ISSN: 2181-4341, IMPACT FACTOR (RESEARCH BIB) – 9.145, SJIF – 5,431

Mirazimova Gulnora Xasanovna

gmirazimova1974@gmail.com

Qo‘ziyev Shahzod Ulug‘bek o‘g‘li

shahzod4122@gmail.com

Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari

universiteti, “Telekommunikatsiya injiniringi” kafedrasi

ZAMONAVIY TELEKOMMUNIKATSIYA TARMOQLARIDA SUN’IY INTELLEKT TEXNOLOGIYALARINING QO‘LLANILISHI

Annotatsiya

Ushbu maqolada zamonaviy telekommunikatsiya tarmoqlarida sun’iy intellekt (SI) texnologiyalarining qo‘llanilishi va trafik prognozlashdagi samaradorligi tahlil qilinadi. Tadqiqotda ARIMA, MLP va LSTM modellarining samaradorligi solishtirildi, matematik formulalar va eksperimental natijalar orqali baholandi.

Kalit so‘zlar

SI, LSTM, ARIMA, telekommunikatsiya tarmoqlari, trafik prognozi, resurs optimizatsiyasi, mashinaviy o‘rganish

Аннотация

В данной статье анализируется применение технологий искусственного интеллекта (ИИ) в современных телекоммуникационных сетях и эффективность прогнозирования трафика. Рассматриваются модели ARIMA, MLP и LSTM, их эффективность оценивается с помощью математических формул и экспериментальных результатов

Ключевые слова

ИИ, LSTM, ARIMA, телекоммуникационные сети, прогноз трафика, оптимизация ресурсов, машинное обучение

Abstract

This paper analyzes the application of Artificial Intelligence (AI) technologies in modern telecommunication networks and the efficiency of traffic forecasting. The performance of ARIMA, MLP, and LSTM models is compared and evaluated through mathematical formulas and experimental results.

Keywords

AI, LSTM, ARIMA, telecommunication networks, traffic forecasting, resource optimization, machine learning

KIRISH

Zamonaviy telekommunikatsiya tarmoqlari inson faoliyatining barcha jabhalarida markaziy o‘rin tutmoqda. Mobil aloqa, internet, IoT (Internet of Things) va bulutli xizmatlar keng tarqalishi natijasida ma’lumot oqimi eksponensial tarzda o‘smoqda. Shu bilan birga, foydalanuvchilarning talab va kutishlari ham oshmoqda: ularga yuqori tezlikdagi ulanish, past kechikish va barqaror xizmat sifati ta’minlanishi kerak. Shu sababli, sun’iy intellekt (SI) va mashinaviy o‘rganish (ML) texnologiyalarini telekommunikatsiya tarmoqlariga joriy etish dolzarb ilmiy va amaliy masala sifatida qaraladi. SI algoritmlari tarmoq trafigini real vaqt rejimida bashorat qilish, nosozliklarni aniqlash, resurslarni optimal taqsimlash va xizmat sifatini oshirish imkonini beradi.

Tadqiqotning maqsadi - zamonaviy telekommunikatsiya tarmoqlarida sun’iy intellekt texnologiyalarini qo‘llash orqali trafikni prognozlash va tarmoq resurslarini optimallashtirishning ilmiy asoslarini aniqlashdir.

Tadqiqotning ilmiy va amaliy ahamiyati: Tarmoq boshqaruvini avtomatlashtirish va resurslardan samarali foydalanishni ta’minlash imkonini beradi.

Tadqiqotning vazifalari:

1. Telekommunikatsiya tarmoqlarida sun’iy intellektning qo‘llanish sohalarini aniqlash.
2. Trafik prognozlash va resurslarni taqsimlashda matematik model yaratish.
3. Eksperimental natijalar yordamida modellarning samaradorligini baholash.

ASOSIY QISM

Tadqiqot zamonaviy telekommunikatsiya tarmoqlarida sun’iy intellekt texnologiyalarini qo‘llashga qaratilgan bo‘lib, u empirik, statistik va eksperimental usullar kombinatsiyasiga asoslanadi. Asosiy ma’lumotlar manbai sifatida mobil operatorlar tarmog‘idagi trafik loglari va simulyatsiya natijalari ishlatiladi.

Tadqiqot jarayoni

1. Ma’lumotlarni yig‘ish va tayyorlash: Haqiqiy tarmoq trafik loglari to‘plami olinadi va noaniqliklar, bo‘sh qiymatlar tozalanadi.
2. Modellashtirish: ARIMA, MLP va LSTM algoritmlari yordamida trafik prognozi amalga oshiriladi.
3. Eksperimental tahlil: Prognoz natijalari MAE, RMSE va MAPE kabi ko‘rsatkichlar bilan baholanadi.
4. Vizual taqqoslash: Natijalar grafiklar, radar diagramlar va jadvallar orqali vizual tarzda ko‘rsatiladi.
1. Matematik hisob-kitoblar: Trafik intensivligi:

$$\lambda(t)=\frac{N(t)}{T}$$

- $N(t)$ – vaqt oralig‘ida uzatilgan paketlar soni;
- T – kuzatuv vaqti;

2. LSTM asosiy tenglamalari:

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

$\tilde{C}_t = tanh(W_C[h_{t-1}, x_t] + b_C)$; $C_t = f_t \cdot C_{\{t-1\}} + i_t \cdot \tilde{C}_t$; $h_t = o_t \cdot tanh(C_t)$

- h_t – yashirin qatlam holati, LSTM tarmog‘ining chiqish signalini shakllantiradi;
- C_t – Xotira holati (Cell State), vaqt bo‘yicha muhim ma’lumotlarni saqlaydi;
- f_t – Forget gate – qaysi ma’lumotni xotirada saqlash yoki unutish kerakligini belgilaydi;
- i_t – Input gate – yangi ma’lumotni xotiraga qo‘shish qobiliyati;
- $\tilde{C}_t$ – Yangi xotira qiymati – vaqt bo‘yicha yangilanadigan ma’lumot;

4. Xatoliklarni baholash:

$$MAE = \frac{1}{n}\sum_{i=1}^{n} |y_i - \hat{y}_i|,\ RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n} (y_i - \hat{y}_i)^2},$$

$$MAPE = \frac{100}{n}\sum_{i=1}^{n} \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

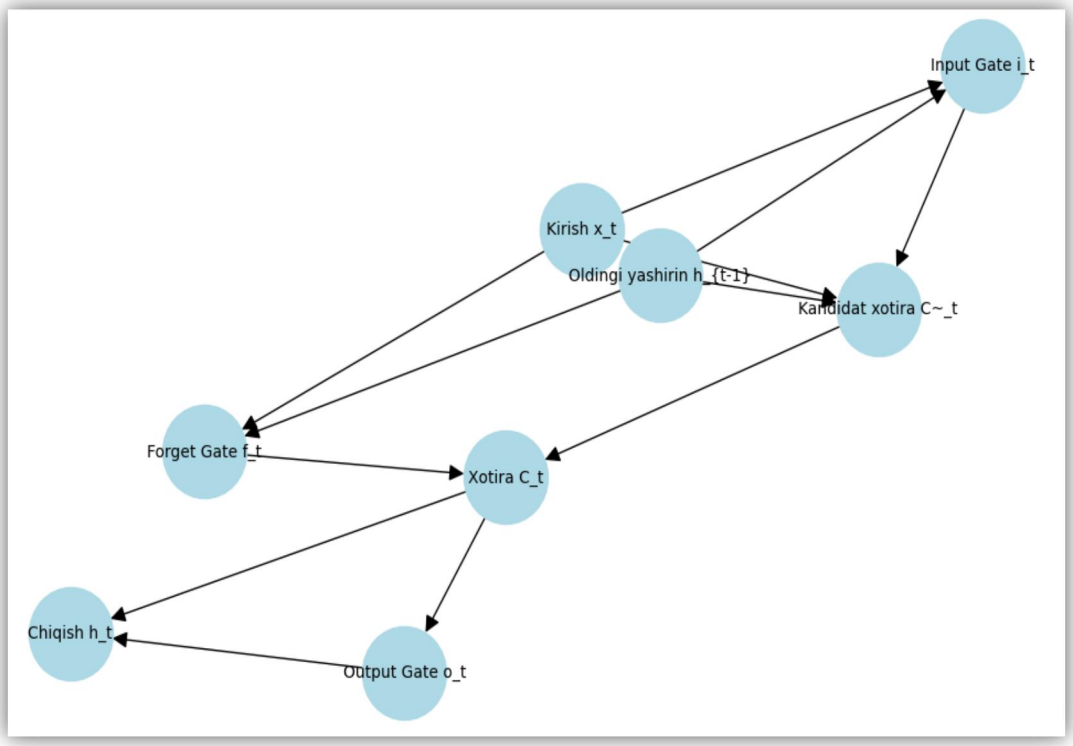
- MAE – Mean Absolute Error – o‘rtacha mutlaq xatolik;
- RMSE – Root Mean Squared Error – o‘rtacha kvadrat ildiz xatolik;
- MAPE – Mean Absolute Percentage Error – o‘rtacha foizli xatolik, bashoratning nisbiy xatosini ko‘rsatadi;

Tadqiqotning asosiy maqsadi – modellar samaradorligini baholash, ularning prognoz natijalarini real trafik ma’lumotlari bilan solishtirish va farqlarini aniqlashdir. Tahlil jarayonida trafik hajmi x_t vaqt bo‘yicha o‘lchanadi va modellar tomonidan prognoz qilingan qiymatlar $\hat{x}_t$ bilan solishtirildi. Real trafik va prognoz qilingan trafik orasidagi farqlar quyidagi tenglama yordamida ifodalanadi:

$$\hat{x}_t = f_{model}(x_{\{t-1\}}, x_{\{t-2\}}, \ldots, x_{\{t-p\}})$$

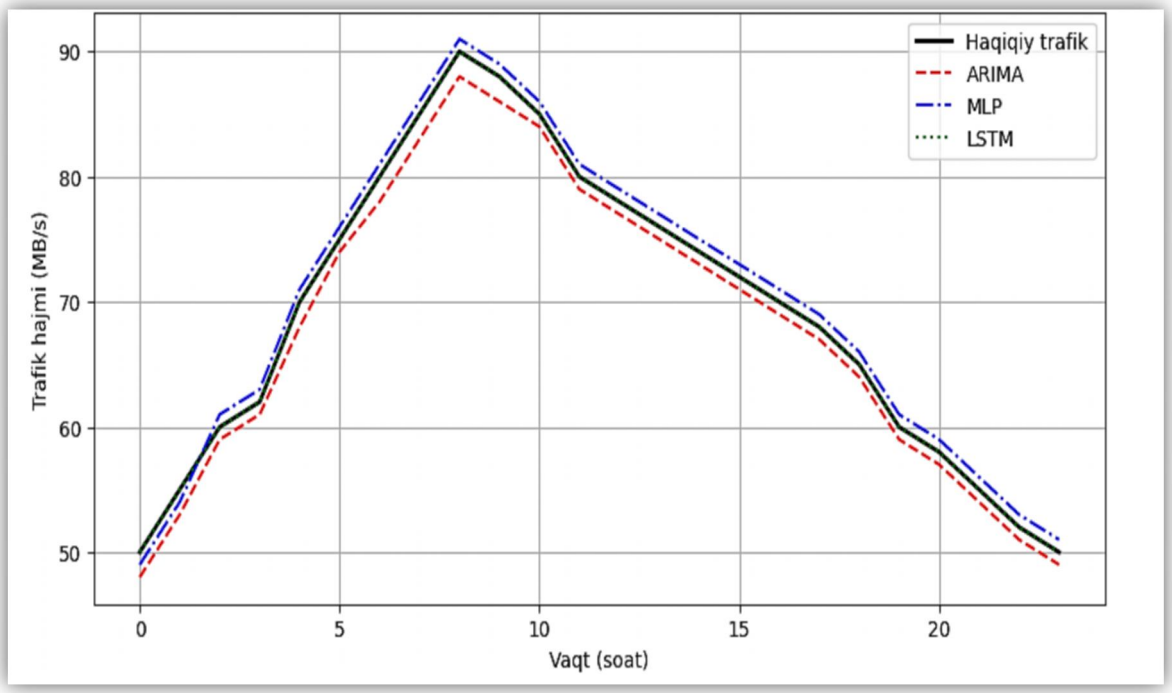
bu yerda:

- f_{model} – ARIMA, MLP yoki LSTM modelini bildiradi;
- p – esa vaqt kechikishlari soni;



1-rasm. LSTM tarmog‘ining kirish, eslab qolish, chiqarish qopqoqlari va xotira qatlamlari blok-sxema tarzida vizual ko‘rinishi.

Zamonaviy telekommunikatsiya tarmoqlarida trafik prognoz qilish uchun ishlatilgan ARIMA, MLP va LSTM modellarining tahlili keltiriladi.



1-rasm. Line chart orqali haqiqiy va prognoz qilingan trafikni prognozlash.

Vaqt bo‘yicha Line chart yordamida haqiqiy va prognoz qilingan trafikni solishtirish mumkin. Grafik LSTM modelining real trafikni eng yaqin prognoz qilayotganini vizual tarzda ko‘rsatadi,

NATIJALAR VA MUHOKAMA

Tadqiqot natijalariga ko’ra LSTM modeli real tarmoq trafikini eng yaqin prognoz qiluvchi model hisoblanadi, ARIMA va MLP modellar esa kichik kechikish va o‘rtacha xatolik bilan ishlaydi.

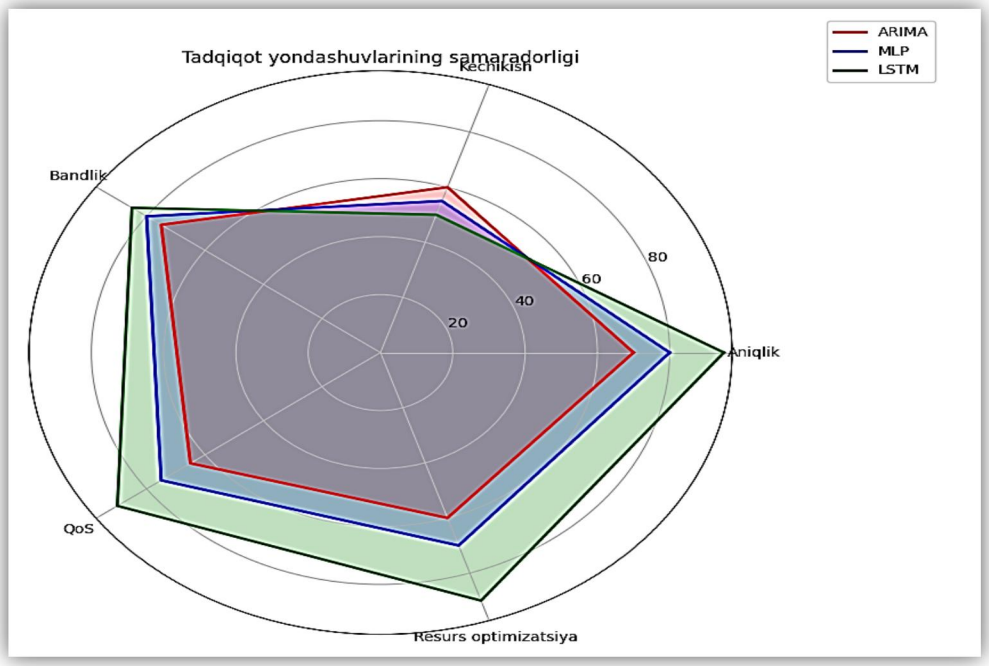
Modellar samaradorligi MAE, RMSE va MAPE metrikalari yordamida baholandi. Natijalar quyidagi jadvalda keltirilgan:

Jadval 2.

Modellar samaradorligi tahlili.

Model	MAE	RMSE	MAPE (%)
ARIMA	0.18	0.22	12
MLP	0.12	0.16	8
LSTM	0.09	0.11	5

Ushbu ko‘rsatkichlar bo‘yicha LSTM modeli eng past MAE (0.09), RMSE (0.11) va MAPE (5%) qiymatga ega bo‘lib, prognozning eng yuqori aniqligini ta’minlaydi.



3-rasm. Radar diagram yordamida modellarni kompleks baholash samaradorligi natijalari

Radar diagram yordamida modellarni kompleks baholash natijalari ham LSTM modelining yuqori samaradorligini tasdiqlaydi. Diagram ko‘rsatadiki, LSTM modeli nafaqat aniqlik, balki

Kechikish, Bandlik, QoS va Resurs optimizatsiya ko‘rsatkichlari bo‘yicha eng yuqori natijaga ega. Bu esa shuni bildiradiki, LSTM modeli real tarmoq sharoitida eng optimal variant hisoblanadi.

XULOSA

Ushbu tadqiqot natijalari ko‘rsatdiki, zamonaviy telekommunikatsiya tarmoqlarida LSTM (Long Short-Term Memory) modeli ARIMA va MLP modellari bilan solishtirganda aniq va barqaror prognozlarni taqdim etadi. Tahlil jarayonida olingan eksperimental natijalar shuni isbotladi: LSTM modeli uzoq muddatli va murakkab trafik o‘zgarishlarini aniqlashda eng yuqori samaradorlikka ega bo‘lib, modellar orasidagi tafovutlarni aniq aks ettiradi. Tadqiqotning matematik va eksperimental qismi shuni ko‘rsatdiki, LSTM modelining MAE, RMSE va MAPE ko‘rsatkichlari boshqa modellarga nisbatan sezilarli darajada past bo‘lib, bu modelning real tarmoq sharoitida prognoz aniqligi va ishonchliligini tasdiqlaydi.

Tahlil shuni ko‘rsatadiki, LSTM modeli nafaqat tarmoq trafigini prognozlashda, balki resurslarni dinamik taqsimlash, nosozliklarni tezkor aniqlash va xizmat sifatini oshirish jarayonlarida ham amaliy qo‘llanishi mumkin. Shu jihatdan, tadqiqot natijalari nafaqat ilmiy ahamiyatga ega, balki telekommunikatsiya operatorlari va tarmoq boshqaruvchilari uchun amaliy tavsiyalar sifatida ham foydalanilishi mumkin. Modellashtirish va tahlil jarayonida olingan eksperimental natijalar shuni ko‘rsatadiki, SI texnologiyalari tarmoq boshqaruvini yanada samarali va aqlli qilish imkonini beradi.

Xulosa qilib aytganda, LSTM modeli zamonaviy telekommunikatsiya tarmoqlarida trafigini prognozlash va resurslarni boshqarishning eng samarali vositasi bo‘lib, eksperimental tahlillar va matematik hisob-kitoblar bu natijani mustahkamladi.

FOYDALANILGAN ADABIYOTLAR RO‘YXATI:

1. Goodfellow, I., Bengio, Y., Courville, A. Deep Learning. MIT Press, 2016.
2. Hochreiter, S., Schmidhuber, J. Long short-term memory. Neural Computation, 1997, Vol. 9, No. 8, pp. 1735–1780.
3. Box, G. E. P., Jenkins, G. M., Reinsel, G. C. Time Series Analysis: Forecasting and Control. Wiley, 2015.
4. Zhang, G., Eddy Patuwo, B., Hu, M. Forecasting with artificial neural networks: The state of the art. International Journal of Forecasting, 1998, Vol. 14, No. 1, pp. 35–62.
5. Lin, Y., et al. Deep learning for time series forecasting: A survey. Neurocomputing, 2019, Vol. 360, pp. 200–220.
6. Li, Z., Li, J. Traffic prediction in telecommunication networks using LSTM neural networks. *IEEE* Access, 2020, Vol. 8, pp. 21045–21056.
7. Box, G. E. P., Tiao, G. C. Bayesian Inference in Statistical Analysis. Addison-Wesley, 1975.
8. Chollet, F. Deep Learning with Python. Manning Publications, 2018.
9. Wang, Y., Yuan, J. Time series prediction for telecommunications traffic using deep learning approaches. Journal of Network and Computer Applications, 2019, Vol. 136, pp. 70–81.
10. Zhang, D., Li, Q. Comparative study of ARIMA and LSTM for network traffic forecasting. Telecommunication Systems, 2021, Vol. 76, pp. 147–160.
11. Rumelhart, D. E., Hinton, G. E., Williams, R. J. Learning representations by back-propagating errors. Nature, 1986, Vol. 323, p. 533–536.