

УДК 621.59:004.032.26

Определение рациональных параметров контура СХА ожижителя азота с помощью методов машинного обучения

Мазякин Максим Сергеевич^(*)

maxim.maziakin@gmail.com

Лавров Николай Алексеевич

lavrovna@bmstu.ru

МГТУ им. Н.Э. Баумана, Москва, Россия

Аннотация. В последнее время значительно расширяется область применения нейронных сетей для решения инженерных задач. Внедрение методов машинного обучения в систему управления криогенной установки может позволить увеличить ее надежность и уменьшить затраты на оборудование автоматизации и трудозатраты в процессе эксплуатации. Целью данной работы является оценка применимости методов машинного обучения для определения рациональных параметров контура СХА ожижителя азота. Сбор данных проводился на модели установки в программе моделирования физико-химических процессов. В программе Matlab был проведен процесс обучения, валидации и верификации нейронной сети типа ANFIS для определения параметров контура СХА. Нейронная сеть имеет среднюю абсолютную ошибку 4,3 % при аппроксимации значений параметров потока смесового хладагента на всех стационарных режимах. Однако на режимах, выходящих за пределы набора данных, использованных при обучении, абсолютная ошибка увеличивается и может достигать 27 % на отдельных режимах с пониженной температурой. Предложен новый метод определения рациональных параметров контура СХА на основе экспериментальных данных с использованием нейросетей. По результатам работы нейросети, можно сделать вывод о возможности ее применения для определения параметров контура СХА ожижителя азота, а также в схожих задачах криогенной техники.

Ключевые слова: смесовой холодильный агент, ожижитель азота, нейронные сети, машинное обучение

Determination of rational parameters of the nitrogen liquefier circuit using machine learning methods

Mazyakin Maxim Sergeevich^(*)

maxim.maziakin@gmail.com

Lavrov Nikolay Alekseevich

lavrovna@bmstu.ru

BMSTU, Moscow, Russia

Abstract. Recently, the scope of application of neural networks for solving engineering problems has significantly expanded. The introduction of machine learning methods into the control system of a cryogenic plant can increase its reliability and reduce the costs of automation equipment and labor costs during operation. This study is aimed at evaluating the applicability of machine learning methods for determining rational parameters of the nitrogen liquefier MR loop. Data collection was carried out on a model of the installation in a program for modeling physical and chemical processes. The process of training, vali-

dation and verification of the ANFIS-type neural network for determining the parameters of the MR loop was carried out in MATLAB. The neural network shows an error rate of 4.3 % when approximating the values of the mixed refrigerant flow parameters in steady-state modes. However, in modes that go beyond the data set used in training, the absolute error increases and can reach 27 % in individual modes with reduced temperature. A new method for determining rational parameters of the MR loop based on experimental data using neural networks is proposed. Based on the results of the neural network, it can be concluded that it can be used to determine the parameters of the MR loop of the nitrogen liquefier, as well as in similar problems of cryogenic engineering. Keywords: mixed refrigerant, nitrogen liquefier, neural networks, machine learning

Введение. В силу ряда факторов, таких как необходимость улучшения эффективности, надежности и безопасности криогенных систем, а также повышение требований к точности управления процессами с низкими температурами, использование нейронных сетей представляет собой важное направление исследований и практической реализации. Эта тема позволяет рассмотреть применение современных методов машинного обучения для оптимизации процессов, диагностики неисправностей, управления энергопотреблением и автоматизации операций в криогенной технике. Такой подход может существенно улучшить работу криогенных систем, снизить операционные расходы и увеличить их надежность.

В настоящее время нейронные сети становятся все более актуальным инструментом для решения прикладных задач. Применение нейронных сетей в проектировании и эксплуатации машин и установок обещает значительное сокращение времени вычислений и повышение эффективности и надежности.

Обзор литературы [1] свидетельствует о явном темпе роста публикаций о применении машинного обучения для решения задач в областях техники и энергетики с 2018 года (рис. 1). Доля нейронных сетей в этих работах превышает 50 % (рис. 2). Это объясняется их высокой точностью прогнозирования и возможностями параллельной и распределенной обработки.




Рис. 1. Количество публикаций о применении нейронных сетей для решения задач техники и энергетики [1]

Было замечено, что большое количество работ с применением нейронных сетей для решения инженерных задач, посвящено расчету и оптимизации теплообменных аппаратов различных конструкций [1–4]. К тому же, существуют научные работы о применении машинного обучения в таких областях, как логистика, переработка, водоподготовка, производство топлива и авиация [5–9].




Рис. 2. Доля различных методов МО в работах [2]

Материалы и методы. Для решения задачи нахождения рациональных параметров ожижителя необходимо обучить и опробовать работу разрабатываемой модели на реальных данных. В качестве такой установки был выбран дроссельный рефрижератор-ожижитель азота, предназначенный для термостатирования объектов на температурном уровне до $-196,15\text{ }^{\circ}\text{C}$ и ожижения азота.

Низкотемпературная холодильная машина (НХМ) ожижителя построена по схеме дроссельного рефрижераторного цикла Линде с отделителем жидкости и предварительным охлаждением чиллером. Внешний вид блоков ожижителя представлен на рис. 3, 4. Параметры НХМ приведены в табл. 1.




Рис. 3. Компрессорный блок ожижителя азота



Рис. 4. НХМ ожижителя азота

Таблица 1

Параметры НХМ

Расход N_2 на входе в НХМ	3 кг/ч
Состав СХА	R-142b, R-22, R-23, R-50, R-14, N_2 , He
Температура СХА на входе в НХМ	$-12\text{ }^{\circ}\text{C}$

Для определения рационального режима работы контура СХА при различных новых режимах работы установки по расходу и температуре азота на входе предлагается провести обучение нейронной сети типа ANFIS на данных, полученных при стационарных режимах работы установки, и с помощью нее сделать аппроксимацию значения расхода СХА на неотработанных режимах работы ожижителя.

Данные по потоку азота на входе в установку и расходу смесового хладагента были получены путем моделирования цикла в программе моделирования физико-химических процессов. Многопоточный теплообменный аппарат можно разбить на несколько двухпоточных, как показано на рис. 5.




Рис. 5. Расчетная схема теплообменного аппарата

$$\begin{cases} \frac{dT_1}{dx} = N_1(T_3 - T_4); \\ \frac{dT_2}{dx} = N_2(T_3 - T_2); \\ -\frac{dT_3}{dx} = N_3(T_1 - T_3) + N_4(T_2 - T_3), \end{cases} \quad (1)$$

где N_1 – N_4 — числа единиц переноса теплоты соответственно между потоками.

Граничные условия, определяющие значения температур потоков на входе в ТОА приведены в табл. 2.

Таблица 2

Граничные условия для расчета ТОА

Температура N_2 :	$T_1(0) = 25\text{ }^{\circ}\text{C}$
Температура прямого потока СХА:	$T_2(0) = -12\text{ }^{\circ}\text{C}$
Температура обратного потока СХА:	$T_3(1) = -94,2\text{ }^{\circ}\text{C}$

Для решения системы использовалась программа моделирования физико-химических процессов. Схема модели представлена на рис. 6.




Рис. 6. Схема модели оживителя

В результате моделирования были получены данные по расходу СХА на различных режимах работы установки по производительности и по температуре азота на входе, что позволяет моделировать производительность установки в различных климатических условиях. Таким образом, был получен

набор данных из 60 точек. Параметры набора данных, для обучения нейронной сети представлены в табл. 3.

Таблица 3

Параметры набора данных

Параметр	Обучение	Верификация
Расход азота, на входе	1–3 кг/ч	1–3,6 кг/ч
Температура азота на входе	10–40 °C	0–50 °C

Адаптивная нейро-нечеткая система вывода (ANFIS) представляет собой комбинацию искусственной нейронной сети (ANN) и нечеткой системы типа Такаги — Сугено, и она была предложена Кангом в 1993 году [10]. ANFIS наследует преимущества как нейронных сетей, так и нечетких систем, поэтому это мощный инструмент для выполнения различных задач контролируемого обучения. Схема нейронной сети представлена на рис. 7.




Рис. 7. Схема нейронной сети

Система состоит из 5 слоев. На первом слое происходит преобразование четких входных данных в нечеткие; второй уровень отвечает за формирование правил; третий слой выполняет нормализацию функций принадлежности; четвертый слой преобразует нечеткие данные обратно в четкие; пятый слой вычисляет результат и осуществляет его вывод.

ANFIS была выбрана, так как имеет как преимущества нейронных сетей, так и нечетких систем, поэтому это мощный инструмент для выполнения различных задач контролируемого обучения.

В качестве основных преимуществ можно выделить отсутствие необходимости в ручной настройке, интерпретируемость структуры, устойчивость к «шумам» и низкой точности данных. С другой стороны, при внедрении ANFIS необходимо учитывать трудность масштабирования данного типа

нейронной сети. С увеличением количества входных данных экспоненциально растет количество функций принадлежности, что снижает эффективность работы сети. Для решения данной проблемы можно уменьшая размерность путем применения методов кластеризации.

Параметры нейронной сети, использованные при обучении и прогнозировании параметров ожижителя представлены в табл. 4.

Таблица 4

Параметры ANFIS

Тип FIS	Такаги — Сугено — Канг
Метод кластеризации	Нечеткая С-средних
Число кластеров	5
Экспонента матрицы разделения	2
Макс. число итераций	200
Число эпох	100
Начальный шаг	0,01
Скорость уменьшения шага	0,9
Скорость увеличения шага	1,1

Результаты. Целью расчета было получить значение расхода СХА в контуре в зависимости от режима работы рефрижератора ожижителя азота по температуре и расходу.

В процессе обучения набор данных разбивается случайным образом на 2 набора: первый, объемом 50 точек, и второй, объемом 10 точек. Первый набор используется для обучения нейронной сети методом обратного распространения, второй — для валидации нейросети. На рис. 8 представлены результаты аппроксимации расхода СХА для набора данных, использованного при обучении.




Рис. 8. Аппроксимация расхода СХА для точек, использованных в обучении

Результаты аппроксимации точек, использованных для валидации приведены на рис. 9.




Рис. 9. Аппроксимация расхода СХА для точек, использованных валидации

Аппроксимация расхода СХА при верификации нейросети представлена на рис. 10. Затем была проведена верификация модели на данных, характеризующих режимы, входящие за пределы расчетных режимов для ожижителя (зеленая область), режимы с пониженной температурой азота на входе в ожижитель (желтая и красная области), режимы с повышенной температурой азота на входе в ожижитель (синяя область).




Рис. 10. Абсолютная ошибка ANFIS на наборе данных для верификации

В качестве критерия точности определения расхода было использовано значение абсолютной ошибки, определяемое по следующей формуле:

$$e_i = y_i - x_i, \quad (2)$$

где y_i — значение, полученное нейросетью; x_i — значение, полученное путем моделирования.

Средняя абсолютная ошибка определяется уравнением 3:

$$MAE = \sum_{i=1}^n |e_i| / n, \quad (3)$$

где n — число тестов.

Обсуждение полученных результатов. Средняя абсолютная ошибка на наборе данных для верификации составила 4,3 %, что позволяет говорить о высокой точности предсказаний, полученных ANFIS даже для точек, выходящих за пределы расчетных режимов. Однако стоит заметить, что при получении величины расхода СХА для режимов с пониженной температурой азота на входе величина абсолютной ошибки составляла до 27 %, т. е. при выходе установки за режимы, на которых осуществлялось обучение модели, с увеличением отклонения параметров режима, увеличивается погрешность определения расхода СХА. Такое значение погрешности можно считать допустимым, учитывая, что работа нейросети осуществлялась на данных, выходящих за пределы набора данных для обучения. Для уменьшения погрешности нейронной сети в области пониженных температур необходимо, либо увеличить диапазон температур в наборе данных для обучения, либо увеличить объем самого набора данных для обучения в области режимов с нормальной температурой.

Заключение. Предложен новый метод определения рациональных параметров контура СХА на основе экспериментальных данных, с использованием нейросетей. Для решения данной задачи использовалась нейронная сеть ANFIS. Построена математическая модель исследуемого объекта. На основе данных, полученных с модели, производилась отработка решения. Нейронная сеть показывает погрешность не более 5 % при аппроксимации значений параметров потока смесового хладагента на стационарных режимах в пределах данных, использованных для обучения, что может позволить прогнозировать поведение контура СХА ожижителя азота на различных режимах, не проводя дополнительные экспериментальные исследования. Планируется оценить применимость данного метода для прогнозирования других параметров установки (состав СХА, доля жидкости на входе в ТОА) в том числе динамических режимах.

Список источников

- [1] Zou J. Recent advances in the applications of machine learning methods for heat exchanger modeling. A review. *Frontiers in Energy Research*, 2023. <https://doi.org/10.3389/fenrg.2023.1294531>
- [2] Лавров Н.А., Хуциева С.И., Шанин В.А. Применение нейронных сетей для динамического моделирования теплообменного аппарата. *Химическое и нефтегазовое машиностроение*, 2023, № 58, с. 917–924. <https://doi.org/10.1007/s10556-023-01183-8>

- [3] Gupta A.K. Performance measurement of plate fin heat exchanger by exploration: ANN, ANFIS, GA, and SA. *Journal of Computational Design and Engineering*, 2017, vol. 4, pp. 60–68. <https://doi.org/10.1016/j.jcde.2016.07.002>
- [4] El-Said E.M.S., Abd E.M., Elsheikh A. H. Machine learning algorithms for improving the prediction of air injection effect on the thermohydraulic performance of shell and tube heat exchanger. *Applied Thermal Engineering*, 2021, vol. 185. <https://doi.org/10.1016/j.applthermaleng.2020.116471>
- [5] Kozlova A., Kurashkin S., Boyko A. Optimization of warehouse processes using machine learning and linear programming. *Smart Industry Con.*, 2025. <https://doi.org/10.1109/SmartIndustryCon65166.2025.10986102>
- [6] Sivova A. Development of a neural network model for solid municipal waste detection. *AIP Conference Proceedings*, 2023, art. no. 2833. <https://doi.org/10.1063/5.0152632>
- [7] Тынченко Я.А. Оценка качества технической воды в горно-промышленном производстве на основе методов машинного обучения. *Устойчивое развитие горных территорий*, 2024, № 16, с. 56–59. <https://doi.org/10.21177/1998-4502-2024-16-1-56-69>
- [8] Bukhtoyarov V. Fuzzy Neural Network Applications in Biomass Gasification and Pyrolysis for Biofuel Production. A Review. *Energies*, 2022, vol. 18 (1). <https://doi.org/10.3390/en18010016>
- [9] Volkov K.D., Panilov P.A., Tsibizova T.Y. Identifying Intersections of Planes using Convolutional Neural Networks. *7th REEPE proc.*, 2025. <https://doi.org/10.1109/REEPE63962.2025.10971066>
- [10] Mostapha K.H. *Nonlinear Regression using ANFIS*. URL: <https://yarpiz.com/301/ypfz101-nonlinear-regression-using-anfis> (дата обращения 11.08.2025).