TRANSPORT-LOGISTIKA TIZIMIDA YUK OQIMINI PROGNOZLASH UCHUN LSTM VA GRU MODELLARINI TAQQOSLASH VA BAHOLASH

Abdumalikov Akmal[1], *Irgasheva Umida*[1]

[1]*Mirzo Ulug'bek nomidagi O'zbekiston Milliy universitetining Jizzax filiali*
E-mail: irgashevaumida1997@gmail.com

KEYWORDS

transport-logistika tizimi, yuk oqimi, vaqt qatori, LSTM, GRU, chuqur o'rganish, prognozlash, MAE, RMSE, MAPE, R^2, CCTV, YOLO, adaptiv marshrut boshqarish

ABSTRACT

Ushbu maqolada transport-logistika tizimida yuk oqimini vaqt qatori sifatida prognozlash uchun LSTM (Long Short-Term Memory) va GRU (Gated Recurrent Unit) neyron tarmoq modellarini taqqoslash va baholash masalasi ko'rib chiqiladi. Tadqiqotda transport oqimining vaqt bo'yicha o'zgarishini ifodalovchi ma'lumotlardan foydalanish, ularni oldindan qayta ishlash, o'qitish va prognozlash bosqichlari tavsiflanadi. LSTM uzoq muddatli bog'lanishlarni xotira katagi va uchta asosiy darvoza orqali saqlasa, GRU yangilash va qayta tiklash darvozalari yordamida nisbatan sodda arxitekturani ta'minlaydi. Modellarni baholashda MAE, RMSE, MAPE va R^2 ko'rsatkichlari, shuningdek, o'qitish vaqti, parametrlar soni hamda hisoblash resurslariga bo'lgan talablar hisobga olinadi. Maqolada CCTV va YOLO asosida transport vositalarini aniqlash va sanashdan olingan ma'lumotlarni LSTM/GRU prognozlash modellariga uzatish imkoniyati ham ko'rsatiladi. Bunday yondashuv keyingi bosqichda adaptiv marshrut boshqarish algoritmlarini ma'lumot bilan ta'minlashga xizmat qiladi. LSTM yoki GRU ning ustunligi oldindan qat'iy belgilanmaydi, u ma'lumotlar to'plami, prognoz gorizonti, belgilar tarkibi va tajriba sharoitlariga bog'liq holda aniqlanishi kerak.

1. Kirish.

Transport-logistika tizimlarida yuk oqimining vaqt bo'yicha o'zgarishini oldindan baholash yuk tashish jarayonlarini rejalashtirish, transport vositalarini taqsimlash, yo'l tarmoqlaridagi yuklanishni aniqlash va marshrutlarni moslashtirish uchun muhimdir. Yuk oqimi kunning soatlari, hafta kunlari, mavsumiylik, ob-havo, yo'l-transport hodisalari va boshqa tashqi omillar ta'sirida o'zgaradi. Shu sababli oddiy statistik usullar bilan bir qatorda murakkab nolinear bog'lanishlarni o'rgana oladigan chuqur o'rganish modellaridan foydalanish dolzarb hisoblanadi.[1]

Transport oqimini prognozlash bo'yicha zamonaviy tadqiqotlarda RNN, LSTM, GRU, CNN, GCN va Transformer oilasidagi modellar keng qo'llanmoqda. Ayniqsa LSTM va GRU vaqt qatorlaridagi ketma-ket bog'lanishlarni modellashtirishga mo'ljallangan bo'lib, ularni bir xil ma'lumotlar va tajriba sharoitida taqqoslash transport-logistika tizimi uchun amaliy model tanlashni asoslash imkonini beradi.[2]

Mazkur tadqiqotning maqsadi transport-logistika tizimida yuk oqimini prognozlashda LSTM va GRU modellarining arxitekturaviy xususiyatlarini, prognoz aniqligini va hisoblash samaradorligini taqqoslash metodikasini ishlab chiqishdan iborat. Bunda model natijasini faqat bitta xatolik ko'rsatkichi bilan emas, bir nechta mezonlar majmuasi bilan baholash ko'zda tutiladi.

2. Tegishli tadqiqotlar

LSTM va GRU transport oqimi prognozida ko'p qo'llanadigan rekurrent modellar sifatida turli tadqiqotlarda sinovdan o'tkazilgan. Masalan, Jang va Chen (2024) shahar transport oqimini prognozlashda LSTM va GRU modellarini taqqoslagan. Boshqa ishlar esa yordamchi ko'p o'zgaruvchili ma'lumotlar, spatio-temporal modellar va gibrid LSTM-GRU yondashuvlarini

(cc) BY

ko‘rib chiqqan. Bu natijalar model samaradorligi ma’lumotlar tuzilishi va tajriba dizayniga kuchli bog‘liqligini ko‘rsatadi.

Shu sababli mazkur maqolada aniq sonli eksperimental natijalar real ma’lumotlar to‘plami bilan tajriba o‘tkazilgandan keyin kiritilishi kerak. Ushbu bosqichda metodika va baholash mezonlari shakllantiriladi; sun’iy yoki tasdiqlanmagan qiymatlarni real tajriba natijasi sifatida ko‘rsatish ilmiy jihatdan to‘g‘ri emas.

Tadqiqot vazifalari

- yuk oqimini vaqt qatori ko‘rinishida shakllantirish va ma’lumotlarni tayyorlash;
- LSTM va GRU modellarining matematik va arxitekturaviy tuzilishini aniqlash;
- bir xil o‘quv va test sharoitida ikkala modelni o‘qitish;
- MAE, RMSE, MAPE va R^2 orqali prognoz natijalarini baholash;
- parametrlar soni, o‘qitish vaqti va inferensiya tezligini taqqoslash;
- olingan prognozlarni transport-logistika tizimida adaptiv marshrut boshqarish jarayoniga integratsiya qilish imkoniyatini aniqlash.

Tadqiqot obyekti va predmeti

Tadqiqot obyekti — transport-logistika tizimidagi vaqt bo‘yicha o‘zgaruvchi yuk oqimi. Tadqiqot predmeti — yuk oqimini LSTM va GRU yordamida prognozlash modellari, ularning algoritmlari va baholash mezonlari.

3. Materiallar va metodlar

Yuk oqimini prognozlash uchun vaqt qatori $Q=\{q_1,q_2,\ldots,q_t\}$ ko‘rinishida ifodalanadi. Bu yerda q_t — t-vaqtdagi yuk avtomobillari soni yoki ma’lum vaqt oralig‘ida aniqlangan yuk oqimi hajmi. CCTV va YOLO yordamida olingan transport vositalari soni vaqt bo‘yicha agregatsiya qilinib, 5, 15, 30 yoki 60 daqiqalik intervallarga keltirilishi mumkin.

Modelga faqat yuk mashinalari soni emas, balki yordamchi belgilarni ham kiritish mumkin: yengil avtomobillar soni, o‘rtacha tezlik, yo‘l bandligi, soat, hafta kuni, ob-havo, hodisa mavjudligi va boshqa omillar. Ko‘p o‘zgaruvchili kirish ma’lumotlari transport oqimining tashqi omillarga bog‘liqligini yaxshiroq ifodalashi mumkin.

3.1. LSTM modeli

LSTM rekurrent neyron tarmog‘ining uzoq muddatli bog‘lanishlarni saqlashga yo‘naltirilgan turi bo‘lib, xotira holatini boshqaruvchi forget, input va output darvozalaridan foydalanadi. Uning asosiy tenglamalari quyidagicha:

$$f_t=\sigma(W_f[h_{t-1},x_t]+b_f);\quad i_t=\sigma(W_i[h_{t-1},x_t]+b_i);$$

$$\hat{c}_t=\tanh(W_c[h_{t-1},x_t]+b_c);\quad c_t=f_t\odot c_{t-1}+i_t\odot \hat{c}_t;$$

$$o_t=\sigma(W_o[h_{t-1},x_t]+b_o);\quad h_t=o_t\odot \tanh(c_t).$$

Bu yerda x_t — kirish vektori, h_t — yashirin holat, c_t — xotira holati, σ — sigmoid funksiyasi, $\odot$ — elementlar bo‘yicha ko‘paytirish amalidir.

3.2. GRU modeli

GRU LSTM ga nisbatan soddaroq rekurrent arxitekturaga ega. U asosan yangilash va qayta tiklash darvozalaridan foydalanadi:

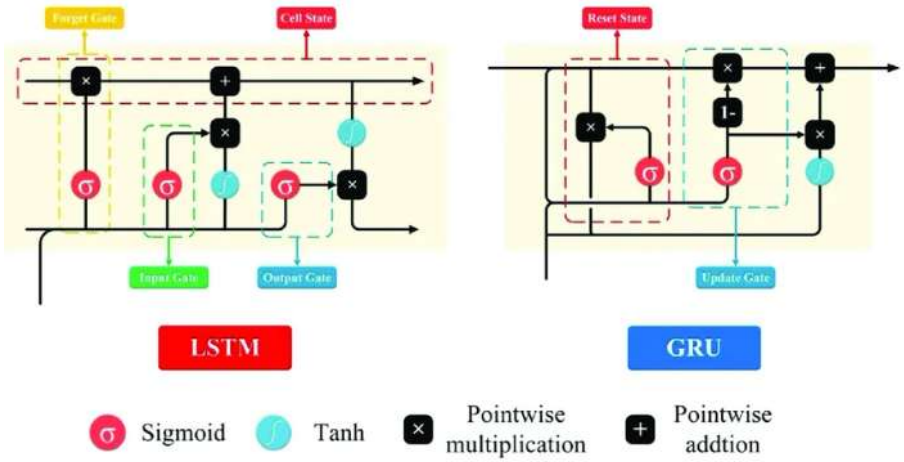
$$z_t=\sigma(W_z[h_{t-1},x_t]+b_z);\quad r_t=\sigma(W_r[h_{t-1},x_t]+b_r);$$

$$\tilde{h}_t=\tanh(W_h[r_t\odot h_{t-1},x_t]+b_h);$$

$$h_t=(1-z_t)\odot h_{t-1}+z_t\odot \tilde{h}_t.$$

GRU da alohida xotira katagi mavjud emasligi sababli parametrlar soni ayrim holatlarda LSTM ga qaraganda kam bo‘ladi. Natijada o‘qitish va inferensiya jarayoni nisbatan tezlashishi mumkin, biroq yakuniy natija konkret ma’lumotlar va model sozlamalariga bog‘liq.[4]

(cc) BY

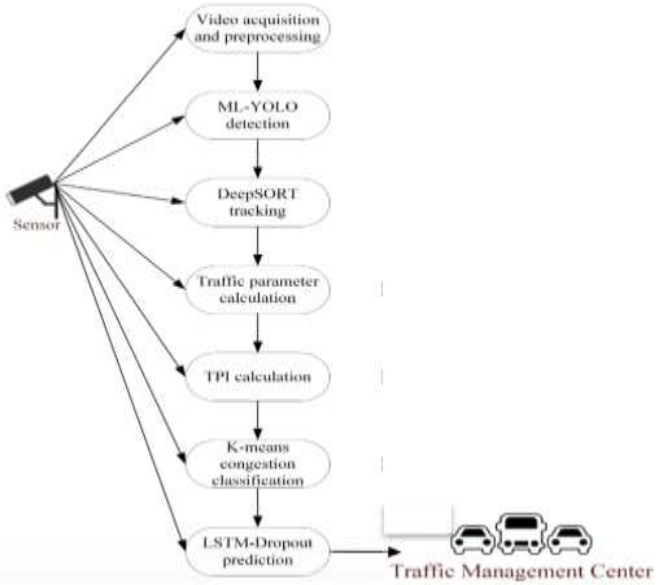


1-rasm. *LSTM va GRU ramkalari o‘rtasidagi farqlar.*

LSTM ning ichki strukturaviy o'zaro ta'sir diagrammasi uchta darvoza tuzilmasini o'z ichiga oladi: Unut Gate, Kirish Gate va Chiqish Gate. Himoya va boshqarish uchun hujayra holati darvozasi ham kiritilgan. GRU LSTM ning bir varianti sifatida, Unut Gate va Kirish Gate ni bitta Yangilash Gate ga birlashtiradi, bu shuningdek, Reset Gate ni ham o'z ichiga oladi. LSTM va GRU ning ichki tuzilishida farqlar mavjud bo'lsa-da, ikkala struktura ham ma'lumotlarni tahlil qilish paytida gradient dispersiyasi hodisasini samarali ravishda oldini olishi mumkin.

4. Ma’lumotlarni tayyorlash va tajriba dizayni

LSTM va GRU ni adolatli taqqoslash uchun ikkala modelga bir xil ma’lumotlar to‘plami, bir xil prognoz gorizonti va imkon qadar teng arxitektura sharoitlari berilishi lozim. Ma’lumotlar vaqt ketma-ketligi buzilmagan holda o‘quv, validatsiya va test qismlariga ajratiladi. Kelajak ma’lumotlarining o‘quv jarayoniga tasodifan kirib qolishi ma’lumotlar sizib chiqishiga olib kelishi mumkin, shuning uchun vaqtga asoslangan ajratish afzal hisoblanadi. Oldindan qayta ishlash bosqichida yetishmayotgan qiymatlarni aniqlash, keskin shovqinlarni tekshirish, xususiyatlarni masshtablash va sirpanma oyna (sliding window) yaratish amalga oshiriladi. Masalan, oxirgi 12 ta vaqt oralig‘idagi ma’lumotdan keyingi vaqt oralig‘idagi yuk oqimini prognozlash vazifasi shakllantirilishi mumkin.[5]



2-rasm. *Video kuzatuv sensorlari va boshqaruv tizimi o‘rtasidagi o‘zaro ta’sir*

CC BY *dtai.uz*

ISSN: 3030-3346

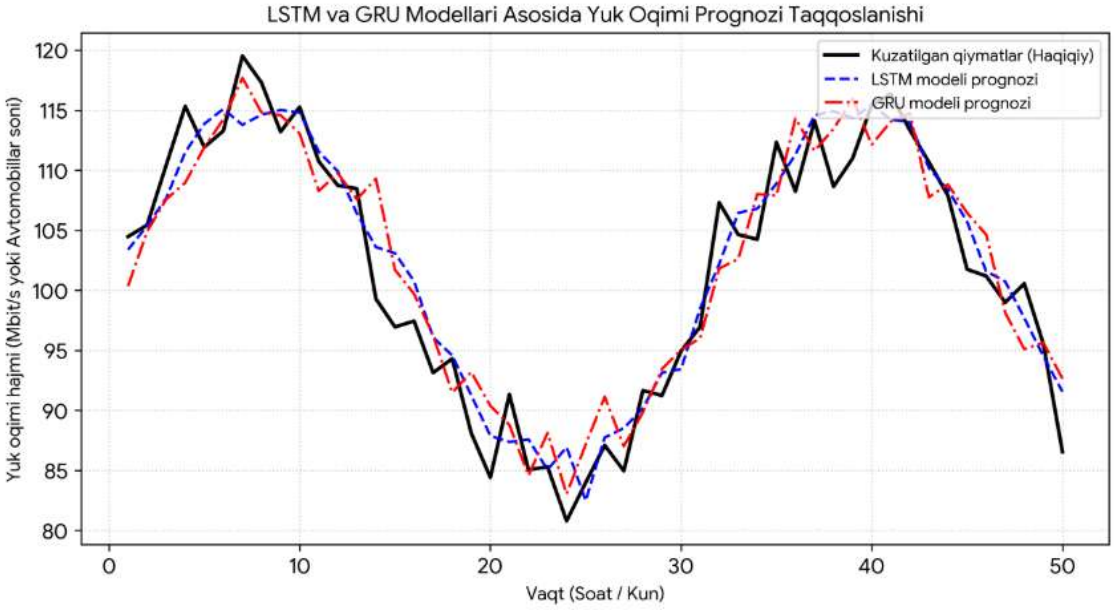
1-jadval.

Taqqoslashning umumiy mezonlari

Mezon	Formula / mazmuni	Talqin
MAE	$1/n\ \Sigma\lvert y_i - \hat{y}_i\rvert$	O‘rtacha absolyut xatolik; kichik qiymat yaxshi.
RMSE	$\sqrt{(1/n\ \Sigma(y_i - \hat{y}_i)^2)}$	Katta xatolarni kuchliroq hisobga oladi.
MAPE	$100/n\ \Sigma\lvert(y_i - \hat{y}_i)/y_i\rvert$	Nisbiy xatolik; nolga yaqin qiymatlarda ehtiyotkorlik zarur.
R^2	$1 - SSres/SStot$	Modelning variatsiyani tushuntirish darajasini ifodalaydi.
Vaqt	O‘qitish va inferensiya vaqti	Hisoblash samaradorligini ko‘rsatadi.

Model tanlashda faqat MAE yoki RMSE qiymatini solishtirish yetarli emas. Amaliy transport tizimida prognozning aniqligi bilan birga modelning qayta o‘qitilish vaqti, real vaqt rejimida javob berishi, xotira talabi, parametrlar soni va yangi ma’lumotlarga moslashish imkoniyati ham muhimdir.

Shuningdek, turli prognoz gorizontlari — masalan, 15, 30, 60 va 120 daqiqa — alohida baholanishi kerak. Bir gorizontda yaxshi natija bergan model boshqa gorizontda xuddi shunday natija berishi shart emas.



3-rasm. *LSTM va GRU modellari asosida yuk oqimi prognozi taqqoslanishi*

Grafik tahlili va asosiy farqlar

Vaqtli qatorlarni prognozlashda LSTM (Long Short-Term Memory) va GRU (Gated Recurrent Unit) modellari quyidagi xususiyatlari bilan ajralib turadi: [6]

- **Kuzatilgan qiymatlar (Qora chiziq):** Tizimdagi haqiqiy yuk oqimi bo'lib, o'zida shovqinlar (noise) va keskin tebranishlarni ifodalaydi.
- **LSTM Prognozi (Ko'k chiziq):** Murakkab va uzoq muddatli bog'liqliklarni eslab qolish xususiyati tufayli ko'pincha silliqroq va aniqroq

(cc) BY

natija beradi. Ammo, hisoblash resurslarini ko'proq talab qiladi. [6, 7]

- **GRU Prognozi (Qizil chiziq):** Tuzilishi jihatidan sodda (faqat *update* va *reset* qopqoqlaridan iborat) bo'lgani uchun tezroq o'qitiladi. Kichikroq ma'lumotlar to'plamida deyarli LSTM kabi yuqori aniqlikni ko'rsatishi mumkin.

5. Natijalar va muhokama

LSTM va GRU ni taqqoslashning ilmiy jihatdan to‘g‘ri shakli oldindan g‘olib modelni belgilash emas, balki bir xil tajriba sharoitida olingan natijalarni statistik va amaliy mezonlar bo‘yicha tahlil qilishdir. Adabiyotlarda LSTM va GRU ning natijalari turli ma’lumotlar to‘plamlarida farq qilishi qayd etilgan. Ayrim tajribalarda GRU hisoblash jihatdan ixcham bo‘lsa, boshqa sharoitlarda LSTM uzoq muddatli bog‘lanishlarni ifodalashda foydali bo‘lishi mumkin. Transport-logistika tizimida yuk oqimi ko‘pincha davriy va notekis xususiyatga ega. Masalan, ish kunlari ertalab va kechki davrlarda transport faolligi oshishi, dam olish kunlarida esa boshqa profil kuzatilishi mumkin. Agar modelga hafta kuni va soat kabi belgilar kiritilsa, bunday takrorlanuvchi qonuniyatlarni o‘rganish imkoniyati oshadi.

2-jadval.

LSTM va GRU ni taqqoslash mezonlari

Ko‘rsatkich	LSTM	GRU	Baholash yo‘nalishi
Arxitektura	Xotira katagi + 3 darvoza	2 asosiy darvoza	Murakkablik
Parametrlar	Odatda ko‘proq	Odatda kamroq	Resurs talabi
Prognoz aniqligi	Datasetga bog‘liq	Datasetga bog‘liq	MAE/RMSE/MAPE/R^2
O‘qitish tezligi	Nisbatan yuqori hisoblash talabi	Ko‘pincha ixchamroq	Sekund/minut
Real vaqt	Moslashtirilishi mumkin	Ixchamligi foydali bo‘lishi mumkin	Inferensiya vaqti

5.1. CCTV–YOLO ma’lumotlarini LSTM/GRU bilan integratsiya qilish

Transport-logistika tadqiqotining amaliy pipeline ko‘rinishi quyidagicha tashkil qilinishi mumkin: CCTV → YOLO → transport vositalarini aniqlash → yuk mashinalari va yengil avtomobillarni guruhlash → tracking/counting → vaqt bo‘yicha agregatsiya → LSTM/GRU prognozi → adaptiv marshrut boshqarish.[8]

Birinchi bosqichda CCTV kameralaridan video oqimi olinadi. YOLO modeli kadrdagi transport vositalarini aniqlaydi va tegishli klasslarni belgilaydi. Keyingi bosqichda transport vositalari ikki asosiy guruhga — yuk mashinalari va yengil avtomobillarga — ajratiladi. ByteTrack kabi ko‘p obyektli kuzatish usuli yordamida obyektlarning kadrlar bo‘yicha takroriy sanalishini kamaytirish mumkin.

Olingan hisoblar vaqt oralig‘i bo‘yicha yig‘iladi. Masalan, har 15 daqiqada nechta yuk mashinasi va nechta yengil avtomobil o‘tgani aniqlanadi. Shunday qilib, LSTM/GRU uchun ketma-ket vaqt qatori hosil qilinadi. Bu yondashuv tasvirdagi xom ma’lumotni bevosita neyron tarmoqqa berish o‘rniga, transport oqimining sonli va vaqtga bog‘liq ko‘rsatkichlarini prognozlashga imkon beradi.

3-jadval.

Integratsiya bosqichlari

Bosqich	Kirish	Jarayon	Chiqish
1	CCTV video	Kadrlarni olish	Video oqimi
2	Video kadr	YOLO aniqlashi	Obyektlar va klasslar

(cc) BY

3	Obyektlar	Tracking + counting	Transport soni
4	Sonli ma’lumot	Vaqt bo‘yicha agregatsiya	Vaqt qatori
5	Vaqt qatori	LSTM/GRU	Prognoz
6	Prognoz	Marshrut algoritmi	Adaptiv yo‘nalish

6. Xulosa

Maqolada transport-logistika tizimida yuk oqimini prognozlash uchun LSTM va GRU modellarini taqqoslash metodikasi ishlab chiqildi. LSTM xotira katagi va uchta asosiy darvoza orqali uzoq muddatli bog‘lanishlarni boshqaradi, GRU esa yangilash va qayta tiklash darvozalari yordamida soddalashtirilgan rekurrent tuzilmani ta’minlaydi. Har ikkala model vaqt qatorlari uchun mos bo‘lib, ularning amaliy samaradorligi konkret ma’lumotlar va tajriba sharoitlari asosida aniqlanishi kerak.

Baholashda MAE, RMSE, MAPE va R^2 bilan bir qatorda parametrlar soni, o‘qitish vaqti, inferensiya tezligi va xotira talabi hisobga olinishi taklif qilindi. Ayniqsa transport-logistika tizimining real vaqtga yaqin ishlashida faqat aniqlik emas, hisoblash samaradorligi ham muhim mezon hisoblanadi.[9]

CCTV va YOLO asosida transport vositalarini aniqlash, yuk mashinalari va yengil avtomobillarni guruhlash hamda avtomatik sanash orqali hosil qilingan vaqt qatorlari LSTM yoki GRU modelining kirish ma’lumotlari sifatida ishlatilishi mumkin. Prognoz natijalari keyingi bosqichda adaptiv marshrut boshqarish algoritmlariga uzatiladi. Kelgusidagi tajribada O‘zbekiston hududidagi real CCTV ma’lumotlari asosida ikkala model bir xil sharoitda o‘qitilib, turli prognoz gorizontlarida statistik jihatdan taqqoslanishi maqsadga muvofiq.

Foydalanilgan adabiyotlar

1. Irgasheva U. A., Ergashev A. A. & Bo‘riboyev A. (2026). Sun’iy intellekt va big data asosida fan va ta’lim integratsiyasining ilmiy-nazariy asoslari. In *Raqamli jamiyatda fan va ta’limning integratsiyalashuvi* (pp. 267–270).
2. Irgasheva U. A. (2026). CNN arxitekturalari yordamida belgilarni avtomatik o‘rganish orqali yuzning individual xususiyatlarini aniqlash. In *Yangi O‘zbekiston taraqqiyotida yosh olimlarning o‘rni* (pp. 582–585).
3. Abdumalikov A.A. & Irgasheva U.A. (2026) FACENET yordamida belgilarni avtomatik o‘rganish orqali yuzning indivdual xususiyatlarini aniqlash. In *Al-Farg‘oniy avlodlari.* (pp. 98-102) https://al-fargoniy.uz/index.php/journal/article/view/1240/2928
4. Jang, H.-C., & Chen, C.-A. (2024). Urban traffic flow prediction using LSTM and GRU. Engineering Proceedings, 55(1), 86. https://doi.org/10.3390/engproc2023055086
5. Incorporating multivariate auxiliary information for traffic prediction on highways. (2023). Sensors, 23(7), 3631. https://doi.org/10.3390/s23073631
6. Applying hybrid LSTM-GRU model based on heterogeneous data sources for traffic speed prediction in urban areas. (2022). Sensors, 22(9), 3348. https://doi.org/10.3390/s22093348
7. Reza, S., Ferreira, M. C., Machado, J. J. M., & Tavares, J. M. R. S. (2022). A multi-head attention-based transformer model for traffic flow forecasting with a comparative analysis to recurrent neural networks. Expert Systems with Applications, 202, 117275. https://doi.org/10.1016/j.eswa.2022.117275
8. A comprehensive review of traffic flow forecasting based on deep learning. (2026). Neurocomputing, 668, 132269. https://doi.org/10.1016/j.neucom.2025.132269
9. Performance analysis of neural network architectures for time series forecasting: A comparative study of RNN, LSTM, GRU, and hybrid models. (2025). MethodsX, 15, 103462. https://doi.org/10.1016/j.mex.2025.103462

(cc) BY *dtai.uz*