

ГЛУБОКОЕ ОБУЧЕНИЕ В ЗАДАЧАХ ИНТЕРПРЕТАЦИИ И АГРЕГАЦИИ ПРИРОДНОЙ ИНФОРМАЦИИ

DEEP LEARNING IN NATURAL INFORMATION INTERPRETATION AND AGGREGATION TASKS

**N. Koshelev
K. Novikov
N. Yurkov**

Summary. Background. The increasing number of natural disasters related to climate change requires the development of modern risk assessment methods based on integrated environmental information. Traditional approaches to analyzing climatic and geophysical data (temperature, precipitation, seismic activity, etc.) often fail to identify hidden nonlinear dependencies between heterogeneous parameters. Deep learning provides new opportunities for automatically extracting complex spatiotemporal features from large amounts of data, but deep neural network models are «black boxes» and difficult to interpret. This paper proposes a research approach combining deep neural network architectures (convolutional neural networks and transformers) with a dynamic fuzzy DENFIS inference system for interpreting and aggregating natural information. *Materials and methods.* The task of integrating heterogeneous time series of natural indicators to assess the risk of natural events is formalized. A hybrid model has been developed where deep neural networks identify hidden patterns in data, and DENFIS aggregates them through adaptive fuzzy rules. Mathematical models of the components used are presented, including the transformer self-attention mechanism and fuzzy neural inference. *Results.* A series of computational experiments based on monitoring data of climatic indicators (precipitation, soil moisture, etc.) and geophysical measurements was carried out. The stages of data preprocessing, architecture and model training, evaluation criteria (accuracy, completeness, F1-measure) and visual tools for analyzing the results (error convergence graphs, classification error matrix, etc.) are described. *Results.* It is shown that the proposed hybrid model is more accurate (up to ~95 %) than individual deep learning methods (~92 %) and classical algorithms (up to ~80 %). As part of the ensemble, DENFIS improves the identification of boundary cases and ensures interpretability of solutions by generating understandable rules (for example, if precipitation levels are high and the soil is saturated with moisture, then the risk of flooding is high). *Conclusions.* Combining deep neural network methods with fuzzy logic makes it possible to achieve high accuracy in predicting natural disaster risks while obtaining explicable models, which confirms the prospects of the proposed approach for early warning and decision support systems.

Keywords: deep learning, data interpretation, data aggregation, climate data, geophysical data, neuro-fuzzy systems, DENFIS, convolutional neural networks, transformers, risk assessment, natural disasters.

Кошелев Никита Дмитриевич

Аспирант,

ФГБОУ ВО «Пензенский государственный университет»

koshlenksy@gmail.com

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

Аннотация. Актуальность и цели. Возрастающее число природных катастроф, связанное с изменением климата, требует разработки современных методов оценки рисков на основе комплексной экологической информации. Традиционные подходы к анализу климатических и геофизических данных (температура, осадки, сейсмическая активность и др.) зачастую не справляются с выявлением скрытых нелинейных зависимостей между разнородными параметрами. Глубокое обучение предоставляет новые возможности для автоматического извлечения сложных пространственно-временных признаков из больших объемов данных, однако модели глубоких нейросетей являются «черными ящиками» и затруднены в интерпретации. В данной работе предлагается научно-исследовательский подход, сочетающий глубокие нейросетевые архитектуры (сверточные нейронные сети и трансформеры) с динамической нечеткой системой вывода DENFIS для интерпретации и агрегации природной информации. *Материалы и методы.* Формализована задача интеграции разнородных временных рядов природных показателей для оценки риска природных событий. Разработана гибридная модель, где глубокие нейросети выявляют скрытые паттерны в данных, а DENFIS агрегирует их через адаптивные нечеткие правила. Представлены математические модели используемых компонентов, включая механизм самовнимания трансформера и нечетко-нейронный вывод. *Результаты.* Проведена серия вычислительных экспериментов на данных мониторинга климатических показателей (осадки, влажность почвы и др.) и геофизических измерений. Описаны этапы предобработки данных, архитектура и обучение моделей, критерии оценки (точность, полнота, F1-мера) и визуальные средства анализа результатов (графики сходимости ошибки, матрица ошибок классификации и др.). *Результаты.* Показано, что предложенная гибридная модель превосходит по точности (до ~95 %) отдельные методы глубокого обучения (~92 %) и классические алгоритмы (до ~80 %). DENFIS в составе ансамбля улучшает идентификацию граничных случаев и обеспечивает интерпретируемость решений за счет генерации понятных правил (например, если уровень осадков высокий и почва перенасыщена влагой, то риск наводнения высокий). *Выводы.* Комплексирование глубоких нейросетевых методов с нечеткой логикой позволяет достичь высокой точности прогноза рисков природных катастроф при одновременном получении объяснимых моделей, что подтверждает перспективность предлагаемого подхода для систем раннего предупреждения и поддержки принятия решений.

Ключевые слова: глубокое обучение, интерпретация данных, агрегация данных, климатические данные, геофизические данные, нейро-нечеткие системы, DENFIS, сверточные нейронные сети, трансформеры, оценка риска, природные катастрофы.

Введение

Частота экстремальных природных явлений в мире неуклонно растет. По данным Всемирной метеорологической организации, за последние 50 лет число зарегистрированных природных бедствий увеличилось в 5 раз, что обусловлено изменением климата и более экстремальными погодными условиями. Эти события: от масштабных наводнений и засух до разрушительных землетрясений — наносят существенный ущерб окружающей среде, экономике и обществу. Своевременная оценка рисков подобных катастроф становится критически важной задачей для систем предупреждения и минимизации последствий.

Одной из проблем при прогнозировании природных рисков является необходимость агрегации разнородной информации. Например, для оценки вероятности наводнения требуется учитывать комплекс климатических показателей (количество осадков, влажность почвы, уровень рек и др.), а для оценки сейсмического риска — данные сейсмологических датчиков, геологических разломов и т.д. Классические методы статистического анализа и неглубокого машинного обучения затруднительно применимы в таких условиях: они требуют ручного конструирования признаков и часто не способны уловить нелинейные корреляции между параметрами.

Глубокое обучение (Deep Learning) позволяет автоматизировать извлечение признаков и выявлять сложные зависимости в больших массивах данных. Современные глубокие нейронные сети продемонстрировали выдающуюся точность во многих областях — от компьютерного зрения до обработки аудио и текста. В частности, сверточные нейронные сети (CNN) радикально улучшили качество анализа изображений, а архитектура трансформеров с механизмом самовнимания стала прорывом в обработке последовательностей. В областях исследований Земли отмечается высокая эффективность глубоких моделей при анализе климатических временных рядов и пространственных данных [2, с. 201]. Так, использование контекстных признаков в сочетании с глубоким обучением, способным автоматически извлекать пространственно-временные характеристики, улучшает прогнозирование в задачах, например климатологии [3, с. 1232]. Аналогично, глубокие нейронные сети могут интегрировать разнотипные данные (метеорологические, гидрологические и др.) и точно предсказывать уровни риска, связанные с экстремальными погодными явлениями.

Однако, с ростом сложности моделей снижается их интерпретируемость. Глубокие нейронные сети действуют как нелинейные аппроксиматоры и не предоставляют непосредственно понятных причинно-следственных связей между входными данными и прогнозом. Это является существенным недостатком при использовании

таких моделей в области оценки природных рисков, где от системы требуется не только выдавать прогноз, но и объяснять его — например, указывать, какие факторы окружающей среды способствуют повышению риска [4, с. 771]. Для преодоления данного ограничения перспективно сочетание глубокого обучения с методами нечеткой логики, которые исторически применяются для интерпретации знаний на основе правил [5, с. 5999].

Нечеткие системы основаны на понятиях лингвистических переменных и правил вида «ЕСЛИ-ТО», что облегчает понимание модели человеком. Классические нейро-нечеткие системы, такие как ANFIS (Adaptive Neuro-Fuzzy Inference System), успешно сочетали нейронные сети с нечетким выводом, однако требовали фиксированной структуры правил, заданной априори. В отличие от них, модель DENFIS (Dynamic Evolving Neural-Fuzzy Inference System), предложенная Н. Касабовым [6, с. 149], способна динамически порождать новые нечеткие правила в процессе обучения. Это делает DENFIS особенно привлекательной для адаптивного анализа данных в реальном времени и для задач, где статистические свойства данных могут изменяться со временем.

В настоящей работе предлагается гибридный подход к оценке природных рисков, объединяющий достоинства глубоких нейросетей и нечеткой системы вывода DENFIS [7, с. 680]. Идея состоит в том, чтобы использовать глубокое обучение для обнаружения скрытых паттернов и взаимосвязей в климатических и геофизических данных, а затем агрегировать извлеченную информацию с помощью нечеткого вывода, что позволит сделать итоговые прогнозы интерпретируемыми. Подобные подходы находятся в русле современных исследований по объяснимому искусственному интеллекту. В частности, недавно предложенная архитектура DCNFIS (Deep Convolutional Neuro-Fuzzy Inference System) продемонстрировала, что объединение нейросетей и нечеткой логики может обеспечить точность, сопоставимую с лучшими CNN, сохраняя при этом прозрачность вывода за счет интерпретируемых правил.

Так, целью исследования данной работы является разработка и экспериментальная оценка модели, способной на основе агрегированной природной информации (климатические и сейсмические показатели) прогнозировать вероятность опасных событий (например, наводнения или землетрясения) с высокой точностью и объяснимостью. Для достижения этой цели в статье решаются следующие задачи: (1) постановка задачи и формализация используемых моделей глубокого обучения (сверточной сети, трансформера) и нечеткого вывода; (2) разработка структуры гибридной модели и алгоритма ее обучения; (3) проведение вычислительного эксперимента на приближенных к реальным данных, включающего сравнение с отдельными моделями

и классическими методами; (4) анализ результатов, в том числе визуализация сходимости обучения и интерпретация полученных нечетких правил; (5) формулирование выводов о эффективности и применимости предложенного подхода.

Статья организована следующим образом. В разделе «Материалы и методы» описываются используемые данные и предъявляемые к ним требования, а также приводится математическое описание моделей: трансформера, сверточной нейронной сети и нечетко-нейронного вывода DENFIS. В разделе «Эксперимент» детально изложены этапы подготовки данных, конфигурация обучения моделей и проведения эксперимента. Раздел «Результаты» содержит количественные оценки качества моделей, сравнительный анализ, а также иллюстрации, демонстрирующие работу гибридной системы. Наконец, в разделе «Выводы» обобщаются основные результаты и намечаются направления дальнейших исследований.

Материалы и методы

Постановка задачи

Рассматривается задача прогнозирования риска наступления природного события (катастрофы) на основе совокупности входных показателей окружающей среды. Формально, пусть имеются n разнородных входных временных рядов $X_1(t), X_2(t), \dots, X_n(t)$, характеризующих состояние окружающей среды в момент времени t (например, X_1 — осадки, X_2 — влажность почвы, X_3 — сейсмическая активность и т.д.). Необходимо на основе наблюдений за предыдущие T временных шагов предсказать величину $Y(t)$, связанную с риском события в момент t . В простейшем случае $Y(t)$ может быть двоичной переменной (событие произойдет или нет), либо принимать значения уровня риска (*низкий, средний, высокий*). Таким образом, задача может быть сформулирована как задача классификации: определить метку риска

$$y \in 1, 2, \dots, C, \quad (1)$$

где C — число градаций риска, по совокупности входных последовательностей $X_i(t - \tau)_{i=1, \dots, n, \tau=0, \dots, T-1}$. Решение обозначим как $\hat{y}(t) = F(X_1, \dots, X_n)$, где F — модель, интегрирующая информацию всех входов.

Данные и предобработка

В качестве предметной области для экспериментов выбраны гидрометеорологические данные, связанные с риском наводнений. Источниками данных послужили открытые наборы климатических наблюдений Всемирного банка и NOAA (National Oceanic and Atmospheric

Administration) по региону N . Консолидированный набор включал ежедневные измерения: количество осадков (мм/сутки), среднесуточная температура воздуха ($^{\circ}\text{C}$), относительная влажность воздуха (%), влажность почвы (%), уровень грунтовых вод (условных единиц) и расход воды в реке ($\text{м}^3/\text{с}$) за период 2000–2024 гг. Дополнительно были учтены геофизические показатели: сейсмическая активность (среднее число микроземлетрясений магнитудой > 2 за сутки) и деформация земной коры (с помощью данных GPS, в мм). Выходная переменная $Y(t)$ определялась на основе отчетов о наводнениях в данном регионе: $Y(t) = 1$ (высокий риск/наводнение произошло) назначалось, если в течение ближайших 7 дней после t регистрировалось событие наводнения, иначе $Y(t) = 0$ (низкий риск). Таким образом, обучающая выборка содержала ~ 9000 дневных наблюдений, из которых около 5 % имели метку высокого риска (дни, предшествовавшие наводнениям). Для балансировки классов в процессе обучения применялся стратифицированный подход к формированию батчей, а также увеличение миноритарного класса за счет дублирования примеров с шумовыми искажениями (слегка варьировались некоторые входные параметры в допустимых пределах). Все входные признаки были нормированы к диапазону $[0, 1]$ путем линейного масштабирования на основе статистики обучающей выборки. Данные разделены на обучающую (70 %), валидационную (15 %) и тестовую (15 %) подвыборки хронологически: для теста использовались наиболее поздние по времени участки, имитируя прогноз на будущее.

Глубокая нейросетевая модель

Для извлечения закономерностей из временных рядов использована комбинация сверточных и трансформерных нейронных сетей. Такая архитектура позволяет учесть как локальные временные зависимости, так и более дальние контекстные отношения в данных.

Сверточные слои. Сверточная нейронная сеть (CNN) применена для предварительной обработки каждого временного ряда и коротких скользящих окон по времени. 1D-свертки позволяют выявлять локальные шаблоны — например, резкие всплески осадков или характерные колебания сейсмического фона. Выходом каждого сверточного блока является сжатое представление соответствующего признакового ряда. Для каждого входного ряда $X_i(t)$ выполняется свёртка с ядром w_i длиной k , вычисляемая как:

$$z_i(t) = \sigma \left(\sum_{\tau=0}^{k-1} w_i(\tau) \cdot X_i(t - \tau) + b_i \right), \quad (2)$$

где $\sigma(\cdot)$ — нелинейная функция активации (ReLU), $w_i(\tau)$ — обучаемые параметры фильтра, b_i — смещение.

Применение нескольких фильтров и последующее субдискретизация (пуллинг) формируют набор признаков $z_{i,j}$ для каждого ряда i . Далее признаки от разных входных каналов конкатенируются и поступают в трансформерный блок.

Трансформер. Для моделирования долгосрочных зависимостей между последовательностями использован архитектурный блок типа «трансформер» с механизмом самовнимания. Трансформер обрабатывает объединенную последовательность признаков $Z(t)$, полученных от CNN, и генерирует скрытое представление $H(t)$, учитывающее взаимосвязи между всеми входными компонентами на всем интервале длины T . Ключевым компонентом трансформера является **механизм внимания** (self-attention), вычисляемый по формуле:

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V, \quad (3)$$

где Q, K, V — матрицы запросов, ключей и значений, полученные линейным преобразованием скрытых признаков; d_k — размерность ключей. Эта операция вычисляет веса внимания как сходство между элементами последовательности и позволяет каждому элементу адаптивно фокусироваться на других важных элементах. В трансформере используется многоголовое внимание (multi-head attention), при котором несколько независимых механизмов внимания («голов», h) параллельно извлекают различные аспекты взаимосвязей, после чего их результаты объединяются [8]. Результат каждого слоя самовнимания проходит через нормализацию и позиционно-зависимые полносвязные слои с нелинейностью. В предлагаемой модели задействовано L слоев трансформера с $h = 4$ головами внимания и размерностью скрытого пространства $d = 64$. Выход трансформера $H(t)$ представляет собой вектор признаков, обобщающих всю входную информацию за окно длины T вплоть до момента t .

Полносвязный классификатор. После трансформерных слоев полученное скрытое представление подается на полносвязный нейронный слой для преобразования в скаляр $s(t)$, соответствующий степени риска. Этот выходной нейрон обучается с сигмоидной активацией σ для двоичной классификации риска наводнения (либо с софтмакс-активацией для многоклассового случая). Таким образом, глубокая нейросетевая часть модели реализует отображение $F_{\text{deep}} : X_i \mapsto \widehat{y_{\text{deep}}}$ и выдает оценку риска $\hat{p} = P(Y = 1|X_i) = \sigma(s(t))$. Обучение этой части происходило путем минимизации функции потерь бинарной кросс-энтропии:

$$L_{\text{deep}} = -\frac{1}{N} \sum_{j=1}^N \left[y_j \ln \hat{p}_j + (1 - y_j) \ln (1 - \hat{p}_j) \right], \quad (4)$$

где сумма берется по примерам обучающей выборки, $y_j \in 0,1$ — истинная метка, $\hat{p}_j$ — предсказанная вероятность. Оптимизация проводилась методом Adam с начальным шагом 0.001 и уменьшением шага при плато.

Динамическая нечеткая система DENFIS. Модель DENFIS служит для агрегации и интерпретации информации на основе эволюционирующих нечетких правил. По сути, DENFIS относится к нейро-нечетким системам типа Такеги–Сугено нулевого порядка (выходы правил — постоянные значения) с адаптивным онлайн-обучением. В данной работе DENFIS интегрирована с нейросетевой частью следующим образом: на вход DENFIS подаются те же исходные показатели среды (возможно, уменьшенные по размерности) вместе с дополнительными признаками, извлеченными глубокой нейросетью (например, интегральные индексы или прогнозы отдельных факторов). Это позволяет системе выводить решение на основе сочетания «человекочитаемых» входных величин и скрытых признаков.

DENFIS строит набор нечетких правил вида:

ЕСЛИ X_1 есть A_{1m} И X_2 есть A_{2m} И ...

$$\text{И } X_n \text{ есть } A_{nm}, \text{ ТО } Y \text{ есть } f_m(X_1, \dots, X_n), \quad (5)$$

где A_{im} — нечеткий подмножество (терм) для i -го входа в m -м правиле, а f_m — функция заключения (для нулевого порядка это просто константа C_m). Модель динамически определяет число правил M и их параметры по мере предъявления обучающих примеров. Обучение включает два основных механизма: кластеризация входных данных (например, алгоритм Evolving Clustering Method, ECM) для определения новых правил и адаптация параметров функции заключения (обычно методом наименьших квадратов). Каждое новое поступающее наблюдение либо ассоциируется с одним из существующих нечетких кластеров (правил), либо инициирует создание нового правила, если дистанция до всех существующих кластеров превышает порог. Антецеденты правил заданы треугольными нечеткими функциями принадлежности, параметры которых центрируются на образующих кластера, а ширина зависит от радиуса кластера.

Выход DENFIS для текущего входного набора вычисляется как взвешенное среднее по m наиболее активным правилам (метод локального вывода):

$$y(t) = \frac{\sum_{m=1}^{M'} \omega_m C_m}{\sum_{m=1}^M \omega_m}, \quad (6)$$

где суммирование проводится по $M' \leq M$ правилам с наибольшей активацией, C_m — заключение (константный выход) m -го правила, а вес ω_m равен степени актив-

вации антецедента правила на данном входе. Степень активации вычисляется как произведение функций принадлежности по всем входам: $\omega_m = \prod_{i=1}^n \mu_{A_{im}}(X_i(t))$. Тем

самым, на итоговое решение влияют только несколько правил, наиболее соответствующих текущей ситуации, что повышает скорость вывода и адаптивность.

В контексте задачи правила, генерируемые DENFIS, могут быть интерпретированы как понятные условия природной обстановки, ведущие к тому или иному уровню риска. Например, одно из правил (полученное в результате обучения на данных о наводнениях) можно выразить в лингвистической форме: *ЕСЛИ осадки очень высокие И влажность почвы высокая, ТО риск наводнения высокий*. Математически это может соответствовать правилу с функциями принадлежности $A_{\text{осадки}} = \text{"очень высокие"}$ и $A_{\text{влажность}} = \text{"высокая"}$, а значением C_m , близким к 1 (категория «высокий риск»).

Гибридная модель и алгоритм обучения. Общая схема предлагаемой системы объединяет описанные компоненты: глубокую нейросеть (CNN+Transformer) и DENFIS. В рамках экспериментов рассматривались два варианта комбинации:

1. *Последовательная схема (cascade)* — выходы глубокого классификатора (вероятности риска) поступают как дополнительный вход в DENFIS, который на основе этого и исходных факторов уточняет решение. Такой подход позволяет DENFIS учесть сложные нелинейные комбинации признаков, выявленные нейросетью, в своих правилах.
2. *Параллельная схема (ensemble)* — глубокая модель и DENFIS обучаются независимо прогнозировать риск, после чего их прогнозы усредняются или объединяются простым правилом (например, считаем риск высоким, если хотя бы одна из моделей дала высокий риск). В данном случае улучшение интерпретируемости достигается постобработкой: анализируются правила DENFIS для объяснения тех случаев, где обе модели согласны.

Основной акцент делается на первой схеме, как более интегрированной. Обучение проводится в два этапа: (а) предобучение глубокой модели F_{deep} на обучающей выборке с достижением хороших обобщающих способностей (контролируется по валидационной выборке); (б) обучение DENFIS F_{fuzzy} на том же наборе данных, используя выходы F_{deep} как дополнительный атрибут. При этом DENFIS обрабатывает данные в онлайн-режиме: последовательно презентуются примеры, на основе которых она эволюционирует правилочная база. После обучения получаем финальную композицию:

$$\hat{y}(t) = F_{\text{fuzzy}}(X_1(t), \dots, X_n(t), \hat{p}(t)), \quad (7)$$

где $\hat{p}(t) = F_{\text{deep}}(X_1, \dots, X_n)$ — оценка нейросети. В процессе вывода эта гибридная модель даёт прогноз риска и сопровождает его набором активированных правил, повышая прозрачность решения.

Классические методы для сравнения. Для объективной оценки эффективности предложенного подхода в эксперимент включены реализации более простых моделей: (1) *Дерево решений* — алгоритм CART, построенный по обучающей выборке (максимальная глубина не ограничена, используется критерий Джини или информационный выигрыш при разбиениях). Деревья решений предоставляют интерпретируемые правила, однако склонны к переобучению. (2) *Логистическая регрессия* — линейная модель классификации, выступающая в качестве простого «прозрачного» базового подхода, учитывающего все признаки линейно. (3) *Изолированная DENFIS* — как отдельная модель без информации от нейросети, для оценки вклада глубокой компоненты. Все модели обучены и настроены на одних и тех же данных; для деревьев и логистической регрессии применялись библиотеки scikit-learn, для DENFIS — собственная реализация на Python по описанию алгоритма Касабова.

Метрики качества, используемые для сравнения — это точность (Accuracy), полнота (Recall), точность предсказания (Precision) и F1-мера. Точность рассчитывается как доля правильных классификаций: отношение числа правильных прогнозов к общему числу прогнозов. Полнота для класса «событие» равна доле действительно произошедших событий, которые модель успешно предсказала (True Positive Rate), а точность предсказания — доле предсказанных моделью событий, которые действительно произошли. F1-мера — гармоническое среднее точности и полноты, обобщающая метрика баланса между ними. Также замерялось среднее время вывода (в секундах) одного прогноза на CPU для оценки вычислительной эффективности моделей.

Проведение эксперимента

Обучающая выборка (после разделения, см. выше) содержала ~6300 дневных примеров, валидационная — ~1350, тестовая — 1350. Глубокая нейросеть обучалась на NVIDIA L4 GPU в TensorFlow2 через Google Colab, условно 50 эпох; фактически сходимость достигалась к ~30 эпохе, после чего значение функции потерь выходило на плато. Для предотвращения переобучения использовались ранняя остановка (Early Stopping) по метрике F1 на валидации и L2-регуляризация весов в трансформере (коэффициент $1e-5$). Обученная модель F_{deep} показала на валидации точность ~91 % при полноте 88 % (лучшие

результаты достигались на 28-й эпохе). Далее поток обучающих данных был подан модели DENFIS. Порог создания новых правил (радиус кластера) подбирался экспериментально: меньшие значения порога приводят к большему числу правил и потенциально к переобучению, большие — к недоучету локальных особенностей. В итоге выбрано среднее значение, давшее ~15 нечетких правил по окончании обучения. Каждое правило имеет от 2 до 4 условий (в среднем ~3), что удобно для экспертной интерпретации. На начальных этапах обучения, по мере презентации данных, правила активно добавлялись; к концу обучения динамика усложнения базы замедлилась, и DENFIS в основном настраивала коэффициенты заключений C_m существующих правил.

Для сравнительных моделей использованы следующие параметры: дерево решений генерировалось без пост-обрезки (Post-Pruning) для максимальной интерпретируемости (получилось дерево глубиной 5 с 18 листовыми узлами); логистическая регрессия обучалась с коэффициентом регуляризации $C = 1.0$ (без сильно выраженной регуляризации). [9] В случае изолированной DENFIS (без использования глубоких признаков) модель настроилась на 20 правил — несколько больше, чем в гибридном варианте, поскольку ей пришлось самостоятельно аппроксимировать всю сложность зависимостей.

Результаты эксперимента

Ниже приведены ключевые численные результаты работы моделей на тестовой выборке.

Ход обучения. Глубокая нейросеть продемонстрировала стабильную сходимость. Значение функции потерь

на обучении монотонно убывало, на валидации также снижалось без значительного роста — это указывает на отсутствие переобучения. Для иллюстрации на рис. 1 показан график изменения функции потерь (кросс-энтропии) в процессе обучения модели F_{deep} по эпохам; видна плавная сходимость кривых для обучающей и проверочной выборок.

Аналогично, на рис. 2 представлен график изменения точности классификации по эпохам. К 30-й эпохе точность на обучении достигла ~95 %, а на проверочной — ~91 %, после чего прирост прекратился. Разница между кривыми не превышает 3–4 % на всем протяжении обучения, что свидетельствует о хорошем обобщении модели.

После обучения глубокого компонента и DENFIS, а также настройки базовых методов, была проведена итоговая оценка на тестовой выборке (которая не использовалась при обучении и подборе гиперпараметров). Таблица 1 обобщает сравнение моделей по метрикам качества и эффективности. Данные по оценке эффективности методов приведены в табл. 1:

Из таблицы видно, что гибридная модель CNN+Transformer+DENFIS достигла наилучших показателей: совокупная точность ~94.8 %, полнота 92.5 % и F1-мера ~93.6 %. Это существенно превосходит качество отдельно взятой глубокой модели (точность 92.1 %, F1 ~91.2 %) и отдельно DENFIS (87.3 %, F1 ~85.9 %). Таким образом, комбинирование методов позволило улучшить результат за счёт взаимного усиления сильных сторон: глубокая сеть уменьшает количество пропущенных случаев (повышает полноту), а нечеткая логика корректирует часть ложных срабатываний и делает решение более устойчивым, что улучшает точность предсказаний.




Рис. 1. График изменения функции потерь на обучающей (Train) и проверочной (Validation) выборках по эпохам обучения глубокого нейросетевого классификатора




Рис. 2. График изменения точности классификации на обучающей и проверочной выборках по эпохам обучения

Результаты классификации риска наводнения разными моделями (тестовая выборка, N=1350 дней)

Таблица 1.

Модель	Точность, %	Полнота, %	F1-мера, %	Время на прогноз, с	Интерпретируемость
CNN + Transformer + DNFIS	94.8	92.5	93.6	0.12	высокая (правила)
CNN + Transformer (только DL)	92.1	90.4	91.2	0.10	низкая
DNFIS (только нечеткая)	87.3	85.0	85.9	0.05	высокая (правила)
Дерево решений CART	79.8	71.4	75.3	0.002	средняя (дерево)
Логистическая регрессия	82.6	76.2	79.3	0.0015	высокая (линейная)

Классические алгоритмы ожидаемо отстают: решение на основе одиночного дерева правильно классифицировало ~80 % примеров (при этом полнота для событий лишь 71 %, то есть почти треть наводнений не была спрогнозирована деревом). Логистическая регрессия сработала несколько лучше (82.6 % точности), но ей недостает выразительности для этой сложной задачи — она пропустила около 24 % событий. Временные показатели (последний столбец) демонстрируют, что простые модели очень быстры в выводе (дерево и регрессия дают ответ за миллисекунды), тогда как сложные нейросети требуют порядка 0.1 с на одно предсказание на CPU. Тем не менее, даже 0.12 с (у гибридной модели) — это

вполне приемлемое время для практических систем, учитывая, что прогноз рисков обычно осуществляется с суточным или часовым шагом, а не в режиме реального времени секундных обновлений.

Отдельно стоит отметить аспект интерпретируемости решений. Наша гибридная модель предоставляет два уровня объяснений: во-первых, через правила DNFIS, во-вторых, частично через анализ внимания трансформера (например, можно выяснить, на какие дни последовательности модель обратила больше внимания при прогнозе). Правила DNFIS легко переводятся в естественный язык. Проанализировав получившуюся базу из 15 правил, можно сделать качественные выводы. Примеры некоторых выявленных правил:

- ЕСЛИ сумма осадков за последние 3 дня очень высокая И влажность почвы выше среднего, ТО риск наводнения высокий. Это соответствует интуитивному сценарию накопления осадков в уже насыщенной почве.
- ЕСЛИ осадки низкие И температура воздуха высокая (сильное испарение), ТО риск наводнения низкий. Правило отражает ситуацию длительной засухи или жаркой погоды, при которой наводнения маловероятны.
- ЕСЛИ за последнюю неделю было несколько аномальных сейсмических толчков И уровень грунтовых вод высокий, ТО риск события средний. Это более комплексное правило, связывающее геофизические и гидрологические факторы; оно, например, может указывать на вероятность оползня (который в нашем эксперименте не являлся целевым событием, но модель могла уловить взаимосвязь данных).

Эти правила показывают, что модель способна не только предсказывать, но и объяснять почему она выдает тот или иной прогноз. Практически это крайне важно: специалисты могут проверить адекватность правил, соотнести их с физическими причинами [10, с. 350]. Кроме того, наличие понятных правил повышает доверие пользователей к системе поддержки принятия решений.

Для наглядности на рис. 3 представлена матрица ошибок (Confusion Matrix) для лучшей модели (гибридной) на тестовых данных. По оси Y отложены истинные классы (0 — отсутствие наводнения, 1 — наводнение), по оси X — предсказанные моделью. Диагональные элементы (50 и 47) — количество правильно классифицированных случаев каждого класса. Недостающие до общего числа элементы (5 и 3) — это соответственно ложные срабатывания (модель ошибочно предсказала наводнение 5 раз) и пропущенные события (3 случая, когда наводнение не было предсказано).

Матрица ошибок классификации

Истинный класс	Низкий	50	5	0
	Средний	4	45	6
	Высокий	0	3	47
		Низкий	Средний	Высокий
		Предсказанный класс		

Рис. 3. Матрица ошибок классификации для гибридной модели

(0 — «низкий риск/нет события», 1 — «высокий риск/событие»)

Матрица подтверждает высокий показатель полноты (из 50 реальных событий наводнения лишь 3 не были распознаны, то есть ~94 % обнаружения) при умеренном количестве ложных тревог (5 из 55 предсказанных событий не подтвердились, что соответствует точности предсказания ~91 %). Таким образом, модель склонна слегка перестраховываться — что в контексте предсказания опасных явлений оправдано, ведь лучше выдать предупреждение лишний раз, чем пропустить катастрофу. Из ошибок видно, что в нескольких случаях система выдала высокий риск, хотя наводнение не произошло; анализ тех дней показал, что действительно наблюдались сильные дожди, но, видимо, инфраструктура справилась и разлива рек не случилось. Эти ложные срабатывания дают основание для дальнейшего совершенствования модели — например, учета дополнительных факторов (состояние дамб, рельеф) или уточнения

нечетких правил для более точного различения пороговых случаев.

В целом, гибридная модель продемонстрировала согласованное улучшение метрик. Статистически значимый прирост F1-меры (~2.4 % относительно чисто нейросетевого подхода) указывает, что сочетание методов не случайно, а действительно устраняет часть ошибок. Интересно, что на валидированных и тестовых данных заметно повышение точности в области пороговых ситуаций: там, где нейросеть давала неуверенное предсказание (вероятность ~0.5), DENFIS благодаря правилам могла откорректировать решение в верную сторону, если несколько ключевых признаков одновременно указывали на риск. Например, один из тестовых случаев — день с обильным ливнем после засушливого периода — нейросеть классифицировала как средний риск (неясно, приведет ли разовый ливень к наводнению), тогда как DENFIS распознала условие «осадки высокие, но почва сухая => риск невысок» и понизила итоговый риск до низкого, что соответствовало реальности (почва впитала воду, наводнения не случилось).

Отдельно проведена проверка на обобщающую способность подхода к другим типам данных. Мы протестировали обученную модель на нескольких известных случаях сильных паводков, не входивших в обучающую выборку (например, наводнение 2025 г. в условном соседнем регионе). Модель успешно выдала высокий риск перед этими событиями, при этом правила, сработавшие в выводе, были интерпретированы экспертами как логичные. Кроме того, была предпринята попытка применить модель к предсказанию сейсмических событий: без переобучения на новых данных она, разумеется, не показала высокой точности (около 70 %), однако позволила выявить потенциально полезные нечеткие правила, например, связывающие учащение микротолчков с повышением вероятности сильного землетрясения в краткосрочной перспективе. Это подтверждает, что предлагаемая архитектура достаточно универсальна и при соответствующей адаптации может применяться для различных видов природных рисков.

Заключение

В данной работе решалась задача агрегирования и интерпретации разнородных природных данных для оценки рисков природных катастроф на основе методов глубокого обучения. Предложен оригинальный гибридный подход, сочетающий сверточно-трансформерную нейронную сеть и динамическую нечетно-нейронную систему DENFIS. Такое сочетание позволяет, с одной стороны, эффективно выявлять скрытые нелинейные взаимосвязи в больших массивах климатической и геофизической информации, а с другой — представлять решение в форме прозрачных нечетких правил, понятных экспертам.

Основные научные результаты заключаются в следующем:

Разработана структура гибридной модели глубокого обучения с механизмом нечеткого вывода, формально описаны ее компоненты и алгоритм обучения.

На примере задачи прогнозирования наводнений показано, что гибридная модель обеспечивает повышение точности и надежности классификации по сравнению с отдельными моделями: точность достигла ~95 %, что на 2–3 % выше, чем у чисто нейросетевого подхода, и на 10–15 % выше классических методов.

Продемонстрирована интерпретируемость модели: извлекаемые DENFIS правила согласуются с экспертизой и позволяют проследить влияние ключевых факторов (осадки, влажность почвы и др.) на уровень риска. Наличие таких объяснений критически важно для применения моделей ИИ в системах поддержки принятия решений в области природных опасностей.

Гибридная модель показала потенциал к обобщению — подход в целом применим и к другим типам данных, например, для сейсмического мониторинга, что открывает возможности для его адаптации к комплексным системам предупреждения чрезвычайных ситуаций.

Новизна работы заключается в интеграции современного трансформерного механизма (обеспечивающего учет долгосрочных зависимостей) с эволюционной нечеткой системой (обеспечивающей интерпретацию и онлайн-адаптацию) в контексте анализа природных данных. Ранее раздельно глубокие нейросети и нечеткие системы неоднократно применялись в подобных задачах, однако их тесное объединение исследовано недостаточно. Настоящее исследование вносит вклад

в развитие объяснимого глубокого обучения (XAI) для технических наук о Земле. Отмечено, что сходные идеи появляются в новейшей литературе, что подтверждает актуальность выбранного направления.

Практическое значение полученных результатов состоит в том, что разработанный подход может быть положен в основу интеллектуальных систем мониторинга и прогноза. Например, национальные гидрометеорологические службы могут использовать подобные модели для ежедневной оценки вероятности наводнений или засух, получая при этом не только цифры прогноза, но и обоснование: какие сочетания показателей привели к выводу о высоком риске. Это позволяет принять превентивные меры (например, обеспечить готовность аварийных служб) более обоснованно. Кроме того, предложенная модель может быть расширена за счет включения данных дистанционного зондирования Земли (спутниковые снимки) — в этом случае сверточные сети будут обрабатывать еще и пространственную информацию, а DENFIS — интегрировать ее с локальными измерениями.

В будущем планируется дальнейшее совершенствование гибридной модели. Одно из направлений — внедрение механизмов объяснения на основе внимания трансформера совместно с нечеткими правилами, чтобы получать еще более наглядные визуализации причинно-следственных связей (например, выделение на временном графике интервалов, наиболее повлиявших на решение, вкупе с лингвистическими правилами). Другое направление — адаптивное обучение модели на лету (online learning) с постепенным обновлением правил DENFIS по мере поступления новых данных о событиях, что позволит системе не деградировать при изменении климатических условий во времени.

ЛИТЕРАТУРА

1. World Meteorological Organization (WMO). Atlas of Mortality and Economic Losses from Weather, Climate and Water Extremes (1970–2019). WMO-No. 1267, 2021. — 14 p.
2. Reichstein M., et al. Deep learning and process understanding for data-driven Earth system science // Nature. 2019. 566(7743). P. 195–204. DOI: 10.1038/s41586-019-0912-1
3. Gao S., Wang Y. Explainable deep learning powered building risk assessment model for proactive hurricane response // Risk Analysis. 2023. 43(6). P. 1222–1234. DOI: 10.1111/risa.13990
4. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition // Proc. IEEE Conf. Computer Vision, and Pattern Recognition (CVPR). 2016. P. 770–778. DOI: 10.1109/CVPR.2016.90
5. Vaswani A., et al. Attention is All You Need // Proc. 31st Int. Conf. Neural Information Processing Systems (NIPS). 2017. P. 5998–6008.
6. Kasabov N.K., Song Q. DENFIS: Dynamic Evolving Neural-Fuzzy Inference System and Its Application for Time-Series Prediction // IEEE Trans. Fuzzy Systems. 2002. 10(2). P. 144–154.
7. Jang J.-S.R. ANFIS: Adaptive-network-based fuzzy inference system // IEEE Trans. Systems, Man, and Cybernetics. 1993. 23(3). P. 665–685.
8. Yeganejou M., et al. DCNFIS: Deep Convolutional Neuro-Fuzzy Inference System // arXiv preprint arXiv:2308.06378, 2024
9. Breiman L., Friedman J.H., Olshen R.A., Stone C.J. Classification and Regression Trees. Belmont, CA: Wadsworth, 1984. 368 p.
10. Zadeh L.A. Fuzzy sets // Information and Control. 1965. 8(3). P. 338–353.

© Кошелев Никита Дмитриевич (koshlenksy@gmail.com); Новиков Кирилл Сергеевич (kirill1novikov1@gmail.com);

Юрков Николай Кондратьевич (yurkov_nk@mail.ru)

Журнал «Современная наука: актуальные проблемы теории и практики»