АНСАМБЛЕВАЯ ПРОСТРАНСТВЕННО-ВРЕМЕННАЯ МОДЕЛЬ ВЕРОЯТНОСТНОГО ПРОГНОЗИРОВАНИЯ ГОРОДСКОЙ ПРЕСТУПНОСТИ С КОНФОРМНОЙ КАЛИБРОВКОЙ

Абдирайимов Х.Б.[1], Болтаев Ж.Э.[1], Насриддинов А.Н.[1],
Марахимов А.Р.[2], д.т.н., профессор, Худайбергенов К.К.[3], PhD
[1] Термезский государственный университет, г. Термез
[2] Ташкентский государственный технический университет им. И. Каримова, г. Ташкент
[3] Международный университет Кимё, г. Ташкент

Ключевые слова: прогнозирование преступности, пространственно-временное моделирование, каузальная маска внимания, графовое распространение, конформная калибровка, счётные данные.

Проблема. Оперативное прогнозирование городской преступности требует одновременного учёта временных закономерностей (недельная цикличность, праздники, погодные эффекты) и пространственных зависимостей (диффузия очагов, влияние городской инфраструктуры). Существующие глубокие модели страдают тремя системными ограничениями. Во-первых, архитектуры с двунаправленным вниманием допускают утечку временной информации, искусственно завышая метрики обучения. Во-вторых, большинство моделей не обеспечивают калиброванных интервалов прогноза, что лишает их операционной ценности при распределении патрульных ресурсов. В-третьих, стандартная регрессия по среднеквадратичной ошибке игнорирует счётную, сверхдисперсную и нуль-инфлированную природу данных о преступлениях: на уровне отдельных ячеек доля нулей достигает 80 %.

Предлагаемое решение. Разработана ансамблевая модель, объединяющая два комплементарных ядра: каузальное временное ядро для учёта циклических закономерностей и пространственное графовое ядро для моделирования диффузии очагов, — с вероятностными декодерами для счётных данных и постфактумной распределённо-свободной калибровкой прогнозных интервалов.

Временное ядро. Каузальный Temporal Fusion Transformer с двухслойным GRU-энкодером (H = 64) и многоголовым самовниманием, снабжённым нижнетреугольной маской, блокирующей внимание к будущим позициям:

$$Attn(Q,K,V) = Softmax\left(\frac{QK^{\top}}{\sqrt{d_k}} + M\right)V, M_{ij} = 0 \text{при} j \le i, -\infty \text{при} j > i.$$

Маска гарантирует отсутствие временной утечки на этапе обучения и сохраняет причинно-следственную структуру прогноза.

Пространственное ядро. Графовая схема APPNP на гексагональной решётке H3 со статическими POI-признаками и k-NN-расширением графа:

$$Z^{(k+1)} = (1-\alpha)\hat{A}Z^{(k)} + \alpha Z^{(0)}, K = 10, \alpha = 0{,}1,$$

где $\hat{A}$ — симметрически нормализованная матрица смежности с самопетлями. Параметры K = 10 и α = 0,1 обеспечивают распространение влияния на три–четыре

гексагональных перехода, что соответствует физической дальности криминогенной диффузии.

Декодер счётных данных и ансамбль. Для каждой ячейки на основе теста отношения правдоподобия с контролем уровня ложных открытий Бенджамини–Хохберга выбирается отрицательное биномиальное или его нуль-инфлированный вариант, учитывающий структурные нули. Точечные прогнозы двух ядер объединяются выпуклой комбинацией $\hat{y} = w_1\hat{y}^{(1)} + w_2\hat{y}^{(2)}$, $w \in \Delta^1$, с весами, минимизирующими MAE на валидационной выборке. Сплит-конформная калибровка строит интервал фиксированного уровня покрытия на основе распределения остатков; стабильность покрытия верифицируется адаптивной схемой со скользящим окном.

Результаты. Валидация на открытых данных LAPD (Лос-Анджелес, 2020–2025, более 1 млн инцидентов, 1572 активные ячейки) с хронологическим разбиением 80/10/10. Результаты сравнения с шестью базовыми методами приведены в таблице 1.

Модель	**MAE↓**	**RMSE↓**	**PAI@10↑**	**Покр.**
Seasonal Naïve	0,452	0,687	1,85	0,79
SARIMA	0,398	0,612	2,12	0,83
DCRNN	0,342	0,541	2,75	0,86
ST-GCN	0,336	0,528	2,82	0,85
Graph WaveNet	0,328	0,510	2,90	0,86
Ансамбль (наш)	**0,298**	**0,468**	**3,15**	**0,90**

Таблица 1. Результаты на данных Лос-Анджелеса (2020–2025).

Предложенная модель превосходит сильнейший базовый метод на 9,1 % по MAE (0,328 → 0,298) и достигает PAI@10 = 3,15 при эмпирическом покрытии конформного интервала 90 % при номинальном уровне 90 %. Абляционный анализ подтверждает неприводимый вклад каждой компоненты: удаление временного ядра ухудшает MAE на 7,7 %, пространственного — на 16,8 %, замена вероятностного декодера на регрессию по среднеквадратичной ошибке — на 15,8 %, снятие каузальной маски — на 17,1 % (максимальное ухудшение).

Выводы. (1) Разработана ансамблевая модель, объединяющая каузальное временное и графовое пространственное ядра с вероятностными декодерами счётных данных. (2) На реальных данных Лос-Анджелеса модель превосходит шесть современных базовых методов по точечным и ранговым метрикам при корректном учёте сверхдисперсности. (3) Абляция подтверждает неприводимый вклад каждой компоненты; каузальная маска является критическим элементом защиты от временной утечки. (4) Конформная калибровка обеспечивает эмпирическое покрытие, согласованное с номинальным уровнем, что открывает возможность операционного применения. Поведение компонент модели в условиях кросс-городского переноса исследуется в тезисе 2.

Литература

1. Lim B. et al. Temporal Fusion Transformers // Int. J. Forecasting. 2021. V. 37(4). P. 1748–1764.
2. Gasteiger J. et al. Predict then propagate // Proc. ICLR. 2019.
3. Wu Z. et al. Graph WaveNet // Proc. IJCAI. 2019. P. 1907–1913.
4. Romano Y. et al. Conformalized quantile regression // NeurIPS. 2019. V. 32.