

ПРОБЛЕМЫ МЕХАНИКИ ЦЕЛЛЮЛОЗНО-БУМАЖНЫХ МАТЕРИАЛОВ



**МАТЕРИАЛЫ
V МЕЖДУНАРОДНОЙ
НАУЧНО-ТЕХНИЧЕСКОЙ КОНФЕРЕНЦИИ
ПОСВЯЩЕННОЙ ПАМЯТИ
ПРОФЕССОРА В.И. КОМАРОВА**

**Архангельск
2019**

ПРОГНОЗИРОВАНИЕ КАЧЕСТВА ТАРНОГО КАРТОНА С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Д.Н. Жирнов¹, Е.В. Дернова², Д.А. Дулькин²

¹ ООО «Сухонский КБК», Сокол, Россия

² ООО «УК «ОБФ», Москва, Россия

В статье представлены практические результаты использования методов машинного обучения для прогнозирования качества тарного картона.

PREDICTION OF THE CARDBOARD PRODUCT QUALITY USING THE MACHINE LEARNING METHODS

D.N. Zhirnov¹, E.V. Dernova², D.A. Dulkin²

¹ LLC «Suhonsky BPM», Sokol, Russia

² LLC «Consolidated Paper Mill», Moscow, Russia

This article is about the practical results of using machine learning methods for production cardboard quality.

Эффективность работы любого предприятия является залогом конкурентоспособности и повышения качества готовой продукции. К большому сожалению, оценка эффективности работы оборудования происходит постфактум, т.е. событие уже произошло и на него не повлиять. Для снижения данного эффекта современные системы менеджмента качества используют целевой подход к управлению несоответствиями с разработкой корректирующих мероприятий для предотвращения появления данных проблем в будущем. Эффективность данных методик в значительной степени зависит от квалифицированности персонала в области выявления причин возникновения проблем с качеством готовой продукции. Типичный технологический процесс представляет собой многокомпонентную взаимосвязанную систему и персоналу крайне сложно выявить истинные причины проблем, которые могут носить «системный характер». К тому же, объем накопленных данных с использованием соответствующего уровня автоматизации, может быть приравнен к объему Big data [1].

Развитие современного общества не представляется возможным без передовых информационных технологий. Используя современные информационные технологии, в т.ч. поисковые системы типа «Яндекс», «Google»



и др., пользователь не замечает, что они основаны на довольно сложных механизмах, которые используют методы машинного обучения. Согласно определению, машинное обучение - класс методов искусственного интеллекта, характерной чертой которых является не прямое решение задачи, а обучение в процессе применения решений множества сходных задач. Для построения таких методов используются средства математической статистики, численных методов, методов оптимизации, теории вероятностей, теории графов, различные техники работы с данными в цифровой форме [2].

Таким образом, использование методов машинного обучения применительно к процессам производства тарного картона позволяет использовать их для выявления «системных» причин возникающих проблем. В частности, нейронные сети (рис. 1), исходя из названия, моделируют поведение человеческого мозга. Нейронная сеть состоит из множества нейронов, которые благодаря взаимодействию между собой получают способность к обучению. После обучения данные сети могут прогнозировать результат по входным параметрам. Таким образом, задачу с предсказанием возможных проблем с качеством готовой продукции можно решить используя нейронные сети, которые выявляют скрытые взаимосвязи и способны применить свой «опыт» к новым входным данным.




Рис. 1. Структура нейронной сети [3]

Необходимым условием правильного функционирования нейронной сети является определение ее архитектуры, с последующей установкой количества слоев и нейронов. Каждый нейрон в сети имеет свой вес. Обучение



состоит из отдельных эпох. В пределах каждой эпохи нейронная сеть изучает входные данные и ключевой результат и пытается прогнозировать ключевое значение. Затем, на основании целевой функции, происходит оптимизация весов каждого нейрона для увеличения точности предсказаний.

ООО «Сухонский КБК» проводит системные исследования в области применения нейронных сетей для прогнозирования качества готовой продукции. Для реализации этого выполняются следующие инструменты:

- Использование информационной базы ИС «Управление производственным предприятием» в качестве источника данных для создания обучающей и тестовой выборки. Средствами языка запросов ИС данные выравниваются по времени и единице оборудования.

- Полученные из ИС данные проходят процедуру «нормализации», которая является необходимым требованием для входных данных нейронной сети. Т.е. итоговый результат, который мы желаем спрогнозировать преобразуется в массив от 0 до 1, где 0 – минимальное значение, 1 – максимальное значение.

- Использование программной библиотеки Tensorflow для построения архитектуры нейронной сети, настройки ее параметров и проведения процедур обучения и прогнозирования.

В качестве входных данных используются следующие технологические параметры:

- Степень помола макулатурной массы в напорном ящике бумагодельной машины (БДМ);
- pH макулатурной массы в напорном ящике;
- температура массы в напорном ящике;
- концентрация регистровой воды;
- средняя масса 1 м² готовой продукции;

В качестве целевого значения для предсказания используется значение показателя «Абсолютное сопротивление продавливанию».

В качестве обучающей выборки используется база из 800 значений, в качестве тестовой - 153 значений.

Результаты предсказаний нейронной сети представлены на рис. 2.




Рис. 2. Сравнение фактических и предсказанных значений показателя «Абсолютное сопротивление продавливанию» с использованием нейронной сети

В целом можно отметить хорошую сходимость между фактическими и предсказанными значениями, среднеквадратичная ошибка составила 0,0094.

На основании полученных данных была высчитана ошибка предсказания, а также ее градация.

Ошибка предсказания рассчитана по формуле:

$$O = \frac{|Y - \hat{Y}|}{Y} \times 100 \%, \quad (1)$$

где O – ошибка предсказания, %; Y – фактическое значение, кПа; \hat{Y} – предсказанное значение, кПа;

Данные представлены в табл. 1.

Таблица 1. Расчет погрешности предсказанных значений

Ошибка, %	Количество значений, шт.	Количество значений, %	Максимальная ошибка предсказания, кПа
Менее 2	33	21,4	± 7,6
2-4	36	23,4	± 15,2
5-7	41	26,6	± 26,5
8-10	22	14,3	± 37,9
10 и более	22	14,3	



На основании данных табл. 1 можно сделать вывод о том, что большинство значений – 71,4 % лежит в пределах ошибки предсказания – до 7 %, при этом фактический разброс значений составляет 253...488 кПа. Более высокие значения ошибок (более 8 %) объясняются недостаточным объемом входных данных для адекватного предсказания значения.

Основные выводы:

1. Использование нейронных сетей позволяет довольно точно (ошибка предсказания не больше 7 % для 71,4 % предсказанных значений) предсказывать фактические значения отдельных физико-механических показателей.

2. Расширение списка входных технологических параметров для тренировки и тонкая настройка параметров самой нейронной сети способны в дальнейшем увеличить точность предсказаний.

3. Получение предсказанных значений on-line возможно при обеспечении достаточных вычислительных мощностей и автоматизации процесса выгрузки данных на вход нейронной сети посредством современных инструментов для работы с Big Data [1].

4. На основе анализа структуры нейронной сети предполагается разработка системы рекомендаций для технологического персонала для поддержания или увеличения физико-механических показателей продукции в зависимости от текущих параметров технологического режима.

Список литературы

1. Большие данные // ru.wikipedia.org: Википедия свободная энциклопедия: https://ru.wikipedia.org/wiki/Большие_данные (дата обращения: 09.06.2019).
2. Машинное обучение // ru.wikipedia.org: Википедия свободная энциклопедия: https://ru.wikipedia.org/wiki/Машинное_обучение (дата обращения: 09.06.2019).
3. Understanding, Building and Using Neural Network Machine Learning Models using Oracle 18c // developer.oracle.com: Developer Article: <https://developer.oracle.com/databases/neural-network-machine-learning.html> (дата обращения: 09.06.2019).