International Journal of Advanced Technology and Natural Sciences ISSN: 2181-144X

DOI: 10.24412/2181-144X-2025-1-68-75 Namozov N.N.

DATCHIK QURILMALARIDAN OLINGAN MA'LUMOTLARNI QAYTA ISHLASHDA NEYRON TARMOQLARINING MATEMATIK VA CNN ARXITEKTURA MODELLAR TAHLILI.

Nodirbek Namozov *[0000-0001-8930-4454]*

Navoiy davlat konchilik va texnologiyalar universiteti Avtomatlashtirish va boshqaruv kafedrasi assistenti, E-mail: nodirshoxnamozov@gmail.com

Аннотация. В данной статье проводится анализ математических моделей нейронных сетей и архитектуры сверточных нейронных сетей (CHC) при обработке данных, полученных с датчиков. Сигналы, поступающие от датчиков, естественным образом шумные и сложные, и для их точной обработки и анализа необходимо использовать передовые подходы искусственного интеллекта. В ходе исследования сравнивается эффективность обработки данных архитектуры CNN с классическими математическими моделями и обсуждаются их преимущества и ограничения. Также были проведены испытания на основе реальных данных, полученных с датчиков, и проанализированы графические результаты точности и вычислительной эффективности нейронных сетей.

Ключевые слова: подземная горная безопасность, искусственные нейронные сети, сенсорные данные, интеллектуальный мониторинг, обнаружение аномалий, алгоритм, анализ в реальном времени, архитектура CNN.

Abstract. In this article, an analysis of mathematical models of neural networks and the architecture of convergent neural networks (CNNs) in the processing of data received from sensors is carried out. Signals coming from sensors are naturally noisy and complex, and for their accurate processing and analysis, it is necessary to use advanced approaches to artificial intelligence. The study compares the data processing efficiency of CNN architecture with classical mathematical models and discusses their advantages and limitations. Also, tests were conducted based on real data obtained from sensors, and graphical results of the accuracy and computational efficiency of neural networks were analyzed.

Keywords: underground mining safety, artificial neural networks, sensor data, intelligent monitoring, anomaly detection, algorithm, real-time analysis, CNN architecture.

Annotatsiya. Mazkur maqolada datchik qurilmalaridan olingan ma'lumotlarni qayta ishlashda neyron tarmoqlarining matematik modellari va konvolyutsion neyron tarmoqlari (CNN) arxitekturasining tahlili amalga oshiriladi. Datchiklardan kelib tushadigan signallar tabiiy ravishda shovqinli va murakkab bo'lib, ularni aniq qayta ishlash hamda tahlil qilish uchun ilg'or sun'iy intellekt yondashuvlaridan foydalanish zarur. Tadqiqot davomida klassik matematik modellar bilan CNN arxitekturasining ma'lumotlarni qayta ishlash samaradorligi taqqoslanadi va ularning afzalliklari hamda cheklovlari muhokama qilinadi. Shuningdek, datchiklardan olingan real ma'lumotlar asosida sinov o'tkazilib, neyron tarmoqlarning aniqlik va hisoblash samaradorligi bo'yicha grafikli natijalari tahlil qilingan.

Kalit so'zlar: yer osti kon xavfsizligi, sun'iy neyron tarmoqlari, sensor ma'lumotlari, intellektual monitoring, anomal holatlarni aniqlash, algoritm, real vaqt tahlili, CNN arxitekturasi.

Kirish

Zamonaviy sanoatning tezkor rivojlanishi va ishlab chiqarish jarayonlarining avtomatlashtirilishi sharoitida ma'lumotlarni qayta ishlash texnologiyalariga bo'lgan talab ortib bormoqda. Ayniqsa, shaxta konlarida texnologik jarayonlarni kuzatish, xavfsizlikni ta'minlash va samaradorlikni oshirish maqsadida datchiklardan olinayotgan katta hajmdagi ma'lumotlarni tahlil qilish muhim ahamiyat kasb etadi. Bu ma'lumotlarning aniqligi va tahlil natijalarining ishonchliligi, kon sanoatida texnologik jarayonlarni to'g'ri boshqarish va xavf-xatarlarni oldindan aniqlashda hal qiluvchi asosiy rol hisoblanadi [1].

Sun’iy intellekt va mashinani o‘rganish texnologiyalarining rivojlanishi ma’lumotlarni qayta ishlash va tahlil qilishda yangi imkoniyatlar yaratmoqda. Ayniqsa, konvolyutsion neyron tarmoqlari asosida algoritmlar va modellar ishlab chiqish shaxta konlarida real vaqt rejimida ma’lumotlarni qayta ishlash jarayonlarini optimallashtirishga imkon beradi. Ushbu yondashuv datchiklardan olingan signallarni samarali tahlil qilish, anomal holatlarni aniqlash va tahlil qilish orqali ma’lumotlarni ishonchliligini ta’minlashga xizmat qiladi [2].

Shaxta konlarida xavfsizlikni ta’minlash global sanoatning eng muhim muammolaridan biri bo‘lib, zamonaviy texnologiyalarni jalb qilish ushbu sohada hal qiluvchi ahamiyat kasb etib kelmoqda [3,4]. Konchilik sanoatida xodimlarning hayotini himoya qilish, avariyalarni oldindan tahlil qilish va xavfli holatlarni nazorat qilish uchun aqlli tizimlardan foydalanish bugungi kunda dolzarb masalalardan birihisoblanadi [5]. Datchik qurilmalari orqali uzatiladigan real vaqt ma’lumotlarini sun’iy intellekt yordamida qayta ishlash xavfsizlik darajasini oshirish va ish jarayonini optimallashtirish imkonini beradi. Ushbu maqolada datchik ma’lumotlarini qayta ishlashda neyron tarmoqlarning matematik modellari va CNN arxitekturasi tahlil qilingan.

So‘nggi yillarda konchilik sanoatida IoT (Internet of Things), mashinali o‘qitish va sun’iy intellekt texnologiyalarining jadal rivojlanishi ishlab chiqarish samaradorligini oshirish, xavfsizlikni ta’minlash va xarajatlarni optimallashtirish imkonini bermoqda. Ilmiy adabiyotlar tahlili shuni ko‘rsatadiki, yer osti konlarida datchiklar tarmog‘i orqali ma’lumot yig‘ish va ularni bashorat qilishga yo‘naltirilgan tadqiqotlar ko‘p uchraydi. Jumladan, Venkatasubramanian K.K., Gupta S.K.S. [8,9] tomonidan taklif qilingan xavfsizlik monitoringi tizimlarida datchiklarning muhim roli ta’kidlangan bo‘lsa, Basumallik S.MaR., va Eftekharnejad S. [10] ishlanmalarida sun’iy neyron tarmoqlari yordamida anomal holatlar aniqlangan. Shu bilan birga, mavjud ilmiy manbalar kon xavfsizligini avtomatlashtirishda MLP modellarining aniq prognoz berish imkoniyatlarini ta’kidlaydi. Biroq, mavjud ishlarda ko‘pincha real vaqt rejimida ishlovchi tizimlarni joriy etish muammolari yetarlicha o‘rganilmagan. CNN asoschilaridan biri Yann LeCun, LeNet arxitekturasini ishlab chiqdi [11]. Muhammad U., Wang W., Chattha S. P., va Ali S. tomonidan yozilgan VGGNet arxitekturasidan foydalanib, masofaviy zondlash (remote sensing) tasvirlari sahna klassifikatsiyasi bo‘yicha tadqiqot olib borilgan [12].

Shaxta konlarida texnologik jarayonlarni samarali boshqarish va xavfsizlikni ta’minlashda katta hajmdagi ma’lumotlarni tahlil qilish va ulardan to‘g‘ri xulosa chiqarish zarurati mavjud. Datchik qurilmalari yordamida to‘plangan ma’lumotlar texnologik jarayonlarning real vaqtdagi holatini aks ettiradi. Ammo ushbu ma’lumotlar odatda shovqinli, murakkab va katta hajmli bo‘lib, ularni an’anaviy statistik usullar yordamida tahlil qilish qiyin kechadi. Natijada, texnologik jarayonlarda anomal holatlarni aniqlash va ularning sabablarini tahlil qilishda samaradorlik pasayishi mumkin. Bundan tashqari, mavjud tizimlar real vaqtda ma’lumotlarni qayta ishlashga moslashmagan yoki yetarli darajada optimallashtirilmagan. Bu esa kon jarayonlarini boshqarishda kechikishlarga va ba’zi holatlarda xavf darajasining ortishiga olib keladi. Ushbu muammo sun’iy intellekt texnologiyalaridan, xususan, sun’iy neyron tarmoqlari asosida yaratilgan modellar va algoritmlardan foydalanish orqali hal qilinishi mumkin [13].

Shaxta konlarida datchiklardan olingan ma’lumotlarni samarali qayta ishlash uchun sun’iy neyron tarmoqlari va mashinani o‘rganish algoritmlaridan foydalanish maqsadga muvofiqdir. Tadqiqot doirasida quyidagi yondashuvlar qo‘llaniladi:

1. datchiklardan olingan ma’lumotlardagi shovqinlarni bartaraf etish va ularni tahlil qilishga moslashtirish uchun signalni qayta ishlash usullari qo‘llaniladi.

2. sun’iy neyron tarmoqlari yordamida ma’lumotlarni tahlil qilish va anomaliyalarni aniqlash uchun mlp asosida model yaratiladi. ushbu model ma’lumotlar xususiyatlarini chuqur o‘rganib, texnologik jarayonlarni prognozlash va boshqarish imkoniyatini ta’minlaydi.

3. ishlab chiqilgan algoritmlar va mlp modelining samaradorligi shaxta konlarida qo‘llanilayotgan real datchik ma’lumotlari asosida sinovdan o‘tkaziladi.

Uslubiyat

Sun'iy neyron tarmoqlari inson miyasining ishlash tamoyiliga asoslangan holda murakkab ma'lumotlar to'plamlarini tahlil qilish va qayta ishlashda samarali yondashuv hisoblanadi. Ko'p qatlamli perseptron (MLP) esa sun'iy neyron tarmoqlarining asosiy arxitekturalaridan biri bo'lib, bir nechta yashirin qatlamlar orqali ma'lumotlarning nochiziqli xususiyatlarini o'rganadi [14].

MLP modeli — kirish ma'lumotlarini bir yoki bir nechta yashirin qatlamlar orqali qayta ishlash va chiqish qiymatlarini hisoblash uchun ishlatiladi. Har bir qatlam quyidagi asosiy elementlardan iborat deb qaraymiz:

Boshlang'ich qatlamida kirish ma'lumotlari $X=[x_1,x_2,...,x_n]$ deb belgilab olamiz. Yashirin qatlamlarda neyronlar soni va aktivatsiya funksiyalari belgilangan bo'lib, ular modelning murakkab bog'liqliklarni o'rganishiga yordam beradi. Chiqish qatlamida esa modelning maqsadiga qarab (klassifikatsiya yoki regressiya) tegishli natijalarni hisoblash uchun mos funksiya qo'llaniladi [15,16].

Har bir neyron quyidagi (1) formulaga asoslanadi

$$z_j = \sum_{i=1}^{n} w_{ij} x_i + b_j \tag{1}$$

bu yerda z_j – j-neyronning aktivatsiya qiymati, w_{ij} – i-kirish va j-neyron o'rtasidagi vazn, x_i – i-kirish qiymati. b_j – j-neyronning bias.

Neyronning chiqishi aktivatsiya funksiyasi (2) orqali hisoblanadi:

$$a_j = f(z_j) \tag{2}$$

bu yerda $f(z_j)$ — aktivatsiya funksiyasi.

Aktivatsiya funksiyalari neyronlarning yashirin qatlamda nochiziqli xatti-harakatini ta'minlaydi va quyidagi (3) formula asosida topiladi

$$f(z) = \max(0, z) \tag{3}$$

yoki

$$f(z) = \begin{cases} f(z) = z, & x>0 \\ f(z) = 0, & x \le 0 \end{cases}$$

Neyron tarmoqning chiqish qatlamida sigmoid funksiyasi (4) formulada berilgan formuladan foydalanamiz

$$f(z) = \frac{1}{1+e^{-z}} \tag{4}$$

Chiqish qiymatlari sigmoid funksiyasi yordamida ehtimollik sifatida hisoblanadi.

Agar ehtimollik >0.5 bo'lsa, model namunani "1" (musbat sinf) deb tasniflaydi. Aks holda, "0" (manfiy sinf) deb belgilaydi.

Dasturda klassifikatsiya masalasini hal qilish uchun Binary Crossentropy yo'qotish funksiyasi ishlatilgan. Bu funksiya haqiqiy qiymatlar y va analiz qilingan ehtimolliklar y_i – orasidagi farqni o'lchaydi va uning matematik modeli (5) formulada berilgan

$$L = -\frac{1}{N}\sum_{i=1}^{N}[y_i \log(\hat{y}_i) + (1-y_i)\log(1-\hat{y}_i)] \tag{5}$$

bu yerda y_i – [0;1] oraliqdagi qiymatni qabul qiladi, $\hat{y}_i$ – model analizi (sigmoid natijasi). *N* – namunalar soni.

Model parametrlari bo'lgan vaznlar va biaslarni o'rganishda Adam optimizatoridan foydalanildi. Adam gradientni matematik ifodasi (6) formulada berilgan

$$w \leftarrow w - \eta \cdot \frac{\partial L}{\partial w} \tag{6}$$

bu yerda η – o‘qitish tezligi, $\frac{\partial L}{\partial w}$ – yo‘qotish funksiyasining gradienti.

Batch Normalization qatlamlari ma’lumotlarni normallashtiradi, ya’ni har bir qatlamdagi ma’lumotlarning o‘rtacha qiymati 0 va dispersiyasi 1 ga tenglashadi.

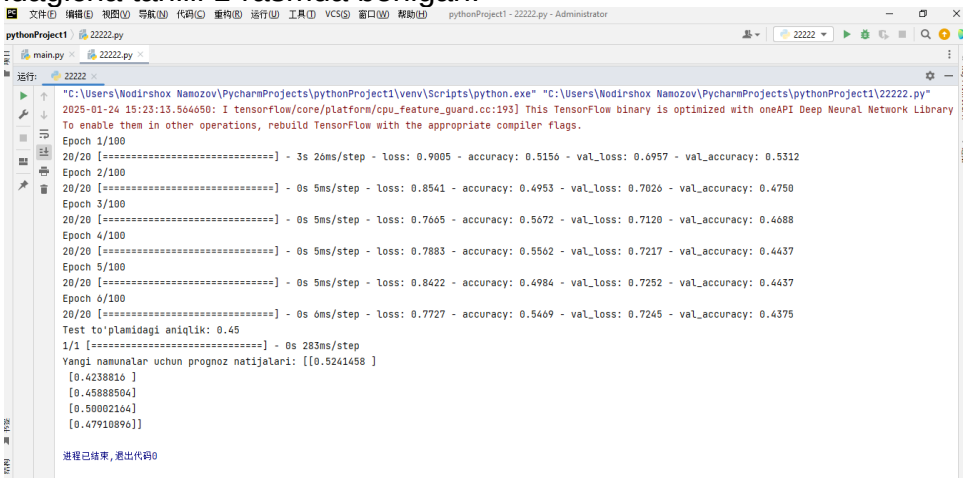
$$\hat{x}_i = \frac{x_i - \mu}{\sqrt{\sigma^2 + \varepsilon}} \tag{7}$$

bu yerda x_i - kirish qiymati, μ - o‘rtacha qiymat, σ^2 - dispersiya, ε - nolga bo‘linishni oldini olish uchun kichik qiymat.

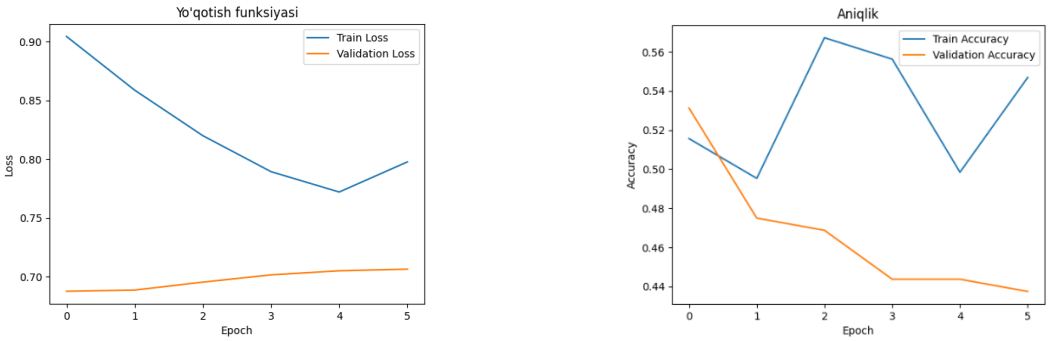
Yuqorida berilgan matematik modellar umumiy ishlash tamoyili quyidagicha bo‘ladi. Kirish ma’lumotlari birinchi yashirin qatlamga uzatiladi. Har bir qatlamda kirish qiymatlari vaznlar va biaslar bilan ko‘paytirilib, aktivatsiya funksiyalari orqali o‘tkaziladi. Chiqish qatlamida sigmoid funksiyasi yordamida ehtimollik qiymatlari hisoblanadi. Yo‘qotish funksiyasi (binary crossentropy) va gradientini hisoblash orqali vaznlar yangilanadi. Iterativ jarayon davomida model o‘z vaznlarini optimallashtirib, yaxshiroq natijalar beradi.

Natijalar

Ushbu tadqiqotda sun’iy neyron tarmoqlaridan foydalanib datchik ma’lumotlarini qayta ishlash va klassifikatsiya masalalarini hal qilish uchun ko‘p qatlamli perseptron (MLP) modeli qo‘llanildi. Python dasturida TensorFlow kutubxonasi asosida ishlab chiqilgan modelning natijalari quyidagicha tahlili 1-rasmda berilgan.



a)



b) c)

1-rasm Python dasturlash tilidagi TensorFlow kutubxonasi asosida ishlab chiqilgan modelning natijalari.

Ishlab chiqilgan modelimiz 5 ta davr davomida o‘qitildi, bu vaqt davomida o‘qitish (train) va validatsiya (validation) ma’lumotlarida yo‘qotish va aniqlik funksiyasi quyidagi natijalarni ko‘rsatdi. o‘qitishdagi xatolikning **d**astlabki davrida 0.9005 bo‘lib, har bir bosqichda pasayib bordi va oxirgi davrga kelib 0.7727 ga teng bo‘ldi. Bu modelimiz o‘quv ma’lumotlarini o‘zlashtirayotganini ko‘rsatadi. Validatsiyadagi xatolik**da** esa boshlang‘ich davrda 0.6957 bo‘lib, keyingi davrlarda biroz oshganini va oxirgi davrda 0.7245 ga yetganini ko‘rishimiz mumkin. Validatsiya xatolikning oshishi haddan tashqari moslashish (overfitting) jarayonining boshlanishini ko‘rsatishi mumkin.

O‘qitish aniqligining dastlabki davrida 51.56% bo‘lib, oxirgi davrga kelib 54.69% ga yetdi. Tasdiqlash aniqligi esa dastlabki davrda 53.12% bo‘lib, oxirgi davrda 43.75% ga pasaydi. Bu natijalar model o‘quv to‘plamiga yaxshi moslashayotganini, ammo tasdiqlash ma’lumotlari uchun umumlashma qobiliyati past bo‘lishi mumkinligini ko‘rsatadi.

Tadqiqotlar natijasida 5 ta namuna asosida tahlil qilinganda prognoz quyidagi qiymatlarni 1-rasm (a) berilgan. Bu qiymatlar har bir namunaga tegishli ehtimolliklarni bildiradi. Modelning chiqish qatlamida sigmoid funksiyasi ishlatilgani sababli, birinchi namuna qiymati “1” sinfiga, qolganlari “0” sinfiga tasniflandi.

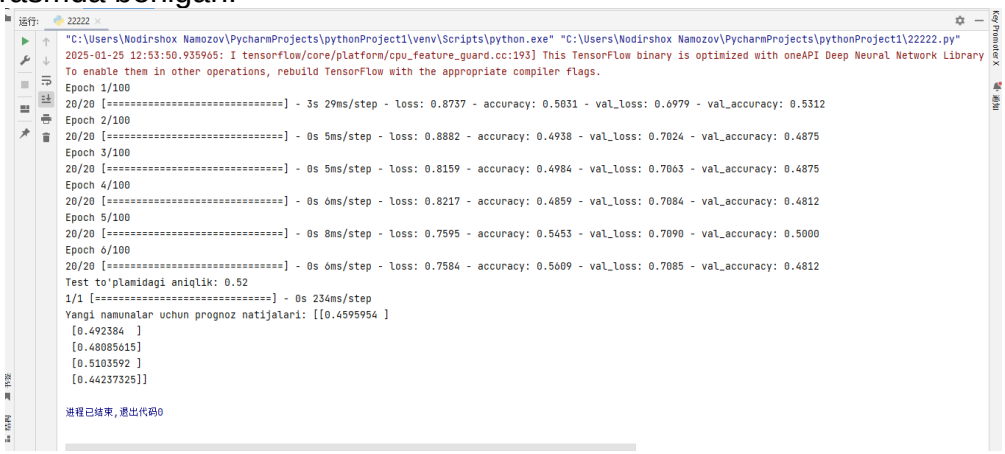
Natijalardan kelib chiqqan holda quyidagilarni aytish mumkin. Tasdiqlash xatoligi Validatsiyadagi xatolikning oshishi va aniqligining pasayishi modelda **haddan tashqari moslashish** muammosi mavjudligini ko‘rsatadi.

Muhokamalar

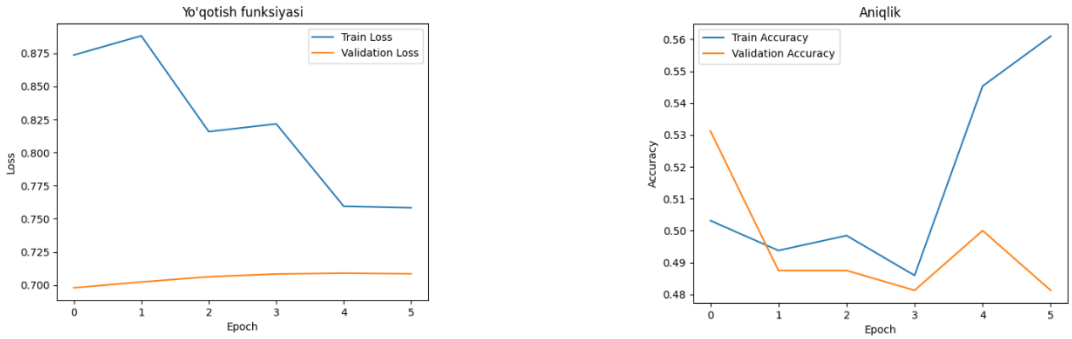
Modelning umumlashma qobiliyatini oshirish uchun quyidagi chora-tadbirlarni amalga oshirish maqsadga muvofiq bo‘ladi:

1. Chiqish qiymatlari sigmoid funksiyasining qiymatini **oshirish**, ya’ni bizda hozirgi qiymat 0.3 bo‘lib, uni 0.4 yoki 0.5 ga oshirish;
2. Ma’lumotlarning xilma-xilligini oshirish orqali modelni ko‘proq ma’lumot bilan ta’minlash;
3. Qatlamlar sonini yoki neyronlar sonini kamaytirish.

Qatlamlarning sonini kamaytirish orqali modelni soddalashtiramiz. Agar modelda ortiqcha qatlamlar bo‘lsa, bu modelning o‘quv ma’lumotlariga haddan tashqari moslashishiga olib keladi, lekin tasdiqlash ma’lumotlarida noto‘g‘ri ishlashiga sabab bo‘ladi. 1-rasmdagi tadqiqot ishimizda yashirin qatlamlar soni 3 ta edi. Yangi taklif qilinadigan dasturimizda yashirin qatlam sonini 2 taga tushirildi. Neyronlar sonini har bir qatlamdagi hisoblashni soddalashtirish maqsadida (128, 64, 32) dan (64, 32) ga kamaytirildi. Python dasturida yashirin qatlamlar soni kamaytirilgandan keyingi ishlab chiqilgan modelning natijalari 2-rasmda berilgan.



a)



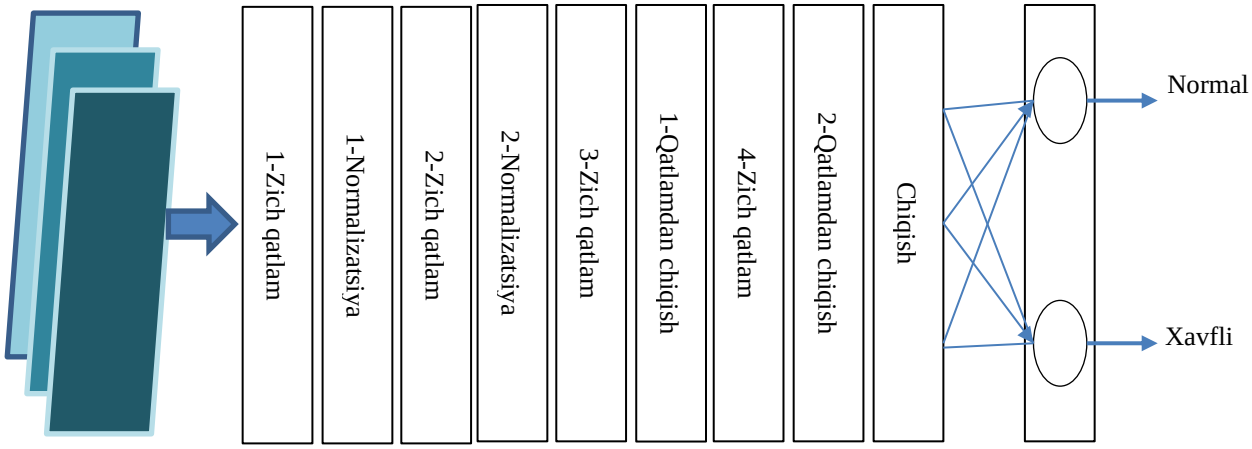
b) c)

2-rasm Python dasturida yashirin qatlamlar soni kamaytirilgandan keyingi ishlab chiqilgan modelning natijalari.

Yashirin qatlamlar sonini kamaytirib, neyronlar sonini moslashtirish orqali optimallashtirilgan MLP modeli bilan quyidagicha natijalar olindi. Ushbu natijalar modelning o‘quv va tasdiqlash ma’lumotlari uchun ishlash samaradorligini ko‘rsatadi. O‘qitishdagi xatolik funksiyasi bosqichma-bosqich pasaygan. Dastlab 0.8737 qiymat bilan boshlanib, 5-davrga kelib 0.7584 ga yetdi. Bu model o‘quv ma’lumotlarini samarali o‘rganayotganini 2b-rasmda ko‘rsatilgan.

Validatsiya xatolikning 0.6977 dan 0.7085 gacha biroz oshishi 2c-rasmda kuzatilgan, ammo katta o‘zgarishlar yo‘q. Bu optimallashtirilgan modelning barqarorroq ishlashidan dalolat beradi. O‘qitish aniqlik darajasi (2c-rasm) dastlab 50.31% bo‘lsa, oxirgi davrga kelib, 56.09% ga yetdi. Validatsiya aniqligi esa biroz o‘zgarib, 48.12% darajasida barqaror qolganini ko‘rishimiz mumkin.

Yashirin qatlamlar sonini kamaytirish orqali modelning murakkabligi pasaytirildi, bu esa haddan tashqari moslashishni kamaytirishga yordam berdi. Biroq, tasdiqlash aniqligida sezilarli yaxshilanish kuzatilmadi. Validatsiya xatolikning oshishi modelning tasdiqlash ma’lumotlari uchun yaxshi moslashmaganligini ko‘rsatmoqda. Yashirin qatlamlar sonini kamaytirish orqali modelning haddan tashqari moslashishga moyilligi kamaygani aniqlandi. Bu natijalar modelni yanada samarali qilish uchun muhim amaliy asos hisoblanadi.



3-rasm Shaxta konlarida datchik qurilmalaridan olingan ma’lumotlarni qayta ishlashning CNN arxitekturasi.

Ushbu tizim shaxta konlarida o‘rnatilgan datchik qurilmalaridan olingan ma’lumotlarni qayta ishlash va xavfsizlik darajasini baholash uchun Multi-Layer Perceptron (MLP) sun’iy neyron tarmog‘iga asoslangan. Tizim ma’lumotlarni kiritishdan boshlab, ular ustida bir qator tahliliy va klassifikatsion operatsiyalarni bajaradi. Birinchi navbatda shaxtadagi datchik

ma’lumotlari harorat, bosim, gaz kontsentratsiyasi, namlik kabi parametrlar datchiklar orqali o‘lchanadi va modelga uzatiladi. Birinchi zich qatlamda kiritilgan ma’lumotlarni dastlabki bosqichda qayta ishlaydi va muhim xususiyatlarni ekstraktsiya qiladi. Aktivatsiya funksiyasi sifatida odatda ReLU (Rectified Linear Unit) ishlatiladi. Normalizatsiya qatlamida ma’lumotlarni muvozanatlashtirish va turli o‘lchov birliklaridan kelib chiqadigan noaniqliklarni kamaytirish uchun ishlatiladi. Bu qatlam ma’lumotlarning aniqroq va barqaror ishlov berilishiga yordam beradi. 2-zich qatlamda oldingi qatlamda chiqarilgan xususiyatlarni chuqurroq o‘rganish va yana qo‘shimcha xususiyatlarni aniqlash uchun ishlatiladi. Ushbu bosqichda yanada murakkab xususiyatlar ajratib olinadi. 2-normalizatsiya bosqichda olinadigan xususiyatlar yana bir bor muvozanatlashtiriladi, bu esa modelning barqarorligini ta’minlashga xizmat qiladi. Uchinchi zich qatlamda model yanada chuqurroq o‘rganish imkoniyatiga ega bo‘ladi va xususiyatlar murakkabroq kombinatsiyalar orqali qayta ishlanadi. 1-Qatlamdan chiqish qatlamida modelning ortiqcha moslashuv muammosini oldini olish uchun ba’zi neyronlarning tasodifiy yo‘q qilinishini ta’minlaydi. Bu qatlam modelning umumiylashuvi va turli xil real vaziyatlarga moslashish qobiliyatini oshiradi. 4- zich qatlamda Modelning yanada yuqori darajadagi xususiyatlarni aniqlashi uchun qo‘shimcha zich qatlam ishlatiladi. U xavfsizlikni baholash uchun eng muhim xususiyatlarni ajratadi. 2-Qatlamdan chiqish qatlamida model barqarorligini saqlab qolish va haddan tashqari moslashuvni kamaytirish uchun qo‘shimcha qatlam. Oxirgi chiqish qatlamida model ma’lumotlarni tahlil qilib, natijani ya’ni Normal – Shaxtadagi holat xavfsiz. Xavfli – Shaxtada anomal holatlar kuzatilmoqda va chora-tadbirlar ko‘rish zarur deb, xavfsizlik holati bo‘yicha tasniflaydi.

Xulosa

Mazkur tadqiqotda datchiklardan olingan ma’lumotlarni qayta ishlash va klassifikatsiya qilish uchun ko‘p qatlamli perseptron (MLP) modeli qo‘llanildi. Modelni ishlab chiqish jarayonida TensorFlow kutubxonasidan foydalanilib, optimal natijalarga erishish uchun qatlamlar soni, neyronlar soni va Dropout kabi parametrlar tahlil qilindi. Dastlabki modelda 3 ta yashirin qatlam va neyronlarning yuqori soni (128, 64, 32) ishlatildi. Natijalar tasdiqlash ma’lumotlarida yo‘qotish funksiyasining oshishi va aniqlikning pasayishini ko‘rsatdi, bu esa overfitting mavjudligini bildiradi.

Modelni optimallashtirish maqsadida qatlamlar soni 2 taga, neyronlar soni esa mos ravishda 64 va 32 ga qisqartirildi. Ushbu yondashuv hisoblash samaradorligini oshirdi va modelning umumlashma qobiliyatini yaxshilashga xizmat qildi. Validation yo‘qotish funksiyasi pasayib, aniqlik biroz yaxshilandi.

Natijalar shuni ko‘rsatadiki, MLP modeli datchik ma’lumotlarini tahlil qilish va tasniflashda samarali bo‘lishi mumkin, ammo overfittingni oldini olish uchun qatlamlar va neyronlar sonini moslash kerak. Ushbu tadqiqot ma’lumotni qayta ishlash bo‘yicha keyingi ishlar uchun muhim amaliy asos yaratadi.

Foydalanilgan adabiyotlar ro‘yhati:

[1]. Kalandarov I.I., Namozov N.N. Yer osti konlarida xodimlarni xavfsizligini ta’minlash individual qurilmalaridagi signallar kechikish vaqtini aniqlash modeli //Journal of Advances in Engineering Technology. – 2024. – №. 1. – С. 33-36.

[2]. Kalandarov I.I., Namozov N.N. LoRa signallari yordamida yer osti kon ishlarida xodimlar harakatlanish traektoriyasini aniqlash modeli //Digital Transformation and Artificial Intelligence. – 2023. – Т. 1. – №. 4. – С. 146-148.

[3]. Ботиров Т. В. и др. Синтез интервальных управляющих устройств в адаптивные системы управления с эталонной моделью //Инновационные

геотехнологии при разработке рудных и нерудных месторождений. – 2020. – С. 231-234.

[4]. Kalandarov I., Namozov N., Bozorov B. Analyses and algorithms of personnel safety in mines using event tree and Bayesian network method //E3S Web of Conferences. – EDP Sciences, 2024. – Т. 531. – С. 03018.

[5]. Vakhromeev A. G. et al. Geoecological monitoring of the “Mustaqillikning 25 yilligi” gas field //E3S Web of Conferences. – EDP Sciences, 2023. – Т. 417. – С. 04007.

[6]. Kalandarov I., Namozov N., Bozorov B. Yer osti kon ishlarida xodimlar xavfsizligini ta’minlash tizimlari tahlili //Innovatsion texnologiyalar. – 2023. – Т. 52. – №. 04.

[7]. Kabulov A. et al. Control System and Algorithm for Construction of Optimal Technological Routes for Machining Parts in the Machining Shop //International Scientific Conference on Agricultural Machinery Industry “Interagromash"”. – Cham: Springer International Publishing, 2022. – С. 2566-2574.

[8]. Venkatasubramanian K.K., Gupta S. K. S. Security for pervasive health monitoring sensor applications //2006 Fourth International Conference on Intelligent Sensing and Information Processing. – IEEE, 2006. – С. 197-202.

[9]. Каландаров И.И. и др. Преобразователь передачи информации в информационную систему контроля горюче-смазочных материалов //Journal of Advances in Engineering Technology. – 2022. – №. 3. – С. 5-8.

[10]. Basumallik S., Ma R., Eftekharnejad S. Packet-data anomaly detection in PMU-based state estimator using convolutional neural network //International Journal of Electrical Power & Energy Systems. – 2019. – Т. 107. – С. 690-702.

[11]. Conneau, A., Schwenk, H., Barrault, L., & Lecun, Y. Very deep convolutional networks for text classification //arXiv preprint arXiv:1606.01781. – 2016.

[12]. Muhammad, U., Wang, W., Chattha, S. P., & Ali, S. Pre-trained VGGNet architecture for remote-sensing image scene classification //2018 24th International Conference on Pattern Recognition (ICPR). – IEEE, 2018. – С. 1622-1627.

[13]. Izenman A.J. Modern multivariate statistical techniques. – New York: Springer, 2008. – Т. 1

[14]. Desai M., Shah M. An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN) //Clinical eHealth. – 2021. – Т. 4. – С. 1-11.

[15]. Park Y. S., Lek S. Artificial neural networks: Multilayer perceptron for ecological modeling //Developments in environmental modelling. – Elsevier, 2016. – Т. 28. – С. 123-140.

[16]. Namozov N.N. Kon sanoatida xodimlar xavfsizligini ta’minlashda xavf omillarini ekstrapolyatsion tahlil asosidagi matematik modeli //Journal of Advances in Engineering Technology. – 2024. – №. 3. – С. 126-130.