

<https://doi.org/10.21603/2074-9414-2021-3-593-603>
УДК 004.032.26

Оригинальная статья
<http://fptt.ru>

Моделирование процесса интенсификации экстракции изогумулону в роторно-пульсационном аппарате при помощи нейронных сетей



А. В. Шафрай¹, Е. А. Сафонова¹, Д. М. Бородулин¹,
Я. С. Головачева^{1,*}, С. А. Ратников¹, В. Б. В. Керлос²

¹ Кемеровский государственный университет , Кемерово, Россия

² Каирский университет , Гиза, Египет

Поступила в редакцию: 20.05.2021

Принята после рецензирования: 10.06.2021

Принята в печать: 15.07.2021

*e-mail: itumr@yandex.ru



© А. В. Шафрай, Е. А. Сафонова, Д. М. Бородулин,
Я. С. Головачева, С. А. Ратников, В. Б. В. Керлос, 2021

Аннотация.

Введение. В последние годы искусственные нейронные сети снова стали популярным инструментом в науке и технологиях. Их начали применять в пищевой промышленности относительно недавно, но с каждым годом количество научных исследований с их использованием растет. Поэтому моделирование технологических процессов с помощью нейронных сетей является актуальной темой. Цель работы – разработка искусственной нейронной сети, способной прогнозировать содержание изогумулону в хмелевом экстракте при заданных технологических параметрах работы роторно-пульсационного аппарата.

Объекты и методы исследования. Математическое моделирование произведено на основе экспериментальных данных, полученных в процессе работы аппарата. За выходной параметр было принято содержание изогумулону в хмелевом экстракте I (мг/дм³). Входные переменные: температура обработки t (°С), частота вращения ротора n (об/мин), время обработки τ (мин), зазор между зубьями ротора и статора s (мм).

Результаты и их обсуждение. Была произведена идентификация искусственной нейронной сети. Модель получила следующие параметры: 2 скрытых слоя; 30 нейронов в каждом скрытом слое; GELU использовалась в качестве функции активации нейронов; функция потерь – MSE Loss; шаг обучения – 0,001; оптимизатор – Adam; применена регуляризация L2 со значением 0,00001; обучающая выборка состояла из 4 батчей по 16 записей в каждом. Обучение длилось 9801 эпоху. Точность искусственной нейронной сети определялась как средняя относительная погрешность и составила 1,67 %. В ходе исследования была построена регрессионная модель, погрешность которой оказалась низкой (2,85 %). Точность нейронной сети обладает лучшей способностью предсказывать значение выходной переменной, чем точность регрессионной модели. Точность искусственной нейронной сети будет выше, т. к. она замерялась на данных, которых не было в обучении (тестовая выборка). Регрессионная модель при тестировании на незнакомых данных показывает результаты гораздо хуже.

Выводы. Применение искусственных нейронных сетей для моделирования технологических процессов имеет большой потенциал и требует дальнейшего изучения и применения.

Ключевые слова. Искусственная нейронная сеть, моделирование, роторно-пульсационный аппарат, пиво, хмель

Финансирование. Работа выполнена при финансовой поддержке Кемеровского государственного университета (КемГУ)  (Индивидуальный грант для молодых ученых 2020 г.). На базе (оборудовании) Центра коллективного пользования научным оборудованием КемГУ в рамках соглашения № 075-12021-694 от 05.08.2021, заключенного между Министерством науки и высшего образования Российской Федерации (Минобрнауки России)  и Кемеровским государственным университетом (уникальный идентификатор контракта RF----2296.61321X0032).

Для цитирования: Моделирование процесса интенсификации экстракции изогумулону в роторно-пульсационном аппарате при помощи нейронных сетей / А. В. Шафрай [и др.] // Техника и технология пищевых производств. 2021. Т. 51. № 3. С. 593–603. <https://doi.org/10.21603/2074-9414-2021-3-593-603>.

Original article

Available online at <http://fptt.ru/eng>

Neuron Network Modeling of Intensification of Isogumulone Extraction in a Rotary Pulse Generator

**Anton V. Shafrai¹, Elena A. Safonova¹, Dmitry M. Borodulin¹,
Yana S. Golovacheva^{1,*}, Sergey A. Ratnikov¹,
Wasfie Barsoom Wasef Kerlos²**

¹ Kemerovo State University, Kemerovo, Russia

² Cairo University, Giza, Egypt

Received: May 20, 2021

Accepted in revised form: June 10, 2021

Accepted for publication: July 15, 2021

*e-mail: iitumr@yandex.ru



© A.V. Shafrai, E.A. Safonova, D.M. Borodulin, Ya.S. Golovacheva, S.A. Ratnikov, W.B.W. Kerlos, 2021

Abstract.

Introduction. Artificial neural networks are a popular tool of contemporary research and technology, including food science, where they can be used to model various technological processes. The present research objective was to develop an artificial neural network capable of predicting the content of isogumulone in a hop extract at given technological parameters of the rotary pulse generator.

Study objects and methods. The mathematical modeling was based on experimental data. The isogumulone content in the hop extract I (mg/dm³) served as an output parameter. The input variables included: processing temperature t (°C), rotor speed n (rpm), processing time τ (min), and the gap between the rotor teeth and stator s (mm).

Results and discussion. The resulting model had the following parameters: two hidden layers, 30 neurons each; neuron activation function – GELU; loss function – MSELoss; learning step – 0.001; optimizer – Adam; L2 regularization at 0.00001; training set of four batches, 16 records each; 9,801 epochs. The accuracy of the artificial neural network (1.67%) was defined as the mean relative error. The error of the regression model was also low (2.85%). The neural network proved to be more accurate than the regression model and had a better ability to predict the value of the output variable. The accuracy of the artificial neural network was higher because it used test data not included in the training. The regression model when tested on test data showed much worse results.

Conclusion. Artificial neural networks proved extremely useful as a means of technological modeling and require further research and application.

Keywords. Artificial neural network, modeling, rotary-pulsating apparatus, beer, hop

Funding. The research was supported by Kemerovo State University (KemSU) as an individual grant for young scientists (2020). The research was conducted on the premises of the Research Equipment Sharing Center of Kemerovo State University, agreement No. 075-12021-694 dated August 5, 2021, between the Ministry of Science and Higher Education of the Russian Federation (Minobrnauka) and Kemerovo State University (contract identifier RF---2296.61321X0032).

For citation: Shafrai AV, Safonova EA, Borodulin DM, Golovacheva YaS, Ratnikov SA, Kerlos WBW. Neuron Network Modeling of Intensification of Isogumulone Extraction in a Rotary Pulse Generator. Food Processing: Techniques and Technology. 2021;51(3):593–603. (In Russ.). <https://doi.org/10.21603/2074-9414-2021-3-593-603>.

Введение

Прогресс производственной деятельности предприятий России и повышение общего экономического уровня страны в настоящее время является одной из важнейших задач государства, решение которой невозможно без участия науки. Повышение эффективности производства может происходить за счет внедрения инновационных технологий, которые связаны с изобретением нового высококачественного оборудования для предприятий, автоматизацией действующих производств и разработкой современных способов прогнозирования качества готовой продукции. Последний аспект заключается в разработке моделей динамических объектов. В условиях научно-технического прогресса одним из приоритетных исследований является

развитие искусственного интеллекта и нейронных сетей как одного из его направлений.

Искусственные нейронные сети (ИНС) – инструмент, который с каждым годом все больше проникает в самые разнообразные разделы науки и техники. Такой успех связан с последними достижениями исследователей по созданию архитектур ИНС в сфере распознавания образов, детекции и сегментации изображений и работы с естественными языками. Данные достижения в последние годы стали доступны за счет открытости информации, исследований крупных ИТ-компаний, создания универсальных средств по работе с ИНС. Для выполнения сложных задач созданы сложные архитектуры ИНС, среди которых сверточные, рекуррентные и другие нейронные сети. Более

простые, полносвязные (fully-connected) нейронные сети хорошо подходят для решения задач анализа и моделирования экспериментальных данных. Иначе говоря, для решения задачи регрессии.

В научных исследованиях пищевой промышленности наиболее распространенным методом анализа данных является регрессионный анализ. Однако с каждым годом появляется все больше публикаций, в которых для моделирования процессов применяются ИНС [1–16]. Точность регрессионных моделей сопоставима с точностью ИНС, но зачастую уступает ей.

В данной работе ИНС применялись для обработки экспериментальных данных по определению содержания изогумулона в хмелевом экстракте. Его образцы получены с помощью роторно-пульсационного аппарата при различных технических и технологических характеристиках.

Данное исследование проведено в инженеринговом центре «FOOD ENGINEERING» кафедры Технологическое проектирование пищевых производств Кемеровского государственного университета.

В ходе исследования требовалось написать нейронную сеть, способную предсказать содержание изогумулона в хмелевом экстракте I (мг/дм³) при заданных входных параметрах: температура обработки t (°С), частота вращения ротора n (об/мин), время обработки τ (мин), зазор между зубьями ротора и статора s (мм). Температура обработки менялась в диапазоне от 55 до 85 °С с шагом 15 °С, частота вращения ротора – от 2000 до 3000 об/мин с шагом 500 об/мин, время обработки – от 1 до 3 мин с шагом 1 мин, зазор между зубьями ротора и статора – от 0,1 до 0,5 мм с шагом 0,2 мм.

Гипотеза исследования состояла в том, что модель, созданная с помощью ИНС, должна превзойти по точности модель, созданную с помощью регрессионного анализа. Обучение ИНС должно было происходить по тем же экспериментальным данным, что и построение регрессионной модели.

Объекты и методы исследования

Производство пива – сложный процесс, состоящий из нескольких стадий. Каждая представляет из себя отдельную и сложную в биохимическом, микробиологическом и аппаратурном плане технологию. Процесс приготовления пива включает следующие основные стадии: дробление, затираание, фильтрование, охмеление, брожение и созревание.

На стадии охмеления пивного сусла задаются органолептические показатели напитка (горечь, аромат). При его проведении классическим способом требуются большие затраты энергии, времени и сырья [17]. Разработан новый способ охмеления пивного сусла, который позволяет эффективно использовать сырье, интенсифицировать процесс

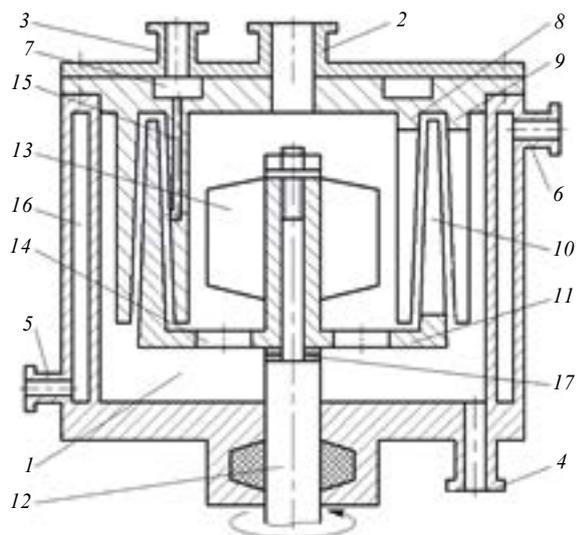
и снизить энергозатраты [18]. Способ состоит в охмелении пивного сусла хмелевым экстрактом, состоящим из хмеля и пивного сусла. Данный экстракт содержит повышенное количество изогумулона – основного компонента горьких веществ охмеленного сусла – за счет воздействия на него гидромеханической кавитации и низкочастотных упругих колебаний. Для их генерирования применялся роторно-пульсационный аппарат (РПА). В последнее время применение данных аппаратов для интенсификации процесса экстракции получило широкое распространение [19–25].

Один из таких аппаратов (рис. 1) разработан в инженеринговом центре «FOOD ENGINEERING» Кемеровского государственного университета. В РПА подаются исходные компоненты через патрубок 2. Внутри аппарата под действием центробежных сил материалы проходят сквозь зубья ротора 10 и статора 8. Твердые частицы, находящиеся в компонентах, измельчаются и истираются. Затем измельченный и перемешанный поток направляется в нижнюю часть ротора и выводится из него через отверстия в ступице 14 ротора и далее через штуцер 4 из аппарата.

На данном роторно-пульсационном аппарате было проведено исследование, полученные результаты которого легли в основу регрессионного анализа и разработки нейронной сети. Суть экспериментов заключалась в том, что в аппарате обрабатывалась суспензия, состоящая из гранулированного хмеля и экстрагента. Для приготовления хмелевого экстракта использовался гранулированный горький хмель «Magnum», а в качестве экстрагента – пивное сусло 12 % плотности. Для исследования процесса охмеления был поставлен полнофакторный эксперимент, значения факторов по уровням которого приведены в таблице 1.

Температура суспензии поддерживалась с помощью тепловой рубашки, соединенной водным универсальным термостатом BWT-U. Для ее контроля в лабораторный стенд был включен. В электрическую схему привода был установлен ЛАТР 9 типа АОСН-20-220-75 У 4 для регулирования частоты вращения вала, которое производилось изменением напряжения обмотки якоря. Для контроля значений данного параметра служил электронный тахометр типа ТЭ 30 5 Р. Межцилиндровый зазор регулировался с помощью регулировочных шайб 17 (рис. 1) вследствие того, что венцы ротора и статоров имеют коническую форму.

В полученных пробах экстракта определялось содержание изогумулона. Метод определения основан на экстракции его из сусла изооктаном и определении оптической плотности изооктанового экстракта на спектрофотометре при длине волны 275 нм. Для этого сусло освобождают от взвешенных частиц центрифугированием. Отбирают пипеткой 10 см³ очищенной жидкости, переносят в стеклянный цилиндр, добавляют 1 см³ 3 Н раствора соляной кислоты и 20 см³ изооктана, закрывают цилиндр пробкой и встряхивают в течение 30 с. Цилиндр



1 – рабочая полость; 2 – штуцер входа свежей реакционной массы; 3 – штуцер входа газовой смеси; 4 – штуцер выхода реакционной массы; 5, 6 – штуцера входа и выхода хладоносителя; 7 – газовая камера; 8 – венец статора внутренний; 9 – венец статора наружный; 10 – венец ротора; 11 – ступица ротора; 12 – вал; 13 – лопасти; 14 – отверстия в ступице ротора; 15 – каналы в зубьях статора; 16 – рубашка; 17 – регулировочные шайбы

Рисунок 1. Роторно-пульсационный аппарат

Figure 1. Rotary pulse generator

оставляют в покое для разделения слоев жидкости. После отстаивания пипеткой отбирают часть прозрачного верхнего слоя и переносят в кювету. В другую кювету наливают чистый изооктан. Кюветы помещают в спектрофотометр и определяют оптическую плотность D при длине волны 275 нм. Содержание изогумулona I (мг/дм³) рассчитывают по формуле:

$$I = 57,2 \cdot D - 5,9 \quad (1)$$

Результаты и их обсуждение

Регрессионный анализ был проведен в программе Statistica 8 в модуле «Общие регрессионные модели» инструментом «Регрессия поверхности отклика».

В результате анализа получена точная модель, показатели которой приведены в таблице 2. Коэффициент корреляции R имеет очень высокое значение – 0,9890. Это означает сильную корреляционную связь, практически приближающуюся к функциональной, между содержанием изогумулona в хмелевом экстракте и входными параметрами. Дисперсия выходного параметра составляет 97,82 %. Об этом говорит коэффициент детерминации R^2 . Высокий показатель критерия Фишера (212,0087) доказывает гипотезу об адекватности модели, что делает ее пригодной для моделирования выходной величины. Нулевое значение p -уровня указывает на то, что модель с вероятностью 0,00 % будет являться лишь случайным совпадением для данных экспериментальных значений, что также говорит об адекватности модели.

Статистические показатели коэффициентов регрессионной модели приведены в таблице 3. Большая разница в значениях t -критерия Стьюдента показывает статистическую значимость различных коэффициентов. Наиболее значимым среди однофакторных коэффициентов является величина зазора между зубьями ротора и статора s , а наименее значимым – частота вращения ротора n . Остальные значения находятся в промежутке между ними с хорошими значениями. При взаимном влиянии двух факторов коэффициенты, в которых входит зазор между зубьями ротора и статора, имеют наименьшие показатели t -критерия, а в которые не входит – наибольшие, что является интересной закономерностью. Статистическая значимость (p -уровень) зеркально отражает значения t -критерия Стьюдента. Она показывает статистическую силу коэффициентов и характеризует случайность особенности экспериментальных данных.

В результате регрессионного анализа можно прийти к выводу, что модель адекватна и пригодна для тестирования. Общий вид математической модели выглядит следующим образом:

$$y = a_0 + \sum_{i=1}^4 a_i x_i + \sum_{i=1}^4 \sum_{j=1}^4 a_{ij} x_i x_j \quad (2)$$

Подставляя значения коэффициентов из таблицы 4 в уравнение 1, получается итоговая регрессионная модель:

Таблица 1. Значение факторов экспериментов по уровням

Table 1. Factor score of the experiments by level

Уровень	Температура обрабатываемой среды t , °C	Частота вращения ротора n , об/мин	Межцилиндровый зазор s , мм	Время обработки τ , мин
Низший	55	2000	0,1	1
Нулевой	70	2500	0,3	2
Верхний	85	3000	0,5	3

Таблица 2. Общие параметры регрессионной модели

Table 2. General parameters of the regression model

Параметр	Значение
Множественный R	0,9890
Множественный R^2	0,9782
F-критерий	212,0087
p-значение	0

$$I = -24,3122 + 0,4754t - 0,0037t^2 + 0,0066n - 2,7623\tau - 0,1701\tau^2 + 47,5444s + 0,2694s^2 + 0,0001t \cdot n + 0,0288t \cdot \tau + 0,0015n \cdot \tau - 0,0404t \cdot s - 0,0019n \cdot s - 0,1732\tau \cdot s \quad (3)$$

Получив законченный вид регрессионной модели, были подсчитаны моделируемые значения содержания изогумулона в хмелевом экстракте. Критерием точности послужила средняя относительная погрешность, которая составила 2,85 %, что является хорошим результатом.

Создание и обучение нейронной сети происходило на языке Python на платформе Colab Laboratory от компании Google. В ходе работы использовалась свободно распространяемая библиотека PyTorch.

Как было отмечено выше, для данного исследования были выбраны полносвязные нейронные сети. Их основная особенность состоит в том, что нейрон в каждом слое связан со всеми нейронами предыдущего слоя и со всеми нейронами следующего слоя. Идентификация архитектуры ИНС сводится к выбору основных параметров сети. Этот процесс осуществляется на основе эмпирических рекомендаций, особенностях экспериментальных

Таблица 3. Статистические показатели коэффициентов модели

Table 3. Statistical indicators of the coefficients of the model

Член модели	Значение	t-критерий	p-уровень
Свободный член	-24,3122	-3,3961	0,001161
t	0,4754	3,7903	0,000328
t ²	-0,0037	-4,4442	0,000035
n	0,0066	1,6671	0,100238
n ²	-0,0000	-1,5121	0,135287
τ	-2,7623	-2,3322	0,022749
τ ²	-0,1701	-0,9176	0,362158
s	47,5444	8,7076	0,000000
s ²	-70,2694	-15,1670	0,000000
t·n	0,0001	4,0417	0,000141
t·τ	0,0288	3,3005	0,001559
n·τ	0,0015	5,6676	0,000000
t·s	-0,0404	-0,9257	0,357976
n·s	-0,0019	-1,4664	0,147276
τ·s	-0,1732	-0,2643	0,792347

Таблица 4. Параметры ИНС

Table 4. Parameters of the artificial neural network

Параметр	Значение
Количество скрытых слоев	2
Количество нейронов в скрытых слоях	30
Функции активации нейронов	GELU
Функции потерь	MSELoss
Шаг обучения	0,001
Оптимизатор	Adam
Регуляризация	L2 = 0,00001
Размер батчей	4
Количество батчей	16
Количество эпох	9801

данных и личном опыте исследователя. Список параметров, а также их значения, определенные для создаваемой ИНС, приведены в таблице 4.

Набор данных для обучения ИНС (датасет) был сформирован из экспериментальных данных полнофакторного эксперимента. Он содержал 81 запись. Датасет был разбит на обучающую (64 записи) и тестовую (17 записей) части и перемешаны в случайном порядке. Весь датасет был нормализован для повышения скорости сходимости алгоритма обучения. Нормализация происходила с помощью уменьшения на минимальное значение и деления на максимальное. Таким образом, все данные были расположены на промежутке от 0 до 1.

Наилучшая конфигурация ИНС включила в себя два скрытых полносвязных слоя с тридцатью нейронами в каждом. Входной слой содержал четыре нейрона для приема входных данных: температуры обработки, частоты вращения ротора, времени обработки, зазора между зубьями ротора и статора. Выходной слой содержал один нейрон, который и рассчитывал прогнозное значение содержания изогумулона в хмелевом экстракте.

В качестве функции активации использовалась GELU, формула которой представлена далее:

$$GELU(x) = x * \Phi(x) \quad (4)$$

где x – аргумент функции; $\Phi(x)$ – кумулятивная функция распределения для Гауссова распределения.

График функции представлен на рисунке 2.

Для функции потерь (лосс-функция) была выбрана MSELoss или среднеквадратическая ошибка, которая имеет следующий вид:

$$MSELoss(y, \hat{y}) = \frac{\sum_{i=0}^N (\hat{y}_i - y_i)^2}{N} \quad (5)$$

где y – вектор выходных значений из датасета; \hat{y} – вектор моделируемых выходных значений; N – количество данных.

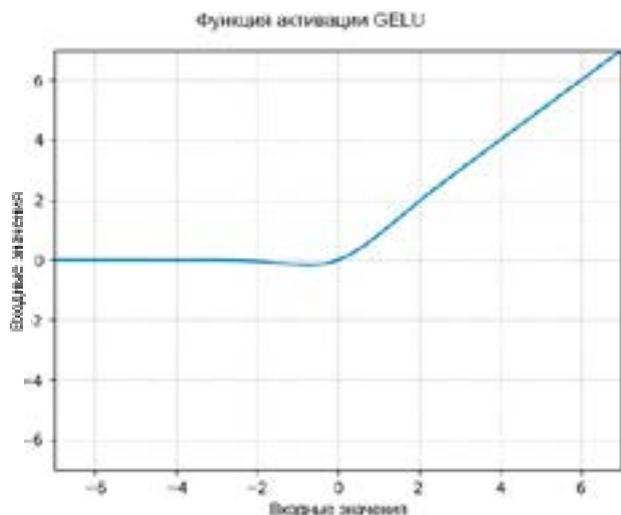


Рисунок 2. График функции GELU

Figure 2. Diagram of GELU

Среди оптимизаторов наилучшим образом подошел Adam (adaptive moment estimation, т. е. адаптивная оценка момента), который является дальнейшей модификацией стохастического градиентного спуска и RMSProp. У него действуют следующие правила обновления весов:

$$W_{t+1} = W_t - \alpha \frac{EMA_{\beta_1}(\nabla f)^t}{\sqrt{EMA_{\beta_2}(\nabla f^2)^t + \epsilon}} \quad (6)$$

где W_{t+1} – новые параметры сети; W_t – текущие параметры сети; α – скорость обучения; $\sqrt{EMA_{\beta_2}(\nabla f^2)^t}$ – экспоненциальное скользящее среднее градиента; β_1 и β_2 – параметры экспоненциального скользящего среднего; ϵ – сглаживающий параметр, исключающий деление на 0.

Наиболее хорошие результаты оптимизатор показал с шагом обучения, равным 0,001, что значительно отличается от стандартного шага (0,0003), заложенного по умолчанию. Это довольно интересное обстоятельство, потому что Adam считается таким оптимизатором, который наилучшим образом работает при стандартных параметрах.

Для нивелирования эффекта переобучения была применена регуляризация Тихонова (L2 или weight decay), которая вносит дополнительный штраф в лосс-функцию. Значение регуляризации составило 0,00001.

Обучающая выборка была разбита на шестнадцать батчей по четыре записи в каждом. Обучение продолжалось на протяжении 9801 эпохи.

Точность ИНС определяют различными способами, которые зависят от поставленной задачи. В проведенном исследовании требовалось решить задачу регрессии и смоделировать содержание изогумулона в хмелевом экстракте при определенных технологических и конструктивных параметрах работы РПА. Для определения точности математических моделей технологических процессов используют относительную точность, поэтому именно она и оценивала точность нейронной сети.

В результате обучения средняя относительная погрешность ИНС составила 1,67 % (рис. 3). Также была рассчитана средняя абсолютная ошибка, которая составила 0,3495 мг/дм³ (рис. 4). Замер погрешностей проводился каждую сотую эпоху. В данных графиках по оси абсцисс откладывались эпохи (каждая сотая), по оси ординат – средняя относительная погрешность в % (рис. 3) и средняя абсолютная погрешность в мг/дм³ (рис. 4).

Визуализация точности приведена на рисунке 5. На изображении по оси абсцисс отсчитываются порядковые номера тестовых значений, а по оси ординат – величины тестовых значений. Синими

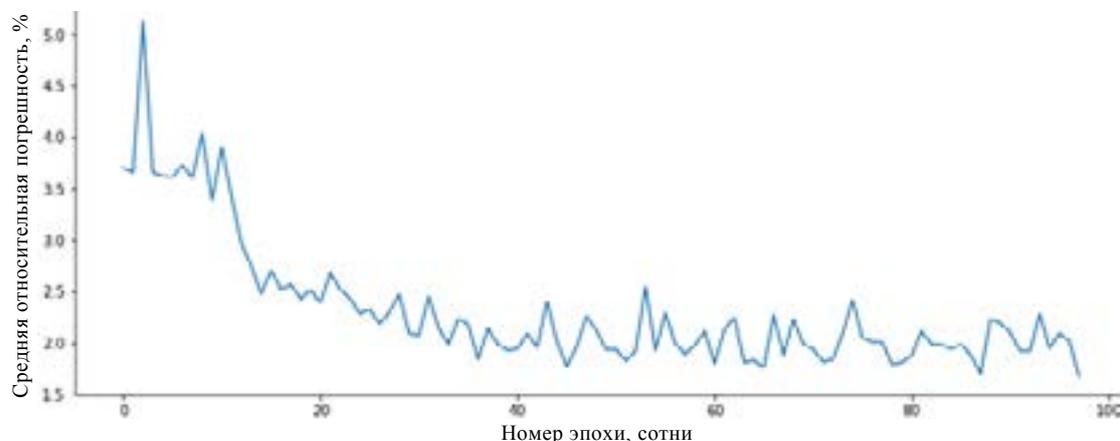


Рисунок 3. Средняя относительная погрешность

Figure 3. Mean relative error

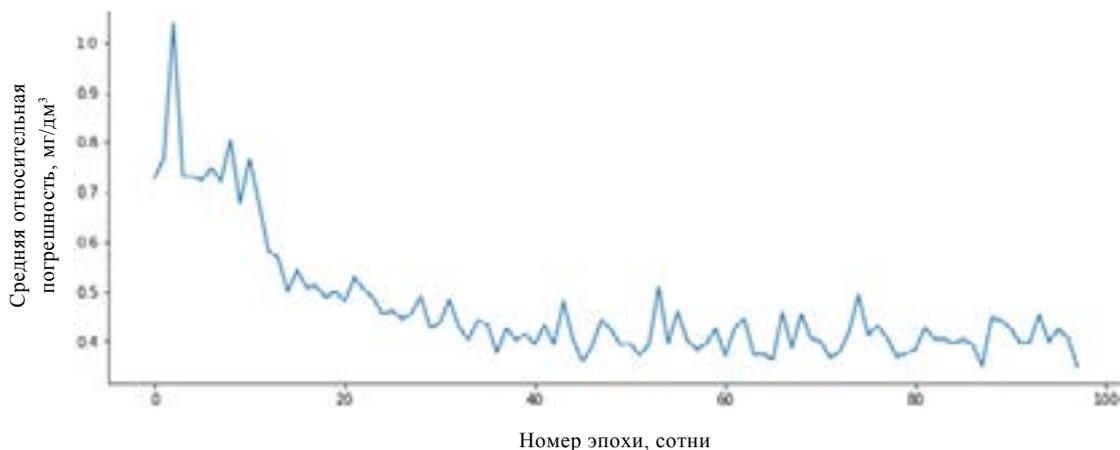


Рисунок 4. Средняя абсолютная погрешность

Figure 4. Mean absolute error

кругами обозначены экспериментальные данные, а красными – моделируемые.

Целью создания математической модели для любого технологического процесса всегда является его оптимизация. Критерием оптимальности в данном исследовании служит максимизация содержания изогумулона в хмелевом экстракте. В соответствии с этим был создан набор данных для тестирования на регрессионной модели и нейронной сети с целью определения наилучших технологических и конструктивных показателей, при которых работа РПА приведет к наибольшей концентрации изогумулона.

Набор данных содержал 1050 записей, в котором температура обработки варьировалась от 55 до 85 °С с шагом 5 °С, частота вращения ротора – от 2000 до 3000 об/мин с шагом 200 об/мин, время обработки – от 1 до 3 мин с шагом 0,5 мин, зазор между зубьями ротора и статора – 0,1 до 0,5 мм с шагом 0,1 мм.

Подготовленные данные были подставлены в обе модели. Предполагалось, что модели могут показать значения технологических параметров процесса работы РПА, при которых содержание изогумулона будет наибольшим и при которых не были проведены экспериментальные исследования, потому что не попали в план эксперимента. Таким образом, модели могли интерполировать содержание изогумулона и предсказать оптимальные технологические параметры, но результаты моделирования определили значения параметров, которые совпали с экспериментальными.

Регрессионная модель показала, что максимальное содержание изогумулона будет при следующих параметрах: температура обработки – 85 °С, частота вращения ротора – 3000 об/мин, время обработки – 3, зазор между зубьями ротора и статора – 0,5 мм. Нейронная сеть: температура обработки – 85 °С, частота вращения ротора – 3000 об/мин, время обработки – 3, зазор между зубьями ротора и статора – 0,3 мм.

Если сравнивать экспериментальные значения с моделируемыми, то во время экспериментов наибольшее количество изогумулона было получено при следующих значениях параметров: температура обработки – 85 °С, частота вращения ротора – 3000 об/мин, время обработки – 3, зазор между зубьями ротора и статора – 0,3 мм, что совпало с результатами нейронной сети. Таким образом, нейронная сеть лучше показала себя на этапе оптимизации технологического процесса.

Оптимальные значения параметров работы РПА как моделируемых, так и экспериментально подтвержденных можно обосновать следующим. Повышение температуры обрабатываемой среды увеличивает показатели по содержанию изогумулона, т. к. он образуется в результате изомеризации гумулонов при кипячении хмеля. При увеличении частоты вращения ротора до значения 3000 об/мин начинает происходить генерирование низкочастотных упругих колебаний и кавитационной энергии, которые воздействуют на обрабатываемую среду. Известно, что данные явления оказывают интенсификацию процессов диспергирования и экстрагирования. Максимальные показатели по выходу изогумулона получены при зазоре $s = 0,3$ мм. Можно предположить, что при зазоре $s = 0,1$ мм частицы гранулированного хмеля подвергаются сильному разрушению, а при зазоре $s = 0,5$ мм не происходит хорошей экстракции компонентов хмеля в пивное сусло.

Выводы

Сравнивая точность регрессионной модели (97,15 %) с искусственными нейронными сетями (98,33 %) становится понятно, что ИНС обладает лучшей способностью предсказывать значение выходной переменной. Также точность ИНС будет выше из-за того, что она замерялась на данных, которых не

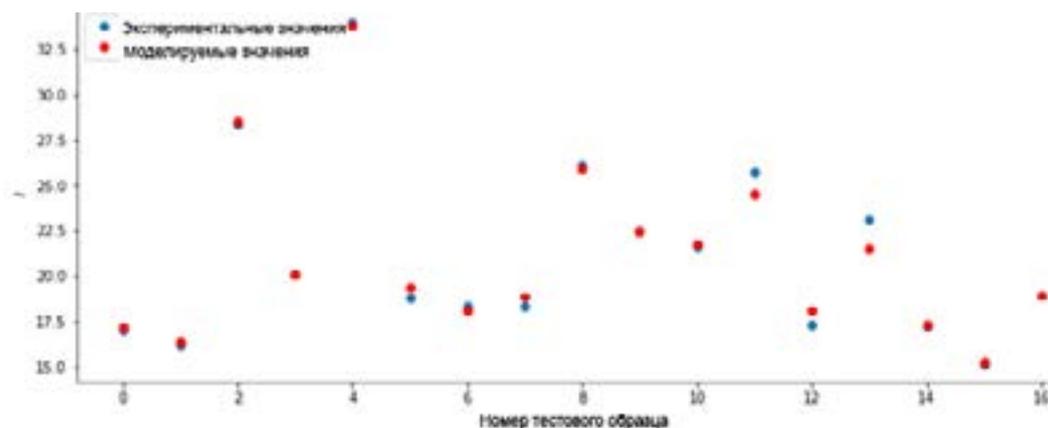


Рисунок 5. Сравнение точности экспериментальных и моделируемых значений

Figure 5. Experimental vs. simulated values

было в обучении (тестовая выборка). Регрессионная модель при тестировании на незнакомых данных показывает результаты гораздо хуже.

Также нейронная сеть смогла лучше оптимизировать процесс, определив технологические и конструкционные параметры, при которых содержание изогумулона при работе РПА будет максимальным, что было подтверждено экспериментальными исследованиями. Таким образом, длительность стадии охмеления пивного суслу сократилась в 1,5–2 раза по сравнению с традиционным способом. Также исследование позволяет уменьшить нормы внесения гранулированного хмеля в суслу в 2 раза, т. к. полученный хмелевой экстракт имеет повышенное содержание изогумулона.

Применение искусственных нейронных сетей для моделирования технологических процессов имеет большой потенциал и требует дальнейшего изучения и применения.

Критерии авторства

А. В. Шафрай – создание регрессионной модели

и модели на основе нейронной сети, написание рукописи. Е. А. Сафонова – аналитический обзор литературы, организация исследований. Д. М. Бородулин – общая редакция рукописи, методология исследований. Я. С. Головачева, С. А. Ратников и К. В. Б. Керлос – получение фактического материала.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Contribution

A.V. Shafrai developed the regression model and the neural network model and wrote the manuscript. E.A. Safonova reviewed scientific publications and supervised the research. D.M. Borodulin edited the manuscript and designed the research methodology. Ya.S. Golovacheva, S.A. Ratnikov, and K.V.B. Kerlos obtained the factual material.

Conflict of interest

The authors declare that there is no conflict of interest regarding the publication of this article.

Список литературы

1. Machine learning approach for the classification of corn seed using hybrid features / A. Ali [et al.] // International Journal of Food Properties. 2020. Vol. 23. № 1. P. 1110–1124. <https://doi.org/10.1080/10942912.2020.1778724>.
2. Black tea withering moisture detection method based on convolution neural network confidence / T. An [et al.] // Journal of Food Process Engineering. 2020. Vol. 43. № 7. <https://doi.org/10.1111/jfpe.13428>.
3. Bhargava A., Barisal A. Automatic detection and grading of multiple fruits by machine learning // Food Analytical Methods. 2020. Vol. 13. № 3. P. 751–761. <https://doi.org/10.1007/s12161-019-01690-6>.
4. Detection of rice plant diseases based on deep transfer learning / J. Chen [et al.] // Journal of the Science of Food and Agriculture. 2020. Vol. 100. № 7. P. 3246–3256. <https://doi.org/10.1002/jsfa.10365>.
5. 1D convolutional neural network for the discrimination of aristolochic acids and their analogues based on near-infrared spectroscopy / X. Chen [et al.] // Analytical Methods. 2019. Vol. 11. № 40. P. 5118–5125. <https://doi.org/10.1039/c9ay01531k>.

6. Codina G. G., Dabija A., Oroian M. Prediction of pasting properties of dough from mixolab measurements using artificial neuronal networks // *Foods*. 2019. Vol. 8. № 10. <https://doi.org/10.3390/foods8100447>.
7. Comparison of the decision tree, artificial neural network and multiple regression methods for prediction of carcass tissues composition of goat kids / B. Ekiz [et al.] // *Meat Science*. 2020. Vol. 161. <https://doi.org/10.1016/j.meatsci.2019.108011>.
8. Artificial neural network modeling and optimization of wheat starch suspension microfiltration using twisted tape as a turbulence promoter / B. Ikonic [et al.] // *Journal of Food Processing and Preservation*. 2019. Vol. 43. № 11. <https://doi.org/10.1111/jfpp.14219>.
9. Modeling the effect of vibration on the quality of stirred yogurt during transportation / A. Lu [et al.] // *Food Science and Biotechnology*. 2020. Vol. 29. № 7. P. 889–896. <https://doi.org/10.1007/s10068-020-00741-7>.
10. Sadeghi E., Haghghi Asl A., Movagharnejad K. Mathematical modelling of infrared-dried kiwifruit slices under natural and forced convection // *Food Science and Nutrition*. 2019. Vol. 7. № 11. P. 3589–3606. <https://doi.org/10.1002/fsn3.1212>.
11. Sadeghi E., Movagharnejad K., Haghghi Asl A. Mathematical modeling of infrared radiation thin-layer drying of pumpkin samples under natural and forced convection // *Journal of Food Processing and Preservation*. 2019. Vol. 43. № 12. <https://doi.org/10.1111/jfpp.14229>.
12. Stangierski J., Weiss D., Kaczmarek A. Multiple regression models and Artificial Neural Network (ANN) as prediction tools of changes in overall quality during the storage of spreadable processed Gouda cheese // *European Food Research and Technology*. 2019. Vol. 245. № 11. P. 2539–2547. <https://doi.org/10.1007/s00217-019-03369-y>.
13. Using a combined neural network – genetic algorithm approach for predicting the complex rheological characteristics of microfluidized sugarcane juice / A. Tarafdar [et al.] // *LWT*. 2020. Vol. 123. <https://doi.org/10.1016/j.lwt.2020.109058>.
14. Classification by artificial neural network for mushroom color changing under effect UV-A irradiation / M. V. Torshizi [et al.] // *Carpathian Journal of Food Science and Technology*. 2020. Vol. 12. № 2. P. 157–167. <https://doi.org/10.34302/crpfjst/2020.12.2.16>.
15. Vacuum drying of sweet cherry: Artificial neural networks approach in process optimization / A. Vakula [et al.] // *Journal of Food Processing and Preservation*. 2020. Vol. 44. № 11. <https://doi.org/10.1111/jfpp.14863>.
16. Predicting mechanical properties of golden delicious apple using ultrasound technique and Artificial Neural Network / H. Vasighi-Shojae [et al.] // *Food Analytical Methods*. 2020. Vol. 13. № 3. P. 699–705. <https://doi.org/10.1007/s12161-019-01689-z>.
17. Mosher M., Trantham K. *Brewing science: A multidisciplinary approach*. Cham: Springer, 2017. 408 p. <https://doi.org/10.1007/978-3-319-46394-0>.
18. Способ охмеления пивного суслу: пат. 2634870С1 Рос. Федерация. № 2016129114 / Бородулин Д. М. [и др.]; заявл. 15.07.2016; опубл. 07.11.2017; Бюл. № 31. 5 с.
19. Исследование процесса растворения полидисперсных материалов в установке с роторно-пульсационным аппаратом / А. А. Кухленко [и др.] // *Инженерно-физический журнал*. 2015. Т. 88. № 1. С. 25–36. <https://doi.org/10.1007/s10891-015-1164-z>.
20. Иванов Е. В., Матвеева Н. А. Экстрагирование растительного сырья с периодическим интенсивным гидродинамическим режимом // *Вестник международной академии холода*. 2015. № 4. С. 16–22.
21. Романова Н. К., Китаевская С. В., Решетник О. А. Оптимизация процесса экстракции ягод клюквы в роторно-пульсационном аппарате // *Вестник технологического университета*. 2018. Т. 21. № 10. С. 166–170.
22. Сафонова Е. А., Потапов А. Н., Вагайцева Е. А. Интенсификация технологических процессов производства пива при использовании роторно-пульсационного аппарата // *Техника и технология пищевых производств*. 2015. Т. 36. № 1. С. 74–81.
23. Совершенствование процесса получения растительного масла из семян винограда / А. Т. Телешев [и др.] // *Научное обозрение*. 2015. № 15. С. 219–225.
24. Gutova S. G., Novoseltseva M. A., Kagan E. S. Mathematical modeling of isohumulone extraction process in beer wort hopping // *Proceedings – 2019 International Russian Automation Conference*. Sochi. 2019. <https://doi.org/10.1109/RUSAUTOCON.2019.8867778>.
25. Определение рациональных параметров работы вибрационного смесителя для получения мучных сыпучих смесей / Д. М. Бородулин [и др.] // *Техника и технология пищевых производств*. 2021. Т. 51. № 1. С. 196–208. <https://doi.org/10.21603/2074-9414-2021-1-196-208>.
26. Просеков А. Ю. Роль межфазных поверхностных явлений в производстве дисперсных продуктов с пенной структурой (обзор) // *Хранение и переработка сельхозсырья*. 2001. № 8. С. 24–27.
27. Просеков А. Ю. *Физико-химические основы получения пищевых продуктов с пенной структурой*. Кемерово: Кемеровский технологический институт пищевой промышленности, 2001. 172 с.

References

1. Ali A, Qadri S, Mashwani WK, Belhaouari SB, Naeem S, Rafique S, et al. Machine learning approach for the classification of corn seed using hybrid features. *International Journal of Food Properties*. 2020;23(1):1110–1124. <https://doi.org/10.1080/10942912.2020.1778724>.
2. An T, Yu H, Yang C, Liang G, Chen J, Hu Z, et al. Black tea withering moisture detection method based on convolution neural network confidence. *Journal of Food Process Engineering*. 2020;43(7). <https://doi.org/10.1111/jfpe.13428>.
3. Bhargava A, Barisal A. Automatic detection and grading of multiple fruits by machine learning. *Food Analytical Methods*. 2020;13(3):751–761. <https://doi.org/10.1007/s12161-019-01690-6>.
4. Chen J, Zhang D, Nanekaran YA, Li D. Detection of rice plant diseases based on deep transfer learning. *Journal of the Science of Food and Agriculture*. 2020;100(7):3246–3256. <https://doi.org/10.1002/jsfa.10365>.
5. Chen X, Chai Q, Lin N, Li X, Wang W. 1D convolutional neural network for the discrimination of aristolochic acids and their analogues based on near-infrared spectroscopy. *Analytical Methods*. 2019;11(40):5118–5125. <https://doi.org/10.1039/c9ay01531k>.
6. Codina GG, Dabija A, Oroian M. Prediction of pasting properties of dough from mixolab measurements using artificial neuronal networks. *Foods*. 2019;8(10). <https://doi.org/10.3390/foods8100447>.
7. Ekiz B, Baygul O, Yalcintan H, Ozcan M. Comparison of the decision tree, artificial neural network and multiple regression methods for prediction of carcass tissues composition of goat kids. *Meat Science*. 2020;161. <https://doi.org/10.1016/j.meatsci.2019.108011>.
8. Ikonc B, Bera O, Pavlicevic J, Kojic P, Jokic A, Ikonc P, et al. Artificial neural network modeling and optimization of wheat starch suspension microfiltration using twisted tape as a turbulence promoter. *Journal of Food Processing and Preservation*. 2019;43(11). <https://doi.org/10.1111/jfpp.14219>.
9. Lu A, Wei X, Cai R, Xiao S, Yuan H, Gong J, et al. Modeling the effect of vibration on the quality of stirred yogurt during transportation. *Food Science and Biotechnology*. 2020;29(7):889–896. <https://doi.org/10.1007/s10068-020-00741-7>.
10. Sadeghi E, Haghighi Asl A, Movagharnejad K. Mathematical modelling of infrared-dried kiwifruit slices under natural and forced convection. *Food Science and Nutrition*. 2019;7(11):3589–3606. <https://doi.org/10.1002/fsn3.1212>.
11. Sadeghi E, Movagharnejad K, Haghighi Asl A. Mathematical modeling of infrared radiation thin-layer drying of pumpkin samples under natural and forced convection. *Journal of Food Processing and Preservation*. 2019;43(12). <https://doi.org/10.1111/jfpp.14229>.
12. Stangierski J, Weiss D, Kaczmarek A. Multiple regression models and Artificial Neural Network (ANN) as prediction tools of changes in overall quality during the storage of spreadable processed Gouda cheese. *European Food Research and Technology*. 2019;245(11):2539–2547. <https://doi.org/10.1007/s00217-019-03369-y>.
13. Tarafdar A, Kaur BP, Nema PK, Babar OA, Kumar D. Using a combined neural network – genetic algorithm approach for predicting the complex rheological characteristics of microfluidized sugarcane juice. *LWT*. 2020;123. <https://doi.org/10.1016/j.lwt.2020.109058>.
14. Torshizi MV, Asghari A, Tabarsa F, Danesh P, Akbarzadeh A, et al. Classification by artificial neural network for mushroom color changing under effect UV-A irradiation. *Carpathian Journal of Food Science and Technology*. 2020;12(2):157–167. <https://doi.org/10.34302/crpjfst/2020.12.2.16>.
15. Vakula A, Pavlic B, Pezo L, Tepic Horecki A, Danicic T, Raicevic L, et al. Vacuum drying of sweet cherry: Artificial neural networks approach in process optimization. *Journal of Food Processing and Preservation*. 2020;44(11). <https://doi.org/10.1111/jfpp.14863>.
16. Vasighi-Shojae H, Gholami-Parashkouhi M, Mohammadzamani D, Soheili A. Predicting mechanical properties of golden delicious apple using ultrasound technique and Artificial Neural Network. *Food Analytical Methods*. 2020;13(3):699–705. <https://doi.org/10.1007/s12161-019-01689-z>.
17. Mosher M, Trantham K. *Brewing science: A multidisciplinary approach*. Cham: Springer; 2017. 408 p. <https://doi.org/10.1007/978-3-319-46394-0>.
18. Borodulin DM, Safonova EA, Ivanets VN, Lapina TP, Milenkij IO. Method for hopping beer wort. Russia patent RU 2634870C1. 2017.
19. Kukhlenko AA, Orlov SE, Ivanova DB, Vasilishin MS. Process of dissolution of polydisperse materials in a unit with a rotary pulsation apparatus. *Journal of Engineering Physics and Thermophysics*. 2015;88(1):25–36. (In Russ.). <https://doi.org/10.1007/s10891-015-1164-z>.
20. Ivanov EV, Matveeva NA. Plant raw material extraction with periodic intensive hydrodynamic regime. *Journal of International Academy of Refrigeration*. 2015;(4):16–22. (In Russ.).

21. Romanova NK, Kitaevskaya SV, Reshetnik OA. Optimization of cranberry extraction in the rotor-pulsating machine. *Bulletin of the Technological University*. 2018;21(10):166–170. (In Russ.).
22. Safonova EA, Potapov AN, Vagaytseva EA. Intensification of technological processes of beer production using rotary-pulsation apparatus. *Food Processing: Techniques and Technology*. 2015;36(1):74–81. (In Russ.).
23. Teleshev AT, Chagava YaD, Asaturyan ZhM, Kaziev GZ, Kudryavtsev AB. Improvement of the process of producing plant oil from grape seeds. *Scientific Review*. 2015;(15):219–225. (In Russ.).
24. Gutova SG, Novoseltseva MA, Kagan ES. Mathematical modeling of isohumulone extraction process in beer wort hopping. *Proceedings – 2019 International Russian Automation Conference*; 2019; Sochi. Sochi: Institute of Electrical and Electronics Engineers Inc.; 2019. <https://doi.org/10.1109/RUSAUTOCON.2019.8867778>.
25. Borodulin DM, Sukhorukov DV, Musina ON, Shulbaeva MT, Zorina TV, Kiselev DI, et al. Flour baking mixes: Optimal operating parameters for vibration mixers. *Food Processing: Techniques and Technology*. 2021;51(1):196–208. (In Russ.). <https://doi.org/10.21603/2074-9414-2021-1-196-208>.
26. Prosekov AYu. Rol' mezhfaznykh poverkhnostnykh yavleniy v proizvodstve dispersnykh produktov s pennoy strukturoy (obzor) [The role of interfacial surface phenomena in the production of dispersed products with a foam structure (review)]. *Storage and Processing of Farm Products*. 2001;(8):24–27. (In Russ.).
27. Prosekov AYu. Fiziko-khimicheskie osnovy polucheniya pishchevykh produktov s pennoy strukturoy [Physico-chemical foundations for obtaining food products with a foam structure]. Kemerovo: Kemerovo Technological Institute of Food Industry; 2001. 172 p. (In Russ.).