

УДК 336

**Машинное обучение для физических измерений: применение  
нейросетей для предсказания параметров системы на основе  
экспериментальных данных**

**Ушакова Юлия Викторовна**

**Круткова Анастасия Юрьевна**

студенты

**Научный руководитель: Павлова Светлана Валерьевна,**

преподаватель

Улан-Удэнский колледж железнодорожного транспорта -  
филиал Федерального государственного бюджетного  
образовательного учреждения высшего образования "Иркутский  
государственный университет путей сообщения", город Улан-Удэ

**Аннотация.** В настоящей работе проводится анализ  
возможностей методов машинного обучения, с акцентом на  
нейросетевые технологии, применительно к задачам анализа и  
прогнозирования параметров физических систем на основе  
экспериментальных данных. Рассматривается полный цикл  
разработки модели: от сбора и подготовки данных до выбора  
архитектуры сети, её обучения, валидации и интерпретации  
полученных результатов. Эффективность данного подхода  
иллюстрируется примерами из различных областей физики, включая  
ядерную физику, астрофизику, физику конденсированного состояния  
и гидродинамику. В заключительной части статьи даётся  
критическая оценка сильных и слабых сторон нейросетевых  
методов, а также намечаются перспективные направления развития,  
такие как интеграция с физическими симуляциями и автоматизация

*экспериментальных исследований.*

**Ключевые слова:** *машинное обучение, нейронные сети, физические измерения, прогнозирование параметров, экспериментальные данные, регрессия, классификация, физика, анализ данных, глубокое обучение.*

В современной науке и технике физические измерения играют ключевую роль в понимании и моделировании сложных систем. Однако традиционные методы анализа экспериментальных данных зачастую сталкиваются с ограничениями: высокой размерностью, шумами, нелинейностью и отсутствием точных аналитических моделей. В последние годы **машинное обучение**, и в особенности нейросетевые подходы, стали мощным инструментом для извлечения информации из экспериментальных данных, предсказания параметров физических систем и даже открытия новых закономерностей [1, с. 15–20].

В данной статье рассматривается применение нейросетей для анализа и предсказания параметров физических систем на основе экспериментальных данных. Описываются основные методы, этапы построения моделей, примеры успешного внедрения в различных областях физики, а также обсуждаются перспективы и ограничения данного подхода.

## **1. Особенности физических измерений и задачи машинного обучения**

Физические измерения часто характеризуются следующими особенностями:

- Высокая размерность данных (сотни и тысячи параметров).
- Наличие шумов и неопределённостей.

- Сложные, часто нелинейные зависимости между переменными.
- Ограниченность или отсутствие априорной теоретической модели [1, с. 45].

Типичные задачи, решаемые с помощью машинного обучения в физике:

- Классификация состояний системы (например, фазовые переходы).
- Регрессия: предсказание численных значений параметров (масса, температура, вязкость и др.).
- Восстановление скрытых переменных по косвенным данным.
- Оптимизация экспериментальных условий [2].

## **2. Основы нейросетевых методов**

Нейронные сети — это класс моделей машинного обучения, вдохновлённых структурой биологических нейронных сетей.

Основные типы, применяемые в физике:

### **2.1. Полносвязные нейронные сети (*MLP*)**

Используются для задач регрессии и классификации, когда входные данные можно представить в виде вектора. Применяются для предсказания параметров по набору измеренных величин [1, с. 89].

### **2.2. Сверточные нейронные сети (*CNN*)**

Эффективны для анализа пространственных или временных данных, например, изображений с детекторов, спектров, временных рядов [3].

Применяются для анализа последовательностей: временных рядов, сигналов, траекторий частиц [1, с. 102].

## **2.4. Графовые нейронные сети (GNN)**

Используются для моделирования сложных взаимодействий в системах частиц, молекулах, кристаллических решётках [8].

# **3. Этапы построения нейросетевой модели для физических измерений**

## **3.1. Сбор и предобработка данных**

Экспериментальные данные часто требуют очистки от шумов, нормализации, устранения выбросов. Важно обеспечить репрезентативность выборки [1, с. 67].

## **3.2. Формулировка задачи**

Определяется, что именно требуется предсказать: конкретный параметр, класс состояния, распределение вероятностей и т.д.

## **3.3. Выбор архитектуры сети**

В зависимости от типа данных и задачи выбирается подходящая архитектура (например, *CNN* для изображений, *RNN* для временных рядов) [1].

## **3.4. Обучение и валидация**

Модель обучается на обучающей выборке, проверяется на валидационной. Используются метрики качества (среднеквадратичная ошибка, коэффициент детерминации и др.) [1, с. 120].

## **3.5. Интерпретация результатов**

Важный этап — анализ предсказаний модели, выявление значимых признаков, сравнение с теоретическими ожиданиями.

## **4. Примеры применения в физике**

### **4.1. Ядерная физика**

Нейросети используются для идентификации частиц по трекам в детекторах, предсказания энергетических спектров, оптимизации условий экспериментов [4].

### **4.2. Физика конденсированного состояния**

*MLP* и *CNN* применяются для классификации фазовых переходов, предсказания свойств материалов по структуре кристаллов [5].

### **4.3. Астрофизика**

Анализ временных рядов светимости звёзд, классификация галактик по изображениям, предсказание параметров экзопланет [7].

### **4.4. Гидродинамика и механика**

Предсказание турбулентных потоков, вязкости, напряжений по экспериментальным данным с помощью *RNN* и *GNN* [6].

## **5. Преимущества и ограничения нейросетевых методов**

### **Преимущества**

- Способность работать с большими и сложными данными.
- Автоматическое извлечение признаков.
- Высокая точность при достаточном объёме данных [1].

### **Ограничения**

- Требуется большой объём размеченных данных.
- Сложность интерпретации («чёрный ящик»).
- Риск переобучения.

- Высокие вычислительные затраты [1].

## **6. Перспективы развития**

Развитие гибридных моделей (физико-информированные нейросети), интеграция с симуляциями, автоматизация экспериментов — основные направления будущего [6].

## **Заключение**

Машинное обучение и нейросети становятся неотъемлемой частью современной экспериментальной физики. Их использование позволяет не только повысить точность измерений и прогнозов, но и открывает новые горизонты для научных открытий. Однако ключевым условием успеха остаётся тщательная валидация моделей и их интерпретация в строгом соответствии с фундаментальными законами физики.

## **Список литературы**

1. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / пер. с англ. — М.: ДМК Пресс, 2017. — 652 с.
2. LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. — 2015. — Vol. 521, № 7553. — P. 436–444.
3. Schmidhuber J. Deep learning in neural networks: An overview // Neural Networks. — 2015. — Vol. 61. — P. 85–117.
4. Baldi P., Sadowski P., Whiteson D. Searching for exotic particles in High-Energy Physics with Deep Learning // Nature Communications. — 2014. — Vol. 5. — Art№ 4308.
5. Carleo G., Troyer M. Solving the quantum many-body problem with artificial neural networks // Science. — 2017. — Vol. 355, № 6325. — P. 602–606.

6. Raissi M., Perdikaris P., Karniadakis G.E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // Journal of Computational Physics. —2019. —Vol. 378. —P. 686–707.
7. Littenberg T.B., Kahn S., Cornelis B., et al. Machine learning for gravitational-wave astronomy // Physical Review D. — 2019. — Vol. 100, № 4. — Art.№043013.
8. Gilmer J., Schoenholz S.S., Riley P.F., et al. Neural message passing for quantum chemistry // arXiv:1704.01212 [ physics.chem-ph]. — 2017.
9. Brock A., Donahue J., Simonyan K. Large scale GAN training for high fidelity natural image synthesis // arXiv:1809.11096 [cs.CV]. —2018.
10. Kaggle Competitions on Physics and Astronomy Data : [сайт]. — URL: <https://www.kaggle.com/datasets?tags=physics-astronomy> ( дата обращения: 20.05.2026).