


III
2026

ELECTRONIC EDUCATION

SCIENTIFIC
JOURNAL



TAHRIRIYAT

Bosh muharrir

Laqayev Saidaxmad Norjigitovich
fizika-matematika fanlari doktori, akademik

Bosh muharrir o‘rinbosari

Ro‘ziyev Rauf Axmadovich
fizika-matematika fanlari nomzodi, dotsent

Mas‘ul muharrir

Mirsanov Uralboy Mukhammadiyevich
pedagogika fanlari doktori DSc, professor

Editor-in-Chief

Saidakhmad Norjigitovich Lakayev
doctor of physical and mathematical sciences,
academician

Deputy Editor-in-Chief

Ruziyev Raup Akhmadovich
Candidate of Physical and Mathematical Sciences,
Associate Professor

Responsible editor

Mirsanov Uralboy Mukhammadiyevich
doctor of Pedagogical Sciences DSc, Professor

TAHRIRIYAT A‘ZOLARI

Kalonov Muxiddin Baxriddinovich - iqtisodiyot fanlari doktori, professor. (O‘zbekiston)

Xujjiyev Sodiq Oltiyevich- biologiya fanlari nomzodi, dotsent. (O‘zbekiston)

Ibragimov Alimjon Artikbayevich-fizika-matematika fanlari nomzodi, dotsent. (O‘zbekiston)

Suvonov Olim Omonovich- texnika fanlari nomzodi, dotsent. (O‘zbekiston)

Yodgorov G‘ayrat Ro‘ziyevich-fizika- matematika fanlari nomzodi, dotsent. (O‘zbekiston)

Nasirova Shaira Narmuradovna-texnika fanlari doktori, professor. (O‘zbekiston)

O‘tapov Toyir Usmonovich-pedagogika fanlari nomzodi, dotsent. (O‘zbekiston)

Xudoyorov Shuxrat Jumaqulovich- fizika-matematika fanlari nomzodi, dotsent. (O‘zbekiston)

Djurayev Risbay Xaydarovich- akademik (O‘zbekiston)

Negmatov Sayibjon Sodiqovich- akademik (O‘zbekiston)

Aripov Mersaid Mirsiddikovich- fizika-matematika fanlari doktori, professor. (O‘zbekiston)

Turabdjano Sadritdin Maxamatdinovich - texnika fanlari doktori, akademik. (O‘zbekiston)

Raximov Isomiddin Sattarovich- fizika-matematika fanlari doktori, professor. (Malayziya)

Shariy Sergey Petrovich- fizika-matematika fanlari doktori, professor. (Rossiya)

Ibraimov Xolboy- pedagogika fanlari doktori, akademik. (O‘zbekiston)

Yunusova Dilfuza Isroilovna- pedagogika fanlari doktori, professor. (O‘zbekiston)

Aloyev Raxmatillo Djurayevich- fizika-matematika fanlari doktori, professor. (O‘zbekiston)

Abdullayeva Shaxzoda Abdullayevna- pedagogika fanlari doktori, professor. (O‘zbekiston)

Norov Abdusaid Murodovich – texnika fanlari bo‘yicha falsafa doktori, dotsent (O‘zbekiston).

Yuldoshev Ismoil Abriyevich – pedagogika fanlari bo‘yicha falsafa doktori, dotsent (O‘zbekiston)

Mo‘minov Bahodir Boltayevich- texnika fanlari doktori, professor. (O‘zbekiston)

Rosmayati Mohemad - professor. (Malayziya)

Zainidin K. Eshkuvatov – fizika-matematikafanlari doktori (DSc). (Malayziya)

Muhammad Suzuri bin Hitam - professor. Malayziya)

Amiza binti Mat Amin- professor. (Malayziya)

Korshunov Igor Lvovich- texnika fanlari nomzodi, dotsent. (Rossiya)

Kolbanyov Mixail Olegovich- texnika fanlari doktori, professor. (Rossiya)

Verzun Natalya Arkadyevna- texnika fanlari nomzodi, dotsent. (Rossiya)

Stelmashonok Yelena Viktorovna- iqtisod fanlari doktori, professor. (Rossiya)

Tatarnikova Tatyana Mixaylovna - texnika fanlari doktori, professor. (Rossiya)

Alekseyev Vladimir Vasilyevich - texnika fanlari doktori, professor. (Rossiya)

Satikov Igor Abuzarovich – fizika-matematika fanlari nomzodi, dotsent. (Belarus)

Boyarshinova Oksana Aleksandrovna – fizika-matematika fanlari nomzodi, dotsent. (Belarus)

Makarenaya Sergey Nikolayevich – texnika fanlari nomzodi, dotsent. (Belarus)

Sednina Marina Aleksandrovna – texnika fanlari nomzodi, dotsent. (Belarus)

Xolmurodov Abdulhamid Erkinovich- fizika-matematika fanlari doktori, professor. (O‘zbekiston)

Lutfillayev Maxmud Xasanovich- pedagogika fanlari doktori, professor (O‘zbekiston)

Ergasheva Gulruxsor Surxonidinovna - pedagogika fanlari doktori (DSc), dotsent. (O‘zbekiston)

Maxmudova Dilfuza Mileyevna – pedagogika fanlari doktori, professor (O‘zbekiston)

Xudjayev Muxiddin Kushshayevich – texnika fanlari doktori, dotsent (O‘zbekiston).

Ibragimov Abdusattar Turgunovich – texnika fanlari doktori, dotsent (O‘zbekiston).

Karaxonova Oysara Yuldoshevna – pedagogika fanlari bo'yicha falsafa doktori (O'zbekiston).

Kurbaniyazova Zamira Kalbaevna- pedagogika fanlari doktori, dotsent. (O'zbekiston)

Jabbarov Oybek Rakhmanovich- fizika-matematika fanlari bo'yicha falsafa doktori, dotsent (O'zbekiston).

Kabiljanova Firuza Azimovna-fizika-matematika fanlari nomzodi, dotsent. (O'zbekiston)

Kalonova Mohigul Baxriddinovna-iqtisod fanlari bo'yicha falsafa doktori. (O'zbekiston)

Baxodirova Umida Baxodirovna-pedagogika fanlari bo'yicha falsafa doktori, dotsent. (O'zbekiston)

Sharipov Ergash Oripovich-pedagogika fanlari bo'yicha falsafa doktori, dotsent. (O'zbekiston)

Xamroyeva Dilafruz Namozovna – fizika-matematika fanlari bo'yicha falsafa doktori, dotsent. (O'zbekiston).

Toxirov Feruz Jamoliddinovich – pedagogika fanlari bo'yicha falsafa doktori (O'zbekiston)

Isroilova Lola Sunnatovna – pedagogika fanlari bo'yicha falsafa doktori, dotsent. (O'zbekiston)

Otaqulova Durdona Raxmonovna – pedagogika fanlari bo'yicha falsafa doktori (O'zbekiston)

Ruziyeva Dilafruz Raupovna – pedagogika fanlari bo'yicha falsafa doktori (O'zbekiston)

Xalikov Akbar Tilovberdiyevich– pedagogika fanlari bo'yicha falsafa doktori (O'zbekiston)

Isroilova Ruhshona Sunnatovna– pedagogika fanlari doktori, dotsent (O'zbekiston)

Jo'rakulov Tolib Toxirovich- texnik muharrir

© Mazkur jurnal O'zbekiston Respublikasi Vazirlar Mahkamasi huzuridagi Oliy Attestatsiya komissiyasi rayosatining 2022-yil 28-fevraldagi 312/6 qaroriga asosan Pedagogika fanlari bo'yicha falsafa doktori (PhD) va fan doktori (DSc) ilmiy darajasiga talabgorlarning dissertatsiya ishlari yuzasidan dissertatsiyalari asosiy ilmiy natijalarini chop etish uchun tavsiya etilgan ilmiy nashrlar ro'yxatiga kiritilgan

Adress: Navoiy sh., Janubiy ko'chasi, 1-A uy. (1-A, South Street, Navoi city) URL:
<http://www.el-nspi.uz>

MUNDARIJA

Aniq fanlarda axborot texnologiyalari

Axunbetova Z. N. UMUMIY O‘RTA TA’LIM MAKTABI O‘QUVCHILARINING ROBOTOTEXNIKAGA OID AMALIY KO‘NIKMALARINI SHAKLLANTIRISHGA MO‘LJALLANGAN WEB-PLATFORMA YARATISHGA QO‘YILADIGAN TALABLAR	7
Rahmatova D. N. MATEMATIK MODELLASHTIRISH MASALALARINI YECHISHDA NEYRON TARMOQLARDAN FOYDALANISH TEXNOLOGIYASI	15
Qulmurodov I. E. O‘QUVCHILARNING DARSDAN TASHQARI O‘QUV FAOLIYATINI TASHKIL ETISHDA RAQAMLI TA’LIM PLATFORMANI AMALIY SAMARADORLIGI	23
Xotamova A. O. STEAM TA’LIM TEXNOLOGIYASI ASOSIDA TALABALARNING KASBIY KOMPETENTLIGINI RIVOJLANTIRISHNING PEDAGOGIK SHARTLARI	30
Yarashov Sh. T. MASOFAVIY TA’LIM SHAKLIDA TAHSIL OLUVCHI TALABALARNI DASTURLASHGA O‘RGATISHGA MO‘LJALLANGAN PLATFORMA YARATISH USULI	43

Tabiiy fanlarda axborot texnologiyalari

Xamidova Sh. X. O‘QUVCHILARNING GEOGRAFIYA FANIDAN DARSDAN TASHQARI O‘QUV FAOLIYATINI TASHKIL ETISHDA BULUTGA ASOSLANGAN MUHITLARDAN FOYDALANISH USULI	54
Xolmurodova L. E. OLIY TA’LIMDA «BLENDED LEARNING» VA «FLIPPED CLASSROOM» TEXNOLOGIYALARIDAN FOYDALANISHNING METODIK ASOSLARI “FIZIK KIMYO VA KOLLOID KIMYO FANLARI MISOLIDA”	62
Parmanov J.T. ZAMONAVIY OLIY TA’LIM SHAROITIDA TALABALARNING TADQIQOT KOMPETENSIYALARINI RIVOJLANTIRISHNING INNOVATSION MEXANIZMLARI	75
Rajabov X. M. ORGANIK KIMYO TA’LIMINI RAQAMLASHTIRISHDA AVOGADRO DASTURINING O‘RNI VA METODIK IMKONIYATLARI	92

Ijtimoiy-gumanitar fanlarda axborot texnologiyalari

Yuldoshev I. A. PSIXOLOGIYADA RAQAMLI TRANSFORMATSIYADAN FOYDALANISH MASALALARI	103
Sa’dullayeva F. S. O‘QUVCHILARNING TASVIRIY SAN’AT KO‘NIKMALARINI SHAKLLANTIRISHDA 3D TEXNOLOGIYALARINING DIDAKTIK IMKONIYATLARI	117
Norov A. M., Ruzimurodova L. B. O‘ZBEK TILI MATNLARIDA SEMANTIK O‘XSHASHLIKNI ANIQLASH UCHUN NEYRON TARMOQ VA VEKTORLI MODELLARNI INTEGRATSIYALASH	127

СОДЕРЖАНИЕ

Информационные технологии в точных науках

Ахунбетова З. Н. ТРЕБОВАНИЯ К СОЗДАНИЮ WEB-ПЛАТФОРМЫ ДЛЯ ФОРМИРОВАНИЯ ПРАКТИЧЕСКИХ НАВЫКОВ ПО РОБОТОТЕХНИКЕ У УЧАЩИХСЯ ОБЩЕОБРАЗОВАТЕЛЬНЫХ ШКОЛ	7
Рахматова Д. ТЕХНОЛОГИЯ ИСПОЛЬЗОВАНИЯ НЕЙРОННЫХ СЕТЕЙ ПРИ РЕШЕНИИ ЗАДАЧ МАТЕМАТИЧЕСКОГО МОДЕЛИРОВАНИЯ	15
Кулмуродов И. ПРАКТИЧЕСКАЯ ЭФФЕКТИВНОСТЬ ЦИФРОВОЙ ОБРАЗОВАТЕЛЬНОЙ ПЛАТФОРМЫ ПРИ ОРГАНИЗАЦИИ ВНЕУРОЧНОЙ УЧЕБНОЙ ДЕЯТЕЛЬНОСТИ УЧАЩИХСЯ	23
Хотамова А. О. ПЕДАГОГИЧЕСКИЕ УСЛОВИЯ РАЗВИТИЯ ПРОФЕССИОНАЛЬНОЙ КОМПЕТЕНТНОСТИ СТУДЕНТОВ НА ОСНОВЕ ОБРАЗОВАТЕЛЬНОЙ ТЕХНОЛОГИИ STEAM	30
Ярашов Ш. МЕТОД СОЗДАНИЯ ПЛАТФОРМЫ, ПРЕДНАЗНАЧЕННОЙ ДЛЯ ОБУЧЕНИЯ ПРОГРАММИРОВАНИЮ СТУДЕНТОВ ДИСТАНЦИОННОЙ ФОРМЫ ОБУЧЕНИЯ	43

Информационные технологии в естественных науках

Хамидова Ш. Х. МЕТОДИКА ИСПОЛЬЗОВАНИЯ ОБЛАЧНЫХ СРЕД ПРИ ОРГАНИЗАЦИИ ВНЕУРОЧНОЙ УЧЕБНОЙ ДЕЯТЕЛЬНОСТИ УЧАЩИХСЯ ПО ГЕОГРАФИИ	54
Холмуродова Л. Э. МЕТОДИЧЕСКИЕ ОСНОВЫ ИСПОЛЬЗОВАНИЯ ТЕХНОЛОГИЙ «BLENDED LEARNING» И «FLIPPED CLASSROOM» В ВЫСШЕМ ОБРАЗОВАНИИ (НА ПРИМЕРЕ ДИСЦИПЛИН «ФИЗИЧЕСКАЯ ХИМИЯ» И «КОЛЛОИДНАЯ ХИМИЯ»)	62
Парманов Ж. Т. ИННОВАЦИОННЫЕ МЕХАНИЗМЫ РАЗВИТИЯ ИССЛЕДОВАТЕЛЬСКИХ КОМПЕТЕНЦИЙ СТУДЕНТОВ В УСЛОВИЯХ СОВРЕМЕННОГО ВЫСШЕГО ОБРАЗОВАНИЯ	75
Ражабов Х. М. РОЛЬ ПРОГРАММЫ AVOGADRO И ЕЁ МЕТОДИЧЕСКИЕ ВОЗМОЖНОСТИ В ЦИФРОВИЗАЦИИ ОБУЧЕНИЯ ОРГАНИЧЕСКОЙ ХИМИИ	92

Информационные технологии в социально-гуманитарных науках

Юлдашев И. А. ВОПРОСЫ ИСПОЛЬЗОВАНИЯ ЦИФРОВОЙ ТРАНСФОРМАЦИИ В ПСИХОЛОГИИ	103
Саъдуллаева Ф. С. ДИДАКТИЧЕСКИЕ ВОЗМОЖНОСТИ 3D-ТЕХНОЛОГИЙ В ФОРМИРОВАНИИ НАВЫКОВ ИЗОБРАЗИТЕЛЬНОГО ИСКУССТВА У УЧАЩИХСЯ	117
Норов А. М., Рузимуродова Л. ИНТЕГРАЦИЯ НЕЙРОСЕТЕВЫХ И ВЕКТОРНЫХ МОДЕЛЕЙ ДЛЯ ОПРЕДЕЛЕНИЯ СЕМАНТИЧЕСКОГО СХОДСТВА В ТЕКСТАХ НА УЗБЕКСКОМ ЯЗЫКЕ	127

CONTENT

<i>Information technologies in exact sciences</i>	
Akhunbetova Zukhra REQUIREMENTS FOR CREATING A WEB PLATFORM DESIGNED TO DEVELOP PRACTICAL SKILLS IN ROBOTICS FOR GENERAL SECONDARY SCHOOL STUDENTS	7
Rahmatova Dilfuza TECHNOLOGY FOR USING NEURAL NETWORKS IN SOLVING MATHEMATICAL MODELING PROBLEMS	15
Kulmurodov Islombek PRACTICAL EFFECTIVENESS OF A DIGITAL EDUCATIONAL PLATFORM IN ORGANIZING STUDENTS' EXTRACURRICULAR LEARNING ACTIVITIES	23
Khotamova Aziza PEDAGOGICAL CONDITIONS FOR THE DEVELOPMENT OF STUDENTS' PROFESSIONAL COMPETENCE BASED ON STEAM EDUCATIONAL TECHNOLOGY	30
Yarashov Shokhruxh METHOD FOR CREATING A PLATFORM FOR TEACHING PROGRAMMING TO DISTANCE LEARNING STUDENTS	43
<i>Information technologies in natural sciences</i>	
Khamidova Shakhzoda METHOD FOR USING CLOUD-BASED ENVIRONMENTS IN ORGANIZING STUDENTS' EXTRACURRICULAR LEARNING ACTIVITIES IN GEOGRAPHY	54
Kholmurodova Laziza METHODOLOGICAL FOUNDATIONS OF USING “BLENDED LEARNING” AND “FLIPPED CLASSROOM” TECHNOLOGIES IN HIGHER EDUCATION (THE CASE OF PHYSICAL CHEMISTRY AND COLLOID CHEMISTRY)	62
Parmanov Jamshid INNOVATIVE MECHANISMS FOR DEVELOPING STUDENTS' RESEARCH COMPETENCIES IN THE MODERN HIGHER EDUCATION ENVIRONMENT	75
Rajabov Khudayor THE ROLE OF THE AVOGADRO SOFTWARE AND ITS METHODOLOGICAL POTENTIAL IN THE DIGITALIZATION OF ORGANIC CHEMISTRY EDUCATION	92
<i>Information Technologies in Social Sciences and Humanities</i>	
Yuldoshev Ismoil ISSUES OF THE USE OF DIGITAL TRANSFORMATION IN PSYCHOLOGY	103
Sa'dullayeva Ferangiz DIDACTIC POTENTIAL OF 3D TECHNOLOGIES IN DEVELOPING STUDENTS' FINE ARTS SKILLS	117
Norov Abdisait, Ruzimurodova Lobar INTEGRATION OF NEURAL NETWORK AND VECTOR MODELS TO DETERMINE SEMANTIC SIMILARITY IN UZBEK LANGUAGE TEXTS	127

Aniq fanlarda axborot texnologiyalari

MATEMATIK MODELLASHTIRISH MASALALARINI YECHISHDA NEYRON TARMOQLARDAN FOYDALANISH TEXNOLOGIYASI

Rahmatova Dilfuza Nurmat qizi

Qarshi shahar 30-maktab o'qituvchisi, O'zbekiston

e-mail: dilfuzaraxmatova958@gmail.com

ScienceID: MFX-0926-0016

Annotatsiya: Ushbu maqolada matematik modellashtirish masalalarini yechishda neyron tarmoqlardan foydalanishning nazariy va amaliy imkoniyatlari tahlil qilingan. Klassik sonli usullar, ma'lumotlarga asoslangan neyron tarmoqlar hamda fizik qonunlar bilan cheklangan Physics-Informed Neural Networks (PINN) yondashuvi o'zaro qiyoslangan. Tadqiqot doirasida matematik modelni formalizatsiya qilish, kirish-chiqish parametrlarini aniqlash, ma'lumotlarni tayyorlash, neyron tarmoq arxitekturasini tanlash, yo'qotish funksiyasini shakllantirish, o'qitish, validatsiya va natijalarni interpretatsiya qilishdan iborat texnologik ketma-ketlik taklif etilgan. Amaliy tekshiruv sifatida logistik differensial model PINN yordamida yechilib, natija analitik yechim va Eyler usuli bilan taqqoslangan. Hisoblash tajribasida PINN yechimining RMSE qiymati 0.00268, MAE qiymati 0.00213 va MAPE qiymati 0.0034 foizni tashkil etdi. Natijalar neyron tarmoqlar murakkab, chiziqsiz va ma'lumot-fizika integratsiyasini talab qiluvchi modellashtirish masalalarida istiqbolli hisoblash vositasi ekanligini ko'rsatadi.

Tayanch so'zlar. matematik modellashtirish, neyron tarmoq, sun'iy intellekt, chuqur o'qitish, PINN, differensial tenglama, sonli usul, model validatsiyasi, ilmiy mashinali o'qitish.

ТЕХНОЛОГИЯ ИСПОЛЬЗОВАНИЯ НЕЙРОННЫХ СЕТЕЙ ПРИ РЕШЕНИИ ЗАДАЧ МАТЕМАТИЧЕСКОГО МОДЕЛИРОВАНИЯ

Рахматова Дилфуза

Учитель школы No 30 города Кариш, Узбекистан

Аннотация: В данной статье анализируются теоретические и практические возможности использования нейронных сетей при решении задач математического моделирования. Сравниваются классические численные методы, нейронные сети, основанные на данных, и подход Physics-Informed Neural Networks (PINN), ограниченный физическими законами. В рамках исследования предложена технологическая последовательность, включающая формализацию математической модели, определение входных и выходных параметров, подготовку данных, выбор архитектуры нейронной сети, формирование функции потерь, обучение, валидацию и интерпретацию результатов. В качестве практической проверки логистическая дифференциальная модель была решена с помощью PINN, а полученный результат сравнивался с аналитическим решением и методом Эйлера. В вычислительном эксперименте значение RMSE решения PINN составило 0,00268, MAE - 0,00213, а MAPE - 0,0034%. Результаты показывают, что нейронные сети являются перспективным вычислительным инструментом в сложных нелинейных задачах моделирования, требующих интеграции данных и физических законов.

Ключевые слова. математическое моделирование, нейронная сеть, искусственный интеллект, глубокое обучение, PINN, дифференциальное уравнение, численный метод, валидация модели, научное машинное обучение.

TECHNOLOGY FOR USING NEURAL NETWORKS IN SOLVING MATHEMATICAL MODELING PROBLEMS

Rahmatova Dilfuza

Teacher at School No. 30, Karshi city, Uzbekistan

Abstract: This article analyzes the theoretical and practical possibilities of using neural networks to solve mathematical modeling problems. A comparison is made between classical numerical methods, data-driven neural networks, and the Physics-Informed Neural Networks (PINN) approach, which is constrained by physical laws. Within the framework of the study, a technological sequence is proposed, consisting of the formalization of a mathematical model, determination of input-output parameters, data preparation, selection of a neural network architecture, formulation of a loss function, training, validation, and interpretation of results. As a practical test, a logistic differential model was solved using PINN, and the result was compared with the analytical solution and Euler’s method. In the computational experiment, the RMSE value of the PINN solution was 0.00268, the MAE value was 0.00213, and the MAPE value was 0.0034%. The results show that neural networks are a promising computational tool for complex, nonlinear modeling problems that require data-physics integration.

Key words: mathematical modeling, neural network, artificial intelligence, deep learning, PINN, differential equation, numerical method, model validation, scientific machine learning.

Kirish. Matematik modellashtirish real obyekt, jarayon va tizimlarning muhim xususiyatlarini matematik munosabatlar orqali ifodalash va ularning holatini hisoblash imkonini beruvchi ilmiy-uslubiy vositadir. An’anaviy modellashtirishda algebraik va differensial tenglamalar, optimallashtirish masalalari, ehtimollik modellar hamda sonli usullar keng qo‘llanadi. Biroq yuqori o‘lchamli, kuchli chiziqsiz, ko‘p parametrlil va to‘liq bo‘lmagan ma’lumotli masalalarda klassik usullar ko‘p hisoblash resursi, murakkab diskretlashtirish yoki maxsus algoritmik sxemalarni talab qilishi mumkin [1, 2].

Neyron tarmoqlarning universal approksimatsiya xususiyati murakkab funksional bog‘lanishlarni ma’lumotlar asosida o‘rganishga imkon beradi. Hornik, Stinchcombe va White ko‘p qatlamli to‘g‘ri tarqaluvchi tarmoqlarning keng sinfdagi funksiyalarni yetarli aniqlikda approksimatsiya qila olishini nazariy asoslagan [3]. Chuqur o‘qitish texnologiyalarining rivojlanishi esa ko‘p qatlamli modellar yordamida murakkab reprezentatsiyalarni avtomatik o‘rganish imkoniyatlarini sezilarli darajada kengaytirdi [4].

Matematik modellashtirish nuqtayi nazaridan neyron tarmoqlar ikki asosiy shaklda qo‘llanadi. Birinchi holatda tarmoq tajriba yoki simulyatsiya natijalaridan

kirish va chiqish orasidagi noma'lum funksional bog'lanishni o'rganadi. Ikkinchi holatda esa modelning fizik yoki matematik qonunlari yo'qotish funksiyasiga kiritilib, tarmoq differensial tenglamalar va chegaraviy shartlarni qanoatlantirishga o'rgatiladi. Raissi, Perdikaris va Karniadakis tomonidan taklif qilingan PINN yondashuvi aynan shu ikkinchi yo'nalishni tizimli ko'rinishda rivojlantirdi [5]. Mazkur maqolaning maqsadi matematik modellashtirish masalalarini neyron tarmoqlar asosida yechishning texnologik ketma-ketligini ishlab chiqish va uni sodda hisoblash tajribasi orqali asoslashdan iborat.

Adabiyotlar tahlili. Neyron tarmoqlarni matematik modellashtirishga tatbiq etish bo'yicha ilmiy qarashlar universal approksimatsiya nazariyasi, avtomatik differensiallashtirish, chuqur o'qitish va ilmiy mashinali o'qitish yo'nalishlarining rivojlanishi bilan shakllangan. Hornik va hammualliflar neyron tarmoqlarni keng funksiyalar sinfi uchun universal approksimator sifatida asoslagan [3]. LeCun, Bengio va Hinton chuqur o'qitishning ko'p qatlamli tasvirlarni o'rganishdagi imkoniyatlarini umumlashtirgan [4].


Raissi va hammualliflar PINN konsepsiyasida ma'lumotlar bilan bir qatorda differensial tenglamaning qoldiq xatosini ham optimallashtirish mezoniga kiritishni taklif qildilar [5]. Bunda neyron tarmoqning hosilalari avtomatik differensiallashtirish orqali olinadi, shu sababli model tenglamasining qoldig'i tarmoq parametrlariga nisbatan bevosita optimallashtiriladi. Karniadakis va hammualliflarning physics-informed machine learning bo'yicha sharhida fizik qonunlarni mashinali o'qitish arxitekturasiga integratsiya qilish yuqori o'lchamli, teskari va ma'lumotlari cheklangan masalalar uchun muhim yo'nalish sifatida ko'rsatilgan [6].

Lu, Meng, Mao va Karniadakis tomonidan ishlab chiqilgan DeepXDE kutubxonasi oddiy va xususiy hosilali differensial tenglamalar, shuningdek teskari masalalarni chuqur o'qitish asosida yechishni soddalashtiradi [7]. Avtomatik differensiallashtirish texnologiyasi esa neyron tarmoqlarda zarur hosilalarni aniq va samarali hisoblashga xizmat qiladi [8]. Ushbu tadqiqotlar tahlili neyron tarmoqlar

matematik modelning faqat statistik surrogati bo‘lib qolmasdan, model tenglamalarini hisobga oluvchi hisoblash mexanizmi sifatida ham ishlashi mumkinligini ko‘rsatadi.

Mavjud yondashuvlarning kuchli jihati murakkab nolinear bog‘lanishlarni approksimatsiya qilish, turli turdagi ma’lumotlarni integratsiya qilish va parametrlarni teskari aniqlash imkoniyatidir. Cheklovlar esa o‘qitish barqarorligi, giperparametr tanlash, katta hisoblash xarajatlari, extrapolatsiya sifati va natijalarning interpretatsiyasi bilan bog‘liq. Shu bois matematik modellashtirish masalasida neyron tarmoqni qo‘llash yagona algoritm emas, balki bosqichma-bosqich tashkil etilgan texnologik jarayon sifatida qaralishi maqsadga muvofiq.

Tadqiqot metodologiyasi. Tadqiqotda nazariy tahlil, qiyosiy tahlil va hisoblash tajribasi metodlaridan foydalanildi. Taklif qilinayotgan texnologiya besh asosiy bosqichdan iborat: 1) muammoni matematik formalizatsiya qilish; 2) ma’lumotlar, boshlang‘ich va chegaraviy shartlarni tayyorlash; 3) neyron tarmoq arxitekturasini tanlash; 4) yo‘qotish funksiyasini shakllantirib tarmoqni o‘qitish; 5) validatsiya, xatoliklarni baholash va modeldan amaliy foydalanish.



Matematik modellashtirish masalasini neyron tarmoq yordamida yechishning texnologik ketma-ketligi

1-rasm. Neyron tarmoq asosida matematik modelni yechish texnologiyasi


Ma’lumotlarga asoslangan oddiy neyron tarmoq uchun kirish vektori x , maqsad qiymat y va tarmoq prognozi $\hat{y} = f\theta(x)$ ko‘rinishida olinadi. Supervised learning holatida asosiy yo‘qotish funksiyasi o‘rtacha kvadratik xato orqali $L_{data} = (1/N)\sum(\hat{y}_i - y_i)^2$ shaklida ifodalanadi. Fizik qonun bilan cheklangan PINN modelida esa umumiy funksiya $L = \lambda_d L_{data} + \lambda_f L_{physics} + \lambda_b L_{boundary}$ ko‘rinishiga ega bo‘ladi. Bu yerda $L_{physics}$ differensial tenglama qoldig‘ining kvadratik xatosini, $L_{boundary}$ esa boshlang‘ich yoki chegaraviy shartlar buzilishini ifodalaydi [5, 6].

Hisoblash tajribasida populyatsiya o‘shini ifodalovchi logistik model tanlandi: $dy/dt = r \cdot y \cdot (1 - y/K)$, $y(0)=10$, bunda $r=0,6$ va $K=100$. PINN arxitekturasini 1 ta kirish neyroni, 64 tadan neyronli ikkita yashirin qatlam, tanh aktivatsiyasi va 1 ta chiqish neyronidan tashkil topdi. Boshlang‘ich shart $y(t)=y_0+t \cdot N\theta(t)$ ko‘rinishidagi konstruktsiya orqali qat’iy ta’minlandi. O‘qitishda 300 ta kollokatsiya nuqtasi va Adam optimizatori qo‘llanib, 6000 iteratsiya bajarildi. Model sifati analitik yechim va Eyler usuli bilan RMSE hamda MAE mezonlari orqali taqqoslandi.

1-jadval. Matematik modellashtirishda asosiy neyron tarmoq yondashuvlari

Yondashuv	Asosiy ma’lumot	Afzalligi	Cheklovi
Oddiy MLP/regressiya	Tajriba yoki simulyatsiya juftliklari	Tez surrogate model yaratadi	Ko‘p va sifatli ma’lumot talab qiladi
RNN/LSTM	Vaqt qatori	Dinamik ketma-ketlikni hisobga oladi	Uzoq muddatli barqarorlik muammosi
PINN	Ma’lumot + tenglama + shartlar	Fizik qonunlarni o‘qitishga kiritadi	O‘qitish va loss balanslash murakkab
Operator learning	Funksiyadan funksiyaga xaritalash	Bir oiladagi PDElar uchun tez prognoz	Katta boshlang‘ich o‘qitish xarajati

Tahlil va natija. Hisoblash tajribasida PINN orqali olingan logistik model yechimi analitik yechimga juda yaqin bo‘ldi. $0 \leq t \leq 10$ oraliqda 201 ta nazorat nuqtasi bo‘yicha PINN uchun $RMSE=0.00268$, $MAE=0.00213$ va $MAPE=0.0034\%$ olindi. Shu masalani qadam $h=0,5$ bilan Eyler usulida yechilganda $RMSE=2.0437$ va $MAE=1.5599$ ni tashkil etdi. Mazkur natija aynan tanlangan model va hisoblash rejimi uchun PINN yechimining yuqori aniqligini ko‘rsatadi; u umumiy holda barcha masalalarda klassik sonli usullardan ustun degan xulosani anglatmaydi.



2-rasm. Logistik model uchun analitik, PINN va Eyler yechimlarini taqqoslash

2-jadval. Hisoblash natijalarining qiyosiy ko‘rsatkichlari

Usul	RMSE	MAE	Izoh
PINN	0.00268	0.00213	Fizik tenglama loss funksiyasiga kiritilgan
Eyler (h=0,5)	2.0437	1.5599	Diskret qadamga bog‘liq klassik sonli yechim

Natijalar neyron tarmoq texnologiyasining uchta muhim xususiyatini ko‘rsatadi. Birinchidan, tarmoq uzluksiz funksiya sifatida $y(t)$ ni butun interval bo‘yicha ifodalaydi. Ikkinchidan, boshlang‘ich shart tarmoq konstruksiyasiga bevosita kiritilishi mumkin. Uchinchidan, differensial tenglamaning qoldig‘i optimallashtirish mezonini sifatida ishlatilgani sababli model faqat kuzatuv nuqtalariga emas, matematik qonuniyatga ham moslashadi [5].

Shu bilan birga, PINN natijalariga tarmoq chuqurligi va kengligi, aktivatsiya funksiyasi, kollokatsiya nuqtalari, optimizator, learning rate va loss hadlarining og‘irlik koeffitsiyentlari kuchli ta’sir qiladi. Murakkab PDElarda gradientlar muvozanatsizligi va spektral qiyinchiliklar o‘qitishni sekinlashtirishi mumkin. Shu

sababli amaliy texnologiyada klassik usullarni butunlay almashtirish emas, balki muammo turiga qarab gibrid tanlov qilish maqsadga muvofiq [6, 7].

Ta’lim va ilmiy tadqiqotlarda ushbu yondashuv talabalar uchun matematik model, algoritm va sun’iy intellekt o’rtasidagi bog’lanishni amaliy ko’rsatish imkonini beradi. Masalan, populyatsiya dinamikasi, issiqlik tarqalishi, tebranishlar, iqtisodiy o’sish, epidemiologik jarayonlar yoki optimallashtirish modellarida avval klassik tenglama tuziladi, keyin neyron tarmoq yordamida yechim yoki noma’lum parametrlar aniqlanadi. Bu matematik modellashtirishni data-driven va physics-informed paradigmalari bilan boyitadi.

Xulosa va takliflar. Matematik modellashtirish masalalarini yechishda neyron tarmoqlardan foydalanish an’anaviy sonli hisoblashni to’ldiruvchi zamonaviy ilmiy-hisoblash texnologiyasidir. Tadqiqot natijasida muammoni formalizatsiya qilish, ma’lumot va fizik cheklovlarni tayyorlash, arxitekturani tanlash, loss funksiyasini shakllantirish, o’qitish hamda validatsiyadan iborat besh bosqichli texnologik ketma-ketlik ishlab chiqildi. Logistik differensial model bo’yicha hisoblash tajribasi PINNning matematik qonuniyatlarni bevosita o’qitish jarayoniga qo’shish orqali yuqori aniqlikdagi uzluksiz yechim bera olishini ko’rsatdi.

Amaliy qo’llashda quyidagi takliflar maqsadga muvofiq: birinchidan, neyron tarmoq turi masalaning fizik va matematik tabiatiga qarab tanlanishi; ikkinchidan, model natijalari albatta klassik sonli yoki analitik yechim bilan validatsiya qilinishi; uchinchidan, o’qitish natijalarini RMSE, MAE, MAPE va zarur hollarda R^2 kabi mezonlar bilan baholash; to’rtinchidan, differensial tenglamali masalalarda PINN yoki boshqa physics-informed usullardan foydalanish; beshinchidan, ta’lim jarayonida Python, PyTorch/TensorFlow va DeepXDE kabi vositalarni matematik modellashtirish kurslari bilan integratsiya qilish tavsiya etiladi.

Adabiyotlar

1. Chapra S.C., Canale R.P. Numerical Methods for Engineers. 8th ed. New York: McGraw-Hill, 2020.

2. Burden R.L., Faires J.D., Burden A.M. Numerical Analysis. 10th ed. Boston: Cengage Learning, 2016.
3. Hornik K., Stinchcombe M., White H. Multilayer feedforward networks are universal approximators // Neural Networks. 1989. Vol. 2, No. 5. P. 359–366. DOI: 10.1016/0893-6080(89)90020-8.
4. LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. 2015. Vol. 521. P. 436–444. DOI: 10.1038/nature14539.
5. Raissi M., Perdikaris P., Karniadakis G.E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // Journal of Computational Physics. 2019. Vol. 378. P. 686–707. DOI: 10.1016/j.jcp.2018.10.045.
6. Karniadakis G.E., Kevrekidis I.G., Lu L., Perdikaris P., Wang S., Yang L. Physics-informed machine learning // Nature Reviews Physics. 2021. Vol. 3. P. 422–440. DOI: 10.1038/s42254-021-00314-5.
7. Lu L., Meng X., Mao Z., Karniadakis G.E. DeepXDE: A Deep Learning Library for Solving Differential Equations // SIAM Review. 2021. Vol. 63, No. 1. P. 208–228. DOI: 10.1137/19M1274067.
8. Baydin A.G., Pearlmutter B.A., Radul A.A., Siskind J.M. Automatic differentiation in machine learning: a survey // Journal of Machine Learning Research. 2018. Vol. 18. P. 1–43.
9. Goodfellow I., Bengio Y., Courville A. Deep Learning. Cambridge, MA: MIT Press, 2016.
10. Brunton S.L., Kutz J.N. Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control. 2nd ed. Cambridge: Cambridge University Press, 2022.