

УДК 33

DOI: 10.34670/AR.2021.11.92.021

## **Разработка модели выбора материалов для валков прокатных станов с использованием нейронных сетей**

**Гафаров Максим Фаизович**

Аспирант кафедры материаловедения и физико-химии материалов,  
инженер ПАО «ЧТПЗ»,  
Южно-Уральский государственный университет  
(национальный исследовательский университет),  
454080, Российская Федерация, Челябинск, просп. Ленина, 76;  
e-mail: gafarovmax@yandex.ru

**Павлова Ксения Петровна**

Аспирант кафедры материаловедения и физико-химии материалов,  
инженер,  
Южно-Уральский государственный университет  
(национальный исследовательский университет),  
454080, Российская Федерация, Челябинск, просп. Ленина, 76;  
e-mail: ksesha952@gmail.com

**Гафарова Елена Аркадьевна**

Кандидат педагогических наук,  
старший преподаватель кафедры автомобильного транспорта,  
информационных технологий и методики обучения техническим дисциплинам,  
Южно-Уральский государственный  
гуманитарно-педагогический университет,  
454080, Российская Федерация, Челябинск, просп. Ленина, 69;  
e-mail: gafarovaea@csru.ru

### **Аннотация**

В статье представлена математическая модель оптимизации подбора материалов для валков прокатных станов для агропромышленного оборудования на основе нейросетевого моделирования. Проведен анализ нейросетевых моделей с целью определения наиболее подходящей архитектуры и других параметров для решения поставленной задачи. Рассмотрено специализированное программное обеспечение для проектирования нейросетевых моделей на основе библиотеки глубокого обучения Keras. Разработана нейронная сеть с многослойной структурой персептрона (МЛП), проверена адекватность полученной нейронной сети. Полученная нейронная сеть способна прогнозировать величину износа валков по заданным параметрам. Описан специальный алгоритм подбора рулонного материала, который при заданных условиях имел бы приемлемый износ при минимальных затратах на ремонт валков. Применение полученной модели позволяет

снизить стоимость технологической оснастки агропромышленного комплекса и повысить в целом экономический эффект от внедрения новых моделей техники.

#### **Для цитирования в научных исследованиях**

Гафаров М.Ф., Павлова К.П., Гафарова Е.А. Экономическая модель выбора материалов для валков прокатных станов в агропромышленном холдинге // Экономика: вчера, сегодня, завтра. 2020. Том 10. № 10А. С. 202-218. DOI: 10.34670/AR.2021.11.92.021

#### **Ключевые слова**

Износ валков, прокатный стан, моделирование нейронных сетей, Python, прогнозирование, оптимизация.

## **Введение**

Потенциальная отказоустойчивость нейронных сетей обоснована незначительным снижением их производительности при неблагоприятных условиях. Эта особенность объясняется распределенным характером хранения информации в нейронной сети, благодаря чему можно утверждать, что только серьезные повреждения структуры нейронной сети существенно повлияют на ее работоспособность. Имеется определенное сходство в использовании нейронных сетей и методов многомерного статистического анализа при оценке финансово-экономического состояния предприятия.

Несмотря на сокращение операционных расходов, в том числе на ИТ, предприятия готовы платить за технологии с понятным и измеримым эффектом для производственного процесса и бизнеса. Именно в кризис они будут еще больше инвестировать в технологии, позволяющие автоматизировано контролировать производственные процессы, исключать человеческий фактор, оптимизировать затраты, повышать качество продукции. Используя технологии глубокого обучения, видеосистемы смогут более точно контролировать качество продукции, действия персонала, управление технологическими процессами.

Производство постоянно усложняется: интеллектуальные системы управления и роботы, интернет вещей — все эти технологии уже работают на современных фабриках, став основой той модели, которую называют «промышленность 4.0». На пике интереса и новые технологии – машинное обучение и нейронные сети, они же нейросети. Системы на базе машинного обучения умеют подстраиваться под бизнес-процессы предприятия, под его особенности. Нейросети на заводах могут использоваться для прогнозирования и планирования, манипуляций с робототехникой, управления качеством продукции и безопасностью на производстве. Нейросети для управления качеством применяет все большее количество компаний. Например, нейронная сеть на предприятиях Intel умеет идентифицировать брак при производстве микросхем и способна забраковать неисправный чип с точностью 99,5%. Еще один пример. Специалисты из National Institute of Standards and Technology (NIST) проверяют качество бетона при толщине материала до полуметра. Они создали систему, которая подает звуковые волны и принимает отраженный сигнал, а данные анализирует нейросеть. Адаптирование к изменениям окружающей среды – нейронные сети могут быть переучены в новых условиях окружающей среды, описываемых незначительными колебаниями параметров этой среды. ешение задач в условиях неопределенности – способность обучения нейронной сети позволяет решать задачи с неизвестными закономерностями и зависимостями между входными и выходными данными,

что позволяет работать с неполными данными.

Все эти новые технологии стали возможны благодаря новым технологиям хранения данных в облаке. Например, контейнеризация полностью изменила подход к разработке и запуску приложений в облаках, позволив не только ускорять процессы вывода новых сервисов на рынок, но и сокращать затраты на использование вычислительных ресурсов. Использование контейнеров и микросервисов обеспечивает ряд существенных преимуществ по сравнению с традиционной технологией виртуализации и монолитными приложениями. Например, повышает эффективность работы ИТ-решений клиента за счет гибкой масштабируемости, повышенной отказоустойчивости и автоматического управления жизненным циклом приложений. В новых проектах уже преобладают технологии контейнеризации и средства их автоматизации (в первую очередь, Kubernetes — ПО для автоматизации развертывания и управления контейнерами), а также технологии serverless. В дальнейшем их проникновение будет только расти, а сервисы на их базе станут мейнстримом на облачном рынке. Российские ученые разработали технологию, которая повышает качество при ремонте нефтепроводов за счет индукционного нагрева. Эта технология Сибирского федерального университета (СФУ) из Красноярска может применяться и в ракетостроении, и в автомобилестроении. В режиме реального времени система отслеживает показания используемых при ремонте трубопровода приборов и управляет сваркой труб. Другая перспективная область – безопасность сотрудников. Для предприятий очень важно снижение количества несчастных случаев и аварий. Этого можно добиться за счет контроля за соблюдением техники безопасности на базе современных систем видеоаналитики. В настоящее время из всех известных организационных форм проведения технического обслуживания и ремонта парка аграрного оборудования преобладает АПК силами рудника или совместно с РТП.

### Основная часть

Последнее несколько десятилетий связаны с увеличением интереса к различным методам цифрового моделирования, позволяющим повысить качество и скорость обрабатываемой информации. Основными задачами являются в первую очередь – управление, классификация и прогнозирование. Подобным функционалом обладает искусственная нейронная сеть, главным преимуществом которой выступает возможность воспроизводить сложные нелинейные зависимости с большим количеством переменных величин. Ключевым свойством сети является способность к обучению, в ходе которого на основе выборки из представительных данных (исключая различные выборы или так называемые «шумы») происходит определение связей и взаимозависимостей между исходными параметрами. Скорость и качество обработки поступающей информации позволяет получать впечатляющие результаты и во многом упрощать работу специалистов в рамках производственных процессов, связанных с обработкой огромного количества поступающих данных. Существует огромное множество видов нейронных сетей, которые можно классифицировать следующим образом: о типу входной информации различают аналоговые нейронные сети (используют информацию в форме действительных чисел), двоичные нейронные сети (используют информацию, представленную в виде 0 и 1) и образные нейронные сети (используют информацию в виде образов: иероглифов, символов, знаков); по характеру обучения выделяются сети с учителем (когда выходное пространство решений нейронной сети известно), без учителя (когда сеть сама формирует

выходное пространство решений только на основе выходных воздействий, подобные сети еще называются самоорганизующимися) и с подкреплением (когда формируется система назначения штрафов и поощрений от среды);

Нейронные сети находят применение в промышленных агрегатах при наличии возмущающих воздействий на объект управления, когда традиционные решения в системах управления недостаточно эффективны. Управление электроприводными комплексами, с использованием нейронных сетей целесообразно при изменении в широком диапазоне параметров механической части и режимов работы электропривода, когда быстродействие или точность традиционных систем управления с линейными регуляторами недостаточны.

Нейронная сеть способна выполнять различные функции: управление динамическими объектами, диагностику оборудования, прогнозирование производственных ситуаций, мониторинг технологических процессов. При использовании нейронных сетей возможно осуществлять параллельную обработку информации всеми звеньями, что значительно ускоряет процесс обработки информации. Для нейронных сетей характерна способность к обучению и обобщению накопленных знаний. Обученная на ограниченном множестве данных сеть в дальнейшем способна обобщать полученную информацию и обрабатывать данные, не использовавшиеся при ее обучении. Нейроуправление динамическими объектами является комбинацией методов автоматического управления и методов искусственного интеллекта. Нейронные сети обладают рядом особенностей, которые позволяют применять их для моделирования и управления нелинейными динамическими объектами.

В настоящее время разработано, исследовано и используется на практике множество типов нейронных сетей, использующих различные обучающие алгоритмы, характеризующихся своими сильными и слабыми сторонами. Наиболее распространенными архитектурами нейронных сетей являются сети прямого распространения, рекуррентные нейронные сети, самоорганизующиеся карты или сеть Кохонена, сверточные нейронные сети, радиально-базисные функции. Количество архитектур нейронных сетей насчитывается десятками, при этом для разных типов задач разные типы нейронных сетей являются наиболее эффективными. Нейронные сети позволяют создать модель объекта, точно передающую его динамику, при этом, не требуя дополнительных знаний о структуре и параметрах объекта. Необходимыми данными являются только значения входных и выходных сигналов, таким образом, объект представляется в виде черного ящика.

Рассмотрим управление с прогнозирующими моделями [1,2]. Контроллер использует нейросетевую модель нелинейного объекта для предсказания поведения объекта управления на различные типы входных воздействий. Построение модели объекта называется идентификацией системы. Процесс построения нейросетевой модели объекта состоит из следующих этапов:

- сбор и нормализация данных для обучения;
- выбор архитектуры сети и алгоритма обучения;
- обучение;
- проверка адекватности обучения.

Построенная модель объекта применяется для создания системы управления этим объектом. Задача нейроконтроллера - рассчитать управляющий сигнал, который позволит оптимизировать работу объекта в течение определенного периода времени. Ошибка предсказания между выходом объекта управления и выходом его нейросетевой модели используют в качестве сигнала для обучения сети.

Нейронные сети и нейроконтроллеры могут применяться для управления различными объектами, в том числе и электроприводами различных механизмов, при этом нейроконтроллер осуществляет выработку управляющего сигнала.

Нейронная сеть на первых итерациях обучающего процесса может выдавать значения управляющего сигнала, недопустимые, например для электропривода. Поэтому настройку нейроконтроллера следует производить с использованием модели объекта.

Одним из наиболее эффективных способов увеличения выпуска проката, а также повышения качества металлопродукции и снижения затрат на перераспределение стали является повышение сопротивления прокатных валков. Валки на прокатных станах эксплуатируются в сложных условиях, которые характеризуются высокими значениями переменных нагрузок, контактных напряжений и высокотемпературного износа в результате трения, возникающего при прокатке [Bystrov, Dyakov, Umanets, 2014].

Стоимость ремонта валков прокатных станов составляет 6-8% от общей стоимости прокатных станов [Bystrov, Dyakov, Umanets, 2014]. Кроме того, износостойкость валков напрямую зависит от времени перед перевалкой, т.е. от времени непрерывного использования валков, что значительно влияет на стоимость прокатки. Поэтому многие исследования направлены на совершенствование материалов валков [Shestakova, Potapov, Eagles, www], подбор оптимальных технологических параметров станов [Dubinsky, Vydrin, Maltsev, Sosedkova, 2007], моделирование износа валков [Rychkov, Kinzin, 2013] для повышения износостойкости материалов валков и др. Для этих исследований используются различные методы моделирования [Bystrov, Dyakov, Umanets, 2014]. В ряде работ показана эффективность применения современных методов машинного обучения в промышленности, приведены примеры успешной реализации нейросетевых моделей [Zhao LiuJun, Kong Weizheng, Wang Qiuling, Song Lihua, 2019].

Развитие алгоритмов цифрового моделирования процессов, а также их внедрение в производственные процессы позволяет уже в настоящее время достигать существенных результатов. При этом потенциал данной технологии поражает своими перспективами. Совершенствование систем оценки качества исходных данных, прогнозирование показателей работы оборудования, а также регулирование операционных процессов в режиме реального времени в случае отклонения от заданных режимов работы позволит выйти на качественно новый уровень развития всей отрасли в целом.

В течение последних 10-15 лет наблюдается бурный рост в области искусственных нейронных сетей. Классические сферы их применения – обработка изображений, звука и других данных высокой размерности. Однако в машинном обучении есть немало задач, где объем данных, поступающих на вход системы, невелик – например, моделирование редких явлений, обработка собранных вручную аналитических данных, анализ сигналов с низкочастотных датчиков и т.д. В таких условиях важным этапом является тщательная работа с признаками (“features”), на которых обучается система, и, в частности, генерация из имеющихся базовых признаков новых, которые позволят улучшить качество работы проектируемой системы. Для такой генерации обычно применяют ручные методы, но хорошей альтернативой является использование нейронных сетей, способных не только обучаться базовым математическим операциям, но и выявлять крайне сложные паттерны во входных данных. Подобным функционалом обладает искусственная нейронная сеть, главным преимуществом которой выступает возможность воспроизводить сложные нелинейные зависимости с большим

количеством переменных величин.

Использование нейросетевых моделей дает ряд преимуществ по сравнению с классическими моделями. Прежде всего, это позволяет осуществлять поиск сложных зависимостей между входящими параметрами. Нейросетевая модель дает возможность восстановить нелинейные закономерности между различными факторами, которые на первый взгляд не кажутся связанными и могут быть представлены порядковыми, категориальными и другими типами данных [Anding et al., 2019].

Многие нейросетевые модели имеют ряд недостатков: большинство подходов к проектированию искусственных нейронных сетей (ИНС) являются эвристическими и часто не приводят к однозначным решениям; для построения модели объекта на основе ИНС необходимо выполнить многоцикловую настройку внутренних элементов и связей между ними и др. В данной статье особое внимание уделяется устранению этих недостатков и обеспечению применимости модели к решению реальной задачи.

Определим возможность использования нейронных сетей для статистического анализа износа валков в зависимости от заданных факторов и решения задачи выбора оптимального материала валков из существующих с целью минимизации экономических потерь. В качестве метода оптимизации используем алгоритм отжига. Этот алгоритм имеет ряд преимуществ перед другими методами оптимизации, одним из таких преимуществ является возможность нахождения глобального экстремума оптимизируемой функции, а также небольшие требования к вычислительной мощности, кроме того, он был успешно применен в ряде работ [Yingzhuo Xu, Qing Yang, 2019; Bendaoud et al., 2019; Mohammadi, Forghani, 2019].

Разработаем метод применения нейросетевой модели и алгоритма имитационного отжига для выбора оптимального сочетания рулонного материала для данного подвижного состава.

Создадим математическую модель, позволяющую прогнозировать износ валков в зависимости от заданных факторов, а также найти оптимальную комбинацию валков из заданного набора при заданных условиях, обеспечивающую минимальные экономические потери при износе. Решение этой задачи осложняется тем, что износ валков зависит от многих факторов [Reihanian, Baharloo, Lari Baghal, 2018]. Эти факторы можно разделить на технические и технологические. Положение клетки, номера клетки и др. являются техническими. Технологическими факторами являются физико-химические свойства материалов валков, материалы обрабатываемой стали, температура, скорость прокатки и др. [Shilnikov, Paderin, 2013].

В последние годы нейросетевые модели находят все большее практическое применение, так как они являются чрезвычайно удобным инструментом для анализа и обработки большого объема данных [Bodrov, Safin, 2012]. Более того, нейросетевые модели чаще всего используются для прогнозирования технических данных [Amirov et al., 2012], обучаемая модель является «черным ящиком», поскольку последняя не позволяет явно установить количественные соотношения между зависимыми и независимыми переменными [Korolev, 2010].

Эффективность прогнозирования по модели нейронной сети тесно связана с правильно выбранными параметрами сети, наиболее важными из которых являются архитектура сети [Isupova, Trusov, 2013], оптимизатор сети [Eberhart, Kennedy, 1995], обработанные данные и др.

Кроме того, возможности модели нейронной сети напрямую зависят от выбранной библиотеки глубокого обучения [Lam, Ling, Leung, Tam, www].

В результате модель нейронной сети должна соответствовать ряду требований [Lam, Ling,

Leung, Tam, www], чтобы быть адекватной.

Модель нейронной сети является лишь промежуточным результатом в решении задачи оптимизации, поскольку она является лишь инструментом для анализа данных. Для успешного решения задачи оптимизации необходимо создать алгоритм применения ранее разработанной математической модели, а затем включить этот алгоритм в программный код.

Таким образом, с точки зрения содержания проблема формулируется следующим образом: необходимо разработать нейронную сеть с подходящими параметрами для прогнозирования износа валков при заданных условиях, а затем алгоритм выбора оптимального материала валков в этих условиях.

Допущения, принятые в работе: износ валков, считается равномерным, экономические потери прямо пропорциональны степени износа рулонного материала.

Анализ библиотек глубокого обучения привел к выводу, что одним из наиболее продвинутых является Keras [Vidnerova, Neruda, www]. Кроме того, есть много примеров программной реализации нейронных сетей различных конфигураций, использующих эту библиотеку [Taylor, Keras, 2014].

В качестве наиболее подходящей архитектурой нейронной сети была выбрана архитектура типа многослойного персептрона [Manaswi, 2018]. MLP состоит как минимум из трех уровней узлов: входной слой, скрытый слой и выходной слой. За исключением входных узлов каждый узел является нейроном, который использует нелинейную функцию активации. В данной работе были использованы следующие функции активации: «relu», «sigmoid». Особенности использования функций активации, а также их применимость к конкретным слоям нейронных сетей подробно описаны в [Prasanna, Ram, 2016].

Из-за небольшого количества исследований для приложения моделирования нейронной сети для прогнозирования износа валков было решено создать программное обеспечение с регулируемыми параметрами нейронной сети с возможностью выбора наиболее подходящего.

В процессе создания стандартные инструменты описаны в библиотеке Keras. «Адам» был выбран в качестве оптимизатора нейронной сети [Kingma, Jimmy. www]. «Адам» – это алгоритм для стохастической целевой функции на основе градиента первого порядка, основанный на адаптивных оценках моментов более низкого порядка. Этот метод прост в реализации, является вычислительно-эффективным, хорошо подходит для задач, которые являются большими с точки зрения данных или параметров. Этот метод также подходит для нестационарных целей и задач с очень шумными или разреженными градиентами. Гиперпараметры имеют интуитивную интерпретацию и обычно требуют небольшой настройки. Эмпирические результаты показывают, что «Адам» хорошо работает на практике и выгодно отличается от других методов стохастической оптимизации [Jacobson et al., 2019].

Точность нейросетевой модели оценивалась путем определения стандартного отклонения прогнозируемого значения от фактического значения износа [Daniel, Jing, Lynn, 1998].

Скриншот разработанной программы показан на рисунке 1. После указания исходных данных в окне программы настраивается архитектура сети, а именно выбирается количество скрытых слоев, устанавливается функция активации для каждого слоя и указывается количество нейронов в скрытом слое. Определив все необходимые параметры и обучив сеть, можно спрогнозировать зависимый фактор по тем параметрам, которые были использованы для обучения сети. Стоит отметить, что инициализированная сеть имеет плотную структуру [Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian, 2017], то есть нейроны каждого слоя

соединены с каждым нейроном другого слоя.

The screenshot shows the main window of a neural network software. It is organized into several functional areas:

- Input data:** A section for loading data, showing a file path 'C:/Users/User/Desktop/arrays.xlsx' and a 'Choose' button. Below it, there are two input fields: 'Select influencing factors (choose the number of the penultimate column in the database)' with the value '4', and 'Select the dependent value' with the value '5'.
- Neural network architecture:** A section for configuring the network. It includes:
  - 'Number of hidden layers' with radio buttons for 1, 2, and 3 (3 is selected).
  - 'Choice of activation functions' with a list: 'Hidden layers: 1 - relu, 2 - relu, 3 - relu' and 'Output layer: 1 - sigmoid'.
  - 'Number of neurons in each layer' with input fields: 15 for the first hidden layer, 10 for the second, and 4 for the output layer.
  - Buttons: 'Select number of layers' and 'Set network architecture'.
- Training options:** A section for training parameters, including 'Number of epochs' (100) and 'Size of the training sample' (10), with a 'Select training options' button.
- Building and saving a model:** A section with 'Build a network' and 'Save the model' buttons.
- Prediction:** A section for running predictions, showing a file path 'C:/Users/User/Desкто' and a 'Predict' button.

**Рисунок 1 - Основное окно программы**

Одной из особенностей обучения нейронных сетей является значительное влияние подготовленных данных на сходимость полученных результатов [Srivastava et al., 2014]. Исходные данные представляют собой массив чисел, его структура представлена в таблице 1.

**Таблица 1 - Исходные данные по износу валков**

Номер клетки	Позиция в клетки	Материал валка	Износ	Марка стали 1	Марка стали 2	...
11	верх	1	0.4858	0.201	0.321	...
9	низ	16	0.5160	0.143	0.224	...
...	...	...	...	...	...	...

Столбцы в таблице 1 имеют следующие значения.

Номер клетки – положение валка в определенной клетки прокатного стана в определенное время заполнения.

Позиция в клетки – позиция валка в определенной клетки в определенное время обработки.

Материал валка – материал валка, используемый в определенных условиях

Износ – сокращение диаметра валка в данных условиях.

Марка стали k – обобщенное значение линейной плотности обрабатываемой стали в определенных условиях.



Для преобразования данных (таблица 1) в тип, приемлемый для обучения нейронной сети, был проведен ряд операций. Преобразуем исходные данные (таблица 1) в матрицу  $I_0$ :

$$I_0 = \begin{pmatrix} x_{11}^{nn} & x_{12}^{mm} & x_{13}^{kk} & \dots & x_{1(k+3)}^{kk} & V_{1(k+4)} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{z1}^{nn} & x_{z2}^{mm} & x_{z3}^{kk} & \dots & \dots & V_{z(k+1)} \end{pmatrix}$$

Здесь  $k$  – марка обрабатываемых стали;

$z$  – размер выборки;

$x_{ij}^p$  – независимый фактор ;

$p$  – фактор категории ( $nn$  – номер клетки;  $mm$  – материал валка;  $kk$  – число обрабатываемых марок сталей;  $i$  – номер строки;  $j$  – номер столбца;  $Y_{ij}$  – износ валка).

Будем учитывать, что существует  $n$  клеток и  $m$  количество материалов валка для преобразования матрицы  $I_0$ , так что категориальные данные («Количество клеток», «Материал валка») были преобразованы в числовые с использованием методики унитарного кодирования [Gafarov, Senin, Gafarova, 2019]. Кроме того, для получения адекватных результатов тренировочная выборка должна иметь нормализованные данные, поскольку значение износа валков  $Y$  не нормировано ( $Y \in [0; c]$ ,  $c > 1$ ), его необходимо нормализовать. В результате была получена матрица  $I$ :

$$I = \begin{pmatrix} x_{11}^{nn} & \dots & x_{1n}^{nn} & x_{1(n+1)}^{mm} & \dots & x_{1(n+m)}^{mm} & x_{1(n+m+1)}^{kk} & \dots & x_{1(k+n+m)}^{kk} & Y_{1(k+n+m+1)}^* \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{z1}^{nn} & \dots & x_{zn}^{nn} & x_{z(n+1)}^{mm} & \dots & x_{z(n+m)}^{mm} & x_{z(n+m+1)}^{kk} & \dots & x_{z(k+n+m)}^{kk} & Y_{z(k+n+m+1)}^{kk} \end{pmatrix}$$

Значения независимых факторов  $x_{ij}^{nn}$  и  $x_{ij}^{mm}$  в матрице  $I$  были получены по уравнениям (1) и (2):

$$x_{ij}^{nn} = \begin{cases} 1, & \text{if } (x_{ij}^{nn} \in I) = (x_{i1}^{nn} \in I_0) \\ 0, & \text{if } (x_{ij}^{nn} \in I) \neq (x_{i1}^{nn} \in I_0) \end{cases} \quad (1)$$

$$x_{ij}^{mm} = \begin{cases} 1, & \text{if } (x_{ij}^{mm} \in I) = (x_{i2}^{mm} \in I_0) \\ 0, & \text{if } (x_{ij}^{mm} \in I) \neq (x_{i2}^{mm} \in I_0) \end{cases} \quad (2)$$

Нормализованные значения износа  $Y^*$  были определены по уравнению (3):

$$Y_{ij}^* = \frac{Y_{ij} - \mu}{\sigma}, \quad (3),$$

где  $\mu, \sigma$  – среднее арифметическое и стандартное отклонение множества значений  $Y_{ij}$   $Y_{ij}$ .

Было принято, что износ валка не зависит от верхнего или нижнего положения в клетке. После преобразований матрица  $I$  может быть использована для обучения нейронной сети. Таким образом, полученный набор данных, пригодный для обучения нейронной сети, представлен в

таблице 2.

**Таблица 2 - Результирующий набор данных для обучения нейронной сети**

Номер клетки 1	...	Материал валка 1	...	Марка стали 1	...	Величина износа
0	...	1	...	0.201	...	0.48582
0	...	0	...	0.143	...	0.51608
...	...	...	...	...	...	...

Для решения задачи оптимизации была построена нейросеть на подготовленных данных, представленных в матрице I в таблице 5. Параметры нейросети представлены на рисунке 1. Обученная нейронная сеть имеет возможность предсказывать величину износа  $Y_{ij}^*$ , используя  $x_{ij}^p$  факторы.

Модифицируем матрицу I: удалим столбец:  $Y_{ij}^*$ , а также увеличим объем выборки, сопоставив каждому фактору  $x_{ij}^{nn}$  («Номер клетки») все  $m$  возможных комбинаций фактора  $x_{ij}^{mm}$ , таким образом размер выборки возрастет в  $m^n$  раз (это означает что каждый материал валка  $m$  может быть в клетки  $p_i$ , с возможными повторениям, так все возможные комбинации выражаются формулой размещения с повторениями. Используя обученную нейронную сеть, величина износа  $Y_{ij}^{**}$  для каждого материала валка в определенной клетки была предсказана для конкретных параметров обрабатываемой стали. Каждому материалу валка можно сопоставить число (удельная величина экономических потерь при истончении валка). Представим матрицу с величинами экономических потерь от износа валков C:

$$C = \begin{pmatrix} x_{11}^m & c_{12} \\ \vdots & \vdots \\ x_{m1}^m & c_{m2} \end{pmatrix}$$

где  $c_{ij}$  = удельная стоимость материала валка  $x_{ij}^m$ . Зададим матрицу L:

$$\begin{pmatrix} x_{11}^{nn} & \dots & x_{1n}^{nn} & x_{1(n+1)}^{mm} & \dots & x_{1(n+m)}^{mm} & x_{1(n+m+1)}^{kk} & \dots & x_{1(k+n+m)}^{kk} & Y_{1(k+n+m+1)}^{**} & l_{1(k+n+m+2)} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{(m-z)1}^{nn} & \dots & x_{(m-z)n}^{nn} & x_{(m-z)(n+1)}^{mm} & \dots & x_{(m-z)(n+m)}^{mm} & x_{(m-z)(n+m+1)}^{kk} & \dots & x_{(m-z)(k+n+m)}^{kk} & Y_{(m-z)(k+n+m+1)}^{**} & l_{(m-z)(k+n+m+2)} \end{pmatrix}$$

$$L = \begin{pmatrix} x_{11}^{nn} & \dots & x_{1(k+n+m)}^{kk} & Y_{1(k+n+m+1)}^{**} & l_{1(k+n+m+2)} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{(m^n)1}^{nn} & \dots & x_{(m^n)(k+n+m)}^{kk} & Y_{(m^n)(k+n+m+1)}^{**} & l_{(m^n)(k+n+m+2)} \end{pmatrix},$$

где  $l_{ij}$  – величина экономических потерь, вычисленная по уравнению (4):

$$l_{ij} = Y_{ij}^{**} c_{ij} \quad (4)$$

Разобьем множество L на подмножества  $L_a$ , в каждом из которых содержится одна комбинация факторов  $x_{ij}^{nn}$ , таким образом, каждое из них содержит информацию о положении валков в клетях  $x_{ij}^{nn}$  из материалов  $x_{ij}^{mm}$ , то есть:

$$L = \bigcup_{a \in A} L_a \quad (5)$$

$l_i^*$  Здесь A – конечный набор индексов подмножеств  $L_a$ .

Введем величину – сумму экономических потерь от износа валков при заполнении клетей

одним из  $m^n$  возможных методов и поставим  $L_a$  в соответствие с этой величиной (зададим функцию), то есть:

$$l_i^* = \sum_{i=1}^{m^n} l_i^a \text{ где } l_i^a \in L_a \quad (6)$$

$$f(l_i^*) = L_a \quad (7)$$

$l_i^*$  Теперь решение проблемы оптимального расположения валков из определенных материалов в клетях прокатных станов при обработке выбранных сталей сводится к нахождению минимального значения  $l_i^*$  функции  $f(l_i^*)$ .

Рассматривая более общий случай оптимизации, а именно: оптимальное выравнивание валков при обработке всех выбранных марок стали ( $k$ ), указанных в планах прокатки, число возможных комбинаций увеличится на  $k$  (количество марок стали) и станет равным  $k m^n$ . Порядок величины комбинаций для 7 клетей чистовой группы стана 2000 с 23 материалами валков и 100 марками стали  $\sim 10^{11}$  [Voronkov, Zavalishchin, Karagodin, 2020]. Решение задачи оптимизации с использованием обычного итерационного подхода в этом случае займет много времени.

В данной статье в качестве метода оптимизации выбран алгоритм моделирования отжига. Используя данный метод, из набора переменных  $l_i^*$  целевой функции ищется точка, которая имеет минимальное значение, а затем параметры  $x_{ij}^p$  определяются подстановкой минимальной величины  $l_i^*$  в функцию  $f(l_i^*)$ .

Алгоритм принимает произвольную точку  $l_i^*$  в качестве входных данных. На каждом шаге вычисляется новая точка и понижается величина (изначально положительная), которая имеет значение, аналогичное «температуре». Алгоритм останавливается, когда достигает точки, которая оказывается равной нулю.

Введем функцию понижения начального значения, понимаемого как «температура»/ В этой работе принята функция:

$$T(i) = \frac{t_0^{0.1}}{i} \quad (8)$$

Здесь  $t_0$  – начальная ‘температура’  $i$  – номер итерации.

$l_0^*$  На первом этапе перемешивается набор аргументов  $l_i^*$  целевой функции случайным образом. Выбирается произвольная точка, затем последовательно выбираем новую точку  $l_1^*$ , эта точка становится новой с вероятностью, рассчитанной по уравнению (9):

$$P(l_i^{**} \rightarrow l_{i+1}^{**} | l_i^*) = \begin{cases} 1, & \text{if } l_i^{**} - l_i^* < 0 \\ e^{\left(-\frac{l_i^{**} - l_i^*}{T_i}\right)}, & \text{if } l_i^{**} - l_i^* \geq 0 \end{cases} \quad (9)$$

Стоит отметить, что использование алгоритма отжига не гарантирует нахождение минимума функции, но из-за случайности выбора промежуточной точки, определенные этим алгоритмом, должны попадать в локальные минимумы реже, чем градиентный спуск. Кроме того, такой алгоритм требует значительно меньшей вычислительной мощности, чем последовательное перечисление всех значений.

Таким образом, задача оптимизации износа валков из определенных материалов, расположенных в клетях в определенном порядке и работающих в условиях проката указанных марок сталей, сводится к совместному использованию модели нейронной сети и алгоритма имитации отжига.

Была разработана программа для построения нейронных сетей с использованием библиотеки глубокого обучения Keras. Нейронная сеть построена и обучена на подготовленных данных, способных прогнозировать износ валков в заданных условиях. Создана методология оптимального выбора материала рулонов с использованием данных моделирования нейронной сети. Язык программирования Python был использован для создания программного обеспечения.

Полученный алгоритм оптимизации, используемый вместе с моделью нейронной сети, позволит оптимизировать долгосрочный план прокатки с целью снижения общих экономических потерь в результате износа материалов валков при текущем плане прокатки.

Стоит отметить, что разработанная математическая модель оптимизации ограничена точностью модели нейронной сети, поэтому в данной статье особое внимание было уделено качеству построения модели нейронной сети. Кроме того, можно выбрать функцию уменьшения значения «температуры», чтобы улучшить показатели сходимости алгоритма моделирования отжига. Также возможно изменить структуру модели нейронной сети для повышения стабильности и точности прогнозов.

Необходимы дальнейшие исследования, чтобы определить применимость модели. Результаты работы позволят оптимально перераспределить валки из разных материалов и снизить потери при прокатке. Дополнительно использование нейронных сетей позволит снизить стоимость производства сельскохозяйственной техники.

Для обеспечения ежегодных валовых сборов продукции сельского хозяйства в объемах, обеспечивающих продовольственную безопасность страны и возможность экспорта? требуется внедрение передовых технологий в растениеводстве, животноводстве и птицеводстве. Освоение таких технологий возможно только на базе современной техники, обеспечивающей повышение производительности труда в 1,5 -1,7 раза, энерговооруженности – на 20-30%, снижение энергопотребления и ресурсопотребления – на 25-30 %.

С учетом роста объема выполняемых работ укрупнения организаций и общемировых тенденций необходимо дооснастить данные предприятия энергонасыщенными тракторами с мощностью двигателя более 250 лошадиных сил в комплекте с оборотными плугами, комбинированными почвообрабатывающими посевными агрегатами, многотоннажными прицепами для перевозки грузов и машинами повышенной грузоподъемности для внесения минеральных и органических удобрений.

Использование энергонасыщенных тракторов на полевых операциях, связанных с обработкой почвы и посевом, позволит сократить затраты труда на 1 гектар на 40-60%, уменьшить удельный расход топлива на 5-15%, снизить себестоимость механизированных работ до 30%. При общей технологической потребности организаций в тракторах не более 52000 единиц удельный вес энергонасыщенных тракторов с мощностью двигателя более 250 лошадиных сил для выполнения вышеперечисленных показателей в перспективе должен составить не менее 15%, или около 8000 таких тракторов.

В настоящее время в организациях эксплуатируется около 5000 тракторов класса 5, из них более 2200 морально и физически устаревших тракторов К-700 и К-701. Следовательно, для обеспечения полной потребности в энергонасыщенных тракторах потребуется закупать их не

менее 1000 ежегодно в течение 5 лет.

Анализ работы новейшей зарубежной техники показал необходимость более широкого использования при обработке почвы универсальных и многофункциональных агрегатов, способных работать в любых системах земледелия. В ближайшие годы необходимо оснастить все организации республики блочно-модульными машинами, позволяющими посредством перестановки отдельных узлов комплектовать агрегаты различными рабочими органами, способными выполнять практически все технологические операции по предпосевной подготовке и посеву всех сельскохозяйственных культур. Применение подобных машин позволит значительно увеличить их годовую наработку, сократить номенклатуру специализированных технических средств в парке сельскохозяйственной техники, снизить эксплуатационные затраты на полевые работы на 5-10 %.

Обеспеченность ремонтно-технологическим оборудованием более значима для предприятий с низким уровнем использования техники (коэффициент снижения затрат на ремонт на единицу стоимости ремонтного оборудования здесь выше).

К факторам, оказывающим наибольшее влияние на содержание оборудования, относятся: в группе А – коэффициент охвата ремонтом ПДМ – 49,5%; в группе Б – себестоимость ремонта парка аграрного оборудования – 11% и обеспеченность ремонтно-технологическим оборудованием – 3%. Так, в группе Б при увеличении обеспеченности ремонтно-технологическим оборудованием на 1% затраты на ремонт оборудования на рудниках снизятся на 19%.

Обеспеченность ремонтно-технологическим оборудованием занимает второе место по влиянию на затраты по ремонту и ТО. Повышение обеспеченности ремонтно-технологическим оборудованием до уровня РТП позволяет уменьшить затраты на содержание парка оборудования на 14%, а по значению коэффициента регрессии в группе Б затраты на содержание техники могут быть уменьшены на 18%.

## Заключение

В настоящее время все больший интерес к искусственным нейронным сетям проявляют различные отрасли промышленности и непромышленной сферы. Искусственные нейронные сети эффективно используются для распознавания видеоизображений, письменного текста и речи, решения разнообразных задач прогнозирования и во многих других областях. В настоящее время известно большое число коммерческих программных систем моделирования, позволяющих исследовать и разрабатывать искусственные нейронные сети для различных приложений, а также разработано значительное число нейрокомпьютерных систем. Нейронные сети, в отличие от статистических методов многомерного классификационного анализа, базируются на параллельной обработке информации и обладают способностью к самообучению, то есть получать обоснованный результат на основании данных, которые не встречались в процессе обучения. Эти свойства позволяют нейронным сетям решать сложные (масштабные) задачи, которые на сегодняшний день считаются трудноразрешимыми.

## Библиография

1. Amirov R.N. et al. The use of neural networks to simulate the power parameters of the stands of the finishing group NSHSGP 2000 MMK // Bulletin of Magnitogorsk State Technical University G.I. Nosova. 2012. No. 2. URL: <https://cyberleninka.ru/article/n/primenenie-neyronnyh-setey-dlya-modelirovaniya-energossilovyh-parametrov-kletey>

- chistovoy-gruppy-nshsgp-2000-oao-mmk.
2. Anding K. et al. Comparison of the performance of innovative deep learning and classical methods of machine learning to solve industrial recognition tasks. NASA Astrophysics Data System (ADS) // Proceedings of the SPIE. 2019. Vol. 11144. P. 11.
  3. Bendaoud R et al. New method for extracting physical parameters of PV generators combining an implemented genetic algorithm and the simulated annealing algorithm. NASA Astrophysics Data System (ADS) // Solar Energy:Volume. 2019. No. 194. P. 8.
  4. Bodrov E.E., Safin I.R. Application of the neural network approach in the development of a system for automatic control of the thickness and tension of a continuous rolling mill // ES and K. 2012. No. 20. URL: <https://cyberleninka.ru/article/n/primenenie-neyrosetevogo-podhoda-pri-razrabotke-sistemy-avtomaticheskogo-regulirovaniya-tolschiny-i-natyazheniya-nepriyvno-1>.
  5. Bystrov V.A., Dyakov P.K., Umanets A. G. Operating conditions and wear of the rolls rolling mill hot metal // Proceedings of higher educational institutions. Ferrous metallurgy. 2014. No. 5. P. 24-29
  6. Bystrov V.A., Dyakov P.K., Umanets A.G. Operating conditions and wear of the rolls rolling mill hot metal mill rolls // Proceedings of higher educational institutions. Ferrous metallurgy. 2014. No. 57(5). P. 24-29. URL: <https://doi.org/10.17073/0368-0797-2014-5-24-29>.
  7. Daniel L.S.; Jing Hjo; Lynn A.A. Classifying features in CT imagery: accuracy for some single- and multiple-species classifiers // Proceedings, 3rd International Seminar. Workshop on Scanning Technology and Image Processing on Wood. 1998. Vol. 342. P. 20.
  8. Dubinsky F.S., Vydrin A.V., Maltsev P.A., Sosedkova M.A. Modeling and design of technological processes of rolling // SUSU Bulletin. Series: Metallurgy. 2007. No. 13 (85). URL: <https://cyberleninka.ru/article/n/modelirovanie-i-proektirovanie-tehnologicheskikh-protsessov-prokatki>
  9. Eberhart R., Kennedy J. A new optimizer using particle swarm theory. MHS'95 // Proceedings of the Sixth International Symposium on Micro Machine and Human Science 4-6 October 1995. URL: <https://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=3570>.
  10. Gafarov M.F., Senin A.V., Gafarova E.A. Modeling of Material and Heat Balance of Ferromanganese Blast Furnace Smelting Using Computer Environment Lazarus // Materials Science Forum. 2019. Vol. 946. P. 411-416.
  11. Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger, Densely Connected Convolutional Networks // The IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017. P. 8.
  12. Isupova I.L., Trusov P.V. Review of mathematical models on phase transformations in steels // Vestnik PNIPU. Mekhanika. 2013. No. 3. P. 157-191.
  13. Jacobson S. et al. Reliable training of convolutional neural networks for GPR-based buried threat detection using the Adam optimizer and batch normalization. NASA Astrophysics Data System (ADS) // Proceedings of the SPIE. 2019. Vol. 1012. P. 10.
  14. Kingma, Jimmy B.A. A Method for Stochastic Optimization. Computer Science/Machine Learning. URL: <https://arxiv.org/abs/1412.6980>.
  15. Korolev L.N. Evolutional computations and neuronet and genetic algorithms — formal statements // Journal of Mathematical Sciences. 2010. Vol. 168. P. 1.
  16. Lam H.K., Ling S.H., Leung F.H.F., Tam P.K.S. Tuning of the structure and parameters of neural network using an improved genetic algorithm // IECON'01. 27th Annual Conference of the IEEE Industrial Electronics Society (Cat. No. 37243). URL: <https://ieeexplore.ieee.org/abstract/document/976448>.
  17. Lam H.K., Ling S.H., Leung F.H.F., Tam P.K.S. Tuning of the structure and parameters of neural network using an improved genetic algorithm // IECON'01. 27th Annual Conference of the IEEE Industrial Electronics Society (Cat. No. 37243). URL: <https://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=7694>.
  18. Manaswi N.K. Regression to MLP in Keras // Deep Learning with Applications Using Python. 2018. P. 69-89.
  19. Mohammadi M., Forghani K. Solving a stochastic berth allocation problem using a hybrid sequence pair-based simulated annealing algorithm. NASA Astrophysics Data System (ADS) // Engineering Optimization. 2019. Vol. 51. P. 10.
  20. Prafull P., Ram G. Analysis of Randomized Performance of Bias Parameters and Activation Function of Extreme Learning Machine. NASA Astrophysics Data System (ADS) // International Journal of Computer Applications. 2016. Vol. 135. P. 5.
  21. Reihanian M., Baharloo A., Lari Baghal S.M. Wear-Resistant Al/SiC-Gr Hybrid Metal Matrix Composite Fabricated by Multiple Annealing and Roll Bonding. NASA Astrophysics Data System (ADS) // Journal of Materials Engineering and Performance. 2018. Vol. 27. P. 12.
  22. Rychkov S.S., Kinzin D.I. Simulation of roll wear by the finite element method when rolling in simple-shaped gauges // Calibration Bureau. 2013. No. 1. Available from: <https://cyberleninka.ru/article/n/modelirovanie-iznosa-valkov-metodom-konechnyh-elementovpri-prokatke-v-kalibrah-prostoy-formy>.
  23. Shestakova E.N., Potapov A.I., Eagles G.A. Ways or quality improvement forged forming. URL: [http://elar.urfu.ru/bitstream/10995/33343/1/itvmim\\_2014\\_103.pdf](http://elar.urfu.ru/bitstream/10995/33343/1/itvmim_2014_103.pdf).

24. Shilnikov E.V., Paderin S.N. Thermodynamics of Oxygen Solutions in Liquid Ni, Co, Fe and Mn Metals E // Russian Metallurgy (Metally). 2013. No.12. P. 939-943.
25. Srivastava N. et al. Dropout: A Simple Way to Prevent Neural Networks from Overfitting // Journal of Machine Learning Research. 2014. Vol. 15. P. 20.
26. Taylor B.A., Keras R.R. Interface to the Keras Deep Learning Library // Journal of Open Source Software. 2014. No. 2(14). P. 296-298.
27. Vidnerova P., Neruda R. Evolving keras architectures for sensor data analysis // 2017 Federated Conference on Computer Science and Information Systems (FedCSIS). URL: <https://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=8095276>.
28. Voronkov S.N.; Zavalishchin A.N.; Karagodin N.N. Effect of cooling conditions in mill 2000 of the magnitogorsk metallurgical works JSC on the structure and properties of hot-rolled steel 08Yu // NASA Astrophysics Data System (ADS). 2000. Metal Science and Heat Treatment. Vol. 42. P. 4.
29. Yingzhuo Xu, Qing Yang. Research on network load balancing method based on simulated annealing algorithm and genetic algorithm. NASA Astrophysics Data System (ADS) // Journal of Physics: Conference Series. 2019. Vol. 1237. P. 2.
30. Zhao LiuJun, Kong Weizheng, Wang Qiuling, Song Lihua. Construction of power industry corpus based on data mining and machine learning intelligent algorithm. NASA Astrophysics Data System (ADS) // Journal of Physics: Conference Series. 2019. Vol. 1187. P. 2.

## **Development of a material selection model for rolling mill rolls using neural networks**

### **Maksim F. Gafarov**

Postgraduate Student of the Department of materials science  
and physical chemistry of materials,  
Engineer of Chelyabinsk Tube Rolling Plant (ChTPZ),  
South Ural State University (National Research University),  
454080, 76 Lenina av., Chelyabinsk, Russian Federation;  
e-mail: gafarovmax@yandex.ru

### **Kseniya P. Pavlova**

Postgraduate Student of the Department of materials science  
and physical chemistry of materials,  
Engineer,  
South Ural State University (National Research University),  
454080, 76 Lenina av., Chelyabinsk, Russian Federation;  
e-mail: ksesha952@gmail.com

### **Elena A. Gafarova**

PhD in Pedagogy,  
Senior Lecturer of the Department of automobile transport,  
information technologies and methods of teaching technical disciplines,  
South Ural State Humanitarian Pedagogical University,  
454080, 76 Lenina av., Chelyabinsk, Russian Federation;  
e-mail: gafarovaea@cspu.ru

## Abstract

The article presents a mathematical model for optimizing the selection of materials for rolls of rolling mills for agro-industrial equipment based on neural network modeling. The analysis of neural network models is carried out in order to determine the most suitable architecture and other parameters for solving the problem. Specialized software for designing neural network models based on the Keras deep learning library is considered. A neural network with a multilayer perceptron structure (MLP) was developed, and the adequacy of the resulting neural network was verified. The resulting neural network is able to predict the amount of roll wear according to the specified parameters. A special algorithm is described for selecting a roll material that, under given conditions, would have acceptable wear with minimal costs for roll repair. The use of the obtained model allows to reduce the cost of technological equipment of the agro-industrial complex and to increase the overall economic effect of the introduction of new models of equipment.

## For citation

Gafarov M.F., Pavlova K.P., Gafarova E.A. (2020) Ekonomicheskaya model' vybora materialov dlya valkov prokatnykh stanov v agropromyshlennom kholdinge [The economic model of the choice of materials for mill rollers in an agro-industrial holding]. *Ekonomika: vchera, segodnya, zavtra* [Economics: Yesterday, Today and Tomorrow], 10 (10A), pp. 202-218. DOI: 10.34670/AR.2021.11.92.021

## Keywords

Roll wear, rolling mill, neural network modeling, Python, forecasting, optimization.

## References

1. Amirov R.N. et al. (2012) The use of neural networks to simulate the power parameters of the stands of the finishing group NSHSGP 2000 MMK. *Bulletin of Magnitogorsk State Technical University G.I. Nosova*, 2. Available at: <https://cyberleninka.ru/article/n/primenenie-neyronnyh-setey-dlya-modelirovaniya-energossilovyh-parametrov-kletey-chistovoy-gruppy-nshsgp-2000-oao-mmk> [Accessed 16/09/2020].
2. Anding K. et al. (2019) Comparison of the performance of innovative deep learning and classical methods of machine learning to solve industrial recognition tasks. NASA Astrophysics Data System (ADS). *Proceedings of the SPIE*, 11144, p. 11.
3. Bendaoud R et al. (2019) New method for extracting physical parameters of PV generators combining an implemented genetic algorithm and the simulated annealing algorithm. NASA Astrophysics Data System (ADS). *Solar Energy*, 194, p. 8.
4. Bodrov E.E., Safin I.R. (2012) Application of the neural network approach in the development of a system for automatic control of the thickness and tension of a continuous rolling mill. *ES and K.*, 20. Available at: <https://cyberleninka.ru/article/n/primenenie-neyrosetevogo-podhoda-pri-razrabotke-sistemy-avtomaticheskogo-regulirovaniya-tolschiny-i-natyazheniya-nepriyvno-1> [Accessed 16/09/2020].
5. Bystrov V.A., Dyakov P.K., Umanets A. G. (2014) Operating conditions and wear of the rolls rolling mill hot metal. *Proceedings of higher educational institutions. Ferrous metallurgy*, 5, pp. 24-29.
6. Bystrov V.A., Dyakov P.K., Umanets A.G. (2014) Operating conditions and wear of the rolls rolling mill hot metal mill rolls. *Proceedings of higher educational institutions. Ferrous metallurgy*, 57(5), pp. 24-29. Available at: <https://doi.org/10.17073/0368-0797-2014-5-24-29> [Accessed 16/09/2020].
7. Daniel L.S.; Jing Hю; Lynn A.A. (1998) Classifying features in CT imagery: accuracy for some single- and multiple-species classifiers. *Proceedings, 3rd International Seminar. Workshop on Scanning Technology and Image Processing on Wood*, 342, p. 20.
8. Dubinsky F.S., Vydrin A.V., Maltsev P.A., Sosedkova M.A. (2007) Modeling and design of technological processes of rolling. *SUSU Bulletin. Series: Metallurgy*, 13 (85). Available at: <https://cyberleninka.ru/article/n/modelirovanie-i-proektirovanie-tehnologicheskikh-protsessov-prokatki> [Accessed 16/09/2020].
9. Eberhart R., Kennedy J. (1995) A new optimizer using particle swarm theory. MHS'95. *Proceedings of the Sixth International Symposium on Micro Machine and Human Science*, 4-6th October. Available at:



- <https://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=3570> [Accessed 16/09/2020].
10. Gafarov M.F., Senin A.V., Gafarova E.A. (2019) Modeling of Material and Heat Balance of Ferromanganese Blast Furnace Smelting Using Computer Environment Lazarus. *Materials Science Forum*, 946, pp. 411-416.
  11. Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. (2017) Weinberger, Densely Connected Convolutional Networks. *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, p. 8.
  12. Isupova I.L., Trusov P.V. (2013) Review of mathematical models on phase transformations in steels. *Perm National Research Polytechnic University Mechanics Bulletin*, 3, pp. 157-191.
  13. Jacobson S. et al. (2019) Reliable training of convolutional neural networks for GPR-based buried threat detection using the Adam optimizer and batch normalization. NASA Astrophysics Data System (ADS). *Proceedings of the SPIE*, 1012, p. 10.
  14. Kingma, Jimmy B.A. *A Method for Stochastic Optimization. Computer Science/Machine Learning*. Available at: <https://arxiv.org/abs/1412.6980> [Accessed 16/09/2020].
  15. Korolev L.N. (2010) Evolutional computations and neuronet and genetic algorithms — formal statements. *Journal of Mathematical Sciences*, 168, p. 1.
  16. Lam H.K., Ling S.H., Leung F.H.F., Tam P.K.S. Tuning of the structure and parameters of neural network using an improved genetic algorithm. *IECON'01. 27th Annual Conference of the IEEE Industrial Electronics Society (Cat. No. 37243)*. Available at: <https://ieeexplore.ieee.org/abstract/document/976448> [Accessed 16/09/2020].
  17. Lam H.K., Ling S.H., Leung F.H.F., Tam P.K.S. Tuning of the structure and parameters of neural network using an improved genetic algorithm. *IECON'01. 27th Annual Conference of the IEEE Industrial Electronics Society (Cat. No. 37243)*. Available at: <https://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=7694> [Accessed 16/09/2020].
  18. Manaswi N.K. (2018) Regression to MLP in Keras. *Deep Learning with Applications Using Python*, pp. 69-89.
  19. Mohammadi M., Forghani K. (2019) Solving a stochastic berth allocation problem using a hybrid sequence pair-based simulated annealing algorithm. NASA Astrophysics Data System (ADS). *Engineering Optimization*, 51, p. 10.
  20. Prafull P., Ram G. (2016) Analysis of Randomized Performance of Bias Parameters and Activation Function of Extreme Learning Machine. NASA Astrophysics Data System (ADS). *International Journal of Computer Applications*, 135, p. 5.
  21. Reihanian M., Baharloo A., Lari Baghal S.M. (2018) Wear-Resistant Al/SiC-Gr Hybrid Metal Matrix Composite Fabricated by Multiple Annealing and Roll Bonding. NASA Astrophysics Data System (ADS). *Journal of Materials Engineering and Performance*, 27, p. 12.
  22. Rychkov S.S., Kinzin D.I. (2013) Simulation of roll wear by the finite element method when rolling in simple-shaped gauges. *Calibration Bureau*, 1. Available from: <https://cyberleninka.ru/article/n/modelirovanie-iznosa-valkov-metodom-konechnyh-elementovpri-prokatke-v-kalibrah-prostoy-formy> [Accessed 16/09/2020].
  23. Shestakova E.N., Potapov A.I., Eagles G.A. *Ways or quality improvement forged forming*. Available at: [http://elar.urfu.ru/bitstream/10995/33343/1/itvmim\\_2014\\_103.pdf](http://elar.urfu.ru/bitstream/10995/33343/1/itvmim_2014_103.pdf).
  24. Shilnikov E.V., Paderin S.N. (2013) Thermodynamics of Oxygen Solutions in Liquid Ni, Co, Fe and Mn Metals E. *Russian Metallurgy (Metally)*, 12, pp. 939-943.
  25. Srivastava N. et al. (2014) Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15, p. 20.
  26. Taylor B.A., Keras R.R. (2014) Interface to the Keras Deep Learning Library. *Journal of Open Source Software*, 2(14), pp. 296-298.
  27. Vidnerova P., Neruda R. Evolving keras architectures for sensor data analysis. *2017 Federated Conference on Computer Science and Information Systems (FedCSIS)*. Available at: <https://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=8095276>.
  28. Voronkov S.N.; Zavalishchin A.N.; Karagodin N.N. Effect of cooling conditions in mill 2000 of the magnitogorsk metallurgical works JSC on the structure and properties of hot-rolled steel 08Yu. *NASA Astrophysics Data System (ADS)*. *2000. Metal Science and Heat Treatment*, 42, p. 4.
  29. Yingzhuo Xu, Qing Yang. (2019) Research on network load balancing method based on simulated annealing algorithm and genetic algorithm. NASA Astrophysics Data System (ADS). *Journal of Physics: Conference Series*, 1237, p. 2.
  30. Zhao LiuJun, Kong Weizheng, Wang Qiuling, Song Lihua. (2019) Construction of power industry corpus based on data mining and machine learning intelligent algorithm. NASA Astrophysics Data System (ADS). *Journal of Physics: Conference Series*, 1187, p. 2.