

УДК: 66.011

Применение искусственных нейронных сетей для подбора состава смесового хладагента с заданной кривой кипения

А. С. Никулин^а, Д. Н. Жедяевский^б, Е. Б. Федорова^с

РГУ нефти и газа (НИУ) имени И. М. Губкина,
Россия, 119991, г. Москва, Ленинский проспект, д. 65, корп. 1

E-mail: ^а nikulin.a@gubkin.ru, ^б jdn@gubkin.ru, ^с fedorova.e@gubkin.ru

*Получено 17.10.2020, после доработки — 12.05.2022.
Принято к публикации 12.05.2022.*

В работе представлен метод подбора состава смесового хладагента (СХА) с заданной изобарной кривой кипения с помощью искусственной нейронной сети (ИНС). Данный метод основан на использовании 1D-слоев сверточной нейронной сети. Для обучения нейронной сети была применена термодинамическая модель простого теплообменника в программе UniSim design с использованием уравнения состояния Пенга – Робинсона. С помощью термодинамической модели была создана синтетическая база данных по изобарным кривым кипения СХА разного состава. Для записи базы данных был разработан алгоритм на языке программирования Python, и с помощью COM интерфейса была выгружена информация по изобарным кривым кипения для 1 049 500 вариантов состава СХА. Генерация составов СХА была проведена с помощью метода Монте-Карло с равномерным распределением псевдослучайного числа. Авторами разработана архитектура искусственной нейронной сети, которая позволяет подбирать состав СХА. Для обучения ИНС была применена методика циклически изменяемого коэффициента обучения. В результате применения обученной ИНС был подобран состав СХА с минимальным температурным напором 3 К, а максимальным — не более 10 К между горячим и холодным потоками в теплообменнике. Было проведено сравнение предложенного метода с методом поиска наилучшего совпадения в исходной выборке по методу *k*-ближних соседей, а также со стандартным методом оптимизации SQP в программе UniSim design. Показано, что искусственная нейронная сеть может быть использована для подбора оптимального состава хладагента при анализе кривой охлаждения природного газа. Разработанный метод может помочь инженерам подбирать состав СХА в режиме реального времени, что позволит сократить энергетические затраты на сжижение природного газа.

Ключевые слова: сжиженный природный газ, СПГ, оптимизация производства СПГ, смесовой хладагент, СХА, нейронные сети, искусственный интеллект

UDC: 66.011

Applying artificial neural network for the selection of mixed refrigerant by boiling curve

A. S. Nikulin^a, D. N. Zhediaevskii^b, E. B. Fedorova^c

National University of Oil and Gas «Gubkin University»,
65/1 Leninsky ave., Moscow, 119991, Russia

E-mail: ^a nikulin.a@gubkin.ru, ^b jdn@gubkin.ru, ^c fedorova.e@gubkin.ru

Received 17.10.2020, after completion – 12.05.2022.

Accepted for publication 12.05.2022.

The paper provides a method for selecting the composition of a refrigerant with a given isobaric cooling curve using an artificial neural network (ANN). This method is based on the use of 1D layers of a convolutional neural network. To train the neural network, we applied a technological model of a simple heat exchanger in the UniSim design program, using the Peng–Robinson equation of state. We created synthetic database on isobaric boiling curves of refrigerants of different compositions using the technological model. To record the database, an algorithm was developed in the Python programming language, and information on isobaric boiling curves for 1 049 500 compositions was uploaded using the COM interface. The compositions have generated by Monte Carlo method. Designed architecture of ANN allows select composition of a mixed refrigerant by 101 points of boiling curve. ANN gives mole flows of mixed refrigerant by composition (methane, ethane, propane, nitrogen) on the output layer. For training ANN, we used method of cyclical learning rate. For results demonstration we selected MR composition by natural gas cooling curve with a minimum temperature drop of 3 K and a maximum temperature drop of no more than 10 K, which turn better than we predicted via UniSim SQP optimizer and better than predicted by *k*-nearest neighbors algorithm. A significant value of this article is the fact that an artificial neural network can be used to select the optimal composition of the refrigerant when analyzing the cooling curve of natural gas. This method can help engineers select the composition of the mixed refrigerant in real time, which will help reduce the energy consumption of natural gas liquefaction.

Keywords: optimization of LNG production, selection of mixed refrigerant composition, big data, neural network, artificial intelligence

Citation: *Computer Research and Modeling*, 2022, vol. 14, no. 3, pp. 593–608 (Russian).

1. Введение

Использование природного газа в энергетике обладает рядом преимуществ и имеет хорошие перспективы в будущем. Это связано с возрастающей тенденцией к снижению парникового эффекта от сжигания ископаемого топлива, а также с активной разработкой газовых месторождений. Природный газ является альтернативным топливом по отношению к нефтепродуктам и углю, при сжигании которого выделяется значительно меньше CO_2 .

Одним из основных способов транспортировки природного газа от места добычи до потребителя является его сжижение и доставка с помощью танкеров. По данным работы [Lim, Choi, Moon, 2013], капитальные и эксплуатационные затраты на сжижение газа составляют до 40 % стоимости конечного продукта — сжиженного природного газа (СПГ). По этой причине в России по-прежнему доминирует газопроводная транспортировка газа, хотя отрасль СПГ с каждым годом набирает все большую популярность. Снижение эксплуатационных затрат на сжижение газа позволит повысить конкурентоспособность СПГ как на мировом рынке, так и на внутреннем рынке при альтернативной газификации труднодоступных регионов.

Сжижение природного газа предполагает создание инфраструктуры СПГ, которая включает: завод по сжижению газа, средства транспортировки СПГ и комплексы регазификации. При проектировании завода СПГ важной стратегической задачей является выбор технологии сжижения. Выбор технологии сжижения зависит от производительности технологической линии [Wood, 2009]. На рис. 1 представлена диаграмма применения технологий производства СПГ в зависимости от производительности технологической линии. На диаграмме видно, что циклы на смесевом хладагенте (СХА) применяются для крупнотоннажного производства с большой производительностью (от 2,5 млн тонн в год). Эффективность циклов на СХА сильно зависит от колебаний температуры окружающей среды и свойств добываемого природного газа. При этом повысить энергоэффективность процесса производства СПГ можно путем изменения состава СХА в зависимости от термобарических условий процесса и температуры окружающей среды [Khan, Karimi, Wood, 2017].

В статьях [Khan et al., 2015; Remelje, Hoadley, 2006; Song et al., 2019] отмечается эффективность эксергетического подхода в поиске оптимального состава СХА. Этот подход заключается в подборе хладагента таким образом, чтобы кривая кипения СХА была максимально близка к кривой охлаждения природного газа [Федорова, 2011], что соответствует минимальным эксергетическим потерям в основном теплообменнике. Это объясняется тем, что при охлаждении природного газа в теплообменном аппарате газ охлаждается практически таким же по температуре хладагентом во всем диапазоне охлаждения, тем самым снижаются необратимые затраты энергии в холодильных циклах. Таким образом, подбор состава хладагента сводится к сравнению кривой кипения с кривой охлаждения природного газа.

Авторы статьи [Khan et al., 2013] предлагают метод оптимизации, основанный на предварительном расчете кривых кипения по каждому компоненту отдельно и последующем использовании градиентов в определенном температурном интервале для оптимизации состава.

Предложенные выше методики предлагают использовать термодинамическую модель, кроме того, задача определения состава хладагента является нелинейной, которая требует больших вычислительных ресурсов и времени на численный расчет градиентов. В связи с этим предлагается использовать алгоритмы нейронных сетей, в основе которых будут данные о кривых кипения разных смесевых хладагентов, для пересчета состава хладагента. Данная методика позволит подбирать состав хладагента без использования модели и инженерного ПО, а также будет работать с более высокой скоростью, что позволит использовать данный алгоритм в динамически изменяемых системах на заводе по производству СПГ. Кроме того, в условиях политической нестабильности использовать зарубежное ПО — достаточно рискованный путь (на данный



Рис. 1. Диаграмма применения разных типов хладагентов

момент в России нет полноценных аналогов технологических симуляторов, таких как UniSim и Hysys), а данное решение сможет сделать систему контроля состава хладагента импортонезависимой.

Целью исследований является поиск архитектуры искусственной нейронной сети (ИНС) и ее обучение для подбора состава смешанного хладагента по заданной форме кривой кипения. Стоит отметить, что в данной статье не будут разбираться вопросы о построении циклов на сгенерированном составе.

2. Описание методики создания ИНС

Для обучения ИНС требуется большой массив данных по кривым кипения СХА. Данные по кривым кипения можно получить на лабораторном оборудовании или смоделировать с помощью известных уравнений состояния, например с помощью уравнения Пенга – Робинсона [Peng, Robinson, 1976]. В данной статье из-за отсутствия достаточного объема реальных данных по кривым кипения было принято решение использовать полностью модельные данные, полученные в профессиональном симуляторе технологических процессов Honeywell UniSim Design на основе уравнения состояния Пенга – Робинсона.

Для получения массива данных по кривым кипения была создана технологическая схема (рис. 2) с одним теплообменником. На входе в теплообменник жидкий СХА находится в насыщенном состоянии (точка начала кипения). В качестве исходных данных были приняты:

- состав хладагента, состоящий из четырех компонентов: метан, этан, пропан, азот;
- количество подведенного тепла Q .

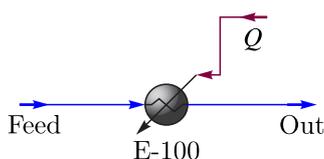


Рис. 2. Технологическая схема для получения массива данных

Для автоматизации получения данных по кривым кипения был написан скрипт на языке Python, взаимодействующий с UniSim через COM-интерфейс. Генерация составов смесевых хладагентов произведена с помощью метода Монте-Карло с равномерным распределением псевдослучайных чисел. Этот метод позволил эффективно задействовать вычислительные мощности и равномерно заполнить пространство составов вне зависимости от времени расчета. На рис. 3 изображен алгоритм получения кривых кипения: алгоритм создавал с помощью генератора псевдослучайного числа мольный расход каждого компонента с равномерным распределением в заданных диапазонах, а далее подведенная к флюиду энергия изменялась в диапазоне от 0 до 70 000 Дж с шагом 700 Дж.

По алгоритму, изображенному на рис. 3, а записана информация о 1 049 500 составов, а также на рис. 3, б приведен пример из 10 000 записанных кривых кипения. На рис. 4 изображены гистограммы распределения мольных расходов для каждого компонента в результате генерации. В ходе цифровых экспериментов были получены температурные кривые, которые и были взяты за основу для обучения ИНС.

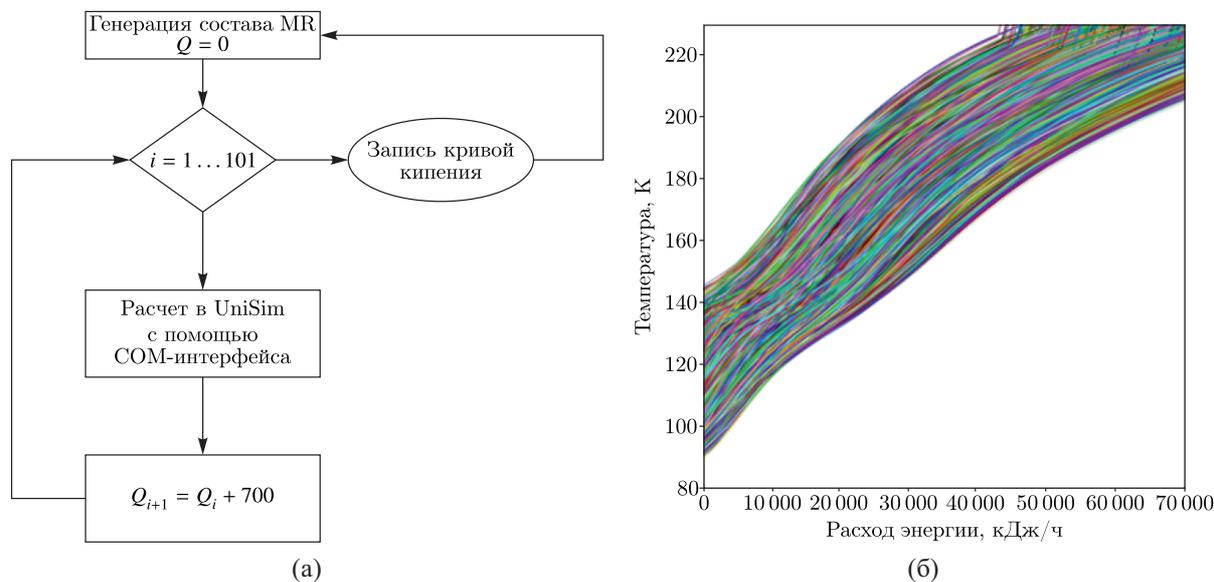


Рис. 3. Алгоритм записи кривых кипения (а) и результат генерации кривых кипения (б)

3. Архитектура нейронной сети

Было протестировано несколько типовых архитектур ИНС, основанных на использовании полносвязных слоев с разными функциями активации. Варьируя количество слоев и количество нейронов в каждом слое, а также используя разные функции активации, не удалось добиться приемлемых показателей работы ИНС, поэтому было принято решение увеличить количество признаков с помощью использования входных сверточных 1D-слоев.

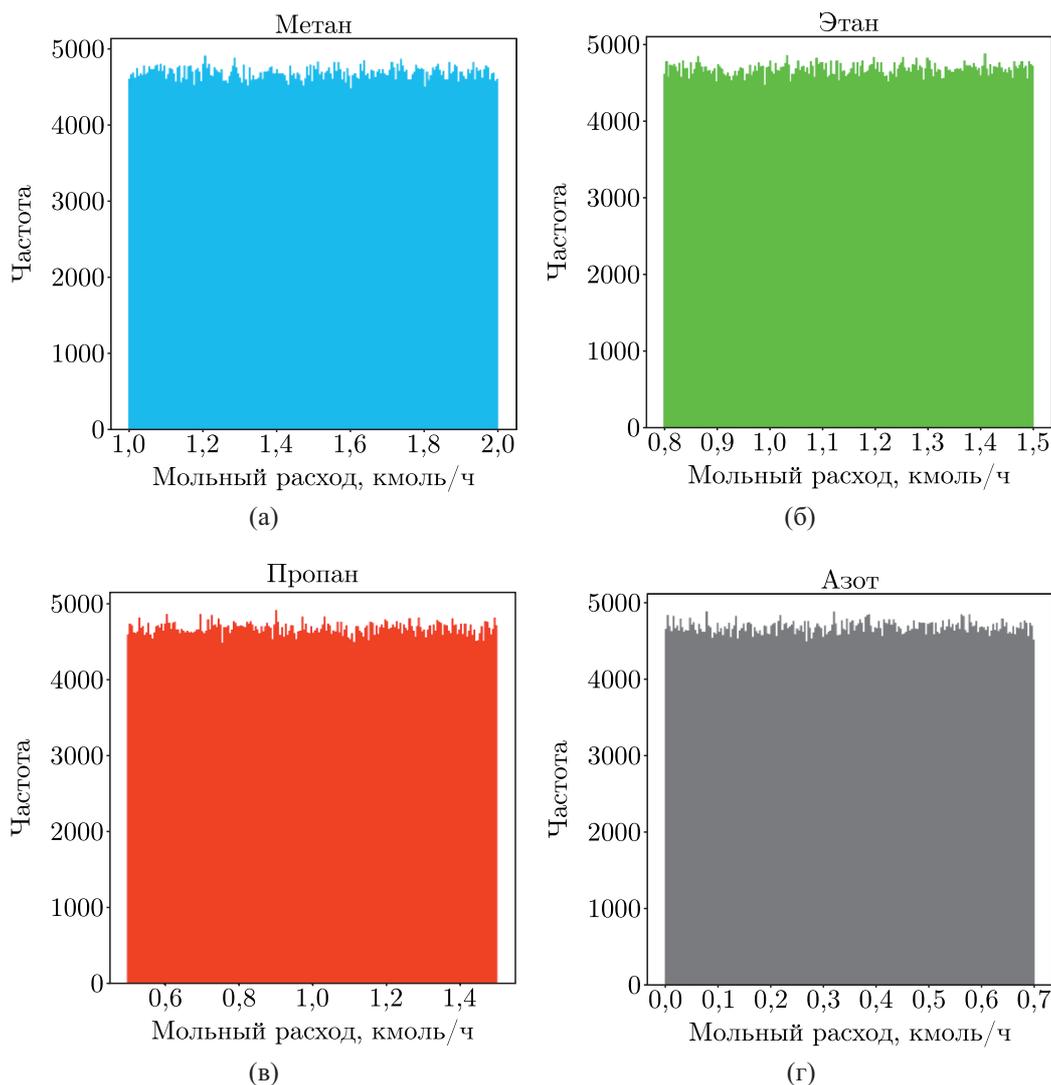


Рис. 4. Гистограммы распределения мольных расходов по каждому компоненту

При загрузке целевой кривой кипения в ИНС загруженная кривая сначала проходит через сверточные 1D-слои, в результате чего получается расширенный набор признаков. После прохождения всех сверточных и пулинг-слоев (подвыборок) получается карта из 128 признаков для загруженной кривой, а далее, после разворачивания карт с помощью полносвязных слоев, рассчитывается мольный расход для каждого компонента СХА: метана, этана, пропана и азота. На рис. 5 изображена подобранная архитектура ИНС. Данная архитектура показала наилучшие результаты при обучении и тестировании, а количество фильтров, размеры ядра и количество слоев подбирались эмпирическим путем.

4. Обучение нейронной сети

В статье [Kingma, Ba, 2015] оптимизатор ADAM (Adaptive Moment Estimation) показал лучше способность обучать ИНС (выше скорость обучения и меньше итоговая ошибка), чем при использовании метода градиентного спуска, поэтому ИНС обучалась с использованием оптимизатора ADAM. В качестве метрики качества обучения использовалась среднеквадратичная ошибка (MSE).

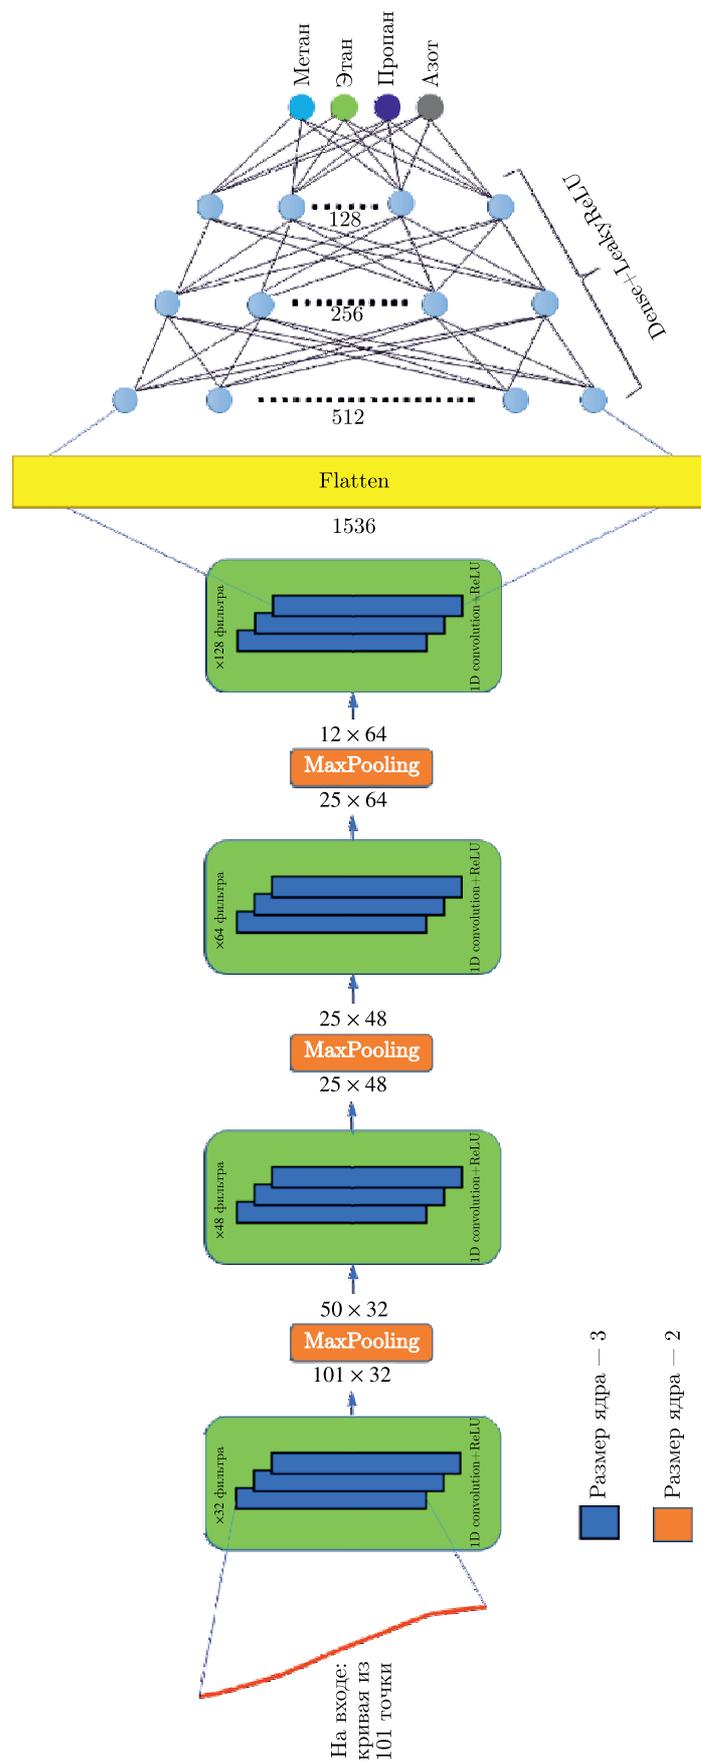


Рис. 5. Архитектура ИНС

Весь массив исходных данных был нормализован по каждому признаку на входе и по каждой целевой переменной на выходе. В результате нормализации все данные в обучающей и тестовой выборках стали безразмерными.

В статье [Smith, 2017] описан эффективный метод обучения нейронной сети с применением переменного коэффициента обучения. Этот метод предлагает изменять коэффициент обучения по циклу от максимального до минимального значения, причем после каждого цикла предлагается изменять максимальное значение коэффициента обучения по формуле

$$\eta_{\max}^i(i) = \eta_{\max}^0 \cdot 0,95^i, \quad (1)$$

где i — порядковый номер цикла, η_{\max}^0 — начальный коэффициент обучения, η_{\max}^i — максимальный коэффициент обучения на i -м цикле.

Для определения η_{\min} и η_{\max} проведен тест: было запущено тестовое обучение нейронной сети представленной архитектуры с размером пакетов по 128, и после обучения каждого пакета η изменялся в диапазоне от 10^{-12} до 10^{-3} за 4 эпохи. На рис. 6 изображен результат этого теста.

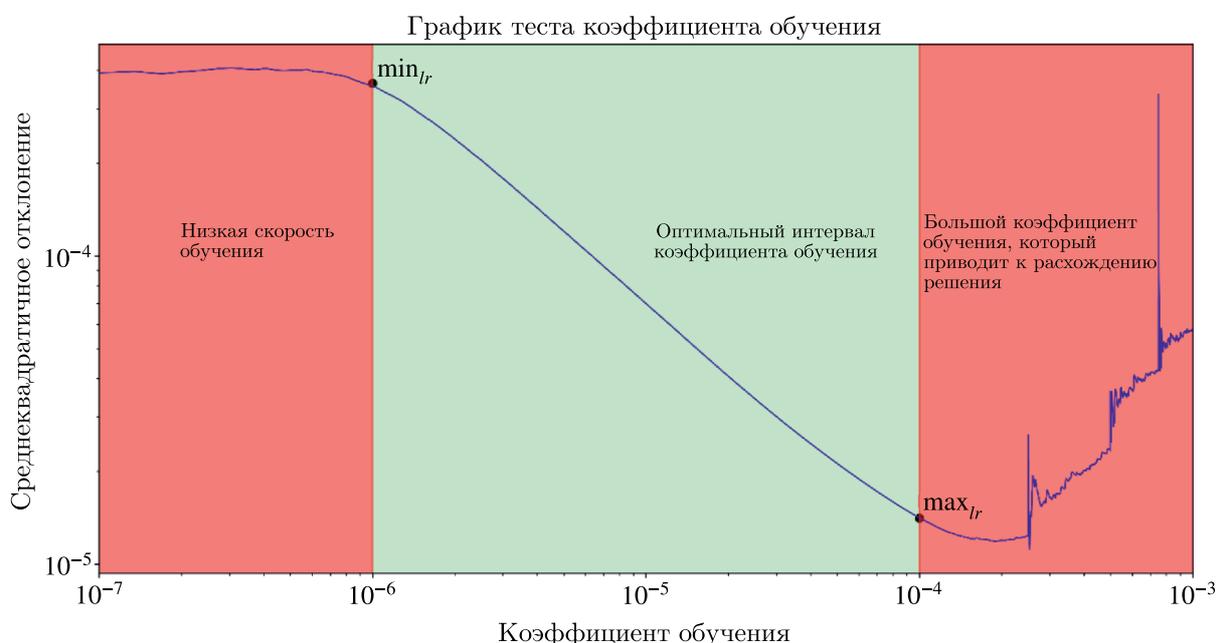


Рис. 6. Тест коэффициента обучения

Как видно по рис. 6, при $\eta < 10^{-6}$ среднеквадратичная ошибка не уменьшается, т. е. нейронная сеть не обучается, поэтому нужно брать коэффициент выше, а при $\eta > 10^{-4}$ среднеквадратичная ошибка ведет себя нестабильно, значит, найденное оптимизатором решение расходится. Оптимальный коэффициент обучения лежит в диапазоне от 10^{-6} до 10^{-4} .

В статье [Jordan, 2018] описывается эффективный метод по уменьшению η в пределах цикла по функции косинуса на интервале $[0, \pi]$:

$$\eta(i, T_{current}) = \eta_{\min} + \frac{1}{2} \cdot (\eta_{\max}^i - \eta_{\min}) \cdot \left(1 + \cos \frac{T_{current}}{T_i} \pi\right), \quad (2)$$

$$T_i(i) = T_0 \cdot 1,2^i, \quad (3)$$

где i — номер цикла, η — текущий коэффициент обучения, η_{\min} — минимальный коэффициент обучения, η_{\max}^i — максимальный коэффициент обучения на i -м цикле, T_0 — количество итераций

в первом цикле (начальная длина цикла), T_i — количество итераций в i -м цикле (длина цикла), $T_{current}$ — номер итерации внутри цикла $[0, T_i]$.

Одна итерация — прохождение пакета из 128 кривых.

Таким образом, в каждом цикле коэффициент обучения уменьшается от максимального до минимального значения по косинусоиде по формуле (2), причем максимальное значение на каждом цикле уменьшается в 0,95 раз по формуле (1), а длина цикла увеличивается в 1,2 раза по формуле (3). На рис. 7 изображена зависимость η от эпох.

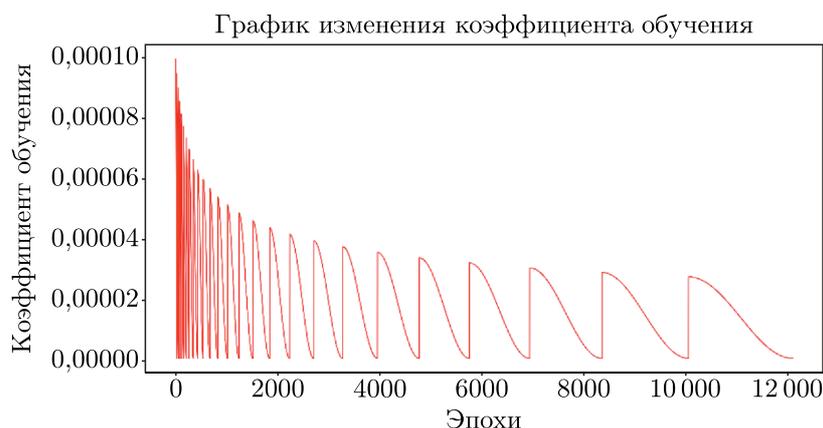


Рис. 7. Изменение коэффициента обучения

При использовании только нижней границы $\eta = 10^{-6}$ ИНС обучается медленно, а при использовании верхней границы $\eta = 10^{-4}$, модель может не найти искомым локальный минимум и перестать уменьшать функцию ошибки (найти сходимость), или вовсе сходимость может быть не достигнута. Выбрав циклически изменяемый коэффициент обучения, мы не только увеличили скорость обучения, но также смогли обучить ИНС лучше, чем при обучении по верхней границе, а как показала практика, модель обучалась даже быстрее. Данный эффект ускорения обучения от применения циклически изменяемого коэффициента обучения описан в статье [Jordan, 2018]. Это связано с тем, что модель находит новые локальные минимумы при резком увеличении коэффициента обучения, а далее, при уменьшении коэффициента, приближается к этому минимуму.

На рис. 8, а приведено сравнение обучения с различными коэффициентами. Если посмотреть на минимумы в каждом цикле, то видно, что скорость обучения с циклами выше, чем при обучении с большим коэффициентом обучения ($\eta = 10^{-4}$). Обученная с разными коэффициентами обучения ИНС была протестирована на реальной кривой охлаждения природного газа. На рисунке 8, б показано, что обучение с большим коэффициентом обучения ($\eta = 10^{-4}$) недостаточно точное для применения, так как максимальное отклонение от более обученной ИНС с циклически изменяемым коэффициентом составило 0,42 К, что существенно оказывает влияние на температурный напор и теплопередачу.

Как было отмечено выше, для обучения было принято взять коэффициент обучения в интервале $10^{-6} < \eta < 10^{-4}$, изменяющийся по формулам (1), (2) и (3). Обучение проходило с использованием оптимизатора Adam, а метрика обучения — MSE.

На рис. 9 показан процесс обучения нейронной сети. Обучение проходило на платформе Google colab pro с использованием графического модуля (GPU) и библиотеки TensorFlow для работы с GPU. Наиболее эффективное обучение при сохранении приемлемого общего времени обучения было достигнуто при разбиении обучающей выборки на пачки по 128 кривых. После каждой пачки оптимизатор методом обратного распределения изменял веса полносвязных слоев

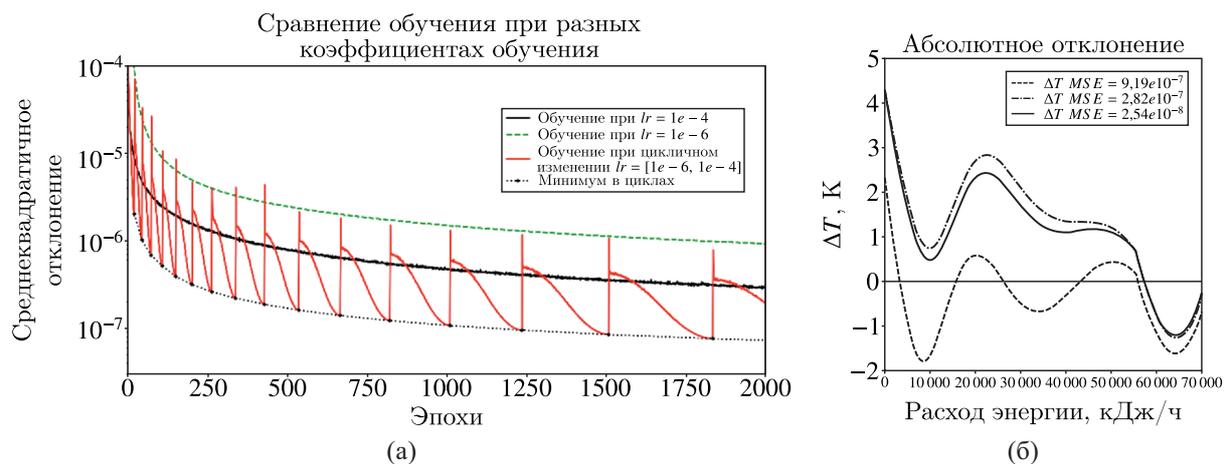


Рис. 8. Сравнение методов обучения: а) среднеквадратичная ошибка тестовой выборки; б) абсолютное отклонение от тестовой кривой

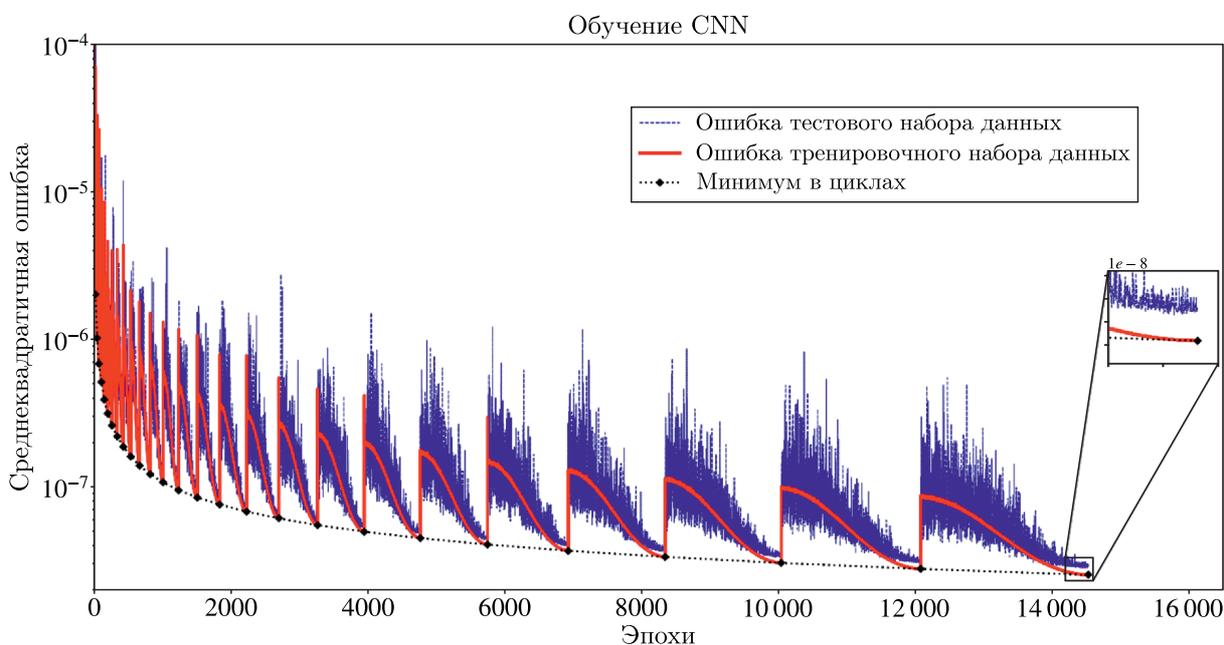


Рис. 9. Обучение нейронной сети

и фильтры сверточных слоев, а также коэффициент обучения изменялся по описанной выше методике.

Весь объем кривых (1 049 500 кривых) был разбит на обучающую и тестовую выборки в соотношении 9:1, таким образом, за 1 эпоху алгоритм проходит 7380 итераций (в каждой итерации 128 кривых), и столько же раз корректируется коэффициент обучения. Всего было пройдено 14 524 эпохи. На графике можно заметить, что минимальное среднеквадратичное отклонение каждого цикла практически перестает меняться, поэтому было принято решение остановить обучение. На рис. 10 показан график скорости изменения минимумов в циклах.

Обученная ИНС была проверена на тестовой выборке с помощью корреляционного теста. На рис. 11 показаны результаты тестирования модели. По оси Y показано фактическое значение мольного расхода компонента, а по оси X — предсказанное значение. В процессе теста в ИНС загружалась кривая кипения СХА, предварительно рассчитанная в UniSim, а на выходе из ИНС

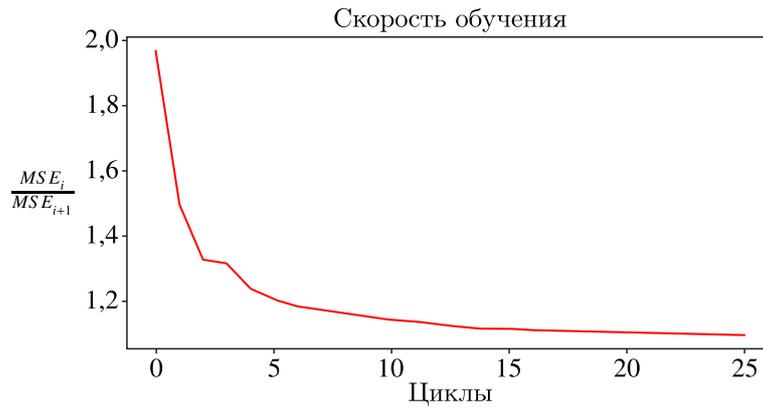


Рис. 10. Скорость обучения

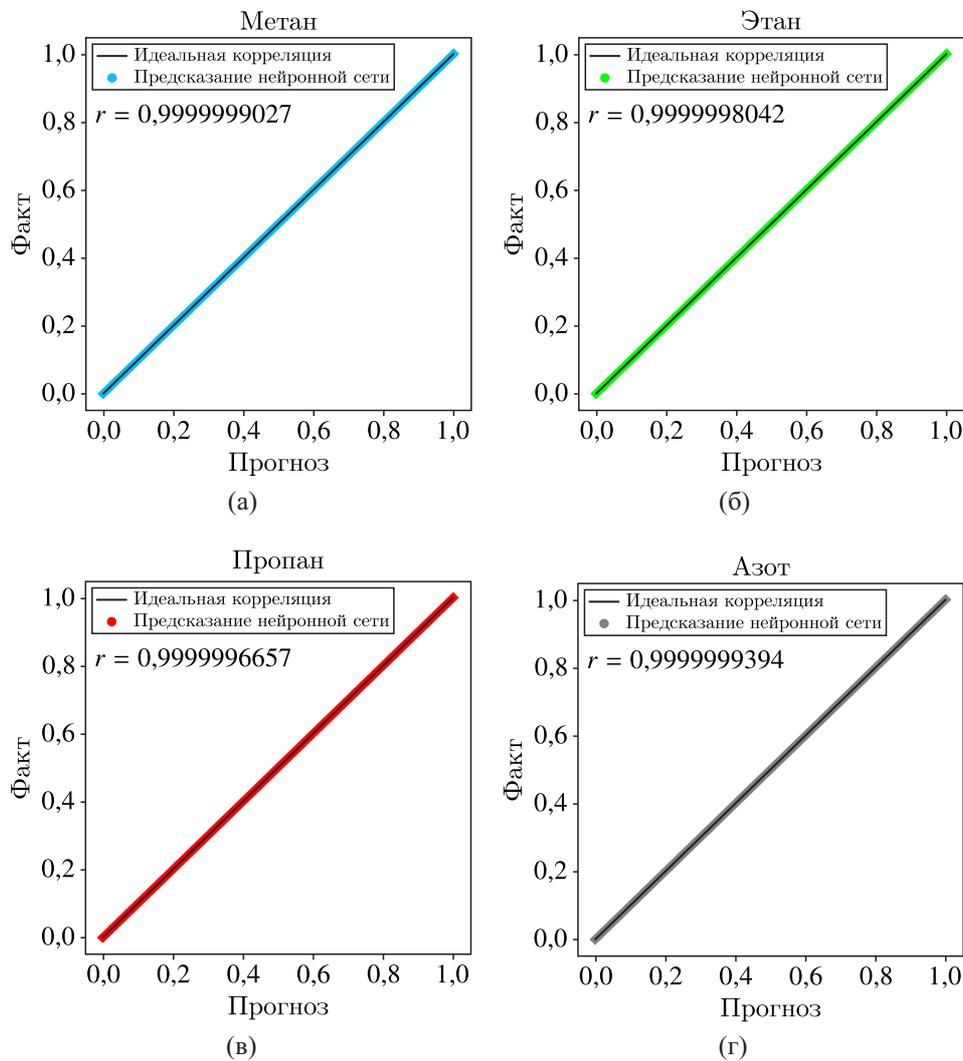


Рис. 11. Результаты тестирования модели ИНС

получали мольный расход по каждому компоненту. Стоит отметить, что ИНС работает с нормализованными данными, поэтому данные на графиках — в безразмерных величинах. На графиче-

как видно, что имеется сильная корреляция между фактическими значениями и предсказаниями с помощью обученной ИНС, таким образом можно сделать вывод, что ИНС достаточно хорошо работает на тестовых данных.

5. Описание работы ИНС

Данная нейронная сеть основана на сочетании сверточных 1D-слоев для составления карты признаков. Уменьшения размерности с помощью пулинг-слоев необходимо для ускорения обучения нейронной сети. Для демонстрации работы сверточной нейронной сети на вход в нейронную сеть была загружена нормализованная температурная кривая охлаждения природного газа, изображенная на рис. 12, а на рис. 13 продемонстрировано, как послойно работает ИНС: нейронная сеть распознает признаки на нормализованной температурной кривой по характерным точкам (точки перегиба, участки высоких градиентов и т. д.), и в результате прохождения нескольких слоев получается карта из 128 признаков. Далее карта признаков разворачивается в столбец, и с помощью полносвязных слоев нейронная сеть на основе карты признаков подбирает искомый состав СХА.

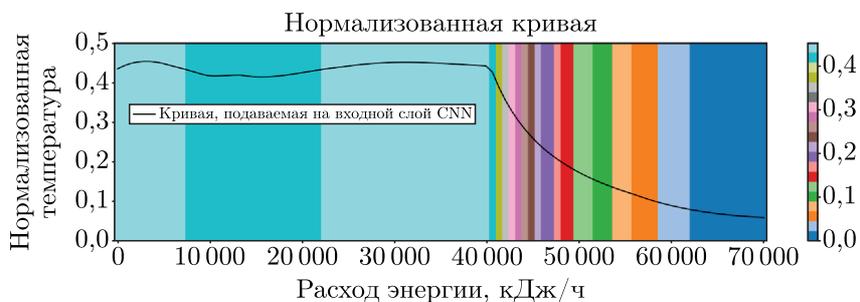


Рис. 12. Нормализованная температурная кривая

6. Результаты

В результате обучения нейронной сети была получена модель, способная подбирать необходимый состав СХА по кривой кипения. Модель ИНС была протестирована на кривой охлаждения природного газа, представленного в таблице 1. Для корректной работы теплообменника также необходимо учесть минимально гарантированный температурный напор в 3 К [Song et al., 2019], для этого опустим кривую охлаждения природного газа на 3 К.

Таблица 1. Природный газ: состав и свойства

| | |
|--------------------------|-------|
| Давление, кПа | 6500 |
| Начальная температура, К | 115 |
| Мольный расход, кмоль/ч | 8 |
| Состав, мольные доли: | |
| метан | 0,875 |
| этан | 0,055 |
| пропан | 0,021 |
| и-бутан | 0,005 |
| н-бутан | 0,003 |
| и-пентан | 0,001 |
| азот | 0,040 |

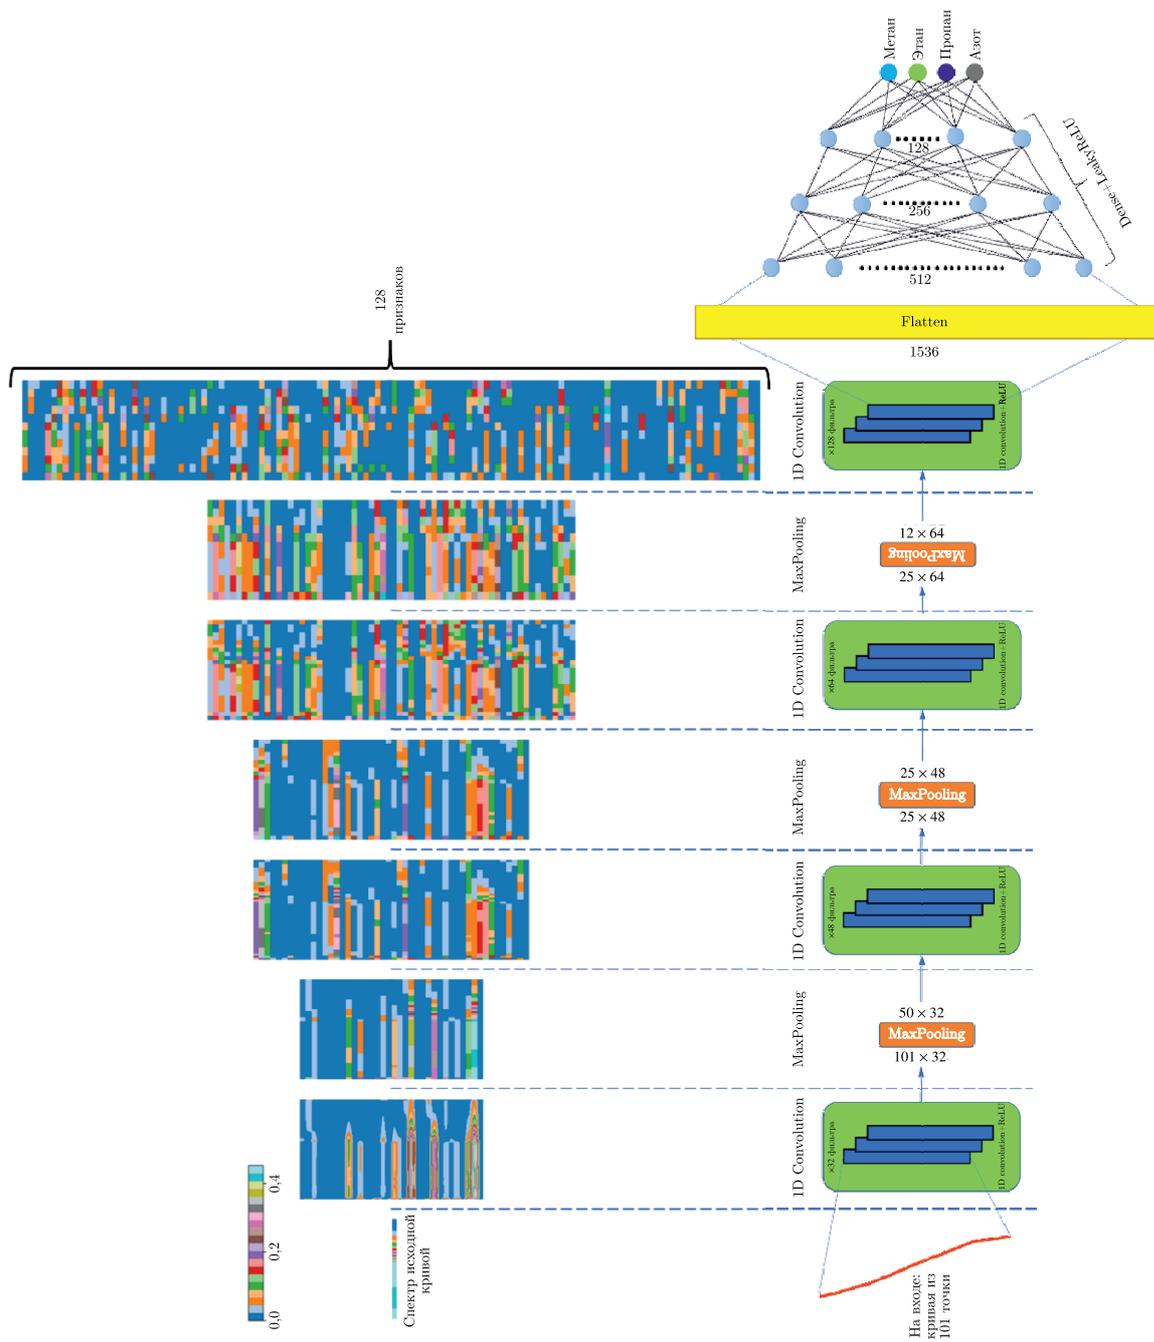


Рис. 13. Иллюстрация работы искусственной нейронной сети

На рис. 14, *a* изображен результат подбора с использованием ИНС. Видно, что ИНС подобрала состав, максимально близкий к загруженной кривой, но ИНС не учитывает технологическое ограничение на минимальный температурный напор, поэтому на рисунке 14, *a* виден минимальный температурный напор менее 3 К. Как отмечалось ранее, температурный напор менее 3 К недопустим для корректной работы теплообменника. Для учета этого ограничения входная кривая опускалась ниже на величину отклонения до тех пор, пока условие ограничения не будет выполнено. В результате такого подбора кривую необходимо опустить дополнительно на 1,44 К. Таким образом, исходная кривая природного газа была опущена на 4,44 К для учета технологического ограничения на минимальный температурный напор. Результат пересчета представлен на рис. 14, *a*. После подбора состава СХА на модели ИНС с учетом ограничения на температурный напор были получены мольные расходы смесового хладагента, указанные в таблице 2.

В связи с тем, что в исходной выборке было смоделировано достаточно много составов СХА (1 049 500), есть вероятность, что в этой выборке уже есть наиболее подходящий состав. Для поиска и последующего сравнения наиболее подходящего состава в исходной выборке был использован метод поиска k -ближних соседей, где $k = 1$, а метрика близости — евклидово расстояние в n -мерном пространстве ($n = 101$):

$$\rho(p, q) = \sqrt{\sum_{i=1}^{n=101} (p_i - q_i)^2}, \quad (4)$$

где p — кривая охлаждения природного газа, q — кривая кипения СХА.

Также для сравнения был выбран стандартный SQP-оптимизатор, встроенный в UniSim design [Venkatarathnam, 2008]. Задача SQP-оптимизации:

$$\min S(X) = \min \int_0^{\dot{Q}_a} (T_{NG} - T_{MR}(X)) d\dot{Q}, \quad (5)$$

$$T_{NG} - T_{MR}(X) > 3, \quad (6)$$

$$X = \{C_1, C_2, C_3, N_2\}, \quad (7)$$

где S — целевая функция, равная площади между кривыми природного газа и смесового хладагента; T_{NG} — кривая охлаждения природного газа с учетом минимального температурного напора в 3 К; T_{MR} — кривая кипения СХА; C_1, C_2, C_3, N_2 — мольные расходы метана, этана, пропана и азота соответственно.

Для оценки эффективности подбора были подсчитаны эксергетические потери в теплообменнике по формуле [Song et al., 2019]

$$\dot{E}_D = \int_0^{\dot{Q}_a} T_0 \left(\frac{1}{T_{MR}} - \frac{1}{T_{NG}} \right) d\dot{Q}, \quad (8)$$

где \dot{E}_D — эксергетические потери в теплообменнике в единицу времени, \dot{Q}_a — тепловая мощность теплообменника, T_0 — температура окружающей среды, принятая 273,15 К.

На рис. 14, *b* показаны графики подбора хладагента с помощью искусственной нейронной сети, поиска ближайших соседей (KNN) и SQP-оптимизатора, а в таблице 2 — подобранные мольные расходы компонентов СХА и эксергетические потери для каждого из методов подбора. По графику видно, что ИНС подобрала лучше состав, а эксергетические потери составили на 54,5 % и 19,8 % меньше, чем при подборе состава методами KNN и SQP соответственно.

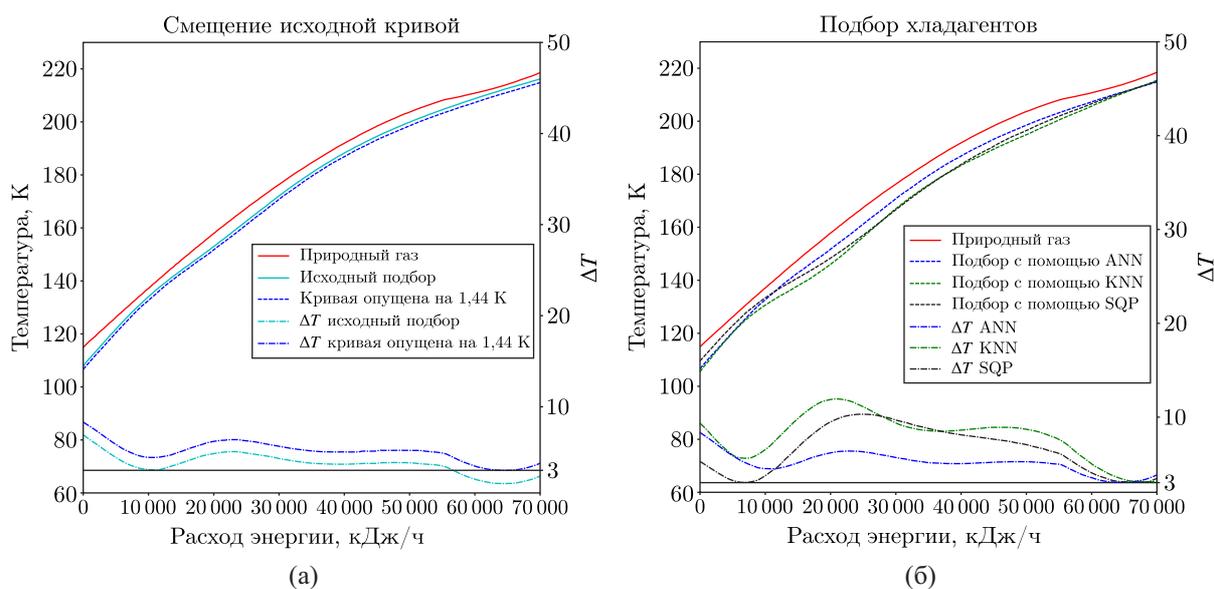


Рис. 14. Результаты подбора СХА: а) смещение исходной кривой для учета минимального температурного напора; б) сравнение с другими методами подбора

Таблица 2. Результат подбора смешеного хладагента

| | ANN | KNN | SQP |
|-------------------------------|----------|----------|----------|
| Эксергетические потери, кДж/ч | 3711,742 | 5734,754 | 4445,008 |
| Расход, кмоль/ч: | | | |
| метан | 1,334 | 1,803 | 1,777 |
| этан | 1,892 | 1,499 | 1,500 |
| пропан | 1,558 | 0,558 | 1,500 |
| азот | 0,246 | 0,287 | 0,220 |

7. Заключение

В результате исследования были получены данные по кривым кипения СХА с использованием уравнений состояния Пенга – Робинсона. На основе этих данных была сконфигурирована и обучена искусственная нейронная сеть. Данная нейронная сеть позволила найти состав смешеного хладагента по заданной кривой кипения.

Было проведено сравнение предложенного метода с поиском наилучшего совпадения в исходной выборке по методу k -ближних соседей и со стандартным методом оптимизации SQP в программе UniSim design.

Данные результаты исследования могут быть использованы при создании системы контроля состава СХА на заводе по производству СПГ с целью снижения энергетических затрат.

Список литературы (References)

Федорова Е. Б. Современное состояние и развитие мировой индустрии сжиженного природного газа: технологии и оборудование. — М.: РГУ нефти и газа имени И. М. Губкина, 2011. — 159 с.

Fedorova E.B. Sovremennoe sostoyanie i razvitie mirovoj industrii szhizhennogo prirodnogo gaza: tekhnologii i oborudovanie [State-of-the-art and development of the global liquefied natural gas industry: technologies and equipment] // Moscow: RGU nefti i gaza imeni I.M.Gubkina [National University of Oil and Gas «Gubkin University»], 2011. — 159 p. (in Russian).

- Jordan J.* Setting the learning rate of your neural network. — URL: <https://www.jeremyjordan.me/nn-learning-rate> (accessed: 27.01.2021).
- Khan M. S. et al.* Knowledge based decision making method for the selection of mixed refrigerant systems for energy efficient LNG processes // *Appl. Energy*. — 2013. — Vol. 111. — P. 1018–1031. — DOI: 10.1016/j.apenergy.2013.06.010
- Khan M. S. et al.* Knowledge inspired investigation of selected parameters on energy consumption in nitrogen single and dual expander processes of natural gas liquefaction // *J. Nat. Gas Sci. Eng.* — 2015. — Vol. 23. — P. 324–337. — DOI: 10.1016/j.jngse.2015.02.008
- Khan M. S., Karimi I. A., Wood D. A.* Retrospective and future perspective of natural gas liquefaction and optimization technologies contributing to efficient LNG supply: A review // *J. Nat. Gas Sci. Eng.* — 2017. — Vol. 45. — P. 165–188. — DOI: 10.1016/j.jngse.2017.04.035
- Kingma D. P., Ba J. L.* Adam: A method for stochastic optimization // 3rd Int. Conf. Learn. Represent. ICLR 2015 — Conf. Track Proc., 2015.
- Lim W., Choi K., Moon I.* Current status and perspectives of Liquefied Natural Gas (LNG) plant design // *Ind. Eng. Chem. Res.* — 2013. — Vol. 52, No. 9. — P. 3065–3088. — DOI: 10.1021/ie302877g
- Peng D.-Y., Robinson D. B.* A New Two-Constant Equation of State // *Ind. Eng. Chem. Fundam.* — 1976. — Vol. 15, No. 1. — P. 59–64. — DOI: 10.1021/i160057a011
- Remelje C. W., Hoadley A. F. A.* An exergy analysis of small-scale liquefied natural gas (LNG) liquefaction processes // *Energy*. — 2006. — Vol. 31, No. 12. — P. 2005–2019. — DOI: 10.1016/j.energy.2005.09.005
- Smith L. N.* Cyclical learning rates for training neural networks // *Proceedings IEEE Winter Conference on Applications of Computer Vision, WACV, 2017.* — Institute of Electrical and Electronics Engineers Inc., 2017. — P. 464–472. — DOI: 10.1109/WACV.2017.58
- Song C. et al.* Optimization of mixed refrigerant system for LNG processes through graphically reducing exergy destruction of cryogenic heat exchangers // *Energy*. — 2019. — Vol. 168. — P. 200–206. — DOI: 10.1016/j.energy.2018.11.105
- Venkatarathnam G.* *Cryogenic Mixed Refrigerant Processes* / K. D. Timmerhaus, C. Rizzuto (eds.). — NY: Springer New York, 2008.
- Wood D.* Floating gas liquefaction: Competing technologies make progress // *Hart's E. P.* — 2009. — Vol. 82, No. 5. — P. 83–85.