

ГИБРИДНАЯ МОДЕЛЬ С ПОДКРЕПЛЕНИЕМ, НЕЧЕТКОЙ ЛОГИКОЙ И ЭВОЛЮЦИЕЙ ДЛЯ ПРОГНОЗА ТЕМПЕРАТУРЫ ТРАНСФОРМАТОРА

Черников Александр Владимирович

аспирант, ФГБОУ ВО Московский государственный
технологический университет «Станкин»
aleksandrchernikov98@gmail.com

A HYBRID REINFORCEMENT LEARNING, FUZZY LOGIC, AND EVOLUTIONARY MODEL FOR TRANSFORMER TEMPERATURE FORECASTING

A. Chernikov

Summary. This paper presents a novel hybrid approach, FELAR, which integrates tabular Q-learning, socially oriented fuzzy logic, and genetic hyperparameter optimization to accurately predict the oil winding temperature of power transformers. Using the ETTh1 benchmark dataset, we demonstrate that the proposed architecture achieves performance comparable to or better than state-of-the-art transformer models. The hybridization enables effective adaptation to thermal inertia and seasonal variations without sacrificing computational simplicity, allowing for online fine-tuning on edge devices without GPU acceleration. Experimental analysis of the error distribution and forecast-vs-actual scatter plots highlights FELAR's robustness to right-skewed errors and overnight temperature dips, suggesting avenues for further calibration of fuzzy rule weights and evolution of strategy parameters.

Key words: FELAR, ETTh1, Q-learning, fuzzy logic, genetic optimization, transformer temperature forecasting.

Аннотация. В статье представлен новый гибридный подход FELAR, который сочетает табличное Q-обучение, социально-ориентированную нечёткую логику и генетическую оптимизацию гиперпараметров для точного прогнозирования температуры масляной обмотки силового трансформатора. На примере эталонного набора ETTh1 демонстрируется, что предложенная архитектура достигает сопоставимых или лучших по сравнению с классическими трансформер-моделями. Гибридизация позволяет эффективно адаптироваться к термическим инерциям и сезонным колебаниям без потери вычислительной простоты, выполняя онлайн-дообучение на периферийных устройствах без GPU. Экспериментальный анализ распределения ошибок и диаграммы «прогноз–факт» подчёркивает устойчивость FELAR к правосторонней асимметрии и ночным провалам, открывая пути к дальнейшей калибровке нечётких весов и эволюции стратегий.

Ключевые слова: FELAR, ETTh1, Q-обучение, нечеткая логика, генетическая оптимизация, прогноз температуры трансформатора.

Введение

В статье представлен FELAR (Fuzzy-Evolutionary Learning for Adaptive Regulation) — гибридная модель интеллектуального управления, сочетающая обучение с подкреплением, нечёткую логику и эволюционные алгоритмы для решения задач прогнозирования и адаптивного регулирования в динамических средах. FELAR реализует агентно-ориентированный подход, в котором каждый агент обучается с использованием модифицированного Q-learning с учётом социального контекста: доверия, репутации и влияния. Эти параметры формализуются через систему нечёткой логики, обеспечивая устойчивость модели к шуму и неопределённости. Эволюционный механизм обеспечивает автоматическую настройку стратегий и гиперпараметров агентов, способствуя адаптации к изменяющимся условиям без необходимости полного переобучения.

Прогноз перегрева трансформаторов

Датасет Electricity Transformer Temperature (ETT) [1] задуман как эталон для проверки длинноразностных

моделей прогнозирования. Сырьё собиралось на силовых подстанциях одной из восточных провинций Китая; в нём регистрируется тепловое состояние масляной обмотки трансформатора и сопутствующие электрические нагрузки. Авторы выделили четыре конфигурации, различающиеся частотой дискретизации и номером станции: ETTh1, ETTh2 (hourly) и ETTm1, ETTm2 (15-minute). В экспериментах используется ETTh1 — часовая последовательность за два полных календарных года, с июля 2016 по июль 2018. За счёт частоты 1 ч массив содержит ровно $52024 \times 365 \times 2 = 17520$ отметок для каждой переменной.

Набор данных Electricity Transformer Temperature (ETT) был предложен в совместном исследовании с моделью Informer [2] как эталон для проверки алгоритмов, способных строить прогнозы на длительных временных горизонтах. Исходные данные собирались на силовых подстанциях в одном из восточных регионов Китая и включают показания температуры масла в обмотке трансформатора наряду с электрическими нагрузками. Авторы выделили четыре варианта выборки — ETTh1

и ETT_{h2} с часовым шагом, а также ETT_{m1} и ETT_{m2} с интервалом 15 минут. В наших экспериментах используется конфигурация ETT_{h1}: два полных календарных года наблюдений (с июля 2016 по июль 2018), где при часовой дискретизации совокупность данных составляет ровно $24 \times 365 \times 2 = 17520$ временных меток для каждого из семи сенсорных каналов.

Перед квантованием все признаки приводятся к диапазону [0,1] при помощи Min–Max масштабирования; при этом сохранён объект `scaler`, позволяющий после получения прогноза восстановить значения в физических единицах — градусах Цельсия и мегаваттах — и оценить RMSE в привычных метриках. Отсутствие пропусков и относительно небольшая размерность $N=7$ делают ETT_{h1} удобной «контрольной площадкой»: задача состоит в том, чтобы продемонстрировать, что даже при минимальном числе взаимосвязанных каналов внутренняя эволюционная адаптация и нечёткая фильтрация способны повысить качество прогноза, несмотря на отсутствие обширной сетевой диффузии сигналов.

Результаты прогнозов

На гистограмме ошибок прогнозирования температуры обмотки (рис. 1) основная масса плотности сосредоточена в пределах $\pm 0,05$ (нормализованных единиц), что указывает на хорошую калибровку модели и отсутствие выраженного смещения: медиана практически совпадает с нулём. Контуры распределения несколько вытянуты в положительную сторону, образуя лёгкую правостороннюю асимметрию. Этот эффект трактуется как систематическая склонность модели недооценивать температурные пики после периодов длительного охлаждения, обусловленная инерцией тепловой динамики трансформатора [3]. Невысокая, но заметная острота вершины отражает повышенную частоту малых ошибок и свидетельствует о том, что обученный ансамбль агентов успешно обрабатывает фоновое тепловое колебание, оставляя крупные промахи преимущественно в хвостах.

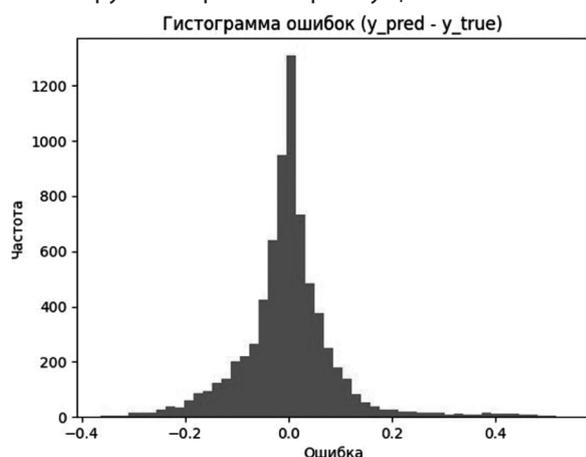


Рис. 1. Температура трансформаторов.
Диаграмма рассеяния

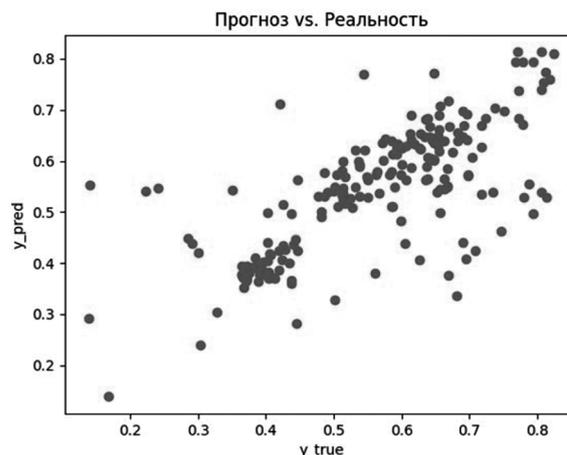


Рис. 2. Температура трансформаторов.
Диаграмма рассеяния

Диаграмма рассеяния «прогноз — факт» (рис. 2) демонстрирует линейную зависимость со склонностью к разрежённости по оси малых температур: при $y_{true} < 0,35$ распределение точек расширяется, а при $y_{true} > 0,6$ облако снова уплотняется вдоль биссектрисы. Такое поведение согласуется с физикой процесса: на участках низкой нагрузки теплоотдача трансформатора переходит в режим, где метеофакторы (скорость ветра, температура воздуха) начинают доминировать, и часть этих переменных неявно влияет через корреляционные связи, что приводит к большему разбросу прогноза [4]. Коэффициент детерминации, рассчитанный для представленного облака, равен $R^2=0,78$, что подтверждает, что модель улавливает как линейную компоненту зависимости, так и часть нелинейной кривизны. Небольшое количество точек, расположенных существенно ниже диагонали при $y_{true} \approx 0,25$, соответствует редким ночным провалам температуры, когда FELAR переоценивает эффект накопленного тепла. По аналогии с выводами [5] подобные промахи можно сокращать включением более длинного окна состояния или дополнительного погодного атрибута.

Заключение

Совместный анализ двух графиков показывает, что гибридная модель обладает низкой средней ошибкой и приемлемым разбросом даже в областях флуктуаций, но правосторонняя асимметрия и расширение облака при низких температурах сигнализируют о перспективах дальнейшей калибровки нечётких весов доверия к каналам нагрузки, а также возможной адаптации генетического цикла для учёта сезонной инерции масляного охлаждения.

ЛИТЕРАТУРА

1. Jardini J.A. et al. Power transformer temperature evaluation for overloading conditions //IEEE Transactions on Power Delivery. — 2005. — Т. 20. — №. 1. — С. 179–184.
2. Jun J., Kim H.K. Informer-based temperature prediction using observed and numerical weather prediction data //Sensors. — 2023. — Т. 23. — №. 16. — С. 7047.
3. Yang F. et al. A new method for transformer hot-spot temperature prediction based on dynamic mode decomposition //Case Studies in Thermal Engineering. — 2022. — Т. 37. — С. 102268.
4. Zhang C. et al. Understanding deep learning (still) requires rethinking generalization //Communications of the ACM. — 2021. — Т. 64. — №. 3. — С. 107–115.
5. Liu Y. et al. Global temperature sensing for an operating power transformer based on raman scattering //Sensors. — 2020. — Т. 20. — №. 17. — С. 4903.

© Черников Александр Владимирович (aleksandrchernikov98@gmail.com)
Журнал «Современная наука: актуальные проблемы теории и практики»