

Нейро-нечеткие вычисления энтальпии для учета потребления тепла

С. М. Морозов

Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия
frostsergei01@gmail.com

Аннотация. Рассматривается способ аппроксимации, основанный на использовании нейро-нечетких вычислений при расчете тепловой энергии. Описываются подходы, реализующие концепции искусственного интеллекта, используемые для повышения точности вычисления энергии на основе периодически получаемых данных о параметрах учета. Оценивается точность работы нейро-нечеткой системы при аппроксимации уравнений, описывающих физическую зависимость параметров учета от параметров среды. Проанализированы причины, которые ограничивают применение нейро-нечетких систем в задачах аппроксимации.

Ключевые слова: нейро-нечеткая аппроксимация, учет энергоносителей, расход тепловой энергии

Для цитирования: Морозов С. М. Нейро-нечеткие вычисления энтальпии для учета потребления тепла // Изв. СПбГЭТУ «ЛЭТИ». 2023. Т. 16, № 8. С. 28–35. doi: 10.32603/2071-8985-2023-16-8-28-35.

Original article

Neuro-Fuzzy Enthalpy Calculations for Heat Consumption Recording

S. M. Morozov

Saint Petersburg Electrotechnical University, Saint Petersburg, Russia
frostsergei01@gmail.com

Abstract. An approximation method for calculating thermal energy, based on the use of neuro-fuzzy calculations is considered. Method for applying approaches based on the concepts of artificial intelligence to improve the accuracy of energy calculations based on periodically obtained data on metering parameters is described. An assessment is made of the accuracy of the operation of a neuro-fuzzy system when approximating equations that describe the physical dependence on several parameters of the environment. The reasons that limit the use of neuro-fuzzy systems in approximation problems are analysed.

Keywords: neuro-fuzzy approximation, accounting for energy carriers, thermal energy consumption

For citation: Morozov S. M. Neuro-Fuzzy Enthalpy Calculations for Heat Consumption Recording // LETI Transactions on Electrical Engineering & Computer Science. 2023. Vol. 16, no. 8. P. 28–35. doi: 10.32603/2071-8985-2023-16-8-28-35.

Введение. Технологии и вычисления, использующие алгоритмы искусственного интеллекта, широко распространены в различных областях. Они применяются для классификации, прогнозирования, принятия решений и для других задач.

Одной из задач, в которых используются интеллектуальные вычисления, является аппроксимация. При математической обработке периодически считываемых сигналов возникают погреш-

ности вычислений, связанные с дискретностью считывания. Чем эффективнее алгоритмы аппроксимации, тем корректнее результаты вычисления в технических системах.

В статье описывается метод аппроксимации, основанный на нейро-нечетких вычислениях. В качестве практического применения нейро-нечеткого аппроксиматора рассматривается сфера коммерческого учета энергоносителей и ставится

задача точного вычисления потребляемой энергии. Чтобы решить поставленную задачу, выполняется аппроксимация вычисления промежуточных физических величин, одна из которых – энтальпия.

Моделируемые вычисления. Для вычисления тепловой энергии (далее – тепла) нужны данные учета. Для этого требуется получить данные о необходимых характеристиках вещества в трубопроводе. Вычисление тепла выполняется на основе объема, давления и температуры теплоносителя. Этим параметрам достаточно для вычисления потребляемого тепла. Чтобы считывать эти параметры, существуют специальные датчики, требования к которым указаны в ГОСТах. Например, датчики температуры, которые представляют данные о температуре в виде сигнала сопротивления, описаны в ГОСТ 6651–2009.

Датчики для определения обозначенных ранее физических величин преобразовывают необходимые физические характеристики, описывающие состояние трубопровода, в электрические сигналы определенного вида. Например, для определения объема теплоносителя может применяться сигнал частоты, давление в трубопроводе может описываться сигналом тока, а температура теплоносителя – сигналом сопротивления. Для корректных вычислений прибор настраивается на работу с конкретными датчиками. Так, для определения объема теплоносителя вводится параметр цены импульса на частотном входе.

Чтобы упростить вычисления, вводятся промежуточные параметры, которые представляют собой вспомогательные физические величины. Для этих целей могут вычисляться плотность и энтальпия. Плотность используется для вычисления массы потребленного теплоносителя, а энтальпия – при вычислении потребляемого тепла. Другая причина выбора этих физических величин – их применение в большинстве конфигураций теплопроводов. Вычисление плотности в общем случае требует данных о температуре, давлении и молярной массе вещества, а энтальпия вычисляется на основе объема, давления и внутренней энергии теплоносителя.

Применение нейро-нечетких систем для коммерческого учета. Для повышения точности вычислений суммарно потребленного тепла требуется аппроксимация значений. В сфере учета основные параметры, учитываемые при разработке алгоритмов вычислений, – это точность расчетов и скорость работы. Качество аппрокси-

мации определяет класс точности прибора и степень достоверности вычислений, а скорость работы обеспечивает получение большего количества данных для расчетов. В зависимости от назначения прибора могут быть важны и другие параметры, приоритет которых может быть выше, чем у основных. Например, для автономных приборов учета, питающихся от автономного источника, важно энергопотребление системы, определяемое сроком службы батареи.

Нейро-нечеткие вычисления – это один из многих методов аппроксимации математических функций. Простейшие методы – такие, как построение интерполяционных полиномов, легко вычислимы и интерпретируемы, однако при большом количестве значений функций их построение может быть долгим и итоговая аппроксимирующая функция может оказаться достаточно сложной и трудновычисляемой. Для решения проблемы низкой точности применяется разбиение аппроксимирующей функции на отдельные участки, что обеспечивает работу, например, сплайновой аппроксимации.

Существуют методы аппроксимации на базе искусственного интеллекта и машинного обучения. Классическое решение задачи заключается в использовании нейронных сетей. В соответствии с теоремой Цыбенко нейронная сеть прямого распространения с одним внутренним слоем может аппроксимировать любую непрерывную функцию с любой точностью. Так как учет энергоносителей ведется постоянно (за исключением нештатных ситуаций, связанных с перебоем питания и снятием прибора с объекта по техническим причинам), применение нейронных сетей корректно. Также нейронные сети могут использоваться для решения задачи предсказания. Например, с их помощью система может описывать ожидаемое потребление тепла на следующий месяц. Проблема нейронных сетей для аппроксимации – высокие вычислительные затраты по сравнению с другими, более простыми методами.

Другой метод аппроксимации основан на использовании теории нечетких множеств. Нечеткие системы способны выполнять аппроксимацию на основе описания правил «ЕСЛИ – ТО». Использование нечетких множеств широко применяется при решении задач классификации для обеспечения интерпретируемости системы, так как лингвистическая составляющая – важный элемент этой концепции. В качестве консеквенты

описанного правила может выступать функция от нескольких переменных. Такой вид систем называется нечеткими системами Такаги–Сугено–Канга и используется в задачах аппроксимации функций [1].

Нейро-нечеткие системы представляют собой объединение систем нечеткой логики и нейронных сетей и используются для решения задач математической аппроксимации. Нейронные сети выполняют аппроксимацию на основе машинного обучения, которое может выполняться в любое время. Системы на основе нечеткой логики в явном виде описывают правила аппроксимации, которые не могут быть изменены в процессе работы. Объединение этих систем представляет собой систему нечеткого вывода, у которой нечеткие правила формируются нейронной сетью. Так, первая разновидность нейро-нечетких систем, называемая ANFIS (адаптивная система нейро-нечеткого вывода), представляет собой классическую систему Такаги–Сугено–Канга, правила которой формируются нейронной сетью в процессе обучения.

Аппроксимация данных учета нужна для каждого из накапливаемых показаний – совокупного объема теплоносителя, потребленного тепла и т. д. Показания накапливаются в течение работы прибора, и в конце определенного периода сохраняются в интервальных архивах.

Другим направлением применения нейро-нечетких систем можно считать контроль и описание нештатных ситуаций. Внутренняя диагностика имеет особое значение, так как позволяет отслеживать состояние датчиков и показаний. Фиксированный набор нештатных ситуаций используется для мониторинга конкретных неполадок, которые могут возникнуть в приборе: сбой микросхемы, выход за диапазоны вычислений, некорректные данные для вычислений. С помощью нейро-нечеткой логики создается универсальный механизм контроля всех параметров, нештатные ситуации в котором могут быть настроены пользователем. В контексте вычисления энтальпии это применяется для контроля значений, которые должны находиться в определенном диапазоне.

Другое применение нейро-нечетких систем – предсказания. В сфере коммерческого учета они могут использоваться для предварительной оценки энергопотребления в будущем и построения рекомендаций по снижению потребления. Для реализации этой задачи необходимы средства контроля каждого отдельного узла в тепловом контуре, так как чтобы определить узлы с

наибольшим потреблением при оценке будущего энергопотребления, нужно отслеживать динамику потребляемого тепла на каждом отдельном трубопроводе.

Архитектура нейро-нечеткого вычислителя. Нейро-нечеткие системы используются для вычисления плотности и энтальпии. Поскольку прямые расчеты этих величин очень сложны, применяются вспомогательные методы. Например, Государственный комитет Российской Федерации по стандартизации и метрологии формирует таблицы значений удельного объема и энтальпии воды (в том числе перегретой) в зависимости от температуры и давления. Использование этих таблиц предполагает интерполяцию для получения более простой зависимости на основе представленных данных. Вычисления энтальпии и плотности конкретного вещества связаны с получением фиксированной зависимости от двух переменных, поэтому для них подойдет ANFIS, который предварительно обучается на официальных данных.

Рассматриваемые физические характеристики зависят от давления и температуры вещества. Реальная математическая зависимость представляет собой набор дифференциальных уравнений. Поскольку тепловычислители должны выполнять вычисления быстро, то чтобы их ускорить применяются различные методы аппроксимации, для реализации которых предоставляются таблицы значений плотности или энтальпии вещества в зависимости от соответствующих физических характеристик. Также предоставляются погрешности измеренных значений для определения минимально необходимой точности аппроксимации. При этом значения физических величин накладывают ограничения на выбираемые методы аппроксимации. Например, зависимость плотности воды от ее температуры не монотонна и достигает максимума на 3.982 °С, что не позволяет использовать методы аппроксимации, предназначенные для монотонных функций.

Рассмотрим вычисления энтальпии. В качестве теплоносителя используется вода. В соответствии с ГСССД 187–99 [2] энтальпия зависит от температуры и давления воды или перегретого пара. Таблицы ГСССД показывают значения энтальпии для температур от 0 до 1000 °С и давления от 0.001 до 1000 МПа и их абсолютные погрешности. Существуют программные решения, выполняющие вычисления дифференциальных уравнений, описывающих эти зависимости. К таким решениям относится программа Water

Steam Pro, разработанная авторами таблиц ГСССД. Программа на основе данных о давлении и температуре воды или пара вычисляет плотность, внутреннюю энергию, удельный объем, энтропию, энтальпию и другие параметры. Она может быть использована при оценке модели аппроксимации или для формирования набора данных для обучения.

Нейро-нечеткий вычислитель энтальпии представляет собой предварительно обученную систему, которая формирует значение энтальпии в зависимости от давления и температуры теплоносителя. Состав и границы нечетких множеств определяются в процессе обучения системы, так как напрямую влияют на точность вычислений. Входными данными являются абсолютные значения температуры и давления теплоносителя. Поскольку эти физические величины преобразовываются в непрерывные электрические сигналы (ток и сопротивление), то реализуема и аппаратная версия нейро-нечеткого аппроксиматора. Это потребует преобразования сигналов тока и сопротивления в сигналы напряжения, для чего используются преобразователи «ток–напряжение» (ПТН) и «сопротивление–напряжение» (ПСН). Реализация такого подхода на основе аналоговых сигналов представлена в [3], но существуют и аппаратные реализации на базе цифровых сигналов [4].

Аппроксимация при вычислениях энтальпии сводится к двум задачам: минимизации среднего отклонения от реальных значений энтальпии и недопущении выхода каждого вычисления за установленные границы. Нейро-нечеткие аппроксиматоры могут контролировать оба фактора. Функция от требуемых физических величин заранее определена, поэтому нужно предварительное обучение вычислителя по набору точек, определенных в таблице или сформированных программой. Прямым следствием использования такого подхода становится возможность автоматизации процесса аппроксимации для построения систем учета в различных диапазонах значений.

Нейро-нечеткая система будет предварительно обучена, чтобы впоследствии использоваться во встраиваемых системах для вычислений энтальпии. Современные средства разработки встраиваемых систем позволяют автоматически встроить предварительно обученную модель в код для последующего применения, для чего нужно обучить модель. В качестве вычислителя используется нейро-нечеткая система вида ANFIS [5].

Программная реализация использует модель S-ANFIS (State-ANFIS) [6], представляющую собой расширение классической ANFIS, которое заточено под моделирование нелинейных функций. Авторы разработали S-ANFIS на базе PyTorch, что позволяет сохранять обученные модели в файлы для последующего применения. Техническим отличием S-ANFIS от ANFIS служит то, что в ANFIS входные переменные используются в моделируемых уравнениях, а в S-ANFIS для этих целей используются различные переменные. Требуется сравнить ANFIS и S-ANFIS для определения системы, которая сформирует аппроксимирующую функцию более точно. Из этого следует, что обучение системы нужно проводить на всех данных рабочего диапазона, выделяя минимально возможную выборку данных, не участвующих в обучении, а также выполнять минимально возможную предобработку данных. Недостаток этих систем при решении задач аппроксимации заключается в ограничении на формат итоговых функций. ANFIS и связанные с ней системы – это системы нечеткого вывода Такаги–Сугено–Канга, которые формируют результат в виде функции от входных переменных. В случае ANFIS итоговая функция аппроксимации представляет собой набор линейных функций от входных сигналов на определенном диапазоне. Это означает, что при использовании этих систем применяется линейная аппроксимация.

Авторы S-ANFIS использовали ее для предсказания в экономических системах. Эта задача отличается от рассматриваемой в данной статье особенностями входных данных и требованиями к результатам. В финансовом секторе характерны скачки определенных показателей – например, котировок ценных бумаг, поэтому в обрабатываемых данных экономической области характерны шумы. При этом к точности полученных результатов не предъявляются большие требования. В задаче аппроксимации математических зависимостей ситуация противоположна: в идеальном случае данные не содержат шумов, однако высоки требования к точности значений. Это означает, что корректное обучение системы должно формировать результат с минимальной погрешностью.

Входные данные для обучения системы представляют собой размеченный набор данных, который содержит значения температуры в градусах Цельсия ($^{\circ}\text{C}$), значения абсолютного давления в мегапаскалях (МПа) и итоговые значения энтальпии в килоджоулях на килограмм (кДж/кг).

Так как аналогичный набор данных требуется для вычисления плотности теплоносителя, соответствующим образом формируется набор данных для ее аппроксимации. Это решение позволяет проверить универсальность исследуемого метода. Таблицы значений энтальпии представлены в том же документе, что и таблицы удельного объема. Плотность представляет собой обратную удельному объему величину. В качестве единиц измерения плотности принимается килограмм на кубометр (кг/м³).

Так как для лучшего обучения системы нужно сформировать наиболее полный и точный набор данных, возникает проблема оптимизации модели. Очень точная модель будет с очень малой погрешностью вычислять требуемые значения, однако может требовать большого объема для хранения. В случае, когда в системе мало памяти для хранения, этот вопрос становится критичным, и для экономии места, а также времени на обучение сети требуется оптимизировать набор входных данных и параметров системы.

Результаты вычислений. В итоге обучения нейро-нечеткой системы были получены две функции аппроксимации, вычисляющие плотность и энтальпию воды и пара. В таблице представлены результаты аппроксимации энтальпии с учетом конфигурации системы: число циклов обучения, количество нечетких множеств и др. Следует отметить, что за начальное значение давления принималось атмосферное, равное 0.10325 МПа вме-

сто нуля. Для простоты рассматривались конфигурации нечетких множеств, представляющих собой гауссовы функции с одинаковым среднеквадратическим отклонением и равномерно распределенным математическим ожиданием. Результаты для ANFIS и S-ANFIS совпадают.

Наибольшая погрешность проявлялась на крайних значениях температуры и давления. При этом абсолютные отклонения абсолютных значений не превышали допусков из таблиц ГСССД. Это означает, что разработанные системы могут использоваться на практике. Демонстрация аппроксимированных функций и погрешностей представлена на рис. 1. Увеличение количества нечетких множеств не всегда приводило к уменьшению максимальной погрешности, однако способствовало тому, чтобы на большем количестве данных была меньшая погрешность. Это означает, что увеличение количества нечетких множеств приводит к уменьшению совокупной погрешности. Время на обучение при увеличении количества нечетких множеств не увеличивалось или увеличивалось незначительно.

Для набора данных от 0 до 2.5 МПа оптимальное количество нечетких множеств – 15. При большем их количестве (например, 19) количество элементов с минимальной погрешностью больше, однако увеличиваются максимальное отклонение и размер системы. Конфигурация наиболее точной системы для минимального набора данных (15 нечетких множеств) представ-

Результаты аппроксимации энтальпии
Enthalpy approximation results

Количество нечетких множеств	Размер набора данных	Шаг в наборе данных	Количество итераций обучения	Время обучения, с	Максимальное абсолютное отклонение, кДж/кг
3	0...2.5 МПа, 0...200 °С	0.5 МПа, 0.1 °С	200	110	2.2
7	0...2.5 МПа, 0...200 °С	0.5 МПа, 0.1 °С	200	114	2.1
11	0...2.5 МПа, 0...200 °С	0.5 МПа, 0.1 °С	200	118	1.75
15	0...2.5 МПа, 0...200 °С	0.5 МПа, 0.1 °С	200	121	1.9
19	0...2.5 МПа, 0...200 °С	0.5 МПа, 0.1 °С	200	126	2
3	0...10 МПа, 0.500 °С	1 МПа, 1 °С	200	62	31
7	0...10 МПа, 0...500 °С	1 МПа, 1 °С	200	61	29
11	0...10 МПа, 0...500 °С	1 МПа, 1 °С	200	62	23
15	0...10 МПа, 0...500 °С	1 МПа, 1 °С	200	69	23
19	0...10 МПа, 0...500 °С	1 МПа, 1 °С	200	70	21

лена на рис. 1. На рис. 2 представлены результаты этой же системы при обучении на нормализованных данных для оценки относительной погрешности аппроксимации. На рис. 1, 2 обозначены: y_t – исходные значения функций, c_t – аппроксимированные; y_{nt} , c_{nt} – значения для нормализованных данных; i – номер итерации; P_i и t_i – значения давления (МПа) и температуры ($^{\circ}\text{C}$) на итерации i ; n – количество элементов с определенной погрешностью; h , h_n – значения энтальпии (кДж/кг) для исходных и нормализованных данных. Значения y_t и c_t отличаются мало, поэтому на графиках они сливаются в одну линию.

Из рис. 1 и 2 видно, что максимальная абсолютная погрешность аппроксимации меньше требуемой по ГСССД на выбранном диапазоне. Большее количество нечетких множеств менее эффективно, так как итоговая модель требует больше места на диске и дольше обучается. Так, для 150 нечетких множеств на каждую переменную

максимальная погрешность меньше 0.9 кДж/кг, однако сохраненная модель занимает 818 Кбайт на диске. Это означает, что полученная модель формирует значения с высшей точностью, однако ее использование во встраиваемых системах с малым объемом памяти невозможно, так как модель требует больше места, чем располагает система.

Файл обученной модели занимает 21 Кбайт памяти. Модель PyTorch может быть загружена во встраиваемую систему с помощью специальных программных утилит – как STM32CubeAI для генератора кода STM32CubeMX. Для этого модель требуется экспортировать в формат ONNX. Модель в этом формате занимает 9 Кбайт, что оптимально для использования во встраиваемых системах.

Заключение. В результате выполнения работы было установлено, что применение ANFIS обеспечивает высокую точность аппроксимации функций для вычисления энтальпии воды. Максимальная абсолютная погрешность вычислений меньше максимальной по таблицам ГСССД,

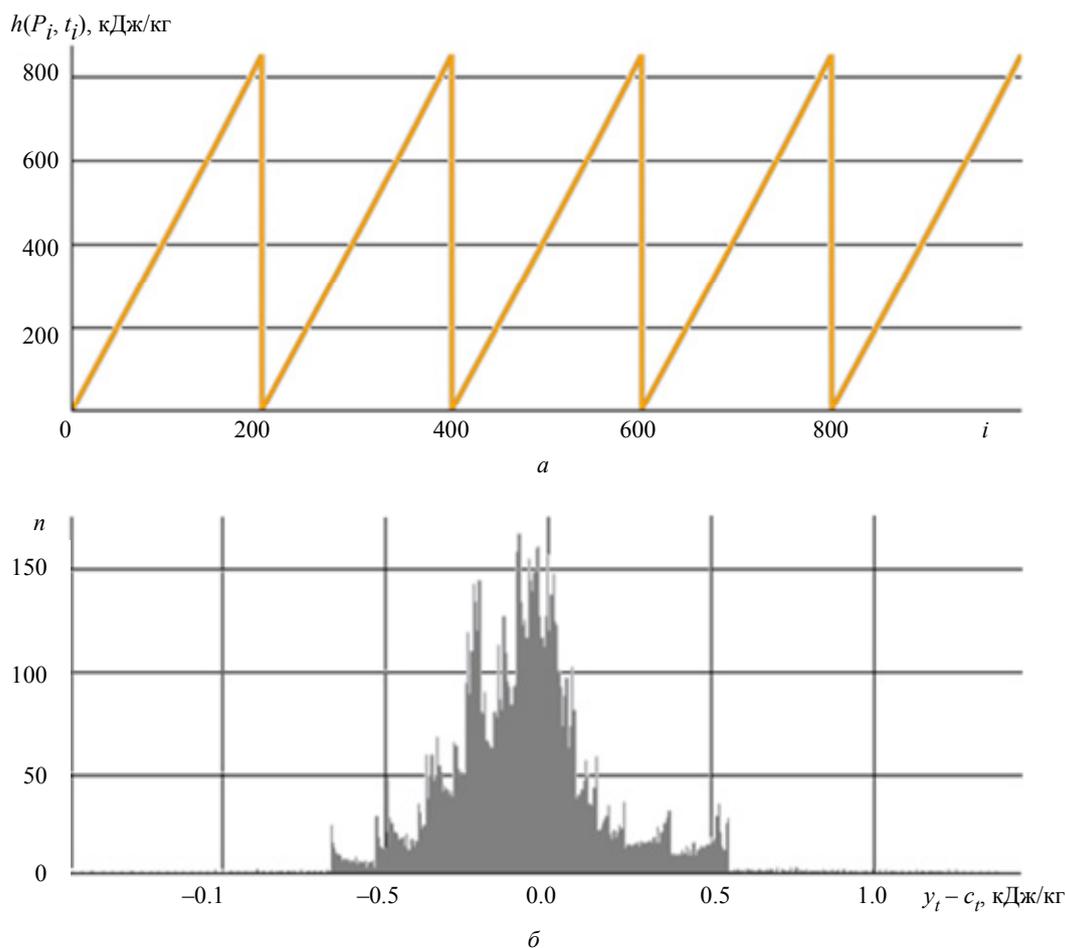


Рис. 1. Результаты вычислений нейро-нечеткой модели, обученной на исходных данных: a – графики вычисленных значений; b – распределение погрешностей

Fig. 1. Results of neuro-fuzzy model calculations, trained on provided data:

a – calculated values graphs; b – errors distribution

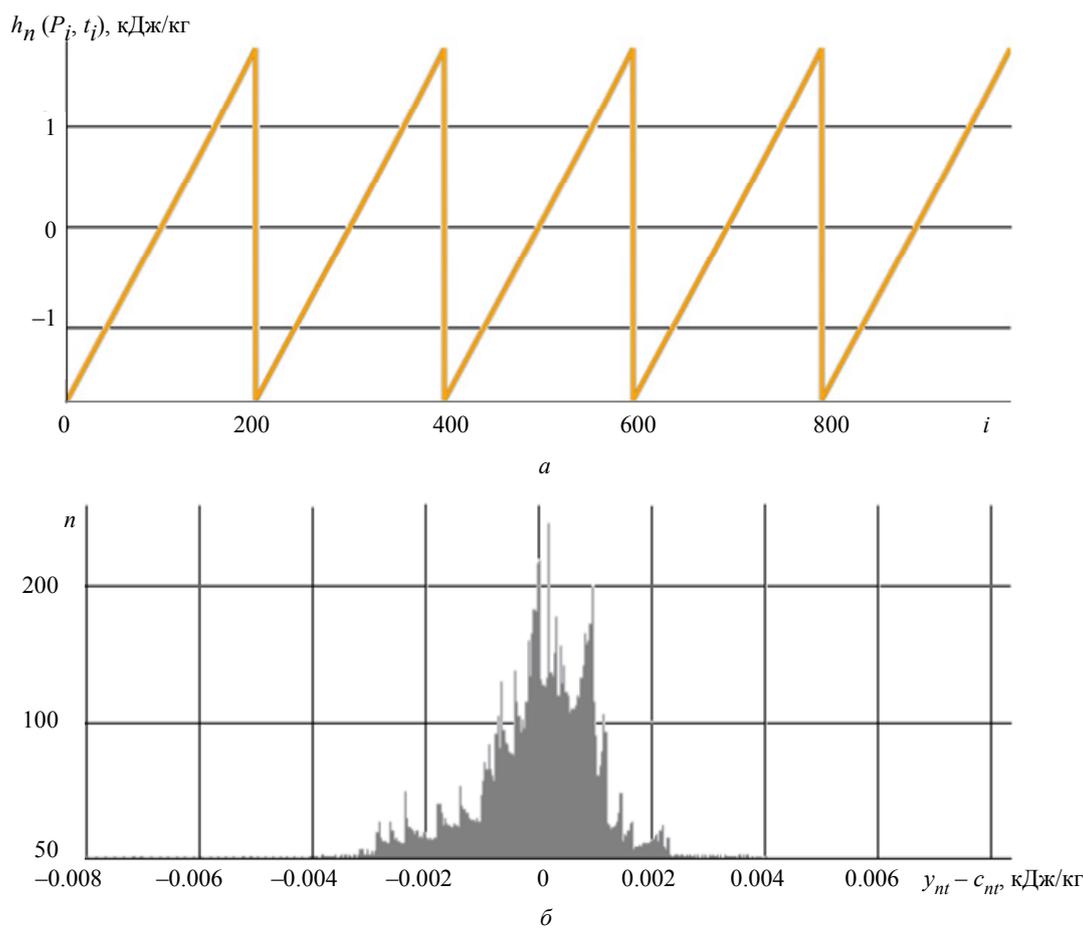


Рис. 2. Результаты вычислений нейро-нечеткой модели, обученной на нормализованных данных:

a – графики вычисленных значений; *b* – распределение погрешностей
Fig. 2. Results of neuro-fuzzy model calculations, trained on normalized data:
a – calculated values graphs; *b* – errors distribution

определяющим минимальные требования к вычислениям. Это доказывает, что нейро-нечеткие вычисления могут применяться в термодинамических системах для аппроксимации сложных функций.

Точность аппроксимации на базе ANFIS и ее разновидности ограничена из-за линейности

функций, выполняющих аппроксимацию. Использование полиномов большей степени способствует уменьшению погрешности аппроксимирующей модели. Для их применения требуется разработка принципиально новой архитектуры нейро-нечетких систем.

Список литературы

1. Zou W., Xia Y., Dai L. Fuzzy broad learning system based on accelerating amount // IEEE Transactions on Fuzzy Systems. 2022. Vol. 30, no. 9. P. 4017–4024. doi: 10.1109/TFUZZ.2021.3128210.
2. Александров А. А., Григорьев Б. А. Таблицы стандартных справочных данных. Вода. Удельный объем и энтальпия при температурах 0...1000 градусов Цельсия и давлениях 0,001...1000 МПа. Табл. станд. справ. данных/ГСССД; Госстандарт. М.: Изд-во стандартов, 1999.
3. Rodriguez-Vazquez A., Vidal-Verdu F. Learning in neuro/fuzzy analog chips // Proc. of ISCAS'95 – Intern. Symp. on Circuits and Systems. Seattle, WA, USA, 1995. P. 2325–2328. Vol. 3. doi: 10.1109/ISCAS.1995.523895.
4. Jain A. A. Z., Sharma V. K. Design and development of neuro-fuzzy based multi-level inverter using FPGA // 2022 Intern. Conf. on Automation, Computing and Renewable Systems (ICACRS). Pudukkottai, India, 2022. P. 1–8. doi: 10.1109/ICACRS55517.2022.10029291.
5. Jang J.-S. R. ANFIS: adaptive-network-based fuzzy inference system // IEEE Transactions on Systems, Man and Cybernetics. 1993. Vol. 23, no. 3. P. 665–685. doi: 10.1109/21.256541.
6. Lenhard G., Maringer D. State-ANFIS: A generalized regime-switching model for financial modeling // IEEE Symp. on Computational Intelligence for Financial Engin. and Econ. (CIFEr). Helsinki, Finland, 2022. P. 1–8. doi: 10.1109/CIFEr52523.2022.9776208.

Информация об авторе

Морозов Сергей Михайлович – аспирант кафедры вычислительной техники СПбГЭТУ «ЛЭТИ».
E-mail: frostsergei01@gmail.com

References

1. Zou W., Xia Y., Dai L. Fuzzy broad learning system based on accelerating amount // IEEE Transactions on Fuzzy Systems. 2022. Vol. 30, no. 9. P. 4017–4024. doi: 10.1109/TFUZZ.2021.3128210.
2. Aleksandrov A. A., Grigor'ev B. A. Tablicy standartnyh spravochnyh dannyh. Voda. Udel'nyj ob'em i jental'pija pri temperaturah 0...1000 gradusov Cel'sija i davlenijah 0,001...1000 МПа. Tabl. stand. sprav. dannyh/GSSSD; Gosstandart. M.: Izd-vo standartov, 1999. (In Russ.).
3. Rodriguez-Vazquez A., Vidal-Verdu F. Learning in neuro/fuzzy analog chips // Proc. of ISCAS'95 – Intern. Symp. on Circuits and Systems. Seattle, WA, USA, 1995. P. 2325–2328. Vol. 3. doi: 10.1109/ISCAS.1995.523895.
4. Jain A. A. Z., Sharma V. K. Design and development of neuro-fuzzy based multi-level inverter using FPGA // 2022 Intern. Conf. on Automation, Computing and Renewable Systems (ICACRS). Pudukkottai, India, 2022. P. 1–8. doi: 10.1109/ICACRS55517.2022.10029291.
5. Jang J. -S. R. ANFIS: adaptive-network-based fuzzy inference system // IEEE Transactions on Systems, Man and Cybernetics. 1993. Vol. 23, no. 3. P. 665–685. doi: 10.1109/21.256541.
6. Lenhard G., Maringer D. State-ANFIS: A generalized regime-switching model for financial modeling // IEEE Symp. on Computational Intelligence for Financial Engin. and Econ. (CIFEr). Helsinki, Finland, 2022. P. 1–8. doi: 10.1109/CIFEr52523.2022.9776208.

Information about the author

Sergey M. Morozov – postgraduate student of Department of Computer Science and Engineering of Saint-Petersburg Electrotechnical University.
E-mail: frostsergei01@gmail.com

Статья поступила в редакцию 18.05.2023; принята к публикации после рецензирования 03.07.2023; опубликована онлайн 19.10.2023.

Submitted 18.05.2023; accepted 03.07.2023; published online 19.10.2023.
