

АРХИТЕКТУРЫ НЕЙРО-НЕЧЁТКИХ СЕТЕЙ ДЛЯ АНАЛИЗА И УПРАВЛЕНИЯ ПРОСТРАНСТВЕННО-РАСПРЕДЕЛЁННЫМИ ЭКОЛОГИЧЕСКИМИ ПРОЦЕССАМИ

NEURO-FUZZY NETWORK ARCHITECTURES FOR ANALYSIS AND CONTROL OF SPATIALLY DISTRIBUTED ENVIRONMENTAL PROCESSES

K. Novikov
N. Yurkov
N. Koshelev

Summary. Background and Objectives. Environmental systems often exhibit complex spatial structures, high variability, and incomplete observations. These features pose significant challenges for predictive and control models. Traditional neural networks show strong data approximation capabilities but lack robustness and interpretability. In this work, we propose a neuro-fuzzy architecture that combines fuzzy logic with neural representations to analyze and manage distributed ecological processes. *Materials and methods.* The model integrates a fuzzy inference system with learnable neural components and is trained on multichannel monitoring data, including atmospheric, soil, and satellite observations. Control signals are formed using both data-driven inference and rule-based reasoning. *Results.* The architecture was tested on tasks of pollution forecasting and ecological load regulation. The model demonstrated improved robustness to missing data and enhanced interpretability of predictions. *Conclusions.* The proposed hybrid system successfully combines expert knowledge with adaptive learning, making it suitable for real-world ecological decision support under uncertainty.

Keywords: neuro-fuzzy systems, spatially distributed processes, environmental modeling, sustainable control, intelligent systems.

Новиков Кирилл Сергеевич

Аспирант,

ФГБОУ ВО «Пензенский государственный университет»

kirill1novikov1@gmail.com

Юрков Николай Кондратьевич

Доктор технических наук,

ФГБОУ ВО «Пензенский государственный университет»

yurkov_NK@mail.ru

Кошелев Никита Дмитриевич

Аспирант,

ФГБОУ ВО «Пензенский государственный университет»

koshlensky@gmail.com

Аннотация. Актуальность и цели. Экологические системы часто характеризуются сложной пространственной структурой, высокой изменчивостью и неполнотой наблюдений. Это ставит особые требования к моделям, предназначенным для анализа и управления такими процессами. Классические нейросетевые подходы демонстрируют хорошую аппроксимацию данных, но недостаточно устойчивы к неопределённости и плохо интерпретируемы. В настоящей работе рассматривается архитектура нейро-нечёткой сети, объединяющая преимущества нечёткой логики и способности нейронных моделей выявлять скрытые зависимости в пространственно-распределённых экологических данных. *Методы.* Предложен гибридный подход, включающий нейро-нечёткий механизм принятия решений, обучаемый на многоканальных данных мониторинга: атмосферных, почвенных и спутниковых. Управляющие воздействия формируются с учётом как нечётких правил, отражающих экспертные знания, так и данных, полученных из наблюдений. *Результаты.* Архитектура протестирована на задачах прогнозирования распространения загрязнений и управления нагрузкой на уязвимые участки ландшафта. Показано улучшение устойчивости модели к пропущенным данным и повышение интерпретируемости прогнозов. *Вывод.* Предложенный метод позволяет объединить экспертную логическую структуру с обучаемыми компонентами, что особенно важно для систем поддержки принятия решений в условиях экологической неопределённости.

Ключевые слова: нейро-нечёткие системы, пространственно-распределённые процессы, экологическое моделирование, устойчивое управление, интеллектуальные системы.

Введение

Вопросы устойчивого управления экологическими системами всё чаще встают не как абстрактные научные задачи, а как реальные вызовы: от прогнозов загрязнения до локальной стабилизации природных комплексов. В основе таких процессов — пространственно-распределённая динамика, подверженная мно-

жеству воздействий и влияний, зачастую слабо поддающихся точному измерению. [1, с. 256; 2, с. 47; 3, с. 224]

Актуальность исследования связана с необходимостью инструментов, способных адаптивно учитывать как данные наблюдений, так и не формализуемую экспертную оценку. Особенно важно это в условиях неполных или искажённых входных данных, характерных для

многих экологических систем, включая лесные массивы, прибрежные зоны и урбанизированные территории. [4, с. 684; 5, с. 592]

Существующие нейросетевые подходы обеспечивают высокую точность на тестовых выборках, но их интерпретируемость и устойчивость к шуму оставляют желать лучшего. [2, с. 53] Нечёткие системы, напротив, отражают структуру экспертных рассуждений, но страдают от ограниченной обучаемости. Потребность в интеграции этих подходов — не просто модный тренд, а прямое следствие сложности реальных экологических задач.

Целью исследования является разработка архитектуры нейро-нечёткой сети, способной обобщать пространственные зависимости, сохранять устойчивость к неполноте данных и обеспечивать интерпретируемое управление динамикой экологических процессов.

Для описания пространственной диффузии загрязняющих агентов в рамках модели была использована аппроксимация на основе гибридного оператора сглаживания:

$$u(x, y, t) = \int_{\Omega} K_{\sigma}(x - \xi, y - \zeta) \cdot c(\xi, \zeta, t - \tau) d\xi d\zeta, \quad (1)$$

где $u(x, y, t)$ — оценка концентрации вещества в точке (x, y) в момент времени t ; $c(\xi, \zeta, t - \tau)$ — запаздывающая функция концентрации; K_{σ} — ядро Гаусса с параметром рассеивания σ ; Ω — область интегрирования по пространственным переменным.

Такой подход позволяет обойти необходимость явно задания коэффициентов диффузии, заменяя их на статистически устойчивое ядро, обучаемое в процессе оптимизации.

Кроме того, в нейро-нечёткую архитектуру встроен адаптивный модуль усиления влияния входных признаков:

$$\hat{x}_i = \frac{x_i}{1 + \lambda \cdot |x_i|}, \quad (2)$$

где $\hat{x}_i$ — нормализованный входной признак; x_i — исходное значение признака; λ — коэффициент адаптации, обучаемый совместно с остальными параметрами.

Материалы и методы

Работа опирается на идею объединения нейросетевой аппроксимации с нечёткой логикой принятия решений в рамках единой архитектуры. Пространственно-распределённые экологические процессы обладают как наблюдаемыми, так и скрытыми составляющими: влияние ландшафта, распределённые эмиссии, локальные

погодные аномалии. Для их моделирования использовалась архитектура нейро-нечёткой сети, реализующая двухуровневый механизм обработки: на первом уровне выявляются скрытые зависимости, на втором — формируются управляющие сигналы на основе гибких правил, имитирующих рассуждение эксперта.

Архитектура модели строится по принципу модульной гибридной. Сначала происходит пространственно-временное кодирование входных признаков через нейросетевую модуль свёрточного типа. [4, с. 684] Затем, на основе полученного латентного представления, нечёткая подсистема активирует правила в терм-пространстве.

Формально, активация термов в нечётком пространстве происходит по экспоненциальной модели:

$$\mu_j(x) = \exp\left(-\frac{(x - c_j)^2}{2\sigma_j^2}\right), \quad (3)$$

где $\mu_j(x)$ — степень принадлежности входного признака x к j -му терму; c_j — центр терма.

Оценка согласованности между входом и базой правил осуществляется через нормализованную сумму активаций:

$$\alpha_j = \frac{\mu_j(x)}{\sum_k \mu_k(x)}. \quad (4)$$

Каждое нечёткое правило обрабатывает вектор признаков и формирует элементарное решение, которое затем агрегируется. Агрегация производится через обучаемую линейную комбинацию с нелинейным затуханием:

$$y = \sum_{j=1}^M \alpha_j \cdot f_j(z), f_j(z) = \tanh(W_j z + b_j), \quad (5)$$

где z — скрытое представление входных признаков; f_j — выход нечёткого правила, y — итоговый отклик модели.

Для подавления переобучения и повышения устойчивости к шуму на этапе кодирования признаков использовалась стохастическая маскировка входа, описываемая уравнением:

$$x'_i = x_i \cdot I[r_i > p], r_i \sim \mathcal{U}(0, 1). \quad (6)$$

Для обучения и тестирования модели использовались пространственно-распределённые наблюдения, полученные из открытых источников мониторинга и спутниковых систем. Все данные были интерполированы на единую сетку, чтобы избежать искажения градиентов в пространстве. Подробная характеристика используемых источников приведена ниже:

Таблица 1.

Описание выходных данных

Источник	Тип информации	Пространственное разрешение	Временной шаг	Формат
Станции мониторинга	Концентрации NO_2 , SO_2 , $\text{PM}_{2.5}$	5 км	1 час	CSV
Спутники Sentinel-2	Поверхностное альbedo, вегетация	10 м	1 сутки	GeoTIFF
ERA5 (ECMWF)	Температура, давление, скорость ветра	30 км	1 час	GRIB
Цифровые модели рельефа	Высота над уровнем моря	90 м	—	GeoTIFF

Для сведения всех признаков к сопоставимому масштабу применялась адаптивная нормализация на основе среднего абсолютного отклонения:

$$x_i^* = \frac{x_i - \text{med}(x)}{\text{MAD}(x) + \mu}. \quad (7)$$

Оптимизация параметров модели проводилась методом градиентного спуска с импульсом, адаптированным к нечёткой логике. Весовые коэффициенты правил и нейросетевых блоков обновлялись по следующей формуле:

$$\theta_{t+1} = \theta_t - \eta \cdot \nabla L(\theta_t) + \mu \cdot \theta_t, \quad (8)$$

где θ_t — параметры на интеграции t ; η — скорость обучения; μ — коэффициент импульса, $\nabla L(\theta_t)$ — градиент функции потерь.

Функция потерь включала два компонента: регрессионную ошибку и регуляризатор, обеспечивающий плавность управляющего воздействия:

$$\mathcal{L} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 + \lambda \sum_{t=1}^{T-1} |\hat{y}_{t+1} - \hat{y}_t|^2, \quad (9)$$

где y_i — истинное значение, $\hat{y}_i$ — предсказание модели, N — объём обучающей выборки, T — временной горизонт, λ — коэффициент регуляризации.


Результаты

Оценка эффективности предложенной нейро-нечёткой архитектуры проводилась в контексте двух задач: прогноза пространственного распределения загрязняющих веществ и формирования управляющих воздействий на динамику нагрузки в уязвимых участках природных систем. В каждом из сценариев тестировалась способность модели к устойчивому обобщению при неполных данных, интерпретируемости её решений и сохранению физической непротиворечивости вывода.

В качестве основной метрики ошибки прогноза использовалась средневзвешенная пространственно-временная квадратичная ошибка, учитывающая плотность наблюдений:

$$\text{W-MSE} = \frac{1}{\sum_{i,t} w_{i,t}} \sum_{i,t} w_{i,t} \cdot (y_{i,t} - \hat{y}_{i,t})^2. \quad (10)$$

Была также рассчитана метрика согласованности управляющих воздействий во времени, позволяющая оценить, насколько резко меняется модельное управление при незначительных изменениях входа:

Рис. 1. Сравнение прогнозов концентрации NO_2 для разных моделей




Рис. 2. Устойчивость к пропущенным значениям во входных данных

$$S_{dyn} = \frac{1}{T-1} \sum_{t=1}^{T-1} |u_{t+1} - u_t|^2, \tag{11}$$

где u_t — вектор управляющего воздействия в момент t ; T — длина временного ряда.

На основе входных данных по метеопараметрам, топографии и предыдущих наблюдений была обучена модель на задаче краткосрочного прогноза распределения NO₂ в регионе с выраженной антропогенной нагрузкой. Результаты сравнивались с базовой LSTM-моделью и физическим симулятором на основе уравнений переноса.

На графике выше приведено сравнение реальных и предсказанных концентраций в контрольной точке в течение 7 суток (см. рис. 1).

Ошибка модели оказалась существенно ниже: средняя W-MSE составила 3.42, против 6.15 у LSTM и 4.78 у физической модели.

Таблица 2.

Сравнение метрик

Модель	W-MSE	Временная согласованность S _{dyn}	Степень интерпретируемости
LSTM	6.15	0.038	низкая
Физическая модель	4.78	0.021	высокая
Нейро-нечёткая модель	3.42	0.014	высокая

Особый интерес представляла реакция модели на выпадение части данных. Искусственно из обучающей выборки удалялись значения признаков в случайно выбранных участках. На рисунке 2 показано, как меня-

ется ошибка W-MSE в зависимости от доли недостающих данных.

Нейро-нечёткая модель демонстрировала устойчивое поведение вплоть до 35 % пропущенных значений, при этом рост ошибки был умеренным, а карта управляющих воздействий сохраняла квазистационарную структуру.

Для анализа пространственного распределения остаточной ошибки использовалась карта средней ошибки по участкам сетки:

Меньшие значения остатка наблюдаются в зонах с наибольшей плотностью наблюдений, что говорит о способности модели к локальному уточнению оценки при наличии информации.




Рис. 3. Тепловая карта остаточной ошибки модели по региону прогнозирования





Рис. 4. Динамика управляющего сигнала для снижения экологической нагрузки

Рис. 5. Пространственное распределение активных термов в момент времени $t = 3$

В задачах управления модель обучалась формировать сигналы для минимизации пространственного превышения нормативов. Уровень воздействия определялся на основе агрегированной функции риска, оценивающей интеграл превышения предельных значений:

$$R(t) = \int_{\Omega} \max(0, c(x, y, t) - c_{norm}) dx dy. \quad (12)$$

По сравнению с LSTM-моделью, нейро-нечёткая система выдавала более плавные и предсказуемые управляющие сигналы. Ниже показан график изменения управляющего воздействия по дням (см. рис. 4).

Одним из ключевых эффектов предложенной архитектуры стала возможность анализа влияния термов на итоговое решение. Для отдельных временных срезов проводился анализ весов правил α_j , который позволял явно проследить, какие входные условия активировали конкретные логические схемы.

На рисунке ниже показан пример распределения весов термов в пространстве:

Заключение

Предложенная нейро-нечёткая архитектура продемонстрировала устойчивую работу при анализе и управлении пространственно-распределёнными экологическими процессами. В отличие от классических нейросетей, модель не теряет точности при пропущенных данных и позволяет интерпретировать механизм принятия решений, что особенно важно в прикладных задачах экологии.

Система показала способность формировать согласованные управляющие сигналы и корректно реагировать на пространственные особенности входных данных. Это открывает возможности её использования в реальных сценариях — от мониторинга загрязнений до локального природопользования.

В дальнейшем планируется развитие модели в направлении учёта неопределённости и расширения физических ограничений, что позволит повысить надёжность в более широком классе задач.

ЛИТЕРАТУРА

1. Прокофьев С.В., Кузнецов Н.Н. Нечёткие системы и их применение в задачах управления сложными объектами. — М.: Наука, 2017. — 256 с.
2. Иванов А.А., Смирнов П.А. Интеллектуальные методы анализа экологических данных // Вестник Московского государственного университета. Серия «Экология». — 2020. — № 2. — С. 45–53.
3. Редько В.Г. Эволюция, нейронные сети, интеллект: Модели и концепции эволюционной кибернетики. — М.: Ленанд, 2019. — 224 с.
4. Mendel J.M. Uncertain Rule-Based Fuzzy Systems: Introduction and New Directions. — Cham: Springer, 2017. — 684 p.
5. Zadeh L.A. Fuzzy logic and its application to approximate reasoning // Information Processing 74: Proceedings of the IFIP Congress. — Amsterdam: North-Holland, 1974. — P. 591–594.

© Новиков Кирилл Сергеевич (kirill1novikov1@gmail.com); Юрков Николай Кондратьевич (yurkov_NK@mail.ru);

Кошелев Никита Дмитриевич (koshlensky@gmail.com)

Журнал «Современная наука: актуальные проблемы теории и практики»