TELEKOMMUNIKATSIYA TIZIMLARIDA MA'LUMOTLARNI UZATISH SAMARADORLIGINI NEYRON TARMOQLAR YORDAMIDA OSHIRISHNING QIYOSIY TAHLILI VA SIMULYATSIYASI

Mirzayeva Malika Baxadirovna[1, 2]

[1] *"Toshkent irrigatsiya va qishloq xo'jaligini mexanizatsiyalash muhandislari instituti" Milliy tadqiqot universiteti, Raqamli texnologiyalar va sun'iy intellekt kafedrasi dotsenti*
[2]*Tashkent International University*
ORCID: 0000-0002-1791-6715
E-mail: malikamirzaeva01@gmail.com

K E Y W O R D S

neyron tarmoq, chuqur o'qitish, kanal dekodlash, BER–SNR, Hamming kodi, AWGN, simulyatsiya, spektral samaradorlik, telekommunikatsiya, 5G

A B S T R A C T

Maqola ikki qismni ichiga olgan bo'lib, birinchi qismda, telekommunikatsiyada ma'lumotlarni uzatishning turli bosqichlarida neyron tarmoqlarni qo'llash bo'yicha ishlar tahliliy sharh ko'rinishda umumiylashtirilgan. Ikkinchi qismda Python muhitida Hamming (7,4) kodi, BPSK modulyatsiyasi va AWGN kanali uchun BER-SNR simulyatsiyasi o'tkazilib, chuqur neyron tarmoqqa (DNN) asoslangan dekoder an'anaviy qattiq qarorli dekoder bilan taqqoslangan. Natijalar DNN dekoder bit xatoligi koeffitsienti (BER)=10-3 darajada an'anaviy usulda 1,2 dB ustun bo'lib, optimal soft ML dekoderlashga deyarli teng natija berishini ko'rsatdi.

Kirish

Mobil aloqaning beshinchi (5G) va kelgusi oltinchi (6G) avlodlariga o'tish bilan tarmoqlarga ulanadigan qurilmalar soni, uzatiladigan ma'lumotlar hajmi va xizmat sifatiga qo'yiladigan talablar keskin oshmoqda. Cheklangan chastota va energiya resurslari ma'lumotlarni ishonchli, yuqori tezlikda va kam kechikish bilan uzatish telekommunikatsiyaning markaziy vazifasi bo'lib qolmoqda. An'anaviy yondashuvlarda fizik sath masalalari (kanal kodlash, modulyatsiya, signalni aniqlash) aniq matematik modellar va iterative algoritmlar yordamida hal etiladi, biroq real kanallarning nochiziqliligi va o'zgaruvchanligi tufayli bu usullar yuqori hisoblash murakkabligiga ega bo'ladigan yoki optimal yechimga faqat taxminan yaqinlashadi. Sun'iy neyron tarmoqlar katta hajmdagi ma'lumotlarndan nochiziqli bog'lanishlarni o'rganish qobiliyati bilan bu cheklovlarni bartaraf etishda istiqbolli vosita hisoblanadi [13].

Ushbu ishning maqsadi ikki yo'nalishda belgilangan. Birinchidan, telekommunikatsiyada ma'lumotlarni uzatish samaradorligini neyron tarmoqlar yordamida oshirish bo'yicha zamonaviy ilmiy adabiyotlarning qiyosiy tahliliy sharhi keltiriladi. Ikkinchidan, mustaqil bajarilgan simulyatsion eksperiment orqali neyron tarmoqli dekoderning an'anaviy usulga nisbatan haqiqiy ustunligi miqdoriy baholanadi. Shu tariqa maqola sharh-tahliliy xarakterga ega bo'lib, uni original eksperimental tekshiruv bilan to'ldiriladi.

Maqolada quyidagi vazifalar hal etiladi: neyron tarmoqlarning fizik va tarmoq sathidagi masalalarga tatbiqni tizimli ko'rib chiqish, turli tadqiqotlardagi natijalarni shartli ravishda umumlashtirish. Hamming (7,4) kodi misolda chuqur neyron tarmoqli dekoder uchun BER-SNR bog'liqligini simulyatsiya qilish va an'anaviy dekoderlash bilan taqqoslash.

Fizik sathda chuqur o'qitishni qo'llashning asos soluvchi g'oyalaridan biri uzatuvchi – kanal – qabul qiluvchi zanjirini yagona avtokoder (autocoder) ko'rinishda modellashtirib butun tizimni uchidan-uchiga (end-to-end) o'qitishdir [1]. Keyingi yillarda 5G va 6G tarmoqlarning fizik sathida neyron tarmoqlarni qo'llash bo'yicha keng sharhlar e'lon qilingan bo'lib, ulardaa kanalni baholash, kodlash – dekoderlash va resurlarni taqsimlash masalalari ajratib ko'rsatilgan [2].

(cc) BY

Kanal kodlash sohasida 5G uchun tanlangan polar va past zichlikdagi juftlik- tekshiruv (LDPC) kodlarni neyron tarmoqlar yordamida dekoderlash faol o‘rganilmoqda. Chuqur o‘qitishga asoslangan polar dekoderlar an’anaviy successive cancellation va belief propogation algoritmlariga nisbatan xatoga chidamlilik bo‘yicha yaxshilanish berishi ko‘rsatilgan [3]. LDPC kodlarni dekodlashda Offset Min-Sum algoritmini konvolyutsion neyron tarmoq (CNN) bilan birlashtirish so‘nuvchi va rangli shovqinli kanallarda dekodlash sifatini oshirishi aniqlangan [4]. Qisqa chiziqli kodlarni neyron tarmoq orqali dekoderlash bo‘yicha klassik ishlarda esa o‘qitilgan dekoder maksimal ishonchlilik (maximum-likelihood) dekodlashga yaqinlasha olishi namoyish etilgan [11, 12].

Tarmoq sathida rekkurent neyron tarmoqlar (RNN), uzoq qisqa muddatli xotira (LSTM) va boshqariladigan recurrent bloklar (GRU) yordamida trafikni bashoratlash energiya tejashning samarali vositasi ekanligi ko‘rsatilgan [5]. Heterogen tarmoqlarda (HetNet) quyi kanal va quvvatni taqsimlashda CNN to‘liq sanab chiqish usuliga yaqin natijani ancha kam hisoblash vaqtida ta’minlashi [6], DNN asosidagi 5G MIMO tizimi esa turli QAM tartiblarida BER va spectral samaradorlikni yaxshilash qayd etilgan [7]. Kognitiv radio tarmoqlarida neyron optimallashtirish usullari o‘tkazuvchanlikni oshirishi [8], bulutli ma’lumot markazlarida ko‘p resursli neyron bashoratlash quvvat tejashni ta’minlashi [9], simsiz sensor tarmoqlarida esa neyron tarmoq orqali ma’lumotlarni birlashtirish ortiqcha uzatishlarni kamaytirishi ko‘rsatilgan [10].

Quyidagi 1-jadvalda turli tadqiqotlarda keltirilgan natijalar umumlashtirilgan. Shuni alohida ta’kidlash zarurki, ushbu ko‘rsatkichlar bir-biridan farq qiluvchi kanal modellari, signal/shovqin diapazonlari, modulyatsiya turlari va ma’lumotlar to‘plamlarida olingan, shu sababli ular bevosita son bo‘yicha taqqoslash uchun emas, balki neyron tarmoqlarning umumiy istiqbolini ko‘rsatish uchun keltiriladi.

1-jadval

Adabiyotlarda neyron tarmoqlarni qo‘llash bo‘yicha natijalar (turli tadqiqotlar, turli sharoitlar)

Soha	Tarmoq turi	Sharoit (manbada keltirilgan)	Qayd etilgan samara
Kanal dekodlash	CNN + Min-Sum	5G IoT; Rayleigh/Rician so‘nuvchi, rangli shovqin	So‘nuvchi kanalda BER pasayishi
MIMO aniqlash	DNN	MIMO; 4/16/256-QAM modulyatsiya	BER va spektral samaradorlik o‘sishi
Trafik bashorati	OS-ELM / LSTM / GRU	Real hujayrali/markaz trafigi, vaqtli qatorlar	Energiya tejash (~12% gacha)
Resurs taqsimoti	CNN	OFDM HetNet; quvvat va quyi kanal	Exhaustive'ga yaqin, vaqt kam
Kognitiv radio	Neyron optimallashtirish	Spektrni baham ko‘rish; lab. va real	O‘tkazuvchanlik o‘sishi
Ma'lumot markazi	Ko‘p resursli FNN	Bulutli markaz, real workload	Quvvat tejash, resurs ishlatilishi

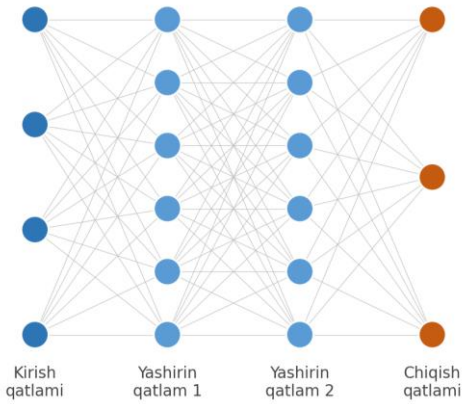
Endi tarmoqlarning umumiy tamoyillarini ko‘rib chiqamiz. Sun’iy neyron tarmoq o‘zaro bog‘langan neyronlar qatlamlaridan iborat bo‘lib, har bir neyron kirish signallarining yig‘indisi hisoblab, uni nochiziqli aktivatsiya funksiyasi orqali o‘tkazadi. Bitta neyronning chiqishi quyidagicha

$$y = f(\sum_{i=1}^{n} w_i x_i + b)$$

Bu yerda x_i -kirish signallari, w_i -og‘irliklar, b -siljish, f -aktivatsiya funksiyasi (ReLU, sigmoid yoki tanh). Chuqur neyron

(cc) BY

tarmoqda bunday qatlamlar ketma-ket joylashtirilib, murakkab nochiziqli akslantirish hosil qilinadi (1-rasm).

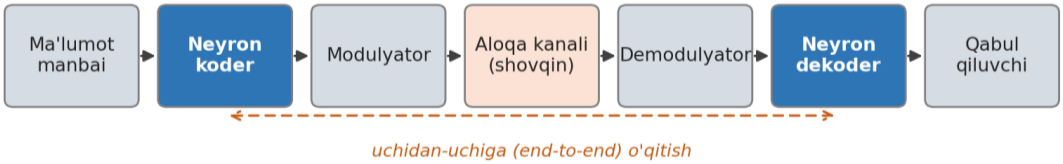


1-rasm. Chuqur neyron tarmoqning umumlashgan strukturasi

Tarmoq parametrlari o‘qitishda xató funksiyasini minimallashtirish yo‘li bilan moslashtiriladi. Regressiya masalallarida o‘rtacha kvadratik xato funksiyasidan foydalaniladi.

$$L = (1/N)...\sum \left\| y_i - \hat{y}_i \right\|^2$$

Parametrlar esa xatoni teskari tarqatish (backpropagation) algoritimi yordamida yangilanadi: $w \leftarrow w - \eta\, \partial L / \partial w$, bu yerda η - o‘qitish tezligi. Aloqa tizimida neyron tarmoqlar uchidan-uchiga o‘qitiladigan zanjir ko‘rinishida ham qo‘llanishi mumkin, bunday tizimning umumlashgan tuzilmasi 2-rasmda keltirilgan.



2-rasm. Neyron tarmoqqa asoslangan ma’lumot uzatish tizimining blok-sxemasi

Metodologiya

Neyron tarmoqli dekoderlashning amaliy samaradorligini mustaqil tekshirish maqsadida mualliflar tomonidan dasturiy simulyatsiya o‘tkazildi. Tadqiqot ob’ekti sifatida Hamming (7,4) chiziqli blok kodi tanlandi: u 4 ta axborotni 7 ta kodlangan bitga akslantiradi (kod tezligi R=4/7) va bitta xatoni tuzatish qobiliyatiga ega. Modulyatsiya-ikki holatli faza siljishi (BPSK), kanal-additiv oq Gauss shovqinli (AWGN) kanal.

Quyidagi to‘rt usul bir xil sharoitda taqqoslanadi: (a) kodlanmagan BPSK (bazaviy holat); (b) Hamming (7,4) kodning sindrom asosidagi qattiq qarorli dekoderi (an’anaviy usul); (c) optimal yumshoq qarorli maksimal ishonchlilik (soft ML) dekoderi (nazariy chegara); (d) taklif etilayotgan chuqur neyron tarmoqli (DNN) dekoder.

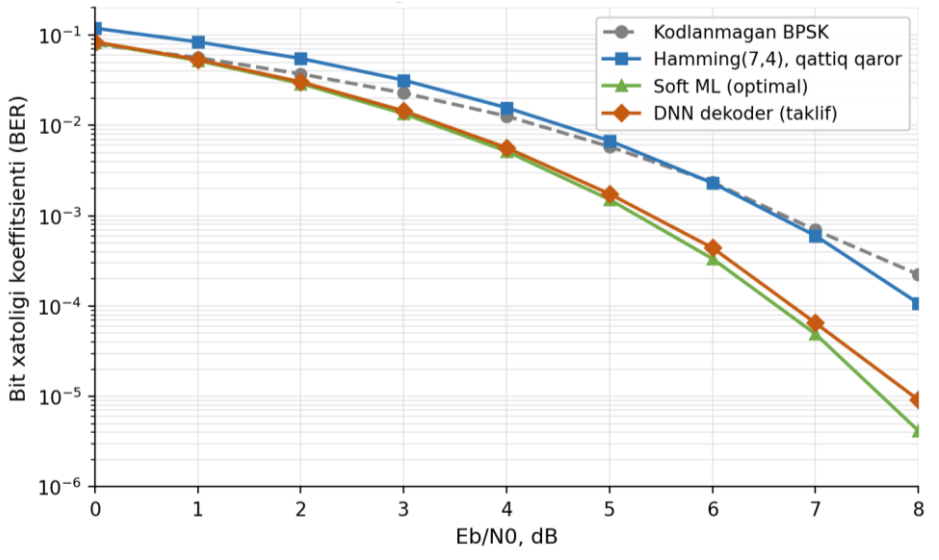
DNN dekoder to‘liq bog‘langan tarmoq bo‘lib, kirishida kanalda qabul qilingan 7 ta yumshoq (soft) qiymat, chiqishida 4 ta axborotni biti joylashgan. Tarmoq arxitekturasi: 7-128-64-32-4; yashirin qatlamlarda ReLU aktivatsiyasi; optimizator _Adam (boshlang‘ich o‘qitish tezligi $2*10^{-3}$). O‘qitish to‘plami 1-7 dB oralig‘idagi Eb/N0 qiymatlarida generatsiya qilingan 280 000 ta kodli so‘zdan tashkil topdi. Dastur Python muhitida Numpy va scikit-learn kutubxonalari yordamida amalga oshirilib, takrorlanuvchilikni ta’minlash uchun tasodifiy sonlar generatori yutug‘i (seed=42) qayd etildi.

Baholash 0 dan 8 dB gacha bo‘lgan Eb/N0 qiymatlarida o‘tkazildi; har bir nuqtada 300 000 ta kodli so‘z uzatilib, axborot bitlari bo‘yicha bit xatoligi koeffitsienti (BER) hisoblanadi. Eb/N0 qiymati (koding yutug‘i, dB) qabul qilindi.

Simulyatsiya natijalari va muhokama

Simulyatsiya natijalari 3-rasmda BER-SNR egri chiqiziqlari ko‘rinishida, 2-jadvalida esa tanlangan Eb/N0 nuqtalaridagi BER qiymatlari ko‘rinishida keltirilgan

(cc) BY



3-rasm. Hamming (7,4), BPSK va AWGN kanali uchun BER–SNR bog‘liqligi

2-jadval

Simulyatsiya natijalari: BER qiymatlari Hamming(7,4), BPSK, AWGN)

Eb/N0, dB	Kodlanmagan BPSK	Hamming, qattiq	Soft ML (optimal)	DNN dekoder
0	$7{,}90\cdot10^{-2}$	$1{,}19\cdot10^{-1}$	$8{,}26\cdot10^{-2}$	$8{,}39\cdot10^{-2}$
2	$3{,}71\cdot10^{-2}$	$5{,}50\cdot10^{-2}$	$2{,}90\cdot10^{-2}$	$3{,}03\cdot10^{-2}$
4	$1{,}27\cdot10^{-2}$	$1{,}57\cdot10^{-2}$	$5{,}17\cdot10^{-3}$	$5{,}66\cdot10^{-3}$
6	$2{,}34\cdot10^{-3}$	$2{,}31\cdot10^{-3}$	$3{,}34\cdot10^{-4}$	$4{,}41\cdot10^{-4}$
8	$2{,}23\cdot10^{-4}$	$1{,}07\cdot10^{-4}$	$4{,}17\cdot10^{-6}$	$9{,}17\cdot10^{-6}$

Natijalar shuni ko‘rsatadiki, past eb/N0 qiymatlarida (0-2 dB) qattiq qarorli Hamming dekoderi hatto kodlanmagan uzatishdan ham yomonroq ishlaydi, chunki qattiq qaror kanal haqidagi yumshoq (soft) axborotni yo‘qotadi. DNN dekoder esa kanaldan kelgan yumshoq qiymatlarni bevosita qayta ishlash, butun diapazonda an’anaviy usuldan ustun chiqdi. BER=10^{-3} darajada DNN dekoder talab qilinadigan Eb/N0≈5,40 dB, qattiq qarorli dekoder uchun esa ≈6,62 dB, ya’ni kodning yutug‘i ~1,22 dB ni tashkil etadi. Bu DNN dekoder optimal soft ML dekoderdan atigi ~0,13 dB orqada ekanini, ya’ni deyarli optimal natija berishini bildiradi

Amaliy nuqtai nazardan ~1,2 dB yuruq bir xil ishonchlilikni pastroq signal quvvatida ta’minlash imkonini beradi; bu uzatish quvvatini kamaytirish yoki qamrov radiusini kengaytirish, demak energetik samaradorlikni oshirish degani. Yuqori eb/N0 sohasida farq yanada kattalashadi: 8 dB da DNN dekoderning BER ko‘rsatkichi qattiq qarorli usulga nisbatan taxminan bir tartibga past.

Tadqiqotning cheklovi shundaki, namuna sifatida qisqa Hamming (7,4) kodi tanlandi; amaliy 5G/6G tizimlarida qo‘llaniladigan uzun LDPC va polar kodlar uchun neyron dekoderni to‘g‘ridan to‘g‘ri o‘qitish o‘lchovlilik (scalability) muammosiga duch keladi. Bunday hollarda neyron tarmoqni an’anaviy iterative dekoder bilan birlashtirilgan gibrid yondashuvlar (masalan, og‘irligi o‘qitiladigan belief propagation) istiqbolli hisoblanadi. Shunga qaramay, olingan natijalar adabiyotlar tahlilidagi xulosalarni tasdiqlaydi: neyron tarmoqlar yumshoq axborotlardan to‘liqroq foydalanish hisobiga uzatish samaradorligi oshadi.

Xulosa

Ishda telekommunikatsiyada ma’lumotlarni uzatish samaradorligini neyron tarmoqlar yordamida oshirish masalasi ikki jihatdan ko‘rib chiqildi. Adabiyotlarning qiyosiy tahlili neyron tarmoqlar kanal kodlash, signalni aniqlash, trafikni bashoratlash va resurslarni taqsimlashda an’anaviy

(cc) BY

usullarga nisbatan ustunlik berishini ko‘rsatdi; ayni paytda turli tadqiqotlardagi miqdoriy ko‘rsatkichlar turli sharoitlarda olingani bois ular faqat umumiy tendentsiyani aks ettiradi.

Bajarilgan simulyatsion eksperiment esa bu xulosani aniq miqdoriy tarzda tasdiqladi: Hamming (7,4), BPSK va AWGN kanali sharoitida chuqur neyron tarmoqli dekoder BER = 10^{-3} darajada an'anaviy qattiq qarorli dekoderdan ~1,22 dB ustun bo‘lib, optimal soft ML dekodlashga deyarli teng natija ko‘rsatdi. Bu bir xil ishonchlilikni pastroq SNR da, ya'ni yuqoriroq energetik samaradorlikda ta’minlashni anglatadi.

Kelgusi tadqiqotlar neyron dekodlash metodikasini uzun LDPC va polar kodlarga, ko‘p kirish-ko‘p chiqishli (MIMO) tizimlarga va so‘nuvchi kanallarga kengaytirishga, shuningdek neyron va an’anaviy algoritmlarni birlashtirgan gibrid arxitekturalarni real qurilmalarda joriy etishga qaratilishi maqsadga muvofiq.

Foydalanilgan adabiyotlar

1. O‘Shea T., Hoydis J. An Introduction to Deep Learning for the Physical Layer // IEEE Transactions on Cognitive Communications and Networking. — 2017. — Vol. 3, No. 4. — P. 563–575.
2. Mao Q., Hu F., Hao Q. Deep Learning in Physical Layer Communications: Evolution and Prospects in 5G and 6G Networks // IET Communications. — 2023. — Vol. 17, No. 16. — P. 1863–1876.
3. Meenalakshmi M., Chaturvedi S., Dwivedi V.K. Deep Learning-Enabled Polar Code Decoders for 5G Networks and Beyond // AEU – International Journal of Electronics and Communications. — 2024. — Vol. 177. — Art. 155220.
4. Tera S.P., Chinthaginjala R., Natha P. et al. Deep Learning Assisted LDPC Decoding for 5G IoT Networks in Fading Environments // Scientific Reports. — 2025. — Vol. 15.
5. A Novel Traffic Prediction Method Using Machine Learning for Energy Efficiency in Service Provider Networks // Sensors (MDPI). — 2023. — Vol. 23, No. 11. — Art. 4997.
6. Zhang G. et al. Energy-Efficient Subchannel and Power Allocation for HetNets Based on Convolutional Neural Network // arXiv preprint. — 2019. — arXiv:1903.00165.
7. A DNN-Based 5G MIMO System Adopting a Mix of Tactics // Discover Electronics (Springer). — 2025. — Vol. 2.
8. Chaudhary A. et al. Augmenting TCP Communication Efficiency in Cognitive Radio Networks Using Iterative Dimensional Neural Optimization // International Journal of Communication Systems (Wiley). — 2025.
9. Saxena D., Singh A.K. A Proactive Autoscaling and Energy-Efficient VM Allocation Framework Using Online Multi-Resource Neural Network for Cloud Data Center // Neurocomputing (Elsevier). — 2021. — Vol. 426. — P. 248–264.
10. Advanced Mathematical Modelling for Energy-Efficient Data Transmission and Fusion in Wireless Sensor Networks // arXiv preprint. — 2024. — arXiv:2407.12806.
11. Nachmani E., Be'ery Y., Burshtein D. Learning to Decode Linear Codes Using Deep Learning // 54th Annual Allerton Conference on Communication, Control, and Computing. — 2016. — P. 341–346.
12. Gruber T., Cammerer S., Hoydis J., ten Brink S. On Deep Learning-Based Channel Decoding // 51st Annual Conference on Information Sciences and Systems (CISS). — 2017. — P. 1–6.
13. LeCun Y., Bengio Y., Hinton G. Deep Learning // Nature. — 2015. — Vol. 521. — P. 436–444.

(cc) BY *dtai.uz*