

ҚАЗАҚСТАН РЕСПУБЛИКАСЫНЫҢ ҒЫЛЫМ ЖӘНЕ ЖОҒАРЫ БІЛІМ МИНИСТРЛІГІ
МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РЕСПУБЛИКИ КАЗАХСТАН
MINISTRY OF SCIENCE AND HIGHER EDUCATION OF THE REPUBLIC OF KAZAKHSTAN



**ХАЛЫҚАРАЛЫҚ АҚПАРАТТЫҚ ЖӘНЕ
КОММУНИКАЦИЯЛЫҚ ТЕХНОЛОГИЯЛАР
ЖУРНАЛЫ**

**МЕЖДУНАРОДНЫЙ ЖУРНАЛ
ИНФОРМАЦИОННЫХ И
КОММУНИКАЦИОННЫХ ТЕХНОЛОГИЙ**

**INTERNATIONAL JOURNAL OF INFORMATION
AND COMMUNICATION TECHNOLOGIES**

2025 (22) 2
сәуір - маусым

ISSN 2708–2032 (print)
ISSN 2708–2040 (online)

БАС РЕДАКТОР:

Исахов Асылбек Абдишимович — есептеу теориясы саласында математика бойынша PhD доктор, "Компьютерлік ғылымдар және информатика" бағыты бойынша қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университетінің Басқарма Төрағасы – Ректор (Қазақстан)

БАС РЕДАКТОРДЫҢ ОРЫНБАСАРЫ:

Колесникова Катерина Викторовна — техника ғылымдарының докторы, профессор, Халықаралық ақпараттық технологиялар университетінің ғылыми-зерттеу қызметі жөніндегі проректор (Қазақстан)

ҒАЛЫМ ХАТШЫ:

Ипалакова Мадина Түлегеновна — техника ғылымдарының кандидаты, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университетінің ғылыми-зерттеу қызметі жөніндегі департамент директоры (Қазақстан)

РЕДАКЦИЯЛЫҚ АЛҚА:

Разак Абдул — PhD, Халықаралық ақпараттық технологиялар университеті киберқауіпсіздік кафедрасының профессоры (Қазақстан)
Лучино Томмазо де Паолис — Саленто Университеті (Италия) инновация және технологиялық инжиниринг департаменті AVR зертханасының зерттеу және әзірлеу бөлімінің директоры

Лиз Бэкон — профессор, Абертей Университеті (Ұлыбритания) вице-канцлерінің орынбасары

Микеле Пагано — PhD, Пиза Университетінің (Италия) профессоры

Өтелбаев Мұхтарбай Өтелбайұлы — физика-математика ғылымдарының докторы, профессор, КР ҰҒА академигі, Халықаралық ақпараттық технологиялар университеті математика және компьютерлік модельдеу кафедрасының профессоры (Қазақстан)

Рысбайұлы Болатбек — физика-математика ғылымдарының докторы, профессор, Есептеу және деректер ғылымдары департаментінің профессоры, Astana IT University (Қазақстан)

Дайнеко Евгения Александровна — PhD, Халықаралық ақпараттық технологиялар университеті ақпараттық жүйелер кафедрасының профессор-зерттеушісі (Қазақстан)

Дузаев Нуржан Токсужаевич — PhD, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университеті цифрландыру және инновациялар жөніндегі проректор (Қазақстан)

Синчев Бахтгерей Куспанович — техника ғылымдарының докторы, профессор, Халықаралық ақпараттық технологиялар университеті ақпараттық жүйелер кафедрасының профессоры (Қазақстан)

Сейлова Нургуль Абдуллаевна — техника ғылымдарының докторы, Халықаралық ақпараттық технологиялар университеті компьютерлік технологиялар және киберқауіпсіздік факультетінің деканы (Қазақстан)

Мұхамедиева Ардак Габитовна — экономика ғылымдарының кандидаты, Халықаралық ақпараттық технологиялар университеті бизнес медиа және басқару факультетінің деканы (Қазақстан)

Абдикаликова Замира Тұрсынбаевна — PhD, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университеті математика және компьютерлік модельдеу кафедрасының меңгерушісі (Қазақстан)

Шильдибеков Ерлан Жаржанович — PhD, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университеті экономика және бизнес кафедрасының меңгерушісі (Қазақстан)

Дамелия Максумовна Ескендірова — техника ғылымдарының кандидаты, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университеті киберқауіпсіздік кафедрасының меңгерушісі (Қазақстан)

Ниязгулова Айгуль Аскарбековна — филология ғылымдарының кандидаты, доцент, профессор, Халықаралық ақпараттық технологиялар университеті медиакоммуникация және Қазақстан тарихы кафедрасының меңгерушісі (Қазақстан)

Айтмағамбетов Алтай Зуфарович — техника ғылымдарының кандидаты, Халықаралық ақпараттық технологиялар университеті радиотехника, электроника және телекоммуникация кафедрасының профессоры (Қазақстан)

Бахтиярова Елена Азизбековна — техника ғылымдарының кандидаты, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университеті радиотехника, электроника және телекоммуникация кафедрасының меңгерушісі (Қазақстан)

Канибек Сансызбай — PhD, қауымдастырылған профессор, Халықаралық ақпараттық технологиялар университеті киберқауіпсіздік кафедрасының профессор-зерттеушісі (Қазақстан)

Тынымбаев Сахиябай — техника ғылымдарының кандидаты, профессор, Халықаралық ақпараттық технологиялар университеті компьютерлік инженерия кафедрасының профессор-зерттеушісі (Қазақстан)

Алимереб Али Абд — PhD, Халықаралық ақпараттық технологиялар университеті киберқауіпсіздік кафедрасының қауымдастырылған профессоры (Қазақстан)

Мохамед Ахмед Хамада — PhD, Халықаралық ақпараттық технологиялар университеті ақпараттық жүйелер кафедрасының қауымдастырылған профессоры (Қазақстан)

Янг Им Чу — PhD, Гачон университетінің профессоры (Оңтүстік Корея)

Талеуш Валдас — PhD, Адам Мицкевич атындағы (Польша) университеттің проректоры

Мамырбаев Оркен Жұмажанович — PhD, КР ҒЖБМ Ғылым комитеті ақпараттық және есептеу технологиялары институты ӨМК директорының ғылым жөніндегі орынбасары (Қазақстан)

Бушуев Сергей Дмитриевич — техника ғылымдарының докторы, профессор, Украинаның "УКРНЕТ" жобаларды басқару қауымдастығының директоры, Киев ұлттық құрылыс және сәулет университеті жобаларды басқару кафедрасының меңгерушісі (Украина)

Белошицкая Светлана Васильевна — техника ғылымдарының докторы, доцент, Astana IT University есептеу және деректер ғылымы кафедрасының профессоры (Қазақстан)

РЕДАКТОР:

Мрзабаева Раушан Жалиевна — магистр, Халықаралық ақпараттық технологиялар университетінің редакторы (Қазақстан)

Халықаралық ақпараттық және коммуникациялық технологиялар журналы

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Меншік иесі: АҚ «Халықаралық ақпараттық технологиялар университеті» (Алматы қ.).

Қазақстан Республикасы Ақпарат және қоғамдық даму министрлігіне мерзімді баспасөз басылымын есепке қою туралы куәлік № KZ82VPY00020475, 20.02.2020 ж. берілген

Тақырып бағыты: ақпараттық технологиялар, ақпараттық қауіпсіздік және коммуникациялық технологиялар, әлеуметтік-экономикалық жүйелерді дамытудағы цифрлық технология.

Мерзімділігі: жылына 4 рет.

Тираж: 100 дана.

Редакция мекенжайы: 050040 Алматы қ., Манас к., 34/1, каб. 709, тел: +7 (727) 244-51-09.

E-mail: ijict@iitu.edu.kz

Журнал сайты: <https://journal.iitu.edu.kz>

© Халықаралық ақпараттық технологиялар университеті АҚ, 2025

Журнал сайты: <https://journal.iitu.edu.kz> © Авторлар ұжымы, 2025

ГЛАВНЫЙ РЕДАКТОР

Исахов Асылбек Абдиашимович — доктор PhD по математике в области теории вычислимости, ассоциированный профессор по направлению "Компьютерные науки и информатика", Председатель Правления – Ректор Международного университета информационных технологий (Казахстан)

ЗАМЕСТИТЕЛЬ ГЛАВНОГО РЕДАКТОРА:

Колесникова Катерина Викторовна — доктор технических наук, профессор, проректор по научно-исследовательской деятельности Международного университета информационных технологий (Казахстан)

УЧЕНЫЙ СЕКРЕТАРЬ:

Ипалакова Мадина Тулегеновна — кандидат технических наук, ассоциированный профессор, директор департамента по научно-исследовательской деятельности Международного университета информационных технологий (Казахстан)

РЕДАКЦИОННАЯ КОЛЛЕГИЯ:

Разак Абдул — PhD, профессор кафедры кибербезопасности Международного университета информационных технологий (Казахстан)

Лучио Томмазо де Паолис — директор отдела исследований и разработок лаборатории AVR департамента инноваций и технологического инжиниринга Университета Саленто (Италия)

Лиз Бэкон — профессор, заместитель вице-канцлера Университета Абертей (Великобритания)

Микеле Пагано — PhD, профессор Университета Пизы (Италия)

Отелбаев Мухтарбай Отелбайұлы — доктор физико-математических наук, профессор, академик НАН РК, профессор кафедры математического и компьютерного моделирования Международного университета информационных технологий (Казахстан)

Рысбайұлы Болатбек — доктор физико-математических наук, профессор, профессор Astana IT University (Казахстан)

Дайнеко Евгения Александровна — PhD, профессор-исследователь кафедры информационных систем Международного университета информационных технологий (Казахстан)

Дузбаев Нуржан Токкужаевич — PhD, ассоциированный профессор, проректор по цифровизации и инновациям Международного университета информационных технологий (Казахстан)

Синчев Бахтгерей Куспанович — доктор технических наук, профессор, профессор кафедры информационных систем Международного университета информационных технологий (Казахстан)

Сейлова Нургуль Абадуллаевна — кандидат технических наук, декан факультета компьютерных технологий и кибербезопасности Международного университета информационных технологий (Казахстан)

Мухамедиева Ардак Габитовна — кандидат экономических наук, декан факультета бизнеса медиа и управления Международного университета информационных технологий (Казахстан)

Абдикаликова Замира Турсынбаевна — PhD, ассоциированный профессор, заведующая кафедрой математического и компьютерного моделирования Международного университета информационных технологий (Казахстан)

Шильдибеков Ерлан Жаржанович — PhD, ассоциированный профессор, заведующий кафедрой экономики и бизнеса Международного университета информационных технологий (Казахстан)

Дамеля Максумовна Ескендирова — кандидат технических наук, ассоциированный профессор, заведующая кафедрой кибербезопасности Международного университета информационных технологий (Казахстан)

Ниязгулова Айгуль Аскарбековна — кандидат филологических наук, доцент, профессор, заведующая кафедрой медиакоммуникации и истории Казахстана Международного университета информационных технологий (Казахстан)

Айтмагамбетов Алтай Зуфарович — кандидат технических наук, профессор кафедры радиотехники, электроники и телекоммуникаций Международного университета информационных технологий (Казахстан)

Бахтиярова Елена Ажибековна — кандидат технических наук, ассоциированный профессор, заведующая кафедрой радиотехники, электроники и телекоммуникаций Международного университета информационных технологий (Казахстан)

Канибек Сансызбай — PhD, ассоциированный профессор, профессор-исследователь кафедры кибербезопасности, Международного университета информационных технологий (Казахстан)

Тынымбаев Сахиябай — кандидат технических наук, профессор, профессор-исследователь кафедры компьютерной инженерии, Международного университета информационных технологий (Казахстан)

Алмисреб Али Абд — PhD, ассоциированный профессор кафедры кибербезопасности Международного университета информационных технологий (Казахстан)

Мохамед Ахмед Хамада — PhD, ассоциированный профессор кафедры информационных систем Международного университета информационных технологий (Казахстан)

Янг Им Чу — PhD, профессор университета Гачон (Южная Корея)

Талеуш Валлас — PhD, проректор университета имен Адама Мицкевича (Польша)

Мамырбаев Оркен Жумажанович — PhD, заместитель директора по науке РГП Института информационных и вычислительных технологий Комитета науки МНВО РК (Казахстан)

Бушуев Сергей Дмитриевич — доктор технических наук, профессор, директор Украинской ассоциации управления проектами «УКРНЕТ», заведующий кафедрой управления проектами Киевского национального университета строительства и архитектуры (Украина)

Белошницкая Светлана Васильевна — доктор технических наук, доцент, профессор кафедры вычислений и науки о данных Astana IT University (Казахстан)

РЕДАКТОР:

Мрзабаева Раушан Жалиевна — магистр, редактор Международного университета информационных технологий (Казахстан)

Международный журнал информационных и коммуникационных технологий

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Собственник: АО «Международный университет информационных технологий» (г. Алматы).

Свидетельство о постановке на учет периодического печатного издания в Министерство информации и общественного развития Республики Казахстан № KZ82VPY00020475, выданное от 20.02.2020 г.

Тематическая направленность: информационные технологии, информационная безопасность и коммуникационные технологии, цифровые технологии в развитии социально-экономических систем.

Периодичность: 4 раза в год.

Тираж: 100 экземпляров.

Адрес редакции: 050040 г. Алматы, ул. Манаса 34/1, каб. 709, тел: +7 (727) 244-51-09.

E-mail: ijict@iitu.edu.kz

Сайт журнала: <https://journal.iitu.edu.kz>

© АО Международный университет информационных технологий, 2025

© Коллектив авторов, 2025

EDITOR-IN-CHIEF

Assylbek Issakhov — PhD in Mathematics in Computability Theory, associate professor in “Computer Science and Informatics,” Chairman of the Board – Rector of the International Information Technology University (Kazakhstan)

DEPUTY EDITOR-IN-CHIEF

Kateryna Kolesnikova — Doctor of Technical Sciences, professor, Vice-Rector for Research, International Information Technology University (Kazakhstan)

ACADEMIC SECRETARY

Madina Ipalakova — Candidate of Technical Sciences, associate professor, Director of the Research Department, International Information Technology University (Kazakhstan)

EDITORIAL BOARD

Abdul Razak — PhD, professor, Department of Cybersecurity, International Information Technology University (Kazakhstan)

Lucio Tommaso De Paolis — Director of the R&D Department of the AVR Laboratory, Department of Engineering for Innovation, University of Salento (Italy)

Liz Bacon — Professor, Deputy Vice-Chancellor, Abertay University (United Kingdom)

Michele Pagano — PhD, Professor, University of Pisa (Italy)

Mukhtarbay Otelbayev — Doctor of Physical and Mathematical Sciences, professor, academician of the National Academy of Sciences of the Republic of Kazakhstan, professor of the Department of Mathematical and Computer Modeling, International Information Technology University (Kazakhstan)

Bolatbek Rysbauly — Doctor of Physical and Mathematical Sciences, professor, professor of the Department of Computing and Data Science, Astana IT University (Kazakhstan)

Yevgeniya Daineko — PhD, research professor, Department of Information Systems, International Information Technology University (Kazakhstan)

Nurzhhan Duzbayev — PhD, associate professor, Vice-Rector for Digitalization and Innovation, International Information Technology University (Kazakhstan)

Bakhtgerai Sinchev — Doctor of Technical Sciences, professor, Department of Information Systems, International Information Technology University (Kazakhstan)

Nurgul Seilova — Candidate of Technical Sciences, Dean of the Faculty of Computer Technologies and Cybersecurity, International Information Technology University (Kazakhstan)

Ardak Mukhamediyeva — Candidate of Economic Sciences, Dean of the Faculty of Business, Media and Management, International Information Technology University (Kazakhstan)

Zamira Abdikalikova — PhD, associate professor, Head of the Department of Mathematical and Computer Modeling, International Information Technology University (Kazakhstan)

Yerlan Shildibekov — PhD, associate professor, Head of the Department of Economics and Business, International Information Technology University (Kazakhstan)

Damilya Yeskendiroya — Candidate of Technical Sciences, associate professor, Head of the Department of Cybersecurity, International Information Technology University (Kazakhstan)

Aigul Niyazgulova — Candidate of Philological Sciences, Professor, Head of the Department of Media Communications and History of Kazakhstan, International Information Technology University (Kazakhstan)

Altai Aitmagambetov — Candidate of Technical Sciences, Professor, Department of Radio Engineering, Electronics and Telecommunications, International Information Technology University (Kazakhstan)

Yelena Bakhtiyarova — Candidate of Technical Sciences, associate professor, Head of the Department of Radio Engineering, Electronics and Telecommunications, International Information Technology University (Kazakhstan)

Kanibek Sansyzbay — PhD, research professor, Department of Cybersecurity, International Information Technology University (Kazakhstan)

Sakhybay Tynymbayev — Candidate of Technical Sciences, Professor, Research Professor, Department of Computer Engineering, International Information Technology University (Kazakhstan)

Ali Abd Almisreb — PhD, associate professor, Department of Cybersecurity, International Information Technology University (Kazakhstan)

Mohamed Ahmed Hamada — PhD, associate professor, Department of Information Systems, International Information Technology University (Kazakhstan)

Yang Im Chu — PhD, Professor, Gachon University (South Korea)

Tadeusz Wallas — PhD, Vice-Rector, Adam Mickiewicz University (Poland)

Orken Mamyrbayev — PhD, Deputy Director for Science, RSE Institute of Information and Computational Technologies, Committee for Science of the Ministry of Science and Higher Education of the Republic of Kazakhstan (Kazakhstan)

Sergey Bushuyev — Doctor of Technical Sciences, professor, Director of the Ukrainian Project Management Association “UKRNET,” Head of the Department of Project Management, Kyiv National University of Construction and Architecture (Ukraine)

Svetlana Beloshitskaya — Doctor of Technical Sciences, professor, Department of Computing and Data Science, Astana IT University (Kazakhstan)

EDITOR

Raushan Mrzabayeva — Master of Science, editor, International Information Technology University (Kazakhstan)

«International Journal of Information and Communication Technologies»

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Owner: International Information Technology University JSC (Almaty).

The certificate of registration of a periodical printed publication in the Ministry of Information and Social Development of the Republic of Kazakhstan, Information Committee No. KZ82VPY00020475, issued on 20.02.2020.

Thematic focus: information technology, digital technologies in the development of socio-economic systems, information security and communication technologies

Periodicity: 4 times a year.

Circulation: 100 copies.

Editorial address: 050040. Manas st. 34/1, Almaty. +7 (727) 244-51-09. E-mail: ijict@iitu.edu.kz

Journal website: <https://journal.iitu.edu.kz>

© International Information Technology University JSC, 2025

© Group of authors, 2025

МАЗМҰНЫ

М.Ж. Айтимов, К.К. Макулов, А.Б. Остаева, Г.Ш. Мусагулова, Я. Култан АЙМАҚТЫҚ ДАМУҒА ӘЛЕУМЕТТІК-ЭКОНОМИКАЛЫҚ ФАКТОРЛАРДЫҢ ӨСЕРІН ЗЕРТТЕУ ҮШІН ГИБРИДТІ МОДЕЛЬДІ ҚОЛДАНУ.....	8
А.С. Баегизова, Г.Е. Мырзабекова, А.З. Алимагамбетова, Г.И. Мухамедрахимова, М. Кассим ИНТЕЛЛЕКТУАЛДЫ КЛАСТЕРЛЕУ ӘДІСТЕРІН ҚОЛДАНА ОТЫРЫП, ҚЫСҚА МӘТІНДЕРДІ ТАЛ ДАУ.....	23
Г.У. Бектемісова, А.А. Быков, Б.А. Нурашихин, А.А. Кереш, М.О. Даулетбек КОМПЬЮТЕРЛІК КӨРУ ЖӘНЕ МАШИНАЛЫҚ ОҚЫТУ НЕГІЗІНДЕ ҚҰРЫЛЫС ПРОЦЕСТЕРІН БАҚЫЛАУДЫҢ ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕСІН ӨЗІРЛЕУ ЖӘНЕ СЫНАУ	37
Д. Еділхан, Н. Хаймұльдин, Д. Оспанова, Б. Амиргалиев БАРЛЫҚ КӨШЕЛЕРДІ ҚОЗҒАЛЫС ШЕКТЕУЛЕРІМЕН ҚАМТУҒА АРНАЛҒАН ОҢТАЙЛЫ МАРШРУТТЫ ТАБУДЫҢ ИНТЕЛЛЕКТУАЛДЫ МОДЕЛІ.....	57
А. Игнатович, А.С. Есенгельдина, Л.Т. Курмангазиева, С.Р. Шармұханбет, М.У. Худойберганов МАШИНАЛЫҚ ОҚЫТУ КӨМЕГІМЕН ҚАЗАҚСТАНДАҒЫ СОТ ШЕШІМДЕРІН БОЛЖАУҒА АРНАЛҒАН ДЕРЕКТЕРДІ ҚҰРУ.....	75
А.Х. Касымова, Г.Б. Абдикеримова, А.К. Асабай, А.Б. Серикбаева, С.М. Ахмедова БЕЙНЕ АҒЫНДАРЫНДА ҚОЗҒАЛАТЫН ОБЪЕКТІЛЕРДІ АНЫҚТАУ ҮШІН НАҚТЫ УАҚЫТТАҒЫ МАТЕМАТИКАЛЫҚ МОДЕЛЬДЕУ.....	91
С.К. Кумаргажанова, Д. Нұрлыбекова, А.С. Тлебалдинова, М.А. Карменова, С.А. Смаилова ШЫҒЫС ҚАЗАҚСТАН ОБЛЫСЫНЫҢ ҚАР КӨШКІНІ АЙМАҚТАРЫН МАШИНАЛЫҚ ОҚЫТУ ӘДІСІ АРҚЫЛЫ АНЫҚТАУ.....	115
С.Б. Муханов, К. Бекболат, Н.А. Сейлова, Ж.М. Бекаулова, С.Ж. Жакыпбеков САУДА ЖҮПТАРЫНДАҒЫ КРИПТОВАЛЮТА БАҒАСЫНЫҢ ҚҰБЫЛМАЛЫЛЫҒЫН БОЛЖАУҒА АРНАЛҒАН НЕЙРОНДЫҚ ЖЕЛІ МОДЕЛЬДЕРІН САЛЫСТЫРУ.....	130
Н.А. Оданова, К.Б. Багитова, Э.Э. Эльдарова, Ж.Т. Қабылхамит, Л.Терейковская АҚПАРАТТЫҚ ҚАУІПСІЗДІК САЛАСЫНДА ПЕРНЕТАҚТАДА ТЕРУ ҮЛГІСІН ТАЛДАУҒА АРНАЛҒАН НЕЙРОЖЕЛІЛІК МОДЕЛЬДЕРДІ ҚОЛДАНУ.....	142
А.С. Сраж, М. Нұртас, А.А. Алтайбек, З.Т. Абдикаликова НЕЙРОНДЫҚ ЖЕЛІЛЕР МАТЕМАТИКАЛЫҚ ЕСЕПТЕУ ҚҰРАЛЫ РЕТІНДЕ.....	154
А.М. Темірхан, Г.Н. Пашенко БАНКТЫҚ АЛАЯҚТЫҚТЫ АНЫҚТАУДАҒЫ ГРАФТЫҚ НЕЙРОНДЫҚ ЖЕЛІЛЕР: ӘДІСТЕРДІ САЛЫСТЫРМАЛЫ ТАЛДАУ	174
Е.Б. Тулебаев, А.А. Муханова, Н. Горанин МУНИЦИПАЛДЫҚ АКТИВТЕРДІҢ ТӘУЕКЕЛДЕРІН БОЛЖАУ: МАШИНАЛЫҚ ОҚЫТУДЫ ПАЙДАЛАНУ АРҚЫЛЫ ЖАС, ТОЗУ ЖӘНЕ ПАЙДАЛАНУ ҚАРҚЫНДЫЛЫҒЫ НЕГІЗІНДЕ ТЕХНИКАЛЫҚ ҚЫЗМЕТ КӨРСЕТУ ШЕШІМДЕРІН МОДЕЛЬДЕУ.....	186
С. Тынымбаев, Ж.Е. Темирбекова, Р.Ш. Бердибаев, С.Е. Маманова ТӨРТ РАЗРЯДТЫ ЕКІЛІК ПАРАЛЛЕЛЬ ТАСЫМАЛДАҒЫШЫ БАР ҚОСЫНДЫЛАРДЫ САЛЫСТЫРМАЛЫ ТАЛДАУ.....	200
Б.М. Укибасов, С.Б. Рахметулаева, Ж.О. Жанабеков, Ансар-уль-Хак Ясар ЭХОКАРДИОГРАММАЛАРДАҒЫ АҚАУЛАРДЫ ДИАГНОСТИКАЛАУ ҮШІН БЕТТІ АНЫҚТАУ ЖӘНЕ ТАНУ ҮЛГІЛЕРІН БЕЙІМДЕУ.....	214
Д.И. Усипбекова, М.Б. Есенова, Н. Ұзаққызы, Р. Муратхан, П. Шмидт МАММОГРАФИЯЛЫҚ СУРЕТТЕРДЕ СҮТ БЕЗІ ҚАТЕРЛІ ІСІГІН ДӨЛ АНЫҚТАУҒА АРНАЛҒАН БЕЛГІЛЕР ВЕКТОРЫН ҚҰРУ.....	235

СОДЕРЖАНИЕ

М.Ж. Айтимов, К.К. Макулов, А.Б. Остаева, Г.Ш. Мусагулова, Я. Култан ПРИМЕНЕНИЕ ГИБРИДНОЙ МОДЕЛИ ДЛЯ ИЗУЧЕНИЯ ВЛИЯНИЯ СОЦИАЛЬНО-ЭКОНОМИЧЕСКИХ ФАКТОРОВ НА РЕГИОНАЛЬНОЕ РАЗВИТИЕ.....	8
А.С. Баегизова, Г.Е. Мырзабекова, А.З. Алимагамбетова, Г.И. Мухамедрахимова, М. Кассим АНАЛИЗ КОРОТКИХ ТЕКСТОВ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ИНТЕЛЛЕКТУАЛЬНОЙ КЛАС- ТЕРИЗАЦИИ.....	23
Г.У. Бектемысова, А.А. Быков, Б.А. Нурашихин, А.А. Кереш, М.О. Даулетбек РАЗРАБОТКА И ТЕСТИРОВАНИЕ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ МОНИТОРИНГА СТРОИТЕЛЬНЫХ ПРОЦЕССОВ НА ОСНОВЕ КОМПЬЮТЕРНОГО ЗРЕНИЯ И МАШИННОГО ОБУЧ- ЕНИЯ.....	37
Д. Едилхан, Н. Хаймульдин, Д. Оспанова, Б. Амиргалиев ИНТЕЛЛЕКТУАЛЬНАЯ МОДЕЛЬ ПОИСКА ОПТИМАЛЬНОГО МАРШРУТА ПОКРЫТИЯ ВСЕХ УЛИЦ С ОГРАНИЧЕНИЯМИ ПО ПЕРЕМЕЩЕНИЯМ.....	57
А. Игнатович, А.С. Есенгельдина, Л.Т. Курмангазиева, С.Р. Шармуханбет, А.М. Недзьведь ГЕНЕРАЦИЯ ДАННЫХ ДЛЯ ПРОГНОЗИРОВАНИЯ СУДЕБНЫХ РЕШЕНИЙ В КАЗАХСТАНЕ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ.....	75
А.Х. Касымова, Г.Б. Абдикеримова, А.К. Асабай, А.Б. Серикбаева, С.М. Ахмедова МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ В РЕАЛЬНОМ ВРЕМЕНИ ДЛЯ ОБНАРУЖЕНИЯ ДВИЖУЩИХСЯ ОБЪЕКТОВ В ВИДЕОПОТОКАХ.....	91
С.К. Кумаргажанова, Д. Нурлыбекова, А.С. Тлебалдинова, М.А. Карменова, С.А. Смаилова ВЫЯЛЕНИЕ ЛАВИНООПАСНЫХ ЗОН В ВОСТОЧНОМ КАЗАХСТАНЕ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ.....	115
С.Б. Муханов, К. Бекболат, Н.А. Сейлова, Ж.М. Бекаулова, С. Ж. Жакыпбеков СРАВНЕНИЕ МОДЕЛЕЙ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ВОЛАТИЛЬНОСТИ ЦЕН КРИПТОВАЛЮТ В ТОРГОВЫХ ПАРАХ.....	130
Н.А. Оданова, К.Б. Багитова, Э.Э. Эльдарова, Ж.Т. Кабылхамит, Л. Терейковская ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ДЛЯ АНАЛИЗА КЛАВИАТУРНОГО ПОЧЕРКА В ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТИ.....	142
А.С. Сраж, М. Нуртас, А.А. Алтайбек, З.Т. Абдикаликова НЕЙРОННЫЕ СЕТИ КАК ИНСТРУМЕНТ МАТЕМАТИЧЕСКИХ ВЫЧИСЛЕНИЙ.....	154
А.М. Темирхан, Г.Н. Пашенко ГРАФОВЫЕ НЕЙРОННЫЕ СЕТИ ДЛЯ ОБНАРУЖЕНИЯ МОШЕННИЧЕСТВА: СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ.....	174
Е.Б. Тулебаев, А.А. Муханова, Н. Горанин ПРОГНОЗНАЯ ОЦЕНКА РИСКОВ МУНИЦИПАЛЬНЫХ АКТИВОВ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ: МОДЕЛИРОВАНИЕ ВОЗРАСТА, ИЗНОСА И ИСПОЛЬЗОВАНИЯ ДЛЯ ПРИНЯТИЯ РЕШЕНИЙ ПО ОБСЛУЖИВАНИЮ.....	186
С. Тынымбаев, Ж.Е. Темирбекова, Р.Ш. Бердибаев, С.Е. Маманова СРАВНИТЕЛЬНЫЙ АНАЛИЗ ЧЕТЫРЕХРАЗЯДНЫХ ДВОИЧНЫХ СУММАТОРОВ С ПАРАЛЛЕЛЬНЫМИ ПЕРЕНОСАМИ.....	200
Б.М. Укибассов, С.Б. Рахметулаева, Ж.О. Жанабеков, Ансар-уль-Хак Ясар АДАПТАЦИЯ МОДЕЛЕЙ ОБНАРУЖЕНИЯ И РАСПОЗНАВАНИЯ ЛИЦ ДЛЯ ДИАГНОСТИКИ ДЕФЕКТОВ НА ЭХОКАРДИОГРАММАХ.....	214
Д.И. Усипбекова, М.Б. Есенова, Н. Узаккызы, Р. Мурадхан, П. Шмидт ОПРЕДЕЛЕНИЕ ВЕКТОРА ПРИЗНАКОВ ДЛЯ ТОЧНОГО ВЫЯВЛЕНИЯ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ НА ИЗОБРАЖЕНИЯХ МАММОГРАММЫ.....	235

CONTENTS

M. Aitimov, K. Makulov, A. Ostayeva, G. Mussagulova, J. Kultan APPLICATION OF A HYBRID MODEL TO STUDY THE IMPACT OF SOCIO-ECONOMIC FACTORS ON REGIONAL DEVELOPMENT.....	8
A. Bayegizova, G. Murzabekova, A. Alimagambetova, G. Mukhamedrakhimova, M. Kassim INTELLIGENT CLUSTERING METHODS FOR PROCESSING AND ANALYZING SHORT TEXTS.....	23
G.U. Bektemysova, A.A. Bykov, B.A. Norashikin, A.A. Keresh, M.O. Dauletbek DEVELOPMENT AND TESTING OF AN INTELLIGENT MONITORING SYSTEM FOR CONSTRUCTION PROCESSES BASED ON COMPUTER VISION AND MACHINE LEARNING.....	37
D. Yedilkhan, N. Khaimuldin, D. Ospanova, B. Amirgaliyev INTELLIGENT MODEL FOR FINDING THE OPTIMAL ROUTE TO COVER ALL STREETS WITH MOVEMENT CONSTRAINTS.....	57
A. Ignatovich, A.S. Yesengeldina, L.T. Kurmangazyeva, S.R. Sharmukhanbet, A.M. Nedzved SIGNIFICANT FACTORS ANALYSIS USING SHAP AND PCA FOR OPTIMIZING AGRICULTURAL RESOURCE MANAGEMENT.....	75
A. Kassymova, G. Abdikerimova, A. Assabay, A. Serikbayeva, S. Akhmedova REAL-TIME MATHEMATICAL MODELING FOR MOVING OBJECT DETECTION IN VIDEO STREAMS.....	91
S.K. Kumargazhanova, D. Nurlybekova, A.S. Tlebaldinova, M.A. Karmenova, S.S. Smailova FINDING AVALANCHE AREAS IN EAST KAZAKHSTAN USING MACHINE LEARNING.....	115
S.B. Mukhanov, K. Bekbolat, N.A. Seilova, Zh.M. Bekaulova, S.Zh. Zhakypbekov COMPARISON OF NEURAL NETWORK MODELS FOR PREDICTION CRYPTOCURRENCY PRICE VOLATILITY IN TRADING PAIRS.....	130
N. Odanova, K. Bagitova, E. Eldarova, Zh. Kabylkhamit, L. Tereikovska APPLICATION OF NEURAL NETWORK MODELS FOR KEYSTROKE DYNAMICS ANALYSIS IN INFORMATION SECURITY.....	142
A.S. Srazh, M. Nurtas, A.A. Altaibek, Z.T. Abdikalikova EURAL NETWORKS AS A TOOL FOR MATHEMATICAL COMPUTATION.....	154
A.M. Temirkhan, G.N. Pachshenko GRAPH NEURAL NETWORKS FOR FRAUD DETECTION: COMPARATIVE ANALYSIS OF METHODS.....	174
Y.B. Tulebayev, A.A. Mukhanova, N. Goranin PREDICTIVE RISK ASSESSMENT OF MUNICIPAL ASSETS USING MACHINE LEARNING: MODELING AGE, DEPRECIATION, AND USAGE FOR MAINTENANCE DECISIONS.....	186
S. Tynymbayev, Zh. E. Temirbekova, R. Berdibayev, E.S. Mamanova COMPARATIVE ANALYSIS OF FOUR-BIT BINARY ADDERS WITH PARALLEL CARRIES.....	200
B.M. Ukibassov, S.B. Rakhmetulayeva, Zh.O. Zhanabekov, Ansar-Ul-Haque Yasar ADAPTING FACE DETECTION AND RECOGNITION MODELS FOR ECHOCARDIOGRAPHIC DEFECT DIAGNOSIS.....	214
D. Ussipbekova, M. Yessenova, N. Uzakkyzy, R. Muratkhan, P. Schmidt DETERMINATION OF SIGNS VECTOR FOR ACCURATE DETECTION OF BREAST CANCER IN MAMMOGRAM IMAGES.....	235

INTERNATIONAL JOURNAL OF INFORMATION AND COMMUNICATION TECHNOLOGIES

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Vol. 6. Is. 1. Number 22 (2025). Pp. 154–173

Journal homepage: <https://journal.iitu.edu.kz><https://doi.org/10.54309/IJICT.2025.22.2.010>

UDC: 004.032.26

NEURAL NETWORKS AS A TOOL FOR MATHEMATICAL COMPUTATION

A.S. Srazh¹, M. Nurtas^{1,2}, A.A. Altaibek¹, Z.T. Abdikalikova^{1}*

¹International Information Technology University, Almaty, Kazakhstan;

²Institute of Ionosphere, Almaty, Kazakhstan.

E-mail: z.abdikalikova@iitu.edu.kz

Srazh A. — PhD student, lecturer, «the Department of Mathematical and Computer Modelling», International Information Technology University, Almaty, Kazakhstan

E-mail: a.srazh@iitu.edu.kz, ORCID: 0009-0003-9682-0766;

Nurtas M. — PhD, associate professor, «the Department of Mathematical and Computer Modelling», International Information Technology University, Almaty, Kazakhstan

E-mail: m.nurtas@iitu.edu.kz, ORCID: 0000-0003-4351-0185;

Altaibek A. — PhD, associate professor, «the Department of Mathematical and Computer Modelling», International Information Technology University, Almaty, Kazakhstan

E-mail: a.altaibek@iitu.edu.kz, ORCID: 0000-0001-8431-7950;

Abdikalikova Z. — associate professor, «the Department of Mathematical and Computer Modelling», International Information Technology University, Almaty, Kazakhstan

E-mail: z.abdikalikova@iitu.edu.kz. ORCID: 0000-0003-0131-4469.

© A.S. Srazh, M. Nurtas, A.A. Altaibek, Z.T. Abdikalikova, 2025

Abstract. The application of neural networks has become nearly ubiquitous across a wide range of domains. However, researchers in fields less closely associated with mathematics often overlook the substantial mathematical foundations underpinning deep neural networks. This gap in understanding can lead to unforeseen challenges in the research process, as the core architecture of every neural network—regardless of complexity—is fundamentally grounded in mathematical principles, from basic expressions to advanced formulations. In this paper, we elucidate the mathematical structures that underpin neural network models and demonstrate how they inform and influence model behavior. By highlighting these mathematical aspects, we aim to bridge the knowledge gap for educators and domain experts, thereby enhancing interdisciplinary understanding and improving the effective application of neural networks.

Keywords: machine learning, microclimate management, HVAC optimization, fault detection, predictive maintenance, user preferences, energy efficiency

For citation: A.S. Srazh, M. Nurtas, A.A. Altaibek, Z.T. Abdikalikova. Neural networks as a tool for mathematical computation//International journal of



information and communication technologies. 2025. Vol. 6. No. 22. Pp. 154–173 (In Eng.). <https://doi.org/10.54309/IJICT.2025.22.2.010>.

Conflict of interest: The authors declare that there is no conflict of interest.

НЕЙРОНДЫҚ ЖЕЛІЛЕР МАТЕМАТИКАЛЫҚ ЕСЕПТЕУ ҚҰРАЛЫ РЕТІНДЕ

А.С. Сразж¹, М. Нұртас^{1,2}, А.А. Алтайбек¹, З.Т. Абдикаликова^{1}*

¹Халықаралық ақпараттық технологиялар университеті, Алматы, Қазақстан;

²Ионосфера институты, Алматы, Қазақстан.

E-mail: z.abdikalikova@iitu.edu.kz

Сразж А. — PhD докторант, Халықаралық ақпараттық технологиялар университеті «Математикалық және компьютерлік модельдеу» кафедрасының лекторы, Алматы, Қазақстан

E-mail: a.srazh@iitu.edu.kz. ORCID: 0000-0003-0341-4017;

Нұртас М. — PhD, Халықаралық ақпараттық технологиялар университеті «Математикалық және компьютерлік модельдеу» кафедрасының қауымдастырылған профессоры, Алматы, Қазақстан

E-mail: m.nurtas@iitu.edu.kz. ORCID: 0000-0003-4351-0185;

Алтайбек А. — PhD, Халықаралық ақпараттық технологиялар университеті «Математикалық және компьютерлік модельдеу» кафедрасының қауымдастырылған профессоры, Алматы, Қазақстан

E-mail: a.altaibek@iitu.edu.kz. ORCID: 0000-0001-8431-7950;

Абдикаликова З. — PhD, Халықаралық ақпараттық технологиялар университеті «Математикалық және компьютерлік модельдеу» кафедрасының қауымдастырылған профессоры, Алматы, Қазақстан

E-mail: z.abdikalikova@iitu.edu.kz. ORCID: 0000-0003-0131-4469.

© А.С. Сразж, М. Нұртас, А.А. Алтайбек, З.Т. Абдикаликова, 2025

Аннотация. Қазіргі таңда нейрондық желілердің қолданысы дерлік барлық жерде кең етек жая бастады. Бірақ осы терең нейрондық желілердің артында үлкен математикалық база тұрғанын математикалан алыс саладағы көптеген зерттеушілер байқай бермейді. Осы кемшілік зерттеу барысында кейін кейбір ойламаған қиыншылықтарды туындатады. Себебі, әрбір жазылған нейрондық желі моделдерін негізгі тірегі қарапайым математикалық өрнектерден бастап, күрделі деңгейге дейін жетеді. Біз осы мақалада сол олқылықтарды аз да болса, толықтыру мақсатында жалпы оқытушы ұстаздарға, әр сала мамандарына осы математикалық аспектілердің қолданысын ашып, қалай қолданылатынын және нейрондық желі моделдерінде қандай маңызды рөл атқаратынын көрсетеміз.

Түйін сөздер: математикадағы нейрондық желілер, терең оқыту, активтендіру функциялары, шығын функциясы, құн функциясы, регрессия, классификация

Дәйексөздер үшін: Н.А. Дауренбаева, Л.Б. Атымтаева, Н.С. Луценко, А. Нұрланұлы. Гимараттардағы микроклиматты басқаруды оңтайландыру үшін машиналық оқытуды біріктіру: перспективалар мен мүмкіндіктер//Халықаралық ақпараттық және коммуникалық технологиялар журналы. 2025. Т. 6. No. 22. 154–173 бет. (ағылшын тілінде). <https://doi.org/10.54309/IJICT.2025.22.2.010>.

Мүдделер қақтығысы: Авторлар осы мақалада мүдделер қақтығысы жоқ деп мәлімдейді.

НЕЙРОННЫЕ СЕТИ КАК ИНСТРУМЕНТ МАТЕМАТИЧЕСКИХ ВЫЧИСЛЕНИЙ

А.С. Сраж¹, М. Нуртас^{1,2}, А.А. Алтайбек¹, З.Т. Абдикаликова^{1}*

¹Международный университет информационных технологий, Алматы, Казахстан;

²Институт ионосферы, Алматы, Казахстан.

E-mail: z.abdikalikova@iitu.edu.kz

Сраж А. — PhD-студент, преподаватель, «Кафедра математического и компьютерного моделирования», Международный университет информационных технологий, Алматы, Казахстан
E-mail: a.srazh@iitu.edu.kz. ORCID: 0009-0003-9682-0766;

Нуртас М. — PhD, ассоциированный профессор, «Кафедра математического и компьютерного моделирования», Международный университет информационных технологий, Алматы, Казахстан
E-mail: m.nurtas@iitu.edu.kz. ORCID: 0000-0003-4351-0185;

Алтайбек А. — PhD, ассоциированный профессор, «Кафедра математического и компьютерного моделирования», Международный университет информационных технологий, Алматы, Казахстан
E-mail: a.altaibek@iitu.edu.kz. ORCID: 0000-0001-8431-7950;

Абдикаликова З. — PhD, ассоциированный профессор, «Кафедра математического и компьютерного моделирования», Международный университет информационных технологий, Алматы, Казахстан
E-mail: z.abdikalikova@iitu.edu.kz. ORCID: 0000-0003-0131-4469.

© А.С. Сраж, М. Нуртас, А.А. Алтайбек, З.Т. Абдикаликова, 2025

Аннотация. В настоящее время нейронные сети активно применяются практически во всех сферах науки и практики. Однако специалисты в областях, не связанных напрямую с математикой, зачастую упускают из виду, что в основе современных глубоких нейронных сетей лежит значительный математический аппарат. Недостаток понимания этих основ порождает определённые трудности в исследовательской деятельности, особенно при разработке и интерпретации моделей. Следует отметить, что каждая модель нейронной сети, вне зависимости от уровня её сложности, базируется на математических конструкциях — от элементарных выражений до многоуровневых структур. В данной статье рассматриваются ключевые математические аспекты, лежащие в основе архитектуры нейронных сетей, а также раскрывается их значимость в контексте практического применения. Особое внимание уделяется популяризации математической базы среди преподавателей и специалистов различных предметных областей с целью частичного преодоления существующего междисциплинарного разрыва в понимании природы нейросетевых моделей.

Ключевые слова: нейронные сети в математике, глубокое обучение, функции активации, функция потерь, функция стоимости, регрессия, классификация

Для цитирования: А.С. Сраж, М. Нуртас, А.А. Алтайбек, З.Т. Абдикаликова. Нейронные сети как инструмент математических вычислений// Международный журнал информационных и коммуникационных технологий. 2025. Т. 6. No. 22. Стр. 154–173. (На англ.). <https://doi.org/10.54309/>

IJICT.2025.22.2.010.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Introduction

Artificial Intelligence (AI) has gone through several key stages of development. In the 1950s-1980s (Stage I) it was in the “warm-up” stage, then from the 1980s to 2010 (Stage II) there was a period of active research, and since 2010 the “golden era” of AI based on industrial data began. Today, AI outperforms humans in many areas (Huang, 2024: 2–3).

Although the concept of neural network is very popular today, it has a long history dating back to the first half of the 20th century. In the 1940s, W. McCulloch and W. Pitts discovered that an artificial neuron could be modeled as a simple threshold device that could compute any arithmetic or logical function (McCulloch, 1943: 115–117). In 1949, D. Hebb proposed the Hebb rule to describe how learning between two neurons affects synaptic connections (Hebb, 1949: 62–63).

An important stage in the formation of AI was the work of Alan Turing. In 1950, he proposed the Turing test, which evaluates whether a machine can demonstrate intelligent behavior indistinguishable from human behavior (Turing, 1950: 433–435). In 1956, John McCarthy defined artificial intelligence and organized the Dartmouth Conference, which was the starting point for the development of the field (McCarthy, 1956: 1–3).

In the late 1950s, Rosenblatt presented the perceptron model, which caused great interest in neural networks. However, as early as 1969, M. Minsky and S. Papert mathematically proved the limitations of the perceptron, which led to the first crisis in neural network research and a decline in interest in neural networks (Minsky, 1969: 4–11).

In the 1980s, with the development of new algorithms, including the error back propagation algorithm, and the advent of more powerful computers, interest in neural networks was renewed. During this period, important models such as the Hopfield network, Kohonen maps and Adaptive Resonance Theory (ART) were proposed (Grossberg, 1988: 37–40).

Since the 2010s, the development of artificial intelligence has accelerated due to the increase in computing power and data volumes. In 2016, the AlphaGo program created by DeepMind beat the world champion in the game of Go, which was a milestone in the development of machine learning (Silver, 2016: 484–485).

Today, neural networks are applied in various fields including medicine, finance, autonomous systems, and natural language processing. Modern models such as deep neural networks show outstanding results in image recognition, disease diagnosis, and intelligent systems development (LeCun, 2015: 436–438).

Materials and methods

Artificial intelligence (AI) is the field of computer science that enables

machines to perform cognitive tasks such as problem-solving, learning, and decision-making (Messerli, 2024: 50–52). One of the key approaches in AI is the development of artificial neural networks (ANNs), which are inspired by the structure and functionality of the biological neural network (BNN) found in the human brain (Thakur, 2021: 407–408).

The human brain contains about 10^{11} neurons that process information using electrical and chemical signals. Each neuron consists of a cell body (soma) that integrates incoming signals, dendrites that receive inputs, and an axon that transmits signals to other neurons. Communication occurs at synapses, where chemical neurotransmitters determine whether the next neuron will activate (Du, 2019: 4; Kandel, 2014: 65–66). Figure 1 illustrates the structural comparison between a biological neuron and an artificial neuron.




Fig.1. Structure of a Biological Neuron and an Artificial Neuron

In artificial neural networks, this process is modeled mathematically. Artificial neurons receive numerical inputs (), multiply them by specific weights (), sum them, and pass the result through an activation function (Goodfellow, 2016: 15–16; Nurtas, 2020: 29–30).

$$y = f \left(\sum_i w_i x_i + b_i \right) \quad (1)$$

where b_i is the bias term.

Weights and biases are the key parameters that determine how input data is transformed as it propagates through the network. Weights represent the strength of connections between neurons and define how much influence a given input has on the neuron's output. Biases, on the other hand, allow the activation of a neuron to shift up or down, enabling better flexibility in learning complex patterns. Parameters, including weights and biases, are optimized during training to minimize errors and enhance performance. The concept of weights and biases can be thought of as “knobs” that we adjust to optimize the model. As seen in Figure 2, increasing the weight increases the slope of the function; while decreasing it reduces the slope. Changing the bias shifts the function up or down, as illustrated in Figure 3.




Fig. 2. Graph of a Single-Input Neuron's Output with a Weight of 1, Bias of 0 and Input .




Fig. 3. Graph of a Single-Input Neuron's Output with a Weight of 1, Bias of 2 and Input .

A practical example of parameter calculation in a neural network is shown in Figure 4.




Fig. 4. Example of a Neural Network with 3 Hidden Layers

The network consists of five layers with sizes 4, 5, 7, 5, and 2. The total number of parameters in this multilayer neural network can be determined by considering the number of weights and biases between the layers. Given a network architecture where each layer has neurons, the number of parameters between two consecutive layers and is given by .

For the given network with architecture (4,5,7,5,2), the total number of parameters is

$$P = (4 \times 5 + 5) + (5 \times 7 + 7) + (7 \times 5 + 5) + (5 \times 2 + 2) = 119.$$

Thus, the total number of parameters in this neural network is 119.

In biological neurons, an activation threshold (around -55mV) determines whether a neuron fires a signal. Similarly, in ANNs, activation functions like Sigmoid, or ReLU decide whether an artificial neuron “activates” (Goodfellow, 2016: 175–176; Altaibek, 2025: 6–7).



The key difference is how information is processed. Biological neurons rely on electrochemical processes and adapt their connections through neuroplasticity, while artificial neurons use mathematical computations and adjust parameters through learning algorithms like backpropagation. However, in both cases, learning occurs by strengthening important connections and improving information processing over time (LeCun, 2015: 436–438).



In biologically inspired neural networks, the activation function serves as an abstraction of the cell’s action potential firing rate. In its simplest form, this function is binary, meaning the neuron is either active (firing) or inactive (not firing) (Keller, 2016: 9–12).

In general, an activation function is a mathematical transformation applied to a neuron’s input (typically a weighted sum of signals) to produce its output. By introducing nonlinearity, it enables the network to model complex relationships in data, thereby enhancing its ability to learn and detect intricate patterns (Haykin, 2009: 12–14). This transformation is key to converting input data into a neuron’s output signal, making the network flexible and capable of capturing complex nonlinear dependencies.

The table below summarizes the main activation functions, their mathematical expressions and corresponding graph (Soares, 2017: 5–6; Venkateswaran, 2017: 13–18):

Table 1. Types of Activation Functions

Function	Equation	Chart
Sigmoid		
Hyperbolic tangent		

Hard limiting threshold		
Rectified Linear Unit		

Results and Discussion

The choice of activation function depends on the specific task and model architecture.

Let us consider an example that uses a step function (Hard limiting threshold) as the activation function, as presented in Table 1. For illustration, we consider the XOR function in a practical context.

Example 1: In modern medicine, early diagnostic algorithms often rely on the combined use of biomarkers to assess both localized and systemic pathological processes. Consider a hypothetical scenario where two independent biomarkers are utilized to detect the early stage of an inflammatory process:

Indicator A: The level of C-reactive protein (CRP), a sensitive marker of inflammation.

Indicator B: The white blood cell (WBC) count, reflecting the immune response of the body.

Under normal conditions, both indicators fall within their respective reference ranges ($X1 = 0$, $X2 = 0$). However, during the early stages of localized inflammation, only one of these parameters might deviate from normal. The application of the XOR logical operation formalizes this case as follows:

Case 1: If the CRP level is elevated ($X1 = 1$) while the WBC count remains normal ($X2 = 0$), this suggests localized inflammation that may warrant targeted intervention.

Case 2: If the WBC count is elevated ($X2 = 1$) while the CRP level remains normal ($X1 = 0$), this also indicates localized inflammation, prompting early therapeutic action.

Case 3: If both indicators are abnormal ($X1 = 1$, $X2 = 1$), it may signify systemic inflammation or a severe infection. In such cases, the standard XOR-based early diagnosis algorithm is not applicable, necessitating a comprehensive diagnostic approach.

Case 4: If both indicators are within normal limits ($X1 = 0, X2 = 0$), no pathological process is detected, and specific therapy is not required.

The corresponding truth table for this example is as follows:

Table 2. Truth Table for Example 1

Indicator $X1$ (CRP)	Indicator $X2$ (WBC count)	Need for Early Diagnosis (XOR)
0	0	0
0	1	1
1	0	1
1	1	0

In Table 2 we can see that when both inputs are the same, the output is 0, and otherwise it is 1. Such dependencies cannot be modeled with a single neuron, so we will use a multi-layer network. The idea behind using multiple layers is that complex dependencies can be broken down into simpler functions and then combined.

Let us express the XOR function (*Note: here '+' means OR and '.' means AND*):

$$X1 \text{ XOR } X2 = (X1.\text{NOT}(X2)) + (\text{NOT}(X1).X2)$$

To realize XOR, we will use a two-layer neural network (see Figure 5):




Fig. 5. Architecture of XOR Function

The first hidden layer consists of 2 neurons:

The first neuron computes $\text{NOT}(X1).X2$

Second neuron calculates $X1.\text{NOT}(X2)$

Output layer consists of 1 neuron:

Performs an OR operation on the two outputs of the hidden layer.

In the first hidden layer, we compute $\text{NOT}(X1).X2$ and $X1.\text{NOT}(X2)$,

where

Input 1:

Input 2:

Second layer (OR calculation)

Output neuron:

Now we can implement it using simplified cases. First, let's design a neuron to model $X1.\text{NOT}(X2)$. This can be modeled as follows (as illustrated in Figure 6):




Fig.6. Neural Network Architecture for X1.NOT(X2)

The output of this neuron is:

$$a_1 = f(-0.5 + x_2 - x_1)$$

Table 3. Truth Table for X1.NOT(X2)

X1	X2	NOT(X1).X2	-0.5 + X2 - X1	a1
0	0	0	-0.5	0
0	1	1	0.5	1
1	0	0	-1.5	0
1	1	0	-0.5	0

In the first layer, we compute NOT(X1).X2 and X1.NOT(X2) separately. Then, in the second layer, we take their outputs and apply an OR function to them. This completes the neural network. The final structure of the network will look like this (see Figure 7):




Fig. 7. Neural Network Architecture for X1.XOR(X2)

Table 4. Truth Table for $X1.NOT(X2)$

X1	X2	a1	a2	a3
0	0	0	0	0
0	1	1	0	1
1	0	0	1	1
1	1	0	0	0

This example demonstrates how the XOR function can be applied in real-world diagnostic cases. By leveraging a neural network with a step activation function (Hard Limiting Threshold), we can formalize decision-making processes based on medical biomarkers. This approach helps distinguish localized inflammation from systemic conditions, allowing for more targeted and timely interventions.

The use of activation functions like the step function highlights the fundamental role they play in transforming input data into meaningful outputs within neural networks. While simple threshold-based functions provide a clear binary decision mechanism, more advanced activation functions may be required for handling complex, non-linear relationships in medical diagnostics and other fields.

Neural networks learn by adjusting weights and biases through forward and backward propagation. Forward propagation computes the output based on given inputs, while backward propagation calculates errors and updates weights accordingly. This process minimizes the difference between predicted and actual values using optimization techniques such as gradient descent. The fundamental goal is to iteratively adjust parameters to improve accuracy.

The training process of a neural network follows a systematic sequence of operations. The following steps outline the complete forward and backward propagation procedures.

Step 1. The neural network is supplied with an input matrix X , consisting of four features and three training samples, as well as a target output matrix y :

$$X = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 1 \\ 0 & 1 & 0 & 1 \end{bmatrix}$$

$$y = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix}$$

The weight matrices for the hidden layer (W_h) and output layer (W_{out}) are initialized with small random values. The bias terms (b_h and b_{out}) are similarly initialized:

$$W_h = \begin{bmatrix} 0.42 & 0.88 & 0.55 \\ 0.10 & 0.73 & 0.68 \\ 0.60 & 0.18 & 0.47 \\ 0.92 & 0.11 & 0.52 \end{bmatrix}$$

$$b_h = [0.46 \quad 0.72 \quad 0.08]$$

$$W_{out} = \begin{bmatrix} 0.30 \\ 0.25 \\ 0.23 \end{bmatrix}$$

$$b_{out} = [0.69]$$

Step 2. To solve this problem, we begin by representing the input in both mathematical and computational forms.

The input to the hidden layer is computed as follows:

Computational Form:

hidden_layer_input = matrix_dot_product(X, W_h) + b_h

Mathematical Form:

$$H_{in} = X \times W_h + b_h = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 1 \\ 0 & 1 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} 0.42 & 0.88 & 0.55 \\ 0.10 & 0.73 & 0.68 \\ 0.60 & 0.18 & 0.47 \\ 0.92 & 0.11 & 0.52 \end{bmatrix} + \begin{bmatrix} 0.46 & 0.72 & 0.08 \\ 0.46 & 0.72 & 0.08 \\ 0.46 & 0.72 & 0.08 \end{bmatrix}$$

Performing the matrix multiplication and addition yields:

First row computation:

$$H_{in_{1,1}} = (1 \times 0.42) + (0 \times 0.10) + (1 \times 0.60) + (0 \times 0.92) + 0.46 = 1.48$$

$$H_{in_{1,2}} = (1 \times 0.88) + (0 \times 0.73) + (1 \times 0.18) + (0 \times 0.11) + 0.72 = 1.78$$

$$H_{in_{1,3}} = (1 \times 0.55) + (0 \times 0.68) + (1 \times 0.47) + (0 \times 0.52) + 0.08 = 1.10$$

Second row computation:

$$H_{in_{2,1}} = (1 \times 0.42) + (0 \times 0.10) + (1 \times 0.60) + (1 \times 0.92) + 0.46 = 2.40$$

$$H_{in_{2,2}} = (1 \times 0.88) + (0 \times 0.73) + (1 \times 0.18) + (1 \times 0.11) + 0.72 = 1.89$$

$$H_{in_{2,3}} = (1 \times 0.55) + (0 \times 0.68) + (1 \times 0.47) + (1 \times 0.52) + 0.08 = 1.62$$

Third row computation:

$$H_{in_{1,3}} = (0 \times 0.42) + (1 \times 0.10) + (0 \times 0.60) + (1 \times 0.92) + 0.46 = 1.48$$

$$H_{in_{1,3}} = (0 \times 0.88) + (1 \times 0.73) + (0 \times 0.18) + (1 \times 0.11) + 0.72 = 1.56$$

$$H_{in_{1,3}} = (0 \times 0.55) + (1 \times 0.68) + (0 \times 0.47) + (1 \times 0.52) + 0.08 = 1.28$$

The input of the hidden layer is obtained as follows:

$$H_{in} = \begin{bmatrix} 1.48 & 1.78 & 1.10 \\ 2.40 & 1.89 & 1.62 \\ 1.48 & 1.56 & 1.28 \end{bmatrix}$$

Step 3. After computing the hidden layer input, an activation function is applied to introduce non-linearity into the model. This step is crucial for capturing complex patterns in the data. In this case, a sigmoid activation function is applied to the hidden layer input:

$$\text{hidden_layer_activations} = \text{sigmoid}(\text{hidden_layer_input})$$

or

$$H_{out} = \frac{1}{1 + e^{-H_{in}}}$$

For example, for the first element

$$H_{out_{1,1}} = 0.815:$$

$$H_{out_{1,1}} = \frac{1}{1 + e^{-1.48}} \approx 0.815$$

Applying this to all elements, the output of the hidden layer is obtained as follows:

$$H_{out} \approx \begin{bmatrix} 0.815 & 0.855 & 0.750 \\ 0.916 & 0.868 & 0.836 \\ 0.815 & 0.825 & 0.782 \end{bmatrix}$$

Step 4. The output layer input is calculated as:

$$\text{output_layer_input} = \text{matrix_dot_product}(\text{hidden_layer_activations} * W_{out-}) + b_{out}$$

or

$$O_{in} = H_{out} \times W_{out} + b_{out}$$

$$O_{in} \approx \begin{bmatrix} (0.815 \times 0.30) + (0.855 \times 0.25) + (0.750 \times 0.23) + 0.69 \\ (0.916 \times 0.30) + (0.868 \times 0.25) + (0.836 \times 0.23) + 0.69 \\ (0.815 \times 0.30) + (0.825 \times 0.25) + (0.782 \times 0.23) + 0.69 \end{bmatrix} \approx \begin{bmatrix} 1.321 \\ 1.3741 \\ 1.3206 \end{bmatrix}$$

Applying the sigmoid function to O_{in} :

output = sigmoid(output_layer_input)

or

$$O_{out} = \sigma(O_{in}) = \frac{1}{1 + e^{-O_{in}}}$$

$$O_{out} = \begin{bmatrix} \frac{1}{1 + e^{-1.321}} \\ \frac{1}{1 + e^{-1.3741}} \\ \frac{1}{1 + e^{-1.3206}} \end{bmatrix} \approx \begin{bmatrix} 0.789 \\ 0.798 \\ 0.789 \end{bmatrix}$$

Step 5. The error is determined by computing the difference between the predicted and target values:

$$E = y - O_{out}$$

$$E = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix} - \begin{bmatrix} 0.789 \\ 0.798 \\ 0.789 \end{bmatrix} = \begin{bmatrix} 0.211 \\ 0.202 \\ -0.789 \end{bmatrix}$$

Step 6. The slope for the hidden and output layer neurons are computed as:

slope_output_layer = derivatives_sigmoid(output)

slope_hidden_layer = derivatives_sigmoid(hidden_layer_activations)

or

$$\sigma'(O_{out}) = O_{out} \times (1 - O_{out})$$

$$\sigma'(O_{in}) = H_{out} \times (1 - H_{out})$$

$$\sigma'(O_{out}) = \begin{bmatrix} 0.789 \times (1 - 0.789) \\ 0.798 \times (1 - 0.798) \\ 0.789 \times (1 - 0.789) \end{bmatrix} = \begin{bmatrix} 0.1665 \\ 0.1612 \\ 0.1665 \end{bmatrix}$$

$$\sigma'(O_{in}) = \begin{bmatrix} 0.815 \times (1 - 0.815) & 0.855 \times (1 - 0.855) & 0.750 \times (1 - 0.750) \\ 0.916 \times (1 - 0.916) & 0.868 \times (1 - 0.868) & 0.836 \times (1 - 0.836) \\ 0.815 \times (1 - 0.815) & 0.825 \times (1 - 0.825) & 0.782 \times (1 - 0.782) \end{bmatrix}$$

$$= \begin{bmatrix} 0.151 & 0.124 & 0.188 \\ 0.077 & 0.115 & 0.137 \\ 0.151 & 0.144 & 0.170 \end{bmatrix}$$

where $\sigma'(x) = x(1 - x)$ is the derivative of the sigmoid function.

Step 7. The delta at the output layer is computed using the formula:

$$d_output = E * slope_output_layer * learning_rate$$

or

$$\delta_{out} = E \times \sigma'(O_{out}) \times 1$$

This yields:

$$\delta_{out} = \begin{bmatrix} 0.211 \times 0.1665 \\ 0.202 \times 0.1612 \\ -0.789 \times 0.1665 \end{bmatrix} = \begin{bmatrix} 0.035 \\ 0.032 \\ -0.13 \end{bmatrix}$$

Step 8. The error at the hidden layer is computed as:

$$Error_at_hidden_layer = matrix_dot_product(d_output, W_out.Transpose)$$

or

$$E_{hidden} = \delta_{out} \times W_{out}^T$$

$$E_{hidden} = \begin{bmatrix} 0.035 \\ 0.032 \\ -0.13 \end{bmatrix} \times \begin{bmatrix} 0.30 & 0.25 & 0.23 \end{bmatrix} = \begin{bmatrix} 0.010 & 0.009 & 0.008 \\ 0.010 & 0.008 & 0.074 \\ -0.039 & -0.033 & -0.03 \end{bmatrix}$$

Step 9. In this step, the delta values for the hidden layer are determined using the element-wise product of the propagated error at the hidden layer and the derivative of the activation function. Mathematically, this relationship is expressed as follows:

$$d_hidden_layer = Error_at_hidden_layer * slope_hidden_layer$$

or

$$\delta_{hidden} = \begin{bmatrix} 0.010 \times 0.151 & 0.009 \times 0.124 & 0.008 \times 0.188 \\ 0.010 \times 0.077 & 0.008 \times 0.115 & 0.074 \times 0.137 \\ -0.039 \times 0.151 & -0.033 \times 0.144 & -0.03 \times 0.170 \end{bmatrix} = \begin{bmatrix} 0.002 & 0.001 & 0.002 \\ 0.001 & 0.001 & 0.001 \\ -0.006 & -0.005 & -0.005 \end{bmatrix}$$

Step 10. The output layer weights are updated using the gradient descent rule:

$$W_out = W_out + matrix_dot_product(hidden_layer_activations.Transpose, d_output) * learning_rate$$

$$W_h = W_h + matrix_dot_product(X.Transpose, d_hidden_layer) * learning_rate$$

or

$$W_{out} = W_{out} + \eta \times (H_{out}^T \cdot \delta_{out})$$

$$W_h = W_h + \eta \times (X^T \times \delta_{hidden})$$

where η is learning rate. Using $\eta = 0.1$, the updated output weights become:

$$W_{out} = \begin{bmatrix} 0.30 \\ 0.25 \\ 0.23 \end{bmatrix} + 0.1 \times \begin{bmatrix} 0.815 & 0.855 & 0.750 \\ 0.916 & 0.868 & 0.836 \\ 0.815 & 0.825 & 0.782 \end{bmatrix}^T \times \begin{bmatrix} 0.035 \\ 0.032 \\ -0.13 \end{bmatrix} \approx \begin{bmatrix} 0.295 \\ 0.245 \\ 0.225 \end{bmatrix}$$

$$W_h = \begin{bmatrix} 0.42 & 0.88 & 0.55 \\ 0.10 & 0.73 & 0.68 \\ 0.60 & 0.18 & 0.47 \\ 0.92 & 0.11 & 0.52 \end{bmatrix} + 0.1 \times \begin{bmatrix} 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 1 \\ 0 & 1 & 0 & 1 \end{bmatrix}^T \times \begin{bmatrix} 0.002 & 0.001 & 0.002 \\ 0.001 & 0.001 & 0.001 \\ -0.006 & -0.005 & -0.005 \end{bmatrix}$$

$$\approx \begin{bmatrix} 0.42 & 0.88 & 0.55 \\ 0.10 & 0.73 & 0.68 \\ 0.60 & 0.18 & 0.47 \\ 0.92 & 0.11 & 0.52 \end{bmatrix}$$

Step 11. In this step, the biases associated with the hidden and output layers are updated using the computed deltas from the previous steps. The update rule follows the principle of gradient descent, where adjustments are made in the direction that minimizes the error function. The mathematical expressions for updating the biases are given by:

$$b_h = b_h + \text{sum}(d_hidden_layer, \text{axis} = 0) * \text{learning_rate}$$

$$b_out = b_out + \text{sum}(d_output, \text{axis} = 0) * \text{learning_rate}$$

or

$$b_h = b_h + \eta \times \sum_{j=0}^N \delta_{hidden_j}$$

$$b_{out} = b_{out} + \eta \times \sum_{j=0}^N \delta_{output_j}$$

Using $\eta = 0.1$, the updated output biases become:

$$b_h = [0.46 \quad 0.72 \quad 0.08] + 0.1 \times [0.002 + 0.001 - 0.006 \quad 0.001 + 0.001 - 0.005 \quad 0.002 + 0.001 - 0.005]$$

$$= [0.46 \quad 0.72 \quad 0.08] + 0.1 \times [-0.003 \quad -0.003 \quad -0.002]$$

$$= [0.4597 \quad 0.7197 \quad 0.0798]$$

$$b_{out} = [0.69] + 0.1 \times [0.035 + 0.032 - 0.13] = 0.6837$$

To validate the theoretical computations discussed above, we implement a Python-based simulation of a simple neural network. The following code executes forward propagation, backpropagation, and weight updates for a neural network with one hidden layer. It utilizes the sigmoid activation function and trains the model using gradient descent.

Python Implemaentation

```
import numpy as np
import matplotlib.pyplot as plt
def sigmoid(x):
    return 1 / (1 + np.exp(-x))
def sigmoid_derivative(x):
    return x * (1 - x)

#input features (3 samples, 4 features)
X = np.array([[1, 0, 1, 0],
              [1, 0, 1, 1],
              [0, 1, 0, 1]])

#target Labels
y = np.array([[1], [1], [0]])

#initialize weights and biases
np.random.seed(42) # Ensures reproducibility
W_h = np.random.rand(4, 3)
b_h = np.random.rand(1, 3)
W_out = np.random.rand(3, 1)
b_out = np.random.rand(1, 1)

#training parameters
epochs = 10000
learning_rate = 0.1
loss_history = [] # Stores Loss at each iteration

#training Loop
for epoch in range(epochs):
    #forward propagation
    H_in = np.dot(X, W_h) + b_h
    H_out = sigmoid(H_in)

    O_in = np.dot(H_out, W_out) + b_out
    O_out = sigmoid(O_in)

    #computing MSE
    error = y - O_out
    loss = np.mean(np.square(error))
    loss_history.append(loss) # Store Loss for visualization

    #backpropagation
    delta_out = error * sigmoid_derivative(O_out)
    W_out += learning_rate * np.dot(H_out.T, delta_out)
    b_out += learning_rate * np.sum(delta_out, axis=0, keepdims=True)

#final trained output
print("\nFinal Predicted Output After Training:\n", O_out)

#visualization of Loss reduction
plt.figure(figsize=(10, 5))
plt.plot(loss_history, label='Loss Reduction Over Iterations', color='blue')
plt.xlabel('Epochs')
plt.ylabel('Mean Squared Error (Loss)')
plt.title('Training Loss Over Time')
plt.legend()
plt.grid()
plt.show()
```

```

import numpy as np
import matplotlib.pyplot as plt
def sigmoid(x):
    return 1 / (1 + np.exp(-x))
def sigmoid_derivative(x):
    return x * (1 - x)

#input features (3 samples, 4 features)
X = np.array([[1, 0, 1, 0],
              [1, 0, 1, 1],
              [0, 1, 0, 1]])

#target Labels
y = np.array([[1], [1], [0]])

#initialize weights and biases
np.random.seed(42) # Ensures reproducibility
W_h = np.random.rand(4, 3)
b_h = np.random.rand(1, 3)
W_out = np.random.rand(3, 1)
b_out = np.random.rand(1, 1)

#training parameters
epochs = 10000
learning_rate = 0.1
loss_history = [] # Stores Loss at each iteration

#training Loop
for epoch in range(epochs):
    #forward propagation
    H_in = np.dot(X, W_h) + b_h
    H_out = sigmoid(H_in)

    O_in = np.dot(H_out, W_out) + b_out
    O_out = sigmoid(O_in)

    #computing MSE
    error = y - O_out
    loss = np.mean(np.square(error))
    loss_history.append(loss) # Store Loss for visualization

    #backpropagation
    delta_out = error * sigmoid_derivative(O_out)
    W_out += learning_rate * np.dot(H_out.T, delta_out)
    b_out += learning_rate * np.sum(delta_out, axis=0, keepdims=True)

#final trained output
print("\nFinal Predicted Output After Training:\n", O_out)

#visualization of Loss reduction
plt.figure(figsize=(10, 5))
plt.plot(loss_history, label='Loss Reduction Over Iterations', color='blue')
plt.xlabel('Epochs')
plt.ylabel('Mean Squared Error (Loss)')
plt.title('Training Loss Over Time')
plt.legend()
plt.grid()
plt.show()

```

After training for 10,000 epochs, the neural network achieved the following predicted outputs:

$$O_{out} = \begin{bmatrix} 0.9803 \\ 0.9684 \\ 0.0453 \end{bmatrix}$$

These values are close to the actual target values:

$$y = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix}$$

indicating that the neural network successfully learned the patterns in the data.

The plot below (see Figure 8) shows how the Mean Squared Error (MSE) loss decreases over time as the neural network learns.

At the beginning of training, the loss is high, meaning the network's predictions are far from the actual values. As the training progresses, the loss gradually decreases, showing that the model is improving. After a certain number of epochs, the loss becomes stable, indicating that the network has learned the patterns in the data and is no longer making significant improvements. Some small errors remain, which could be reduced by using more training data or fine-tuning the model's settings.




Fig. 8. Training Loss Reduction

In this section, we systematically derived and computed the backpropagation process for a neural network, focusing on error calculation, weight updates, and bias adjustments. Each computational step, from determining the error at the hidden layer to updating weights and biases, was illustrated with mathematical formulations and numerical computations. The results demonstrate how the backpropagation algorithm efficiently propagates error signals and adjusts model parameters, enabling the network to learn from data. These insights provide a clear understanding of how neural networks refine their internal representations to improve accuracy and performance.

Conclusion

In this study, we explored the mathematical foundations and computational implementation of neural networks as a tool for mathematical computation. We systematically derived the forward and backward propagation processes, illustrating each step with detailed mathematical formulations and numerical computations. Furthermore, a Python-based simulation was presented to validate the theoretical calculations, demonstrating how neural networks learn through iterative weight and bias updates.

The results indicate that the neural network successfully approximated the target values, with the predicted outputs converging close to the expected results. The decreasing loss function over multiple training iterations confirms that the model effectively minimizes error through gradient descent. This highlights the efficiency of backpropagation in optimizing network parameters and improving predictive accuracy.

This research demonstrates the practical application of neural networks in

solving mathematical problems and highlights their ability to generalize patterns from data. The study contributes to a deeper understanding of artificial neural networks by linking theoretical concepts with hands-on implementation.

REFERENCES

- Altaibek A., Zhumabayev B., Sarsembayeva A., Nurtas M. & Zakir D. (2025). Enhancing geomagnetic disturbance predictions with neural networks: A case study on K-index classification — *Atmosphere*. — 16(3). — P. 267. (DOI: 10.3390/atmos16030267).
- Du K.-L. & Swamy M.N.S. (2019). *Neural Networks and Statistical Learning*. 2nd ed. Upper Saddle River. — NJ: Prentice Hall. — P. 996 (Doi:10.1007/978-1-4471-7452-3).
- Goodfellow I., Bengio Y. & Courville A. (2016). *Deep Learning*. — Cambridge. — MA: MIT Press. — P.775
- Grossberg S. (1988). “Nonlinear neural networks: Principles, mechanisms, and architectures”. — *Neural Networks*. — 1988. — 1 (1). — Pp. 17–61. doi: 10.1016/0893-6080(88)90021-4.
- Haykin S. (2009). *Neural Networks and Learning Machines*. — 3rd ed. Upper Saddle River. — NJ. — USA: Pearson Education. — P. 938.
- Hebb D.O. (1949). *The organization of behavior*. — New York: Wiley. — P. 364.
- Huang G.-B., Westover M.B., Tan E.-K., Wang H., Cui D., Ma W.-Y., Wang T., He Q., Wei H., Wang N., Tian Q., Lam K.-Y., Yao X., Wong T.Y. (2024). Artificial Intelligence without Restriction Surpassing Human Intelligence with Probability One: Theoretical Insight into Secrets of the Brain with AI Twins of the Brain. — *Neurocomputing*. — 619. — P. 129053. (DOI:10.1016/j.neucom.2024.129053).
- Kandel E.R. et al. (2014). *Principles of Neural Science*. — 5th ed. New York — NY, USA: McGraw-Hill Education. — P.1760 (<https://accessbiomedicalsscience.mhmedical.com/content.aspx?bookid=1049§ionid=59138139>).
- Keller J.M., Liu D. & Fogel D.B. (2016). *Fundamentals of Computational Intelligence: Neural Networks, Fuzzy Systems, and Evolutionary Computation*. — Hoboken. — NJ, USA: Wiley. — P. 392.
- LeCun Y., Bengio Y. & Hinton G. (2015). Deep learning. — *Nature*. — 521(7553). — Pp. 436–444. (DOI: 10.1038/nature14539).
- Messeri L. & Crockett M.J. (2024). Artificial intelligence and illusions of understanding in scientific research. — *Nature*. — 627(8002). — Pp. 49–58.
- Minsky M. & Papert S. (1969). *Perceptrons: An Introduction to Computational Geometry*. — Cambridge. — MA: MIT Press — p. 316 (<https://rodsmith.nz/wp-content/uploads/Minsky-and-Papert-Perceptrons.pdf>).
- McCarthy J., Minsky M.L., Rochester N. & Shannon C.E. (1956). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. — 1956. — P.17 (<http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>).
- McCulloch W.S. & Pitts W. (1943). A logical calculus of the ideas immanent in nervous activity. — *Bulletin of Mathematical Biology*. — 5. — Pp. 115–133. (PII: S0092-8240(05)80006-0).
- Nurtas M., Baishemirov Z., Tsay V., Tastanov M. & Zhanabekov Z. (2020). Applying neural network for predicting cardiovascular disease risk. — *Известия НАН РК. Серия физико-математическая*. — 4. — Pp. 28–34. (DOI: 10.32014/2020.2518-1726.62).
- Silver D., Huang A., Maddison C.J. et al. (2016). Mastering the game of Go with deep neural networks and tree search. — *Nature*. — 529(7587). — Pp. 484–489. (DOI: 10.1038/nature16961).
- Soares F. M. & Souza A. M. F. (2016). *Neural Network Programming with Java*. — 2nd ed. Birmingham — UK: Packt Publishing. — P. 244.
- Thakur A. & Konde A. (2021). “Fundamentals of Neural Networks”. — *International Journal for Research in Applied Science & Engineering Technology*. — 2021. — 9(8). — Pp. 407–426. doi: 10.22214/ijraset.2021.37362.
- Turing A. M. (1950). Computing Machinery and Intelligence. — *Mind*, LIX(236) — pp. 433–460. (<https://doi.org/10.1093/mind/LIX.236.433>).
- Venkateswaran B. & Ciaburro G. (2017). *Neural Networks with R: Build Smart Systems by Implementing Popular Deep Learning Models in R*. — 1st ed. Birmingham. — UK: Packt Publishing. — P. 270.



**ХАЛЫҚАРАЛЫҚ АҚПАРАТТЫҚ ЖӘНЕ
КОММУНИКАЦИЯЛЫҚ ТЕХНОЛОГИЯЛАР ЖУРНАЛЫ**

**МЕЖДУНАРОДНЫЙ ЖУРНАЛ ИНФОРМАЦИОННЫХ И
КОММУНИКАЦИОННЫХ ТЕХНОЛОГИЙ**

**INTERNATIONAL JOURNAL OF INFORMATION AND
COMMUNICATION TECHNOLOGIES**

Правила оформления статьи для публикации в журнале на сайте:

<https://journal.iitu.edu.kz>

ISSN 2708–2032 (print)

ISSN 2708–2040 (online)

Собственник: АО «Международный университет
информационных технологий» (Казахстан, Алматы)

ОТВЕТСТВЕННЫЙ РЕДАКТОР
Мрзабаева Раушан Жалиқызы

НАУЧНЫЙ РЕДАКТОР
Ермакова Вера Александровна

ТЕХНИЧЕСКИЙ РЕДАКТОР
Рашидинов Дамир Рашидинович

КОМПЬЮТЕРНАЯ ВЕРСТКА
Асанова Жадыра

Подписано в печать 15.06.2025.

Формат 60x881/8. Бумага офсетная. Печать - ризограф. 9,0 п.л. Тираж 100
050040 г. Алматы, ул. Манаса 34/1, каб. 709, тел: +7 (727) 244-51-09).

Издание Международного университета информационных технологий
Издательский центр КБТУ, Алматы, ул. Толе би, 59