

УДК 004.8

Шишло Артём Андреевич, магистрант, МИРЭА — Российский технологический университет, Россия, г. Москва

Терин Денис Владимирович, кандидат физико-математических наук, доцент, советник директора Главного межрегионального центра Росстата, Россия, г. Москва

ПРОГНОЗИРОВАНИЕ ПЛОТНОСТИ ВОЗДУШНОГО ТРАФИКА ДЛЯ ЗАДАЧ ДИНАМИЧЕСКОГО КОНФИГУРИРОВАНИЯ ВОЗДУШНОГО ПРОСТРАНСТВА

Аннотация

В работе рассматривается задача краткосрочного прогнозирования плотности воздушного трафика по секторам для задач динамического конфигурирования воздушного пространства. Для её решения предлагается архитектура ST-GAT — графовая нейронная сеть с механизмом внимания и рекуррентным временным блоком. Текущая загрузка сектора определяется сразу двумя факторами: его недавней загрузкой и состоянием соседних секторов в тот же момент времени. Архитектура ST-GAT учитывает обе эти составляющие в едином пространственно-временном слое. Сетка секторов и граф связности между ними строятся напрямую по открытым данным ADS-B проекта OpenSky Network, что обеспечивает воспроизводимость методики и позволяет применять её в других регионах. Чтобы понять, в каких условиях графовая структура работает лучше всего, ST-GAT сравнивается с тремя базовыми архитектурами LSTM, ConvLSTM и GCN-LSTM. Эксперимент проводится в четырёх режимах с двумя объёмами обучения (248 и 14 суток) и двумя уровнями детализации сетки (24 и 48 секторов). Преимущество ST-GAT ярче проявляется при плотной сетке секторов и коротком обучающем периоде, то есть в тех условиях, в которых концепция DAC обычно применяется на

практике. В таких сценариях модель опережает остальные с заметным отрывом. При этом на больших выборках и при грубой сетке ST-GAT не теряет конкурентоспособности и работает на уровне лучших моделей.

Annotation

The paper deals with short-term per-sector forecasting of air traffic density for tasks of dynamic airspace configuration. To address this problem, the ST-GAT architecture is proposed — a graph neural network with an attention mechanism and a recurrent temporal block. The current load of a sector is determined by two factors at once: its recent density values and the state of the neighbouring sectors at the same moment in time. ST-GAT captures both these components within a single spatio-temporal layer. The sector grid and the connectivity graph between sectors are built directly from open ADS-B data of the OpenSky Network, which makes the method reproducible. To understand when the graph structure performs best, ST-GAT is compared with three baseline architectures — LSTM, ConvLSTM and GCN-LSTM. The experiment runs in four regimes with two training-window sizes (248 and 14 days) and two grid resolutions (24 and 48 sectors). The advantage of ST-GAT is most pronounced with a dense sector grid and a short training window, i.e. under the conditions in which the DAC concept is typically applied in practice. In such scenarios the model outperforms the others by a noticeable margin. At the same time, on larger samples and with a coarser grid ST-GAT does not lose competitiveness and performs on par with the best models.

Ключевые слова: прогнозирование плотности воздушного трафика, графовая нейронная сеть, механизм внимания, динамическое конфигурирование воздушного пространства, OpenSky Network, ADS-B, секторизация.

Keywords: air traffic density forecasting, graph neural network, attention mechanism, dynamic airspace configuration, OpenSky Network, ADS-B, sectorization.

Введение

Современная система управления воздушным движением работает в условиях высокой нагрузки. Для удобства управления воздушное

пространство разделено на сектора — относительно небольшие зоны, за каждой из которых следит отдельный диспетчер. Нагрузка между секторами распределена неравномерно. Одни сектора пропускают большую часть трафика, другие почти пусты. Уровень загрузки конкретного сектора в каждый момент времени зависит от расписания рейсов, погоды, временных ограничений и общей пропускной способности инфраструктуры [1].

Чтобы предупреждать перегрузки секторов заранее, ICAO и EUROCONTROL развивают концепцию динамического конфигурирования воздушного пространства (Dynamic Airspace Configuration, DAC). В её рамках границы секторов могут изменяться в зависимости от прогнозируемой загрузки на горизонте 10-60 минут [2, 3]. Чтобы такая концепция работала, нужен точный краткосрочный прогноз числа воздушных судов в каждом секторе.

Для решения этой задачи предлагается архитектура ST-GAT — пространственно-временная графовая нейронная сеть с механизмом внимания. Текущая загрузка сектора определяется сразу двумя факторами: его недавними значениями плотности и состоянием соседних секторов в тот же момент времени. Архитектура ST-GAT учитывает обе эти составляющие в едином слое: графовая часть с обучаемыми коэффициентами внимания отвечает за пространственное взаимодействие, а рекуррентный блок — за временную динамику.

Дополнительной особенностью предлагаемого подхода является то, что сетка секторов и граф связности между ними строятся напрямую по реальным траекториям воздушных судов из открытых ADS-B-данных проекта OpenSky Network [4, 5]. Это снимает зависимость от закрытых нормативных источников и позволяет применять методику в любых регионах без существенных архитектурных изменений.

Чтобы понять, в каких условиях графовая структура работает лучше всего, ST-GAT сравнивается с тремя стандартными архитектурами LSTM,

ConvLSTM и GCN-LSTM при разных объёмах обучения и разных уровнях детализации сетки секторов.

Модель

Целевой переменной служит плотность сектора $\rho_{i,t}$, равная числу уникальных воздушных судов в секторе i на десятиминутном интервале t . Прогноз строится сразу для всех секторов с горизонтом 30 минут.

Каждый сектор в каждый момент времени описывается вектором из шести признаков. В этот вектор входят логарифмированная плотность, средняя путевая скорость, средняя барометрическая высота, средний вертикальный темп, доля набирающих высоту судов и доля судов в нижнем эшелоне. Граф связности $G = (V, E)$ между секторами задаётся реальными переходами воздушных судов. Каждое изменение секторного идентификатора в хронологически упорядоченной траектории одного воздушного судна учитывается как одно ребро.

Архитектура ST-GAT состоит из двух графовых слоёв с многоголовым вниманием [6] и одного рекуррентного слоя GRU [7]. На каждом слое внимания для пары соседних секторов $(i, j) \in E$ вычисляется коэффициент внимания $\alpha_{ij}^{(k)}$ по формуле (1):

$$\alpha_{ij}^{(k)} = \frac{\exp\left(\text{LeakyReLU}\left(\mathbf{a}_k^\top [W^{(k)}\mathbf{h}_i \parallel W^{(k)}\mathbf{h}_j]\right)\right)}{\sum_{l \in \mathcal{N}_i} \exp\left(\text{LeakyReLU}\left(\mathbf{a}_k^\top [W^{(k)}\mathbf{h}_i \parallel W^{(k)}\mathbf{h}_l]\right)\right)}, \quad (1)$$

где \mathbf{h}_i — текущее представление сектора i ;

e_{ij} — $W^{(k)}$ и \mathbf{a}_k — обучаемая матрица проекции и обучаемый вектор внимания на k -й голове;

\mathcal{N}_i — множество соседей сектора i в графе;

Знак \parallel обозначает конкатенацию векторов;

Софтмакс в знаменателе нормирует веса по соседям сектора.

Новое представление сектора получается агрегированием признаков соседей с весами $\alpha_{ij}^{(k)}$ и конкатенацией результатов K голов внимания по формуле (2):

$$h'_i = \parallel_{k=1}^K \sigma \left(\sum_{j \in \mathcal{N}_i} \alpha_{ij}^{(k)} W^{(k)} h_j \right) \quad (2)$$

Выходы графовых слоёв за шесть последовательных интервалов подаются в GRU, последнее скрытое состояние линейно отображается в вектор прогноза для всех секторов на три шага вперёд. В качестве сравнительных моделей используются LSTM на плоском векторе признаков всех секторов, ConvLSTM на регулярной сетке покрытия [8] и GCN-LSTM с двумя графовыми свёртками [9]. В качестве референтной модели применяется persistence-прогноз — повторение последнего наблюдаемого значения плотности.

Данные и схема экспериментов

Используются открытые недельные снимки ADS-B-данных проекта OpenSky Network за период 2017-2022 годов [4, 5]. Регион эксперимента — участок Центральной Европы с координатами 47-55° северной широты и 2-14° восточной долготы. Эта зона охватывает воздушное пространство Германии, Бенилюкса, Швейцарии и севера Франции. Покрытие приёмников OpenSky здесь высокое, а трафик — один из самых интенсивных в Европе. Высотный фильтр от 1524 м исключает наземное движение. Шаг агрегирования по времени равен 10 минутам.

Сетка секторов формируется автоматически. На облаке точек манёвров (вертикальная скорость более 0,5 м/с или путевая скорость менее 200 м/с) проводится кластеризация методом K-средних. По центрам кластеров

строится диаграмма Вороного, обрезанная по границам региона. Полученные сетки для двух уровней детализации показаны на Рисунке 1:

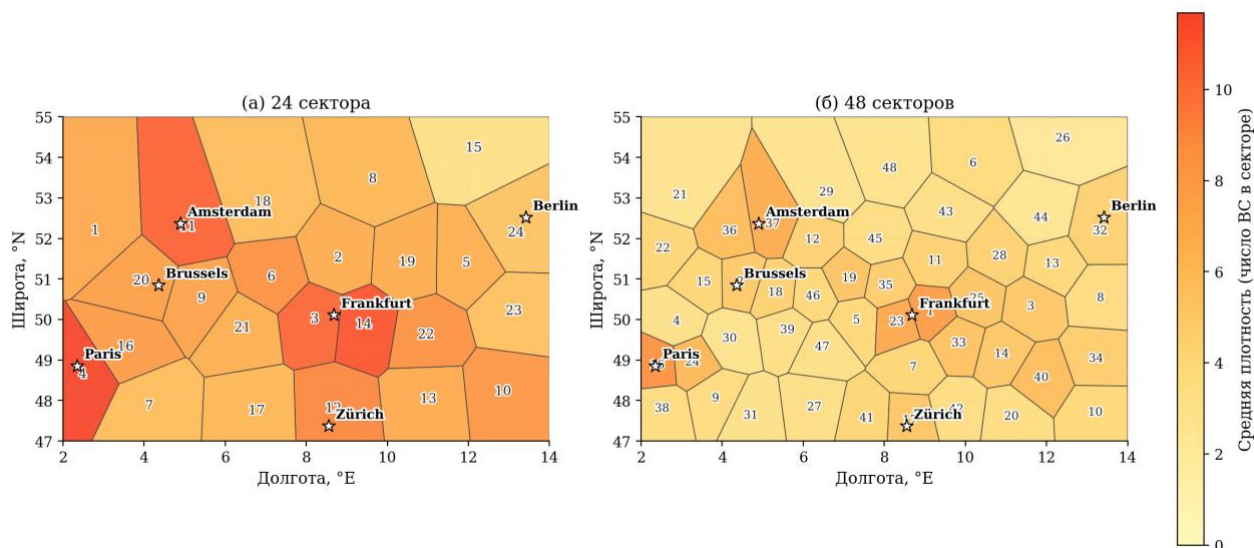


Рисунок 1 — Сетки секторов, построенные методом К-средних

На Рисунке 1 видно, что наибольшая плотность трафика приходится на район Франкфурта и Бенилюкса, а периферийные секторы у Парижа и Цюриха значительно менее загружены. Цифры на полигонах — порядковые номера секторов.

Почему два уровня детализации сетки

Сетка из 24 секторов соответствует масштабу крупного европейского функционального блока. Средняя плотность одного сектора в этой сетке составляет десятки воздушных судов на 10-минутный интервал — сигнал крупный и относительно гладкий. Сетка из 48 секторов примерно вдвое детальнее и ближе к размеру одного диспетчерского сектора. Здесь средняя плотность сектора ниже, и целевая переменная становится более зашумлённой. Зато пространственная структура графа богаче, и графовые модели получают больше осмысленной информации.

Почему два объёма выборки

Первый режим использует все 248 суток наблюдений из архива OpenSky. Это исследовательская выборка, на которой модели выходят на свой потолок

возможностей. Второй режим — 14 последовательных понедельников 2021 года. Это операционно-релевантный объём, то есть типичное окно, в котором работает диспетчер, когда расписание, сезон или регуляторные ограничения изменились и накопленных свежих данных пока немного. Сочетание этих двух режимов с двумя сетками даёт четыре экспериментальные ячейки.

Все модели обучаются по одинаковой схеме: оптимизатор Adam, скорость обучения $3 \cdot 10^{-3}$, dropout 0,3, размер батча 64, 40 эпох с ранней остановкой по валидационной ошибке, среднеквадратичная функция потерь. Разбиение каждой выборки на обучающую, валидационную и тестовую части — хронологическое, в пропорции 70 / 15 / 15.

Результаты

Качество прогноза оценивается четырьмя метриками: средняя абсолютная ошибка (MAE), корень среднеквадратичной ошибки (RMSE), средняя абсолютная процентная ошибка (MAPE) и коэффициент детерминации R^2 . Сводные результаты для четырёх режимов приведены в Таблицах 1-4. В каждой таблице модели упорядочены по возрастанию MAE.

Таблица 1 — 248 суток × 24 сектора

| Модель | MAE | RMSE | MAPE, % | R^2 |
|---------------|--------------|--------------|-------------|--------------|
| ST-GAT | 4,349 | 5,901 | 25,2 | 0,882 |
| LSTM | 4,375 | 5,872 | 25,6 | 0,883 |
| GCN-LSTM | 4,479 | 6,034 | 27,4 | 0,876 |
| ConvLSTM | 4,632 | 6,242 | 28,3 | 0,868 |
| Persistence | 4,925 | 6,700 | 30,9 | 0,848 |

Таблица 2 — 248 суток × 48 секторов

| Модель | MAE | RMSE | MAPE, % | R^2 |
|---------------|--------------|--------------|-------------|--------------|
| ST-GAT | 3,382 | 4,629 | 30,1 | 0,813 |
| LSTM | 3,371 | 4,643 | 30,0 | 0,812 |
| GCN-LSTM | 3,466 | 4,740 | 31,6 | 0,804 |
| ConvLSTM | 3,527 | 4,822 | 31,7 | 0,797 |
| Persistence | 3,816 | 5,196 | 38,1 | 0,764 |

Таблица 3 — 14 суток × 24 сектора

| Модель | MAE | RMSE | MAPE, % | R^2 |
|---------------|--------------|--------------|-------------|--------------|
| ST-GAT | 2,613 | 3,507 | 38,4 | 0,665 |
| LSTM | 2,613 | 3,502 | 37,9 | 0,666 |

| | | | | |
|-------------|-------|-------|------|-------|
| GCN-LSTM | 2,619 | 3,491 | 39,4 | 0,668 |
| ConvLSTM | 2,723 | 3,683 | 40,3 | 0,630 |
| Persistence | 3,043 | 4,098 | 45,9 | 0,543 |

Таблица 4 — 14 суток × 48 секторов

| Модель | MAE | RMSE | MAPE, % | R ² |
|---------------|--------------|--------------|-------------|----------------|
| ST-GAT | 1,942 | 2,602 | 45,8 | 0,570 |
| GCN-LSTM | 1,968 | 2,649 | 45,1 | 0,555 |
| LSTM | 1,969 | 2,646 | 44,8 | 0,556 |
| ConvLSTM | 2,027 | 2,735 | 45,7 | 0,525 |
| Persistence | 2,351 | 3,187 | 58,1 | 0,355 |

Чтобы увидеть общую картину сразу для всех четырёх режимов, сводное сравнение моделей по MAE и R² показано на Рисунке 2. На нём хорошо видно, что все модели уверенно превосходят persistence-прогноз по MAE на 6-22 % и по R² на 4-22 процентных пункта. Это означает, что построенный по ADS-B вектор признаков несёт информацию, которой persistence-модель не пользуется.

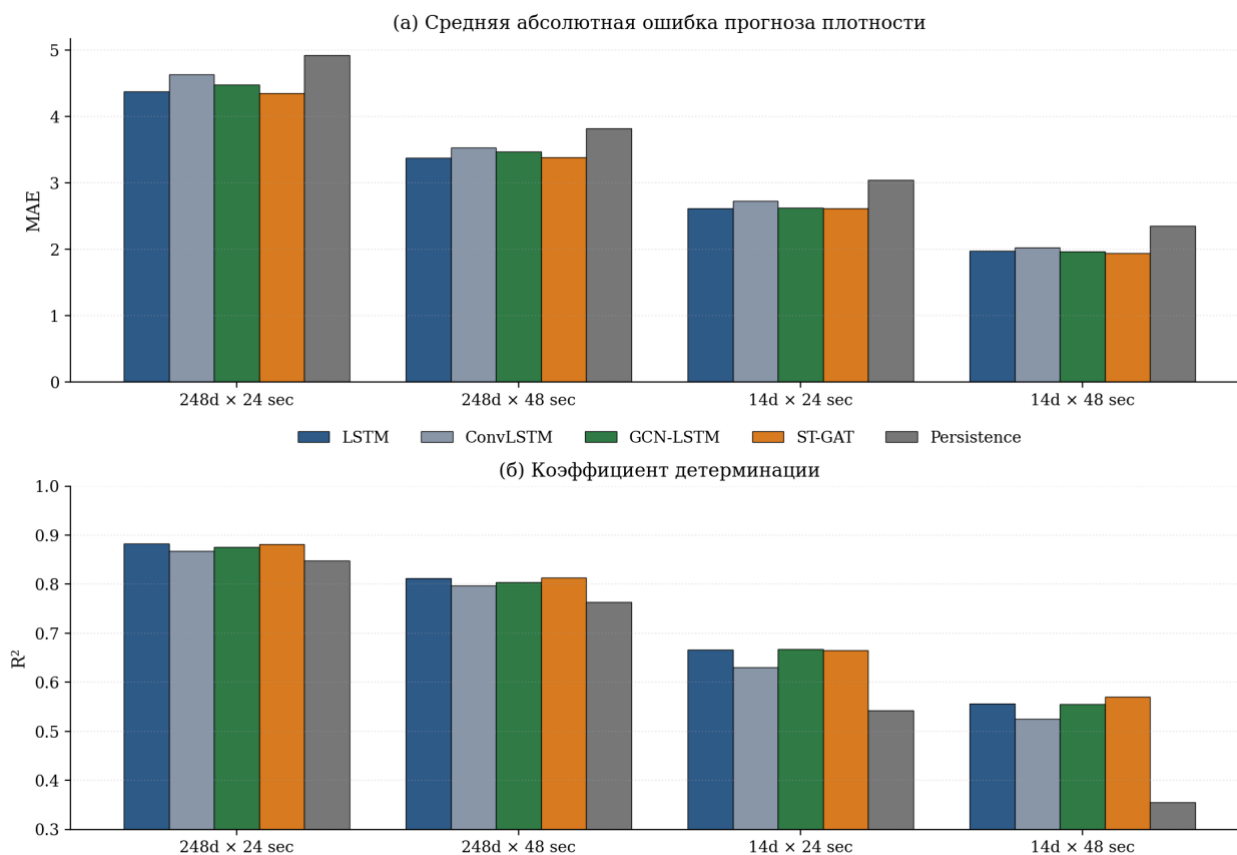


Рисунок 2 — Сравнение четырёх моделей и persistence-прогноза

Динамика обучения четырёх моделей в двух характерных режимах приведена на Рисунке 3. На полной выборке (а) все модели сходятся к близкому уровню валидационной ошибки. На ограниченной выборке (б) ST-GAT раньше остальных опускается к нижней границе диапазона и удерживается на ней до конца обучения.

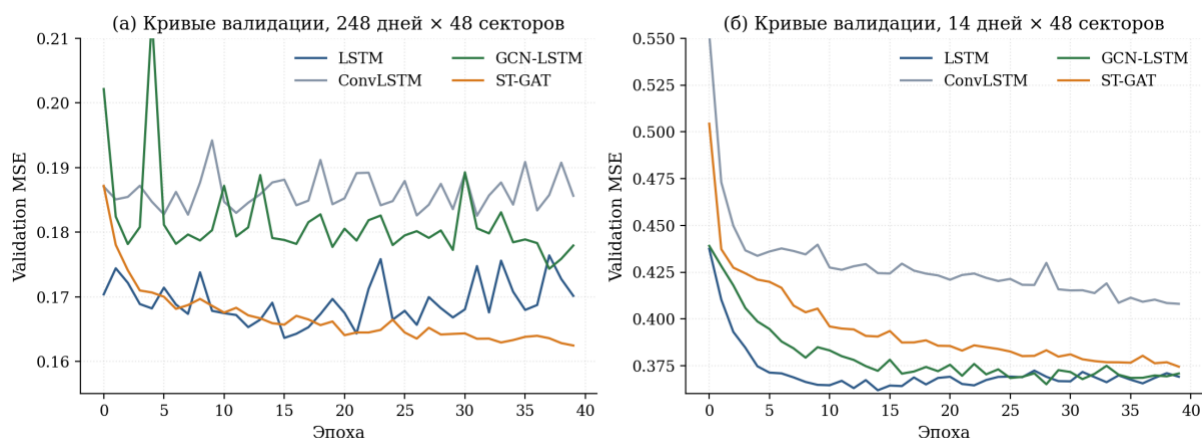


Рисунок 3 — Кривые валидационной ошибки при обучении

Качественную картину прогноза можно увидеть на Рисунке 4. На нём показан 30-минутный прогноз для одного из загруженных секторов режима 14 суток \times 48 секторов. Видно, что прогноз ST-GAT точнее восстанавливает амплитуду и моменты пиков плотности, чем прогноз LSTM, особенно в часы максимальной нагрузки.

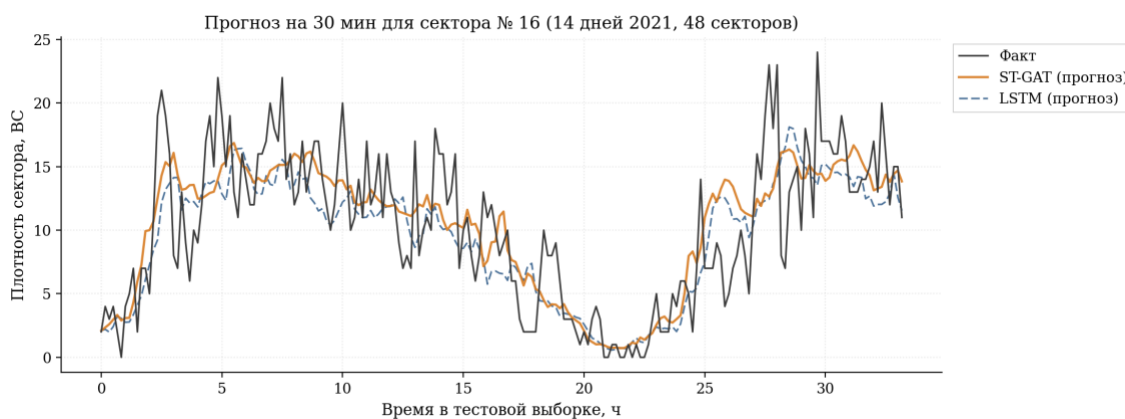


Рисунок 4 — Прогноз плотности на 30 минут для одного из секторов

Опираясь на рассмотренные количественные метрики и качественный пример прогноза, перейдём к их анализу и интерпретации.

Обсуждение результатов

Ключевая закономерность видна при сопоставлении четырёх таблиц. В режиме большой выборки и грубой сетки (Таблица 1) ST-GAT и LSTM показывают практически одинаковые значения MAE и R^2 . При увеличении детализации до 48 секторов (Таблица 2) обе модели остаются близкими, но ST-GAT уже опережает LSTM по RMSE и R^2 . В режиме ограниченной выборки и грубой сетки (Таблица 3) различия между всеми моделями становятся несущественными — данных слишком мало, чтобы какая-либо архитектура получила преимущество. И наконец, в режиме ограниченной выборки и детальной сетки (Таблица 4) ST-GAT занимает первое место сразу по трём метрикам — MAE, RMSE и R^2 — и опережает ближайший аналог GCN-LSTM на 1,3 % MAE.

Этот эффект объясняется ролью графовой структуры. В плоской LSTM число входных признаков растёт пропорционально числу секторов: при переходе с 24 секторов на 48 размер вектора увеличивается с 144 до 288. На большой выборке у LSTM достаточно примеров, чтобы разобраться в этом увеличенном пространстве. Но если данных мало, плоская модель начинает переобучаться. ST-GAT же делит параметры между секторами через общие матрицы внимания и сглаживает шум за счёт агрегирования признаков соседей. Графовая структура выступает регуляризатором, и его роль становится заметной именно там, где данных меньше, а пространственная структура богаче.

С практической точки зрения наиболее интересен именно режим 14 суток \times 48 секторов. Он ближе всего к тому, как концепция DAC применяется в реальной работе: на короткое окно свежих наблюдений и на достаточно подробную сетку секторов.

Дополнительным практическим преимуществом ST-GAT является интерпретируемость обученных коэффициентов внимания. Они дают оператору управления воздушным движением прямую количественную оценку взаимного влияния секторов и могут использоваться при принятии решений о слиянии или разделении секторов в задаче DAC.

Заключение

Предложена пространственно-временная графовая нейронная сеть с механизмом внимания ST-GAT для прогнозирования плотности воздушного трафика на горизонте 30 минут. Сетка секторов и граф их связности построены автоматически по открытым ADS-B-данным проекта OpenSky Network, что обеспечивает воспроизводимость методики. На сравнительном эксперименте в четырёх режимах ST-GAT занимает первое место по средней абсолютной ошибке, причём её относительное превосходство наиболее заметно при ограниченном объёме выборки и детальной сетке секторов, то есть в тех условиях, в которых концепция DAC обычно применяется на практике.

Литература

1. International Civil Aviation Organization. Air Traffic Management Automation System Implementation and Guidance Document. Edition 1.5. — ICAO, 2025. — 115 p.
2. EUROCONTROL. ATFCM Operations Manual: Network Manager. Edition MAINT-2. — EUROCONTROL, 2024. — 289 p.
3. Criscuolo P., Perrotta L., Di Bitonto G., Grani G. Enhanced Dynamic Airspace Configuration Algorithm // 14th SESAR Innovation Days. — SESAR Joint Undertaking, 2024. — 8 p.
4. Schäfer M., Strohmeier M., Lenders V., Martinovic I., Wilhelm M. Bringing Up OpenSky: A Large-scale ADS-B Sensor Network for Research // Proceedings of the 13th International Symposium on Information Processing in Sensor Networks (IPSN). — Berlin: ACM/IEEE, 2014. — P. 83–94.
5. Schäfer M., Olive X., Strohmeier M., Smith M., Martinovic I., Lenders V. Crowdsourced Air Traffic Data from the OpenSky Network 2019–2020 // Earth System Science Data. — 2021. — Vol. 13, № 2. — P. 357–366.
6. Veličković P., Cucurull G., Casanova A., Romero A., Liò P., Bengio Y. Graph Attention Networks // Proceedings of the International Conference on Learning Representations (ICLR). — 2018.
7. Cho K., van Merriënboer B., Gulcehre C., Bahdanau D., Bougares F., Schwenk H., Bengio Y. Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation // Proceedings of the Conference on Empirical Methods in Natural Language Processing (EMNLP). — Doha: ACL, 2014. — P. 1724–1734.
8. Shi X., Chen Z., Wang H., Yeung D.-Y., Wong W.-K., Woo W.-C. Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting // Advances in Neural Information Processing Systems (NeurIPS). — 2015. — P. 802–810.
9. Kipf T. N., Welling M. Semi-Supervised Classification with Graph Convolutional Networks // Proceedings of the International Conference on Learning Representations (ICLR). — 2017.

References

1. International Civil Aviation Organization. Air Traffic Management Automation System Implementation and Guidance Document. Edition 1.5. — ICAO, 2025. — 115 p.
2. EUROCONTROL. ATFCM Operations Manual: Network Manager. Edition MAINT-2. — EUROCONTROL, 2024. — 289 p.
3. Criscuolo P., Perrotta L., Di Bitonto G., Grani G. Enhanced Dynamic Airspace Configuration Algorithm // 14th SESAR Innovation Days. — SESAR Joint Undertaking, 2024. — 8 p.
4. Schäfer M., Strohmeier M., Lenders V., Martinovic I., Wilhelm M. Bringing Up OpenSky: A Large-scale ADS-B Sensor Network for Research // Proceedings of the 13th International Symposium on Information Processing in Sensor Networks (IPSN). — Berlin: ACM/IEEE, 2014. — P. 83–94.
5. Schäfer M., Olive X., Strohmeier M., Smith M., Martinovic I., Lenders V. Crowdsourced Air Traffic Data from the OpenSky Network 2019–2020 // Earth System Science Data. — 2021. — Vol. 13, № 2. — P. 357–366.
6. Veličković P., Cucurull G., Casanova A., Romero A., Liò P., Bengio Y. Graph Attention Networks // Proceedings of the International Conference on Learning Representations (ICLR). — 2018.
7. Cho K., van Merriënboer B., Gulcehre C., Bahdanau D., Bougares F., Schwenk H., Bengio Y. Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation // Proceedings of the Conference on Empirical Methods in Natural Language Processing (EMNLP). — Doha: ACL, 2014. — P. 1724–1734.
8. Shi X., Chen Z., Wang H., Yeung D.-Y., Wong W.-K., Woo W.-C. Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting // Advances in Neural Information Processing Systems (NeurIPS). — 2015. — P. 802–810.
9. Kipf T. N., Welling M. Semi-Supervised Classification with Graph Convolutional Networks // Proceedings of the International Conference on Learning Representations (ICLR). — 2017.