

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



«ҚАЗАҚСТАН РЕСПУБЛИКАСЫ
ҰЛТТЫҚ ҒЫЛЫМ АКАДЕМИЯСЫ» РҚБ

Х А Б А Р Л А Р Ы

ИЗВЕСТИЯ

РОО «НАЦИОНАЛЬНОЙ
АКАДЕМИИ НАУК РЕСПУБЛИКИ
КАЗАХСТАН»

N E W S

OF THE ACADEMY OF SCIENCES
OF THE REPUBLIC OF
KAZAKHSTAN

PHYSICO-MATHEMATICAL SERIES

4 (352)

OCTOBER – DECEMBER 2024

PUBLISHED SINCE JANUARY 1963

PUBLISHED 4 TIMES A YEAR

ALMATY, NAS RK

БАС РЕДАКТОР:

МУТАНОВ Ғалымқайыр Мұтанұлы, техника ғылымдарының докторы, профессор, ҚР ҰҒА академигі, ҚР БҒМ ҒК «Ақпараттық және есептеу технологиялары институты» бас директорының м.а. (Алматы, Қазақстан), **Н=5**

БАС РЕДАКТОРДЫҢ ОРЫНБАСАРЫ:

МАМЫРБАЕВ Өркен Жұмажанұлы, ақпараттық жүйелер мамандығы бойынша философия докторы (Ph.D), ҚР БҒМ Ғылым комитеті «Ақпараттық және есептеуші технологиялар институты» РМК жауапты хатшысы (Алматы, Қазақстан), **Н=5**

РЕДАКЦИЯ АЛҚАСЫ:

ҚАЛИМОЛДАЕВ Мақсат Нұрәділұлы, физика-математика ғылымдарының докторы, профессор, ҚР ҰҒА академигі (Алматы, Қазақстан), **Н=7**

БАЙГУНЧЕКОВ Жұмаділ Жанабайұлы, техника ғылымдарының докторы, профессор, ҚР ҰҒА академигі, Кибернетика және ақпараттық технологиялар институты, Сатпаев университетінің Қолданбалы механика және инженерлік графика кафедрасы, (Алматы, Қазақстан), **Н=3**

ВОЙЧИК Вальдемар, техника ғылымдарының докторы (физика), Люблин технологиялық университетінің профессоры (Люблин, Польша), **Н=23**

БОШКАЕВ Қуантай Авғазыұлы, Ph.D. Теориялық және ядролық физика кафедрасының доценті, әл-Фараби атындағы Қазақ ұлттық университеті (Алматы, Қазақстан), **Н=10**

QUEVEDO Nemando, профессор, Ядролық ғылымдар институты (Мехико, Мексика), **Н=28**

ЖҮСІПОВ Марат Абжанұлы, физика-математика ғылымдарының докторы, теориялық және ядролық физика кафедрасының профессоры, әл-Фараби атындағы Қазақ ұлттық университеті (Алматы, Қазақстан), **Н=7**

КОВАЛЕВ Александр Михайлович, физика-математика ғылымдарының докторы, Украина ҰҒА академигі, Қолданбалы математика және механика институты (Донецк, Украина), **Н=5**

РАМАЗАНОВ Тілекқабұл Сәбитұлы, физика-математика ғылымдарының докторы, профессор, ҚР ҰҒА академигі, әл-Фараби атындағы Қазақ ұлттық университетінің ғылыми-инновациялық қызмет жөніндегі проректоры, (Алматы, Қазақстан), **Н=26**

ТАКИБАЕВ Нұрғали Жабағаұлы, физика-математика ғылымдарының докторы, профессор, ҚР ҰҒА академигі, әл-Фараби атындағы Қазақ ұлттық университеті (Алматы, Қазақстан), **Н=5**

ТИГИНЯНУ Ион Михайлович, физика-математика ғылымдарының докторы, академик, Молдова Ғылым Академиясының президенті, Молдова техникалық университеті (Кишинев, Молдова), **Н=42**

ХАРИН Станислав Николаевич, физика-математика ғылымдарының докторы, профессор, ҚР ҰҒА академигі, Қазақстан-Британ техникалық университеті (Алматы, Қазақстан), **Н=10**

ДАВЛЕТОВ Асқар Ербуланович, физика-математика ғылымдарының докторы, профессор, әл-Фараби атындағы Қазақ ұлттық университеті (Алматы, Қазақстан), **Н=12**

КАЛАНДРА Пьетро, Ph.D (физика), Нанокұрылымды материалдарды зерттеу институтының профессоры (Рим, Италия), **Н=26**

«ҚР ҰҒА Хабарлары. Физика және информатика сериясы».

ISSN 2518-1726 (Online),

ISSN 1991-346X (Print)

Меншіктеуші: «Қазақстан Республикасының Ұлттық ғылым академиясы» РҚБ (Алматы қ.). Қазақстан Республикасының Ақпарат және қоғамдық даму министрлігінің Ақпарат комитетінде 14.02.2018 ж. берілген **№ 16906-Ж** мерзімдік басылым тіркеуіне қойылу туралы куәлік.

Тақырыптық бағыты: *физика және ақпараттық коммуникациялық технологиялар сериясы*. Қазіргі уақытта: *«ақпараттық технологиялар» бағыты бойынша ҚР БҒМ БҒСБК ұсынған журналдар тізіміне енді.*

Мерзімділігі: *жылына 4 рет.*

Тиражы: *300 дана.*

Редакцияның мекен-жайы: *050010, Алматы қ., Шевченко көш., 28, 219 бөл., тел.: 272-13-19*
<http://www.physico-mathematical.kz/index.php/en/>

ГЛАВНЫЙ РЕДАКТОР:

МУТАНОВ Галимжаир Мутанович, доктор технических наук, профессор, академик НАН РК, и.о. генерального директора «Института информационных и вычислительных технологий» КН МОН РК (Алматы, Казахстан), **H=5**

ЗАМЕСТИТЕЛЬ ГЛАВНОГО РЕДАКТОРА:

МАМЫРБАЕВ Оркен Жумажанович, доктор философии (PhD) по специальности Информационные системы, ответственный секретарь РГП «Института информационных и вычислительных технологий» Комитета науки МОН РК (Алматы, Казахстан), **H=5**

РЕДАКЦИОННАЯ КОЛЛЕГИЯ:

КАЛИМОЛДАЕВ Максат Нурадилович, доктор физико-математических наук, профессор, академик НАН РК (Алматы, Казахстан), **H=7**

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), **H=3**

ВОЙЧИК Вальдемар, доктор технических наук (физ.-мат.), профессор Люблинского технологического университета (Люблин, Польша), **H=23**

БОШКАЕВ Куантай Авгазыевич, доктор Ph.D, преподаватель, доцент кафедры теоретической и ядерной физики, Казахский национальный университет им. аль-Фараби (Алматы, Казахстан), **H=10**

QUEVEDO Hemando, профессор, Национальный автономный университет Мексики (UNAM), Институт ядерных наук (Мехико, Мексика), **H=28**

ЖУСУПОВ Марат Абжанович, доктор физико-математических наук, профессор кафедры теоретической и ядерной физики, Казахский национальный университет им. аль-Фараби (Алматы, Казахстан), **H=7**

КОВАЛЕВ Александр Михайлович, доктор физико-математических наук, академик НАН Украины, Институт прикладной математики и механики (Донецк, Украина), **H=5**

РАМАЗАНОВ Тлексабул Сабитович, доктор физико-математических наук, профессор, академик НАН РК, проректор по научно-инновационной деятельности, Казахский национальный университет им. аль-Фараби (Алматы, Казахстан), **H=26**

ТАКИБАЕВ Нурғали Жабағевич, доктор физико-математических наук, профессор, академик НАН РК, Казахский национальный университет им. аль-Фараби (Алматы, Казахстан), **H=5**

ТИГИНЯНУ Ион Михайлович, доктор физико-математических наук, академик, президент Академии наук Молдовы, Технический университет Молдовы (Кишинев, Молдова), **H=42**

ХАРИН Станислав Николаевич, доктор физико-математических наук, профессор, академик НАН РК, Казахстанско-Британский технический университет (Алматы, Казахстан), **H=10**

ДАВЛЕТОВ Аскар Ербуланович, доктор физико-математических наук, профессор, Казахский национальный университет им. аль-Фараби (Алматы, Казахстан), **H=12**

КАЛАНДРА Пьетро, доктор философии (Ph.D, физика), профессор Института по изучению наноструктурированных материалов (Рим, Италия), **H=26**

«Известия НАН РК. Серия физика и информатики».

ISSN 2518-1726 (Online),

ISSN 1991-346X (Print)

Собственник: *Республиканское общественное объединение «Национальная академия наук Республики Казахстан» (г. Алматы).*

Свидетельство о постановке на учет периодического печатного издания в Комитете информации Министерства информации и общественного развития Республики Казахстан **№ 16906-Ж** выданное 14.02.2018 г.

Тематическая направленность: *серия физика и информационные коммуникационные технологии.* В настоящее время: *вошел в список журналов, рекомендованных ККСОН МОН РК по направлению «информационные коммуникационные технологии».*

Периодичность: *4 раз в год.*

Тираж: *300 экземпляров.*

Адрес редакции: *050010, г. Алматы, ул. Шевченко, 28, оф. 219, тел.: 272-13-19*

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

EDITOR IN CHIEF:

MUTANOV Galimkair Mutanovich, doctor of technical Sciences, Professor, Academician of NAS RK, acting director of the Institute of Information and Computing Technologies of SC MES RK (Almaty, Kazakhstan), **H=5**

DEPUTY EDITOR-IN-CHIEF

MAMYRBAYEV Orken Zhumazhanovich, Ph.D. in the specialty "Information systems, executive secretary of the RSE "Institute of Information and Computational Technologies", Committee of Science MES RK (Almaty, Kazakhstan) **H=5**

EDITORIAL BOARD:

KALIMOLDAYEV Maksat Nuradilovich, doctor in Physics and Mathematics, Professor, Academician of NAS RK (Almaty, Kazakhstan), **H=7**

BAYGUNCHEKOV Zhumadil Zhanabayevich, 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), **H=3**

WOICIK Waldemar, Doctor of Phys.-Math. Sciences, Professor, Lublin University of Technology (Lublin, Poland), **H=23**

BOSHKAYEV Kuantai Avgazievich, PhD, Lecturer, Associate Professor of the Department of Theoretical and Nuclear Physics, Al-Farabi Kazakh National University (Almaty, Kazakhstan), **H=10**

QUEVEDO Hemando, Professor, National Autonomous University of Mexico (UNAM), Institute of Nuclear Sciences (Mexico City, Mexico), **H=28**

ZHUSSUPOV Marat Abzhanovich, Doctor in Physics and Mathematics, Professor of the Department of Theoretical and Nuclear Physics, Al-Farabi Kazakh National University (Almaty, Kazakhstan), **H=7**

KOVALEV Alexander Mikhailovich, Doctor in Physics and Mathematics, Academician of NAS of Ukraine, Director of the State Institution «Institute of Applied Mathematics and Mechanics» DPR (Donetsk, Ukraine), **H=5**

RAMAZANOV Tlekkabul Sabitovich, Doctor in Physics and Mathematics, Professor, Academician of NAS RK, Vice-Rector for Scientific and Innovative Activity, Al-Farabi Kazakh National University (Almaty, Kazakhstan), **H=26**

TAKIBAYEV Nurgali Zhabagaevich, Doctor in Physics and Mathematics, Professor, Academician of NAS RK, Al-Farabi Kazakh National University (Almaty, Kazakhstan), **H=5**

TIGHINEANU Ion Mikhailovich, Doctor in Physics and Mathematics, Academician, Full Member of the Academy of Sciences of Moldova, President of the AS of Moldova, Technical University of Moldova (Chisinau, Moldova), **H=42**

KHARIN Stanislav Nikolayevich, Doctor in Physics and Mathematics, Professor, Academician of NAS RK, Kazakh-British Technical University (Almaty, Kazakhstan), **H=10**

DAVLETOV Askar Erbulanovich, Doctor in Physics and Mathematics, Professor, Al-Farabi Kazakh National University (Almaty, Kazakhstan), **H=12**

CALANDRA Pietro, PhD in Physics, Professor at the Institute of Nanostructured Materials (Monterotondo Station Rome, Italy), **H=26**

News of the National Academy of Sciences of the Republic of Kazakhstan.

Series of physics and informatics.

ISSN 2518-1726 (Online),

ISSN 1991-346X (Print)

Owner: RPA «National Academy of Sciences of the Republic of Kazakhstan» (Almaty). The certificate of registration of a periodical printed publication in the Committee of information of the Ministry of Information and Social Development of the Republic of Kazakhstan **No. 16906-ЖК**, issued 14.02.2018
Thematic scope: *series physics and information technology.*

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

Periodicity: *4 times a year.*

Circulation: *300 copies.*

Editorial address: *28, Shevchenko str., of. 219, Almaty, 050010, tel. 272-13-19*

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

УДК 004.852

©**A.A. Myrzatay**^{1*}, **L.G. Rzaeva**², **B. Zhumadilla**¹, **A.A. Mukhanova**³,
G.A. Uskenbayeva³, 2024.

¹Kyzylorda University named after Korkyt-ata, Kyzylorda, Kazakhstan;

²Astana IT University, Astana, Kazakhstan;

³L.N. Gumilyov Eurasian National University, Astana, Kazakhstan.

e-mail: mirzataitegiali@gmail.com

DOUBLE EXPONENTIAL SMOOTHING AND TIME WINDOW METHODS FOR PREDICTIVE LAN MONITORING: ANALYSIS, COMPARISON AND APPLICATION

Myrzatay A.A. – Lecturer at the Department of Computer Science, Korkyt Ata Kyzylorda University, Kyzylorda, Kazakhstan, ORCID ID: <https://orcid.org/0000-0002-5339-2437>;

Rzaeva L.G. – PhD, associate professor, Department of Intelligent Systems and Cybersecurity, Astana IT University, Astana, Kazakhstan, ORCID ID: <https://orcid.org/0000-0002-3382-4685>;

Zhumadilla B. – Lecturer at the Department of Informatics, Korkyt Ata Kyzylorda University, Kyzylorda, Kazakhstan; ORCID ID: <https://orcid.org/0009-0005-0976-6250>;

Mukhanova A.A. – PhD, associate professor, Department of Information systems, L.N. Gumilyov Eurasian National University, Astana, Kazakhstan, ORCID ID: <https://orcid.org/0000-0003-3987-0938>;

Uskenbayeva G.A. – PhD, associate professor, Department of System analysis and control, L.N. Gumilyov Eurasian National University; Astana, Kazakhstan, ORCID ID: <https://orcid.org/0000-0001-6904-8000>.

Abstract. This article focuses on the study of predictive monitoring methods for Local Area Networks (LANs), emphasizing the comparative analysis and practical application of Double Exponential Smoothing (DES) and Windowed Time Series (WTC) methods. The research aims to identify the most effective approach to predicting LAN failures through a detailed analysis of their key characteristics, including principles of operation, advantages, limitations, and application areas. The study highlights the importance of adapting these methods to specific network operating conditions, which is a critical factor in improving forecast accuracy and ensuring the stability of LAN operations.

DES and WTC were chosen for their distinct advantages: DES, as a time series analysis method, demonstrates high efficiency in long-term trend forecasting, while WTC provides deeper insights into local changes and short-term anomalies. The comparative analysis revealed their strengths and weaknesses, as well as optimal parameters for enhancing their effectiveness. The article offers recommendations

for implementing these approaches in real-world network environments, enabling early detection of potential faults and minimizing downtime.

Additionally, the research addresses the integration of predictive methods into existing LAN monitoring systems, including their potential combination with modern machine learning tools. This integration enables flexible solutions that can be tailored to various operational scenarios and organizational needs.

The findings of this study are particularly relevant for organizations aiming to modernize their network infrastructure and transition to proactive network management. Such approaches not only enhance reliability but also improve cost efficiency by optimizing maintenance and preventing unplanned outages. This work contributes to the advancement of predictive analysis technologies and demonstrates their practical value in the context of LAN operations.

Keywords: Local Area Networks (LANs); predictive monitoring; Double Exponential Smoothing (DES); Windowed Time Series (WTC); anomaly detection; trend forecasting; network reliability; network analytics; failure prediction; fault detection.

©А.А. Мырзатай^{1*}, Л.Г. Рзаева², Б. Жұмаділла¹, А.А. Муханова³,
Г.А. Ускенбаева³, 2024.

¹Қорқыт ата атындағы Қызылорда университеті, Қызылорда, Қазақстан;

²Astana IT University, Астана, Қазақстан;

³Л.Н. Гумилев атындағы ЕҰУ, Астана, Қазақстан.

e-mail: *mirzataitegiali@gmail.com*

ЖЕРГІЛІКТІ ЖЕЛІНІ БОЛЖАМДЫ БАҚЫЛАУҒА АРНАЛҒАН ҚОС ЭКСПОНЕНЦИАЛДЫ ТЕГІСТЕУ ЖӘНЕ УАҚЫТ ТЕРЕЗЕЛЕРІНІҢ ӘДІСТЕРІ: ТАЛДАУ, САЛЫСТЫРУ ЖӘНЕ ҚОЛДАНУ

Мырзатай А.А. – Қорқыт Ата атындағы Қызылорда университетінің Компьютерлік ғылымдар кафедрасының оқытушысы, Қызылорда, Қазақстан, ORCID ID: <https://orcid.org/0000-0002-5339-2437>;

Рзаева Л.Г. – Зияткерлік жүйелер және киберқауіпсіздік кафедрасы, Astana IT University, Астана, Қазақстан, ORCID ID: <https://orcid.org/0000-0002-3382-4685>;

Жұмаділла Б. – PhD, қауымдастырылған профессор, Қорқыт Ата атындағы Қызылорда университетінің Информатика кафедрасының оқытушысы, Қызылорда, Қазақстан; ORCID ID: <https://orcid.org/0009-0005-0976-6250>;

Мұханова А.А. – PhD, қауымдастырылған профессор, Ақпараттық жүйелер кафедрасы, Л.Н. Гумилев атындағы Евразия Ұлттық университеті, Астана, Қазақстан, ORCID ID: <https://orcid.org/0000-0003-3987-0938>;

Ускенбаева Г.А. – PhD, қауымдастырылған профессор, Жүйелік талдау және басқару кафедрасы, Л.Н. Гумилев атындағы ЕҰУ, Астана, Қазақстан, ORCID ID: <https://orcid.org/0000-0001-6904-8000>.

Аннотация. Бұл мақалада жергілікті есептеу желілерін (LAN) болжау мониторингі әдістерін зерттеуге баса назар аударылып, екі әдісті – қос

экспоненциалды тегістеу (DES) және уақыттық терезелер әдісін (WTC) салыстыру мен практикалық қолдану қарастырылады. Зерттеу мақсаты – LAN ақауларын болжау үшін ең тиімді тәсілді анықтау, олардың негізгі сипаттамаларын, соның ішінде жұмыс істеу қағидаттарын, артықшылықтары мен шектеулерін және қолдану салаларын егжей-тегжейлі талдау. Зерттеу осы әдістерді желінің нақты жұмыс жағдайларына бейімдеудің болжау дәлдігін арттыру және желінің тұрақтылығын қамтамасыз етудегі маңыздылығын көрсетеді.

DES және WTC әдістері өз ерекшеліктерімен таңдалған: DES уақыттық қатарларды талдау әдісі ретінде ұзақ мерзімді үрдістерді болжауда жоғары тиімділікті көрсетеді, ал WTC қысқа мерзімді ауытқулар мен жергілікті өзгерістерді терең талдауды қамтамасыз етеді. Салыстырмалы талдау олардың артықшылықтары мен кемшіліктерін, сондай-ақ тиімділікті арттырудың оңтайлы параметрлерін анықтауға мүмкіндік берді. Мақалада осы тәсілдерді нақты желілік ортада іске асыру бойынша ұсыныстар беріледі, бұл әлеуетті ақауларды ерте анықтауға және тоқтап қалуды азайтуға ықпал етеді.

Сонымен қатар, зерттеуде болжау әдістерін заманауи машиналық оқыту құралдарымен біріктіру мүмкіндіктерін қоса отырып, қолданыстағы LAN мониторинг жүйелеріне интеграциялау мәселелері қарастырылады. Бұл шешімдерді әртүрлі операциялық сценарийлерге және ұйымның қажеттіліктеріне бейімдеуге мүмкіндік береді.

Зерттеу нәтижелері желілік инфрақұрылымды жаңғыртуды және желілерді проактивті басқаруға көшуді мақсат еткен ұйымдар үшін өте маңызды. Мұндай тәсілдер жүйенің сенімділігін арттырып қана қоймай, техникалық қызмет көрсетуді оңтайландыру және жоспардан тыс тоқтап қалулардың алдын алу арқылы экономикалық тиімділікті жақсартады. Осылайша, бұл жұмыс болжау талдау технологияларын дамытуға үлес қосып, олардың практикалық құндылығын көрсетеді.

©А.А. Мырзатай^{1*}, Л.Г. Рзаева², Б. Жұмаділла¹, А.А. Муханова³,
Г.А. Ускенбаева³, 2024.

¹Кызылординский университет им. Коркыт Ата, Кызылорда, Казахстан;

²Astana IT University, Астана, Казахстан;

³Евразийский национальный университет им. Л.Н. Гумилева,
Астана, Казахстан.

e-mail: mirzataitegiali@gmail.com

МЕТОДЫ ДВОЙНОГО ЭКСПОНЕНЦИАЛЬНОГО СГЛАЖИВАНИЯ И ВРЕМЕННЫХ ОКОН ДЛЯ ПРЕДИКТИВНОГО МОНИТОРИНГА ЛВС: АНАЛИЗ, СРАВНЕНИЕ И ПРИМЕНЕНИЕ

А.А. Мырзатай – преподаватель кафедры компьютерных наук Кызылординского университета имени Коркыт Ата, Кызылорда, Казахстан, ORCID ID: <https://orcid.org/0000-0002-5339-2437>;

Л.Г. Рзаева – PhD, ассоциированный профессор, кафедра интеллектуальных систем и кибербезопасности, Astana IT University, Астана, Казахстан, ORCID ID: <https://orcid.org/0000-0002-3382-4685>;

Б. Жұмаділла – преподаватель кафедры информатики Кызылординского университета имени Коркыт Ата, Кызылорда, Казахстан, ORCID ID: <https://orcid.org/0009-0005-0976-6250>;

А.А. Мұханова – PhD, ассоциированный профессор, кафедра информационных систем, Евразийский национальный университет имени Л.Н.Гумилева, Астана, Казахстан, ORCID ID: <https://orcid.org/0000-0003-3987-0938>;

Г.А. Ускенбаева – PhD, ассоциированный профессор, кафедра системного анализа и управления, Евразийский национальный университет имени Л.Н. Гумилева, Астана, Казахстан, ORCID ID: <https://orcid.org/0000-0001-6904-8000>.

Аннотация. Данная статья посвящена исследованию методов предиктивного мониторинга локальных вычислительных сетей (ЛВС), с акцентом на сравнительный анализ и практическое применение методов двойного экспоненциального сглаживания (DES) и временных окон (WTC). Предметом исследования является поиск наиболее эффективного подхода к прогнозированию отказов в ЛВС путем детального анализа их ключевых характеристик, таких как принципы работы, преимущества, недостатки и сферы применения. В статье подчеркивается важность адаптации этих методов к специфическим условиям эксплуатации сети, что является ключевым аспектом повышения точности прогнозов и обеспечения стабильности работы ЛВС.

Методы DES и WTC были выбраны не случайно: DES, как метод анализа временных рядов, демонстрирует высокую эффективность в прогнозировании долгосрочных трендов, в то время как WTC обеспечивает более глубокий анализ локальных изменений и краткосрочных аномалий. Проведенный сравнительный анализ позволил выявить их сильные и слабые стороны, а также оптимальные параметры для повышения эффективности. В статье представлены рекомендации по внедрению данных подходов в реальные условия работы сетей, что способствует раннему обнаружению потенциальных неисправностей и минимизации простоев.

Кроме того, исследование уделяет внимание вопросам интеграции предиктивных методов в существующие системы мониторинга ЛВС, включая возможности их использования в сочетании с современными инструментами машинного обучения. Это позволяет предложить гибкие решения, которые могут быть адаптированы под различные эксплуатационные сценарии и потребности организаций.

Выводы исследования являются актуальными для организаций, заинтересованных в модернизации своей сетевой инфраструктуры и переходе к проактивному управлению сетями. Такие подходы повышают не только надежность, но и экономическую эффективность за счет оптимизации обслуживания и предотвращения внеплановых простоев. Таким образом, работа вносит вклад в развитие технологий предиктивного анализа и демонстрирует их практическую ценность.

Ключевые слова: локальные вычислительные сети (ЛВС), предиктивный мониторинг, двойное экспоненциальное сглаживание (DES), метод временных окон (WTC), обнаружение аномалий, прогнозирование трендов, надежность сетей, сетевая аналитика, прогнозирование сбоев, выявление поломок.

Введение. Локальные вычислительные сети (ЛВС) занимают важное место в современных информационных системах, обеспечивая надежную передачу данных и поддержку критически важных бизнес-процессов. В условиях растущей зависимости от сетевых технологий, обеспечение бесперебойного функционирования ЛВС становится приоритетной задачей для организаций различных масштабов. Одним из ключевых аспектов повышения надежности сетей является внедрение предиктивных систем мониторинга, способных своевременно обнаруживать потенциальные поломки и сбои.

Предиктивный мониторинг, опирающийся на анализ исторических данных и текущих показателей, предоставляет возможности для предсказания неисправностей до их возникновения. Среди разнообразных методов анализа временных рядов особое внимание уделяется методам двойного экспоненциального сглаживания и временных окон. Эти методы широко применяются для выявления аномалий и прогнозирования трендов в данных ЛВС, демонстрируя высокую эффективность в различных сценариях.

Целью настоящей статьи является проведение сравнительного анализа методов двойного экспоненциального сглаживания и временных окон в контексте предиктивного мониторинга ЛВС и выбора наилучшего для дальнейшего применения в разработке предиктивной системы ЛВС. В рамках исследования будут рассмотрены основные принципы функционирования каждого метода, их преимущества и недостатки, а также результаты применения в различных условиях. Полученные данные позволят сделать выводы о целесообразности использования каждого метода для предсказания поломок в ЛВС и будет выбрана наиболее подходящая для дальнейшего исследования.

Материалы и методы:

1.1 Предиктивные системы

Понятие прогнозирования не имеет универсального или формального определения, но в большинстве контекстов его можно понимать, как объявление или догадку о будущем событии, основанную на текущих и прошлых знаниях или опыте. Основной аспект будущего – его неопределённость; таким образом, любое решение, предложенное для проблемы прогнозирования, никогда не будет совершенно точным, а будет представлять собой приближение наиболее вероятного исхода. Кроме того, краткосрочные прогнозы, как правило, более достижимы, чем долгосрочные.

Для создания прогнозных моделей необходимо наличие исторических

данных для анализа и обучения модели. Характер этих данных будет различаться в зависимости от конкретной области применения, и, следовательно, прогнозируемая цель также будет разнообразной. В медицине прогнозы могут помогать специалистам в диагностике (Chen, et al, 2017) или в оценке рисков, связанных с определенными лечениями (Weng, et al, 2017). Прогностические возможности машинного обучения были использованы в экономической сфере для оценки доходов от рекламных инвестиций или для моделирования возникающих экономических динамик (Athey, 2018). Различные геологические исследования использовали прогнозирование в попытках предвидеть землетрясения (Asim, et al, 2017; Kong, et al, 2019). В областях, более тесно связанных с информационными технологиями, машинное обучение использовалось для прогнозирования сбоев в телекоммуникационных инфраструктурах (Sasisekharan, et al, 1996), выявления дефектов в программном обеспечении (Challagulla, et al, 2008), прогнозирования сетевых и памятных сбоев в суперкомпьютерах (Liang, et al, 2006, June) или обнаружения мошенничества в веб-платежах (Lima, et al, 2015). Ещё одной обычной проблемой, как правило, связанной с последней областью, является прогнозирование сбоев.

Прогнозирование сбоев сосредоточено на разработке моделей, которые могут предвидеть неисправность или поломку в компонентах программного или аппаратного обеспечения. На основе всестороннего изучения существующей литературы, Salfner и др. (Salfner, et al, 2010) разъясняют три ключевых понятия в этой области:

- 1) сбой: это относится к событию, которое происходит, когда предоставленная услуга отклоняется от правильной или ожидаемой услуги;
- 2) ошибка: она составляет часть общего состояния системы, которая может вызвать её последующий сбой в обслуживании;
- 3) дефект: они считаются или предполагаются как истоки ошибки, представляя собой фундаментальную причину самой ошибки.

Существует множество исследований по прогнозированию сбоев в различных областях, включая прогнозирование сбоев жёстких дисков (Hamerly, et al, 2001), сбоев суперкомпьютеров (Pelaez, et al, M. 2014, December), сбоев аппаратных компонентов (Chigurupati, et al, 2016), сбоев телекоммуникационных систем (Weiss, 2002) и сбоев распределённых систем (Shatnawi, et al, 2015).

В контексте распределённых систем прогнозирование обычно основывается на данных, собранных путём мониторинга сети системы. Эти мониторинговые данные обычно включают отчёты об ошибках, события мониторинга или даже события обнаружения сбоев. Прогнозисты используют эту информацию для выявления шаблонов активности, которые предвещают сбои (Weiss, et al, 1998; Agarwal, et al, 2009; Borkowski, et al, 2019).

1.2 Метод двойного экспоненциального сглаживания и временных окон.

Метод двойного экспоненциального сглаживания (DES) (Gardner, 1998; Gardner, 2006), также известный как метод Холта, был разработан для улучшения прогнозирования временных рядов, учитывающих тренды. Этот метод является расширением простого экспоненциального сглаживания, которое справляется только с временными рядами без тренда. Развитие метода двойного экспоненциального сглаживания сыграло важную роль в управлении запасами и планировании производства в различных отраслях, включая военные и коммерческие применения.

Метод двойного экспоненциального сглаживания основывается на идее использования двух уравнений для обновления оценки уровня и тренда временного ряда. Эти уравнения можно выразить следующим образом:

$$S_t^{(1)} = aY_t + (1 - a)S_{t-1}^{(1)} \quad (1.1a)$$

$$S_t^{(2)} = aS_t^{(1)} + (1 - a)S_{t-1}^{(2)} \quad (1.1b)$$

Формула 1.1b представляет второй компонент (компонент тренда) алгоритма Двойного Экспоненциального Сглаживания (DES). Описание этой формулы следующее:

1. $S_t^{(2)}$ – Этот термин представляет оценочный компонент тренда временного ряда на момент времени t . Это результат этой части формулы, указывающий на сглаженную оценку тренда на текущем временном шаге.

2. a : Это параметр сглаживания для компонента тренда. Это значение между 0 и 1, которое определяет, сколько веса отдаётся наиболее недавнему наблюдению в временном ряду. Большее значение a придаёт больше веса недавним изменениям в тренде, делая алгоритм более чувствительным к новым трендам.

3. $S_t^{(1)}$ Этот термин является оценочным уровневый компонентом временного ряда на момент времени t , полученным из первого уравнения алгоритма DES. Он представляет сглаженную оценку значения серии на текущем временном шаге.

4. $(1 - a)$: Эта часть формулы придаёт вес предыдущей оценке тренда. Она дополняет параметр сглаживания a так, что сумма весов составляет 1. Это обеспечивает учёт всего диапазона прошлых данных с акцентом на наиболее последний тренд.

5. $S_{t-1}^{(2)}$: Это оценочный компонент тренда с предыдущего временного шага. Он переносит ранее оценённый тренд в текущий расчёт, обеспечивая непрерывность в оценке тренда.

$S_t^{(1)}$ и $S_t^{(2)}$ используются для расчёта прогнозируемого значения \hat{Y}_{t+T} на момент времени $t+T$ согласно уравнениям (1.1a)-(1.1c)

$$\hat{Y}_{t+T} = a_t + b_t * T \quad (1.2a)$$

$$a_t = 2S_t^{(1)} - S_t^{(2)} \quad (1.2b)$$

$$b_t = \frac{a}{1-a} (S_t^{(1)} - S_t^{(2)}) \quad (1.2c)$$

В этом уравнении a_t рассчитывается с использованием текущей оценки уровня $S_t^{(1)}$ и тренда $S_t^{(2)}$ на момент времени t . Эта формула корректирует уровневый компонент, учитывая текущий тренд.

b_t является компонентом тренда на момент времени t . Он рассчитывается как функция разницы между уровневым и трендовым компонентами, масштабируемая сглаживающим параметром a . Эта формула фиксирует скорость изменения уровня компонента, что является индикатором тренда.

Есть также вариации уравнений для различных методов экспоненциального сглаживания. Различия между этими методами заключаются в их способности учитывать различные характеристики временных рядов, такие как наличие или отсутствие тренда и сезонности, а также аддитивные или мультипликативные изменения. Правильный выбор метода зависит от структуры временного ряда и целей прогнозирования. Использование правильного метода позволяет получить более точные прогнозы и лучше понять динамику данных. Ниже представлены уравнения метода двойного экспоненциального сглаживания:

В приведенной ниже таблице описаны формулы методов DES b процессы в которых можно потенциально применить для предиктивной системы ЛВС:

Таблица 1: примеры методов DES и их применения в предиктивной системе ЛВС:

Методы DES и их формулы	Задачи	Примеры применения
Без тренда и сезонности (N-N) Рекурсивная форма: $S_t = aY_t + (1 - a)S_{t-1}$ Форма коррекции ошибок: $S_t = S_{t-1} + ae_t$	Прогнозирование количества поломок на основе стабильных данных о предыдущих поломках. Анализ временных рядов без явных трендов и сезонных колебаний.	Прогнозирование числа поломок в небольших стабильных сетях. Анализ данных о поломках в сегментах сети без значительных изменений в эксплуатации.
Аддитивный тренд (A-N) Рекурсивная форма: $S_t = aY_t + (1 - a)(S_{t-1} + T_{t-1})$ $T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}$ Форма коррекции ошибок: $S_t = S_{t-1} + T_{t-1} + ae_t$ $T_t = T_{t-1} + \beta e_t$	Прогнозирование числа поломок с учетом линейного увеличения или уменьшения поломок. Анализ данных с постоянным увеличением или уменьшением числа поломок.	Прогнозирование роста числа поломок в сети с увеличивающимся трафиком. Анализ уменьшения числа поломок в сети после обновления оборудования или ПО.
Мультипликативный тренд (M-N) Рекурсивная форма: $S_t = a \frac{Y_t}{I_{t-p}} + (1 - a)(S_{t-1} + T_{t-1})$	Прогнозирование числа поломок с экспоненциальным ростом или спадом.	Прогнозирование поломок в сети с экспоненциально растущей нагрузкой.

$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}$ Форма коррекции ошибок: $S_t = (S_{t-1} + T_{t-1})(1 + \alpha e_t)$ $T_t = T_{t-1} + \beta e_t$	Анализ данных, где изменения числа поломок пропорциональны текущему уровню поломок.	Анализ данных о поломках в сетях, где поломки возрастают экспоненциально с ростом нагрузки.
Аддитивная сезонность (N-A) Рекурсивная форма: $S_t = a(Y_t - I_{t-p}) + (1 - a)S_{t-1}$ $I_t = \gamma(Y_t - S_t) + (1 - \gamma)I_{t-p}$ Форма коррекции ошибок: $S_t = S_{t-1} + \alpha e_t$ $I_t = I_{t-p} + \gamma e_t$	Прогнозирование числа поломок с аддитивными сезонными колебаниями. Анализ данных, где сезонные колебания числа поломок имеют фиксированную амплитуду.	Прогнозирование числа поломок в сети, где пик поломок приходится на определенные периоды (например, перед квартальными отчетами). Анализ данных о поломках в периоды максимальной активности пользователей.
Мультипликативная сезонность (N-M) Рекурсивная форма: $S_t = \alpha \frac{Y_t}{I_{t-p}} + (1 - \alpha)S_{t-1}$ $I_t = \gamma \frac{Y_t}{S_t} + (1 - \gamma)I_{t-p}$ Форма коррекции ошибок: $S_t = S_{t-1} + \alpha e_t$ $I_t = I_{t-p} + \gamma e_t$	Прогнозирование числа поломок с мультипликативными сезонными колебаниями. Анализ данных, где амплитуда сезонных колебаний числа поломок зависит от уровня поломок.	Прогнозирование числа поломок в сетях, где сезонные колебания увеличиваются с ростом нагрузки (например, во время сезонных распродаж или других крупных мероприятий). Анализ данных о поломках в сетях с изменяющимся уровнем сезонных нагрузок.

Метод временных окон (Window-based Time Series Feature Extraction, WTC) (Lewin, et al, 1994; Katircioglu-Öztürk, et al, 2017) представляет собой мощный инструмент для анализа временных рядов, особенно полезный в контексте плотных и крупных наборов данных. Этот метод позволяет выделять важные локальные признаки временного ряда и использовать их для классификации и прогноза.

Основные этапы метода WTC

1. **Предобработка данных:** Регистрация временных рядов заключается в выравнивании временных серий по фиксированному и известному положению, например, моменту времени, когда ожидается определенное событие. Это позволяет унифицировать временные ряды и облегчить их дальнейший анализ.

2. **Определение локальных временных окон:** Временные ряды делятся на неперекрывающиеся и смежные временные окна фиксированной длины. Этот шаг помогает выделить локальные особенности временных рядов.

3. **Оценка сходства на основе расстояния:** Вычисляется евклидово расстояние между экземплярами временного ряда и средней временной серий для каждого окна. Это расстояние используется для оценки сходства временных рядов.

4. Оценка сходимости на основе траекторий: Используются доверительные интервалы для средней временной серии, чтобы определить траектории сходимости. Это помогает учитывать вариации внутри класса и улучшить точность модели.

Как и в методе DES, WTC имеет несколько методов под различные задачи:

Скольльзящее окно (Sliding Window): Скользящее окно перемещается по временной серии с фиксированным шагом. Для каждого положения окна вычисляются статистики или выполняется анализ.

Увеличивающееся окно (Expanding Window): начинается с начальной длины и увеличивается, включая все больше данных.

Покрывающее окно (Covering Window): временной ряд делится на неперекрывающиеся окна фиксированной длины.

Адаптивное окно (Adaptive Window): изменяет свою длину и положение в зависимости от характеристик временного ряда.

Таблица 2: примеры методов WTC и их применения в предиктивной системе ЛВС:

Методы временных окон и их формулы	Задачи	Примеры применения
<p>Скольльзящее окно (Sliding Window) Для временного ряда $X = \{x_1, x_2, \dots, x_n\}$ и окно длиной w: $W_t = \{x_t, x_{t+1}, \dots, x_{t+w-1}\}$ где $t=1, 2, \dots, n-w+1$. Пример расчета средней: $\bar{X}_t = \frac{1}{w} \sum_{i=t}^{t+w-1} x_i$</p>	<p>Обнаружение краткосрочных аномалий в данных. Прогнозирование временных рядов с высоким уровнем динамики.</p>	<p>Прогнозирование трафика в сети: Анализ краткосрочных изменений и всплесков трафика. Мониторинг производительности серверов: Обнаружение краткосрочных аномалий и перегрузок.</p>
<p>Увеличивающееся окно (Expanding Window) Для временного ряда $X = \{x_1, x_2, \dots, x_n\}$ $W_t = \{x_t, x_2, \dots, x_t\}$ где $t=1, 2, \dots, n$. Пример расчета средней: $\bar{X}_t = \frac{1}{t} \sum_{i=1}^t x_i$</p>	<p>Анализ трендов и долгосрочных зависимостей. Построение кумулятивных метрик и обобщающих характеристик временных рядов.</p>	<p>Анализ долгосрочных трендов в данных о поломках ЛВС. Прогнозирование финансовых показателей на основе всей доступной истории данных.</p>
<p>Покрывающее окно (Covering Window) Для временного ряда $X = \{x_1, x_2, \dots, x_n\}$ и окно длиной w: $W_k = \{x_{(k-1)w+1}, x_{(k-1)w+2}, \dots, x_{kw}\}$ где $k=1, 2, \dots, \lfloor \frac{n}{w} \rfloor$. Пример расчета средней: $\bar{X}_k = \frac{1}{w} \sum_{i=(k-1)w+1}^{kw} x_i$</p>	<p>Обнаружение сезонных паттернов и циклических изменений. Анализ временных рядов с повторяющимися структурами.</p>	<p>Обнаружение сезонных колебаний в использовании сети. Анализ потребления ресурсов в сети с циклическими паттернами.</p>

<p>Адаптивное окно (Adaptive Window) Для временного ряда $X = \{x_1, x_2, \dots, x_n\}$ длина окна w_t и положение окна t изменяются в зависимости от условий: $W_t = \{x_t, x_{t+1}, \dots, x_{t+w_t-1}\}$ где t и w_t выбираются в зависимости от текущего состоя ряда (например, диспер- сии, средних значений и т.д.). Пример адаптивное окно на основе дисперсии: Пусть σ_t^2 дисперсия на интервале $\{x_t, x_{t+1}, \dots, x_{t+w_t-1}\}$</p> $\sigma_t^2 = \frac{1}{w_t} \sum_{i=1}^{t+w_t-1} (x_i - \bar{X}_t)^2$ <p>где $\bar{X}_t = \frac{1}{w_t} \sum_{i=t}^{t+w_t-1} x_i$.</p> <p>Длина окно w_t может адаптироваться в зависимости от уровня дисперсии, например:</p> $w_t = \min \left(w_{max}, \max \left(w_{min}, \frac{C}{\sigma_t^2} \right) \right)$ <p>где C – константа, w_{max} и w_{min} – максимальная и минимальная длина окна</p>	<p>Обнаружение резких изменений и переходов в данных. Анализ временных рядов с нерегулярными и случайными изменениями.</p>	<p>Обнаружение резких изменений в трафике сети, связанных с атаками или неисправностями. Анализ данных о поломках, где временные ряды имеют нерегулярные изменения.</p>
---	---	--

1.3 Сравнение методов

Методология оконных данных относится к процессу захвата состояния системы путём наблюдения за её состоянием в течение определенного периода времени, называемого временным окном (Akidau, T., Chernyak, S., & Lax, R., 2018). Временное окно характеризуется своей продолжительностью. Эта продолжительность обычно измеряется во времени (например, 5 минут, 1 час или 1 раз в день). В некоторых случаях, когда данные представлены в виде дискретных событий, длина или вместимость окна может измеряться в количестве образцов (Gwadera, R., Atallah, M. J., & Szpankowski, W., 2005) (например, последние сто произошедших событий в системе мониторинга или последние двадцать образцов, полученных датчиком).

Данные, собранные во временном интервале, объединяются и представляются в виде численных переменных. Тип агрегации, который применяется, зависит от проблемы. В некоторых случаях это может быть подсчёт событий, скользящая средняя или другие специфические для области типы агрегации. В задачах прогнозирования окно, с помощью которого формируется вход моделей, известно, как «окно наблюдения». В этих ситуациях необходимо определить окно, которое определяет время действия прогноза или вывода. Это второе окно называется окном прогноза или временем прогноза (Salfner, F., Lenk, M., & Malek, M., 2010).

В онлайн-прогнозировании сбоев текущий момент обозначается как t . Сбои прогнозируются с некоторым запасом времени t_p , который должен быть больше минимального времени предупреждения t_w . Прогноз считается действительным в течение определенного периода времени, называемого периодом прогноза, t_p . Для осуществления прогноза используются данные вплоть до временного горизонта t_d , который называется размером окна данных (рисунок 1.1) (Salfner, F., Lenk, M., & Malek, M., 2010).

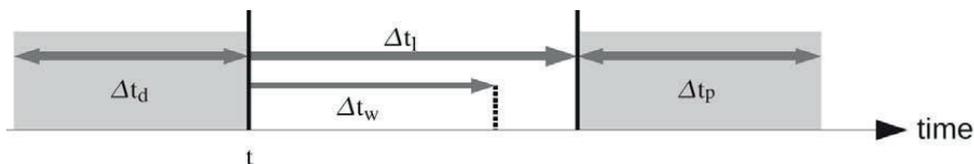


Рисунок 1.1 – Схема онлайн-прогноза

Окно наблюдения играет ключевую роль в способности модели изучать систему для определения выходных данных. Размер (длина) окна указывает на количество информации, которое оно может содержать, и напрямую связано с характером данных, который может варьироваться от секунд (Sahoo, R. K., Oliner, A. J., Rish, I., Gupta, M., Moreira, J. E., Ma, S., ... & Sivasubramaniam, A., 2003, August) до часов 26 (Fu, S., & Xu, C. Z., 2007, November) и даже дней (Li, J., Stones, R. J., Wang, G., Liu, X., Li, Z., & Xu, M., 2017). Выявление оптимального размера для каждого проекта является нерешённым вопросом в научной литературе, хотя было предложено различные методы. В некоторых случаях авторы сами выбирают размер окна без обсуждения его влияния (Chuah, E., Jhumka, A., Narasimhamurthy, S., Hammond, J., Browne, J. C., & Barth, B., 2013, September). Другие используют поиск по сетке для изучения влияния длины окна на производительность модели (Fulp, E. W., Fink, G. A., & Naack, J. N., 2008); Li, J., Ji, X., Jia, Y., Zhu, B., Wang, G., Li, Z., & Liu, X., 2014, June). Также применяются более сложные методы, такие как использование генетического алгоритма для определения оптимального размера окна, как показано в исследованиях Вайса и др. в нескольких статьях (Weiss, G., 2002; Weiss, G. M., 1999, July; Weiss, G. M., & Hirsh, H., 2000, July).

Что касается размера окна прогнозирования, он меняется в зависимости от изучаемой проблемы и может варьироваться от минут до дней или больше. Прогнозы, связанные с отказами жёстких дисков или компонентов аппаратного обеспечения, могут иметь окна в несколько часов (Chuah, E., Jhumka, A., Narasimhamurthy, S., Hammond, J., Browne, J. C., & Barth, B., 2013, September; Yang, W., Hu, D., Liu, Y., Wang, S., & Jiang, T., 2015, September), в то время как прогнозы, связанные с обнаружением вторжений в облачных системах, могут потребовать окно в минутах (Kholidy, H. A., Erradi, A., Abdelwahed, S., Yousof, A. M., & Ali, H. A., 2014, November). Иногда окно может быть определено количеством использований, а не временным измерением, как в прогнозах, связанных с физическими компонентами (Dangut, M. D., Skaf, Z., & Jennions, I. K., 2021). В (Yu, L., Zheng, Z., Lan, Z., & Coghlan, S., 2011, June) был предложен альтернативный подход, известный как прогнозирование на основе событий (в отличие от традиционного оконного прогнозирования).

Этот метод устраняет окно прогнозирования, подтверждая прогнозы в один момент времени, который отделяется от окна наблюдения временем, называемым время набега.

Другим методом прогнозирования во временном промежутке является метод двойного экспоненциального сглаживания (Double Exponential Smoothing (DES)), широко применяемый в анализе временных рядов. Данный метод разработан для более точного прогнозирования данных, содержащих как уровни (или базовые значения), так и тренды. Этот метод является расширением простого экспоненциального сглаживания и особенно эффективен в случаях, когда данные демонстрируют трендовую составляющую. Это может включать прогнозирование продаж, погоды, финансовых индикаторов и, в вашем случае, отказов оборудования в системах ЛВС.

Примером использования этого метода можно указать результаты исследования (Wang, Z., Zhang, M., Wang, D., Song, C., Liu, M., Li, J., ... & Liu, Z., 2017) где группа исследователей смогли комбинировать метод DES с алгоритмом МО, использующим метод опорных векторов. В этом исследовании особое внимание уделяется моделям, учитывающим риски в оптических сетях, и исследуется, как спрогнозировать риск отказа оборудования. Результаты экспериментов показали среднюю точность прогнозирования состояния отказа оптического оборудования 95%.

Другие исследования также изучали эффективность использования метода DES в различных контекстах прогнозирования. Например, в исследовании (Wiyanti, W., 2023) оценивается эффективность экспоненциального сглаживания для прогнозирования данных временных рядов с тенденциями и несезонными характеристиками, обнаружив, что методы экспоненциального сглаживания эффективны для таких данных. В другом исследовании (Shabir, F., Abdullah, A. I., & Nur, S. A. A., 2022, December) применяется двойное экспоненциальное сглаживание для прогнозирования факторов окружающей среды, таких как осадки и температура. В работе (Yousuf, M. U., Al-Bahadly, I., & Avci, E., 2022) исследователи представили гибридную модель, основанную на двойном экспоненциальном сглаживании, для прогнозирования скорости ветра, подчёркивающий преимущества этой модели по сравнению с традиционными моделями МО. Также метод DES применялся в исследовании (Sabarina, A. M., Rustamaji, H. S., & Himawan, H., 2021) для прогнозирования продаж лекарств.

Если сравнить эти два метода, метод оконных данных и метод двойного экспоненциального сглаживания, можно выделить преимущества и недостатки каждого из методов (таблица 1.3).

Таблица 1.3 – Сравнение методов оконных данных и двойного экспоненциального сглаживания

Сравнение	Метод оконных данных	Метод двойного экспоненциального сглаживания (DES)
Преимущества	Сосредоточенность на последних тенденциях: Сосредоточив внимание на последних данных, использование метода оконных данных может сделать модель более чувствительной к недавним изменениям и аномалиям.	Осведомлённость о тенденциях: DES эффективно фиксирует как уровень, так и тенденцию данных, что может иметь решающее значение для прогнозирования сбоев, которые возникают постепенно

	Гибкость: размер окна можно регулировать, чтобы сбалансировать актуальность и объём рассматриваемых данных.	Эффект сглаживания: сглаживает краткосрочные колебания, что может быть полезно для уменьшения шума в прогнозе.
	Уменьшенная сложность: анализ меньшего набора данных может снизить сложность вычислений и повысить скорость обработки.	Использует более полный набор данных для создания более обоснованных прогнозов.
Недостатки	<i>Потеря исторического контекста.</i> Сосредоточение внимания на меньшем окне данных может привести к потере важных исторических тенденций и закономерностей.	<i>Задержка реакции:</i> DES может не реагировать быстро на внезапные изменения или аномалии, поскольку по своей сути он сглаживает недавние наблюдения. Но этот недостаток можно нивелировать, используя другие алгоритмы МО параллельно с DES.
	<i>Чувствительность параметра:</i> Выбор размера окна может существенно повлиять на производительность модели.	<i>Допущение линейности:</i> DES предполагает линейный тренд, который не всегда подходит для сложных, нелинейных закономерностей в данных об отказах

Подводя итог сравнения двух методов, хочется заметить, что, если характер сбоев в коммутаторах локальной сети демонстрирует чёткую тенденцию с течением времени, DES может оказаться более подходящим. Однако, если сбои более резкие или недавние данные более указывают на будущие сбои, оконное управление может быть лучше.

Что касается вычислительных ресурсов то для крупномасштабных сетей вычислительная эффективность WTC может быть более практичной. Однако это требует дальнейших исследований, так-как тот же метод DES совместно с другими алгоритмами МО могут дать не менее эффективный результат.

После анализа множества работ проведенной в разделе «Материалы и методы», а также учитывая особенности исследуемого объекта, описанных в работе авторов (Rzayeva, L., Myrzatay, A., Abitova, G., Sarinova, A., Kulniyazova, K., Saoud, B., & Shayea, I., 2023), был выбран метод DES как более приемлемый метод для решения поставленных задач при формировании предиктивной системы. Более подробно об использовании метода DES совместно с другими алгоритмами МО описаны в других работах авторов (Rzayeva, L., Myrzatay, A., Abitova, G., Sarinova, A., Kulniyazova, K., Saoud, B., & Shayea, I., 2023; Myrzatay, A., Rzayeva, L., Bandini, S., Shayea, I., Saoud, B., Çolak, I., & Kayisli, K., 2024).

3. Результаты и обсуждение: Применение метода DES в прогностической модели:

Как говорилось в разделах «Материалы и методы», а также, как описывалось в других работах авторов (Rzayeva, L., Myrzatay, A., Abitova, G., Sarinova, A., Kulniyazova, K., Saoud, B., & Shayea, I., 2023; Myrzatay, A., Rzayeva, L., Bandini, S., Shayea, I., Saoud, B., Çolak, I., & Kayisli, K., 2024), для прогнозирования тренда параметров (Myrzatay, A., Rzayeva, L., Bandini,

S., Shayea, I., Saoud, B., Çolak, I., & Kayisli, K., 2024) данных на момент (\hat{Y}_{T+1}) был применён метод двойного экспоненциального сглаживания. Результаты прогноза тренда были следующими: при попытке выявить тренд параметра «Temperature» (рисунок 3.1), метод DES показал, что разность значений между предсказанными и наблюдаемыми значениями не велик, и колеблется от 1 (min) до 10 (max) значений. Красная линия показывает сглаженный тренд, который отражает общее направление и динамику изменений температуры. Из графика видно, что модель DES эффективно выявляет основные тенденции в данных, позволяя лучше понять общее направление изменений температуры. Средний абсолютный процент ошибок (MAPE) равен примерно 5.25%. Это указывает на то, что в среднем предсказания отклоняются от фактических значений на 5.25%.

Средний абсолютный процент ошибок (MAPE) измеряет относительную точность модели и рассчитывается как среднее абсолютных процентов ошибок по всем наблюдениям и высчитывается следующим образом:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3.1)$$

где n-это количество наблюдений;

y_i -фактические значения;

\hat{y}_i – предсказанные значения.

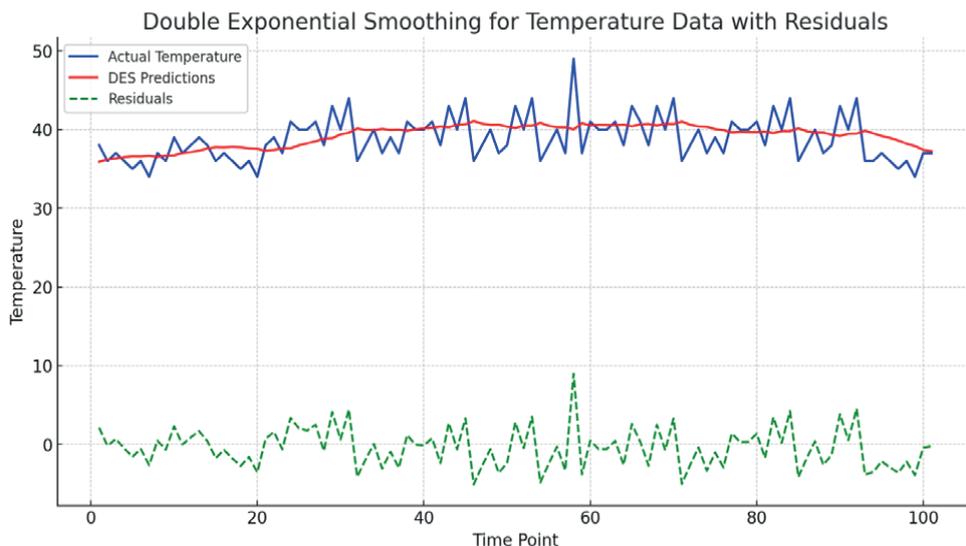


Рисунок 3.1 – Прогноз показателей параметра «Temperature» методом DES

RMSE, или Среднеквадратичная ошибка (Root Mean Square Error), измеряет среднее значение квадратов ошибок, то есть разности между предсказанными значениями модели и фактическими значениями данных и его формула (3.2):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \tag{3.2}$$

В данном случае, показатель RMSE приблизительно равна 2.56. Это говорит о том, что в среднем предсказания данной модели отклоняются от фактических значений на 2.56 единицы температуры, что является очень неплохим результатом в данном случае.

Далее DES был применён на параметр «CPU Load» для годичной записи (365 записей), и как показывает график, DES успешно справляется с прогнозированием трендов этого параметра (рисунок 3.2). Среднеквадратичная ошибка (RMSE) в данном случае в среднем, отклоняются от фактических значений на 0.2486 единицы. Средний абсолютный процент ошибок (MAPE) равен 1.1490%. Другими словами, метод DES для параметра «CPU Load» показывал очень неплохие результаты.

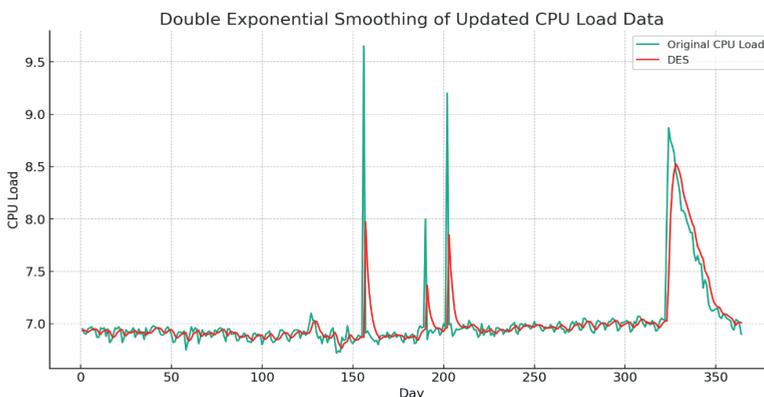


Рисунок 3.2 – Прогноз показателей параметра «CPU Load» методом DES

Далее представлены результаты применения метода DES на параметры «Traffic index» и «Response time index» на рисунках 3.3 и 3.4 соответственно.

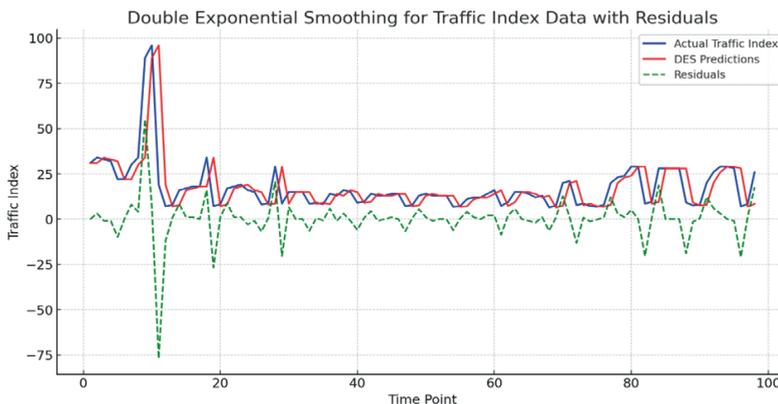


Рисунок 3.3 – Прогноз показателей параметра «Traffic index» методом DES.

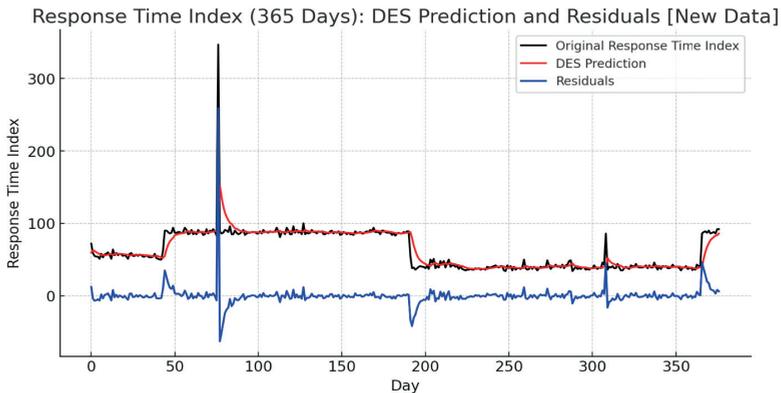


Рисунок 3.4 – Прогноз показателей параметра «Response time index» методом DES

Заклучение:

Как видно из представленных (рисунки 3.1, 3.2, 3.3, 3.4) визуализации работы двойного экспоненциального сглаживания по каждому из приведённых в пример параметров, при плавном изменении параметров, результат прогнозирования имеет высокую точность. Однако, при резком изменении показателей, точность данных на короткое время снижается. Основной причиной этого является недостаточное количество точек данных, из-за чего алгоритм не может гладко соответствовать изменениям. Тем не менее, DES все же демонстрирует высокую точность предсказаний. А показатели MAPE и RMSE для этих параметров были не столь высоки, что свидетельствует о том, что модель в целом хорошо справляется с прогнозированием, хотя и с некоторыми отклонениями от фактических значений. В других работах авторов (Rzayeva, et al, 2023; Myrzatay, et al, 2024) метод DES комбинировался с алгоритмами МО для классификации поломок, и согласно итогам тех работ, комбинированный метод на основе DES получился в высокой степени точным и быстроедейственным.

References

- Chen, J. H., & Asch, S. M. (2017). Machine learning and prediction in medicine—beyond the peak of inflated expectations. *The New England journal of medicine*, 376(26), 2507. <https://doi.org/10.1056%2FNEJMp1702071>
- Weng, S. F., Reys, J., Kai, J., Garibaldi, J. M., & Qureshi, N. (2017). Can machine-learning improve cardiovascular risk prediction using routine clinical data?. *PloS one*, 12(4), e0174944. <https://doi.org/10.1371/journal.pone.0174944>
- Athey, S. (2018). The impact of machine learning on economics. *The economics of artificial intelligence: An agenda*, 507-547pp. <https://doi.org/10.7208/9780226613475-023>
- Asim, K. M., Martínez-Álvarez, F., Basit, A., & Iqbal, T. (2017). Earthquake magnitude prediction in Hindukush region using machine learning techniques. *Natural Hazards*, 85, 471-486. <https://doi.org/10.1007/s11069-016-2579-3>
- Kong, Q., Trugman, D. T., Ross, Z. E., Bianco, M. J., Meade, B. J., & Gerstoft, P. (2019). Machine learning in seismology: Turning data into insights. *Seismological Research Letters*, 90(1), 3-14. <https://doi.org/10.1785/0220180259>

- Sasisekharan, R., Seshadri, V., & Weiss, S. M. (1996). Data mining and forecasting in large-scale telecommunication networks. *IEEE expert*, 11(1), 37-43. <https://doi.org/10.1109/64.482956>
- Challagulla, V. U. B., Bastani, F. B., Yen, I. L., & Paul, R. A. (2008). Empirical assessment of machine learning based software defect prediction techniques. *International Journal on Artificial Intelligence Tools*, 17(02), 389-400. <https://doi.org/10.1142/S0218213008003947>
- Liang, Y., Zhang, Y., Sivasubramaniam, A., Jette, M., & Sahoo, R. (2006, June). Bluegene/l failure analysis and prediction models. In *International Conference on Dependable Systems and Networks (DSN'06)* (pp. 425-434). IEEE. <https://doi.org/10.1109/DSN.2006.18>
- Lima, R. F., & Pereira, A. C. M. (2015, December). A fraud detection model based on feature selection and undersampling applied to web payment systems. In *2015 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology (WI-IAT)* (Vol. 3, pp. 219-222). IEEE. <https://doi.org/10.1109/WI-IAT.2015.13>
- Salfner, F., Lenk, M., & Malek, M. (2010). A survey of online failure prediction methods. *ACM Computing Surveys (CSUR)*, 42(3), 1-42. <https://doi.org/10.1145/1670679.1670680>
- Hamerly, G., & Elkan, C. (2001, June). Bayesian approaches to failure prediction for disk drives. In *ICML* (Vol. 1, No. 2001, pp. 202-209). <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=0173d1fb01ff1a28b425960bce99798dd70befd5>
- Pelaez, A., Quiroz, A., Browne, J. C., Chuah, E., & Parashar, M. (2014, December). Online failure prediction for hpc resources using decentralized clustering. In *2014 21st International Conference on High Performance Computing (HiPC)* (pp. 1-9). IEEE. <https://doi.org/10.1109/HiPC.2014.7116903>
- Chigurupati, A., Thibaux, R., & Lassar, N. (2016, January). Predicting hardware failure using machine learning. In *2016 Annual Reliability and Maintainability Symposium (RAMS)* (pp. 1-6). IEEE. <https://doi.org/10.1109/RAMS.2016.7448033>
- Weiss, G. (2002). Predicting telecommunication equipment failures from sequences of network alarms. *Handbook of Knowledge Discovery and Data Mining*, 891-896. https://www.researchgate.net/profile/Gary-Weiss-2/publication/2628375_Predicting_Telecommunication_Equipment_Failures_from_Sequences_of_Network_Alarms/links/00b49524049db65282000000/Predicting-Telecommunication-Equipment-Failures-from-Sequences-of-Network-Alarms.pdf
- Shatnawi, M., & Hefeeda, M. (2015, April). Real-time failure prediction in online services. In *2015 IEEE Conference on Computer Communications (INFOCOM)* (pp. 1391-1399). IEEE. <https://doi.org/10.1109/INFOCOM.2015.7218516>
- Weiss, G. M., & Hirsh, H. (1998, July). Learning to predict rare events in categorical time-series data. In *International Conference on Machine Learning* (pp. 83-90). <https://cdn.aaai.org/Workshops/1998/WS-98-07/WS98-07-015.pdf>
- Agarwal, V., Bhattacharyya, C., Niranjan, T., & Susarla, S. (2009, December). Discovering rules from disk events for predicting hard drive failures. In *2009 International Conference on Machine Learning and Applications* (pp. 782-786). IEEE. <https://doi.org/10.1109/ICMLA.2009.62>
- Borkowski, M., Fdhila, W., Nardelli, M., Rinderle-Ma, S., & Schulte, S. (2019). Event-based failure prediction in distributed business processes. *Information Systems*, 81, 220-235. <https://doi.org/10.1016/j.is.2017.12.005>
- Gardner Jr, E. S. (1985). Exponential smoothing: The state of the art. *Journal of forecasting*, 4(1), 1-28. <https://doi.org/10.1002/for.3980040103>
- Gardner Jr, E. S. (2006). Exponential smoothing: The state of the art—Part II. *International journal of forecasting*, 22(4), 637-666. <https://doi.org/10.1016/j.ijforecast.2006.03.005>
- Lewin, D. R., & Harmaty, Y. (1994). Predictive maintenance using PCA. *IFAC Proceedings Volumes*, 27(2), 439-444. [https://doi.org/10.1016/S1474-6670\(17\)48189-4](https://doi.org/10.1016/S1474-6670(17)48189-4)
- Katircioglu-Öztürk, D., Güvenir, H. A., Ravens, U., & Baykal, N. (2017). A window-based time series feature extraction method. *Computers in biology and medicine*, 89, 466-486. <https://doi.org/10.1016/j.combiomed.2017.08.011>
- Akidau, T., Chernyak, S., & Lax, R. (2018). Streaming systems: the what, where, when, and how of large-scale data processing. “O’Reilly Media, Inc.”. <https://dl.acm.org/doi/abs/10.5555/3294646>
- Gwadera, R., Atallah, M. J., & Szpankowski, W. (2005). Reliable detection of episodes in event

sequences. *Knowledge and Information Systems*, 7, 415-437. <https://doi.org/10.1007/s10115-004-0174-5>

Sahoo, R. K., Oliner, A. J., Rish, I., Gupta, M., Moreira, J. E., Ma, S., ... & Sivasubramaniam, A. (2003, August). Critical event prediction for proactive management in large-scale computer clusters. In *Proceedings of the ninth ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 426-435). <https://doi.org/10.1145/956750.956799>

Fu, S., & Xu, C. Z. (2007, November). Exploring event correlation for failure prediction in coalitions of clusters. In *Proceedings of the 2007 ACM/IEEE conference on Supercomputing* (pp. 1-12). <https://doi.org/10.1145/1362622.1362678>

Li, J., Stones, R. J., Wang, G., Liu, X., Li, Z., & Xu, M. (2017). Hard drive failure prediction using decision trees. *Reliability Engineering & System Safety*, 164, 55-65. <https://doi.org/10.1016/j.res.2017.03.004>

Chuah, E., Jhumka, A., Narasimhamurthy, S., Hammond, J., Browne, J. C., & Barth, B. (2013, September). Linking resource usage anomalies with system failures from cluster log data. In *2013 IEEE 32nd International Symposium on Reliable Distributed Systems* (pp. 111-120). IEEE. <https://doi.org/10.1109/SRDS.2013.20>

Fulp, E. W., Fink, G. A., & Haack, J. N. (2008). Predicting Computer System Failures Using Support Vector Machines. *WASL*, 8, 5-5. <https://dl.acm.org/doi/abs/10.5555/1855886.1855891>

Li, J., Ji, X., Jia, Y., Zhu, B., Wang, G., Li, Z., & Liu, X. (2014, June). Hard drive failure prediction using classification and regression trees. In *2014 44th annual IEEE/IFIP international conference on dependable systems and networks* (pp. 383-394). IEEE. <https://doi.org/10.1109/DSN.2014.44>

Weiss, G. M. (1999, July). Timeweaver: A genetic algorithm for identifying predictive patterns in sequences of events. In *Proceedings of the 1st Annual Conference on Genetic and Evolutionary Computation-Volume 1* (pp. 718-725). <https://dl.acm.org/doi/abs/10.5555/2933923.2933992>

Weiss, G. M., & Hirsh, H. (2000, July). Learning to predict extremely rare events. In *AAAI workshop on learning from imbalanced data sets* (Vol. 5, p. 4). Austin: AAAI Press. <https://aaai.org/papers/WS00-05-013-learning-to-predict-extremely-rare>

Yang, W., Hu, D., Liu, Y., Wang, S., & Jiang, T. (2015, September). Hard drive failure prediction using big data. In *2015 IEEE 34th Symposium on Reliable Distributed Systems Workshop (SRDSW)* (pp. 13-18). IEEE. <https://doi.org/10.1109/SRDSW.2015.15>

Kholidy, H. A., Erradi, A., Abdelwahed, S., Yousof, A. M., & Ali, H. A. (2014, November). Online risk assessment and prediction models for autonomic cloud intrusion prevention systems. In *2014 IEEE/ACS 11th International Conference on Computer Systems and Applications (AICCSA)* (pp. 715-722). IEEE. <https://doi.org/10.1109/AICCSA.2014.7073270>

Dangut, M. D., Skaf, Z., & Jennions, I. K. (2021). An integrated machine learning model for aircraft components rare failure prognostics with log-based dataset. *ISA transactions*, 113, 127-139. <https://doi.org/10.1016/j.isatra.2020.05.001>

Yu, L., Zheng, Z., Lan, Z., & Coghlan, S. (2011, June). Practical online failure prediction for blue gene/p: Period-based vs event-driven. In *2011 IEEE/IFIP 41st International Conference on Dependable Systems and Networks Workshops (DSN-W)* (pp. 259-264). IEEE. <https://doi.org/10.1109/DSNW.2011.5958823>

Wang, Z., Zhang, M., Wang, D., Song, C., Liu, M., Li, J., ... & Liu, Z. (2017). Failure prediction using machine learning and time series in optical network. *Optics Express*, 25(16), 18553-18565. <https://doi.org/10.1364/OE.25.018553>

Wiyanti, W. (2023). Effectiveness of Single and Double Exponential Smoothing: SES, ARSES and Holt's Linear for Time Series Data Prediction with Trend and Non-seasonal Characteristic (Covid-19 Vaccinate Case): Efektivitas Metode Exponential Smoothing untuk Prediksi Data Runtun Waktu Pola Tren dan Non-musiman (Studi Kasus Cakupan Vaksinasi Covid-19). *Jurnal Matematika, Statistika dan Komputasi*, 20(1), 52-64. <https://doi.org/10.20956/j.v20i1.27193>

Shabir, F., Abdullah, A. I., & Nur, S. A. A. (2022, December). Implementation Of The Double Exponential Smoothing Method In Determining The Planting Time In Strawberry Plantations. In *Proceedings Of The First Jakarta International Conference On Multidisciplinary Studies Towards*

Creative Industries, Jicoms 2022, 16 November 2022, Jakarta, Indonesia: Jicoms 2022 (p. 50). <https://doi.org/10.31315/telematika.v19i2.7544>

Yousuf, M. U., Al-Bahadly, I., & Avci, E. (2022). Wind speed prediction for small sample dataset using hybrid first-order accumulated generating operation-based double exponential smoothing model. *Energy Science & Engineering*, 10(3), 726-739. <https://doi.org/10.1002/ese3.1047>

Sabarina, A. M., Rustamaji, H. C., & Himawan, H. (2021). Prediction Of Drug Sales Using Methods Forecasting Double Exponential Smoothing (Case Study: Hospital Pharmacy of Condong Catur). *Telematika: Jurnal Informatika dan Teknologi Informasi*, 18(1), 106-117. <https://doi.org/10.31315/telematika.v18i1.4586>

Rzayeva, L., Myrzatay, A., Abitova, G., Sarinova, A., Kulniyazova, K., Saoud, B., & Shayea, I. (2023). Enhancing LAN Failure Predictions with Decision Trees and SVMs: Methodology and Implementation. *Electronics*, 12(18), 3950. <https://doi.org/10.3390/electronics12183950>

Myrzatay, A., Rzayeva, L., Bandini, S., Shayea, I., Saoud, B., Çolak, I., & Kayisli, K. (2024). Predicting LAN Switch Failures: An Integrated Approach with DES and Machine Learning Techniques (RF/LR/DT/SVM). *Results in Engineering*, 102356. <https://doi.org/10.1016/j.rineng.2024.102356>

CONTENTS

INFORMATION AND COMMUNICATION TECHNOLOGIES

M. Aitimov, R.U Almenayeva, K.K. Makulov, A.B. Ostayeva, R. Muratkhan APPLICATION OF MACHINE LEARNING METHOD TO ANALYZE AND EXTRACT SEMANTIC STRUCTURES FROM SCIENTIFIC TEXTS.....	5
A.K. Aitim, G.K. Sembina MODELING OF HUMAN BEHAVIOR FOR SMARTPHONE WITH USING MACHINE LEARNING ALGORITHM.....	17
G. Aksholak, A. Bedelbayev, R. Magazov ANALYSIS AND COMPARISON OF MACHINE LEARNING METHODS FOR MALWARE DETECTION.....	29
A.L. Alexeyeva SUBSONIC VIBROTRANSPORT SOLUTIONS OF THE WAVE EQUATION IN SPACES OF DIMENSION $N=1,2,3$	42
K. Bagitova, Sh. Mussiraliyeva, K. Azanbai ANALYSIS OF SYSTEMS FOR RECOGNIZING POLITICAL EXTREMISM IN ONLINE SOCIAL NETWORKS.....	60
A.S. Baegizova, G.I. Mukhamedrakhimova, I. Bapiyev, M.Zh. Bazarova, U.M. Smailova EVALUATING THE EFFECTIVENESS OF MACHINE LEARNING METHODS FOR KEYWORD COVERAGE.....	73
G. Bekmanova, B. Yergesh, G. Yelibayeva, A. Omarbekova, M. Strecker MODELING THE RULES AND CONDITIONS FOR CONDUCTING PRE-ELECTION DEBATES.....	89
M. Bolatbek, M. Sagynay, Sh. Mussiraliyeva USING MACHINE LEARNING METHODS FOR DETECTING DESTRUCTIVE WEB CONTENT IN KAZAKH LANGUAGE.....	99
Y. Golenko, A. Ismailova, K. Kadirkulov, R. Kalendar DEVELOPMENT OF AN ONLINE PLATFORM FOR SEARCHING FOR TANDEM REPEATS USING WHOLE GENOME SEQUENCING.....	112

T. Zhukabayeva, L. Zholshiyeva, N. Karabayev, Sh. Akhmetzhanova A BIBLIOMETRIC ANALYSIS OF EDGE COMPUTING IN INDUSTRIAL INTERNET OF THINGS (IIoT) CYBER-PHYSICAL SYSTEMS.....	123
S.S. Koishybay, N. Meirambekuly, A.E. Kulakaeva, B.A. Kozhakhmetova, A.A. Bulin DEVELOPMENT OF THE DESIGN OF A MULTI-BAND DISCONE ANTENNA.....	138
A. Kydyrbekova, D. Oralbekova SPEAKER IDENTIFICATION USING DISTRIBUTION-PRESERVING X-VECTOR GENERATION.....	152
B. Medetov, A. Nurlankyzy, A. Akhmediyarova, A. Zhetpisbayeva, D. Zhexebay COMPARATIVE ANALYSIS OF THE EFFECTIVENESS OF NEURAL NETWORKS WITHIN THE LOW SNR.....	163
A.A Myrzatay, L.G. Rzaeva, B. Zhumadilla, A.A. Mukhanova, G.A. Uskenbayeva DOUBLE EXPONENTIAL SMOOTHING AND TIME WINDOW METHODS FOR PREDICTIVE LAN MONITORING: ANALYSIS, COMPARISON AND APPLICATION.....	174
L. Naizabayeva, M.N. Satymbekov PREDICTING URBAN SOIL POLLUTION USING MACHINE LEARNING ALGORITHMS.....	194
A.U. Mukhiyadin, U.T. Makhazhanova, A.Z. Alimagambetova, A.A. Mukhanova, A.I. Akmoldina PREDICTING STUDENT LEARNING ENGAGEMENT USING MACHINE LEARNING TECHNIQUES: ANALYSIS OF EDUCATION DATA IN KAZAKHSTAN.....	204
Zh. Tashenova, Zh. Abdugulova, Sh. Amanzholova, E. Nurlybaeva PENETRATION TESTING APPROACHES EMPLOYING THE OPENVAS VULNERABILITY MANAGEMENT UTILITY.....	218
D.B. Tyulemissova, A.K. Shaikhanova, V. Martsenyuk, G.A. Uskenbayeva MODERN APPROACHES TO STUDYING THE DYNAMICS OF INFORMATION FLOW IN SOCIAL MEDIA BASED ON MACHINE LEARNING METHODS.....	231

МАЗМҰНЫ

АҚПАРАТТЫҚ-КОММУНИКАЦИЯЛЫҚ ТЕХНОЛОГИЯЛАР

М. Айтимов, Р.У Альменаева, К.К. Макулов, А.Б. Остаева, Р. Муратхан
ҒЫЛЫМИ МӘТІНДЕРДЕН СЕМАНТИКАЛЫҚ ҚҰРЫЛЫМДАРДЫ
ТАЛДАУ ЖӘНЕ АЛУ ҮШІН МАШИНАЛЫҚ ОҚЫТУ ӘДІСІН
ҚОЛДАНУ.....5

Ә.Қ. Әйтiм, Г.К. Сембина
МАШИНАЛЫҚ ОҚУ АЛГОРИТМІН ПАЙДАЛАНЫП СМАРТФОН
ҮШІН АДАМ МІНЕЗІН МОДЕЛДЕУ.....17

Г.И. Ақшолақ, А.А. Бедельбаев, Р.С. Мағазов
ЗИЯНДЫ БАҒДАРЛАМАЛАРДЫ АНЫҚТАУҒА АРНАЛҒАН
МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН ТАЛДАУ ЖӘНЕ САЛЫСТЫРУ.....29

А.Л. Алексеева
N=1,2,3 ӨЛШЕМДІ КЕҢІСТІГІНДЕГІ ТОЛҚЫНДЫҚ ТЕҢДЕУДІҢ
ДЫБЫСҚА ДЕЙІНГІ ДІРІЛКӨЛІКТІК ШЕШІМДЕРІ.....42

Қ.Б. Бағитова, Ш.Ж. Мусиралиева, Қ. Азанбай
ӘЛЕУМЕТТІК ЖЕЛІЛЕРДЕГІ САЯСИ ЭКСТРЕМИЗМДІ ОНЛАЙН ТАҢУ
ЖҮЙЕЛЕРІН ТАЛДАУ.....60

**А.С. Баегизова, Г.И. Мухамедрахимова, И.М. Бапиев, М.Ж. Базарова,
У.М. Смайлова**
ТҮЙІН СӨЗДЕРДІ ҚАМТУ ҮШІН МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІНІҢ
ТИІМДІЛІГІН БАҒАЛАУ.....73

**Г.Т. Бекманова, Б.Ж. Ергеш, Г.К. Елибаева, А.С. Омарбекова,
М. Strecker**
САЙЛАУ АЛДЫНДАҒЫ ПІКІРТАЛАСТАРДЫ ӨТКІЗУ ЕРЕЖЕЛЕРІ
МЕН ШАРТТАРЫН МОДЕЛЬДЕУ.....89

М.А. Болатбек, М.Сағынай, Ш.Ж. Мусиралиева
ҚАЗАҚ ТІЛІНДЕГІ ДЕСТРУКТИВТІ ВЕБ-КОНТЕНТТІ АНЫҚТАУ ҮШІН
МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН ҚОЛДАНУ.....99

Е.С. Голенко, А.А. Исмаилова, К.К. Кадиркулов, Р.Н. Календарь
ТОЛЫҚ ГЕНОМДЫҚ СЕКВЕНИРЛЕУДЕ ТАНДЕМДІК
ҚАЙТАЛАНУЛАРДЫ ІЗДЕУ ҮШІН ОНЛАЙН ПЛАТФОРМАСЫН
ӘЗІРЛЕУ.....112

- Т. Жукабаева, Л. Жолшиева, Н. Карабаев, Ш. Ахметжанова**
ӨНДІРІСТІК ЗАТТАР ИНТЕРНЕТІ (IoT) КИБЕРФИЗИКАЛЫҚ
ЖҮЙЕЛЕРІНДЕ ШЕТКІ ЕСЕПТЕУЛЕРДІ ҚОЛДАНУҒА
БИБЛИОМЕТРИЯЛЫҚ ТАЛДАУ.....123
- С.С. Қойшыбай, Н. Мейрамбекұлы, А.Е. Кулакаева, Б.А. Кожаметова,
А.А. Булин**
КӨПДИАПАЗОНДЫДИСКОНУСТЫҚАНТЕННАКОНСТРУКЦИЯСЫН
ӘЗІРЛЕУ.....138
- А.С. Кыдырбекова, Д.О. Оралбекова**
ТАРАТУДЫ САҚТАЙТЫН Х-ВЕКТОРЛАР ГЕНЕРАЦИЯСЫН
ПАЙДАЛАНЫП ДАУЫСТЫ ИДЕНТИФИКАЦИЯЛАУ.....152
- Б. Медетов, А. Нурланқызы, А. Ахмедиярова, А. Жетписбаева, Д. Жексебай**
СИГНАЛШУЫЛ ҚАТЫНАСЫ ТӨМЕН ЖАҒДАЙДА НЕЙРОНДЫҚ
ЖЕЛЛЕРДІҢ ТИІМДІЛІГІНЕ САЛЫСТЫРМАЛЫ ТАЛДАУ ЖАСАУ.....163
- А.А. Мырзатай, Л.Г. Рзаева, Б. Жұмаділла, А.А. Муханова,
Г.А. Ускенбаева**
ЖЕРГІЛІКТІ ЖЕЛІНІ БОЛЖАМДЫ БАҚЫЛАУҒА АРНАЛҒАН ҚОС
ЭКСПОНЕНЦИАЛДЫ ТЕГІСТЕУ ЖӘНЕ УАҚЫТ ТЕРЕЗЕЛЕРІНІҢ
ӘДІСТЕРІ: ТАЛДАУ, САЛЫСТЫРУ ЖӘНЕ ҚОЛДАНУ.....174
- Л. Найзабаева, М.Н. Сатымбеков**
МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІН ПАЙДАЛАНУ АРҚЫЛЫ
ҚАЛА ТОПЫРАҒЫНЫҢ ЛАСТАНУЫН БОЛЖАУ.....194
- А.Ұ. Мұхиядин, У.Т. Махажанова, А.З. Алимагамбетова, А.А.Муханова,
А.И. Акмолдина**
МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІН ПАЙДАЛАНА ОТЫРЫП,
ОҚУШЫЛАРДЫҢ БІЛІМ АЛУҒА ЫНТАСЫН БОЛЖАУ:
ҚАЗАҚСТАНДАҒЫ БІЛІМ БЕРУ ДЕРЕКТЕРІН ТАЛДАУ.....204
- Ж.М. Ташенова, Ж.К. Абдугулова, Ш.А. Аманжолова, Э. Нурлыбаева**
OPENVAS ОСАЛДЫҒЫН БАСҚАРУ УТИЛИТАСЫН ҚОЛДАНА
ОТЫРЫП, ЕНУДІ ТЕСТІЛЕУ ТӘСІЛДЕРІ.....218
- Д.Б. Тюлемисова, А.К. Шайханова, В.П. Мартценюк, Г.А. Ускенбаева,
Г.В. Бекешева**
МАШИНАЛЫҚ ОҚЫТУ ӘДІСТЕРІНЕ НЕГІЗДЕЛГЕН ӘЛЕУМЕТТІК
ЖЕЛЛЕРДЕГІ АҚПАРАТ АҒЫНЫНЫҢ ДИНАМИКАСЫН ЗЕРТТЕУДІҢ
ЗАМАНАУИ ТӘСІЛДЕРІ.....231

СОДЕРЖАНИЕ

ИНФОРМАЦИОННО-КОММУНИКАЦИОННЫЕ ТЕХНОЛОГИИ

М. Айтимов, Р.У. Альменаева, К.К. Макулов, А.Б. Остаева, Р. Муратхан ПРИМЕНЕНИЕ МЕТОДА МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНАЛИЗА И ИЗВЛЕЧЕНИЯ СЕМАНТИЧЕСКИХ СТРУКТУР ИЗ НАУЧНЫХ ТЕКСТОВ.....	5
А.К. Айтим, Г.К. Сембина МОДЕЛИРОВАНИЕ ЧЕЛОВЕЧЕСКОГО ПОВЕДЕНИЯ ДЛЯ СМАРТФОНА С ИСПОЛЬЗОВАНИЕМ АЛГОРИТМА МАШИННОГО ОБУЧЕНИЯ.....	17
Г.И. Акшолок, А.А. Бедельбаев, Р.С. Магазов АНАЛИЗ И СРАВНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОБНАРУЖЕНИЯ ВРЕДОНОСНОГО ПО.....	29
Л.А. Алексеева ДОЗВУКОВЫЕ ВИБРОТРАНСПОРТНЫЕ РЕШЕНИЯ ВОЛНОВОГО УРАВНЕНИЯ В ПРОСТРАНСТВАХ РАЗМЕРНОСТИ $N=1,2,3$	42
К.Б. Багитова, Ш.Ж. Мусиралиева, К. Азанбай АНАЛИЗ СИСТЕМ РАСПОЗНАВАНИЯ ПОЛИТИЧЕСКОГО ЭКСТРЕМИЗМА В СОЦИАЛЬНЫХ СЕТЯХ ОНЛАЙН.....	60
А.С. Баегизова, Г.И. Мухамедрахимова, И.М. Бапиев, М.Ж. Базарова, У.М. Смайлова ОЦЕНКА ЭФФЕКТИВНОСТИ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОХВАТА КЛЮЧЕВЫХ СЛОВ.....	73
Г.Т. Бекманова, Б.Ж. Ергеш, Г.К. Елибаева, А.С. Омарбекова, М. Strecker МОДЕЛИРОВАНИЕ ПРАВИЛ И УСЛОВИЙ ПРОВЕДЕНИЯ ПРЕДВЫБОРНЫХ ДЕБАТОВ.....	89
М.А. Болатбек, М. Сагынай, Ш.Ж. Мусиралиева ИСПОЛЬЗОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОБНАРУЖЕНИЯ ДЕСТРУКТИВНОГО ВЕБ-КОНТЕНТА НА КАЗАХСКОМ ЯЗЫКЕ.....	99
Е.С. Голенко, А.А. Исмаилова, К.К. Кадиркулов, Р.Н. Календарь РАЗРАБОТКА ОНЛАЙН-ПЛАТФОРМЫ ДЛЯ ПОИСКА ТАНДЕМНЫХ ПОВТОРОВ ПРИ ПОЛНОГЕНОМНОМ СЕКВЕНИРОВАНИИ.....	112

Т. Жукабаева, Л. Жолшиева, Н. Карабаев, Ш. Ахметжанова БИБЛИОМЕТРИЧЕСКИЙ АНАЛИЗ ПРИМЕНЕНИЯ ГРАНИЧНЫХ ВЫЧИСЛЕНИЙ В КИБЕРФИЗИЧЕСКИХ СИСТЕМАХ ПРОМЫШЛЕННОГО ИНТЕРНЕТА ВЕЩЕЙ (IIoT).....	123
С.С. Койшыбай, Н. Мейрамбекұлы, А.Е. Кулакаева, Б.А. Кожаметова, А.А. Булин РАЗРАБОТКА КОНСТРУКЦИИ МНОГОДИАПАЗОННОЙ ДИСКОНУСНОЙ АНТЕННЫ.....	138
А.С. Кыдырбекова, Д.О. Оралбекова ИДЕНТИФИКАЦИЯ ГОВОРЯЩЕГО С ИСПОЛЬЗОВАНИЕМ ГЕНЕРАЦИИ X-ВЕКТОРОВ С СОХРАНЕНИЕМ РАСПРЕДЕЛЕНИЯ...152	152
Б. Медетов, А. Нурланкызы, А. Ахмедиярова, А. Жетписбаева, Д. Жексебай СРАВНИТЕЛЬНЫЙ АНАЛИЗ ЭФФЕКТИВНОСТИ НЕЙРОННЫХ СЕТЕЙ ПРИ НИЗКОМ ЗНАЧЕНИИ ОТНОШЕНИЯ С/Ш.....	163
А.А. Мырзатай, Л.Г. Рзаева, Б. Жұмаділла, А.А. Муханова, Г.А. Ускенбаева МЕТОДЫ ДВОЙНОГО ЭКСПОНЕНЦИАЛЬНОГО СГЛАЖИВАНИЯ И ВРЕМЕННЫХ ОКОН ДЛЯ ПРЕДИКТИВНОГО МОНИТОРИНГА ЛВС: АНАЛИЗ, СРАВНЕНИЕ И ПРИМЕНЕНИЕ.....	174
Л. Найзабаева, М.Н. Сатымбеков ПРОГНОЗИРОВАНИЕ ЗАГРЯЗНЕНИЯ ГОРОДСКОЙ ПОЧВЫ С ИСПОЛЬЗОВАНИЕМ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ.....	194
А.У. Мухиядин, У.Т. Махажанов, А.З. Алимагамбетова, А.А. Муханова, А.И. Акмолдина ПРОГНОЗИРОВАНИЕ МОТИВАЦИИ УЧАЩИХСЯ К ОБУЧЕНИЮ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ: АНАЛИЗ ДАННЫХ ОБ ОБРАЗОВАНИИ В КАЗАХСТАНЕ.....	204
Ж.М. Ташенова, Ж.К. Абдугулова, Ш.А. Аманжолова, Э. Нурлыбаева ПОДХОДЫ К ТЕСТИРОВАНИЮ НА ПРОНИКНОВЕНИЕ С ИСПОЛЬЗОВАНИЕМ УТИЛИТЫ УПРАВЛЕНИЯ УЯЗВИМОСТЯМИ OPENVAS.....	218
Д.Б. Тюлемисова, А.К. Шайханова, В. Мартценюк, Г.А. Ускенбаева, Г.В. Бекешева СОВРЕМЕННЫЕ ПОДХОДЫ К ИЗУЧЕНИЮ ДИНАМИКИ ИНФОРМАЦИОННОГО ПОТОКА В СОЦИАЛЬНЫХ МЕДИА НА ОСНОВЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ.....	231

**Publication Ethics and Publication Malpractice
the journals of the National Academy of Sciences of the Republic of Kazakhstan**

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 National Academy of Sciences of the Republic of Kazakhstan 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 National Academy of Sciences of the Republic of Kazakhstan 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 National Academy of Sciences of the Republic of Kazakhstan.

The Editorial Board of the National Academy of Sciences of the Republic of Kazakhstan 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>

ISSN 2518-1726 (Online),

ISSN 1991-346X (Print)

Директор отдела издания научных журналов НАН РК *А. Ботанқызы*

Редакторы: *Д.С. Аленов, Ж.Ш. Әден*

Верстка на компьютере *Г.Д. Жадыранова*

Подписано в печать 2.12.2024.

Формат 60x881/8. Бумага офсетная. Печать – ризограф.

16,0 п.л. Тираж 300. Заказ 4.