

Применение нейронных сетей при создании аппаратурных схем мембранных установок

Борис А. Лобасенко ¹	lobasenko@mail.ru	 0000-0003-0245-7904
Антон В. Шафрай ¹	shafraia@mail.ru	 0000-0003-4512-1933
Андрей Г. Семенов ¹	agsem55@ya.ru	 0000-0002-3136-3942
Павел А. Галязимов ¹	galiyazimov33@gmail.com	 0009-0004-5590-1946

¹ Кемеровский государственный университет, ул. Красная, д. 6, Кемерово, 650043, Россия

Аннотация. Рассматривается схема и принцип работы мембранного аппарата, характеризующегося отделением поляризационного слоя. Аппараты этого типа, помимо удаления пермеата, производят отдельный вывод концентрированного поляризационного слоя, образующегося на мембране и ядра потока, имеющего меньшую концентрацию, из центральной части аппарата. Анализ аппаратурной схемы установки с параллельным расположением подобных аппаратов показывает ее недостаточную эффективность и низкую производительность. Основной целью проектирования новых установок является интенсификация процесса разделения низкомолекулярных и высокомолекулярных компонентов смеси. Для этого целесообразно не смешивать потоки, имеющие различную концентрацию. С целью определения оптимальной конфигурации мембранной установки для выполнения вышеизложенных условий была использована математическая модель, разработанная на основе искусственных нейронных сетей. Нейронные сети были разработаны в интерактивной среде разработки Google Colaboratory на языке программирования Python во фреймворке PyTorch. В результате этого были смоделированы две сети, одна из которых предсказывала содержание сухих веществ в концентрате, а другая содержание сухих веществ в обедненном потоке. Для подтверждения результатов разработанной математической модели была предложена программа расчета концентраций получаемых компонентов с использованием материального баланса. Результаты, полученные на основе модели, применены при создании аппаратурной схемы установки. Предлагается алгоритм, блок-схема и программа расчета продолжительности работы мембранной установки и количества мембранных аппаратов, необходимых для получения требуемой концентрации конечного продукта. На программу расчета получено свидетельство о государственной регистрации программы на ЭВМ. Описан интерфейс программы.

Ключевые слова: искусственная нейронная сеть, установка мембранного концентрирования, поляризационный слой, аппаратурная схема.

Application of neural networks in creating hardware schemes of membrane plants

Boris A. Lobasenko ¹	lobasenko@mail.ru	 0000-0003-0245-7904
Anton V. Shafrai ¹	shafraia@mail.ru	 0000-0003-4512-1933
Andrey G. Semenov ¹	agsem55@ya.ru	 0000-0002-3136-3942
Pavel A. Galyazimov ¹	galiyazimov33@gmail.com	 0009-0004-5590-1946

¹ Kemerovo State University, Krasnaya st., 6, Kemerovo, 650043, Russia

Abstract. The scheme and operating principle of a membrane unit characterized by separation of polarization layer are considered. Units of this type, in addition to permeate removal, realize separate extraction of the concentrated polarization layer formed on the membrane, and flux core with a lower concentration from the central part of the unit. Analysis of the hardware scheme of the plant with a parallel arrangement of such units shows its insufficient efficiency and low productivity. The main purpose of designing new plants is to intensify the process of separating low-molecular and high-molecular components of the mixture. For this purpose, it is advisable not to mix flows with different concentrations. In order to determine the optimal configuration of the membrane plant to meet the above conditions, a mathematical model developed on the basis of an artificial neural network was used. The neural networks were developed in the interactive development environment Google Colaboratory in the Python programming language with the use of the PyTorch framework. As a result, two networks were modeled, one of which predicted the dry matter content of the concentrate, and the other predicted the dry matter content of the lean stream. To confirm the results of the developed mathematical model, a program for calculating the concentrations of the components obtained using the material balance was proposed. The results obtained on the basis of the model were used to create the hardware scheme of the plant. An algorithm, a block diagram and a program for calculating the operating time of a membrane plant and the necessary number of membrane units for obtaining a required concentration of the final product are proposed. A certificate of state registration of the computer program has been received for the calculation program. The program interface is described.

Keywords: artificial neural network, membrane concentrating plant, polarization layer, hardware scheme.

Для цитирования

Лобасенко Б.А., Шафрай А.В., Семенов А.Г., Галязимов П.А. Применение нейронных сетей при создании аппаратурных схем мембранных установок // Вестник ВГУИТ. 2024. Т. 86. № 4. С. 222–229. doi:10.20914/2310-1202-2024-4-222-229

For citation

Lobasenko B.A., Shafrai A.V., Semenov A.G., Galyazimov P.A. Application of neural networks in creating hardware schemes of membrane plants. Vestnik VGUIT [Proceedings of VSUET]. 2024. vol. 86. no. 4. pp. 222–229. (in Russian). doi:10.20914/2310-1202-2024-4-222-229

This is an open access article distributed under the terms of the Creative Commons Attribution 4.0 International License

Введение

По прогнозам научно-технологического развития России в биотехнологии до 2030 г. планируется получение белковых продуктов из побочных продуктов переработки растительного и животного сырья, а также создание белковых продуктов с улучшенными свойствами. Особое внимание при этом уделяется использованию мембранных методов [1–3]. Это вполне обоснованно, так как разделение высокомолекулярных веществ (ВМС) и низкомолекулярных компонентов раствора происходит на молекулярном уровне и позволяет в результате переработки целенаправленно синтезировать продукты с заданными свойствами. При этом мембранные методы за счет щадящих условий переработки позволяют перерабатывать лабильные продукты с сохранением высокого качества за счет их малой инактивации. Уменьшение продолжительности переработки (увеличение производительности) также способствует сохранению качества и сокращению энергозатрат. Одним из направлений повышения производительности является использование мембранных аппаратов с отводом поляризационного слоя и установок на их основе [2]. В частности, в одной из них предусматривается наличие двух контуров с емкостями, по которым циркулируют растворы с меньшей и большей концентрацией. В процессе работы используется раствор из емкости с более высокой концентрацией раствора. Это позволяет уменьшить продолжительность получения готового продукта. Недостатком данной схемы является взаимодействие различных по концентрации потоков, что приводит к более длительному времени переработки, т. е. к снижению производительности. В этой связи важной задачей является разработка мембранных установок, отличающихся более высокой производительностью. Для создания оптимальной конфигурации мембранных установок, отвечающих данным требованиям, целесообразно использовать математические методы и, в частности, нейронные сети. Искусственные нейронные сети являются одним из направлений машинного обучения и одной из технологий создания искусственного интеллекта [4–10]. Они отличаются тем, что могут моделировать нелинейные зависимости высокой сложности и с большой точностью решать задачи классификации, регрессии, кластеризации и т. п. В последние годы они все чаще применяются при решении задач пищевой инженерии [11–15] и мембранных технологий [16–20].

Материалы и методы

При комплектации установки использовали мембранный аппарат с отводом поляризационного слоя, схема которого представлена на рисунке 1. Предлагаемый аппарат состоит из трех секций длиной 0,2 метра с отводящими

устройствами для поляризационного слоя (концентрата). Количество отводимого слоя находится в пределах 1/20–1/40 расхода потока через аппарат. Секция состоит из семи одноканальных ультрафилтрационных керамических мембран типа КУФЭ-1, с внутренним диаметром канала 6 мм и размером пор 0,01 мкм, расположенных в общем кожухе. Более подробное описание конструкции представлено в [2]. Из каждой секции аппарата производится отдельный отвод поляризационного слоя (концентрата), обедненного потока (ретентата) и пермеата [3]. Пермеат практически не содержит ВМС и далее не используется, тогда как ретентат может подвергаться дальнейшей переработке для более полного извлечения ВМС. Рекомендуемое значение потока, подаваемого в мембранный аппарат такой конструкции, должно соответствовать скорости движения среды в канале аппарата не более 0,5 м/с [2].




Рисунок 1. Схема мембранного аппарата с отводом поляризационного слоя

Figure 1. The scheme of a membrane unit with the separation of the polarization layer

Основным принципом, положенным в основу проектирования установки, является интенсификация процесса разделения ВМС и низкомолекулярных компонентов. Для выполнения этого условия целесообразно не смешивать потоки, имеющие различную концентрацию. Возможность организации процесса может быть различной. С целью определения оптимальной конфигурации мембранной установки для выполнения вышеизложенных условий, были использованы математические модели, разработанные с помощью искусственных нейронных сетей (ИНС). ИНС являются математическими аналогами биологических нейронов головного мозга человека. В большинстве случаев они

решают задачи регрессии, классификации и кластеризации. В данном исследовании ИНС использовались для решения задачи регрессии, а именно, для предсказания содержания ВМС в концентрате и ретентате по содержанию сухих веществ в исходном растворе.

Нейронные сети были разработаны в интерактивной среде разработки Google Colaboratory (<https://colab.research.google.com>) на языке программирования Python во фреймворке PyTorch (<https://pytorch.org/>). Математические модели на основе ИНС должны обучаться на основе данных. Такие подборки данных называют датасетами. Датасет для данного исследования был получен на основе проведенных экспериментов. Он содержал 51 запись, основанных на проведенных экспериментах. Входной величиной было содержание ВМС в исходном растворе, а выходными величинами – их содержание в концентрате и ретентате.

Первоначально была предпринята попытка создать одну сеть, которая предсказывала бы сразу обе величины, однако для такой сети не удалось добиться высокой точности. Поэтому разработали две отдельных ИНС. Одна предсказывала содержание ВМС в концентрате (ИНС1), другая – содержание ВМС в ретентате (ИНС2). Характеристики обеих сетей приведены в таблице 1.

Таблица 1.
Параметры нейронных сетей
Table 1.

Network parameters

Параметр Parameter	ИНС1 ANN1	ИНС2 ANN2
Количество скрытых слоев Number of hidden layers	5	4
Количество нейронов в скрытом слое Number of neurons in hidden layer	15	10
Функция активации Activation function	Tanh	Tanh
Алгоритм оптимизации Optimization algorithm	Adam	Adam
Шаг оптимизации Optimization step	0.01	0.01
Количество эпох обучения Number of training epochs	90	80

При обучении обеих сетей датасет был разделен на обучающую и тестовую часть в пропорции 7:3. Далее сети обучались раздельно. Для каждой сети была подобрана оптимальная архитектура и наилучшие гиперпараметры. В качестве критерия точности выбрана относительная погрешность.

Наивысшую точность ИНС1 получила при наличии 5 скрытых слоев, содержащих по 15 нейронов каждый, при одном входном и одном выходном нейроне. В качестве функции активации использовалась функция гиперболического тангенса, график которой приведен на рисунке 2.

В качестве оптимизатора градиентного спуска применен алгоритм Adaptive Moment Estimation (Adam), который является оптимальным

в большинстве случаев. Длина шага градиентного спуска при этом составила 0.01. Наилучшее сходжение ИНС1 получила после 90 эпох. Средняя относительная погрешность составила 2,32 % (рисунок 3).




Рисунок 2. Функция активации (гиперболический тангенс)

Figure 2. Activation function (hyperbolic tangent)




Рисунок 3. Обучение ИНС1. δ – средняя относительная ошибка, N – номер эпохи

Figure 3. Learning of the artificial neural network 1. δ – mean relative error, N – epoch number

Архитектура ИНС2 составила 4 скрытых слоя, по 10 нейронов в каждом. Использовалась та же функция активации что и для ИНС1 (гиперболический тангенс). В качестве оптимизатора также использовался Adam, с шагом 0.01. Обучение сети продолжалось 80 эпох, а ошибка опустилась до 2,27 % (рисунок 4).




Рисунок 4. Обучение ИНС2. δ – средняя относительная ошибка, N – номер эпохи

Figure 4. Learning of the artificial neural network 2. δ – mean relative error, N – epoch number

По результатам анализа полученных данных была предложена аппаратурная схема мембранной установки, которая представлена

на рисунке 5. В состав установки входят мембранные блоки, которые включают собственно мембранные аппараты и ёмкости.




Рисунок 4. Схема мембранной установки, состоящей из аппаратов с отводом поляризационного слоя: 1, 1' – мембранный аппарат и ёмкость для исходного раствора; 2, 3, 4, 5, 6, 7 – мембранные аппараты; 2', 3', 4', 5'', 6'', 7'' – ёмкости; 8 – насосы; I – линия увеличения концентрации ВМС; II – линия уменьшения концентрации ВМС

Figure 4. Scheme of membrane system consisting of devices with polarization layer removal: 1, 1' – membrane unit and tank for initial solution; 2, 3, 4, 5, 6, 7 – membrane units; 2', 3', 4', 5'', 6'', 7'' – tanks; 8 – pumps; I – line of high-molecular compound (HMC) concentration increasing; II – line of HMC concentration decreasing

Вначале ёмкость 1' заполняют исходным раствором (в качестве обрабатываемого раствора использовалась молочная сыворотка). Из ёмкости 1' раствор подают в мембранный аппарат 1, где образуется пермеат, ретентат (обедненный поток) и концентрат (поляризационный слой). Пермеат выводится из системы. Так как содержание задерживаемых веществ в ретентате и концентрате различно, их целесообразно разделить. Концентрат подают в линию увеличения концентрации ВМС (I), которая включает аппараты 2, 3, 4 и ёмкости 2', 3', 4',

а ретентат направляют в линию снижения концентрации ВМС (II), состоящую из аппаратов 5, 6, 7 и ёмкостей 5'', 6'', 7''. Назначением линии I является увеличение концентрации ВМС на каждом аппарате за счет использования поляризационного слоя предыдущего аппарата и отвода обедненного потока, а назначением линии II – увеличение содержания низкомолекулярных веществ в потоке за счет удаления ВМС. В процессе переработки происходит перераспределение концентрации потоков между мембранными аппаратами. Его необходимо

отслеживать с помощью приборного оснащения с тем, чтобы значения концентраций смешивающихся потоков, которые направляются в соответствующие емкости, отличались бы не более чем на $\pm 0,1\%$ массового содержания ВМС. Кроме того, необходимо следить, чтобы количество раствора, находящегося в емкости 1', в любой момент было бы достаточным для обеспечения непрерывной работы установки.

Результаты и обсуждение

Для подтверждения эффективности разработанной математической модели была предложена программа расчета концентраций получаемых компонентов с использованием материального баланса. Интерфейс программы расчета представлен на рисунке 6. Программа написана на языке Visual Basic Scripting [https://learn.microsoft.com/].




Рисунок 5. Интерфейс программы

Figure 5. Program interface

Расчет производится по алгоритму, представленному схемой, изображенной на рисунке 7.

Расчет начинается с ввода исходной информации (поз. 2). При этом задаются: исходное количество перерабатываемой среды $M_{исх}$, концентрация ВМС в ней $C_{исх}$, проницаемость G , количество пермеата $M_{п}$ и его концентрация $C_{п}$, площадь проходного сечения мембранного аппарата.

По заданным значениям $M_{исх}$, $C_{исх}$, а также $M_{п}$, $C_{п}$, и учитывая количество отводимого поляризационного слоя, рекомендуемое значение которого находится в пределах $1/20$ – $1/40$ от количества исходного раствора, из материального баланса определяют количество концентрата (поляризационного слоя) $M_{к}$, количество обедненного потока $M_{об}$ и пермеата $M_{п}$, получаемого на каждой из трех секций отдельного мембранного аппарата (поз. 3).

Определяют значения концентраций концентрата и ретентата. Поток концентрата (концентрация которого превышает исходную) передается в блок расчета линии увеличения концентрации (поз. 5), поток ретентата – в блок расчета линии уменьшения концентрации (поз. 10).

Так как количество получаемого концентрата любого блока недостаточно для обеспечения соответствующих гидродинамических условий работы следующего блока (необходимой скорости движения раствора в аппарате) (поз. 5), раствор накапливается в течение некоторого времени в следующей емкости до накопления необходимого количества. Если в емкость подаются различные потоки, необходимо предусмотреть, чтобы их концентрации были близки и не отличались более, чем на $0,1\%$. Предусмотрена возможность передачи в емкость концентрата из линии уменьшения концентрации, если его концентрация соответствует накапливаемому потоку, т. е. отличается не более, чем на $0,1\%$ (поз. 12). Также предусмотрена возможность обратной передачи части ретентата из линии увеличения концентрации в линию ее уменьшения. Определяются средняя концентрация получаемого концентрата (поз. 7) и продолжительность переработки с учетом времени накопления раствора в емкостях (поз. 8). Процесс проводится до получения заданной концентрации продукта $C_{к(3)}$ (поз. 9).

Для определения количества и концентрации ретентата также используются уравнения материального баланса. Количество ретентата на входе каждой из секций аппарата будет уменьшаться на величину отводимых пермеата и концентрата. Так как этого количества может оказаться недостаточно для создания соответствующих гидродинамических условий работы в следующем аппарате, ретентат накапливают до необходимого количества в емкости следующего мембранного аппарата (поз. 10). Определяют продолжительность цикла переработки с учетом времени накопления. Переработка ретентата продолжается до получения заданной минимальной концентрации (поз. 14).

Основным условием переработки раствора с использованием этого алгоритма является использование близких по концентрации потоков. Соблюдение этого условия позволит добиться разделения (концентрирования) вещества за меньший промежуток времени, что является предпосылкой для интенсификации производства и создания малоотходных и безотходных технологий. Интерфейс программы с отображением результатов расчета представлен на рисунке 8.




Рисунок 6. Алгоритм расчета

Figure 6. Calculation algorithm

На программу расчета получено свидетельство о государственной регистрации.

ГЛАВНЫЙ ЭКРАН			
ВВОД ИСХОДНОЙ ИНФОРМАЦИИ		ИТОГОВЫЕ РЕЗУЛЬТАТЫ	
ЛИНИЯ КОНЦЕНТРАЦИИ		ЛИНИЯ ОБЪЕДИНЕННОГО ПОТОКА	
Количество аппаратов	17	Количество аппаратов	14
Концентрация	21.537111	Концентрация	4.007721
Время, мин	11	Время, мин	9

Рисунок 7. Представление результатов расчета

Figure 7. Presentation of calculation results

Заключение

На основе искусственных нейронных сетей получены данные, которые были использованы для определения оптимальной конфигурации мембранной установки, включающей аппараты с отводом поляризационного слоя. Основным условием, которое принималось во внимание при проектировании установки являлось использование близких по концентрации потоков, образующихся в процессе мембранной переработки. Это позволило значительно интенсифицировать процесс и создать предпосылки для организации малоотходных и безотходных технологий.

Для подтверждения разработанной математической модели была предложена программа расчета концентраций получаемых компонентов с использованием материального баланса. Разработан алгоритм расчета, блок-схема и программа

расчета продолжительности работы мембранной установки и количество аппаратов, необходимых для получения заданных концентраций. На программу расчета получено свидетельство о государственной регистрации программы на ЭВМ.

Литература

- 1 Гохберг Л.М., Кирпичников М.П. Прогноз научно-технологического развития России: 2030. Биотехнологии. Москва: Министерство образования и науки Российской Федерации, Национальный исследовательский университет «Высшая школа экономики», 2014. – 48 с.
- 2 Лобасенко Б.А., Семенов А.Г., Захаров Ю.Н. Ультрафильтрация: Теория и практика // Наука, 2015. 204 с.
- 3 Терминология. Мембраны и мембранные технологии (научно-информационный портал). URL: <http://www.memtech.ru/index.php/ru/glavnaya/terms>
- 4 Maytakov A.L., Yusupov Sh. T., Popov A.M., Kravchenko S.N. Study of the process of concentration as a factor of product quality formation // Foods and Raw Materials. 2018. V. 6. № 1. P. 172–181.
- 5 Shafrai A.V., Prosekov A. Yu., Vechtomova E.A. Modeling the biocatalytic method of lipid extraction using artificial neural networks // Information (Switzerland). 2023. V. 14. № 8. P. 452.
- 6 Torshizi, M.V., Asghari, A., Tabarsa, F., Danesh, P. et al. Classification by artificial neural network for mushroom color changing under effect uv-A irradiation. Carpathian J. Food Sci. Technol. 2020. V. 12. P.157–167. doi:10.34302/crpjfst/2020.12.2.16
- 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 Sci. 2020. V. 161. P. 108011. doi: 10.1016/j.meatsci.2019.108011
- 8 Shafrai A.V., Permyakova L.V., Borodulin D.M., Sergeeva I.Y. Modeling the physiological parameters of brewer's yeast during storage with natural zeolite-containing tuffs using artificial neural networks // Information (Switzerland). 2022. V. 13. № 11. P. 529.
- 9 Chen J.D., Zhang D.F., Nanehkaran Y.A., Li D.L. Detection of rice plant diseases based on deep transfer learning. J. Sci. Food Agric. 2020. V. 100. P. 3246–3256. doi:10.1002/jsfa.10365
- 10 Cunha A.F., Caetano N.S., Ramalho E., Crispim A. Fat extraction from fleshings – Optimization of operating conditions. Energy Rep. 2020. V. 6. P. 381–390. doi: 10.1016/j.egy.2020.11.176
- 11 Tarafdar A., Kaur B.P., Nema P.K., Babar O.A. et al. Using a combined neural network-genetic algorithm approach for predicting the complex rheological characteristics of microfluidized sugarcane juice. LWT-Food Sci. Technol. 2020. V. 123. P. 109058. doi: 10.1016/j.lwt.2020.109058
- 12 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 Anal. Methods 2020. V. 13. P. 699–705. doi:10.1007/s12161-019-01689-z
- 13 Lu A., Wei X., Cai R., Xiao S., et al. Modeling the effect of vibration on the quality of stirred yogurt during transportation. Food Sci. Biotechnol. 2020. V. 29. P. 889–896. doi:10.1007/s10068-020-00741-7
- 14 Jenkins B., Ronis M., Koulman A. LC-MS lipidomics: Exploiting a simple high-throughput method for the comprehensive extraction of lipids in a ruminant fat dose-response study. Metabolites. 2020. V. 10. P. 296. doi:10.3390/metabo10070296
- 15 Ali A., Qadri S., Mashwani W.K., Brahim Belhaouari S. et al. Machine learning approach for the classification of corn seed using hybrid features. Int. J. Food Prop. 2020. V. 23. P. 1097–1111. doi:10.1080/10942912.2020.1778724
- 16 Asghari M., Dashti A., Rezakazemi M., Jokar E. et al. Application of neural networks in membrane separation // Reviews in Chemical Engineering. 2020. V. 36. №. 2. P. 265–310. doi:10.1515/revce-2018-0011
- 17 Alver A., Kazan Z. Prediction of full-scale filtration plant performance using artificial neural networks based on principal component analysis // Separation and Purification Technology. 2020. V. 230. P. 115868. doi: 10.1016/j.seppur.2019.115868
- 18 Ibrahim, S., Abdul Wahab N. Improved Artificial Neural Network Training Based on Response Surface Methodology for Membrane Flux Prediction. Membranes. 2022. V. 12(8). P. 726. doi: 10.3390/membranes12080726
- 19 Abuwatfa, W.H., AlSawaftah, N., Darwish N., Pitt W.G. A Review on Membrane Fouling Prediction Using Artificial Neural Networks (ANNs) // Membranes. 2023. V. 13(7). P. 685. doi:10.3390/membranes13070685
- 20 Chan, M., Shams, A., Wang C., Lee P. et al. Artificial Neural Network Model for Membrane Desalination: A Predictive and Optimization Study. Computation. 2023. V. 11(3). P. 68. doi:10.3390/computation11030068

References

- 1 Gokhberg L.M., Kirpichnikov M.P. Forecast of scientific and technological development of Russia: 2030. Biotechnologies // Moscow: The Ministry of Education and Science of the Russian Federation, National Research University «Higher School of Economics». 2014. 48 p. (in Russian).
- 2 Lobasenko B.A., Semenov A.G., Zakharov Yu. N. Ultrafiltration: Theory and Practice // Nauka. 2015. 204 p. (in Russian).
- 3 Glossary of Terms //Membranes and Membrane Technologies. URL: <http://www.memtech.ru/index.php/ru/glavnaya/terms> (in Russian).
- 4 Maytakov A.L., Yusupov Sh. T., Popov A.M., Kravchenko S.N. Study of the process of concentration as a factor of product quality formation // Foods and Raw Materials. 2018. Vol. 6. no. 1. pp. 172–181.
- 5 Shafrai A.V., Prosekov A. Yu., Vechtomova E.A. Modeling the biocatalytic method of lipid extraction using artificial neural network // Information (Switzerland). 2023. Vol. 14. no. 8. pp. 452.
- 6 Torshizi M.V., Asghari A., Tabarsa F., Danesh P. et al. Classification by artificial neural network for mushroom color changing under effect uv-A irradiation. Carpathian J. Food Sci. Technol. 2020. Vol. 12. pp. 157–167. doi:10.34302/crpjfst/2020.12.2.16

- 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 Sci.* 2020. Vol. 161. pp. 108011. doi: 10.1016/j.meatsci.2019.108011
- 8 Shafrai A.V., Permyakova L.V., Borodulin D.M., Sergeeva I.Y. Modeling the physiological parameters of brewer's yeast during storage with natural zeolite-containing tuffs using artificial neural networks // *Information (Switzerland)*. 2022. Vol. 13. no. 11. pp. 529.
- 9 Chen J.D., Zhang D.F., Nanekharan Y.A., Li D.L. Detection of rice plant diseases based on deep transfer learning. *J. Sci. Food Agric.* 2020. Vol. 100. pp. 3246–3256. doi:10.1002/jsfa.10365
- 10 Cunha A.F., Caetano N.S., Ramalho E., Crispim A. Fat extraction from fleshings – Optimization of operating conditions // *Energy Rep.* 2020. Vol. 6. pp. 381–390. doi: 10.1016/j.egy.2020.11.176
- 11 Tarafdar A., Kaur B.P., Nema P.K., Babar, O.A. Using a combined neural network-genetic algorithm approach for predicting the complex rheological characteristics of microfluidized sugarcane juice // *LWT-Food Sci. Technol.* 2020. Vol. 123. pp. 109058. doi: 10.1016/j.lwt.2020.109058
- 12 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 Anal. Methods.* 2020. Vol. 13. pp. 699–705. doi:10.1007/s12161-019-01689-z
- 13 Lu A., Wei X., Cai R., Xiao S. Modeling the effect of vibration on the quality of stirred yogurt during transportation. // *Food Sci. Biotechnol.* 2020. Vol. 29. pp. 889–896. doi:10.1007/s10068-020-00741-7
- 14 Jenkins B., Ronis M., Koulman A. LC-MS lipidomics: Exploiting a simple high-throughput method for the comprehensive extraction of lipids in a ruminant fat dose-response study // *Metabolites* 2020, 10, 296. <https://doi.org/10.3390/metabo10070296>.
- 15 Ali A., Qadri S., Mashwani W.K., Brahim Belhaouari S. Machine learning approach for the classification of corn seed using hybrid features // *Int. J. Food Prop.* 2020. Vol. 23. pp. 1097–1111. doi:10.1080/10942912.2020.1778724
- 16 Asghari M., Dashti A., Rezakazemi M., Jekar E. et al. Application of neural networks in membrane separation // *Reviews in Chemical Engineering.* 2020. Vol. 36. no. 2. pp. 265–310. doi:10.1515/revce-2018-0011
- 17 Alver A., Zeynep Kazan Z. Prediction of full-scale filtration plant performance using artificial neural networks based on principal component analysis // *Separation and Purification Technology.* 2020. Vol. 230. P. 115868. doi: 10.1016/j.seppur.2019.115868
- 18 Ibrahim S., Abdul Wahab N. Improved Artificial Neural Network Training Based on Response Surface Methodology for Membrane Flux Prediction // *Membranes.* 2022. Vol. 12(8). pp. 726. doi:10.3390/membranes12080726
- 19 Abuwatfa W.H., AlSawafah N., Darwish N., Pitt W.G. et al. A Review on Membrane Fouling Prediction Using Artificial Neural Networks (ANNs) // *Membranes.* 2023. Vol. 13(7). pp. 685. doi:10.3390/membranes13070685
- 20 Chan M., Shams A., Wang C.; Lee P. et al. Artificial Neural Network Model for Membrane Desalination: A Predictive and Optimization Study // *Computation.* 2023. Vol. 11(3). pp. 68. doi:10.3390/computation11030068

Сведения об авторах

Борис А. Лобасенко д.т.н., профессор, кафедра инженерного дизайна, Кемеровский государственный университет, ул. Красная, 6, г. Кемерово, 650000, Россия, lobasenko@mail.ru

 <https://orcid.org/0000-0003-0245-7904>

Антон В. Шафрай к.т.н., доцент, кафедра инженерного дизайна, Кемеровский государственный университет, ул. Красная, 6, г. Кемерово, 650000, Россия, shafraia@mail.ru

 <https://orcid.org/0000-0003-4512-1933>

Андрей Г. Семенов д.т.н., профессор, кафедра теории и методики преподавания естественнонаучных и математических дисциплин, Кемеровский государственный университет, ул. Красная, 6, г. Кемерово, 650000, Россия, agsem55@ya.ru

 <https://orcid.org/0000-0002-3136-3942>

Павел А. Галязимов магистрант, кафедра теории и методики преподавания естественнонаучных и математических дисциплин, Кемеровский государственный университет, ул. Красная, 6, г. Кемерово, 650000, Россия, galiazimov33@gmail.com

 <https://orcid.org/0009-0004-5590-1946>

Вклад авторов

Все авторы в равной степени принимали участие в написании рукописи и несут ответственность за плагиат

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Information about authors

Boris A. Lobasenko Dr. Sci. (Engin.), professor, Department of Industrial Design, Kemerovo State University, Krasnaya St. 6, Kemerovo 650000, Russia, lobasenko@mail.ru

 <https://orcid.org/0000-0003-0245-7904>

Anton V. Shafrai Cand. Sci. (Engin.), assistant professor, Department of Industrial Design, Kemerovo State University, Krasnaya St. 6, Kemerovo 650000, Russia, shafraia@mail.ru

 <https://orcid.org/0000-0003-4512-1933>

Andrey G. Semenov Cand. Sci. (Econ.), engineer, Department of Theory and Methodology of Teaching Natural Sciences and Mathematics, Kemerovo State University, Krasnaya St. 6, Kemerovo 650000, Russia, agsem55@ya.ru

 <https://orcid.org/0000-0002-3136-3942>

Pavel A. Galjazimov Master student, Department of Theory and Methodology of Teaching Natural Sciences and Mathematics, Kemerovo State University, Krasnaya St. 6, Kemerovo 650000, Russia, galiazimov33@gmail.com

 <https://orcid.org/0009-0004-5590-1946>

Contribution

All authors are equally involved in the writing of the manuscript and are responsible for plagiarism

Conflict of interest

The authors declare no conflict of interest.

Поступила 21/10/2024	После редакции 18/11/2024	Принята в печать 29/11/2024
Received 21/10/2024	Accepted in revised 18/11/2024	Accepted 29/11/2024