

3) Курносова Е.А. Оценка эффективности функционирования аэрокосмических кластеров / Е.А. Курносова // Вестник Самарского государственного университета. Серия: Экономика и управление. – 2015. – № 9-2(131). – С. 97-105.

4) Никитская Е.Ф., Валишвили М.А. Международные тенденции развития сетевых инновационных систем в цифровой экономике // Экономические отношения. - 2021. - № 4. - с. 689-712.

5) Оруч Т.А. Инновационная деятельность предприятий и ее роль в импортозамещении / Т.А. Оруч // Бюллетень транспортной информации. – 2021. – № 7(313). – С. 26-34.

6) Шаталова Т.Н., Богатырев В.Д., Чебыкина М.В., Миронова Е.А. Методологические основы регионального инновационного развития и управления экономическими процессами промышленного предприятия Самара: Самара, 2023. 205 с.

ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ ВРЕМЕННЫХ ПАТТЕРНОВ ЗАДЕРЖЕК АВИАРЕЙСОВ С ПРИМЕНЕНИЕМ ГИБРИДНОЙ НЕЙРОСЕТЕВОЙ АРХИТЕКТУРЫ НА ОСНОВЕ BiLSTM И MULTI-HEAD ATTENTION

**Митюнина Варвара Юрьевна, Чуткина Маргарита
Игоревна, Грансон Алёна Олеговна¹**

Российская Федерация, г. Москва, Московский
государственный технический университет гражданской авиации
(МГТУ ГА).

Аннотация: В статье представлен инновационный подход к прогнозированию задержек авиарейсов в гражданской авиации на основе гибридной нейросетевой архитектуры, сочетающей двунаправленные рекуррентные слои (BiLSTM) и механизм множественного внимания (Multi-Head Attention). В качестве входных

¹Студенты 4 курса бакалавриата Московского государственного технического университета гражданской авиации. Научный руководитель: Гаранин С.А., кандидат технических наук, доцент кафедры вычислительных машин, комплексов, систем и сетей Московского государственного технического университета гражданской авиации (Garanin S.A., Candidate of Technical Sciences Associate Professor of the Department of Computer Machines, Complexes, Systems and Networks at Moscow State Technical University of Civil Aviation).

данных используются временные, логистические, операционные и погодные признаки, обогащённые с помощью внешних API (Geoapify и Open-Meteo). Подбор гиперпараметров архитектуры осуществляется автоматически с помощью фреймворка Optuna.

Ключевые слова: интеллектуальные системы, временные ряды, BiLSTM, Multi-Head Attention, Data Science, погодные ковариаты, Optuna, машинное обучение.

INTELLIGENT ANALYSIS OF TEMPORAL PATTERNS IN FLIGHT DELAYS USING A HYBRID NEURAL NETWORK ARCHITECTURE BASED ON BILSTM AND MULTI-HEAD ATTENTION

Mityunina V.Yu., Chutkina M.I., Granson A.O.

Russian Federation, Moscow, Moscow State Technical University of
Civil Aviation.

Abstract: The paper presents an innovative approach to forecasting flight delays in civil aviation based on a hybrid neural network architecture combining bidirectional recurrent layers (BiLSTM) and a multi-head attention mechanism. The input data consist of temporal, logistical, operational, and weather-related features, enriched via external APIs (Geoapify and Open-Meteo). Hyperparameter optimization for both the architecture and training process is performed automatically using the Optuna framework.

Key words: intelligent systems, time series, BiLSTM, Multi-Head Attention, Data Science, weather covariates, Optuna, machine learning.

Введение

Задержки авиарейсов – одна из самых острых проблем в современной авиационной логистике. Они не только нарушают планы пассажиров, но и влекут за собой каскадные сбои в расписании, увеличение операционных издержек и снижение доверия к перевозчику. Традиционные методы прогнозирования, основанные на статистике или простых регрессионных моделях, зачастую не справляются с нелинейной природой задержек, особенно когда речь идёт о редких, но критически важных событиях [4]. Например, многочасовых опозданиях из-за шторма или технической неисправности.

В этой работе мы предлагаем подход, объединяющий временные, логистические и погодные признаки в единую модель на основе гибридной нейросетевой архитектуры. Основная идея –

рассматривать каждый маршрут как временной ряд и использовать комбинацию двунаправленных рекуррентных слоёв (BiLSTM) и механизма Multi-Head Attention для выявления скрытых паттернов, предшествующих задержкам. Для подбора оптимальных гиперпараметров применяется автоматизированный поиск с помощью библиотеки Optuna. Цель – предсказывать задержку прибытия в минутах с минимальной ошибкой, особенно в тех случаях, когда она действительно влияет на качество обслуживания.

Причины задержек лежат не только в наблюдаемых внешних или операционных факторах. При использовании даже самого совершенного радиоэлектронного оборудования могут возникать ситуации, когда, эксплуатируя оборудование строго по показаниям приборов, специалист выводит его далеко за пределы допусков. Именно это приводит к тому, что исправно работающие приборы начинают давать неверные показания, поскольку они воспринимают помехи в качестве полезного сигнала, на основании которого должны приниматься управленческие решения [3]. Подобные скрытые сбои, хотя и редки, могут вызывать каскадные задержки – особенно в условиях высокой загрузки воздушного пространства.

Ход исследования

В работе используется открытый датасет «US Domestic Flights Delay Prediction (2016–2017)» в формате CSV. Он содержит подробную информацию о внутренних рейсах США за два года.

Целевая переменная: *ArrDelayMinutes* – количество минут задержки прибытия (включая нули и отрицательные значения, если рейс прибыл раньше срока).

Распределение целевой переменной демонстрирует характерную для авиазадержек картину: подавляющее большинство рейсов выполняется без опозданий или с минимальной задержкой (много нулей и малых значений), но при этом наблюдается длинный правый хвост – редкие, но значительные задержки. Такое распределение напоминает пуассоновское и накладывает особые требования на модель: она не должна «игнорировать» редкие события, так как именно они чаще всего вызывают серьёзные последствия.

Поскольку задержки обладают ярко выраженной временной структурой, данные преобразуются в временные ряды. Для каждого маршрута (например, JFK → LAX) формируются последовательности фиксированной длины – по 10 последовательных рейсов. Каждая такая последовательность становится обучающим примером: на вход

подаётся вектор признаков за 10 предыдущих рейсов, а на выходе модель должна предсказать задержку следующего [1].

Предобработка включает несколько этапов:

1. Преобразование временных полей (извлечение часа отправления и т.п.).

2. Кодирование категориальных признаков (аэропортов, штатов и авиакомпаний) в числовые представления.

3. Обогащение погодными данными: для каждого аэропорта отправления по его названию определяются географические координаты с помощью сервиса Georify. Затем по координатам и дате рейса запрашиваются почасовые метеоданные из Open-Meteo (температура, осадки, скорость ветра).

4. Удаление записей с пропущенными погодными или ключевыми логистическими данными – чтобы не вносить шум.

5. Стандартизация числовых признаков для устойчивой сходимости нейросети.

6. Формирование скользящих окон и разделение на обучающую и тестовую выборки.

Для оптимизации запросов к внешним API реализовано кеширование: координаты аэропортов сохраняются после первого запроса, а обращения к Open-Meteo выполняются с учётом лимитов.

Задача формулируется как многомерное прогнозирование временных рядов: по последовательности векторов признаков длиной 10 шагов предсказать скалярное значение – задержку следующего рейса.

Архитектура модели построена как гибрид двух подходов:

BiLSTM (Bidirectional Long Short-Term Memory) – позволяет улавливать долгосрочные зависимости как в прошлом, так и в будущем относительно текущего момента (в рамках окна).

Multi-Head Attention – помогает модели фокусироваться на наиболее релевантных временных шагах, особенно полезно при наличии редких аномалий.

Последовательность признаков проходит через два слоя BiLSTM с возвратом последовательности (`return_sequences=True`), затем подаётся на вход механизму внимания. Результат внимания складывается с исходным представлением и нормализуется через *LayerNormalization*. Далее берётся только последний временной шаг, применяется *dropout* для регуляризации, и финальный линейный слой выдаёт предсказание в минутах [5].

Функция потерь – среднеквадратичная ошибка (MSE). Несмотря на дисбаланс в распределении задержек, MSE выбрана намеренно: она чувствительна к крупным отклонениям, что заставляет модель «замечать» редкие, но значимые события. В качестве оптимизатора используется Adam, обеспечивающий стабильную и быструю сходимость. Функция создания модели выглядит так:

```
def build_model(seq_len, feat_count, units1, units2, heads,
dropout=0.2):
    inp = Input(shape=(seq_len, feat_count))
    x = Bidirectional(LSTM(units1, return_sequences=True))(inp)
    x = Bidirectional(LSTM(units2, return_sequences=True))(x)
    attn = MultiHeadAttention(num_heads=heads, key_dim=units2)(x, x)
    x = LayerNormalization()(x + attn)
    x = x[:, -1, :]
    x = Dropout(dropout)(x)
    out = Dense(1)(x)
    model = Model(inp, out)
    model.compile('adam', 'mse', metrics=['mae'])
    return model
```

Подбор гиперпараметров (число нейронов в LSTM-слоях, количество голов внимания, скорость обучения, размер батча и число эпох) осуществляется автоматически с помощью Optuna. Целевой метрикой при оптимизации служит RMSE на валидационной выборке [5]. После завершения поиска лучшая конфигурация используется для финального обучения на полной обучающей выборке.

Полученные результаты и выводы (Заключение)

Модель обучалась на данных, разделённых в соотношении 80/20 (обучение/тест). В процессе оптимизации Optuna провела более 50 испытаний, и лучшая конфигурация показала следующие результаты:

Минимальное значение MSE на валидационной выборке: 28.1 (достигнуто на 46-й эпохе), что соответствует $RMSE \approx 5.3$ минуты.

На обучающей выборке MSE достигла 12.6 ($RMSE \approx 3.6$ минуты) к 50-й эпохе.

Это означает, что в среднем модель ошибается на около 5 минут при прогнозировании задержки на ранее не виденных данных. График обучения (Рисунок 1) демонстрирует отсутствие переобучения до 46-й эпохи, после чего валидационная ошибка стабилизируется.

Хотя в текущей версии проекта прямое сравнение с бейзлайнами (например, XGBoost или простой LSTM) не проводилось, предварительные тесты показали, что гибридная архитектура с

вниманием даёт более устойчивые предсказания на «хвосте» распределения – именно там, где традиционные модели склонны недооценивать риск.

Интересный момент – выбор функции потерь. MSE, безусловно, штрафует за большие ошибки, но при сильном дисбалансе (тысячи нулевых задержек против сотен крупных) модель всё равно может быть смещена в сторону «безопасного» прогноза.

На уровне эксплуатации воздушных судов на точность навигации и, как следствие, на своевременность выполнения рейсов влияют и технические факторы. В процессе эксплуатации ВС на радионавигационное оборудование (РНО) постоянно воздействуют помехи и другие дестабилизирующие факторы различного рода, что неизбежно приводит к отклонениям значений параметров РНО от истинных и ошибкам в оценивании навигационных элементов полета [2]. Даже при идеальном прогнозировании внешних условий внутренние технические сбои или деградация навигационного оборудования могут стать причиной задержек.




Рисунок 1 – График MSE на обучающей и валидационной выборках по эпохам

Гибридная архитектура на основе BiLSTM и Multi-Head Attention показала способность выявлять временные паттерны, в том числе предшествующие редким, но критическим задержкам.

Обученная модель сохраняется в формате TensorFlow SavedModel и готова к развёртыванию – как в виде пакетного инструмента для анализа исторических данных, так и в виде REST API для онлайн-прогнозирования в реальном времени [1]. Это открывает путь к практическому применению: от персонализированных уведомлений для пассажиров до оптимизации расписания авиакомпаний.

В перспективе планируется расширить набор признаков, протестировать альтернативные функции потерь и провести полноценное сравнение с классическими методами машинного обучения. Но уже сейчас модель демонстрирует, что интеллектуальный анализ временных паттернов может стать надёжным инструментом в борьбе с одной из самых болезненных проблем современной гражданской авиации.

Список использованных источников

1) Бхат А., Годбол В. Практическое глубокое обучение. М.: ДМК Пресс, 2021. 482 с.

2) Гаранин С.А. Взаимосвязь ошибок оценивания навигационных параметров полета воздушного судна с показателем безопасности полетов // Научный вестник МГТУ ГА. 2012. № 176. – С. 68-73.

3) Гаранин С.А. О точности оценивания параметров радиоэлектронных систем в сложных электромагнитных условиях // Научный вестник МГТУ ГА. 2012. № 186. – С. 123-125.

4) Николенко С., Кадурын А. Глубокое обучение. Погружение в мир нейронных сетей. СПб.: Питер, 2021. 480 с.

5) Шолле Ф. Глубокое обучение на Python. СПб.: Питер, 2018. 400 с.