

Парфенов Арсений Андреевич

студент, кафедра ИУ7,

ФГАОУ ВО «Московский государственный технический университет

им. Н.Э. Баумана (национальный исследовательский университет)»,

РФ, г. Москва,

**ПРОГНОЗИРОВАНИЕ РАЗМЕРА КАСКАДА РАСПРОСТРАНЕНИЯ
ИНФОРМАЦИИ В СОЦИАЛЬНЫХ СЕТЯХ С ПОМОЩЬЮ
ГРАФОВОЙ НЕЙРОННОЙ СЕТИ TRACE**

Аннотация. В данной статье будет рассмотрена нейросетевая модель TRACE (Temporal-Relative Attention-based Cascade Estimator) для прогнозирования распространения информации в социальных сетях. Предложенная модель развивает модель CCasGNN: синусоидальное позиционное кодирование заменено обучаемыми MLP-кодировщиками позиции и времени, добавлены агрегированные каскадные признаки, пулинг уровня графа выполняется через внимание, прогнозы веток GAT и GCN объединяются обучаемым взвешенным средним. На наборе данных CasFlow Weibo (наблюдаемое окно 2 ч, горизонт 24 ч) среднее значение MSLE снизилось на 7,73 %, а стабильность обучения увеличилась на 46 %.

Ключевые слова: прогнозирование каскадов, графовые нейронные сети, GAT, GCN, механизм внимания, Weibo, MSLE.

Abstract. This paper considers a neural network model TRACE (Temporal-Relative Attention-based Cascade Estimator) for predicting information diffusion in social networks. The proposed model extends the CCasGNN model: sinusoidal positional encoding is replaced by trainable MLP encoders of position and time, aggregated cascade features are added, graph-level pooling is performed via attention, GAT and GCN branch predictions are combined via a trainable weighted average. On

the CasFlow Weibo dataset (observation window 2 h, horizon 24 h) the mean MSLE decreased by 7.73% and training stability increased by 46%.

Keywords: cascade prediction, graph neural networks, GAT, GCN, attention mechanism, Weibo, MSLE.

Актуальность. Прогнозирование размера каскада распространения сообщения востребовано для оптимизации рекомендательных систем, для своевременного локализования распространения дезинформации и для изучения социальных процессов. Формально для каскада $C_i = (V_i, E_i, P_i)$ требуется оценить прирост числа осведомлённых пользователей за горизонт Δt по наблюдаемой части каскада за интервал $[0, T]$:

$$\Delta R_i^T = |R_i^{T+\Delta t}| - |R_i^T|$$

Существующие методы используют эпидемиологические, статистические на основе самовозбуждающихся процессов, пороговые/каскадные и нейросетевые [1] модели. Первые три либо игнорируют структуру каскада распространения, либо требуют ручной параметризации. Среди нейросетевых моделей DeepCas [2] и CasCN [3] основаны на RNN и имеют большие временные затраты на обучение. CCasGNN [4] отказывается от RNN, но использует статичное синусоидальное позиционное кодирование и простое усреднение признаков узлов для предсказания уровня графа. Цель работы – повысить точность модели и стабильность обучения за счёт обучаемых кодировщиков, обогащения признаков и механизма внимания для предсказания на уровне графа.

Суть. Модель TRACE расширяет CCasGNN [4]. Архитектура состоит из двух параллельных веток – GAT [5] и GCN [6]:

$$h'_{\text{GAT}(v)}(l) = \sigma \left\langle \sum_{u \in N_v} \alpha_{uv} W \left(h'_{\text{GAT}(u)}(l-1) \parallel PE_u \right) \right\rangle$$

$$H'_{\text{GCN}}(l) = \sigma(L^{sn}(H'_{\text{GCN}}(l-1) \parallel PE)W^T + b)$$

где $L^{sn} = D^{-1/2}LD^{-1/2}$ – симметрично нормированный лапласиан, α_{uv} – коэффициент внимания, PE – позиционное кодирование. В исходной

модели PE – синусоидальная функция [7], а финальный прогноз – фиксированное взвешенное среднее веток.

В TRACE внесены пять изменений:

1. обучаемые MLP-кодировщики позиции $p \in [0,1]$ и нормированного времени активации $t \in [0,1]$ – вместо синусоидальной формулы;
2. семь агрегированных каскадных признаков (средняя/максимальная степень, логарифм от количества узлов, плотность рёбер, доля листьев, среднее и стандартное отклонение временных интервалов) конкатенируются с признаками каждого узла;
3. прогноз уровня графа выполняется с использованием механизма внимания, что позволяет адаптивно выделять информативные узлы;
4. прогнозы веток объединяются обучаемым взвешенным средним $\Delta\tilde{R}_i^T = w_1\Delta\tilde{R}_i^T(\text{GAT}) + w_2\Delta\tilde{R}_i^T(\text{GCN})$;
5. в обучении применяются косинусное затухание скорости обучения, обрезка градиентов и ранняя остановка по валидационной MSLE.

Структура модели приведена на рисунке 1.




Рисунок 1. Структура модели TRACE

В качестве функции потерь и метрики качества используется MSLE на логарифмированных значениях $\log_2(1 + y)$:

$$\text{MSLE} = \frac{1}{N} \sum_{i=1}^N (\log_2(1 + y_i) - \log_2(1 + \hat{y}_i))^2$$

Программа. Реализация выполнена на языке Python с использованием библиотек PyTorch и PyTorch Geometric. Использовался датасет CasFlow Weibo (120 тыс. каскадов из социальной сети Sina Weibo): окно наблюдения 2 ч, горизонт прогнозирования 24 ч. Выборка случайным образом

делилась на обучающую (70 %), валидационную (10 %) и тестовую (20 %) части.

Результат. Обе модели обучались с одинаковыми гиперпараметрами (таблица 1) при трёх значениях зерна генератора: 42, 43, 44. Кривые обучения приведены на рисунке 2 – TRACE стабильно показывает меньшую MSLE; на валидационной выборке преимущество сохраняется с пятнадцатой эпохи.

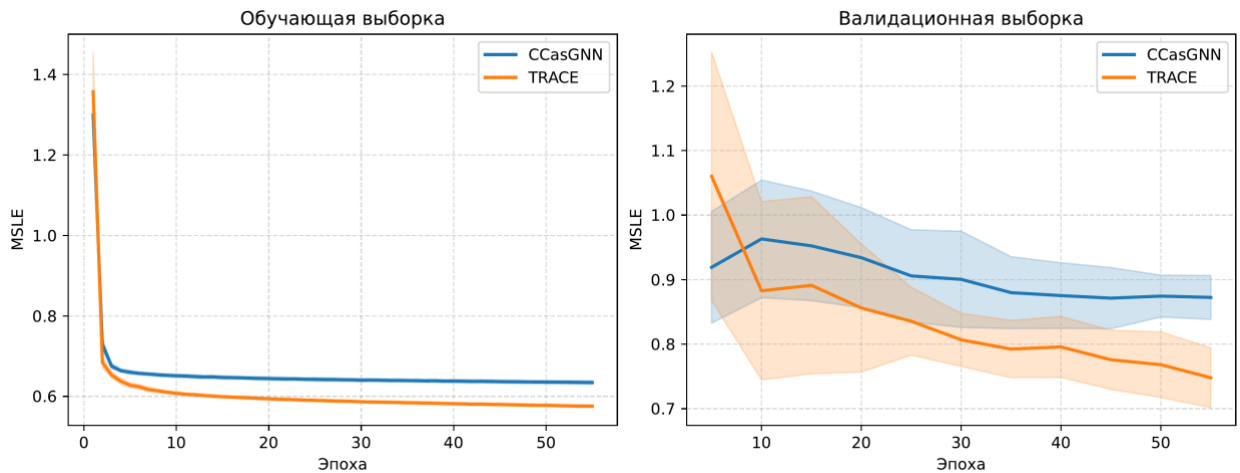


Рисунок 2. Кривые обучения CCasGNN и TRACE

Таблица 1. Общие гиперпараметры обучения

Параметр	Значение	Параметр	Значение
Эпох	100	Планировщик LR	косинус
Размер пакета	64	Минимальный LR	10^{-6}
Начальный LR	0,003	Терпение остановки	10 эпох
L2-регуляризация	0,0005	Размерность GCN	32

Таблица 2. Сравнение CCasGNN и TRACE по MSLE на тестовой выборке

Seed	CCasGNN	TRACE	Δ	Улучшение, %
42	0,7940	0,6992	+0,0948	11,94
43	0,7041	0,6716	+0,0325	4,62
44	0,7690	0,7209	+0,0480	6,24

TRACE показала меньшую ошибку во всех трёх запусках. Среднее MSLE по трём запускам: $0,697 \pm 0,025$ у TRACE против $0,756 \pm 0,046$ у CCasGNN – относительное улучшение точности 7,73 % и снижение

стандартного отклонения на 46 %. Визуальное сравнение приведено на рисунке 3.

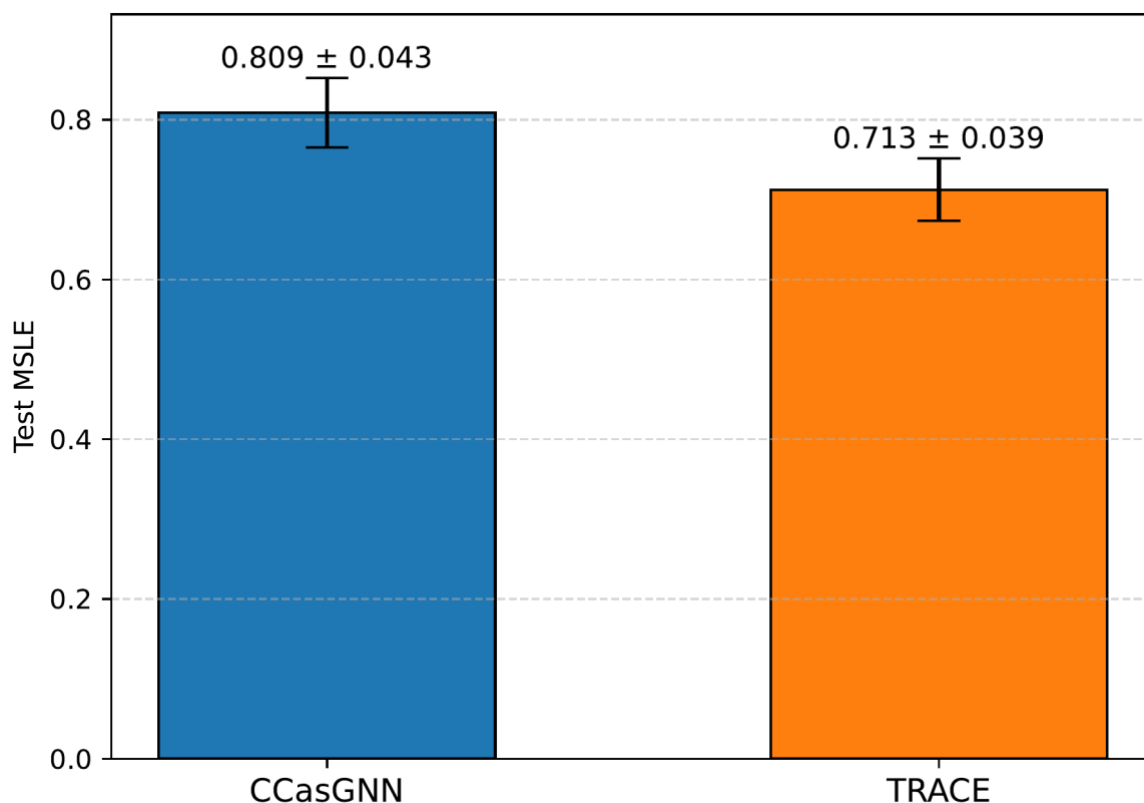


Рисунок 3. Среднее MSLE на тестовой выборке

Заключение. Предложенная модель TRACE превзошла базовую CCasGNN по метрике MSLE во всех трёх запусках на датасете CasFlow Weibo, показав улучшение точности на 7,73 % и снижение стандартного отклонения на 46 %. Планируется провести исследование на других социальных платформах и при больших горизонтах прогнозирования.

Список литературы:

1. Li M. et al. A survey on information diffusion in online social networks: Models and methods // Information. – 2017. – Т. 8, № 4. – С. 118.
2. Li C. et al. DeepCas: An end-to-end predictor of information cascades // Proc. 26th International Conference on World Wide Web. – 2017. – С. 577–586.

3. Chen X. et al. Information diffusion prediction via recurrent cascades convolution // 2019 IEEE 35th ICDE. – IEEE, 2019. – C. 770–781.
4. Wang Y., Wang X., Jia T. CCasGNN: Collaborative cascade prediction based on graph neural networks // 2022 IEEE 25th CSCWD. – IEEE, 2022. – C. 810–815.
5. Vrahatis A. G., Lazaros K., Kotsiantis S. Graph attention networks: a comprehensive review of methods and applications // Future Internet. – 2024. – T. 16, № 9. – C. 318.
6. Ren H. et al. Graph convolutional networks in language and vision: A survey // Knowledge-Based Systems. – 2022. – T. 251. – C. 109250.
7. Vaswani A. et al. Attention is all you need // Advances in Neural Information Processing Systems. – 2017. – T. 30.