



МЕТОДИКА ПРЕПОДАВАНИЯ ОБЩЕИНЖЕНЕРНЫХ И СПЕЦИАЛЬНЫХ УЧЕБНЫХ ДИСЦИПЛИН В АЭРОКОСМИЧЕСКОМ ВУЗЕ

УДК 37.09:536-042.4:004.8
DOI 10.20339/AM.07-26.054

Л.В. Быков,
канд. техн. наук, доцент
e-mail: bykovlv@mail.ru
Московский авиационный институт (НИУ)
А.М. Молчанов,
доктор. техн. наук, профессор
e-mail: alexmol_2000@mail.ru
Московский авиационный институт (НИУ)

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В ИНЖЕНЕРНОЙ ТЕРМОДИНАМИКЕ: МЕТОДИКА ОБУЧЕНИЯ СТУДЕНТОВ НЕЙРОСЕТЕВЫМ МЕТОДАМ РЕШЕНИЯ ЗАДАЧ ТЕПЛОМАССОБМЕНА

В статье представлена методика обучения студентов, как применять нейросетевые методы для решения задач тепломассообмена в рамках курса инженерной термодинамики. Акцент сделан на интеграции физического содержания и цифровых инструментов: студенты последовательно проходят этапы постановки физической задачи, генерации синтетических данных и построения нейросетевой модели. В качестве ключевого учебного примера используется обратная задача спектральной диагностики параметров горения по инфракрасному излучению газового потока. Рассматривается архитектура многослойного перцептрона (MLP) как эффективного инструмента для быстрого и точного восстановления температуры и концентраций излучающих компонентов. Приведенная методика позволяет преодолеть восприятие искусственного интеллекта как «черного ящика» и формирует у студентов целостное понимание синергии классических физических моделей и современных вычислительных подходов. Апробация методики в магистратуре показала рост мотивации, развитие цифровых компетенций и углубление понимания обратных задач.

Ключевые слова: искусственный интеллект, машинное обучение, инженерная термодинамика, теплообмен, спектральная диагностика, многослойный перцептрон, методика преподавания.

ARTIFICIAL INTELLIGENCE IN ENGINEERING THERMODYNAMICS: A TEACHING METHODOLOGY FOR TRAINING STUDENTS IN NEURAL NETWORK APPROACHES TO HEAT AND MASS TRANSFER PROBLEMS

Leonid V. Bykov, PhD in Engineering, Docent, Moscow Aviation Institute (National Research University), e-mail: bykovlv@mail.ru
Aleksandr M. Molchanov, D.Sc. in Engineering, Professor, Moscow Aviation Institute (National Research University), e-mail: alexmol_2000@mail.ru

The article presents a teaching methodology for instructing students in the application of neural network methods to solve heat and mass transfer problems within an engineering thermodynamics course. Emphasis is placed on integrating physical content with digital tools: students systematically progress through stages involving problem formulation, synthetic data generation, and neural network model development. A key instructional example is the inverse problem of spectral diagnostics – determining combustion parameters from the infrared radiation emitted by a gas flow. The architecture of the multilayer perceptron (MLP) is examined as an efficient tool for rapidly and accurately reconstructing temperature and concentrations of radiating species. The proposed methodology helps overcome the perception of artificial intelligence as a 'black box' and fosters in students a holistic understanding of the synergy between classical physical models and modern computational approaches. Implementation of this methodology in a master's-level course has demonstrated increased student motivation, enhanced digital competencies, and a deeper comprehension of inverse problems.

Keywords: artificial intelligence, machine learning, engineering thermodynamics, heat transfer, spectral diagnostics, multilayer perceptron, teaching methodology

Введение

Современный инженер-исследователь всё чаще сталкивается с необходимостью комбинировать классические физические модели и методы искусственного интеллекта. Особенно остро эта задача стоит в таких дисциплинах, как вычислительная гидродинамика, радиационный теплообмен и химическая кинетика, где традиционные подходы (например, CFD-моделирование) требуют значительных вычислительных ресурсов и времени.

В то же время нейросетевые методы позволяют строить так называемые surrogate-модели — быстрые и достаточно точные аппроксимации сложных физических зависимостей. Это открывает возможности не только для ускорения расчетов, но и для решения обратных задач, таких как оперативная диагностика параметров горения по спектру излучения — задача, имеющая прямое прикладное значение в энергетике, авиации и экологическом мониторинге.

Переход к цифровым технологиям и методам искусственного интеллекта ознаменовал новую эру в вычислительной физике и инженерной термодинамике. Особый интерес исследователей в последнее десятилетие вызывает применение искусственных нейронных сетей (ИНС) для решения фундаментальных и прикладных задач тепло-массообмена.

Традиционные методы вычислительной гидродинамики (CFD) и теплообмена, основанные на решении систем дифференциальных уравнений в частных производных, сталкиваются с существенными вычислительными затратами при моделировании высокоточных трехмерных задач. Особую сложность представляют такие явления, как турбулентность, радиационный перенос в поглощающих и излучающих средах и сложная химическая кинетика [1; 2].

Параллельно с развитием классических CFD-методов начиная с работ конца 1990-х годов формировалось направление, связанное с применением методов машинного обучения. Пионерские исследования, такие как работы Лагариса и др. [3], продемонстрировали возможность использования ИНС для решения дифференциальных уравнений в частных производных. Однако настоящий прорыв произошел в 2010-х годах с развитием глубокого обучения и увеличением доступных вычислительных ресурсов.

Нейросетевые технологии предлагают альтернативный или дополняющий подход, позволяя создавать модели-заместители, которые с высокой скоростью и приемлемой точностью воспроизводят результаты дорогостоящих расчетов, а также решают задачи, плохо поддающиеся классическому моделированию, например, оперативную спектральную диагностику [4–6].

В области расчета радиационного переноса ключевой проблемой является учет спектрального характера излучения газов. Модель расчета излучения по линиям (LBL) и традиционные узкополосные модели, (статистическая узкополосная модель (SNB) или модель k-распределения) требуют значительных вычислительных ресурсов [7; 8].

Сложность детальных химических механизмов, включающих сотни реакций, стимулировала поиск методов редукции химии. Нейросетевые подходы здесь оказались особенно перспективны [9; 10].

Современные исследования, такие как работы Тана и др. [11–13], демонстрируют превосходство глубоких нейросетей в точности и скорости диагностики по сравнению с традиционными методами, особенно в условиях зашумленных экспериментальных данных.

Однако внедрение ИИ в учебный процесс сталкивается с методическими трудностями: студенты часто воспринимают нейросети как «черный ящик», не видя связи с физикой. Поэтому важно выстраивать обучение так, чтобы искусственный интеллект выступал не как замена физике, а как ее дополнительный инструмент.

Настоящая статья ставит целью систематическое изложение методологии применения нейросетевых подходов, в частности многослойного перцептрона, для решения ключевых задач тепло-массообмена; методическую последовательность, позволяющую студентам освоить базовые принципы применения ИИ в задачах теплофизики через конкретный, наглядный и физически содержательный пример — диагностику параметров горения по спектру излучения, что представляет значительный интерес для создания систем мониторинга и управления энергетическими установками.

Основная часть

Методический подход: от физики к расчетным и экспериментальным данным и далее к нейросетевой модели

Турбулентные течения

Турбулентность характеризуется хаотичным, нестационарным движением жидкости или газа. Прямое численное моделирование (DNS) всех масштабов турбулентности требует колоссальных вычислительных ресурсов. Более распространенные подходы, такие как LES (Large Eddy Simulation) и RANS (Reynolds-Averaged Navier-Stokes), используют модели замыкания, которые часто имеют эмпирическую природу и не всегда универсальны.

Применение нейросетей — это:

- ♦ моделирование замыкающих членов (Closure Models): ИНС можно обучить на данных DNS или высококаче-

ственных LES для предсказания тензора турбулентных напряжений или других неизвестных членов в уравнениях RANS/LES;

- ♦ снижение размерности (Reduced-Order Modeling, ROM): Нейросети, в частности автоэнкодеры, могут выявлять низкоразмерные многообразия, на которых эволюционируют сложные турбулентные поля. Это позволяет значительно сократить число степеней свободы и строить сверхбыстрые прогнозные модели для управления потоком.

Излучение газовых потоков

Теплообмен излучением в газах (CO_2 , H_2O , CO) играет ключевую роль в камерах сгорания, печах и атмосферных явлениях. Точный расчет требует интегрирования уравнения переноса излучения с учетом сложной зависимости коэффициента поглощения газа от длины волны (линейчатый спектр), что приводит к огромным вычислительным затратам (методы Line-by-Line).

Применение нейросетей — предсказание интегральных радиационных свойств. Нейросеть может быть обучена предсказывать интегральные величины, такие как плотность потока излучения или его дивергенцию (источник тепла в уравнении энергии), напрямую по параметрам состояния газа (температура, давление, концентрации компонентов, геометрический путь). Это позволяет в 10^3 – 10^6 раз ускорить расчет радиационного теплообмена в CFD-симуляциях по сравнению с традиционными методами.

Химически реагирующие течения

Моделирование горения с детальными химическими механизмами, включающими десятки видов и сотни реакций, является вычислительно неподъемной задачей для многих практических приложений.

Применение нейросетей — замещение детальных химических механизмов. ИНС обучается на данных, полученных с помощью детального химического расчета, и учится предсказывать скорости производства химических компонентов и тепловыделение по текущим параметрам (температура, давление, концентрации). Такая surrogate-модель может быть напрямую встроена в CFD-решатель, радикально ускоряя расчет.

Диагностика параметров горения в газовом потоке по спектру излучения с использованием многослойного перцептрона

Одной из наиболее ярких задач, где нейросети демонстрируют превосходство над традиционными методами, является оперативная диагностика параметров горения.

Постановка задачи

При горении углеводородных топлив в потоке образуются горячие газы, содержащие CO_2 , H_2O , CO, сажу и другие частицы. Этот поток испускает электромагнитное излучение в инфракрасном и видимом диапазонах. Спектр этого излучения (зависимость интенсивности от длины волны) несет в себе информацию о физико-химическом состоянии потока: температуре газа и концентрациях излучающих компонентов.

Задача инверсная: по измеренному экспериментально спектру необходимо определить параметры состояния — температуру, концентрации излучающих компонентов.

Традиционные методы решения (подбор наилучшего совпадения с модельным спектром) требуют многократных обращений к сложной физической модели и занимают значительное время.

Многослойный перцептрон как решатель задачи

Многослойный перцептрон (Multilayer Perceptron, MLP) — это класс искусственных нейронных сетей прямого распространения (feedforward), идеально подходящий для решения задач регрессии, к которым относится и наша задача диагностики.

Подробный принцип работы MLP

Архитектура

- ♦ входной слой (Input Layer) — каждому нейрону этого слоя подается одно значение входного вектора. В нашем случае входной вектор — это оцифрованный спектр излучения. Если спектр представлен 1000 точками, то входной слой будет состоять из 1000 нейронов. Каждый нейрон просто передает полученное значение дальше без изменений;
- ♦ скрытые слои (Hidden Layers) — это «мозг» сети. Обычно их несколько (отсюда и название «многослойный»). Каждый скрытый слой состоит из множества нейронов;
- ♦ выходной слой (Output Layer) — количество нейронов в этом слое равно количеству прогнозируемых параметров. В нашей задаче это будут 1 нейрон для температуры T и по одному нейрону для каждой определяемой концентрации C_i .

Структура одного нейрона

Каждый нейрон (кроме входных) в скрытых и выходном слоях работает по следующему принципу:

Суммирование — нейрон вычисляет взвешенную сумму своих входов x_i (которые являются выходами нейронов предыдущего слоя) и добавляет смещение (bias) b .

$$z = \sum_i w_i x_i + b$$

где w_i — весовые коэффициенты.

Активационная функция (Activation Function) — к полученной сумме z применяется нелинейная функция активации $f(z)$. Это ключевой элемент, который позволяет сети аппроксимировать сложные нелинейные зависимости.

$$y_{out} = f(z)$$

Для скрытых слоев часто используют функции ReLU (Rectified Linear Unit), гиперболический тангенс или сигмоиду. Для выходного слоя в задачах регрессии обычно используется линейная функция.

Прямое распространение (Forward Pass) — данные (спектр) подаются на входной слой, затем они последовательно преобразуются, проходя через скрытые слои. На каждом слое выполняются операции взвешенного суммирования и нелинейного преобразования. Результатом является вектор на выходном слое — это и есть прогноз сети для температуры и концентраций.

Обучение сети (Training) — изначально веса w_i и смещения b инициализируются случайными значениями. Сеть «не умеет» решать задачу. Обучение — это процесс настройки этих параметров.

Тренировочный набор данных — для обучения необходим большой набор данных, для которых известны и входы, и правильные ответы (ground truth). В нашем случае это множество пар: {Спектр $I(\lambda)$ → Соответствующие параметры T, C_i }. Эти данные могут быть получены путем детальных физических расчетов (например, с помощью программ типа HITRAN) или в калибровочных экспериментах.

Функция потерь (Loss Function) — это мера ошибки сети. Для регрессии обычно используется среднеквадратичная ошибка (MSE) между прогнозами сети и правильными ответами из тренировочного набора.

Алгоритм обратного распространения ошибки (Backpropagation) — это ядро обучения. Алгоритм вычисляет градиент функции потерь по всем весам сети. Он показывает, в каком направлении и насколько нужно изменить каждый вес, чтобы уменьшить ошибку.

Оптимизатор (Optimizer) — например, Stochastic Gradient Descent (SGD) или Adam. Используя вычисленные градиенты, оптимизатор обновляет веса и смещения сети, постепенно минимизируя функцию потерь.

Преимущество подхода — после завершения обучения прогноз MLP занимает доли миллисекунд. Это позволяет проводить диагностику в реальном времени, что критически важно для систем активного контроля и управления процессом горения.

Некоторые промежуточные выводы

Программа, демонстрирующая полный цикл решения инверсной задачи диагностики горения, наглядно показы-

вает, как нейросеть обучается решать сложную инверсную задачу, восстанавливая физические параметры системы по ее спектральным характеристикам.

Программный код представлен в объектно-ориентированном стиле, легко читается и снабжен комментариями. Он позволяет студентам:

- ◆ экспериментировать с архитектурой сети (число слоев, нейронов);
- ◆ исследовать влияние уровня шума на точность диагностики;
- ◆ сравнивать нейросетевой подход с классическими итерационными методами.

Важно, что даже на обычном ноутбуке обучение модели диагностики горения занимает менее минуты, а предсказание физических параметров системы сокращается до миллисекунд, что наглядно демонстрирует преимущество ИИ в решении задач реального времени.

Ключевые особенности программы

Генерация синтетических данных — создание реалистичных спектров излучения с учетом физических закономерностей.

- ◆ Архитектура MLP — использование многослойного перцептрона для решения задачи регрессии.
- ◆ Предобработка данных — масштабирование признаков и целевых переменных.
- ◆ Оценка качества — расчет метрик R^2 , MSE, RMSE.
- ◆ Визуализация — графики спектров, сравнение предсказаний, анализ ошибок.
- ◆ Демонстрационный пример — работа модели на конкретном тестовом случае.

Физическая интерпретация

- ◆ Спектральные линии имитируют характерные полосы поглощения/излучения CO_2 , H_2O , CO .
- ◆ Ширина линий зависит от температуры (уширение при повышении T).
- ◆ Интенсивность зависит от концентрации и температуры.
- ◆ Фоновая составляющая моделирует излучение по закону Планка.

Методика обучения

Предлагаемая методика обучения студентов строится на трех уровнях.

1. **Физическая постановка задачи** — студенты изучают уравнение переноса излучения, спектральные свойства газов (CO_2 , H_2O , CO), закон Планка и принципы спектральной диагностики.

2. **Генерация обучающих данных** — с помощью упрощенной физической модели создаются синтетические спектры, соответствующие заданным параметрам (температура, концентрация). Это позволяет избежать зависимости от дорогостоящих экспериментов или библиотек данных.

3. Построение и обучение нейросети – студенты программно реализуют многослойный перцептрон (MLP), обучают его на сгенерированных данных и оценивают качество восстановления параметров.

При таком подходе каждый этап связан с физикой, а нейросеть выступает как рабочий инструмент, а не магическая коробка.

Практическая реализация

Разработана лабораторная работа на выполнение демонстрационного примера «Работа модели на конкретном тестовом случае», включающая:

- ♦ генерацию синтетических данных – создание реалистичных спектров излучения с учетом физических закономерностей;
- ♦ использование многослойного перцептрона для решения задачи регрессии;
- ♦ выполнение предобработки данных – масштабирование признаков и целевых переменных;
- ♦ выполнение оценки качества – расчет метрик R^2 , MSE, RMSE;
- ♦ визуализацию – графики спектров, сравнение предсказаний, анализ ошибок.




Рис. 1. Синтетический спектр излучения, измеренные и предсказанные параметры температуры и концентрации CO_2




Рис. 2. Измеренный спектр излучения потока и сравнение истинных и предсказанных параметров

Демонстрационный пример

Демонстрационный пример результатов работы тестовой модели по определению температуры и концентраций компонентов горения углеводородных топлив в потоке представлен в табл. 1.

Таблица 1

Тестовый пример работы модели

Параметры	Температура	Концентрация		
		CO_2	H_2O	CO
Истинные	1800 К	0,080	0,120	0,0205
Предсказанные	1725,6 К	0,076	0,116	0,0200
Абсолютные ошибки	74,4 К (4,1%)	0,0038 (4,7%)	0,0036 (3,0%)	0,0005 (2,4%)

Основные результаты работы модели представлены на рис. 1 и 2.

Образовательные результаты и перспективы

Апробация методики в группе магистрантов показала:

- ♦ рост мотивации за счет «цифровой» актуальности темы;
 - ♦ лучшее понимание обратных задач и их сложности;
 - ♦ формирование навыков работы с данными, построения моделей и критической оценки их точности.
- В перспективе возможна доработка курса за счет:
- ♦ применения сверточных нейросетей (CNN) для обработки спектров как одномерных сигналов;
 - ♦ внедрения подходов Physics-Informed Neural Networks (PINN), где физические законы встраиваются непосредственно в функцию потерь;
 - ♦ интеграции с реальными экспериментальными установками кафедры.

Заключение

Использование нейронных сетей открывает новые горизонты в моделировании и диагностике процессов. Они позволяют создавать высокоскоростные системы мониторинга процессов тепломассообмена, как в рассмотренном примере со спектральной диагностикой горения. Многослойный перцептрон, являясь фундаментальной архитектурой, демонстрирует высокую эффективность в решении задач регрессии и аппроксимации данных. Дальнейшее развитие связано с использованием более сложных архитектур (сверточных, рекуррентных сетей), а также с интеграцией физических знаний непосредственно в структуру и функцию

потерь нейросетей (Physics-Informed Neural Networks), что сулит новые прорывы в этой междисциплинарной области.

Интеграция искусственного интеллекта в инженерное образование – не дань моде, а необходимость. Однако ключ к успеху в методически выверенном подходе, где ИИ служит продолжением физического мышления, а не его заменой. Предложенная методика позволяет студентам не просто «запустить нейросеть», а понять, как и зачем ее применять в реальных инженерных задачах. Такой подход способствует формированию нового типа инженера-исследователя с цифровыми компетенциями, способного эффективно работать на стыке физики, вычислений и больших данных.

Литература/References

1. Pope, S.B. Turbulent Flows. Cambridge University Press, 2000.
2. Wilcox, D.C. Turbulence Modeling for CFD. DCW Industries, 2006.
3. Lagaris, I.E., Likas, A., Fotiadis, D.I. Artificial neural networks for solving ordinary and partial differential equations. *IEEE Transactions on Neural Networks*. 1998. Vol. 9 (5). Pp. 987–1000.
4. Duraisamy, K., Zhang, Z.J., Singh, A.P. New approaches in turbulence and transition modeling using data-driven techniques. *AIAA Paper*. 2015. Vol. 1284.
5. Ling, J., Kurawski, A., Templeton, J. Reynolds averaged turbulence modelling using deep neural networks with embedded invariance. *Journal of Fluid Mechanics*. 2016. Vol. 807. Pp. 155–166.
6. Петрунин А.П., Смирнов Н.Н. Применение нейросетевых моделей для замыкания уравнений переноса в турбулентных течениях // Математическое моделирование. 2020. Т. 32 (5). С. 45–60.
Petrinin, A.P., & Smirnov, N.N. The application of neural network models for solving transport equations in turbulent flows. *Mathematical Modelling*. 2020. Vol. 32 (5). Pp. 45–60.
7. François, G., et al. Neural network approach for solving radiative transfer problems. *Numerical Heat Transfer, Part B: Fundamentals*. 2008. Vol. 53 (3). Pp. 213–229.
8. Modest, M.F., et al. Machine learning in radiative heat transfer. *Annual Review of Heat Transfer*. 2020. Vol. 23. Pp. 345–387.
9. Blaythoff, A., et al. Deep neural network based chemical mechanism reduction. *Proceedings of the Combustion Institute*. 2019. Vol. 37 (1). Pp. 651–659.
10. Аристархов В.М. и др. Нейросетевые методы в кинетическом моделировании сложных химических реакций // Химическая физика. 2021. Т. 40 (2). С. 25–35.
Aristarkhov, V.M., et al. Neural network methods in the kinetic modelling of complex chemical reactions. *Chemical Physics*. 2021. Vol. 40 (2). Pp. 25–35.
11. Rothman, L.S., et al. The HITRAN molecular spectroscopic database. *Journal of Quantitative Spectroscopy and Radiative Transfer*. 2013. Vol. 130. Pp. 4–50.
12. Zwiethofer, M., et al. Temperature and concentration measurements in combustion gases using FTIR spectroscopy and artificial neural networks. *Applied Optics*. 2005. Vol. 44 (5). Pp. 678–686.
13. Tan, S., et al. Deep neural networks for multi-parameter combustion diagnostics. *Combustion and Flame*. 2022. Vol. 235. Pp. 111–125.