодаря возможности легко дополнить процесс новыми параметрами и нейронами. Заключительным этапом является анализ полученных результатов. Корректно проведенная классификация данных предоставляет возможность не только проводить оценку соблюдения технологической дисциплины на участке, но и улучшить процесс выявления причин образования брака литья. Применение предложенного подхода позволяет снизить влияние человеческого фактора в процессе анализа тепловых режимов плавки и разлива сплавов при минимальных затратах на обеспечение мониторинга плавки.

Ключевые слова: температура, сплав, отливка, искусственная нейронная сеть, классификация, тепловой режим, плавка, разлива, человеческий фактор.

DOI: 10.17073/0368-0797-2020-10-856-861

Температура в печи на выпуске и при заливке сплавов оказывает значительное влияние на образование целого ряда дефектов в литых заготовках. Высокая температура сплава способствует образованию усадочных раковин, холодных и горячих трещин, несоответствию механических свойств и других, прямо или косвенно связанных дефектов. Выпуск металла с недостаточной температурой приводит к образованию недоливов, спавев, ухудшению условий удаления газов из сплава, а также к несоответствию макро- и микроструктуры [1 – 4]. Поэтому организация достоверного контроля теплового состояния сплава жизненно необходима в литейном производстве.

На сегодняшний день наиболее технологичным и точным способом температурных измерений является метод погружной термопары [5 – 7]. Измерение температуры жидких сталей и чугунов, как правило, осуществляется в виде разовых актов в определенные технологические периоды. При этом отдельное внима-

ние следует уделить вопросу фиксирования показаний термопары, которое может производиться как вручную, так и автоматически [8 – 10]. Ручной подход предполагает вовлечение рабочего в процесс визуального фиксирования показаний прибора с дальнейшим вводом значений в заводскую базу данных. Применение такого подхода не позволит минимизировать риски, связанные с наличием человеческого фактора и не соответствует современной концепции организации производства. Реализация автоматического способа фиксирования температуры предполагает решение вопроса привязки получаемых значений к участку проведения измерений, что, как правило, решается установкой дополнительных измерительных блоков на каждом участке с их подключением к заводской сети. В данном случае минимизируется неоднозначность процесса фиксирования, но при этом возрастает общая стоимость процесса контроля. Применительно к крупномасштабным металлургическим производствам данный подход без-

условно оправдан, но в литейных цехах с относительно небольшими плавильными агрегатами в несколько тонн и компактными производственными площадками, увеличение парка измерительных блоков может оказаться экономически и технологически нерационально. В этом случае несомненный интерес представляет подход, который позволит минимизировать человеческий фактор на этапе фиксирования значений температуры, но при этом не потребует увеличения парка измерительных приборов.

Целью работы является разработка и реализация способа автоматической классификации температурных замеров на основе сквозного массива данных, полученных в производственном потоке с помощью одного измерительного блока.

В современном металлургическом и литейном производстве все большее применение находят системы интеллектуального анализа данных. Их внедрение позволяет реализовать целый ряд сложных задач по автоматизации, управлению и анализу производственных процессов [11 – 16]. Отдельно следует выделить класс задач по классификации данных, решение которых либо стало возможным только благодаря применению интеллектуальных систем, либо вывело результаты работы на новый качественный уровень. Ярким примером является применение систем распознавания образов для производственных целей, реализация которых успешно базируется на искусственных нейронных сетях (ИНС) [17 – 20].

При решении поставленной задачи также предлагается использовать уже хорошо зарекомендовавшие себя принципы ИНС. Для этого общую постановку задачи необходимо разбить на три этапа.

1. Подготовка исходных данных и формирование пространства признаков.

2. Классификация замеров.

3. Анализ теплового режима плавки.

Целью первого этапа является формирование множества параметров, по которым будет производиться классификация. Исходными данными, влияющими на принятие решения классификации, являются значения температуры и времени проведения замера. В зависимости от эксплуатируемого измерительного оборудования пользователь может получать либо готовый пакет данных – номер замера/время/температура, либо непрерывный поток значений температуры, записанный с заданной дискретностью. Во втором случае данные необходимо предварительно обработать с целью выделения истинной температуры замера. Для этой цели используются различные алгоритмы анализа термограмм, позволяющие выделить площадку термического равновесия [10], значение которой соответствует температуре замера.

Исходных параметров (время и температура) недостаточно для проведения корректной классификации. Для решения этой проблемы необходимо увеличить

размерность пространства признаков при условии соблюдения непротиворечивости параметров. Так, исходный массив замеров дополняется значениями разности между текущей и предыдущей записями (Δt , ΔT), скоростью изменения температуры ($\Delta T/\Delta t$), порядковым номером плавки и кодом, отражающим порядок замера в пределах плавки и признак дублирующего замера.

Для назначения номера плавки используется простой счетчик, срабатывающий по условию превышения значения Δt некоторого порога, отражающего интервал между плавками. Время плавки гарантировано превышает любые другие технологические интервалы, которые являются ее составными частями. В зависимости от технологического процесса время плавки в литейных цехах может быть от одного часа и более. В то же время процесс доводки металла, после его расплавления, стараются свести к минимуму, и время между последующими технологическими операциями редко превышает 10 – 15 мин.

Код замера вводится для его предварительной идентификации. При этом выделяются первый, последний и дублирующие замеры плавки. Согласно технологическому регламенту проведения замеров их должно быть, как минимум, два: замер в печи и замер в ковше. Замер в печи показывает готовность металла и служит сигналом к его выпуску. Замер в ковше подтверждает корректность всех технологических операций по выпуску металла и подготовке ковша и показывает готовность металла к разливке. В дальнейшем, при строгом соблюдении регламента разливки, повторное проведение замеров в ковше не требуется. Таким образом, существует высокая вероятность того, что первый замер плавки – это замер, проведенный в печи, а последний замер – в ковше.

Следует сразу отметить, что классификация при наличии только одного замера в плавке невозможна. Такие плавки проведены с нарушением регламента контроля технологических параметров и должны быть рассмотрены отдельно с выявлением причин нарушения. Кроме того, первый замер плавки всегда будет приниматься за замер, произведенный в печи.

Дублирующий замер производится при возникновении сомнений в корректности показаний. Например, если показания температуры после подогрева металла оказались ниже первоначальных значений, весьма вероятно, что замер выполнен некорректно и требуется повтор. Причины некорректных показаний могут быть связаны как с работой прибора, так и с техникой проведения замеров. Большой объем дублирующих замеров указывает либо на необходимость проверки оборудования, либо на неквалифицированные действия сталевара. Назначение кода дублирующего замера определяется временем, необходимым для выполнения дубля и производится при условии, что Δt меньше минимального технологически обоснованного интервала. При проведении дубля сталевар должен произвести

замену сменного наконечника термопары и повторить замер. Современные приборы позволяют осуществить это за 20 – 30 с [10]. Существенных изменений в ванне печи за такой короткий промежуток времени не происходит, в связи с чем проводить замеры с такой частотой технологически нецелесообразно. Следовательно, если интервал менее 30 с, можно уверенно утверждать, что данный замер является дублирующим. В дальнейшем анализе в расчет принимается значение температуры последнего дубля, при этом предыдущие, «сомнительные» значения игнорируются.

Задача классификации замеров реализована на базе ИНС с архитектурой простой однослойный персептрон [21]. При этом применяются как пороговые, так и линейные функции активации элементов сети. Нормирование значений входных параметров обеспечивает универсальность применения ИНС, однако модель в этом случае получается абстрагированной от исследуемых процессов и трудно поддается описанию с точки зрения взаимодействия входных и выходных параметров. Если опустить этап нормирования, модель работы небольшой ИНС может быть проанализирована с позиции технологии процесса, а применяемые пороговые значения приобретают технологический смысл и могут быть непосредственно назначены из регламентирующей документации.

Рассмотрим работу предложенной ИНС. Значения признаков (табл. 1) поступают на входной слой нейронов, активация которых производится согласно соответствующим пороговым значениям. В результате внутренний слой ИНС получает состояние активации, которое в зависимости от типа нейрона принимает дискретные 0 и 1 или действительное число от 0 до 1. Во внутреннем слое состояния активации умножаются на соответствующие весовые коэффициенты, после чего сигналы поступают на сумматор, который выпол-

няет роль выходного слоя, представляющего результат работы ИНС. Как было отмечено ранее, пороговые значения активации нейронов могут быть назначены в соответствии с регламентом и физикой технологического процесса. Определение же весовых коэффициентов является задачей обучения ИНС.

Рассмотрим логику назначения пороговых значений и работу нейронов сети. Первая пара нейронов отражает порядок замера в процессе плавки. По сути «код замера» в табл. 1 и есть состояние активации первой пары нейронов. Знак значений, поступающих на сумматор после умножения на весовые коэффициенты, указывает на то, в какую сторону будет смещен баланс процесса классификации. Отрицательные значения выходного слоя указывают на то, что замер был выполнен в печи, положительные на замер в ковше. Нулевое или близкое к нулю значение говорит о том, что сеть «не уверена» в своем ответе, и, соответственно, чем больше модуль значения, тем выше «уверенность» в корректности классификации.

Обработка параметра Δt заключена в трех нейронах с использованием порога «время выпуска». Значение данного порога отражает минимальный интервал, за который выполняются все необходимые операции по подготовке к выпуску и, собственно, по выпуску сплава. Это минимально возможное время между замером, выполненным в печи, и последующим замером в ковше. Первый нейрон активируется при выполнении двух условий: значение Δt не превышает порог «время выпуска» и предыдущий замер был выполнен в печи. В этом случае активность нейрона с высокой вероятностью указывает на принадлежность замера к печи. Второй и третий нейроны введены в противовес первому и отражают оставшиеся варианты: интервал больше порогового значения и интервал меньше порогового значения, но при этом предыдущий замер был выполнен в ковше.

Таблица 1

Пример подготовки вектора признаков для классификации замеров

Table 1. An example of preparing a feature vector for measurements classification

Номер замера	Дата – время	T , °C	Δt , ч:мин:с	ΔT , °C	$\Delta T/\Delta t$, °C/мин	Номер плавки	Код замера
1	24.01.19 – 9:39:16	1619,7	–	–	–	1	–1
2	24.01.19 – 9:47:51	1771,9	0:08:35	152,2	17,73	1	0
3	24.01.19 – 9:48:58	1755,9	0:01:07	–16,0	–14,33	1	0
4	24.01.19 – 9:53:26	1715,9	0:04:28	–40,0	–8,96	1	0
5	24.01.19 – 9:57:08	1644,1	0:03:42	–71,8	–19,41	1	1
6	09.01.18 – 15:58:32	1706,5	4:31:35	13,4	0,05	2	–1
7	09.01.18 – 16:04:31	1656,8	0:05:59	–49,7	–9,94	2	1
8	09.01.18 – 18:40:09	1684,2	2:35:38	27,4	0,18	3	–1
9	10.01.18 – 10:05:42	1696,6	15:25:33	12,4	0,01	4	–1
10	10.01.18 – 10:13:50	1654,5	0:08:08	–42,1	–5,26	4	1

Для оценки параметра «изменение температуры ΔT » также задействовано три нейрона. Первый отражает тот факт, что процесс выпуска сплава из печной установки в ковш сопровождается значительными тепловыми потерями и резким уменьшением температуры сплава. Пороговое значение в этом случае будет динамически зависеть от температуры выпускаемого сплава. Чем выше температура сплава, тем выше тепловые потери, и тем больше модуль порога. Для определения его величины предлагается использовать полином второго порядка, где в качестве независимой переменной используется значение температуры сплава из предыдущего замера (температура сплава в печи перед выпуском). Определение коэффициентов уравнения производится на основании фактических данных мониторинга технологического процесса. Линия уравнения должна подчеркивать минимальные значения перепада температуры сплава в процессе его выпуска из печи. Пример уравнения, построенного для условий выпуска стали из ДСП-3, приведен на рис. 1.

Положительный знак величина ΔT принимает в случае нагрева сплава, что технически возможно только в печи. Так, второй нейрон активируется, если ΔT больше, либо равен нулю. Оставшийся интервал от минимального значения перепада температуры до нуля выражается через активацию третьего нейрона.

Таким образом, для решения поставленной задачи задействуется четыре входных параметра и минимум восемь нейронов. Количество последних может быть увеличено при выделении дополнительных особенностей технологического процесса. Так, при реализации данной ИНС, для условий выпуска сплава из печи в два приема был введен нейрон для оценки времени оборота ковша. Пороговое значение – «Минимальное время оборота ковша» применяется для подтверждения того, что замер произведен во втором ковше. При выпуске

сплава в два приема измерения во втором ковше могут быть произведены только после завершения операций разливки и возвращения ковша для выпуска остатков сплава из печи. Учет дополнительных условий позволил увеличить точность процесса классификации и уменьшить объем неопределенных решений.

Результатом работы сети является список принадлежности замеров к участкам их проведения. Очевидно, что ключевыми параметрами, определяющими принадлежность замера, являются изменение температуры и временной интервал. Остальные факторы выполняют вспомогательную роль. Чтобы оценить их вклад и преимущество применения ИНС в процессе классификации, результаты были представлены в двумерном пространстве ΔT , Δt (рис. 2).

Вертикальная сплошная линия на рис. 2 представляет пороговое значение «время выпуска». Вертикальная пунктирная – пороговое значение «минимальное время оборота ковша». Рамкой выделена область неопределенности по перепаду температуры. Данные границы должны делить пространство графика на области принадлежности замеров. Однако хорошо видно, что небольшая часть маркеров проникает в условно выделенные соседние области. Объем таких несоответствий составляет порядка 15 %, что является показателем преимущества применения ИНС, учитывающей вспомогательные параметры процесса.

Анализ теплового режима производится на основе сводной таблицы статистического анализа результатов работы плавильного участка в рассматриваемый период (табл. 2).

Такая форма представления результатов работы ИНС позволяет проводить оценку соблюдения технологической дисциплины на участке и использовать ее при выявлении причин образования брака литья.




Рис. 1. Определение минимального значения перепада температуры в процессе выпуска стали из ДСП-3

Fig. 1. Determination of minimum value of temperature difference at tapping molten steel from EAF for 3 ton




Рис. 2. Распределение результатов классификации:

● – печь; ▲ – ковш; ■ – ковш 2

Fig. 2. Distribution of classification results:

● – furnace; ▲ – ladle; ■ – ladle 2

Т а б л и ц а 2

Сводная таблица пакетной обработки результатов классификации за определенный период работы плавильного участка

Table 2. Summary table of batch processing of classification results for a certain period of the melting site operation

Сплав		Ст35ТЛ	
Плавков согласно плану		65	100 %
Всего плавков согласно замерам		64	98 %
Замеры в печи	Температура $<T_{\min}$	1	2 %
	Температура $>T_{\max}$	37	58 %
	Средняя температура, °С	1702	
Снижение температуры на выпуске, °С		52	
Замеры в первом ковше	Всего замеров	63	97 %
	Температура $<T_{\min}$	15	24 %
	Температура $>T_{\max}$	28	44 %
	Всего несоответствий	43	68 %
	Средняя температура, °С	1649	

Эффективность работы нейронной сети оценивалась по объему неопределенных замеров, который составил не более 10 %. Анализ случаев неопределенности позволил установить, что основная причина их появления связана с отклонениями условий процесса выплавки и выпуска сплава от технологически установленного регламента. Таким образом, результаты работы сети дополнительно могут быть использованы для выявления нарушений хода технологического процесса.

Безусловным преимуществом применения ИНС также является высокий потенциал повышения эффективности процесса классификации при расширении вектора признаков параметрами, прямо или косвенно связанными с процессом плавки, такими как электрические показатели работы плавильного агрегата.

Выводы. Предложенный способ классификации температурных замеров позволяет минимизировать затраты при организации процесса автоматизированного мониторинга тепловых режимов выплавки сплавов в литейных цехах.

Применение ИНС для решения задачи классификации замеров температуры позволяет учитывать влияние косвенных факторов процесса, что обеспечивает высокую степень соответствия (порядка 90 %) результатов анализа с фактической ситуацией на рабочей площадке.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Дубинин Н.П. Стальное литье: Справочник для мастеров литейного производства. – М.: Машгиз, 1961. – 887 с.

2. Campbell J. Complete Casting Handbook: Metal Casting Processes, Techniques and Design. 1st ed. Oxford, UK; Waltham, MA: Butterworth-Heinemann, 2011. – 1220 p.

3. Гиршович Н.Г. Справочник по чугуному литью. – Л.: Машиностроение, 1978. – 758 с.

4. Воронин Ю.Ф., Камаев В.А. Атлас литейных дефектов. Черные сплавы. – М.: Машиностроение-1, 2005. – 328 с.

5. Вологдин В.В., Харазов В.Г. Об измерении высоких температур в литейном и металлургическом производствах // Литейное производство. 2008. № 10. С. 21 – 27.

6. Гордов А.Н. Основы температурных измерений. – М.: Энергоатомиздат, 1992. – 304 с.

7. Childs P.R.N. Practical Temperature Measurement. Elsevier, 2001. – 386 p.

8. Гордеев Ю., Швецов Г., Репин А. Новые технологии контроля параметров металлических расплавов // НМ-оборудование. 2004. № 2. С. 11 – 14.

9. Кропачев Д.Ю., Гришин А.А., Масло А.Д. Способы оперативного измерения температуры расплава металлов на машиностроительных предприятиях // Металлург. 2012. № 6. С. 82 – 83.

10. Чистяков С., Синявин С., Савин А., Киркин Д. Система измерения температуры и окисленности и отбора проб расплавов стали в электросталеплавильной печи через рабочее окно // Современные технологии автоматизации. 2010. № 4. С. 28 – 34.

11. Chertov A.D. Use of artificial intelligence systems in the metallurgical industry (survey) // Metallurgist. 2003. Vol. 47. No. 7. P. 257 – 264.

12. Sizyakin R. etc. Defect detection on videos using neural network // MATEC Web of Conference. 2017. Vol. 132. Article 05014.

13. Ботников С.А., Хлыбов О.С., Костычев А.Н. Разработка модели прогнозирования температуры металла в сталеразливочном и промежуточном ковшах в литейно-прокатном комплексе // Металлург. 2019. № 8. С. 26 – 35.

14. He F. etc. Hybrid model of molten steel temperature prediction based on ladle heat status and artificial neural network // Journal of Iron and Steel Research Int. 2014. Vol. 21. No. 2. P. 181 – 190.

15. Tian H., Mao Z., Wang A. A new incremental learning modeling method based on multiple models for temperature prediction of molten steel in LF // ISIJ International. 2009. Vol. 49. No. 1. P. 58 – 63.

16. Bednaya T.A., Konovalenko S.P. Development of a neural network model for predicting the physical and chemical properties of materials from the technological parameters of their formation // IOP Conference Series: Material Science and Engineering. 2018. Vol. 447. No. 1. Article 012086.

17. Azimi S.M. etc. Advanced steel microstructural classification by deep learning methods // Scientific Reports. 2018. Vol. 8. No. 1. P. 1 – 14.

18. Masci J. etc. Steel defect classification with Max-Pooling Convolutional Neural Networks // The 2012 Int. Joint Conference on Neural Networks (IJCNN). 2012. P. 1 – 6.

19. Трофимов В.Б. Многоструктурный распознаватель поверхностных дефектов рельсов // Металлург. 2016. № 4. С. 11 – 16.

20. Sizyakin R., Voronin V., Gapon N. eds. Automatic detection of welding defects using the convolutional neural network // Automated Visual Inspection and Machine Vision III / Beyerer J., Puente León F. eds. Munich, Germany: SPIE, 2019. P. 14.

21. Каллан Р. Основные концепции нейронных сетей. – Москва: Вильямс, 2001. – 288 с.

Поступила в редакцию 25 декабря 2019 г.

После доработки 25 декабря 2019 г.

Принята к публикации 20 октября 2020 г.

ANALYSIS AND CLASSIFICATION OF TEMPERATURE MEASUREMENTS DURING MELTING AND CASTING OF ALLOYS USING NEURAL NETWORKS

A.V. Fedosov^{1,2}, G.V. Chumachenko¹

¹ Don State Technical University, Rostov-on-Don, Russia

² LLC “Rostov Foundry”, Rostov-on-Don, Russia

Abstract. The article considers the issues of monitoring the thermal conditions of alloys melting and casting at foundries. It is noted that the least reliable method is when the measurement and fixing the temperature is assigned to the worker. On the other hand, a fully automatic approach is not always available for small foundries. In this regard, the expediency of using an automated approach is shown, in which the measurement is assigned to the worker, and the values are recorded automatically. This method assumes implementation of an algorithm for automatic classification of temperature measurements based on an end-to-end array of data obtained in the production stream. The solving of this task is divided into three stages. Preparing of raw data for classification process is provided on the first stage. On the second stage, the task of measurement classification is solved by using neural network principles. Analysis of the results of the artificial neural network has shown its high efficiency and degree of their correspondence with the actual situation on the work site. It was also noted that the application of artificial neural networks principles makes the classification process flexible, due to the ability to easily supplement the process with new parameters and neurons. The final stage is analysis of the obtained results. Correctly performed data classification provides an opportunity not only to assess compliance with technological discipline at the site, but also to improve the process of identifying the causes of casting defects. Application of the proposed approach allows us to reduce the influence of human factor in the analysis of thermal conditions of alloys melting and casting with minimal costs for melting monitoring.

Keywords: temperature, alloy, casting, artificial neural network, classification, thermal conditions, melting, casting, human factor.

DOI: 10.17073/0368-0797-2020-10-856-861

REFERENCES

1. Dubinin N.P. *Stal'noe lit'e: spravochnik dlya masterov liteinogo proizvodstva* [Steel Casting: a Guide for Foundry Masters]. Moscow: Mashgiz, 1961, 887 p. (In Russ.).
2. Campbell J. *Complete Casting Handbook: Metal Casting Processes, Techniques and Design*. 1st ed. Oxford, UK; Waltham, MA: Butterworth-Heinemann, 2011, 1220 p.
3. Girshovich N.G. *Spravochnik po chugunnomu lit'yu* [Iron Casting Guide]. Leningrad: Mashinostroenie, 1978, 758 p. (In Russ.).
4. Voronin Yu.F., Kamaev V.A. *Atlas liteinykh defektov. Chernye splavy* [Atlas of Casting Defects. Ferrous Alloys]. Moscow: Mashinostroenie-1, 2005, 328 p. (In Russ.).
5. Vologdin V.V., Kharazov V.G. Measurement of high temperatures in foundry and metallurgical industries. *Liteinoe proizvodstvo*. 2008, no. 10, pp. 21–27. (In Russ.).
6. Gordov A.N. *Osnovy temperaturnykh izmerenii* [Basics of Temperature Measurement]. Moscow: Energoatomizdat, 1992, 304 p. (In Russ.).
7. Childs P.R.N. *Practical Temperature Measurement*. Elsevier, 2001, 386 p.
8. Gordeev Yu., Shvetsov G., Repin A. New technologies for monitoring the parameters of metal melts. *NM-oborudovanie*. 2004, no. 2, pp. 11–14. (In Russ.).
9. Kropachev D.Yu., Grishin A.A., Maslo A.D. Real-time methods of measuring the temperature of metallic melts at machine plants. *Metallurgist*. 2012, vol. 56, no. 5-6, pp. 472–474.
10. Chistyakov S., Sinyavin S., Savin A., Kirkin D. System for measuring temperature and oxidation and sampling of steel melts in EAF through a working window. *STA*. 2010, no. 4, pp. 28–34. (In Russ.).
11. Chertov A.D. Use of artificial intelligence systems in the metallurgical industry (survey). *Metallurgist*. 2003, vol. 47, no. 7, pp. 257–264.
12. Sizyakin R. etc. Defect detection on videos using neural network. *MATEC Web of Conference*. 2017, vol. 132, article 05014.
13. Botnikov S.A., Khlybov O.S., Kostychev A.N. Development of the metal temperature prediction model for steel-pouring and tundish ladles used at the casting and rolling complex. *Metallurgist*. 2019, vol. 63, no. 7-8, pp. 792–803.
14. He F. etc. Hybrid model of molten steel temperature prediction based on ladle heat status and artificial neural network. *Journal of Iron and Steel Research, Int*. 2014, vol. 21, no. 2, pp. 181–190.
15. Tian H., Mao Z., Wang A. A new incremental learning modeling method based on multiple models for temperature prediction of molten steel in LF. *ISIJ International*. 2009, vol. 49, no. 1, pp. 58–63.
16. Bednaya T.A., Konovalenko S.P. Development of a neural network model for predicting the physical and chemical properties of materials from the technological parameters of their formation. *IOP Conference Series: Material Science and Engineering*. 2018, vol. 447, article 012086.
17. Azimi S.M. etc. Advanced steel microstructural classification by deep learning methods. *Scientific Reports*. 2018, vol. 8, no. 1, pp. 1–14.
18. Masci J. etc. Steel defect classification with Max-Pooling Convolutional Neural Networks. *The 2012 Int. Joint Conference on Neural Networks (IJCNN)*. 2012, pp. 1–6.
19. Trofimov V.B. Multi-structural instrument for identifying surface defects on rails. *Metallurgist*. 2016, vol. 60, no. 3-4, pp. 351–357.
20. Sizyakin R., Voronin V., Gapon N., Zelensky A., Pizurica A. Automatic detection of welding defects using the convolutional neural network. In: *Automated Visual Inspection and Machine Vision III*. Beyerer J., Puente León F. eds. Munich, Germany: SPIE, 2019, p. 14.
21. Callan R. *The Essence of Neural Networks*. Prentice Hall, 1998, 248 p. (Russ. ed.: Callan R. *Osnovnye kontseptsii neironnykh setei*. Moscow: Vil'yams, 2001, 288 p.).

Information about the authors:

A.V. Fedosov, Cand. Sci. (Eng.), Assist. Professor of the Chair “Molding and Art Materials Processing” (fedosov-sol@mail.ru)

G.V. Chumachenko, Cand. Sci. (Eng.), Assist. Professor, Head of the Chair “Molding and Art Materials Processing” (gchumachenko@dstu.edu.ru)

Received December 25, 2019

Revised December 25, 2019

Accepted October 20, 2020