

ЧУҚУР ЎҚИТИШ МОДЕЛЛАРИ АСОСИДА ТРАНСПОРТ ОҚИМИНИ БАШОРАТЛАШ

Жалелов Р.М.

Мирзо-Улуғбек номидаги Ўзбекистон миллий университети,
Тошкент, Ўзбекистон

<https://doi.org/10.5281/zenodo.12741607>

Аннотация. Мазкур тадқиқот жаҳонда транспорт воситалар сонини ўсиши билан боғлиқ бўлган тирбандлик муаммосини тадқиқ қилишга бағишланган бўлиб, унда чуқур ўқитиш моделларидан фойдаланган ҳолда транспорт оқимларини башоратлаш учун тажрибалар таҳлили келтирилган. Тажрибалар учун Elman модели, LSTM ва GRU моделини ўз ичига олган рекуррент нейрон тармоқлари танланган бўлиб, уларнинг ишлашини таққослаш учун MSE кўрсаткичидан фойдаланилган. Натижалар шуни кўрсатдики, GRU модели транспорт оқимларини башоратлашда энг яхши самарадорликни намоиши этади, бу эса уни тирбандликни бошқариш ва транспорт инфратузилмасини оптималлаштириш учун истиқболли воситага айлантиради.

Калит сўзлар: транспорт оқими, рекуррент нейрон тармоқ, Elman, LSTM, GRU, нормализация, чуқур ўқитиш.

Аннотация. Исследованию проблемы заторов на дорогах, связанных с ростом количества транспортных средств в мире, посвящено данное исследование, в котором представлен анализ экспериментов по прогнозированию транспортных потоков с использованием моделей глубокого обучения. Для экспериментов были выбраны рекуррентные нейронные сети, включая модель Элмана, LSTM и модель GRU, а для сравнения их производительности использовался показатель MSE. Результаты показали, что модель GRU демонстрирует наилучшие результаты при прогнозировании транспортных потоков, что делает ее перспективным инструментом для управления дорожным движением и оптимизации дорожной инфраструктуры.

Ключевые слова: транспортный поток, рекуррентная нейронная сеть, Элман, LSTM, GRU, нормализация, глубокое обучение.

Abstract. This study is devoted to researching the problem of traffic congestion related to the growth of the number of vehicles in the world, in which the analysis of experiments to predict traffic flows using deep learning models is presented. Recurrent

neural networks including the Elman model, LSTM, and GRU model were selected for the experiments, and the MSE indicator was used to compare their performance. The results showed that the GRU model performs best in predicting traffic flows, making it a promising tool for traffic management and infrastructure optimization.

Keywords: *traffic flow, recurrent neural network, Elman, LSTM, GRU, normalization, deep learning.*

Кириш. Иқтисодий ва технологик тараққиёт бугунги кунда транспорт воситалари сонининг кўпайишига ва натижада шаҳарларда тирбандликка сабаб бўлиб, жамият ва иқтисодиёт учун жиддий муаммога айланиб бормоқда. Йўл тирбандлиги билан боғлиқ муаммолар ёнилғи сарфининг ошишига, атроф-мухитни ифлосланишига ва аҳоли саломатлиги учун салбий оқибатларга олиб келади. Ушбу муаммони ҳал қилиш интеграциялашган ёндашувни ва транспорт оқимларини бошқариш инфратузилмасини такомиллаштиришни талаб қилади [1].

Транспорт оқимларини башоратлаш учун фойдаланиладиган анъанавий статистик моделлар маълумотларни ўзгарувчанлигига мослашиш қобилияти бўйича чекланган [2]. Улар олдиндан белгиланган тузилмалар ва ўзгарувчилар ҳақидаги тахминларга таянади, бу эса транспорт оқими динамикасини аниқ башорат қилишни мураккаблаштиради.

Замонавий тадқиқотларда нейрон тармоқлар каби чуқур ўқитиш моделлари транспорт оқимларини башоратлаш учун кенг қўлланилади [3]. Улар маълумотлардаги ўзгаришларга автоматик мослашиш ва ўзгарувчилар ўртасидаги мураккаб боғлиқликларни ажратиб олиш қобилиятига эга. Хусусан, LSTM (Long Short-Term Memory) ва GRU (Gated Recurrent Unit) каби рекуррент нейрон тармоқ моделлари вақт серияларини, жумладан, транспорт оқимларини башоратлашда юқори самарадорликни кўрсатмоқда.

Мазкур тадқиқотни мақсади рекуррент нейрон тармоқларидан фойдаланган ҳолда вақт серияларини башоратлаш моделини ишлаб чиқиш ва натижаларни вақт серияси хусусиятларига боғлиқлигини ўрганишдан иборат бўлиб, бу транспорт оқими динамикасини янада аниқроқ башоратлаш ва шаҳар инфратузилмасини самарали бошқариш имконини беради.

Йўл ҳаракати тирбандлиги муаммоси шаҳар инфратузилмаси ва аҳоли фаровонлиги учун жиддий муаммо туғдиради, бу эса транспорт оқимини башоратлашнинг янги ва такомиллаштирилган моделларини ишлаб чиқишни талаб қилади. Сўнгги йилларда тадқиқотчилар маълумотлардаги мураккаб

стохастик ва чизикли бўлмаган муносабатларни тадқиқ қилиш жараёнида RNN ва унинг такомиллаштирилган моделларига алоҳида эътибор қаратишмоқда. Бироқ, RNN модели баъзи камчиликларга эга бўлганлиги сабаб, у ҳар доим ҳам транспорт оқимини башоратлашда муқобил бўла олмайди. GRU архитектураси эса RNN моделидаги камчиликларни бартараф этиш учун ишлаб чиқилган бўлиб, у транспорт оқимини башоратлашда юқори самарадорликни намойиш этади. SAE, FFNN ва SVM каби муқобил усуллар билан таққослаганда, GRU моделлари яхшироқ натижаларни кўрсатади. Айрим адабиётларда транспорт оқимларини бошқаришда реал вақт режимида навбат узунлигини башоратлаш учун LSTM моделига асосланган ёндашув анъанавий башоратлаш усулларида устун эканлиги таъкидланган.

Юқоридаги адабиётларни таҳлил қилиш натижасида, транспорт оқимини башорат қилиш соҳасида чуқур ўқитиш моделлари кенг қўлланилгани эътиборга олиниб, мазкур тадқиқот ишида Elman RNN, GRU [4] ва LSTM [5] моделлари тажрибавий тадқиқотларни ўтказишда фойдаланиш учун танланган.

Elman рекуррент нейрон тармоқ (RNN). Elman RNN чиқиши қуйидаги иккита тенгламани тақрорий ҳисоблаш орқали амалга оширилади:

$$h_t = H(W_{xh}x_t + W_{hh}h_{t-1} + b_h), \quad (1)$$

$$y_t = W_{hy}h_t + b_y, \quad (2)$$

бу ерда x - кириш вектори, y - чиқиш вектори, h - бу $t = 1$ дан T гача бўлган вақт бўлақларидаги яширин вектор, w - вазн матрицалари, b - биас, H - яширин қатламларда қўлланиладиган фаоллаштириш функцияси.

Long Short-Term Memory (LSTM). LSTM моделидан фойдаланиш учун қуйидаги формулалар орқали ҳисоблашлар амалга оширилади:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (3)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (4)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C), \quad (5)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t, \quad (6)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (7)$$

$$h_t = o_t * \tanh(C_t), \quad (8)$$

бу ерда, f - унутиш компоненти, i - кириш компоненти, C - мавжуд хотирани қисман унутиш, \tilde{C} - янги хотира таркибини қўшиш, o - чиқиш компоненти, σ - сигмасимон функция, \tanh - гиперболик тангенс функцияси.

Gated Recurrent Units (GRU). GRU моделидан фойдаланиш учун қуйидаги

формулалар орқали ҳисоблашлар амалга оширилади:

$$r_t = \text{sigm}(W_{xr}x_t + W_{hr}h_{t-1} + b_r), \quad (9)$$

$$z_t = \text{sigm}(W_{xz}x_t + W_{hz}h_{t-1} + b_z), \quad (10)$$

$$\tilde{h}_t = \text{tanh}(W_{xh}x_t + W_{hh}(r_t \square h_{t-1}) + b_h), \quad (11)$$

$$h_t = z_t \square h_{t-1} + (1 - z_t) \square \tilde{h}_t, \quad (12)$$

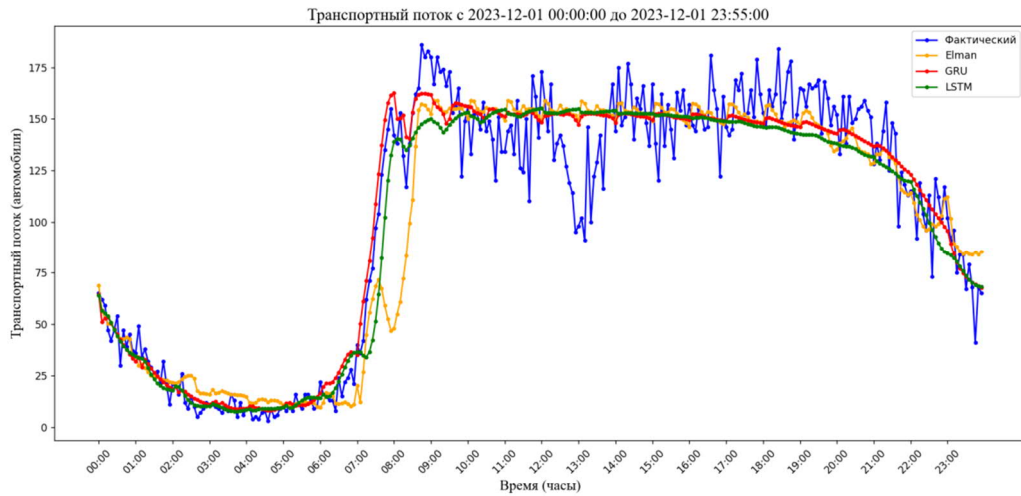
бу ерда r_t - қайта ўрнатиш жараёни, z_t - янгилаш жараёни, x_t - кириш вектори, h_t - чиқиш вектори, w - вазн матрицалари, b - биас, sigm - сигмасимон ва tanh - гиперболик тангенс фаоллаштириш функцияси.

Ҳисоблаш таржибалари натижалари. Ҳисоблаш тажрибалари Тошкент шаҳри мисолида кўрилди. Унда чорраҳадаги транспорт оқимини башоратлаш учун 1 ойлик маълумотлар тўпламидан фойдаланилди. Ушбу маълумотлар тўплами тўртта йўналишдаги 8640×4 намунадан иборат транспорт оқими маълумотлари ва вақт сериясини ўз ичига олади. Тўғри башоратлаш натижаларига эришиш учун маълумотларни қайта ишлашни қуйидаги босқичларидан ўтказиш муҳимдир:

- дастлабки маълумотларда этишмаётган қийматлар ўртача қийматлар билан алмаштирилади;
- бирламчи ишлов беришдан сўнг маълумотлар $[0,1]$ оралиғига нормаллаштирилади;
- маълумотлар тўплами ўқитиш ва синов тўпламларига ажратилади, моделни кириш ва чиқиш қийматлари аниқланади;
- қатламлар, нейронлар сони ва бошқа параметрларни ҳисобга олган ҳолда нейрон тармоқ модели курилади.

Тажрибавий тадқиқот натижаларини таққослаш учун MSE кўрсаткичи фойдаланилган бўлиб, унда GRU модели маълум бир йўл чорраҳасида транспорт оқимларини башоратлашда самарали эканлиги аниқланди.

Ҳисоблаш тажрибасида Elman RNN, GRU ва LSTM моделлари транспорт оқимининг йиғилган маълумотлари бўйича ўқитилди. Сўнг бу моделлар навбатдаги кунлик транспорт оқимини башоратлаш учун фойдаланилган (1-расм).



**1-расм. Elman RNN, GRU ва LSTM моделлари асосида башоратлаш
натижаси**

Elman RNN, GRU ва LSTM моделлари асосида башоратлаш
натижаларининг MSE қийматлари 1-жадвалда келтирилган.

1-жадвал

Модель номлари	MSE	Аниқлиги
Elman RNN	261,886	79,01%
LSTM	250,753	79,46%
GRU	224,301	80,69%

Хулоса. Мазкур тадқиқот ишида транспорт тирбандлиги муаммоси ўрганилди ва уни ҳал қилиш учун чуқур нейрон тармоқларга асосланган башоратлаш моделлари таҳлил қилинди. Транспорт оқимини башоратлашда кенг қўлланиладиган RNN, GRU ва LSTM моделлари кўриб чиқилди. Тажрибавий тадқиқотларни ўтказишда башоратлаш натижалари MSE кўрсаткичи ёрдамида баҳоланди ва бунда GRU модели ҳақиқий қийматларга энг яқин натижаларни кўрсатди.

Адабиётлар рўйхати

1. W. Zeng et al., “Traffic Flow Prediction Based on Hybrid Deep Learning Models Considering Missing Data and Multiple Factors,” Sustainability 2023, Vol. 15, Page

- 11092, vol. 15, no. 14, p. 11092, Jul. 2023, doi: 10.3390/SU151411092.
2. H. F. Yang, T. S. Dillon, and Y. P. P. Chen, “Optimized Structure of the Traffic Flow Forecasting Model with a Deep Learning Approach,” *IEEE Trans Neural Netw Learn Syst*, vol. 28, no. 10, pp. 2371–2381, Oct. 2017, doi: 10.1109/TNNLS.2016.2574840.
 3. B. L. Smith and M. J. Demetsky, “Traffic Flow Forecasting: Comparison of Modeling Approaches,” *J Transp Eng*, vol. 123, no. 4, pp. 261–266, Jul. 1997, doi: 10.1061/(ASCE)0733-947X(1997)123:4(261).
 4. Farhad MortezaPour Shiri, Thinagaran Perumal, Norwati Mustapha, Raihani Mohamed “A Comprehensive Overview and Comparative Analysis on Deep Learning Models: CNN, RNN, LSTM, GRU” *Computer Science*, May 2023, pp 1-16, DOI:10.48550/arXiv.2305.17473
 5. S. Hochreiter, J. Schmidhuber, Long Short-Term Memory. *Neural Comput.* 9, 8, 1735-1780, November 1997.