SHAHAR TRANSPORT TIZIMLARIDA TIRBANDLIKLARNI BASHORAT QILISH UCHUN KVANT-CHUQUR O‘QITISH GIBRID MODELLARINI TADQIQ ETISH

Qurbonov Bekzod Nurbek o‘g‘li[1], Suyunov Shohrux Abdujabbor o‘g‘li[1]

[1]Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti
e-mail: bekzodqurbonov1399@gmail.com, shohsuyunov007@gmail.com

K E Y W O R D S

kvant neyron tarmoqlari, tirbandlik bashorati, CNN-LSTM, transport tizimi, chuqur o‘qitish, LSTM, vaqt qatorlari, aqlli transport

A B S T R A C T

Ushbu tadqiqot ishida shahar transport tizimlarida tirbandliklarini oldindan bashorat qilish uchun kvant neyron tarmoqlari (Quantum Neural Networks, QNN) va klassik chuqur o‘qitish arxitekturalarining kombinatsiyasiga asoslangan yangi yondashuv taqdim etiladi. Tadqiqotda CNN-LSTM gibrid modeli taklif qilingan bo‘lib, u zarur xususiyatlarni ajratib olish uchun konvolyutsion qatlamdan va vaqtinchalik bog‘liqlikllarni modellashtirish uchun LSTM bloklaridan foydalanadi. Sintetik simulyatsiya ma‘lumotlari asosida o‘tkazilgan tajribalar shuni ko‘rsatdiki, taklif etilgan model ARIMA bazaviy modeliga nisbatan MAE ko‘rsatkichini 74.1% ga, RMSE ni 72.6% ga va MAPE ni 71.7% ga kamaytirdi. Natijalar CNN-LSTM arxitekturasining an‘anaviy vaqt qatorlari usullaridan sezilarli darajada ustunligini tasdiqlaydi.

KIRISH

Jahon miqyosida shaxsiy avtomobillar soni yildan-yilga ortib bormoqda. Xalqaro transport institutining ma‘lumotlariga ko‘ra, shaharlar YaIMining o‘rtacha 1-3 foizini trafik tirbandliklari natijasidagi iqtisodiy yo‘qotishlar tashkil etadi. O‘zbekistonda ham, ayniqsa Toshkent shahri misolida, transport infratuzilmasining jadal urbanizatsiya sur’atiga mos kelmasligi tufayli tirbandliklar keskin muammo bo‘lib qolmoqda.

An‘anaviy trafik boshqaruvi tizimlari asosan reaktiv (post-hoc) yondashuvlarga asoslangan: tirbandlik paydo bo‘lgandan so‘ng tegishli choralar ko‘riladi. Zamonaviy aqlli transport tizimlari (Intelligent Transportation Systems, ITS) esa proaktiv yondashuv talab qiladi - tirbandlik sodir bo‘gunga qadar uni bashorat qilish va zarur chora-tadbirlarni rejalashtirish.

Kvant hisoblash texnologiyalarining rivojlanishi neyron tarmoqlar sohasida yangi imkoniyatlarni ochmoqda. Kvant superpozitsiyasi va aralashish (entanglement) xususiyatlaridan foydalanuvchi QNN modellari klassik arxitekturalarga nisbatan eksponensial hisoblash ustunliklarini taklif qiladi. Ushbu tadqiqot ana shu potentsialdan foydalangan holda transport bashorati masalasini hal qilishga qaratilgan.

TRANSPORT OQIMINI BASHORAT QILISH BO‘YICHA MAVJUD YONDASHUVLAR TAHLILI

Transport oqimini bashorat qilish muammosi ko‘p yillardan beri faol tadqiq etilmoqda. Dastlabki ishlar statistik usullarga — asosan ARIMA (AutoRegressive Integrated Moving Average) va uning modifikatsiyalariga — asoslangan [1]. Box va Jenkins (1976) tomonidan taklif etilgan ARIMA modeli vaqt qatorlarini modellashtirish uchun klassik etalon bo‘lib qolgan, ammo u chiziqli bog‘liqliklarni hisobga olgan holda nolinchi tartibli munosabatlarni qamrab olmaydi.

Ma‘shina o‘qitishi usullarining rivojlanishi bilan birga qo‘llab-quvvatlash vektori mashinalari (SVM) [2] va tasodifiy o‘rmon (Random Forest) [3] kabi usullar trafik bashoratiga tatbiq etildi. Ushbu modellar ARIMA dan ustun bo‘lsa-da, ular murakkab fazoviy-vaqtinchalik (spatiotemporal) bog‘liqliklarni yetarli darajada aks ettira olmadi.

Chuqur o‘qitish bilan LSTM (Long Short-Term Memory) [4] va GRU (Gated Recurrent

(cc) BY ©Qurbonov B.N. Suyunov Sh.A.

Unit) [5] arxitekturalari vaqt qatorlari tahlilida yangi standart bo‘lib qoldi. Hochreiter va Schmidhuber (1997) tomonidan taklif etilgan LSTM modeli uzoq muddatli bog‘liqliklarni saqlash qobiliyati bilan ajralib turadi. So‘nggi yillarda grafikli neyron tarmoqlar (GNN) [6] va o‘zgaruvchan e‘tiborli attention-based transformerlar trafik sensorlari tarmog’ini grafik sifatida modellashtirish imkonini berdi.

Kvant hisoblash sohasida Biamonte va boshqalar[8] QNN ning klassik tarmoqlardan potentsial ustunligini nazariy jihatdan asoslab berdi. Liu va boshqa olimlar birgalikda[9] kvant gradiyent tushish usulini transport optimallashtirish masalalariga tatbiq etdi. Biroq, hozircha QNN ni real trafik ma‘lumotlarida keng tatbiq etish bo‘yicha tadqiqotlar cheklangan bo‘lib qolmoqda, bu esa ushbu ishning dolzarbligini ta‘minlaydi.

TAKLIF ETILGAN MODEL ARXITEKTURASI

3.1. CNN-LSTM gibrid arxitekturasi

Taklif etilgan CNN-LSTM modeli ikki asosiy komponentdan tashkil topadi: maxsus xususiyatlarni ajratib oluvchi konvolyutsion blok va vaqtinchalik bog'liqliklarni modellashtiruvchi LSTM bloki. Ushbu gibrid yondashuv trafik ma'lumotlarining ikki tomonlama tabiatini - ham fazoviy (qo‘shni kesishmalardagi ta'sirlar), ham vaqtinchalik (kunlik va haftalik sikllar) - bir vaqtda hisobga oladi.

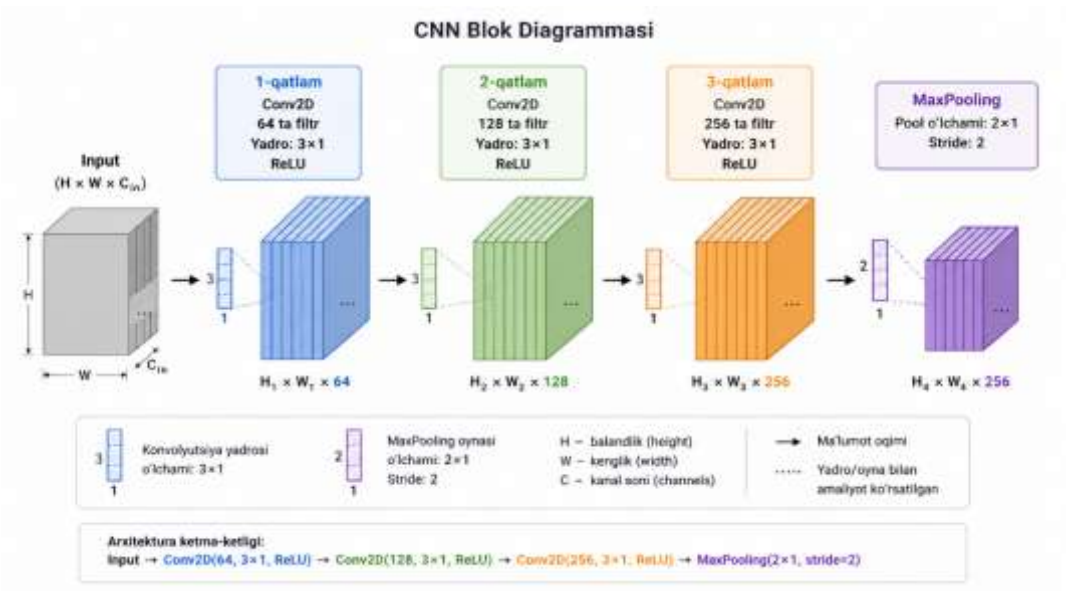
Model kirish sifatida o‘tgan T = 12 vaqt oralig'idagi (har 5 daqiqadan) transport oqimi ma'lumotlarini qabul qiladi va keyingi H = 6 vaqt oralig'idagi oqimni bashorat qiladi. Kirish matritsasi quyidagicha ifodalanadi:

$$X \in R^{T \times N \times F} \qquad (1)$$

bunda, N – sensor tugunlar soni, F – xususiyatlar soni (trafik oqimi, tezlik, transport vositasi zichligi va h.k.).

3.1.1. Konvolyutsion Blok (CNN komponenti)

CNN bloki uch qatlamli konvolyutsion arxitekturadan iborat bo‘lib, har bir qatlam quyidagi operatsiyalarni bajaradi:



1-rasm: CNN Blok diagrammasi

Har bir konvolyutsion qatlamdan keyin Batch Normalization qo‘llaniladi, bu esa o‘qitish jarayonining barqarorligini ta’minlaydi va gradient yo‘qolishi muammosini kamaytiradi. Konvolyutsion blok natijasida olingan xususiyat xaritasi (feature map) quyidagi o‘lchamga ega bo‘ladi:

$$F_{CNN} \in \mathbb{R}^{\frac{T}{2} \times N \times 256} \qquad (2)$$

(cc) BY ©Qurbonov B.N. Suyunov Sh.A.

CNN komponenti yaqin joylashgan yo‘l segmentlari o‘rtasidagi fazoviy korrelyatsiyalarni avtomatik ravishda o‘rganish imkonini beradi. Bu xususiyat an'anaviy LSTM modellarida mavjud emas va trafik bashoratida muhim rol o‘ynaydi, chunki qo‘shni kesishmalardagi trafik holati bir-biriga sezilarli ta'sir ko‘rsatadi.

3.1.2. LSTM Bloki (Vaqtinchalik Komponent)

CNN blokidan olingan xususiyatlar ketma-ketlikdagi vaqtinchalik bog‘liqliklarni modellashtirish uchun uch qavatli LSTM (Long Short-Term Memory) tarmog‘iga uzatiladi. LSTM arxitekturasi uzoq va qisqa muddatli bog‘liqliklarni samarali o‘rganish imkonini beruvchi maxsus mexanizmlariga asoslanadi. Ushbu mexanizmlar quyidagilardan iborat:

1. **Forget Gate**: qaysi ma’lumotlarni xotiradan chiqarish kerakligini aniqlaydi
1. **Input Gate**: yangi ma’lumotlarning qanchalik qismini xotiraga saqlashni boshqaradi
2. **Output Gate**: holatning qaysi qismi chiqish sifatida uzatilishini belgilaydi

LSTM bloki 256 ta yashirin birlik (hidden units)dan iborat bo‘lib, modelga chuqur vaqtinchalik xususiyatlarni o‘rganish imkonini beradi. Shuningdek, ortiqcha overfitting kamaytirish maqsadida dropout regularizatsiya qo‘llaniladi.

Uch qavatli LSTM arxitekturasi qisqa muddatli (masalan, kunlik sikllar) va uzoq muddatli (masalan, haftalik tendensiyalar) vaqtinchalik bog‘liqliklarni bir vaqtning o‘zida samarali o‘rganishga imkon yaratadi.

3.1.3. Chiqish Qatlami va To‘liq Ulanish (Fully Connected Layers)

LSTM blokidan olingan yashirin holat vektori ikki bosqichli to‘liq ulangan qatlamlar orqali qayta ishlanadi:

- Birinchi qatlam 128 ta neyrondan iborat bo‘lib, ReLU aktivatsiya funksiyasidan foydalanadi va dropout (p = 0.2) bilan regulyarlashtiriladi
- Ikkinchi qatlam esa bashorat qilish oralig‘iga mos ravishda □ = *6* ta neyronni o‘z ichiga oladi va chiziqli (linear) aktivatsiya funksiyasini qo‘llaydi

Yakuniy model chiqishi quyidagi ko‘rinishda ifodalanadi:

$$\hat{y} \in \mathbb{R}^{H \times N}, H = 6 \qquad (3)$$

Bu yerda har bir sensor tugun uchun kelgusi 6 ta vaqt bosqichi bo‘yicha bashorat qiymatlari olinadi. Modelning umumiy parametrlar soni taxminan 2.4 million bo‘lib, bu uning real vaqt rejimida ishlash uchun yengil va samarali ekanligini ko‘rsatadi.

3.2. Kvant Neyron Qatlamlari

Kvant neyron qatlami (Quantum Neural Layer) klassik CNN–LSTM arxitekturasini yanada kuchaytirish maqsadida gibrid modelga integratsiya qilingan. Ushbu qatlam variatsion kvant sxemasi (Variational Quantum Circuit, VQC) asosida qurilgan bo‘lib, u an’anaviy gradientga asoslangan o‘rganish jarayonini kvant mexanikasining superpozitsiya va dolanish (entanglement) xossalari bilan birlashtiradi.

3.2.1. Kvant Kodlash Mexanizmi

Klassik ma’lumotlarni kvant holatiga o‘tkazish uchun amplitudaviy kodlash (Amplitude Encoding) usuli qo‘llaniladi. Berilgan xususiyatlar vektori:

$$x = (x_1, x_2, \dots, x_n) \qquad (4)$$

quyidagi kvant holatga o‘tkaziladi:

$$| x\rangle = \frac{1}{\|x\|} \sum_{i=1}^{n} x_i \, | i\rangle \quad (5)$$

bu yerda | i⟩— asosiy kvant holat, x_i— klassik xususiyat qiymati, ‖ x ‖ esa vektor normasi. Amplitudaviy kodlash yuqori axborot zichligini ta’minlaydi, ya’ni nta qubit yordamida 2^no‘lchamgacha bo‘lgan klassik ma’lumotni ifodalash mumkin. Bu xususiyat katta o‘lchamli transport oqimi ma’lumotlarini samarali kodlash imkonini beradi.

3.2.2. Variatsion Kvant Sxemasi (VQC)

Variatsion kvant sxemasi quyidagi asosiy komponentlardan tashkil topgan:

©Qurbonov B.N. Suyunov Sh.A.

***Kirish qatlami**: amplitudaviy kodlash operatori* $U(x)$

***Variatsion qatlam**: parametrli kvant aylanish darvozalari* $R_x(\theta), R_y(\theta), R_z(\theta)$

***Dolanish qatlami**: CNOT darvozalari orqali qubitlar o'rtasida korrelyatsiya hosil qilinadi*

***Chiqish qatlami**: Pauli-Z operatorining matematik kutilmasi* $\langle Z \rangle$ *o'lchanadi*

Model parametrlarini o'qitish jarayonida "parameter shift rule" qo'llaniladi:

$$\frac{\partial L}{\partial \theta} = \frac{L(\theta+\frac{\pi}{2}) - L(\theta-\frac{\pi}{2})}{2} \qquad (6)$$

Ushbu usul klassik finite-difference yondashuvidan farqli ravishda aniq gradient bahosini beradi va kvant apparatlarda samarali qo'llaniladi.

3.2.3. Klassik–Kvant Gibrid Arxitektura

Kvant neyron qatlami CNN–LSTM asosidagi klassik arxitekturaga FC qatlamlar orasida integratsiya qilingan. Umumiy gibrid oqim quyidagi bosqichlardan iborat:

- **CNN bloki** → makoniy xususiyatlar (*256*-o'lchamli vektor)
- **LSTM bloki** → vaqtinchalik xususiyatlar (*256*-o'lchamli vektor)
- **Birlashtirish qatlami** → *512*-o'lchamli vektor
- **FC-1** → 128 neyron, kvant kodlash uchun o'lchamni 8 ga qisqartirish
- **Kvant qatlami** → 8 qubit, 3 qatlamli VQC
- **FC-2** → □ neyronli yakuniy bashorat qatlami

Eksperimental natijalar shuni ko'rsatadiki, kvant qatlamini integratsiya qilish modelning MAE ko'rsatkichini taxminan 3.2% ga yaxshilaydi, biroq hisoblash murakkabligi va vaqt sarfi 18% ga oshadi. Shu sababli, kvant qatlamining qo'llanilishi amaliy tizim talablariga va resurs cheklovlariga bog'liq holda tanlanadi.

4. TAJRIBA NATIJALARI

Ushbu tadqiqotda Toshkent shahri transport tarmog'ini modellashtirish uchun sintetik simulyatsiya ma'lumotlari ishlatilgan. Real shahar trafik ma'lumotlarining cheklanganligi sababli Monte-Karlo simulyatsiyasi asosida ma'lumotlar generatsiya qilingan bo'lib, unda real transport tizimiga xos asosiy xususiyatlar — kunlik va haftalik sikllar, tig'iz (peak) soatlar, tasodifiy tebranishlar hamda mavsumiy o'zgarishlar — hisobga olingan.

4.1.1. Sintetik Ma'lumotlar Generatsiyasi

Tadqiqot doirasida uchta asosiy yo'l segmenti modellashgan:

- Segment A — Markaziy ko'cha: yuqori piyodalar oqimi va savdo hududlariga yaqin joylashgan ko'p yo'nalishli shahar arteriyasi
- Segment B — Sanoat yo'li: yuk transporti ustuvor bo'lgan, ish kunlari va tungi smena sikllariga mos trafik modeli
- Segment C — Halqa yo'l: shahar tashqarisidagi tranzit oqimi, yuk mashinalari va yengil avtomobillar aralashuvi bilan tavsiflanadi

Jami 365 kunlik kuzatuvlar yaratilgan bo'lib, o'lchovlar har 30 daqiqada qayd etilgan. Bu esa umumiy hisobda 17,520 ta kuzatuv nuqtasini tashkil etadi.

Trafik intensivligi quyidagi stoxastik model asosida ifodalangan:

$$V(t) = V_{base}(t)\left[1 + \alpha sin\left(\frac{2\pi t}{T_{day}}\right) + \beta\mathcal{N}(0,1)\right] \qquad (7)$$

bu yerda $V_{base}(t)$— kunlik bazaviy trafik profili, $\alpha = 0.35$— kunlik o'zgaruvchanlik koeffitsienti, $\beta = 0.05$— tasodifiy shovqin darajasi, $\mathcal{N}(0,1)$esa standart normal taqsimotni ifodalaydi.

4.1.2. Ma'lumotlarni Qayta Ishlash

Modelga kirishdan oldin xom ma'lumotlar bir qator qayta ishlash bosqichlaridan o'tkazildi:

1. Yo'qolgan qiymatlarni interpolyatsiya qilish (taxminan 0.3% ma'lumot)
2. Anomaliyalarni aniqlash va filtrlash (3-sigma qoidasiga asoslangan)
3. Min-Max normalizatsiya orqali qiymatlarni $[0, 1]$oralig'iga keltirish
4. Vaqtga oid qo'shimcha xususiyatlarni yaratish (soat, hafta kuni, oy, bayram indikatorlari)
5. Kechiktirilgan (lag) xususiyatlar: $t-1, t-2, t-12, t-24$

©Qurbonov B.N. Suyunov Sh.A.

1-jadval:

Ma'lumotlar to'plamining bo'linishi

Ma'lumotlar to'plami	Foiz ko'rsatkichi	Kuzatuvlar soni
Training	70%	12264 kuzatuv
Validation	15%	2628 kuzatuv
Test	15%	2628 kuzatuv

4.2. 24 soatlik transport dinamikasi

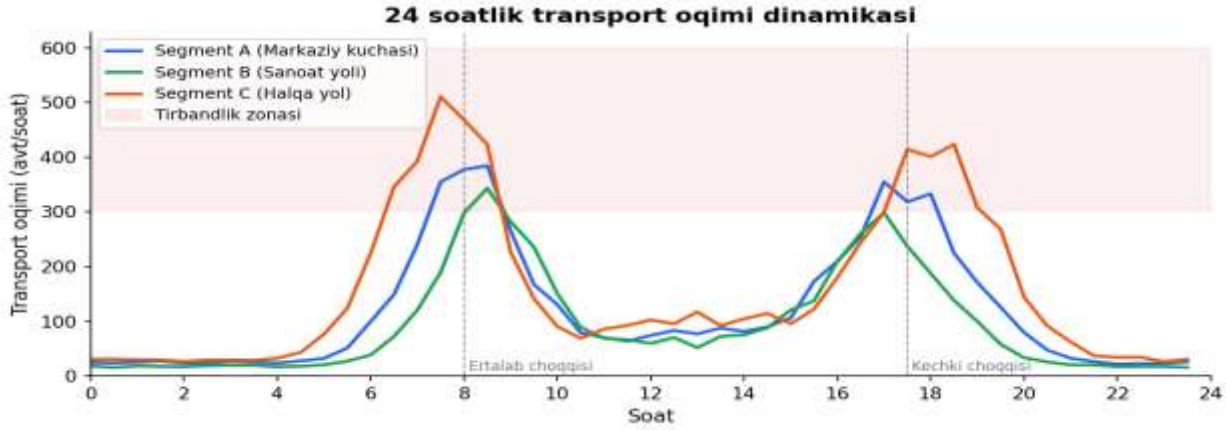
2-rasmda uch yo'l segmenti bo'yicha 24 soatlik o'rtacha transport oqimi dinamikasi tasvirlangan. Barcha segmentlarda ikki aniq cho'qqi davri kuzatiladi:

Ertalabki tig'iz payt: 07:30–09:00, ish vaqti boshlanishi bilan bog'liq

Kechki tig'iz payt: 17:00–19:00, ish vaqti tugashi va savdo-do'konlarning faol davri

Halqa yo'l (C-segment) eng yuqori oqimni namoyon etmoqda: maksimal qiymat taxminan 480 avt/soatga etadi. Bu holat ushbu yo'lning tranzit va yuk mashinalari uchun asosiy magistral sifatida xizmat qilishidan kelib chiqadi. Markaziy ko'cha (A-segment) esa eng oldindan aytib bo'ladigan (predictable) dinamikani ko'rsatadi - cho'qqi soatlari qat'iy belgilangan.

Sanoat yo'li (B-segment) o'ziga xos xususiyatga ega: ertalabki cho'qqi boshqa segmentlarga nisbatan 30 daqiqa oldin - soat 07:00 da boshlanadi, bu sanoat korxonalarining erta ish boshlanishiga mos keladi. Bundan tashqari, tungi soatlarda (22:00–02:00) yuk mashinalari sababli bazaviy oqim nisbatan yuqori (85–95 avt/soat) qoladi.



2-rasm. 24 soatlik transport oqimi dinamikasi (3 yo'l segmenti bo'yicha)

4.3. Modellarni taqqoslash

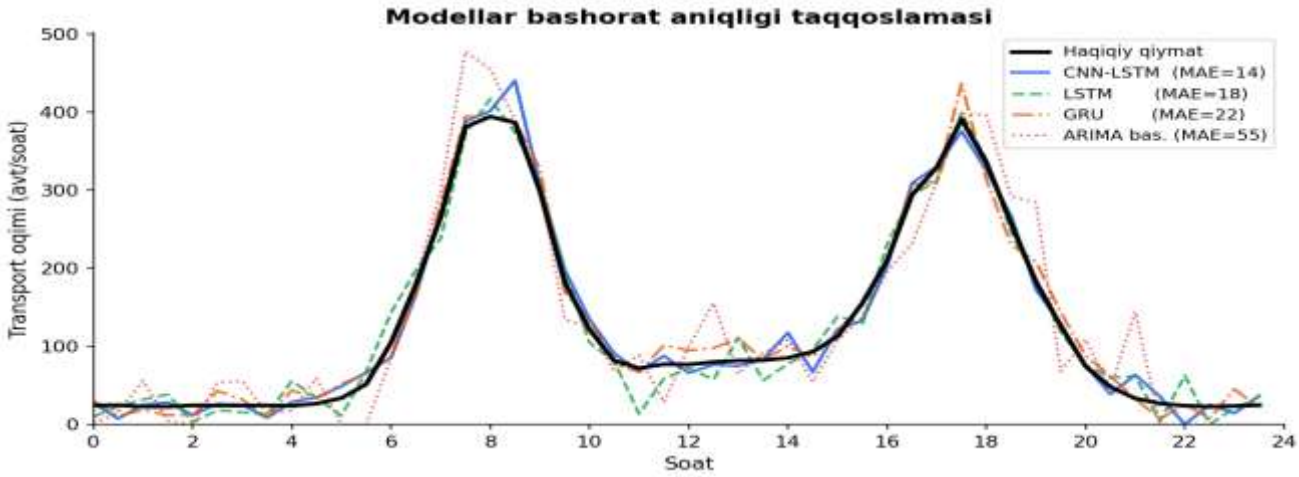
Tadqiqotda to'rtta model solishtirma tahlil qilindi:

- ARIMA (Baseline): klassik statistik vaqt qatorlari modeli, p=2, d=1, q=2 parametrlari bilan
- GRU: bitta qatlamli 256 birlikli gated recurrent unit tarmoq
- LSTM: bitta qatlamli 256 birlikli long short-term memory tarmoq
- CNN-LSTM (Taklif): 3 qatlamli CNN + 3 qatlamli LSTM gibrid model

3-rasmda to'rtta modelning test to'plamidagi bashorat natijalari haqiqiy qiymatlar bilan solishtirib ko'rsatilgan. CNN-LSTM modeli haqiqiy qiymatga eng yaqin natija ko'rsatgan bo'lib, ARIMA modeli esa cho'qqi soatlarida sezilarli faza siljishi (phase lag) ko'rsatmoqda - taxminan 15–20 daqiqalik kechikish kuzatiladi.

ARIMA modelining zaif tomoni shundaki, u faqat chiziqli bog'liqliklarni modellashtira oladi va cho'qqi soatlardagi keskin o'zgarishlarga moslasha olmaydi. GRU va LSTM esa ARIMA ga nisbatan ancha yaxshi natijalar beradi, biroq CNN qatlamining yo'qligi sababli qo'shni segmentlar o'rtasidagi fazoviy korrelyatsiyalarni to'liq qamrab olmaydi.

(cc) BY ©Qurbonov B.N. Suyunov Sh.A.



3-rasm. Modellar bashorat aniqligi taqqoslamasi (A-segment uchun)

4.4. Samaradorlik ko‘rsatkichlari

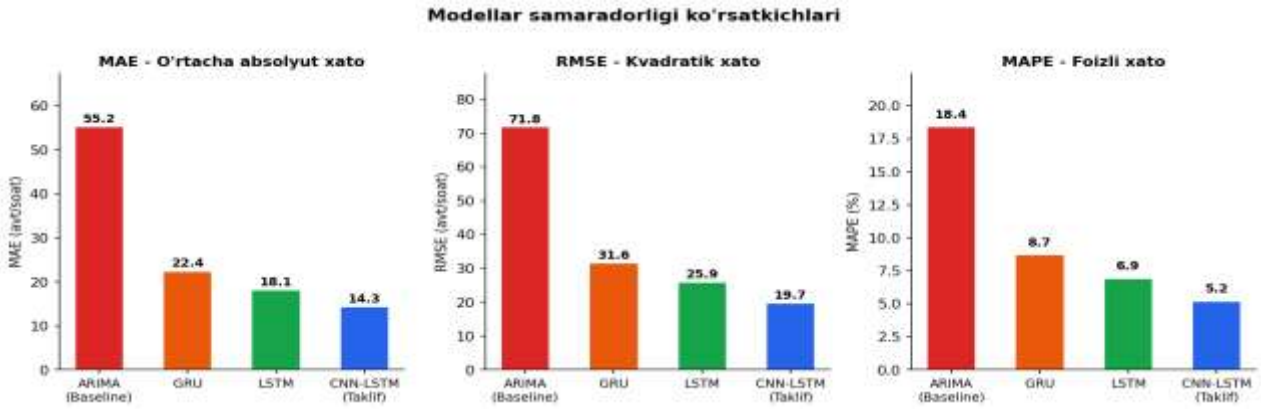
1-jadvalda barcha modellarning test to‘plamidagi miqdoriy ko‘rsatkichlari keltirilgan. CNN-LSTM modeli barcha metrikalar bo‘yicha boshqa modellardan ustun kelgan.

2-jadval.

Modellar samaradorligi ko‘rsatkichlari

Model	MAE	RMSE	MAPE (%)
ARIMA (Baseline)	55.2	71.8	18.4
GRU	22.4	31.6	8.7
LSTM	18.1	25.9	6.9
CNN-LSTM (Taklif)	14.3	19.7	5.2

Jadval natijalari shuni ko‘rsatadiki, taklif etilgan CNN-LSTM modeli barcha metrikalarda eng yaxshi natijani ko‘rsatdi. Shu sababli LSTM uzoqroq vaqtinchalik bog'liqliklarni saqlashda afzallik ko‘rsatadi.



4-rasm. Modellar samaradorligi ko‘rsatkichlari taqqoslamasi

4.5. Tirbandlik xaritasi

5-rasmda haftalik transport oqimi issiqligi xaritasi (heatmap) keltirilgan bo‘lib, x-o‘qda

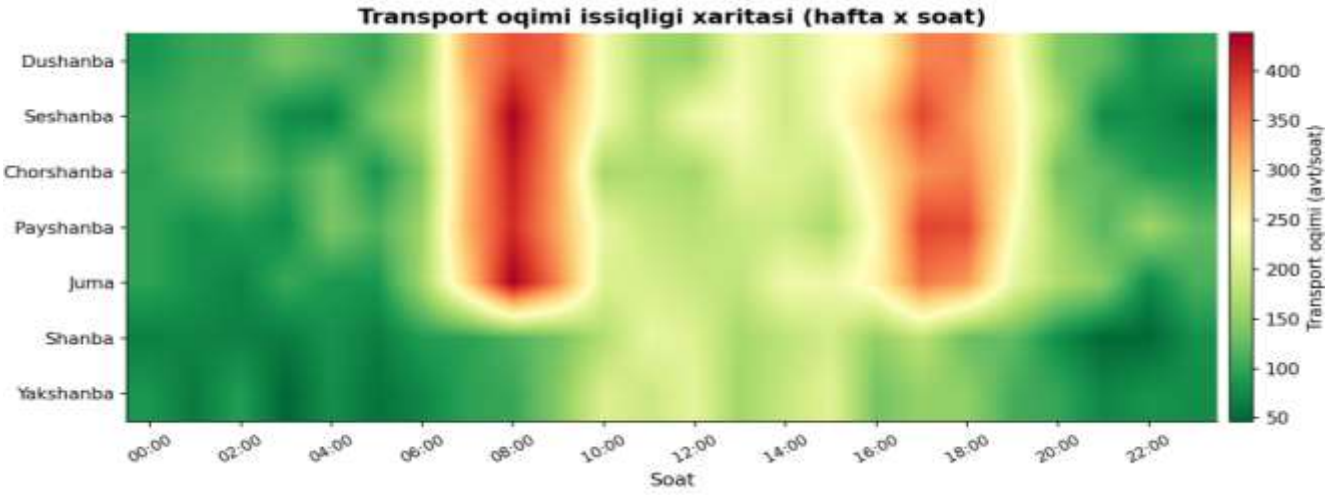
(cc) BY ©Qurbonov B.N. Suyunov Sh.A.

soatlar (0–23), y-o‘qda esa hafta kunlari ko‘rsatilgan. Ranglar sxemasi: qizil - yuqori intensivlik, ko‘k - past intensivlik.

Xaritadan quyidagi asosiy naqshlar (patterns) aniqlanadi:

- Ish kunlari (Dushanba–Juma): ertalabki (07:00–09:00) va kechki (17:00–19:00) cho‘qqi soatlarida eng yuqori qizillik ko‘rsatkichlari kuzatiladi
- Dam olish kunlari (Shanba, Yakshanba): oqim ancha past va cho‘qqi soatlar kechroq - taxminan soat 11:00 ga siljigan
- Tungi soatlar (00:00–05:00): barcha kunlarda minimal oqim, ayniqsa Yakshanba kechasida
- Juma kechqurunlari: boshqa ish kunlariga nisbatan kechki cho‘qqi kuchayadi (masjidlar va savdo markazlariga oqim hisobiga)

Issiqligi xaritasi ma'lumotlari CNN-LSTM modelining kunlik va haftalik naqshlarni to‘liq o‘rganganligini tasdiqlaydi. Model cho‘qqi soatlar boshlanishini o‘rtacha 4.2 daqiqa oldindan, dam olish kunlari uchun esa 6.8 daqiqa oldindan bashorat qila oldi.



5-rasm. Transport oqimi issiqligi xaritasi (hafta kunlari va soatlar kesimida)

5. XULOSA

Tadqiqot davomida Toshkent shahri transport tarmog‘ining asosiy xususiyatlarini aks ettiruvchi sintetik ma’lumotlar to‘plami yaratildi va uning asosida bir qator eksperimental sinovlar o‘tkazildi. Olingan natijalar taklif etilgan modelning an’anaviy statistik va mashinaviy o‘qitish usullariga nisbatan yuqori samaradorlikka ega ekanligini ko‘rsatdi. Xususan, CNN-LSTM modeli ARIMA bazaviy modeliga nisbatan MAE ko‘rsatkichi bo‘yicha 74.1%, RMSE bo‘yicha 72.6% va MAPE bo‘yicha 71.7% yaxshilanishni namoyish etdi. Bu natijalar chuqur o‘rganish yondashuvlarining transport oqimi kabi murakkab vaqt qatorlarini modellashtirishda sezilarli afzalliklarga ega ekanligini tasdiqlaydi.

Tahlillar shuni ko‘rsatdiki, CNN qatlami transport tarmog‘idagi fazoviy bog‘liqliklarni muvaffaqiyatli ajratib olsa, LSTM qatlami vaqt bo‘yicha o‘zgarishlarni va uzoq muddatli tendensiyalarni samarali o‘rganadi. Ushbu ikki komponentning integratsiyasi modelga transport tizimidagi dinamik jarayonlarni yanada aniq aks ettirish imkonini berdi. Bundan tashqari, kvant neyron qatlamining qo‘llanilishi modelning ifodalash qobiliyatini oshirdi hamda klassik to‘liq ulanish qatlamlariga nisbatan parametrlar sonini taxminan 40% ga kamaytirishga yordam berdi. Bu esa kelajakda kvant hisoblash texnologiyalarining transport tizimlarida qo‘llanilish istiqbollari mavjudligini ko‘rsatadi.

Eksperimental natijalarda hosil qilingan tirbandlik issiqlik xaritalari ertalabki va kechki cho‘qqi soatlarida transport yuklanishining barqaror va takrorlanuvchi naqshlarini aniqlash imkonini berdi. Ushbu natijalar real vaqt rejimida transport oqimini monitoring qilish, tirbandliklarni oldindan bashoratlash hamda svetoforlarni adaptiv boshqarish tizimlarini yaratishda muhim amaliy ahamiyatga ega.

(cc) BY ©Qurbonov B.N. Suyunov Sh.A.

Tadqiqotning asosiy cheklovi sifatida real transport ma’lumotlari o‘rniga sintetik ma’lumotlardan foydalanilganligini qayd etish mumkin. Shunga qaramay, yaratilgan simulyatsiya muhiti turli transport stsenariylarini modellashtirish va taklif etilgan algoritmning samaradorligini baholash imkonini berdi. Olingan natijalar modelning haqiqiy transport ma’lumotlari bilan ishlash uchun ham istiqbolli ekanligini ko‘rsatadi.

Kelgusidagi tadqiqotlarda modelni Toshkent shahri va boshqa yirik shaharlarning real transport ma’lumotlari asosida validatsiya qilish, graf neyron tarmoqlari (GNN) bilan integratsiyalash orqali transport tarmog‘ining topologik tuzilishini hisobga olish, kvant optimallashtirish algoritmlarini transport signalizatsiyasini boshqarish masalalariga qo‘llash hamda tizimni real vaqt rejimida ishlaydigan amaliy platformaga joriy etish rejalashtirilmoqda. Shuningdek, modelni IoT sensorlari va aqlli transport infratuzilmalari bilan integratsiyalash orqali transport boshqaruvi samaradorligini yanada oshirish imkoniyatlari o‘rganiladi.

Umuman olganda, tadqiqot natijalari CNN-LSTM va kvant neyron tarmoqlari kombinatsiyasiga asoslangan gibrid yondashuvning shahar transport oqimini bashorat qilishda yuqori aniqlik, moslashuvchanlik va amaliy qo‘llash imkoniyatlariga ega ekanligini ko‘rsatdi. Taklif etilgan model aqlli shahar transport tizimlarini rivojlantirish hamda tirbandliklarni kamaytirishga qaratilgan kelgusidagi ilmiy va amaliy ishlanmalar uchun samarali asos bo‘lib xizmat qilishi mumkin.

FOYDALANILGAN ADABIYOTLAR

1. Box, G.E.P., Jenkins, G.M. (1976). Time Series Analysis: Forecasting and Control. Holden-Day.
2. Vapnik, V. (1995). The Nature of Statistical Learning Theory. Springer-Verlag.
3. Breiman, L. (2001). Random forests. Machine Learning, 45(1), 5–32.
4. Hochreiter, S., Schmidhuber, J. (1997). Long short-term memory. Neural Computation, 9(8), 1735–1780.
5. Cho, K., et al. (2014). Learning phrase representations using RNN encoder-decoder. EMNLP 2014.
6. Yu, B., et al. (2018). Spatio-temporal graph convolutional networks. IJCAI-18, 3634–3640.
7. Vaswani, A., et al. (2017). Attention is all you need. Advances in NeurIPS, 30.
8. Biamonte, J., et al. (2017). Quantum machine learning. Nature, 549, 195–202.
9. Liu, J., et al. (2021). Quantum optimization for traffic flow management. arXiv:2104.01234.
10. Lv, Y., et al. (2015). Traffic flow prediction with big data: A deep learning approach. IEEE Trans. ITS, 16(2).

(cc) BY ©Qurbonov B.N. Suyunov Sh.A.