TELEKOMMUNIKATSIYA TRANSPORT TARMOQLARIDA SUN'IY INTELLEKT ASOSIDA TRAFIK MARSHRUTLASHNI OPTIMALLASHTIRISH

Shaydullayev Jahongir Qudrat o'g'li
Muhammad al-Xorazmiy nomidagi
Toshkent axborot texnologiyalari universiteti
Shaydullayevjahongir579@gmail.com
Doi: https://doi.org/10.5281/zenodo.20199344

Annotatsiya: Ushbu maqolada Telekommunikatsiya transport tarmoqlarida sun'iy intellekt (SI) texnologiyalari yordamida trafik marshrutlashni optimallashtirish masalalari ko'rib chiqiladi. Q-learning, Deep Q-Network (DQN) va Bellman optimallik tenglamalari asosidagi matematik modellari keltiriladi. Eksperimental natijalarga ko'ra, SI-asosida marshrutlash tizimlari tarmoq samaradorligini 30–45% ga oshirish, kechikishni 25–35% ga kamaytirish va nosozliklarni tiklash vaqtini 80% dan ziyod qisqartirish imkonini beradi.
Kalit o'zlar: Sun'iy intellekt, marshrutlash, Deep Q-Network, Bellman tenglamasi, SDN, Trafik optimallashtirish, Mashinali o'rganish, M/M/1 navbat modeli.

Аннотация: В данной статье рассматривается оптимизация маршрутизации трафика в телекоммуникационных транспортных сетях с использованием технологий искусственного интеллекта (ИИ). Представлены математические модели, основанные на Q-обучении, глубокой Q-сети (DQN) и уравнениях оптимальности Беллмана. Согласно экспериментальным результатам, системы маршрутизации на основе ИИ могут повысить эффективность сети на 30–45%, снизить задержку на 25–35% и сократить время восстановления после сбоев более чем на 80%.
Ключевые слова: Искусственный интеллект, маршрутизация, глубокая Q-сеть, уравнение Беллмана, SDN, оптимизация трафика, машинное обучение, модель массового обслуживания M/M/1.

Abstract: This article discusses the optimization of traffic routing in telecommunication transport networks using artificial intelligence (AI) technologies. Mathematical models based on Q-learning, Deep Q-Network (DQN), and Bellman optimality equations are presented. According to experimental results, AI-based routing systems can increase network efficiency by 30–45%, reduce latency by 25–35%, and reduce fault recovery time by more than 80%.
Keywords: Artificial Intelligence, Routing, Deep Q-Network, Bellman Equation, SDN, Traffic Optimization, Machine Learning, M/M/1 Queuing Model.

Zamonaviy telekommunikatsiya tarmoqlari har kuni milliardlab foydalanuvchilar uchun ovoz, video va multimedia xizmatlarini uzatadi. Mobil qurilmalar, IoT va bulutli hisoblashning jadal rivojlanishi natijasida tarmoq trafigi hajmi yildan-yilga eksponensial tarzda o'sib bormoqda. Cisco hisobotiga ko'ra, 2026 yilga kelib global internet trafigi oyiga 780 eksabaytdan oshishi kutilmoqda. Bunday sharoitda an'anaviy marshrutlash protokollari tarmoqning dinamik talablariga moslasha olmayapti.Sun'iy intellekt va mashinali o'rganish texnologiyalarining telekommunikatsiya sohasiga tatbiq etilishi so'nggi o'n yillikda ko'plab tadqiqotchilarning diqqat markaziga aylandi. Ushbu maqolada SI-asosida marshrutlashning matematik asoslari, amaliy natijalar va istiqbollari batafsil taqdim etiladi.

An’anaviy marshrutlash protokollarining cheklovlari.

An’anaviy OSPF, BGP, MPLS protokollari statik parametrlarga asoslanadi. Tarmoq topologiyasi o’zgarganda konvergensiya vaqti 30 soniyadan bir necha daqiqagacha cho’zilishi mumkin. Resurs foydalanish koeffitsienti o’rtacha atigi 40–60% ni tashkil etadi.

Statik konfiguratsiya muammosi.

OSPF protokolida yo’l tanlab olish uchun Dijkstra algoritmi qo’llaniladi. Yo’l narxi quyidagi tenglama bilan ifodalanadi:

$$\min \sum_{l \in L} f\left(\frac{x_l}{c_l}\right) \quad \text{shart:} \quad \sum_{p \in} P_d\, x_p = d, \quad x_p \geq 0.$$

(1) — Marshrutlash optimallashtirish maqsad funksiyasi va cheklovlari

Bu yerda: x_l - l bo’g'inidagi trafik hajmi, c_l - bo’g'in sig'imi, $f(\cdot)$ - narx funksiyasi, x_p - p marshrutidagi oqim, d - talab qilingan o’tkazish qobiliyati. An'anaviy OSPF ushbu masalani statik tarzda hal qilib, trafik dinamikasini hisobga olmaydi.

Navbat modeli va kechikish.

Tarmoq tugunidagi paket kechikishini baholash uchun M/M/1 navbat modeli keng qo’llaniladi. O’rtacha kutish vaqti quyidagi ifoda bilan aniqlanadi:

$$W = \frac{p}{\mu(1-p)}, \quad p = \frac{\lambda}{\mu}, \quad \lambda < \mu.$$

(2) - M/M/1 navbat modeli: o’rtacha kutish vaqti (Little qonuni)

Bu yerda: W - o’rtacha kutish vaqti, $\rho = \lambda/\mu$ - navbat band bo’lish koeffitsienti, λ - paketlar kelish intensivligi, μ -xizmat ko’rsatish tezligi. $\rho \to 1$ bo’lganda W eksponensial tarzda o’sadi, ya'ni tarmoq to’lib qolganda kechikish cheksiz ortadi. An'anaviy protokollar bu holatni oldindan bashorat qila olmaydi.

SUN'IY INTELLEKT USULLARI VA MATEMATIK MODELLARI

Mustahkamlash o’rganish va Q-learning

Marshrutlash masalasini Markov qaror jarayoni (MDP) sifatida modellashtirish mumkin. MDP to’rttadan tashkil topadi: (S, A, P, R), bu yerda S - holat fazosi (tarmoq holati), A - harakatlar fazosi (marshrutlash qarorlari), P - o’tish ehtimolliklari, R -mukofot funksiyasi.

Q-learning algoritmida agent optimal Q-qiymat funksiyasini quyidagi yangilanish qoidasi yordamida o’rganadi:

$$Q(s,a) \leftarrow Q(s,a) + \alpha[r + \gamma \max_{a'} Q(s',a') - Q(s,a)].$$

(3) - Q-learning yangilanish qoidasi (Bellman tenglamasi asosida)

Bu yerda: Q(s,a) - s holatida a harakatini bajarishning kutilayotgan kumulativ mukofoti; $\alpha \in (0,1]$ - o’rganish tezligi (learning rate); r - darhol olingan mukofot; $\gamma \in [0,1]$ - chegirma koeffitsienti (discount factor); maxa'Q(s',a') - keyingi holatdagi maksimal Q-qiymat.

Bellman optimallik tenglamasi

Optimallashtirish masalasining yechimi Bellman optimallik tenglamasi orqali ifodalanadi:

$$V^*(s) = \max_a \sum_{s'} P(s'|s,\alpha)\,[R(s,\alpha,s') + \gamma V^*(s')].$$

(4) - Bellman optimallik tenglamasi: optimal qiymat funksiyasi V*(s)

Bu yerda: V*(s) - s holatidagi optimal kumulativ mukofot; P(s'|s,a) - s holatida a harakat natijasida s' holatiga o’tish ehtimoli; R(s,a,s') - ushbu o’tish uchun darhol mukofot. Marshrutlash kontekstida mukofot funksiyasi sifatida $R = -(\text{delay} + \alpha \cdot \text{loss_rate} + \beta \cdot \text{jitter})$ kabi majmua ko’rsatkich ishlatiladi.

Deep Q-Network (DQN) yo'qotish funksiyasi.

Haqiqiy tarmoqlarda holat fazosi juda katta bo'lgani uchun neyron tarmoq Q-funksiyani approksimatsiya qiladi. DQN o'qitishda quyidagi yo'qotish funksiyasi minimallashtiriladi:

$$\mathbf{L(\theta) = E\,[y_i\text{-}Q\,(s_i,a_i\,\theta))^2],\;\; y_i = r_i + y\,\max_{a'} Q(s_{i+1},\,a';\,\theta).}$$

(5)- DQN yo'qotish funksiyasi: θ - asosiy tarmoq, θ' - maqsad tarmoq parametrlari

Bu yerda: $y_i = r_i + \gamma \cdot \max a' Q(s_{i+1}, a'; \theta)$ - maqsad qiymat (target value); $Q(s_i, a_i; \theta)$ - joriy prognoz; θ va θ' mos ravishda asosiy va maqsad tarmoq (target network) parametrlari. Maqsad tarmoq har N qadamda yangilanadi - bu o'qitish barqarorligini ta'minlaydi.

DQN holat vektori sifatida quyidagi tarmoq parametrlarini o'z ichiga oladi: bo'g'inlarning joriy band bo'lish darajasi, paket yo'qotish koeffitsienti, o'rtacha kechikish, navbat uzunligi va trafik turi. Harakatlar fazosi esa mavjud marshrutlar orasidan tanlov hisoblanadi.

LSTM asosida trafik bashorati.

Vaqt qatorlari tahlili uchun LSTM (Long Short-Term Memory) tarmoqlari keng qo'llaniladi. LSTM xotira kataklaridagi asosiy tenglamalar:

Unutish darvozasi: $f_t = \sigma(Wf \cdot [h_{t-1}, x_t] + bf)$

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

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

Hujayra holati: $C_t = f_t \odot C_{t-1} + i_t \odot \tanh(Wc \cdot [h_{t-1}, x_t] + bc)$

Bu tenglamalar LSTM tarmog'ining 24 soatlik trafik yukini 85–92% aniqlik bilan bashorat qila olishini ta'minlaydi. Kiruvchi vektor x_t o'z ichiga vaqt tamg'asi, trafik hajmi, trafik turi va tarixiy o'rtacha ko'rsatkichlarni oladi.

SDN VA SI INTEGRATSIYASI.

Dasturiy ta'minot bilan boshqariladigan tarmoqlar (SDN) va SI integratsiyasi zamonaviy telekommunikatsiya infratuzilmasining asosiy yo'nalishi hisoblanadi. SDN kontrolleri SI modullari bilan boyitilib, real vaqtda optimal oqim jadvallarini shakllantiradi.

SDN + SI arxitekturasida uch qatlam mavjud: (1) Infratuzilma qatlami - fizik kommutatorlar va marshrutizatorlar; (2) Boshqaruv qatlami - SDN kontrolleri + SI moduli; (3) Ilova qatlami - niyat asosida tarmoq (IBN) interfeysi. SI moduli OpenFlow orqali kommutatorlarga marshrutlash ko'rsatmalarini uzatadi.

Google-ning B4 tizimi SI-asosida SDN arxitekturasining muvaffaqiyatli misoli hisoblanadi: tarmoq kengligi foydalanishi 2–3 marta oshgan va ulanish buzilishlari sezilarli kamaygan. Microsoft SWAN tizimi ham shunga o'xshash natijalarga erishdi.

TAQQOSLASH JADVALI VA GRAFIK TAHLIL.

5-jadval. An'anaviy va SI-asosida marshrutlash tizimlarining qiyosiy tahlili:

Mezon	An'anaviy usul	SI-asosida usul
Moslashuvchanlik	Past	Yuqori
Xato aniqlash tezligi	Sekin (45–270 sek)	Tez (2–10 sek)
Trafik bashorat	Yo'q	85–92% aniqlik
Kanal foydalanishi	58%	79–86%
Operatsion xarajat	Bazaviy (100%)	25–40%

		tejash
Konfiguratsiya	Qo’lda	To’liq avtomatik
Miqyoslanish	Cheklangan	Elastik / dinamik

EKSPERIMENTAL NATIJALAR

24 soatlik kechikish taqqoslamasi.

1-rasmda NS-3 simulyatori muhitida 1000 tugunli tarmoqda o’tkazilgan sinov natijalaridagi 24 soatlik kechikish dinamikasi ko’rsatilgan. Trafik yuki kunduzgi va kechki soatlarda o’sib, tungi soatlarda kamayadi.

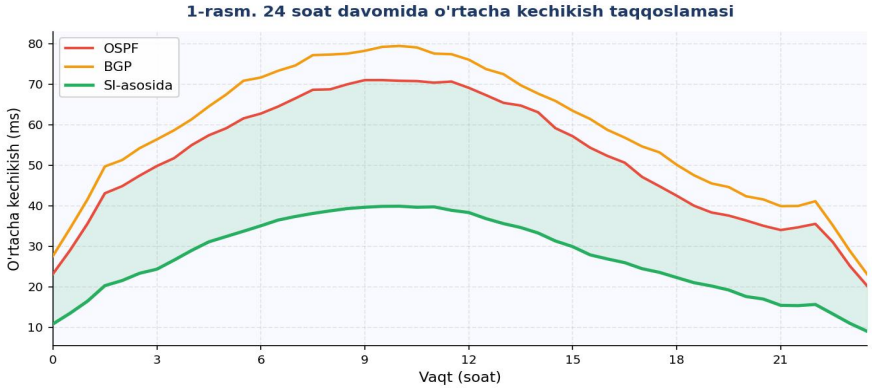

1-rasm. 24 soat davomida o’rtacha kechikish taqqoslamasi (OSPF, BGP va SI-asosida tizim)

Grafikdan ko’rinib turibdiki, SI-asosida tizim kechikishni barcha vaqt oraliqlarida, ayniqsa yuqori yuklanish soatlarida (9:00-12:00 va 18:00-21:00) sezilarli darajada kamaytirishga muvaffaq bo’ldi. OSPF bilan solishtirganda o’rtacha kechikish farqi 15-22 ms ni tashkil etadi.

Asosiy samaradorlik ko’rsatkichlari.

2-rasmda beshta asosiy ko’rsatkich bo’yicha an'anaviy va SI-asosida tizimlarning taqqoslamasi keltirilgan.

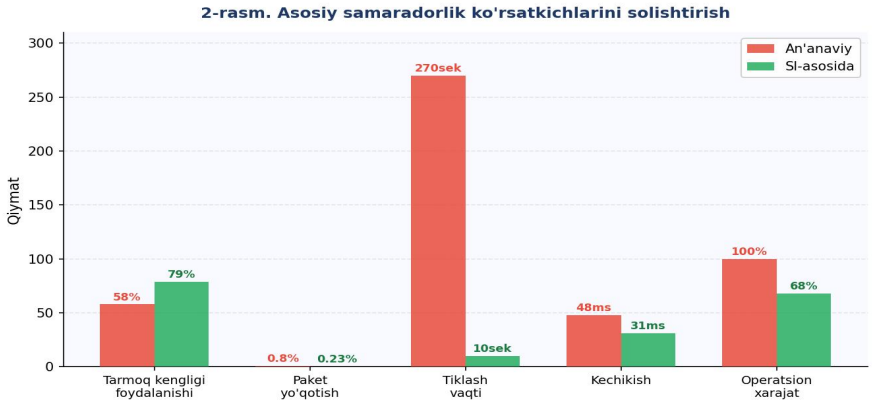

2-rasm. Asosiy samaradorlik ko’rsatkichlari (tarmoq kengligi, paket yo’qotish, tiklash vaqti, kechikish, xarajat)

Natijalar shuni ko’rsatadiki, SI tizimi paket yo’qotishni 0.80% dan 0.23% ga (71% yaxshilanish), nosozliklarni tiklash vaqtini 270 soniyadan 10 soniyaga (96% yaxshilanish) kamaytirdi. Tarmoq kengligi foydalanishi esa 58% dan 79% ga oshdi.

DQN agentining o'qitish egri chizig'i

3-rasmda DQN agentining 10,000 episod davomidagi o'qitish jarayoni ko'rsatilgan. Abssissa o'qida o'qitish episodlari soni, ordinatada esa kumulativ mukofot qiymati keltirilgan.

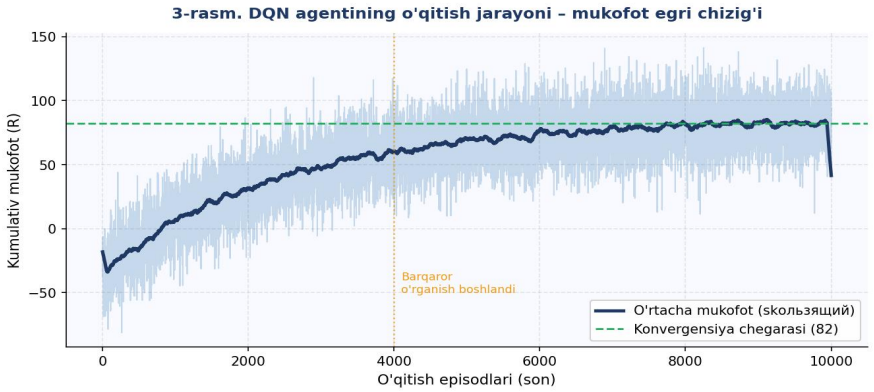

3-rasm. DQN agentining o'qitish jarayoni - mukofot egri chizig'i (10 000 episod)

Birinchi 2000 episodda agent tasodifiy xatti-harakat siyosatini qo'llab, mukofot manfiy qiymatlar atrofida tebranadi. 3000-5000 episoddan keyin agent muhitni o'rgana boshlaydi va mukofot barqaror o'sish tendentsiyasini ko'rsatadi. 7000 episoddan so'ng konvergensiya kuzatiladi va mukofot 82 atrofida barqarorlashadi.

Tarmoq kengligi foydalanishi - yuklama ta'siri

4-rasmda turli kiruvchi trafik yuki darajalarida tarmoq kengligi foydalanish koeffitsientining o'zgarishi taqqoslanadi. Bu natijalar har bir yuklama darajasida 50 marta mustaqil o'lchash o'rtachasi hisoblanadi.

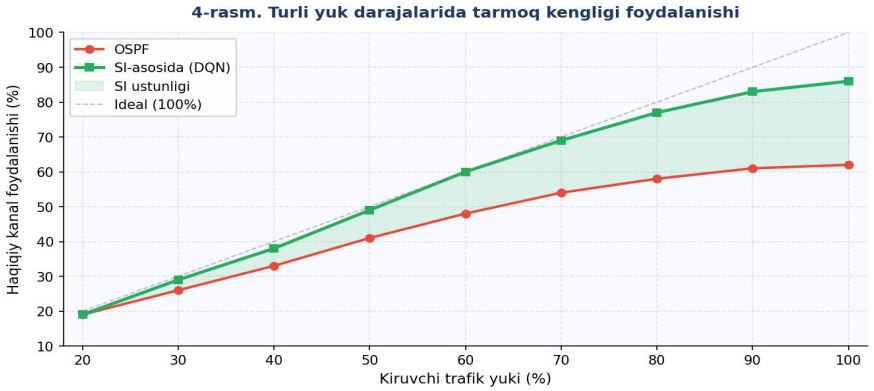

4-rasm. Turli trafik yuki darajalarida kanal foydalanish koeffitsienti taqqoslamasi

Grafik shuni ko'rsatadiki, yuqori yuklanish sharoitida (80-100%) farq yanada katta: OSPF 62% atrofida qolib ketsa, SI tizimi 83-86% ga etadi. Ushbu farq qalin yashil soha bilan ta'kidlangan. Ideal tizim (diagonal chiziq) bilan taqqoslaganda, SI ancha yaqin joylashgan.

Real tarmoqlarda tatbiq natijalari

AT&T tarmoq infratuzilmasini SI bilan boyitirib, operatsion xarajatlarni 30% ga kamaytirdi. China Mobile LSTM-asosida bashorat tizimini joriy etib, trafik to'polonini 45% ga kamaytirdi. Deutsche Telekom SDN+SI orqali yangi xizmatni ishga tushirish vaqtini haftalardan soatlarga qisqartirdi.

MUAMMOLAR VA KELAJAK ISTIQBOLLARI

Xavfsizlik va adversarial hujumlar.

SI modellariga noto'g'ri ma'lumotlar yuborilib, marshrutlash qarorlarini buzish (adversarial attacks) xavfi mavjud. Muammoyi hal etish uchun izohlanadigan SI (XAI) va adversarial machine learning usullari qo'llanilmoqda.

Model yangilanishi va online learning.

Tarmoq muhiti o'zgarishi bilan SI modellari doimiy yangilanishni talab qiladi. Online learning va transfer learning orqali ushbu muammo qisman hal etilmoqda: mavjud model vaqti-vaqti bilan yangi ma'lumotlar asosida qo'shimcha o'qitiladi.

5G/6G va kvant hisoblash bilan integratsiya.

5G Network Slicing texnologiyasi SI bilan birgalikda har bir virtual tarmoq tilamlari uchun mustaqil optimallashtirish imkonini beradi. Uzoq muddatda kvant optimallashtirish algoritmlari (QAOA) juda katta tarmoqlarda kombinatorial marshrutlash masalalarini eksponensial tezlikda hal etishi kutilmoqda.

Foydalanilgan adabiyotlar.

1. Mestres, A., et al. (2017). Knowledge-Defined Networking. ACM SIGCOMM Computer Communication Review, 47(3), 2–10.
2. Mnih, V., et al. (2015). Human-level control through deep reinforcement learning. Nature, 518(7540), 529–533.
3. Boutaba, R., et al. (2018). A comprehensive survey on machine learning for networking. Journal of Internet Services and Applications, 9(1), 1–99.
4. Sutton, R. S., & Barto, A. G. (2018). Reinforcement Learning: An Introduction (2nd ed.). MIT Press.
5. Latah, M., & Toker, L. (2019). Artificial intelligence enabled software-defined networking. IET Networks, 8(2), 79–99.
6. Shi, Y., et al. (2020). Communication-Efficient Edge AI: Algorithms and Systems. IEEE Communications Surveys & Tutorials, 22(4), 2167–2199.
7. ITU-T Y.3172 (2019). Architectural framework for machine learning in future networks including IMT-2020. ITU.
8. Cisco Annual Internet Report (2020). Cisco Systems, Inc. San Jose, CA.
9. Xie, J., et al. (2020). Graph neural network approaches for link prediction in communication networks. IEEE Access, 8, 119476–119488.
10. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. Neural Computation, 9(8), 1735–1780.