

ISSN 2518-1726 (Online),
ISSN 1991-346X (Print)

**ACADEMIC SCIENTIFIC
JOURNAL OF COMPUTER SCIENCE**

**№1
2026**

ISSN 2518-1726 (Online),
ISSN 1991-346X (Print)



CENTRAL ASIAN ACADEMIC
RESEARCH CENTER



**ACADEMIC SCIENTIFIC
JOURNAL OF COMPUTER
SCIENCE**

1 (357)

JANUARY – MARCH 2026

**PUBLISHED SINCE JANUARY 1963
PUBLISHED 4 TIMES A YEAR**

ALMATY, NAS RK

Chief Editor:

MUTANOV Galimkair Mutanovich, doctor of technical sciences, professor, academician of NAS RK, (Almaty, Kazakhstan), <https://www.scopus.com/authid/detail.uri?authorId=6506682964>, <https://www.webofscience.com/wos/author/record/1423665>

EDITORIAL BOARD:

KALIMOLDAYEV Maksat Nuradilovich, (Deputy Editor-in-Chief), Doctor of Physical and Mathematical Sciences, Professor, Academician of NAS RK, Advisor to the General Director of the Institute of Information and Computing Technologies of the CS MES RK, Head of the Laboratory (Almaty, Kazakhstan), <https://www.scopus.com/authid/detail.uri?authorId=56153126500>, <https://www.webofscience.com/wos/author/record/2428551>

MAMYRBAEV Orken Zhumazhanovich, (Academic Secretary), PhD in Information Systems, Deputy Director for Science of the Institute of Information and Computing Technologies CS MES RK (Almaty, Kazakhstan), <https://www.scopus.com/authid/detail.uri?authorId=55967630400>, <https://www.webofscience.com/wos/author/record/1774027>

BAIGUNCHEKOV Zhumadil Zhanabaevich, Doctor of Technical Sciences, Professor, Academician of NAS RK, Institute of Cybernetics and Information Technologies, Department of Applied Mechanics and Engineering Graphics, Satbayev University (Almaty, Kazakhstan), <https://www.scopus.com/authid/detail.uri?authorId=6506823633>, <https://www.webofscience.com/wos/author/record/1923423>

WOICIK Waldemar, Doctor of Technical Sciences (Phys.-Math.), Professor of the Lublin University of Technology (Lublin, Poland), <https://www.scopus.com/authid/detail.uri?authorId=7005121594>, <https://www.webofscience.com/wos/author/record/678586>

SMOLARJ Andrej, Associate Professor Faculty of Electronics, Lublin polytechnic university (Lublin, Poland), <https://www.scopus.com/authid/detail.uri?authorId=56249263000>, <https://www.webofscience.com/wos/author/record/1268523>

KEILAN Alimkhan, Doctor of Technical Sciences, Professor (Doctor of science (Japan)), chief researcher of Institute of Information and Computational Technologies CS MES RK (Almaty, Kazakhstan), <https://www.scopus.com/authid/detail.uri?authorId=8701101900>, <https://www.webofscience.com/wos/author/record/1436451>

KHAIROVA Nina, Doctor of Technical Sciences, Professor, Chief Researcher of the Institute of Information and Computational Technologies CS MES RK (Almaty, Kazakhstan), <https://www.scopus.com/authid/detail.uri?authorId=37461441200>, <https://www.webofscience.com/wos/author/record/1768515>

OTMAN Mohamed, PhD, Professor of Computer Science Department of Communication Technology and Networks, Putra University Malaysia (Selangor, Malaysia), <https://www.scopus.com/authid/detail.uri?authorId=56036884700>, <https://www.webofscience.com/wos/author/record/747649>

NYSANBAYEVA Saule Yerkebulanovna, Doctor of Technical Sciences, Associate Professor, Senior Researcher of the Institute of Information and Computing Technologies CS MES RK (Almaty, Kazakhstan), <https://www.scopus.com/authid/detail.uri?authorId=55453992600>, <https://www.webofscience.com/wos/author/record/3802041>

USATOVA Olga Alexandrovna, PhD, Associate Professor, Chief Scientific Secretary of the Institute of Information and Computing Technologies of the National Academy of Sciences of the Republic of Kazakhstan (Almaty, Kazakhstan), <https://www.scopus.com/authid/detail.uri?authorId=57204581062>, <https://www.webofscience.com/wos/author/record/JCO-3058-2023>

KAPALOVA Nursulu Aldazharovna, Candidate of Technical Sciences, Head of the Laboratory cybersecurity, Institute of Information and Computing Technologies CS MES RK (Almaty, Kazakhstan), <https://www.scopus.com/authid/detail.uri?authorId=57191242124>,

KOVALYOV Alexander Mikhailovich, Doctor of Physical and Mathematical Sciences, Academician of the National Academy of Sciences of Ukraine, Institute of Applied Mathematics and Mechanics (Donetsk, Ukraine), <https://www.scopus.com/authid/detail.uri?authorId=7202799321>, <https://www.webofscience.com/wos/author/record/38481396>

MIKHALEVICH Alexander Alexandrovich, Doctor of Technical Sciences, Professor, Academician of the National Academy of Sciences of Belarus (Minsk, Belarus), <https://www.scopus.com/authid/detail.uri?authorId=7004159952>, <https://www.webofscience.com/wos/author/record/46249977>

TIGHINEANU Ion Mihailovich, Doctor of Physical and Mathematical Sciences, Academician, President of the Academy of Sciences of Moldova, Technical University of Moldova (Chisinau, Moldova), <https://www.scopus.com/authid/detail.uri?authorId=7006315935>, <https://www.webofscience.com/wos/author/record/524462>

Academic Scientific Journal of Computer Science

ISSN 2518-1726 (Online),

ISSN 1991-346X (Print)

Owner: «Central Asian Academic Research Center» LLP (Almaty).

Certificate № **KZ77VPY00121154** on the re-registration of the periodical printed and online publication of the information agency, issued on **05.06.2025** by the Republican State Institution «Information Committee» of the Ministry of Culture and Information of the Republic of Kazakhstan

Subject area: *information and communication technologies*.

Currently: *included in the list of journals recommended by the CCSES MSHE RK in the direction of «Information and communication technologies».*

Periodicity: *4 times a year.*

<http://www.physico-mathematical.kz/index.php/en/>

© «Central Asian Academic Research Center» LLP, 2026

БАС РЕДАКТОР:

МУТАНОВ Ғалымқайыр Мұтанұлы, техника ғылымдарының докторы, профессор, ҚР ҰҒА академигі, (Алматы, Қазақстан), <https://www.scopus.com/authid/detail.uri?authorId=6506682964>, <https://www.webofscience.com/wos/author/record/1423665>

РЕДАКЦИЯ АЛҚАСЫ:

КАЛИМОЛДАЕВ Мақсат Нұрәділұлы, (бас редактордың орынбасары), физика-математика ғылымдарының докторы, профессор, ҚР ҰҒА академигі, ҚР ҒЖБМ ҒК «Ақпараттық және есептеу технологиялары институты» бас директорының кеңесшісі, зертхана меңгерушісі (Алматы, Қазақстан), <https://www.scopus.com/authid/detail.uri?authorId=56153126500>, <https://www.webofscience.com/wos/author/record/2428551>

МАМЫРБАЕВ Өркен Жұмажанұлы (ғалым хатшы), Ақпараттық жүйелер саласындағы техника ғылымдарының (PhD) докторы, ҚР ҒЖБМ ҒК «Ақпараттық және есептеу технологиялары институты» директорының ғылым жөніндегі орынбасары (Алматы, Қазақстан), <https://www.scopus.com/authid/detail.uri?authorId=55967630400>, <https://www.webofscience.com/wos/author/record/1774027>

БАЙГУНЧЕКОВ Жұмаділ Жаңабайұлы, техника ғылымдарының докторы, профессор, ҚР ҰҒА академигі, Кибернетика және ақпараттық технологиялар институты, Қолданбалы механика және инженерлік графика кафедрасы, Сәтбаев университеті (Алматы, Қазақстан), <https://www.scopus.com/authid/detail.uri?authorId=6506823633>, <https://www.webofscience.com/wos/author/record/1923423>

ВОЙЧИК Вальдемар, техника ғылымдарының докторы (физ-мат), Люблин технологиялық университетінің профессоры (Люблин, Польша), <https://www.scopus.com/authid/detail.uri?authorId=7005121594>, <https://www.webofscience.com/wos/author/record/678586>

СМОЛАРЖ Анджей, Люблин политехникалық университетінің электроника факультетінің доценті (Люблин, Польша), <https://www.scopus.com/authid/detail.uri?authorId=56249263000>, <https://www.webofscience.com/wos/author/record/1268523>

КЕЙЛАН Әлімхан, техника ғылымдарының докторы, профессор (ғылым докторы (Жапония)), ҚР ҒЖБМ ҒК «Ақпараттық және есептеу технологиялары институтының» бас ғылыми қызметкері (Алматы, Қазақстан), <https://www.scopus.com/authid/detail.uri?authorId=8701101900>, <https://www.webofscience.com/wos/author/record/1436451>

ХАЙРОВА Нина, техника ғылымдарының докторы, профессор, ҚР ҒЖБМ ҒК «Ақпараттық және есептеу технологиялары институтының» бас ғылыми қызметкері (Алматы, Қазақстан), <https://www.scopus.com/authid/detail.uri?authorId=37461441200>, <https://www.webofscience.com/wos/author/record/1768515>

ОТМАН Мохаммед, PhD, Информатика, Коммуникациялық технологиялар және желілер кафедрасының профессоры, Путра университеті Малайзия (Селангор, Малайзия), <https://www.scopus.com/authid/detail.uri?authorId=56036884700>, <https://www.webofscience.com/wos/author/record/747649>

НЫСАНБАЕВА Сауле Еркебұланқызы, техника ғылымдарының докторы, доцент, ҚР ҒЖБМ ҒК «Ақпараттық және есептеу технологиялары институтының» аға ғылыми қызметкері (Алматы, Қазақстан), <https://www.scopus.com/authid/detail.uri?authorId=55453992600>, <https://www.webofscience.com/wos/author/record/3802041>

УСАТОВА Ольга Александровна, PhD, қауымдастырылған профессор, ҚР ҒЖБМ "Ақпараттық және есептеу технологиялары институтының" бас ғалым хатшысы (Алматы, Қазақстан), <https://www.scopus.com/authid/detail.uri?authorId=57204581062>, <https://www.webofscience.com/wos/author/record/JCO-3058-2023>

КАПАЛОВА Нұрсұлу Алдажарқызы, техника ғылымдарының кандидаты, ҚР ҒЖБМ ҒК «Ақпараттық және есептеу технологиялары институты», Киберқауіпсіздік зертханасының меңгерушісі (Алматы, Қазақстан), <https://www.scopus.com/authid/detail.uri?authorId=57191242124>,

КОВАЛЕВ Александр Михайлович, физика-математика ғылымдарының докторы, Украина Ұлттық Ғылым академиясының академигі, Қолданбалы математика және механика институты (Донецк, Украина), <https://www.scopus.com/authid/detail.uri?authorId=7202799321>, <https://www.webofscience.com/wos/author/record/38481396>

МИХАЛЕВИЧ Александр Александрович, техника ғылымдарының докторы, профессор, Беларусь Ұлттық Ғылым академиясының академигі (Минск, Беларусь), <https://www.scopus.com/authid/detail.uri?authorId=7004159952>, <https://www.webofscience.com/wos/author/record/46249977>

ТИГИНЯНУ Ион Михайлович, физика-математика ғылымдарының докторы, академик, Молдова Ғылым Академиясының президенті, Молдова техникалық университеті (Кишинев, Молдова), <https://www.scopus.com/authid/detail.uri?authorId=7006315935>, <https://www.webofscience.com/wos/author/record/524462>

Academic Scientific Journal of Computer Science

ISSN 2518-1726 (Online),

ISSN 1991-346X (Print)

Меншіктеуші: «Орталық Азия академиялық ғылыми орталығы» ЖШС (Алматы).

Ақпарат агенттігінің мерзімді баспасөз басылымын, ақпарат агенттігін және желілік басылымды қайта есепке қою туралы ҚР Мәдениет және Ақпарат министрлігі «Ақпарат комитеті» Республикалық мемлекеттік мекемесі **05.06.2025** ж. берген № **KZ77VPY00121154** Куәлік.

Тақырыптық бағыты: *ақпараттық-коммуникациялық технологиялар*

Қазіргі уақытта: *«ақпараттық-коммуникациялық технологиялар» бағыты бойынша ҚР БҒМ БҒСБК ұсынған журналдар тізіміне енді.*

Мерзімділігі: *жылына 4 рет.*

<http://www.physico-mathematical.kz/index.php/en/>

© «Орталық Азия академиялық ғылыми орталығы» ЖШС, 2026

Главный редактор:

МУТАНОВ Галимканр Мутанович, доктор технических наук, профессор, академик НАН РК, (Алматы, Казахстан), <https://www.scopus.com/author/detail.uri?authorId=6506682964>, <https://www.webofscience.com/wos/author/record/1423665>

Редакционная коллегия:

КАЛИМОЛДАЕВ Максат Нурадилович, (заместитель главного редактора), доктор физико-математических наук, профессор, академик НАН РК, советник генерального директора «Института информационных и вычислительных технологий» КН МНВО РК, заведующий лабораторией (Алматы, Казахстан), <https://www.scopus.com/author/detail.uri?authorId=56153126500>, <https://www.webofscience.com/wos/author/record/2428551>

МАМЫРБАЕВ Оркен Жумажанович, (ученый секретарь), доктор философии (PhD) по специальности «Информационные системы», заместитель директора по науке РГП «Институт информационных и вычислительных технологий» Комитета науки МНВО РК (Алматы, Казахстан), <https://www.scopus.com/author/detail.uri?authorId=55967630400>, <https://www.webofscience.com/wos/author/record/1774027>

БАЙГУНЧЕКОВ Жумадил Жанабаевич, доктор технических наук, профессор, академик НАН РК, Институт кибернетики и информационных технологий, кафедра прикладной механики и инженерной графики, Университет Сагпаева (Алматы, Казахстан), <https://www.scopus.com/author/detail.uri?authorId=6506823633>, <https://www.webofscience.com/wos/author/record/1923423>

ВОЙЧИК Вальдемар, доктор технических наук (физ.-мат.), профессор Люблинского технологического университета (Люблин, Польша), <https://www.scopus.com/author/detail.uri?authorId=7005121594>, <https://www.webofscience.com/wos/author/record/678586>

СМОЛАРЖ Анджей, доцент факультета электроники Люблинского политехнического университета (Люблин, Польша), <https://www.scopus.com/author/detail.uri?authorId=56249263000>, <https://www.webofscience.com/wos/author/record/1268523>

КЕЙЛАН Алимхан, доктор технических наук, профессор (Doctor of science (Japan)), главный научный сотрудник РГП «Института информационных и вычислительных технологий» КН МНВО РК (Алматы, Казахстан), <https://www.scopus.com/author/detail.uri?authorId=8701101900>, <https://www.webofscience.com/wos/author/record/1436451>

ХАЙРОВА Нина, доктор технических наук, профессор, главный научный сотрудник РГП «Института информационных и вычислительных технологий» КН МНВО РК (Алматы, Казахстан), <https://www.scopus.com/author/detail.uri?authorId=37461441200>, <https://www.webofscience.com/wos/author/record/1768515>

ОТМАН Мохамед, доктор философии, профессор компьютерных наук, Департамент коммуникационных технологий и сетей, Университет Путра Малайзия (Селангор, Малайзия), <https://www.scopus.com/author/detail.uri?authorId=56036884700>, <https://www.webofscience.com/wos/author/record/747649>

НЫСАНБАЕВА Сауле Еркебулановна, доктор технических наук, доцент, старший научный сотрудник РГП «Института информационных и вычислительных технологий» КН МНВО РК (Алматы, Казахстан), <https://www.scopus.com/author/detail.uri?authorId=55453992600>, <https://www.webofscience.com/wos/author/record/3802041>

УСАТОВА Ольга Александровна, PhD, ассоциированный профессор, Главный ученый секретарь «Института информационных и вычислительных технологий» КН МНВО РК (Алматы, Казахстан), <https://www.scopus.com/author/detail.uri?authorId=57204581062>, <https://www.webofscience.com/wos/author/record/JCO-3058-2023>

КАПАЛОВА Нурсулу Алдажаровна, кандидат технических наук, заведующий лабораторией кибербезопасности РГП «Института информационных и вычислительных технологий» КН МНВО РК (Алматы, Казахстан), <https://www.scopus.com/author/detail.uri?authorId=57191242124>,

КОВАЛЕВ Александр Михайлович, доктор физико-математических наук, академик НАН Украины, Институт прикладной математики и механики (Донецк, Украина), <https://www.scopus.com/author/detail.uri?authorId=7202799321>, <https://www.webofscience.com/wos/author/record/38481396>

МИХАЛЕВИЧ Александр Александрович, доктор технических наук, профессор, академик НАН Беларуси (Минск, Беларусь), <https://www.scopus.com/author/detail.uri?authorId=7004159952>, <https://www.webofscience.com/wos/author/record/46249977>

ТИГИНЯНУ Ион Михайлович, доктор физико-математических наук, академик, президент Академии наук Молдовы, Технический университет Молдовы (Кишинев, Молдова), <https://www.scopus.com/author/detail.uri?authorId=7006315935>, <https://www.webofscience.com/wos/author/record/524462>

Academic Scientific Journal of Computer Science

ISSN 2518-1726 (Online),

ISSN 1991-346X (Print)

Собственник: *ТОО «Центрально-азиатский академический научный центр» (г. Алматы).*

Свидетельство о постановке на переучет периодического печатного издания, информационного агентства и сетевого издания № **KZ77VPU00121154**. Дата выдачи **05.06.2025**

Тематическая направленность: *информационно-коммуникационные технологии.*

В настоящее время: *вошел в список журналов, рекомендованных КОКШВО МНВО РК по направлению «информационно-коммуникационные технологии».*

Периодичность: *4 раза в год.*

<http://www.physico-mathematical.kz/index.php/en/>

© ТОО «Центрально-азиатский академический научный центр», 2026

CONTENTS

COMPUTER SCIENCE

Akhmetova S.T., Yunussova A.A., Alisheva S.S., Olzhataeva B.T., Mussirepova E.B. Social network data mining for automated offensive language detection.....	13
Amanov A.N., Kazbekova G.N., Zhunissov N.M., Abibullayeva A.A., Aben A.B. Artificial intelligence-based intrusion detection for DDOS attacks in Software Defined Networking.....	30
Amanzholova S.T., Ussatova O.A., Mutanov G.M., Mukhanov S.B., Aitmukash D. Backend architecture of a hybrid blockchain-based academic credential verification system.....	52
Amirkhanova G.A., Nurgazy T.N., Amirkhanov B.S., Tokhtassyn M.M., Nurgazy N.N. Developing a predictive digital twin for a food product based on Edge ML and IoT sensors.....	73
Bekarystankyzy A., Ussen D., Kassenkhan A., Chinibayev Y. Cold-start in educational recommender systems: classical and LLM-Era strategies.....	91
Bimoldina Zh., Mussiraliyeva Sh., Bagitova K., Tereikovska L. Detection of cyber-propaganda content using machine learning and semantic models....	106
Chezhimbayeva K.S. Forecasting key 5G network KPIs using MLP and LSTM neural network models.....	129
Dauitbayeva A.O., Konyrbaev N.B., Abildayeva Zh.T., Yessirkepova A.U., Karim N.A. Development of an application to optimize the process of employment of graduates.....	148
Dzhsupbekova G., Othman M., Ordabayeva G. Comparative analysis of artificial intelligence algorithms to detect network attacks.....	167
Issakhov A., Orazmoldayev N., Zharkynbek Y., Abylkassymova A. Numerical modeling of the spread of viral infection by airborne droplets in confined spaces.....	182
Kantureeva M., Omarova G.S., Duisen Z.D., Shekerbek A.A., Tulebayev Y.B. Application of machine learning methods in forecasting and optimizing the processes of evacuation of people in high-rise buildings.....	202
Khusain B., Telmanov M., Khusain A.B., Brodskiy A.R., Sass A.S. Digital twin of an integrated emission purification and decarbonization system for thermal units.....	218
Kulakayeva A., Ashurov A., Zhumazhanov B., Daineko Ye., Zylgara A. Algorithm for determining the initial orbital parameters of KazeEOSat-1 for deorbiting.....	236

Mimenbayeva A.B., Turebayeva R.D., Ospanova T.T., Aruova A.B., Naizagarayeva A.A. Development and comparative analysis of machine learning models for urban traffic prediction.....	253
Naumenko V.V., Mukanova Zh.A., Kiseleva O.V., Maintser D.A., Nerezov A.K. The use of real-time polling to improve student academic performance.....	271
Nazyrova A.E., Kaderkeyeva Z.K., Bekmanova G.T., Milosz M., Lamasheva Zh. Transformation of education through digital technologies: advancing student academic performance across learning stages.....	287
Oralbekova D., Mamyrbayev O., Akhmediyarova A., Kassymova D., Alibiyeva Z. Development of a multi-level model for text summarization based on pretrained models.....	316
Orazbayev B.B., Zhumadillayeva A.K., Kurbangalieva N.B., Yessirkessinov R.Zh., Orazbayeva K.N. Synthesis of linguistic models for assessing sulfur quality and fuzzy modeling of the sulfur production process.....	337
Sarsenbayeva A.K., Rakhimova D.R., Shormakova A.N., Mansurova M.E., Adali E. Application of semantic methods in the field of legislation: an intellectual system for analysis of agglutinative texts.....	354
Serek A., Shoiynbek A., Sharipov K., Kuanyshbay D., Mukhametzhano A. Analysis and classification of telephone fraud based on lexical features of speech transcriptions.....	373
Shynzhigit B.B., Balabekova M.O., Amangeldy T.T. Analysis and forecasting of brick product sales using machine learning models.....	393
Tokhayeva A.O., Alzhanov A.K., Nezh Önal, Ziyatbekova G.Z., Begalieva K.B. Formation of students virtualization competencies in higher education based on Proxmox VE.....	412
Tukenova L.M., Auyelbekov O.A., Sapakova S.Z., Sametova A.A., Bostanov E.L. Modelling and optimisation of hybrid power plant operating modes for unmanned aerial vehicles.....	430
Yerimbetova A., Berzhanova U., Daiyrbayeva E., Sakenov B., Sambetbayeva M. Sign language recognition using temporal convolutional network and MediaPipe.....	443
Zhukabayeva T.K., Benkhelifa E., Mardenov Y.M., Baumuratova D., Karabayev N. Decision support for responding to attacks in cyber-physical industrial internet-of-things systems.....	461

МАЗМҰНЫ

ИНФОРМАТИКА

Ахметова С.Т., Юнусова А.А., Алишева С.С., Олжатаева Б.Т., Мүсірепова Э.Б. Әлеуметтік желідегі бейәдеп пікірлерді автоматты анықтауда деректерді интеллектуалды талдау.....	13
Аманов А.Н., Казбекова Г.Н., Жунисов Н.М., Абибуллаева А.А., Абен А.Б. Бағдарламалық жасақтамамен анықталған желідегі DDOS шабуылдары үшін жасанды интеллектке негізделген шабуылдарды анықтау.....	30
Аманжолова С.Т., Усатова О.А., Мутанов Г.М., Муханов С.Б., Айтмукаш Д. Гибридтік блокчейнге негізделген академиялық сенімдік деректерді тексеру жүйесінің бекендік архитектурасы.....	52
Амирханова Г.А., Нұрғазы Т.Н., Амирханов Б.С., Нұрғазы Н. Н. EDGE ML және IOT сенсорлары негізінде азық-түлік өнімінің предиктивті цифрлық егізін әзірлеу.....	73
Бекарыстанқызы А., Үсен Д., Қасенхан А., Чинибаев Е. Білім беру саласындағы ұсынымдық жүйелеріндегі «Cold-start» мәселесі: классикалық әдістер және LLM дәуірінің стратегиялары.....	91
Бимолдина Ж.А., Мусиралиева Ш.Ж., Багитова К.Б., Терейковская Л.З Кибернасихаттық контентті анықтау үшін машиналық оқыту және семантикалық модельдер қолдану.....	106
Чечимбаева К.С. MLP және LSTM нейрондық желі модельдерін қолдана отырып, 5G желісінің негізгі KPI-лерін болжау.....	129
Дәуітбаева А.О., Қоңырбаев Н.Б., Әбілдаева Ж.Т., Есіркепова А.У., Кәрім Н.Ә. Бітіруші түлектердің жұмысқа орналастыру процесін оңтайландыру үшін қосымша әзірлеу.....	148
Джусупбекова Г., Othman M., Ордабаева Г. Жасанды интеллект алгоритмдерін желілік шабуылдарды анықтау үшін салыстырмалы талдау.....	167
Исахов А.А., Оразмолдаев Н., Жаркынбек Е., Абылкасымова А. Ауа тамшылары арқылы вирустық инфекцияның шектеулі кеңістікте таралуын сандық модельдеу.....	182
Қантурсева М.А., Омарова Г.С., Дүйсен Ж.Д., Шекербек А.Ә., Түлебаев Е.Б. Биік ғимараттардағы адамдарды эвакуациялау процестерін болжау және оңтайландыруда машиналық оқыту әдістерін қолдану.....	202

Хусаин Б., Тельманов М.М., Хусаин А.Б., Бродский А.Р., Сасс А.С. Жылу қондырғыларының шығарындыларын кешенді тазалау және декарбонизациялау жүйесінің цифрлық егізі.....	218
Кулакаева А.Е., Ашуров А.Е., Жумажанов Б.Р., Дайнеко Е.А., Зылғара А.Е. КАZEOSAT-1 ғарыш аппаратының деорбитациясын жүзеге асыру үшін бастапқы орбиталық параметрлерін анықтау алгоритмі.....	236
Мименбаева А.Б., Туребаева А.Д., Оспанова Т.Т., Аруова А.Б., Найзағарасва А.А. Қалалық көлік ағынын болжауға арналған машиналық оқыту модельдерін әзірлеу және салыстырмалы талдау.....	253
Науменко В.В., Муканова Ж.А., Киселева О.В., Майнцер Д.А., Нерезов А.К. Білім алушылардың үлгерімін арттыру үшін real-time сауалнамаларын қолдану.....	271
Назырова А.Е., Кадеркеева З.К., Бекманова Г.Т., Милош М., Ламашева Ж.Б. Цифрлық білім және студенттердің академиялық жетістіктері: деңгейлер бойынша білім беруді дамыту.....	287
Оралбекова Д., Мамырбаев О., Ахмедиярова А., Қасымова Д.З, Алибиева Ж., Алдын ала оқытылған модельдер негізінде мәтінді резюмелеуге арналған көпдеңгейлі модельді әзірлеу.....	316
Оразбаев Б.Б., Жумадиллаева А.К., Курбанғалиева Н.Б., Оразбаева К.Н. Күкірт сапасын бағалаудың лингвистикалық модельдерін синтездеу және күкіртті өндіру процесін бұлыңғыр модельдеу.....	337
Сарсенбаева А.К., Рахимова Д.Р., Шормакова А.Н., Мансурова М.Е., Адали Э. Семантикалық әдістерді заңнама саласында қолдану: агглютинативті мәтіндерді талдауға арналған интеллектуалды жүйе.....	354
Серек А., Шойынбек А., Шарипов К., Қуанышбай Д., Мухаметжанов А. Сөйлеу транскрипцияларының лексикалық белгілеріне негізделген телефон алаяқтықтарын талдау және жіктеу.....	373
Шынжігіт Б.Б., Балабекова М.О., Амангелді Т.Т. Кірпіш өнімдерін сату көлемдерін машиналық оқытуда талдау және болжамдау.....	393
Тохаева А.О., Альжанов А.К., Nezir Ö., Зиятбекова Г.З., Бегалиева К.Б. PROXMOX VE негізінде жоғары оқу орындарында білім алушыларды виртуалдандыру құзыреттерін қалыптастыру.....	412

Төкенова Л.М., Әуелбеков О.А., Сапақова С., Саметова А.А., Бостанов Е.Л.
Пилотсыз ұшу аппараттарына арналған гибриді электр станцияларының жұмыс режимдерін модельдеу және оңтайландыру.....430

Еримбетова А.С., Бержанова У.Г., Дайырбаева Э.Н., Сәкенов Б.Е., Самбетбаева М.А.
Уақытша конволюциялық желі мен media pipe көмегімен ым тілін тану.....443

Жукабаева Т.К., Бенхелифа Э., Марденов Е.М., Баумуратова Д., Карабаев Н.
Киберфизикалық өнеркәсіптік интернет заттары жүйелеріндегі шабуылдарға әрекет ету кезінде шешім қабылдауды қолдау.....461

СОДЕРЖАНИЕ

ИНФОРМАТИКА

Ахметова С.Т., Юнусова А.А., Алишева С.С., Олжатаева Б.Т., Мүсірепова Э.Б. Интеллектуальный анализ данных для автоматического выявления языка ненависти в социальных сетях.....	13
Аманов А.Н., Казбекова Г.Н., Жунисов Н.М., Абибуллаева А.А., Абен А.Б. Обнаружение вторжений на основе искусственного интеллекта для DDoS-атак в программно-определяемых сетях.....	30
Аманжолова С.Т., Усатова О.А., Мутанов Г.М., Муханов С.Б., Айтмукаш Д. Бэкенд-архитектура гибридной системы проверки академических достижений на основе блокчейна.....	52
Амирханова Г.А., Нургазы Т.Н., Амирханов Б.С., Нургазы Н.Н. Разработка предиктивного цифрового двойника пищевого продукта на основе Edge ML и IoT-сенсоров.....	73
Бекарыстанқызы А., Үсен Д., Қасенхан А., Чинибаев Е. Холодный старт в системах рекомендаций в области образования: классические подходы и стратегии эпохи LLM.....	91
Бимолдина Ж.А., Мусиралиева Ш.Ж., Багитова К.Б., Терейковская Л. Использование машинного обучения и семантических моделей для обнаружения киберпропагандистского контента.....	106
Чечимбаева К.С. Прогнозирование ключевых KPI сетей 5G на основе нейросетевых моделей MLP и LSTM.....	129
Даутбаева А.О., Конырбаев Н.Б., Абильдаева Ж.Т., Есиркепова А.У., Карим Н.А. Разработка приложения для оптимизации процесса трудоустройства выпускников.....	148
Джусупбекова Г., Othman M., Ордабаева Г. Сравнительный анализ алгоритмов искусственного интеллекта для обнаружения сетевых атак.....	167
Исахов А.А., Оразмолдаев Н., Жаркынбек Е., Абылкасымова А. Численное моделирование распространения вирусной инфекции воздушно-капельным путём в замкнутых помещениях.....	182

Кантуреева М.А., Омарова Г.С., Дүйсен Ж.Д., Шекербек А.Ә., Тулебаев Е.Б. Использование методов машинного обучения для прогнозирования и оптимизации процессов эвакуации людей в высотных зданиях.....	202
Хусаин Б., Тельманов М.М., Хусаин А.Б., Бродский А.Р., Сасс А.С. Цифровой двойник комплексной системы очистки и декарбонизации выбросов тепловых установок.....	218
Кулакаева А.Е., Ашуров А.Е., Жумажанов Б.Р., Дайнеко Е.А., Зылгара А.Е. Алгоритм определения начальных орбитальных параметров KazEOSat-1 для деорбитации.....	236
Мименбаева А.Б., Туребаева А.Д., Оспанова Т.Т., Аруова А.Б., Найзагараева А.А. Разработка и сравнительный анализ моделей машинного обучения для прогнозирования городского трафика.....	253
Науменко В.В., Муканова Ж.А., Киселёва О.В., Майнцер Д.А., Нерезов А.К. Применение опросов в режиме реального времени для повышения успеваемости обучающихся.....	271
Назырова А.Е., Кадеркеева З.К., Бекманова Г.Т., Милош М., Ламашева Ж.Б. Цифровое образование и академическая успеваемость учащихся: межуровневый анализ.....	287
Оралбекова Д., Мамырбаев О., Ахмедиярова А., Касымова Д., Алибиева Ж. Разработка многоуровневой модели для абстрактивного резюмирования текста на основе предварительно обученных моделей.....	316
Оразбаев Б.Б., Жумадиллаева А.К., Курбангалиева Н.Б., Есиркесинов Р.Ж., Оразбаева К.Н. Синтез лингвистических моделей оценки качества серы и нечёткое моделирование процесса её производства.....	337
Сарсенбаева А.К., Рахимова Д.Р., Шормакова А.Н., Мансурова М.Е., Адали Э. Применение семантических методов в юридическом анализе: интеллектуальная система для обработки агглютинативных текстов.....	354
Серек А., Шойынбек А., Шарипов К., Куанышбай Д., Мухаметжанов А. Анализ и классификация телефонного мошенничества на основе лексических признаков речевых транскрипций.....	373
Шынжігіт Б.Б., Балабекова М.О., Амангелді Т.Т. Анализ и прогнозирование объёмов продаж кирпичной продукции с использованием машинного обучения.....	393

Тохаева А.О., Альжанов А.К., Nezih Ö., Зиятбекова Г.З., Бегалиева К.Б. Формирование компетенций в области виртуализации у обучающихся в высшем образовании на основе платформы Proxmox VE.....	412
Тукенова Л.М., Ауелбеков О.А., Сапакова С.З., Саметова А.А., Бостанов Е.Л. Моделирование и оптимизация режимов работы гибридных силовых установок для беспилотных летательных аппаратов.....	430
Еримбетова А.С., Бержанова У.Г., Дайырбаева Э.Н., Сакенов Б.Е., Самбетбаева М.А. Распознавание языка жестов с использованием временных свёрточных сетей и MediaPipe4.....	43
Жукабаева Т.К., Бенхелифа Э., Марденов Е.М., Баумуратова Д., Карабаев Н. Поддержка принятия решений при реагировании на атаки в киберфизических промышленных системах интернета вещей.....	461

ACADEMIC SCIENTIFIC JOURNAL OF COMPUTER SCIENCE
ISSN 1991-346X
Volume 1.
Number 357 (2026). 129–147

<https://doi.org/10.32014/2026.2518-1726.405>

IRSTI: 49.33.31, 28.23.15
UDC 621.396.67:004.8

© **Chezhimbayeva K.S., 2026.**

G. Daukeev Almaty University of Energy and Communications,
Almaty, Kazakhstan.
E-mail: k.chezhimbayeva@aes.kz

FORECASTING KEY 5G NETWORK KPIS USING MLP AND LSTM NEURAL NETWORK MODELS

Chezhimbayeva Katipa — Professor of the Department of “Telecommunication Engineering” at the Almaty University of Power Engineering and Telecommunications named after Gumarbek Daukeyev, Almaty, Kazakhstan,
E-mail k.chezhimbayeva@aes.kz, <https://orcid.org/0000-0002-1661-2226>.

Abstract. Fifth-generation (5G) networks are rapidly developing to ensure reliable radio access and reduce the likelihood of abnormal connection disconnections (ABRs), which have become a key challenge for mobile operators in the Republic of Kazakhstan. Increasing base station density allows for increased traffic volumes and highly dynamic user loads, which complicate quality of service management processes and require the use of intelligent methods for analyzing operational data. This study examines the problem of predicting the likelihood of abnormal disconnections in 5G NR cells based on key performance indicators (KPIs) characterizing the state of the radio network. This study uses real-world statistical network performance indicators, including connection success rates, connection integrity parameters, average user throughput, and resource block utilization. Deep learning methods were used to build a predictive model, including a multilayer perceptron (MLP) and a Long Short-Term Memory (LSTM) recurrent neural network designed to process time series and identify hidden dependencies in data. The study also compared the accuracy of the models using RMSE, MAE, and R^2 metrics. The results demonstrated that neural network methods are highly capable of identifying nonlinear relationships between radio network parameters and the probability of abnormal disconnection, providing more accurate predictions than traditional approaches. This paper proposes a new approach for use in self-organizing networks (SON) and intelligent quality of service management systems to improve the resilience and operational efficiency of 5G networks.

Keywords: quality of service, abnormal disconnections, Abnormal Release Rate, deep learning, neural networks, time series forecasting, radio network optimization

For citations: Chezhimbayeva K.S. Forecasting key 5G network KPIs using mlp and LSTM neural network models. Academic Scientific Journal of Computer Science, 2026. — No.1. — P. 129–147. DOI: <https://doi.org/10.32014/2026.2518-1726.405>

© **Чезжимбаева К.С., 2026.**

Ғ. Дәукеев атындағы Алматы энергетика және байланыс университеті,
Алматы, Қазақстан.
E-mail: k.chezhimbayeva@aes.kz

MLP ЖӘНЕ LSTM НЕЙРОНДЫҚ ЖЕЛІ МОДЕЛЬДЕРІН ҚОЛДАНА ОТЫРЫП, 5G ЖЕЛІСІНІҢ НЕГІЗГІ КРІ-ЛЕРІН БОЛЖАУ

Чезжимбаева Катипа — Телекоммуникациялық инженерия кафедрасының профессоры, Ғұмарбек Даукеев атындағы Алматы энергетика және байланыс университеті, Алматы, Қазақстан,
E-mail k.chezhimbayeva@aes.kz, <https://orcid.org/0000-0002-1661-2226>.

Аннотация. Бесінші буын (5G) желілері сенімді радио қолжетімділікті қамтамасыз ету және Қазақстан Республикасындағы ұялы байланыс операторлары үшін негізгі қиындыққа айналған қалыптан тыс қосылыс үзілістерінің (ABR) ықтималдығын азайту үшін қарқынды дамып келеді. Базалық станция тығыздығының артуы трафик көлемінің және пайдаланушылардың жоғары динамикалық жүктемесінің артуына мүмкіндік береді, бұл қызмет көрсету сапасын басқару процестерін қиындатады және операциялық деректерді талдау үшін интеллектуалды әдістерді қолдануды талап етеді. Бұл зерттеу радио желісінің күйін сипаттайтын негізгі өнімділік көрсеткіштеріне (KPI) негізделген 5G NR ұяшықтарындағы қалыптан тыс ажыратылулардың ықтималдығын болжау мәселесін зерттейді. Бұл зерттеуде қосылымның сәттілік көрсеткіштері, қосылым тұтастығы параметрлері, пайдаланушының орташа өткізу қабілеті және ресурстар блогын пайдалану сияқты нақты әлемдегі желінің статистикалық өнімділік көрсеткіштері қолданылады. Уақыт қатарларын өңдеуге және деректердегі жасырын тәуелділіктерді анықтауға арналған көп қабатты перцептронды (MLP) және ұзақ қысқа мерзімді жақты (LSTM) қайталанатын нейрондық желіні қамтитын болжамдық модельді құру үшін терең оқыту әдістері қолданылды. Зерттеуде сонымен қатар RMSE, MAE және R² метрикаларын қолдана отырып, модельдердің дәлдігі салыстырылды. Нәтижелер нейрондық желі әдістерінің радиожелі параметрлері мен қалыптан тыс ажыратылу ықтималдығы арасындағы сызықтық емес байланыстарды анықтауға жоғары қабілетті екенін көрсетті, бұл дәстүрлі тәсілдерге қарағанда дәлірек болжамдарды

қамтамасыз етеді. Бұл мақалада 5G желілерінің тұрақтылығы мен жұмыс тиімділігін арттыру үшін өзін-өзі ұйымдастыратын желілерде (SON) және қызмет көрсету сапасын басқарудың интеллектуалды жүйелерінде қолдануға арналған жаңа тәсіл ұсынылады.

Түйін сөздер: қызмет көрсету сапасы; қалыптан тыс ажыратылулар; қалыптан тыс босату жылдамдығы; терең оқыту; нейрондық желілер; уақыт қатарларын болжау; радиожелісін оңтайландыру

© **Чезимбаева К.С., 2026.**

Алматинский университет энергетики и связи им. Г. Даукеева,

Алматы, Казахстан.

E-mail: k.chezhibayeva@aes.kz

ПРОГНОЗИРОВАНИЕ КЛЮЧЕВЫХ KPI СЕТЕЙ 5G НА ОСНОВЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ MLP И LSTM

Чезимбаева Катипа Сламбаевна — профессор кафедры «Телекоммуникационной инженерии» Алматинского Университета энергетики и связи имени Г. Даукеева, Алматы, Казахстан,

E-mail: k.chezhibayeva@aes.kz, <https://orcid.org/0000-0002-1661-2226>.

Аннотация. В настоящее время наблюдается стремительное развитие сетей пятого поколения (5G), что требует обеспечения высокой надёжности радиодоступа и снижения вероятности аномальных разъединений соединений (Abnormal Release Rate), являющихся одним из ключевых показателей качества работы сетей мобильной связи в Республике Казахстан. Увеличение плотности базовых станций, рост объёма передаваемого трафика и высокая динамичность пользовательской нагрузки приводят к усложнению процессов управления качеством обслуживания, что обуславливает необходимость применения интеллектуальных методов анализа эксплуатационных данных. В исследовании рассматривается задача прогнозирования вероятности аномальных разъединений в сотах 5G NR на основе ключевых эксплуатационных показателей (KPI), характеризующих состояние радиосети. В качестве исходных данных использованы реальные статистические показатели функционирования сети, включая успешность процедур подключения, параметры целостности соединений, среднюю пользовательскую пропускную способность и уровень загрузки ресурсных блоков. Для построения предиктивных моделей применены методы глубокого обучения, в том числе многослойный перцептрон (MLP) и рекуррентная нейронная сеть Long Short-Term Memory (LSTM), предназначенная для обработки временных рядов и выявления скрытых зависимостей в данных. Проведено сравнительное исследование точности моделей с использованием метрик RMSE, MAE и коэффициента детерминации R^2 . Результаты показали, что нейросетевые методы обладают высокой способностью выявлять

нелинейные взаимосвязи между параметрами радиосети и вероятностью аномальных разъединений, обеспечивая более точное прогнозирование по сравнению с традиционными подходами. В работе предложен подход, который может быть использован в системах самоорганизующихся сетей (SON) и интеллектуального управления качеством обслуживания для повышения устойчивости и эффективности функционирования сетей 5G.

Ключевые слова: качество обслуживания; аномальные разъединения; Abnormal Release Rate; глубокое обучение; нейронные сети; прогнозирование временных рядов; оптимизация радиосети

Введение. По мере развития сетей пятого поколения (5G) растет потребность в повышении надежности радиоинтерфейса, улучшении качества предоставляемых услуг и обеспечении бесперебойности сетевых соединений. Архитектура 5G NR создана для поддержки разнообразных сценариев использования, от обеспечения высокоскоростного мобильного доступа (eMBB) до критически важных приложений с минимальной задержкой (URLLC). В таких условиях стабильность соединения становится определяющим параметром, влияющим на эффективность работы сети и удовлетворенность пользователей. Для измерения надежности радиосети одним из важнейших эксплуатационных показателей является частота аномальных разъединений (Abnormal Release Rate, ARR), которая показывает, как часто сеансы передачи завершаются нештатно.

Сетевой трафик становится все более плотным, радиочастотный спектр – все более запутанным, а зоны покрытия – все более обширными. В сочетании с растущей нагрузкой на сеть, это делает традиционные методы анализа сетевых показателей, похожие на простые линейки и чек-листы, устаревшими. Они не могут уловить тонкие, нелинейные взаимосвязи между различными элементами сети и не реагируют на постоянные колебания трафика и качества радиосигнала. В итоге, сеть становится «слепой» к надвигающимся проблемам, что затрудняет своевременное реагирование и предотвращение сбоев.

Методы машинного и глубокого обучения активно развиваются в последние годы, предлагая мощные инструменты для анализа временных рядов, обнаружения сложных закономерностей и создания эффективных прогностических моделей. В частности, применение нейронных сетей для анализа KPI открывает путь к более автоматизированному управлению радиосетями и формированию основы для интеллектуальных самоорганизующихся сетей (SON), что является неотъемлемой частью сетей нового поколения (5G/6G). Среди них особенно выделяются модели глубокого обучения, такие как многослойные перцептроны (MLP) и рекуррентные нейронные сети LSTM, благодаря их уникальной способности учитывать временные зависимости и нелинейные факторы.

Актуальность работы продиктована потребностью в более надёжных и

стабильных сетях 5G. Внедрение предиктивного анализа для прогнозирования аномальных разъединений позволяет автоматически предотвращать снижение качества связи и оптимизировать сеть. Это критически важно для URLLC

Научная новизна исследования заключается в разработке передовой многофакторной нейросетевой модели, предназначенной для прогнозирования вероятности аномальных разъединений в сетях 5G на основе анализа реальных эксплуатационных данных. Впервые проводится комплексное сравнение двух ключевых архитектур глубокого обучения – MLP и LSTM – для определения наиболее эффективного подхода к анализу KPI, обладающих выраженной временной структурой. Кроме того, предлагается инновационный метод интеграции множества эксплуатационных показателей (таких как успешность процедур подключения, пропускная способность, загрузка ресурсных блоков) в единую прогностическую модель, предназначенную для применения в системах самоорганизующихся сетей (SON). Таким образом, данное исследование направлено на создание интеллектуальной модели прогнозирования аномальных разъединений, способной эффективно использовать реальные KPI радиосети 5G, учитывать нелинейные зависимости и временные эффекты, что в конечном итоге повышает устойчивость и управляемость сетевой инфраструктуры. Результаты работы предоставляют операторам связи мощный инструмент для автоматизации мониторинга состояния сети, предотвращения отказов и повышения качества обслуживания абонентов.

Мы хотим создать и изучить специальные компьютерные программы (нейросети), которые смогут предсказывать, когда в сетях 5G могут произойти сбои в связи. Мы также проверим, насколько хорошо эти программы работают на настоящих данных от оператора связи. Раньше для анализа и предсказания работы мобильных сетей использовали простые статистические методы. Но сейчас сети стали намного сложнее и постоянно меняются, поэтому эти старые методы уже не так хорошо работают. Они не могут разобраться в большом количестве разных данных и не всегда показывают, как ухудшается качество связи, когда много людей пользуются сетью или когда нагрузка на нее меняется.

Переход к применению методов машинного обучения стал важным этапом в развитии аналитики KPI мобильных сетей. В работе (Awofolaju et al., 2023) показано, что использование искусственных нейронных сетей позволяет существенно повысить точность прогнозирования ключевых показателей операторской сети по сравнению с традиционными методами. Авторы продемонстрировали способность многослойных нейросетевых моделей эффективно аппроксимировать нелинейные зависимости в эксплуатационных данных и адаптироваться к изменениям условий функционирования сети.

Литературный обзор. С развитием сетей 5G и переходом к архитектурам Standalone (SA) внимание исследователей сместилось в сторону более сложных моделей глубокого обучения. Так, в работе (Nurakhov et al., 2025) предложен

подход к анализу ключевых факторов, влияющих на производительность 5G SA сетей, на основе методов машинного обучения. Полученные результаты подтвердили высокую информативность KPI-данных и их пригодность для построения предиктивных моделей качества сети.

Значительный интерес представляют исследования, направленные на прогнозирование временных характеристик сети, таких как задержка, трафик и пропускная способность. В работе (Stojčić et al., 2023) предложена модель прогнозирования задержки в LTE-сетях с использованием методов снижения размерности признакового пространства, что позволило повысить точность прогнозов и сократить вычислительные затраты. Аналогичные задачи рассматриваются в исследованиях (Liu et al., 2025), где предложена архитектура прогнозирования трафика с динамическим управлением компонентами модели.

Особое место в современных исследованиях занимают рекуррентные нейросетевые архитектуры. Модели на основе LSTM и их гибридные варианты демонстрируют высокую эффективность при анализе временных рядов KPI благодаря способности учитывать долгосрочные временные зависимости. Данные подходы успешно применяются для прогнозирования сетевой нагрузки, пропускной способности и задержек в мобильных сетях (Almeida et al., 2024; Yuliana et al., 2024).

Параллельно развивается направление, связанное с обнаружением аномалий в телекоммуникационных сетях. Методы на основе автоэнкодеров и их модификаций активно используются для выявления аномальных состояний, связанных с деградацией качества обслуживания и отказами элементов сети. Работы Wang et al. (2021) и Wu et al., (2018) демонстрируют эффективность регрессионных и генеративных моделей для автоматического обнаружения отклонений в KPI. Более современные исследования применяют глубокие автоэнкодеры и трансформер-архитектуры, позволяющие выявлять сложные и слабовыраженные аномалии в сетях 5G (Arun Prasad et al., 2025; Kim and Thulasiraman, 2024; Khan et al., 2020).

Дополнительное внимание уделяется задачам прогнозирования пропускной способности и загрузки радиоресурсов. В работах Al-Thaedan et al. (2024) и Yuliana et al. (2024) показано, что модели машинного обучения позволяют эффективно оценивать будущую загрузку сети и пропускную способность базовых станций, что имеет прямую связь с вероятностью аномальных разъединений и ухудшением QoS.

Современные тенденции также включают разработку распределённых и федеративных методов анализа KPI. Обзор Nassef et al. (2022) подчёркивает перспективность распределённого машинного обучения для сетей 5G и последующих поколений, особенно в контексте снижения нагрузки на центральные узлы сети. В этом направлении Reis et al. (2025) предложил федеративный фреймворк Edge-FLGuard+, предназначенный для обнаружения аномалий в 5G-IoT средах с минимальными затратами сетевых ресурсов.

Наконец, альтернативные интеллектуальные подходы, такие как экспертные системы на основе нечёткой логики, также находят применение в задачах прогнозирования QoS. В работе *Чежимбаева и др. (2025)* показано, что гибридные экспертные системы могут эффективно дополнять нейросетевые модели при анализе показателей качества обслуживания в сетях 5G.

Таким образом, анализ существующих исследований показывает, что методы глубокого обучения и машинного интеллекта являются наиболее перспективным инструментом для прогнозирования и анализа KPI современных мобильных сетей. Несмотря на значительный прогресс, остаётся актуальной задача построения устойчивых и интерпретируемых моделей, способных эффективно работать в условиях высокой динамики и многомерности данных сетей 5G.

Таким образом, анализ литературы показывает:

1. Глубокое обучение широко применяется в анализе KPI 5G;
2. LSTM-модели особенно эффективны для прогнозирования параметров, обладающих временной структурой;
3. Автоэнкодеры и гибридные архитектуры высокого уровня демонстрируют лучшие результаты при обнаружении аномалий;
4. Проблема прогнозирования вероятности аномальных разъединений ARR на основе многофакторных KPI остается недостаточно исследованной, и в литературе отсутствуют комплексные модели, учитывающие одновременно параметры успешности подключения, пропускной способности и загрузки ресурса.

Эти результаты подтверждают актуальность разработки многофакторных нейросетевых моделей глубокого обучения для предиктивного анализа вероятности аномальных разъединений в сетях 5G.

Материалы и методология исследования

Исследование основано на анализе эксплуатационных данных сети 5G, собранных с реальных базовых станций оператора связи. Данные представлены в виде временного ряда с дискретизацией по часу и содержат набор ключевых показателей качества (KPI), характеризующих работу нескольких сот NR. Каждый временной шаг описывает состояние конкретной соты в определённый момент времени и может интерпретироваться как «снимок» её функционирования. Это позволяет рассматривать задачу как многофакторное прогнозирование во временной области.

1. Структура и содержание исходных данных

Основной массив данных сформирован в формате таблицы, где каждая строка соответствует одной соте и одному часовому интервалу.

В качестве материалов исследования использованы реальные эксплуатационные данные сети 5G, содержащие ключевые показатели эффективности (KPI) функционирования радиодоступа. Набор данных включает агрегированные почасовые измерения для нескольких сот NR, каждая из которых характеризуется следующими параметрами:

- Time - временная метка наблюдений;
- Cell Name - идентификатор соты NR;
- NR Cell ID - цифровой идентификатор соты;
- Integrity (%) - показатель целостности сигналов;
- SgNB Addition Success Rate (%) - успешность процедуры добавления вторичной соты в EN-DC;
- Service Setup Success Rate (%) - успешность установления сервисных соединений;
- Abnormal Release Rate (%) - целевой KPI, отражающий вероятность аномального разъединения;
- User Downlink Throughput (Mbps) - средняя пользовательская пропускная способность;
- Downlink RB Utilization (%) - степень загрузки физического ресурса (PRB).

Данные включают пропуски, шумы и единичные выбросы, что характерно для практических измерений в телекоммуникационных сетях.

Таблица 1 - Массив данных

Time	Cell Name	NR Cell ID	Integrity	SgNB SR	Setup SR	ARR (%)	Throughput (Mbps)	RB Util (%)
2025-02-25 00:00	C3600N2	303	100	100	100		166.88	2.64
2025-02-25 00:00	C3600N1	302	100	100	100		83.77	2.20
2025-02-25 00:00	C0700N1	300	100	35.64	30.59	83.27	11.07	7.80
2025-02-25 00:00	A3600N2	103	100	100	100	4.16	557.05	1.30
2025-02-25 01:00	C3600N2	303	100	100	100		222.45	1.21
2025-02-25 01:00	C0700N1	300	100	45.93	42.59	70.21	9.15	5.08

Данный фрагмент отражает характерную неоднородность KPI: ряд сот демонстрирует стабильное состояние (ARR=0%), в то время как другие имеют значительные отклонения (ARR>70%). Это подтверждает необходимость применения методов глубокого анализа.

Даже на небольшом фрагменте данных уже заметны принципиально разные режимы работы. Например, для сот C3600N2 в 00:00 и 01:00 наблюдаются высокие значения пропускной способности (166–222 Мбит/с) при нулевом значении Abnormal Release Rate, что соответствует стабильной работе. В то же время сота C0700N1 при тех же временных метках демонстрирует крайне высокие значения ARR (70–83%), одновременно с пониженной успешностью сервисной установки. Такая неоднородность поведения сот показывает, что между KPI существует нелинейная и далеко не очевидная взаимосвязь, что и оправдывает применение методов глубокого обучения.

2. Подготовка данных и предварительная обработка

Поскольку исходные данные представляют собой эксплуатационный лог, для их использования в модели требовалась предварительная очистка и приведение к численному виду. В первую очередь все временные метки были

преобразованы в тип `datetime`, что позволило упорядочить наблюдения во времени и формировать временные окна для LSTM-модели.

Следующим шагом стало приведение текстовых и процентных полей к числовому формату. Показатель *Integrity* зачастую хранится в виде строк «100%», «99%» и т.п., поэтому данный столбец был очищен от символов «%» и конвертирован в числовой вид. Аналогичным образом были обработаны и другие проценты, если они были представлены нечисленно.

Отдельное внимание уделялось выбросам. Сеть 5G — живая система, и в процессе эксплуатации могут возникать единичные аномалии измерений (ошибки оборудования, некорректные отчёты, кратковременные сбои), не отражающие устойчивое состояние системы. Для их выявления использовался стандартный механизм `isoutlier`, основанный на межквартильном размахе. Наблюдения, отмеченные как выбросы, временно заменялись значением `NaN`. Это решение было выбрано осознанно: такие точки не должны напрямую участвовать в обучении, но при этом их присутствие компенсируется процедурами восстановления пропусков.

Поскольку данные измеряются в реальной сети, отсутствие измерений в отдельных часах неизбежно. Для борьбы с пропусками использовалась двухэтапная схема:

1. **Линейная интерполяция** внутри временного ряда:

$$x_{interp}(t) = x(t_1) + \frac{x(t_2) - x(t_1)}{t_2 - t_1} \cdot (t - t_1), \quad t_1 < t < t_2. \quad (1)$$

Она корректно восстанавливает значения KPI, если пропуски локальны и поведение ряда не меняется резко.

2. **Метод ближайшего соседа** для граничных значений (начала и конца ряда), когда с одной стороны опорных точек просто нет. В этом случае логично считать, что ближайшее известное состояние является лучшей аппроксимацией неизвестного.

После очистки и восстановления все числовые признаки были приведены к единому масштабу с помощью нормализации по схеме `min-max`:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}, \quad (2)$$

что предотвратило доминирование признаков с большим диапазоном (например, пропускной способности) над менее вариативными (процентами успешности).

3. Формирование признаков и целевой переменной

Центральным объектом прогноза в данном исследовании является показатель *Abnormal Release Rate (%)*, описывающий долю аномальных разъединений. В этом контексте модель должна, по сути, отвечать на вопрос: «Какова вероятность того, что в следующем временном интервале *cost*

будет иметь высокую долю аномальных разъединений при заданных текущих условиях?»

Для реализации были сформированы два уровня представления данных:

1) Многофакторный «статический» вектор признаков для MLP.

Каждое наблюдение описывается вектором:

$$x(t) = [CellID(t), Integrity(t), SgNB_{SR(t)}, Setup_{SR(t)}, Throughput(t), RB_Util(t)] \quad (3)$$

Целевая переменная:

$$y(t) = ARR(t). \quad (4)$$

В таком представлении модель пытается уловить мгновенную зависимость между состоянием сети и вероятностью аномального разъединения.

2) Временная последовательность для LSTM.

Здесь в качестве входа используется история развития показателя ARR (по желанию, вместе с другими KPI):

$$X_t = [y(t - L), y(t - L + 1), \dots, y(t - 1)], \quad (5)$$

и задача состоит в оценке:

$$\hat{y}(t) \approx ARR(t), \quad (6)$$

где L - длина временного окна (например, 10 часов). Такой подход позволяет модели «помнить» предыдущее состояние соты и выявлять тенденции: растёт ли ARR, стабилен или имеет эпизодические всплески.

Заметим, что для сот вроде **C0700N1**, где несколько подряд идущих часов характеризуются высоким ARR, именно временной контекст оказывается критичен. LSTM в этом случае обучается связывать устойчиво высокую нагрузку, низкие уровни успешности процедур setup и последовательное ухудшение показателя ARR.

3. Нейросетевые модели и архитектуры

Выбор методов глубокого обучения в исследовании обусловлен характером задачи: с одной стороны, присутствуют явно нелинейные зависимости между показателями, с другой — эти зависимости динамически развиваются во времени. Поэтому были использованы две взаимодополняющие архитектуры: **многослойный перцептрон (MLP)** и **рекуррентная LSTM-сеть**.

Многослойный перцептрон (MLP) рассматривает каждое наблюдение как точку в многомерном пространстве признаков. В базовой конфигурации использовались:

- входной слой с числом нейронов, равным числу признаков (6 - 8 в зависимости от включения дополнительных KPI);
- два скрытых слоя по 20 нейронов с функцией активации ReLU;
- один выходной нейрон, формирующий прогноз ARR;
- алгоритм оптимизации – Levenberg - Marquardt, ориентированный на быстрое решение задач регрессии средних размеров.

MLP хорошо подходит для анализа «срезов» сети: например, для ответа на вопрос, как изменится ARR при фиксированной нагрузке и изменении успешности процедур установления соединений.

LSTM-модель, в свою очередь, была ориентирована на временной аспект. Её структура включает:

- входной слой `sequenceInputLayer`, принимающий последовательности значений (нормализованный ARR, по желанию — векторизованный KPI);
- один LSTM-слой (50–100 единиц состояния), который учится отслеживать долговременные зависимости;
- полносвязный слой и регрессионный выход.

Обучение велось с использованием оптимизатора Adam, функция потерь - среднеквадратичная ошибка (MSE). Такой выбор позволяет сети постепенно «подстраиваться» под динамику сети, избегая слишком резких изменений параметров на каждой итерации.

Важно подчеркнуть, что MLP и LSTM решают одну и ту же задачу - прогноз $ARR(t)$, но делают это с разных позиций: MLP - как регрессионный аппроксиматор в пространстве признаков, LSTM - как модель временной эволюции показателя.

4. Схема обучения и оценка качества моделей

Обучение моделей проводилось по единой схеме: данные сортировались по времени, и затем делились на обучающую и тестовую части в пропорции примерно 70/30. Такой подход имитирует реальный сценарий: модель обучается на исторических данных и затем проверяется на более позднем периоде, который она «не видела».

Для количественной оценки качества прогноза использовались три стандартные метрики регрессии:

- **RMSE** (корень среднеквадратичной ошибки):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (7)$$

- **MAE** (средняя абсолютная ошибка):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (8)$$

- **коэффициент детерминации R^2 :**

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \quad (9)$$

Интерпретация проста: чем меньше RMSE и MAE - тем выше точность; чем ближе R^2 к 1 - тем лучше модель объясняет вариацию целевого показателя. В контексте телекоммуникаций значимым является не только абсолютное значение ошибки, но и способность модели «реагировать» на рост ARR. Например, если ARR возрастает с 5% до 20%, важно, чтобы модель также показала заметный рост, даже если точное значение будет отличаться на доли процента.

5. Результаты

На рисунке 1 представлено сравнение **фактических значений ключевого показателя качества (KPI) сети 5G и прогнозных значений**, полученных с использованием нейросетевой модели, на тестовом временном интервале. По оси абсцисс отложено время наблюдений, охватывающее период с 1 по 4 марта, а по оси ординат - значение KPI, выраженное в процентах.




Рисунок 1 – Сравнение фактических и прогнозируемых значений KPI сети 5G на тестовом интервале

Фактические значения KPI обозначены синими маркерами и демонстрируют выраженную нестационарность временного ряда, что характерно для эксплуатационных данных телекоммуникационных сетей. Наблюдаются как относительно стабильные интервалы с низкими значениями показателя, так и резкие локальные всплески, достигающие значений порядка 15-17%. Подобные скачки отражают периоды ухудшения качества соединений и повышенной вероятности аномальных событий в сети.

Прогнозные значения, отображённые красными маркерами, в целом следуют за динамикой фактического ряда, корректно воспроизводя основные тренды и кратковременные изменения KPI. Нейросетевая модель адекватно

улавливает как фазы стабильной работы сети, так и периоды повышения показателя, что свидетельствует о её способности учитывать временную структуру данных.

При этом вблизи экстремальных пиков наблюдается некоторое сглаживание прогноза, что типично для моделей, ориентированных на минимизацию среднеквадратичной ошибки. Несмотря на это, прогноз сохраняет общую форму временного ряда и не демонстрирует существенных систематических отклонений.

Полученные результаты подтверждают, что применяемая нейросетевая модель обеспечивает достаточную точность прогнозирования КРП на тестовом интервале и может быть использована для анализа динамики состояния сети 5G, а также для раннего выявления потенциальных деградаций качества обслуживания.

На рисунке 2 представлены основные этапы обработки временного ряда ключевого показателя качества (КРП) сети 5G, включающие исходные данные, очищенные данные и сглаженный ряд, полученный с использованием нейросетевого подхода. Все три графика построены для одного и того же временного интервала, что позволяет наглядно сравнить влияние каждого этапа обработки на структуру сигнала.



Рисунок 2 – Этапы предварительной обработки и сглаживания временного ряда КРП сети 5G

Этапы предварительной обработки временного ряда КРП, представленные на рисунке 2, оказывают существенное влияние на показатели качества прогнозирования, выраженные метриками RMSE, MAE и коэффициентом детерминации R^2 . Сырые данные характеризуются высокой зашумлённостью и наличием выбросов, что приводит к увеличению RMSE вследствие чувствительности данной метрики к крупным отклонениям.

Итог по моделям получили следующие результаты:

MLP: RMSE=5.8806 | MAE=4.4683 | $R^2=-5.5438$

LSTM: RMSE=2.1848 | MAE=1.3999 | $R^2=0.0967$

Применение процедур очистки данных позволяет устранить экстремальные значения и снизить вариативность временного ряда, что непосредственно отражается в уменьшении MAE и повышении устойчивости прогноза. Нейросетевое сглаживание дополнительно подавляет высокочастотный шум и выделяет основные тенденции изменения KPI, обеспечивая рост коэффициента R^2 и более точное воспроизведение реальной динамики показателя.

Обсуждение. Таким образом, результаты, показанные на рисунке 2, подтверждают, что последовательная очистка и сглаживание данных являются ключевыми факторами снижения RMSE и MAE и увеличения R^2 , что повышает точность и надёжность прогнозирования KPI сети 5G.

На рисунке 3 представлена динамика изменения среднеквадратичной ошибки (Mean Squared Error, MSE) в процессе обучения нейросетевой модели на протяжении 1000 эпох. По оси абсцисс отложено количество эпох обучения, по оси ординат — значение функции ошибки, приведённое в логарифмическом масштабе, что позволяет наглядно оценить процесс сходимости модели.

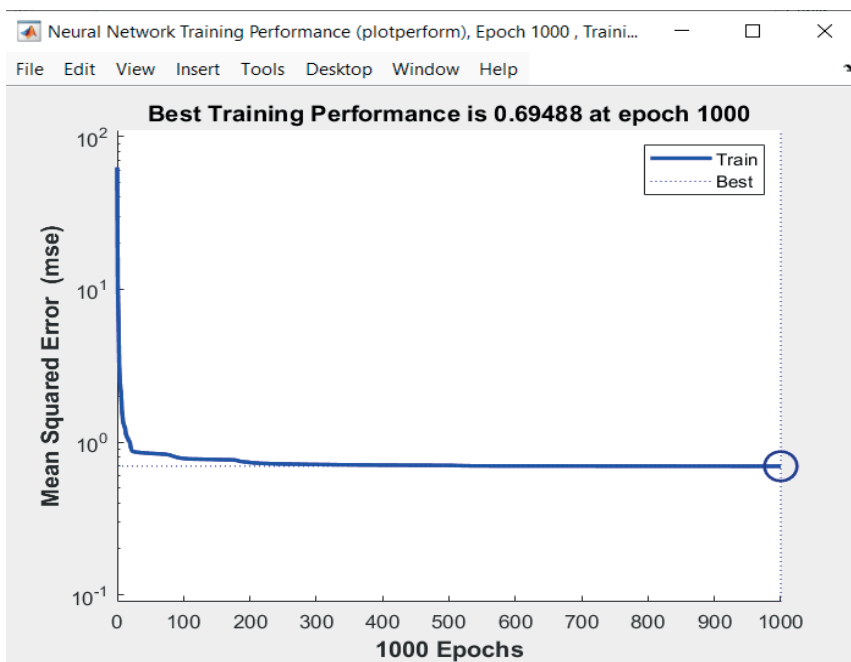


Рисунок 3 – Динамика обучения нейросетевой модели по функции ошибки

В начальной фазе обучения наблюдается резкое снижение значения MSE, что свидетельствует о быстром захвате моделью основных закономерностей во входных данных. Уже на первых десятках эпох ошибка уменьшается на порядок, что указывает на корректный выбор архитектуры сети и параметров оптимизации.

На последующих этапах обучения кривая ошибки выходит на плато, демонстрируя стабилизацию процесса обучения и отсутствие резких колебаний. Минимальное значение ошибки, равное 0.69488, достигается на 1000-й эпохе, что соответствует наилучшему результату обучения. Отсутствие роста ошибки на завершающем участке обучения свидетельствует об устойчивости модели и отсутствии признаков переобучения.

Таким образом, результаты, представленные на рисунке 3, подтверждают сходимость нейросетевой модели и её способность к устойчивому обучению на зашумлённых эксплуатационных данных сети 5G. Достигнутое минимальное значение MSE служит основанием для дальнейшего использования обученной модели в задачах прогнозирования показателей качества обслуживания.

На рисунке 4 представлена гистограмма распределения ошибок нейросетевой модели, полученная на этапе обучения. Ошибка определяется как разность между фактическими и прогнозируемыми значениями показателя KPI и вычисляется по выражению

$$e = y - \hat{y}, \quad (10)$$

где y - наблюдаемое значение KPI, \hat{y} - соответствующее значение, предсказанное моделью.

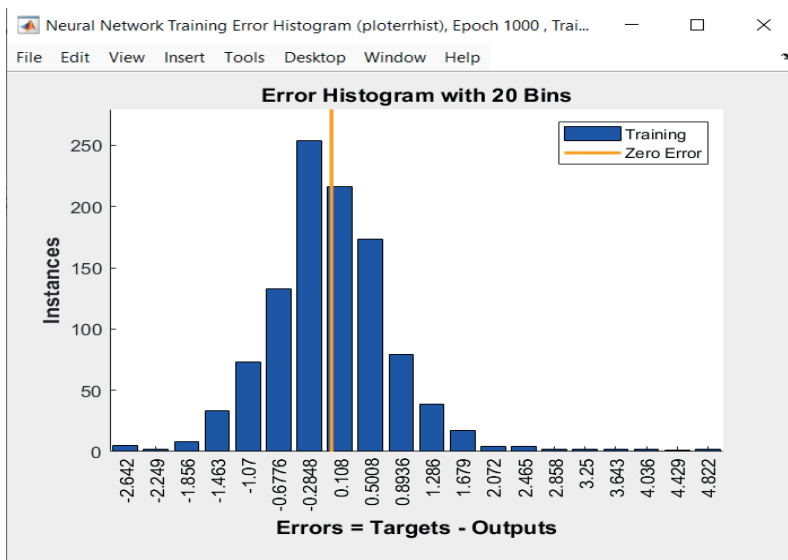


Рисунок 4 – Гистограмма ошибок обучения нейросетевой модели

Гистограмма ошибок прогнозирования показывает, что основная часть отклонений сосредоточена в интервале $\pm 1\%$, при среднем значении ошибки, близком к нулю. Максимальная плотность ошибок наблюдается в диапазоне $-0.5 \dots 0.5\%$, что согласуется с достигнутыми значениями $RMSE \approx 0.7\%$ и $MAE < 0.5\%$, подтверждая высокую точность и отсутствие систематического смещения модели.

На рисунке 5 показано состояние процесса обучения нейросетевой модели, включающее динамику градиента, параметра демпфирования μ алгоритма Левенберга–Маркуардта и число проверок валидации.

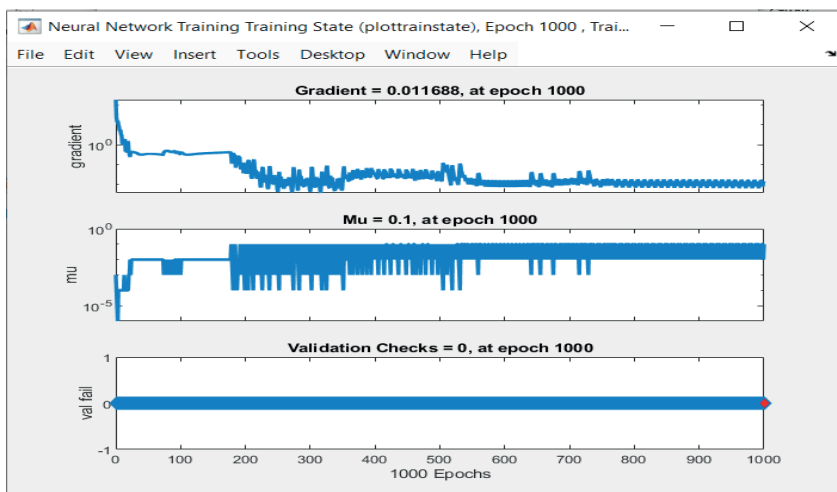


Рисунок 5 – Состояние обучения нейросетевой модели

К 1000-й эпохе значение градиента снижается до **0.0117**, параметр $\mu=0.1$, а проверки валидации отсутствуют, что указывает на устойчивую сходимость модели и корректную работу алгоритма обучения.

На рисунке 6 представлена регрессионная зависимость между фактическими значениями целевого показателя КРІ (ось абсцисс) и значениями, предсказанными нейросетевой моделью на обучающей выборке (ось ординат). Каждая точка соответствует отдельному наблюдению, пунктирная линия $Y=T$ отражает идеальное совпадение прогноза с фактическими данными, а сплошная линия представляет линейную аппроксимацию выходов модели.



Рисунок 6 – Регрессионный анализ результатов обучения нейросетевой модели

Полученное значение коэффициента корреляции $R = 0.86065$ указывает на сильную линейную зависимость между прогнозируемыми и реальными значениями КРІ. Большинство точек сосредоточено вблизи линии идеального соответствия, что свидетельствует о высокой способности модели воспроизводить общую структуру данных. Наблюдаемый разброс в области больших значений целевой переменной объясняется повышенной вариативностью КРІ и наличием редких экстремальных состояний сети.

Таким образом, регрессионный анализ подтверждает адекватность обученной нейросетевой модели и согласуется с ранее полученными значениями метрик RMSE, MAE и коэффициента детерминации R^2 .

Обоснование выбранной методологии

Предложенная методология - комбинация предобработки данных, многофакторного моделирования и временного анализа - ориентирована на практическое применение в системах мониторинга и оптимизации сети. Использование реальных КРІ, а не синтетических данных, делает модель ближе к реальным сценариям эксплуатации. Выбор MLP и LSTM оправдан тем, что они дополняют друг друга: первая модель хорошо описывает статический «портрет» соты, вторая - её поведение во времени.

За счёт такого подхода удастся не просто построить «чёрный ящик», а сформировать интерпретируемое решение: по совокупности КРІ можно оценивать вероятность аномальных разъединений, отслеживать её динамику и использовать результаты прогноза для принятия инженерных решений - от

изменения параметров handover и таймеров до перенастройки радиоресурса в рамках SON.

Заключение

Мы провели исследование, направленное на прогнозирование вероятности аномальных разъединений в сетях 5G, анализируя временные ряды ключевых показателей качества обслуживания (KPI). Актуальность этой работы обусловлена высокой динамичностью современных телекоммуникационных сетей и потребностью в заблаговременном выявлении ухудшений качества для повышения надежности и устойчивости сетевой инфраструктуры. Ключевым этапом нашего исследования стала комплексная предварительная обработка данных KPI. Мы очистили данные от выбросов, заполнили пропуски и использовали нейронные сети для сглаживания временных рядов. Результаты показывают, что эти шаги значительно уменьшают шум и делают входные данные более стабильными, что напрямую улучшает точность прогнозирования.

В рамках задачи прогнозирования были созданы и сопоставлены нейросетевые модели на базе многослойного перцептрона (MLP) и рекуррентной сети LSTM. Хотя обе модели успешно отражают общую динамику показателя Abnormal Release Rate, модель LSTM продемонстрировала превосходную точность. Её способность учитывать временные зависимости в данных позволила значительно снизить ошибки прогнозирования (RMSE, MAE) и повысить объясняющую способность (R^2) по сравнению с MLP. Дополнительный анализ подтвердил стабильность обучения нейросетей, отсутствие систематических ошибок и их высокую применимость для анализа реальных эксплуатационных данных 5G.

Исследование подтвердило, что глубокое обучение является мощным инструментом для анализа и прогнозирования KPI телекоммуникационных сетей. Разработанный подход открывает возможности для создания интеллектуальных систем мониторинга и поддержки принятия решений для операторов связи. Его потенциал может быть расширен путем включения дополнительных сетевых показателей и разработки многомерных, многокомпонентных моделей прогнозирования.

Будущие исследования должны быть направлены на создание многомерных нейросетевых моделей, которые смогут комплексно учитывать взаимосвязь различных KPI сетей 5G. Также перспективным является применение гибридных архитектур глубокого обучения, таких как CNN-LSTM и Transformer. Интеграция прогнозных моделей в системы предиктивного управления радиосетью (Predictive SON) позволит проактивно предотвращать ухудшение качества обслуживания. Особое внимание следует уделить распределенным и федеративным подходам к обнаружению аномалий, особенно в сценариях 5G-IoT и edge-вычислений.

References

- Awofolaju T., Lasisi H.O., Olawuyi A., Adebayo S. (2023) Artificial Neural Network Based Prediction of Key Performance Indicators for Mobile Telecommunications. *Journal of Science and Technology*, 15(2). <https://doi.org/10.30880/jst.2023.15.02.005> (in Eng.).
- Stojić M., Banjanin M.K., Vasiljević M., et al. (2023) Predictive Modeling of Delay in an LTE Network by Optimizing the Number of Predictors Using Dimensionality Reduction Techniques. *Applied Sciences*, 13(14). — 8511p. <https://doi.org/10.3390/app13148511> (in Eng.).
- Nurakhov Y., Mukhanbet A., Aibagarov S., Imankulov T.A (2025) Machine Learning Approach to Investigating Key Performance Factors in 5G Standalone Networks. *Electronics*, 14(19), 3817. <https://doi.org/10.3390/electronics14193817> (in Eng.).
- Nassef O., Sun W., Purmehdi H., Tatipamula M., Mahmoodi T.A (2022) Survey: Distributed Machine Learning for 5G and Beyond. *Computer Networks*, 207, 108820. <https://doi.org/10.1016/j.comnet.2022.108820> (in Eng.).
- Islam M.A., Siddique H., Zhang W., et al. (2023) A Deep Neural Network-Based Communication Failure Prediction Scheme in 5G RAN. *IEEE Transactions on Network and Service Management*, 20(2). — P. 1140–1152. <https://doi.org/10.1109/TNSM.2022.3229658> (in Eng.).
- Arun Prasad K., Abdul Basith M., Harish Kumar V. (2025) Deep Autoencoder-Based Anomaly Detection for Intelligent Network Slice Monitoring in B5G Networks. *Journal of Artificial Intelligence and Capsule Networks*, 7(2). — P. 107–124. <https://doi.org/10.36548/jaicn.2025.2.002> (in Eng.).
- Wang C., et al. (2021) TSAGen: Synthetic Time Series Generation for KPI Anomaly Detection. *IEEE Transactions on Network and Service Management*, 18(4). <https://doi.org/10.1109/TNSM.2021.3098784> (in Eng.).
- Wu J., Lee P.P., Li Q., Pan, L., Zhang, J. (2018) CellPAD: Detecting Performance Anomalies in Cellular Networks via Regression Analysis. In: *Proc. IFIP Networking Conference (IFIP Networking)*. — P. 1–9. <https://doi.org/10.23919/IFIPNetworking.2018.8697027> (in Eng.).
- Yuliana H., Hendrawan I., Musashi Y. (2024) Estimating Base Station Traffic and Throughput Using Machine Learning Based on Hourly Key Performance Indicator (KPI) Network Analysis. *IEEE Access*, 12. — P. 116285–116301. <https://doi.org/10.1109/ACCESS.2024.3447098> (in Eng.).
- Liu X., Li Y., Zhu S., et al. (2025) A Traffic Forecasting Framework for Cellular Networks Based on a Dynamic Component Management Mechanism. *Electronics*, 14(20), 4003. <https://doi.org/10.3390/electronics14204003> (in Eng.).
- Almeida A., Rito P., Brás S., Pinto F.C., Sargento S. (2024) A Machine Learning Approach to Forecast 5G Metrics in a Commercial and Operational 5G Platform: 5G and Mobility. *Computer Communications*, 228, 10797. <https://doi.org/10.23919/WONS60642.2024.10449577> (in Eng.).
- Al-Thaedan A., Shakir Z., Mjhoor A. Y., et al. (2024) A Machine Learning Framework for Predicting Downlink Throughput in 4G-LTE/5G Cellular Networks. *International Journal of Information Technology*, 16(2). — P. 651–657. <https://doi.org/10.1007/s41870-023-01678-w> (in Eng.).
- Kim J., Thulasiraman P. (2024) Anomaly Detection in 5G Networks Using Transformer-Based Autoencoder. In: *2024 International Conference on Recent Advances in Systems Science and Engineering (RASSE)*. <https://doi.org/10.1109/RASSE64357.2024.10773774> (in Eng.).
- Khan I., Abdullah J., et al. (2020) Network Anomaly Detection Using LSTM Based Autoencoder. In: *Proc. 2020 3rd International Conference on Computing and Informatics (ICCI), 2020*. <https://www.researchgate.net/publication/346006810> (in Eng.).
- Reis M.J.C.S. (2025) Edge-FLGuard+: A Federated and Lightweight Anomaly Detection Framework for Securing 5G-Enabled IoT in Smart Homes. *Future Internet*, 17(8). — 329 p. <https://doi.org/10.3390/fi17080329> (in Eng.).
- K.S. Chezhibayeva, A. Mukhamedzhanova, Yu. Garmashova. (2025) Ekspertnaya sistema prognozirovaniya qos v 5G-Setyah na osnove nechetkoj logikiempirically [Expert qos forecasting system in 5G networks based on fuzzy logic]. *Ademic scientific journal of computer science*. Volume 4. Number 356. P. 306–320. <https://doi.org/10.32014/2025.2518-1726.398> <https://doi.org/10.32014/2025.2518-1726.398> (in Russ.).

Publication Ethics and Publication Malpractice in the journals of the Central Asian Academic Research Center LLP

For information on Ethics in publishing and Ethical guidelines for journal publication see <http://www.elsevier.com/publishingethics> and <http://www.elsevier.com/journal-authors/ethics>.

Submission of an article to the journals of the Central Asian Academic Research Center LLP implies that the described work has not been published previously (except in the form of an abstract or as part of a published lecture or academic thesis or as an electronic preprint, see <http://www.elsevier.com/postingpolicy>), that it is not under consideration for publication elsewhere, that its publication is approved by all authors and tacitly or explicitly by the responsible authorities where the work was carried out, and that, if accepted, it will not be published elsewhere in the same form, in English or in any other language, including electronically without the written consent of the copyright-holder. In particular, translations into English of papers already published in another language are not accepted.

No other forms of scientific misconduct are allowed, such as plagiarism, falsification, fraudulent data, incorrect interpretation of other works, incorrect citations, etc. The Central Asian Academic Research Center LLP follows the Code of Conduct of the Committee on Publication Ethics (COPE), and follows the COPE Flowcharts for Resolving Cases of Suspected Misconduct (http://publicationethics.org/files/u2/New_Code.pdf). To verify originality, your article may be checked by the Cross Check originality detection service <http://www.elsevier.com/editors/plagdetect>.

The authors are obliged to participate in peer review process and be ready to provide corrections, clarifications, retractions and apologies when needed. All authors of a paper should have significantly contributed to the research.

The reviewers should provide objective judgments and should point out relevant published works which are not yet cited. Reviewed articles should be treated confidentially. The reviewers will be chosen in such a way that there is no conflict of interests with respect to the research, the authors and/or the research funders.

The editors have complete responsibility and authority to reject or accept a paper, and they will only accept a paper when reasonably certain. They will preserve anonymity of reviewers and promote publication of corrections, clarifications, retractions and apologies when needed. The acceptance of a paper automatically implies the copyright transfer to the Central Asian Academic Research Center LLP.

The Editorial Board of the Central Asian Academic Research Center LLP will monitor and safeguard publishing ethics.

Правила оформления статьи для публикации в журнале смотреть на сайтах:

www.nauka-nanrk.kz

<http://physics-mathematics.kz/index.php/en/archive>

ISSN2518-1726 (Online),

ISSN 1991-346X (Print)

Ответственный редактор *А. Ботанқызы*

Редакторы: *Д.С. Аленов, Т. Апендиев*

Верстка на компьютере: *Г.Д. Жадырановой*

Подписано в печать 31.03.2026.

Формат 60x881/8.

20,0 п.л. Заказ 1.