



## СИСТЕМНЫЙ ПОДХОД К ПРОГНОЗИРОВАНИЮ ТРАНСПОРТНЫХ ПОТОКОВ С ИСПОЛЬЗОВАНИЕМ LSTM

**М. В. Галимова, К. В. Золотухин**

Санкт-Петербургский государственный университет аэрокосмического приборостроения

*Предложена методология прогнозирования транспортных потоков на основе использования рекуррентных нейронных сетей, в частности модели LSTM, в контексте управления и регулирования транспортных потоков в связи с увеличением нагрузки на транспортную сеть. Описана простая математическая модель прогноза транспортного потока с использованием LSTM.*

*Ключевые слова: транспортный поток, системный подход, прогнозирование, рекуррентные нейронные сети, LSTM, интеллектуальные транспортные системы.*

**Для цитирования:**

*Галимова, М. В. Системный подход к прогнозированию транспортных потоков с использованием LSTM / М. В. Галимова, К. В. Золотухин // Системный анализ и логистика. – 2024. – № 2(40). – с. 36 – 40. DOI: 10.31799/2077-5687-2024-2-36-40.*

## SYSTEM APPROACH TO FORECASTING TRANSPORTATION FLOWS USING LSTM

**M. V. Galimova, K. V. Zolotukhin**

St. Petersburg State University of Aerospace Instrumentation

*A methodology for forecasting transportation flows is proposed based on the utilization of recurrent neural networks, specifically LSTM models, in the context of traffic management and regulation due to increasing load on the transportation network. A simple mathematical forecasting model of traffic flow using LSTM is described.*

*Keywords: traffic flow, system approach, forecasting, recurrent neural networks, LSTM, intelligent transportation systems.*

**For citation:**

*Galimova, M. V. System approach to forecasting transportation flows using LSTM / M. V. Galimova, K. V. Zolotukhin // System analysis and logistics. – 2024. – № 2(40). – p. 36 – 40. DOI: 10.31799/2077-5687-2024-2-36-40.*

### **Введение**

В современном мире достаточно остро стоит транспортный вопрос, вызванный непрерывным ростом количества транспортных средств (ТС) на дорогах. В связи с увеличением общего числа автомобилей возрастает численность дорожных инцидентов, значительно снижается пропускная способность дорог, повышается износ дорожного полотна и т. д. [1]. С целью понижения отрицательного влияния роста количества ТС могут применяться различные подходы и методологии. Решение может быть достигнуто с помощью системного подхода к анализу информации о движении ТС с использованием современных информационных технологий. Благодаря комплексному учету множества факторов в процессе планирования, системный подход обеспечивает повышенное качество и точность прогнозирования.

Для эффективного управления транспортными потоками (ТП) и принятия обоснованных решений в области планирования и эксплуатации транспортных систем крайне важна своевременная информация и точное описание предстоящих транспортных условий. Независимо от целей и задач, прогнозирование осуществляется в условиях неопределенности, где интересующий параметр подвержен влиянию как прямых, так и косвенных факторов, изменяющихся во времени.

### **Подход к прогнозированию транспортных потоков**

Прогнозирование ТП – это эффективный инструмент для оптимизации маршрутов и обнаружения аномалий в схемах движения. В настоящее время активно развивается



множество разнообразных подходов прогнозирования ТП, например, использование глубокого обучения и РНС [2].

Опираясь на различные технологические подходы, во всем мире набирает обороты внедрение интеллектуальных транспортных систем (ИТС) [3]. Общей целью этих систем является сбор данных о текущем состоянии транспортной системы и прогнозирование ее будущего поведения. Собранные данные используются для оптимизации управления трафиком, информирования водителей о дорожных происшествиях и планирования транспортных операций. Кроме того, анализ данных ИТС позволяет выявлять тенденции и улучшать модели прогнозирования.

Интеграция данных ИТС с другими источниками информации, такими как погодные условия и события, еще больше повышает точность прогнозов. Таким образом, ИТС играют важную роль в повышении эффективности и безопасности транспортных систем, предоставляя ценные сведения о текущем и будущем состоянии дорожного движения.

Анализируя данные о ТП, важно учитывать их тесную взаимосвязь, из чего следует возможность рассматривать совокупности нескольких характеристик, как одну систему. Таким образом формируется концепция системного подхода к прогнозированию, которая состоит в том, чтобы учитывать не только текущие значения ТП, но и взаимосвязи между различными факторами, такими как время суток, день недели, праздничные дни и т.д. Математически это можно представить как:

$$Y=f(X_1, X_2, \dots, X_n), \quad (1)$$

где  $Y$  – это прогнозируемые значения транспортного потока,  $X_1, X_2, \dots, X_n$  – различные признаки, которые могут влиять на транспортный поток, а  $f$  – функция, которая учитывает взаимосвязи между этими признаками для прогнозирования транспортного потока.

Преимуществом системного подхода к прогнозированию ТП является обеспечение более качественных и точных результатов по сравнению с фрагментарными подходами [4]. Это достигается за счет учета множества факторов и их взаимосвязей, что позволяет получить более полное представление о транспортной системе. Повышенная точность прогнозов приводит к улучшению организации ТП и повышению эффективности управления. Системный подход позволяет оптимизировать распределение ресурсов, сокращать задержки и повышать безопасность дорожного движения.

### **Описание архитектуры LSTM**

Long short-term memory (LSTM) – продолжительная цепочка компонентов краткосрочной памяти, вариант организации РНС [5]. Прогнозирование ТП с использованием LSTM основано на применении РНС, способных учитывать долгосрочные зависимости в последовательных данных. LSTM – это особый тип РНС, который специально разработан для работы с последовательностями данных и борьбы с проблемой затухания и взрыва градиентов.

Системный подход к прогнозированию ТП с использованием LSTM представляет собой комплексный метод, включающий в себя сбор и предобработку исторических данных о транспорте, разработку и обучение модели LSTM, а также оценку и прогнозирование будущих значений ТП. Давайте рассмотрим этот подход подробнее:

#### **1. Сбор и предобработка исторических данных.**

В первую очередь необходимо собрать исторические данные о ТП. Эти данные могут включать в себя информацию о количестве транспортных средств, движущихся по определенному участку дороги или маршруту в течение определенного времени. Далее производится предварительная обработка данных, включающая в себя удаление выбросов, заполнение пропущенных значений, масштабирование и нормализацию данных.

#### **2. Разработка и обучение модели LSTM.**



После предобработки данных разрабатывается и обучается модель LSTM для прогнозирования ТП. Для обучения модели LSTM данные разбиваются на обучающий и тестовый наборы. Обычно используется метод скользящего окна, при котором последовательность значений разбивается на окна фиксированной длины.

Модель LSTM состоит из входного слоя, скрытых слоев LSTM и выходного слоя. Каждый временной шаг представляет собой последовательность данных, которая подается на вход LSTM. Модель обучается на обучающем наборе данных с целью минимизации функции потерь.

### 3. Оценка и прогнозирование:

После обучения модели производится оценка ее производительности на тестовом наборе данных с использованием метрик, таких как среднеквадратичная ошибка или средняя абсолютная ошибка. Затем модель может быть использована для прогнозирования будущих значений ТП. Для этого используются данные из тестового набора и/или новые данные, которые поступают в реальном времени [1].

## Математическая модель прогноза транспортного потока с использованием LSTM

Основные параметры и переменные:

$X$  – входные данные, представляющие собой исторические временные ряды транспортного потока.

$Y$  – выходные данные, представляющие собой прогнозы транспортного потока на определенный временной горизонт.

$n$  – количество временных шагов (например, количество предыдущих дней, используемых для прогнозирования будущего).

$m$  – количество нейронов в скрытом слое LSTM.

$w_{ij}$  – веса, соединяющие  $i$ -ый нейрон входного слоя с  $j$ -ым нейроном скрытого слоя LSTM.

$b_j$  – смещения (bias) для  $j$ -го нейрона скрытого слоя LSTM.

Математическая модель:

1. Входной слой: входные данные  $X$  представляют собой исторические временные ряды транспортного потока. Первый слой LSTM принимает входные данные размерности  $n \times d$ , где  $n$  – количество временных шагов,  $d$  – количество признаков в каждом временном шаге.
2. Скрытый слой LSTM: состоит из  $m$  нейронов. Каждый нейрон имеет свои веса  $w_{ij}$  для входных данных и смещение  $b_j$ . Скрытый слой LSTM вычисляет скрытые состояния и выходы для каждого временного шага  $t$  по следующим формулам [6]:

$$\begin{aligned}
 i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i); \\
 f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f); \\
 k_t &= \sigma(W_k \cdot [h_{t-1}, x_t] + b_k); \\
 g_t &= \tanh(W_c \cdot [h_{t-1}, x_t] + b_c); \\
 c_t &= f_t \odot c_{t-1} + i_t \odot g; \\
 h_t &= k_t \odot \tanh(c_t),
 \end{aligned} \tag{2}$$

где  $i_t, f_t, o_t, g_t$  – векторы входных, забывания, выходных и ячеек памяти LSTM соответственно;  $W_i, W_f, W_o, W_c$  – матрицы весов;  $b_i, b_f, b_o, b_c$  – векторы смещений;  $\sigma$  – функция активации сигмоиды;  $\odot$  – поэлементное умножение.



3. Выходной слой: выходной слой LSTM состоит из одного нейрона. Прогноз транспортного потока  $\hat{y}_t$  для временного шага  $t$  вычисляется как сумма всех скрытых состояний  $h_t$  в последовательности:

$$\hat{y}_t = \sum_{i=1}^m V \cdot h_{i,t}. \quad (3)$$

4. Обучение модели: для обучения модели LSTM используется оптимизация градиентным спуском, минимизируя среднеквадратичную ошибку между прогнозами и фактическими значениями транспортного потока.

### **Возможный пример системного подхода к прогнозированию ТП с использованием LSTM**

Исторические данные: пусть у нас есть исторические данные о количестве автомобилей, проходящих по определенному участку дороги каждый час в течение последних нескольких месяцев.

Математическая модель LSTM:

1. Входной слой LSTM принимает последовательность данных о количестве автомобилей за предыдущие  $n$  часов.
2. Скрытые слои LSTM моделируют зависимости между данными о количестве автомобилей на различных временных шагах.
3. Выходной слой LSTM генерирует прогнозы количества автомобилей на следующий временной шаг.
4. Прогнозирование: на основе обученной модели LSTM можно прогнозировать количество автомобилей на следующий час или на более длительный временной горизонт.

Таким образом, системный подход к прогнозированию ТП с использованием LSTM позволяет учитывать долгосрочные зависимости в данных и создавать более точные прогнозы, что способствует эффективному управлению транспортной инфраструктурой.

### **Заключение**

Прогнозирование ТП является важным инструментом для оптимизации транспортных систем. В этой статье представлен комплексный подход к прогнозированию ТП, учитывающий многочисленные факторы и их взаимосвязи. Этот подход обеспечивает точные прогнозы на различные временные горизонты, что позволяет оптимизировать маршруты, управлять трафиком, информировать водителей о дорожных происшествиях и планировать транспортные операции. Благодаря своей точности и простоте использования этот метод является ценным инструментом для решения проблем управления ТП. Дальнейшие исследования могут сосредоточиться на улучшении обработки данных и оптимизации модели LSTM для еще более точных прогнозов. Предложенный подход имеет широкий спектр применений, включая городское планирование, логистику и транспортные услуги.

### **СПИСОК ЛИТЕРАТУРЫ**

1. Хуссейн, А. Х. С. Модель прогнозирования транспортного потока на основе нейронных сетей для предсказания трафика на дорогах / А. Х. С. Хуссейн, Е. В. Заргарян, Ю. А. Заргарян // Известия ЮФУ. Технические науки. – 2021. – № 6(223). – С. 124-132. – DOI:10.18522/2311-3103-2021-6-124-132.
2. Ковалев, А. Л. Прогнозирование загруженности дорог при помощи рекуррентных нейронных сетей / А. Л. Ковалев, А. А. Куликов // Транспортное дело России. – 2023. – № 3. – С. 270-271. – DOI:10.52375/20728689\_2023\_3\_270.



3. Галкин, А. В. Управление транспортными потоками в интеллектуальной транспортной системе / А. В. Галкин, А. С. Сысоев // Математические методы в технике и технологиях – ММТТ. – 2020. – Т. 6. – С. 32-35.
4. Малиев, Х. Е. Системный подход в прогнозировании денежных потоков / Х. Е. Малиев // Актуальные проблемы гуманитарных и естественных наук. – 2015. – № 6 (4). – С. 52-54.
5. "Notation for ARIMA Models". Time Series Forecasting System. SAS Institute. [Электронный ресурс]. – URL: <https://dms.umontreal.ca/~duchesne/chap7.pdf> (дата обращения 02.03.2024)
6. Лысов, Г. М. Исследование метода прогнозирования временных рядов на транспорте с помощью рекуррентных нейронных сетей / Г. М. Лысов, Ф. Н. Приходько, А. А. Коновалова, К. А. Тимошенко // Дневник науки. – 2023. – № 1(73). – DOI:10.51691/2541-8327\_2023\_1\_6.

### ИНФОРМАЦИЯ ОБ АВТОРАХ

#### **Галимова Мария Владимировна**

Студент

Санкт-Петербургский государственный университет аэрокосмического приборостроения  
190000, Россия, Санкт-Петербург, ул. Большая Морская, д. 67, лит. А

E-mail: kivy123@mail.ru

#### **Золотухин Кирилл Вячеславович**

Ассистент

Санкт-Петербургский государственный университет аэрокосмического приборостроения  
190000, Санкт-Петербург, ул. Большая Морская, д. 67, лит. А

e-mail: zoloto.kv@mail.ru

### INFORMATION ABOUT THE AUTHORS

#### **Galimova Mariya Vladimirovna**

Student

Saint-Petersburg State University of Aerospace Instrumentation  
67, Bolshaya Morskaya str., Saint-Petersburg, 190000, Russia

E-mail: kivy123@mail.ru

#### **Zolotukhin Kirill Vyacheslavovich**

Assistant

Saint-Petersburg State University of Aerospace Instrumentation  
67, Bolshaya Morskaya str., Saint-Petersburg, 190000, Russia

E-mail: zoloto.kv@mail.ru