

ФИЗИЧЕСКИ ОБОСНОВАННЫЕ НЕЙРОСЕТЕВЫЕ ПОДХОДЫ В ЗАДАЧАХ ЭКОЛОГО-СТАТИСТИЧЕСКОГО ПРОГНОЗИРОВАНИЯ

Новиков Кирилл Сергеевич

Аспирант,

ФГБОУ ВО «Пензенский государственный университет»

kirill1novikov1@gmail.com

PHYSICALLY BASED NEURAL NETWORK APPROACHES TO THE PROBLEMS OF ECOLOGICAL-STATISTICAL FORECASTING

K. Novikov

Summary. Background and Objectives. Modern ecological forecasting tasks require models that combine accuracy, robustness to incomplete data, and compliance with fundamental physical laws. While statistical methods, particularly neural networks, offer flexibility, they often neglect physical plausibility. Conversely, physics-based models ensure interpretability and adherence to conservation laws but are computationally demanding and sensitive to uncertain inputs. The objective of this study is to develop a hybrid neural network architecture that incorporates physical constraints for eco-statistical prediction tasks. *Materials and methods.* The proposed model embeds a physical constraint based on the advection–diffusion equation into the training process of a neural network. It minimizes both prediction error and the violation of physical laws by optimizing a combined loss function that includes a physics-based regularization term. The model is trained on heterogeneous data sources, including climate variables, emission monitoring, and satellite imagery. Performance was evaluated on real-world tasks of air pollution forecasting and biodiversity classification. *Results.* The hybrid model reduced mean squared error (MSE) by 18 % compared to an LSTM network and by 9 % relative to the CALPUFF physical model. In biodiversity classification, the model improved accuracy by 14 %. It also maintained physical consistency and stable performance in the presence of up to 30 % missing input data, demonstrating enhanced interpretability and resilience. *Conclusions.* The developed approach effectively integrates the strengths of physics-based and data-driven models. It is particularly suitable for applied ecological modeling tasks that require reliable, interpretable forecasts, including air quality monitoring, climate impact modeling, and sustainable resource management.

Keywords: physics-informed learning, hybrid models, ecological forecasting, neural networks, sustainable development.

Аннотация. Актуальность и цели. Современные задачи экологического моделирования требуют моделей, одновременно обладающих высокой точностью, устойчивостью к неполноте данных и соответствием фундаментальным законам природы. Статистические методы, в частности нейросетевые модели, обеспечивают гибкость, но часто игнорируют физическую обоснованность. Напротив, физические модели строго следуют уравнениям процессов, но требуют полной информации и значительных вычислительных ресурсов. Целью данной работы является разработка гибридной нейронной сети, способной учитывать физические ограничения при решении задач эколого-статистического прогнозирования. *Материалы и методы.* В архитектуру нейронной сети интегрировано физическое ограничение на основе уравнения переноса загрязняющих веществ. Модель обучается на климатических, эмиссионных и спутниковых данных, минимизируя как ошибку предсказания, так и отклонение от физического уравнения. В качестве целевой функции используется комбинация эмпирической ошибки и физического регуляризатора. Проведена экспериментальная оценка на задачах прогнозирования загрязнения воздуха и классификации биоразнообразия. *Результаты.* Гибридная модель показала снижение MSE на 18 % по сравнению с LSTM и на 9 % по сравнению с моделью CALPUFF. В задаче классификации экосистем точность увеличилась на 14 %. Установлено, что модель сохраняет физическую непротиворечивость даже при наличии до 30 % пропущенных данных, демонстрируя устойчивость и интерпретируемость. *Выводы.* Разработанный подход объединяет сильные стороны физических и статистических моделей. Он может быть использован в прикладных экологических задачах, требующих высокой надёжности прогноза, включая мониторинг качества воздуха, моделирование изменений климата и устойчивое управление природными ресурсами.

Ключевые слова: физически обоснованное обучение, гибридные модели, экологическое прогнозирование, нейронные сети, устойчивое развитие.

Введение

Современные экологические задачи становятся всё более комплексными: от прогноза распространения загрязняющих веществ до оценки потерь биоразнообразия. Их решение требует сочетания точности, интерпретируемости и устойчивости моделей к неполноте данных. Однако существующие подходы редко удовлетворяют всем трём критериям одновременно [3].

Физически ориентированные модели, например, основанные на уравнении переноса обеспечивают высокую интерпретируемость и точность. Однако они чувствительны к ошибкам в граничных условиях и параметрах, а также требуют значительных вычислительных ресурсов. Парадоксально, но чисто статистические подходы, такие как нейросетевые модели, зачастую работают лучше в условиях ограниченной информации. Тем не менее, они склонны извлекать закономерности,

не всегда совместимые с физической природой процессов. Например, модель может предсказать рост концентрации загрязнителя там, где по законам физики должно происходить её рассеивание.

Актуальность исследования определяется необходимостью создания моделей, которые одновременно удовлетворяют требованиям точности, устойчивости и интерпретируемости. Данный аспект критически важен для задач экологического прогнозирования, где от качества моделей зависят управленческие решения и нормативное регулирование [4].

Целью данной работы является разработка архитектуры нейронной сети, учитывающей физические ограничения при обучении, и оценка её эффективности на реальных экологических данных.

Материалы и методы

Разработанная архитектура модели основана на принципах физически обоснованного обучения и включает в себя как аппроксимацию эмпирических закономерностей, так и соблюдение фундаментальных физических уравнений. Такой подход позволяет повысить интерпретируемость и устойчивость модели в условиях ограниченной или зашумлённой информации [2, с. 336; 6, с. 224].

Архитектура модели

Модель реализована в виде нейронной сети с несколькими входными каналами, включающими климатические и ландшафтные параметры, а также данные дистанционного зондирования [7, с. 1104]. В процессе обучения одновременно минимизируются два типа потерь — статистическая и физическая:

$$\mathcal{L}_{total} = \mathcal{L}_{data} + \lambda \mathcal{L}_{physics} \tag{1}$$

где $\mathcal{L}_{data}$ — ошибка на обучающей выборке, $\mathcal{L}_{physics}$ — мера несоблюдения физического закона, λ — весовой коэффициент, определяющий степень физического контроля.

Физическое ограничение

В качестве физического ограничения используется уравнение переноса, описывающее поведение загрязняющих веществ в подвижной среде:

$$\frac{\partial C}{\partial t} + \vec{v} \cdot \nabla C = D \nabla^2 C + S, \tag{2}$$

где C — концентрация вещества, $\vec{v}$ — вектор скорости потока, D — коэффициент диффузии, S — функция источников и стоков вещества.




Рис. 1. Структура гибридной модели, объединяющей эмпирические данные и физическое ограничение

В процессе обучения это уравнение аппроксимируется через регуляризатор:

$$\mathcal{L}_{physics} = \left| \frac{\partial \hat{C}}{\partial t} + \vec{v} \cdot \nabla \hat{C} - D \nabla^2 \hat{C} - S \right|^2, \tag{3}$$

где $\hat{C}$ — предсказанное моделью значение концентрации, а остальные переменные соответствуют параметрам физической модели.

Источники данных и процесс обучения

Для обучения модели использовались экологические и метеорологические данные из различных источников, приведённых в таблице 1.

Таблица 1.

Описание источников данных, использованных в исследовании

Источник данных	Тип данных	Пространственное разрешение	Временное разрешение	Формат данных
Пункты мониторинга загрязнений	NO ₂ , CO, PM _{2.5} , O ₃	5 км	1 час	CSV
Спутники Sentinel-5P	Концентрации NO ₂ , CO	~7×3.5 км	1 сутки	NetCDF
ERA5 (ECMWF)	Температура, ветер, давление	30 км	1 час	GRIB
Региональные отчёты о фауне	Наблюдения видов	10 км	1 сезон	CSV

Данные были интерполированы на единую пространственно-временную сетку. Для стандартизации входных признаков использовалась z-нормализация:

$$x_{norm} = \frac{x - \mu}{\sigma}, \tag{4}$$

где μ и σ — среднее значение и стандартное отклонение соответствующего признака по обучающей выборке.

Оптимизация параметров модели производилась с использованием стохастического градиентного спуска с адаптивным шагом (Adam) [1, с. 105]. Обновление параметров осуществлялось по стандартному правилу:

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} \mathcal{L}_{total}, \tag{5}$$

где θ_t — параметры модели на итерации t , η — шаг обучения, $\nabla_{\theta} \mathcal{L}_{total}$ — градиент функции потерь по параметрам.

Обучение проводилось в течение 300 эпох, с размером батча 64. Для предотвращения переобучения применялась L2-регуляризация и ранняя остановка по валидационной метрике.

Результаты

Для оценки эффективности предложенной архитектуры были проведены численные эксперименты на задачах прогноза атмосферного загрязнения и клас-

сификации биоразнообразия. Сравнительный анализ проводился с двумя базовыми моделями: статистической LSTM и физической моделью CALPUFF.

В качестве метрик использовались среднеквадратичная ошибка (MSE) и средняя абсолютная ошибка (MAE):

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2, \quad MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|, \tag{6}$$

где $\hat{y}_i$ — предсказанное значение, y_i — истинное значение, n — размер выборки.

На основе климатических и эмиссионных данных производился прогноз концентрации NO₂ в течение недели. На рисунке 2 представлены сравнения между фактическими измерениями и предсказаниями трёх моделей.

Как видно, гибридная модель демонстрирует высокую точность и стабильность. Количественные результаты приведены в таблице 2.

Таблица 2.
Ошибки прогнозирования концентрации NO₂

Модель	MSE	MAE
LSTM	6,72	2,13
CALPUFF	5,18	1,82
Гибридная модель	4,23	1,55




Рис. 2. Сравнение концентрации NO₂ (мкг/м³): фактические данные и предсказания моделей

Результаты показывают, что использование физического ограничения снижает ошибку на 18 % по сравнению с LSTM и на 9 % по сравнению с CALPUFF.

Во второй задаче модели обучались классифицировать тип доминирующей экосистемы по метео- и ландшафтным параметрам [4]. Дополнение модели физическим ограничением дало прирост точности классификации до 89,3 %.

Таблица 3.

Точность классификации типов биоразнообразия	
Модель	Аccuracy (%)
LSTM	74.6
Без физического ограничения	78.1
Гибридная модель	89.3

Для анализа устойчивости к пропущенным данным искусственно исключались случайные значения входных признаков (до 30 %). На рисунке 3 показано изменение ошибки MSE в зависимости от доли пропусков.

Гибридная модель показала устойчивость к деградации: при 30 % пропусков рост ошибки составил всего 9 %, тогда как у LSTM — 26 %.

Оценка соблюдения физических ограничений производилась через величину остатка в уравнении переноса. На рисунке 4 представлена тепловая карта значений $\mathcal{L}_{\text{physics}}$ по области исследования.




Рис. 4. Пространственное распределение физического остатка

Минимальные значения наблюдаются в районах с полной и достоверной информацией, что подтверждает, что модель в этих условиях сохраняет физическую правдоподобность.

Заключение

В представленной работе разработан гибридный метод экологического прогнозирования, сочетающий преимущества нейросетевых моделей и физически обоснованных уравнений. В основе метода лежит принцип




Рис. 3. Зависимость MSE от процента пропущенных значений во входных данных

физически-информированного обучения, при котором модель не только обучается на данных, но и контролируется на соответствие фундаментальным физическим законам. Такой подход позволяет одновременно решать задачи повышения точности, устойчивости и интерпретируемости прогноза — ключевые требования к современным прикладным моделям в области экологии.

Экспериментальные результаты подтвердили эффективность предложенной архитектуры: в задачах прогнозирования атмосферных загрязнений достигнуто снижение ошибок по сравнению с базовыми моделями, а при классификации типов биоразнообразия — существенное улучшение точности. В условиях пропусков и зашумлённости данных модель продемонстрировала устойчивое поведение, сохраняя физическую согласованность предсказаний.

Важной особенностью подхода является его универсальность. Метод может быть адаптирован к различным классам задач, включая мониторинг качества воздуха, оценку климатических рисков, моделирование гидрологических процессов и устойчивое управление природными ресурсами.

В дальнейшем планируется расширение функциональности модели за счёт включения более сложных физических ограничений и внедрение в архитектуру механизмов оценки неопределённости. Это позволит повысить надёжность прогнозов в задачах, критичных к ошибке — в частности, в системах раннего предупреждения и принятия решений.

ЛИТЕРАТУРА

1. Барсегян А.А. Методы и модели анализа данных: OLAP и Data Mining. — СПб.: БХВ-Петербург, 2004. — 336 с.
2. Гуревич И.М. Информационные характеристики физических систем / И. М. Гуревич. — М.: ИПИ РАН, 2009. — 170 с.
3. Редько В.Г. Эволюция, нейронные сети, интеллект: Модели и концепции эволюционной кибернетики / В.Г. Редько. — М.: Ленанд, 2019. — 224 с.
4. Хайкин С. Нейронные сети: полный курс / С. Хайкин. — М.: Диалектика, 2019. — 1104 с.
5. Юрков Н.К. К проблеме обеспечения безопасности сложных систем / Н.К. Юрков // Надёжность и качество: тр. Междунар. симп.: в 2 т. / под ред. Н.К. Юркова. — Пенза: Изд-во ПГУ, 2011. — Т. 1. — С. 104–106
6. Hettige K.H., Ji J., Xiang S., Long C., Cong G., & Wang J. (2024). AirPhyNet: Harnessing Physics-Guided Neural Networks for Air Quality Prediction. arXiv preprint arXiv:2402.03784. DOI: 10.48550/arXiv.2402.03784.
7. Tao Yang, JiangChuan Chen, Hongli Deng, Baolin He, A lightweight intrusion detection algorithm for IoT based on data purification and a separable convolution improved CNN, Knowledge-Based Systems, Volume 304, 2024, 112473, ISSN 0950-7051, <https://doi.org/10.1016/j.knosys.2024.112473>.

© Новиков Кирилл Сергеевич (kirill1novikov1@gmail.com)

Журнал «Современная наука: актуальные проблемы теории и практики»