

Торайғыров университетінің хабаршысы
ҒЫЛЫМИ ЖУРНАЛЫ

НАУЧНЫЙ ЖУРНАЛ
Вестник Торайғыров университета

Торайғыров университетінің ХАБАРШЫСЫ

Энергетикалық сериясы
1997 жылдан бастап шығады



ВЕСТНИК Торайғыров университета

Энергетическая серия
Издается с 1997 года

ISSN 2710-3420

№ 3 (2025)

ПАВЛОДАР

НАУЧНЫЙ ЖУРНАЛ
Вестник Торайгыров университета

Энергетическая серия
выходит 4 раза в год

СВИДЕТЕЛЬСТВО

о постановке на переучет периодического печатного издания,
информационного агентства и сетевого издания

№ 14310-Ж

выдано

Министерство информации и общественного развития
Республики Казахстан

Тематическая направленность

публикация материалов в области электроэнергетики,
электротехнологии, автоматизации, автоматизированных и
информационных систем, электромеханики и теплоэнергетики

Подписной индекс – 76136

<https://doi.org/10.48081/TPDW7598>

Бас редакторы – главный редактор

Талипов О. М.

доктор PhD, ассоц. профессор (доцент)

Заместитель главного редактора

Калтаев А.Г., *доктор PhD*

Ответственный секретарь

Сағындық Ә.Б., *доктор PhD*

Редакция алқасы – Редакционная коллегия

Клецель М. Я.,	<i>д.т.н., профессор</i>
Никифоров А. С.,	<i>д.т.н., профессор</i>
Новожилов А. Н.,	<i>д.т.н., профессор</i>
Никитин К. И.,	<i>д.т.н., профессор (Российская Федерация)</i>
Алиферов А. И.,	<i>д.т.н., профессор (Российская Федерация)</i>
Кошеков К. Т.,	<i>д.т.н., профессор</i>
Приходько Е. В.,	<i>к.т.н., профессор</i>
Кислов А. П.,	<i>к.т.н., доцент</i>
Нефтисов А. В.,	<i>доктор PhD</i>
	<i>технический редактор</i>

За достоверность материалов и рекламы ответственность несут авторы и рекламодатели

Редакция оставляет за собой право на отклонение материалов

При использовании материалов журнала ссылка на «Вестник Торайгыров университета» обязательна

© Торайгыров университет

<https://doi.org/10.48081/YKOW1325>

**К. Н. Тайсариева¹, *Е. Таштай²,
Е. Бекенов³, А. Джахметов⁴**

^{1,2,4}Қ. И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті
Қазақстан Республикасы, Алматы қ.

³RTEL Telecom, Қазақстан Республикасы, Алматы қ.

¹ORCID: <https://orcid.org/0000-0002-1949-4288>

²ORCID: <https://orcid.org/0000-0002-0809-537X>

³ORCID <https://orcid.org/0009-0000-5201-0225>

⁴ORCID: <https://orcid.org/0009-0009-5754-8492>

*e-mail: y.yashtay@satbayev.university

5G ЖЕЛІЛЕРІНДЕ ИОТ ТРАФИГІНІҢ ӨТКІЗУ ҚАБІЛЕТІН БОЛЖАУ ҮШІН LSTM АЛГОРИТМІН ҚОЛДАНУДЫ ЗЕРТТЕУ

Бұл ғылыми жұмыста 5G желісіндегі IoT трафигінің өткізу қабілеттілігі уақыт бойынша модельденіп, үш түрлі LSTM конфигурациясы (50, 100 және 500 жасырын нейрон) салыстырмалы түрде талданды. Зерттеу нәтижелерге сәйкес, 100 нейронмен жасалған LSTM моделі ең төмен RMSE мәнін көрсетті және артық үйренушіз (overfitting) жақсы жалтылау қабілетін сақтады. Ал 50 нейронды модель жеткіліксіз болжаммен сипатталып, трафиктің күрделі өзгерістерін көрсете алмады. 500 нейронды модель жақсы нәтиже бергенімен, оның күрделілігі артып, артық үйрену байқалды, бұл нақты уақыттағы жоспарлауға кедергі келтіруі мүмкін. LSTM моделі бұл рекуррентті нейрондық желілердің бір түрі, ол уақыттық тәуелділігі бар мәліметтерді оңдеуде кеңінен қолданылады. LSTM модельдерінің болжам дәлдігін бағалау үшін жиі қолданылатын метрика – RMSE. Бұл көрсеткіштің төмен мәні модельдің нақты деректерге жақын болжам жасағанын білдіреді.

Зерттеу барысында машиналық және терең оқыту әдістерінің, оның ішінде мұғаліммен/мұғалімсіз оқыту, күшейтілген оқыту, қайталанатын және тікелей таралатын нейрондық желілердің мүмкіндіктері сарапталып, 5G/6G желілеріндегі IoT пен тактильді интернет үшін трафик сипаттамаларын болжау міндеттерінің

шеңбері анықталды. Бұл тәсіл пакеттердің жоғалуы, кідірістер, және өткізу қабілеттілігін алдын ала болжауға мүмкіндік береді.

Бұл зерттеу Қазақстан Республикасы Ғылым және жоғары білім министрлігінің Ғылым комитеті тарапынан қаржыландырылды BR24993051-ОТ-24 «IoT және деректерді талдау негізінде интеллектуалды қала жүйесін дамыту» жоба тақырыбында жүзеге асырылды.

Кілтті сөздер: IoT, 5G, жасанды интелект, LSTM, өткізу қабілеттілігі, трафик.

Кіріспе

5G желілерінің дамуы ауқымды, көп деңгейлі, өте күрделі, динамикалық және гетерогенді болады. Сонымен қатар, 5G желілері дискриминацияланбаған қосылуды қолдап, көптеген құрылғылар үшін қызмет көрсету сапасы (QoS) бойынша бірнеше талаптарды қамтамасыз етуі және физикалық ортадан туындайтын үлкен деректер көлемін өңдеуі тиіс. Қуатты аналитикалық мүмкіндіктері, оқу, оңтайландыру және интеллектуалды табу мүмкіндіктері бар жасанды интелект (ЖИ) әдістері 5G желілерінде өнімділікті интеллектуалды арттыру, білімді кеңейту, ұйымдық құрылымды кешенді басқару және күрделі шешімдер қабылдау үшін қолданылуы мүмкін [1, 74–85 б].

Машиналық оқыту – ЖИ саласының бір бөлігі, ол жүйелерге өз тәжірибесіне сүйене отырып үйренуге және айқын бағдарламалаусыз жетілдіруге мүмкіндік береді. Бұл компьютерлік бағдарламаларды әзірлеуге бағытталған, олар деректерге қол жеткізіп, оларды оқыту үшін пайдалана алады. Машиналық оқыту 5G желілерінде жұмыс істеуге толықтай сәйкес келеді, себебі ол әрекеттерді дәл болжау үшін үлкен деректер көлемін талап етеді. Бұл 5G үшін өте қолайлы жағдай, себебі бұл желі бар болғаны бар деректерді қазіргі желілерден жылдамырақ жібере алады.

5G және келесі буын желілерінде ЖИ мен машина оқыту (МО) әдістерін қолдану туралы көптеген мақалалар бар [2, 143–147.б.б]. Жасанды интелект пен машинамен оқыту желінің өнімділігін арттыру үшін әртүрлі мүмкіндіктер ұсынады. Машинамен оқыту жалпы желі басқаруын және мониторингін оңтайландыруға, ресурстарды тиімді пайдалануға және слайсингті оңтайландыруға көмектеседі, бұл операторларға өз желісінің пайдалануын бақылауда көп бақылау мүмкіндігін береді. Сонымен қатар, МО желі сегменттерін 5G желісінде баптауды оңайлатуы мүмкін. Жүйені пайдалану арқылы машинамен оқыту және жасанды интелект әдістері құрылғылардың мобильділік модельдерін және қызмет көрсету сапасын (QoS) анықтап, жақсартып, желіні пайдалануды және белгілі бір жерлерде күн ішінде жүктемені болжауға көмектеседі. Бұл сізге трафикті реттеп, ресурстарды

тиімдірек бөлуге мүмкіндік береді, осылайша пайдаланушыларға аз ресурстар тұтыну арқылы жақсы желілік қызмет көрсетеді. Сонымен қатар, МО желінің күйін бақылауды қамтамасыз етіп, ақауларды басқару, өнімділік және қауіпсіздік үшін көбірек мүмкіндіктер мен функцияларды ұсынады[3,921–923.6.6].

Материалдар мен әдістері

5G желілерінде Заттар Интернеті трафигінің өткізу қабілетін болжау үшін белгілі әдістерден айырмашылығы, терең оқыту мен ұзақ мерзімді қысқа мерзімді жады (LSTM) алгоритмі қолданылып, бұл әдіс 100 жасырын нейронмен болжаудың практикалық тұрғыдан қолайлы дәлдігін қамтамасыз етеді. VANET желісінде пакеттер жоғалуын болжауда робастық бағалауларды қолдануда болып табылады, бұл жағдайда мәліметтер гаусс шуымен және кездейсоқ ауытқулармен бұрмаланған. Сонымен қатар, Заттар Интернеті мен Тактильді Интернет желілерінде кідірістер мен жоғалтуларды болжау үшін сызықсыз рекуррентті авторегрессионды нейрондық желілерді қолдану 5G және кейінгі ұрпақтың байланыс желілерінде трафикті болжау үшін де маңызды. Сондай-ақ, 5G желілерінде Заттар Интернеті трафигінің өткізу қабілетін болжау үшін терең оқыту мен ұзақ мерзімді қысқа мерзімді жады (LSTM) алгоритмін қолдану ұсынылды[4,496–5026.6].


Сонымен қатар, соңғы уақытта интеллектуалды құрылғылар мен мобильді қосымшалардың дамуы пайдаланушы мен мобильді жүйелер арасындағы өзара әрекеттесу мүмкіндіктерін айтарлықтай кеңейтті. Оқыту арқылы алынған ЖНЖ адамға қатысты деректермен жұмыс істейтін «маман» ретінде қарастырылуы мүмкін. Сондықтан ЖНЖ пайдаланып пайдаланушы ортасынан ақпарат алу сымсыз желіні пайдаланушылардың болашақ мінез-құлқын болжау үшін және соңғы сапа деңгейін (QoS) және сенімділікті жақсартудың оңтайлы стратегиясын әзірлеу үшін деректермен қамтамасыз етуі мүмкін.

ЖНЖ-ның әртүрлі түрлері бар, бірақ олардың ең танымал түрі, тікелей тарату нейрондық желілері.

Тікелей тарату нейрондық желілері: тікелей тарату нейрондық желілерінде ақпараттың ағымы тек бір бағытта жүреді. Ақпарат кіріс деңгейінен жасырын деңгейге және соңында шығыс деңгейіне өтеді. Бұл нейрондық желіде кері байланыс циклдары жоқ, 1- суретте көрсетілгендей. Мұндай нейрондық желілер әдетте бақылаулы оқытуда классификация, бейнелерді тану және т.б. үшін қолданылады. Біз оларды деректер реттілігі болмаған жағдайларда қолданамыз [5,455–4706.6].

Тікелей тарату нейрондық желілері: тікелей тарату нейрондық желілерінде ақпараттың ағымы тек бір бағытта жүреді. Ақпарат кіріс деңгейінен жасырын деңгейге және соңында шығыс деңгейіне өтеді.

Бұл нейрондық желіде кері байланыс циклы жоқ. Мұндай нейрондық желілер әдетте бақылаулы оқытуда классификация, бейнелерді тану және т.б. үшін қолданылады. Біз оларды деректер реттілігі болмаған жағдайларда қолданамыз.



1-сурет – Тікелей тарату нейрондық желісінің архитектурасы


VANET жүйесінде түйіндер RSU (жол бойындағы құрылғы) және басқа түйіндермен сымсыз байланысады. Осылайша, олар жол қозғалысы, жабылған жолдар немесе жол жөндеу жұмыстары, жол-көлік оқиғалары және т. б. туралы ақпаратты тез ала алады. Бұл ақпарат негізінде жүргізушілер жол жағдайына байланысты дұрыс шешімдер қабылдай алады, мысалы, мақсатты орынға бағытты өзгерту, жылдамдықты азайту және т. б. Сонымен қатар, олар RSU-ден белгісіз аймақтағы мақсатты орынға бағыт, тұрақ орындары, қонақ үйлер, жанармай құю станциялары мен ауруханалар туралы сұрау жасай алады [6,300–320.6.6].

LSTM моделін зерттеу және модельдеу. Ең танымал және жиі қолданылатын құрылымдардың бірі-LSTM (ұзақ мерзімді қысқа мерзімді жад); LSTM моделі бар DL – алдыңғы деректерді ескере отырып үйренуге болатын RNN-дің ерекше түрі. Бұл желілер қайталанатын желілердің ұзақ мерзімді тәуелділігінің жағдайын бағалауға арналған. LSTM ұзақ уақыт бойы деректерді сақтау үшін тамаша. Модельдің жұмысына ақпараттың едәуір мөлшері әсер етуі мүмкін болғандықтан, LSTM-бұл жұмыс үшін табиғи таңдау. Сондай-ақ, желі ұяшықта, зерттеуде, желіде қандай ақпарат бар екенін шешуге және нені сақтау керектігі туралы нақты түсінікке ие болуы керек. Жаңа деректерді енгізуде және құндылығы жоқ ақпаратты жоюда ешқандай проблема жоқ.

LSTM желісі әмбебап болып табылады, өйткені ол кез-келген есептеулерді әдеттегіге сәйкес келетін желілік элементтердің санымен орындай алады компьютердің өнімділігі, ол үшін бағдарлама ретінде қарастыруға болатын тиісті салмақ матрицасы қажет. Әдеттегіден

айырмашылығы нейрондық желілер, LSTM желісі маңызды болған кезде уақыт қатарларын жіктеу, өңдеу және болжау міндеттерін зерттеуге өте қолайлы оқиғалар белгісіз ұзақтық пен шекараның уақыт кідірістерімен бөлінеді. Уақыт аралықтарының ұзақтығына салыстырмалы сезімталдық LSTM-ге балама қайталанатын нейрондық желілерге, жасырын Марков модельдеріне және әртүрлі қолданбаларда уақыт қатарын оқытудың басқа әдістеріне қарағанда артықшылық береді. ATM ұяшық блогы болжау дәлдігін жақсарту үшін жад мәселесін шеше алады[6,332–345. 6.6].

Терең нейрондық желіде (DNN) және әсіресе LSTM желісінде Нейронды бірнеше кіріс енгізу және кіріс алу арқылы белсендіруге болады деректер дәйекті.



2-сурет – LSTM алгоритмінің архитектурасы

2-суретте LSTM архитектурасы көрсетілген, ол үш ұяшық сүзгісінен тұрады: ұмыту, енгізу және шығару. Олар $[0,1]$ диапазонындағы мәндерді қабылдайтын және ақпаратты ұяшыққа және одан жіберетін сигмоидты функциялар, содан кейін өткен ақпаратты есте сақтау немесе ұмыту керектігін анықтау үшін процесті көбейту. LSTM сөйлеуді тануды, роботты басқаруды және басқа да көптеген болжау тапсырмаларын жүзеге асыру үшін кеңінен қолданылады. Кіріс LSTM құрылымына енгеннен кейін, жадтың бір бөлігі кейінірек пайдалану үшін сақталды. Біз жіктеуді, регрессияны орындау үшін кіріс белгілерін пайдалана аламыз немесе болжай аламыз. STM маңызды компоненті-бұл ұяшық күйі, алдыңғы блоктың жадынан (C_{t-1}) ағымдағы жадқа өтетін сызық блок (C_t), ақпараттың тікелей сызық бойымен өтуіне

мүмкіндік береді. Желі қанша деректерді жібергісі келетінін өзі шеше алады. Ұяшық күйінде әрбір Сан үшін $St-1$ жасырын күй ($ht-1$) және 0-ден 1-ге дейінгі кіріс және шығыс саны болып табылады [7,40–45 б.б].

Кіріс (тензорлар) төмендегі келесі процедурада LSTM арқылы өтеді; кіші айнымалылар векторларды білдіреді. Wq және Uq матрицаларында сәйкесінше кіріс және қайталанатын байланыстардың салмақтары бар, ал BQ -ден басқа қол жетімді терминдердің орын ауыстыру векторы, мұндағы индекс q кіріс сүзгісі i , шығыс сүзгісі o , ұмытып кету сүзгісі f немесе жад ұяшығы s , активацияға байланысты есептеледі.

Бірінші қадам-LSTM ұяшығының күйі. Бұл деңгей ұмыту сүзгісі деп аталатын сигмоидты деңгейді білдіреді:

$$\sigma(x) = 1/(1 + e^{-x}) \quad (1)$$

Кіріс сүзгісі жад ұяшығында сақтау үшін жаңа деректерді таңдайды. Жаңа үміткер мәндерінің векторын қабаттағы күйге қолдануға болады. Кіріс сүзгісі күйдің өзгеруін жасау үшін $\tanh$ қабатымен біріктіріледі. $\tanh$ функциясы олардың маңыздылығын анықтау үшін -1-ден 1-ге дейінгі мәндерді өлшейді. Өлшеу тангенс функциясын келесідей қолданады:

$$\tanh(x) = \frac{e - e}{x - x} \quad (2)$$

$\tanh$ мәні -1-ден 1-ге дейін болғандықтан, бұл белсенді және теріс үлестерді сипаттау үшін жақсы активтендіру функциясы. А $\tanh$ қабаты әдетте LSTM ұяшық құрылымына кіру сүзгісі болып табылады. Мұнда ұмыту сүзгісінің векторы f_t кіріс және қайталанатын қосылыстарды ұмытып кету сүзгісінің салмақ матрицаларының функциясы ретінде берілген sa және Ga және иысу векторы ia келесідей:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (3)$$

Бұл процесте біз x_t арқылы t уақытындағы кіріс векторын, ал t уақытындағы h_t жасырын күй векторын белгілейміз. «қалыпты» RNN сияқты екі вектор; X_t кіріс деректерінен алынған жаңа вектор және осы ұяшықтың жасырын күйінен алынған $ht-1$ жасырын күй векторы алдыңғы қадам. Бұл векторлар сызықтық түрлендіруге де ұшырайды.

Содан кейін олар алдыңғы қадамдағы ақпараттың келесі ұяшық күйіне әсер ететінін шешу үшін 0-ден 1-ге дейінгі екілік нәтижелерді алу үшін сигма тәрізді беру функциясына енгізіледі. Бұл ұмыту сүзгісінің негізгі

құрылымы. Ұмыту сүзгісі СТ-1 уақытының соңғы қадамын ұяшық күйіне дейін қабылдауға шешім қабылдағаннан кейін [8,50-5366].

Келесі кадам-ағымдағы уақыт қадамының кірістері ұяшық күйіне ықпал ететінін анықтау. Негізгі сәйкес қайталанатын нейрондық желілер идеясы алдыңғы уақыт қадамының шығуын ескеруі керек. Сондықтан ағымдағы h_t кірісі мен алдыңғы h_{t-1} шығысы біріктірілуі керек. Ұмыту сүзгі векторы, i_t сүзгі кіріс векторы, C Т ұяшығының күйі сияқты белгілерді пайдалану W_i , U_i , W_c , U_c және b_i және b_c сысу векторларының салмақ матрицаларының функциясы ретінде анықталады:


$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (4)$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (5)$$

Соңында, өнімділік ұяшықтың күйіне байланысты болады. Сигма функциясы мәндерді $[0,1]$ бойынша таңдайды, ал тангенс функциясы мәндерді олардың маңыздылығын -1 мен 1 арасында анықтауға және Сигма шығысына көбейтуге болатындай етіп өлшейді.


LST RNN архитектурасында жоқ жадты қамтиды. Тереңдікті қолдайтын LSTM сонымен қатар тұрақты қатені қолдайды. LTE желісі ең жақсы нәтижелерге қол жеткізе алады деп күтілуде, өйткені ол уақыт қатарының тапсырмаларына сәйкес келеді. LTE желілері қарапайым дәстүрлі тәсілдер жұмыс істемеген кезде ғана қолданылады деп болжанады. LSTM-уақыт сериялары мен машиналық оқыту статистикасын болжаудың ең кең таралған әдістерінің бірі.

Бұл ғылыми жұмыста LSTM желісімен терең нейрондық желіні оқыту мультисервистік желі көмегімен IoT трафигін болжау орындалды. LSM Deep Learning көмегімен IoT трафигін болжалды. Біз LSTM желісіндегі жасырын нейрондардың санына байланысты үш жағдайда өнімділікті зерттедік. Болжам үшін жасырын нейрондар санына байланысты үш жағдайды таңдалды: сәйкесінше 500, 100 және 50. LSTM қабатындағы жасырын нейрондар санының өзгеруі болжау дәлдігін оңтайландыруға қалай әсер ететінін зерттеу үшін LSTM қабатындағы жасырын нейрондар санына негізделген терең оқытудың үш моделі ұсынылады. Болжамның дәлдігі RMSE және MAPE көмегімен бағаланады.




3-сурет – LSTM, 500 нейрон бергендегі қате графигі

Нақты және 500 болжамдалған өткізу қабілеттілігі, қате (нақты – болжам) және **RMSE = 0.0428**.



Нақты және 100 нейронмен болжанған өткізу қабілеттілігі, қате графигі және **RMSE = 0.0312**.



4-сурет – LSTM, 50 нейрон бергендегі қате графигі

Нақты және 50 нейронмен болжанған өткізу қабілеттілігі, қате графигі және **RMSE = 0.0648**.

Нәтижелер және талқылау

Бүгінгі таңда 5G желілерінде IoTкең ауқымда дамуы, жоғары жылдамдықтағы және кідірісі аз байланысқа деген сұраныстың артуы телекоммуникация операторларынан трафикті нақты болжауды және тиімді жоспарлауды талап етеді. Осы міндетті шешуде LSTM (Long Short-Term Memory) нейрондық желілері – уақыттық деректермен жұмыс істеуге бейімделген терең үйрену модельдері – маңызды құралға айналып отыр.

Біз жасаған тәжірибелік зерттеуде 5G желісіндегі IoTөткізу қабілеттілігі (throughput) уақытқа байланысты модельденіп, үш түрлі LSTM конфигурациясы (50, 100 және 500 жасырын нейронмен) салыстырылды. Осы зерттеулер негізінде төмендегідей қорытынды жасауға болады:

1 Тиімді модель – 100 нейрон.

100 нейроннан тұратын модель ең төмен RMSE қателігімен ерекшеленді. Бұл модель нақты трафикті дәл болжаумен қатар, артық үйренуге ұшырамай, жалпылау қабілетін сақтай алды. Сондықтан бұл конфигурация 5G трафигін жоспарлауда ең тиімді нұсқа ретінде ұсынылады.

2 50 нейрон – жеткіліксіз болжам.

50 нейронмен жасалған модель нақты деректерден едәуір ауытқыған. Бұл модель трафиктегі күрделі ауытқуларды толық қамти алмады, сондықтан трафиктің нақты динамикасын көрсетуге жарамсыз деп есептеледі.

3 500 нейрон – артық күрделілік.

500 нейрондық LSTM моделі жалпы алғанда жақсы нәтиже бергенімен, қателігі 100 нейронды модельден жоғары болды. Мұнда артық үйрену (overfitting) байқалуы мүмкін. Модель күрделілігі артқан сайын есептеу шығыны да көбейеді, бұл реалды уақыттағы жоспарлау үшін тиімсіз болуы ықтимал.

Қорытынды

Трафикті болжау мәселелерін шешу үшін машиналық оқыту және терең оқыту мүмкіндіктері, оқыту әдістері талданады мұғалім, мұғалімсіз, күшейтілген, тікелей тарату нейрондық желілері, қайталанатын кері тарату нейрондық желілері және бесінші және кейінгі ұрпақтардың байланыс желілерінде машиналық және терең оқытуды тиімді қолдануға болатын трафиктің сипаттамаларын болжау міндеттерінің шеңбері анықталды. Бұл IoT пен тактильді интернет үшін 5G/6G байланыс желілеріндегі пакеттердің жоғалуы, IoT мен тактильді интернет үшін 5G/6G байланыс желілеріндегі кідірістер және желілердегі өткізу қабілеттілігін алдын ала болжай алады. **100 нейронды LSTM моделі** – тиімділік пен дәлдіктің үйлесімді нұсқасы ретінде, жүйені нақты жоспарлауда ұсынуға болады.

Бұл зерттеу Қазақстан Республикасы Ғылым және жоғары білім министрлігінің Ғылым комитеті тарапынан қаржыландырылды. (BR24993051-OT-24 «IoT және деректерді талдау негізінде интеллектуалды қала жүйесін дамыту».)

ПАЙДАЛАНЫЛҒАН ДЕРЕКТЕР ТІЗІМІ

1 **Ferreira, A., Mendes, L. Dias, W. Marins, T. Gaspar, D., Matos, A., Silva, C. Sokal, B.** 5G-RANGE Project Field Trial. In Proceedings of the 2019 European Conference on Networks and Communications (EuCNC), Valencia, Spain, 18–21 June 2019; P. 490–494.

2 **Mwanje, S.** «Network management automation in 5G: challenges and opportunities,» / Mwanje, S., Decarreau, G., Mannweiler, C., Naseer-ul-Islam, M., and Schmelz, L. C. // IEEE 27th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC) (Valencia), P.1–6, 2016, doi: 10.1109/PIMRC.2016.7794614.

3 **Sun, Y.** «Application of Machine Learning in Wireless Networks: Key Techniques and Open Issues,» / Y. Sun, M. Peng, Y. Zhou, Y. Huang and S. Mao // in IEEE Communications Surveys & Tutorials, Vol. 21, No. 4, P. 3072-3108, Fourthquarter 2019, <https://doi.org10.1109/COMST.2019.2924243>.

4 **Abdellah, A. R.** Deep Learning for IoT Traffic Prediction Based on Edge Computing. / Abdellah, A. R., Artem, V., Muthanna, A., Gallyamov, D.,

Koucheryavy, A. // In: Vishnevskiy, V.M., Samouylov, K. E., Kozyrev, D. V. (eds) Distributed Computer and Communication Networks: Control, Computation, Communications. DCCN 2020. Communications in Computer and Information Science, Springer, Cham. Vol 1337. P. 18–29, 2020.

5 Fe lix Gomez, Marmol «TRIP, a trust and reputation infrastructure-based proposal for vehicular ad hoc networks,» / Fe lix Gomez, Marmol, Gregorio, Martinez Perez // Journal of Network and Computer Applications, Vol. 35, Issue. 3, PP. 934–941, May 2012.

6 **Ali R. Abdellah**, «Deep Learning with Long Short-Term Memory for IoT Traffic Prediction» / Ali R. Abdellah, Andrey Koucheryavy, // Galinina, O., Andreev, S., Balandin, S., Koucheryavy, Y. (eds) Internet of Things, Smart Spaces, and Next Generation Networks and Systems (NEW2AN /SMART), Lecture Notes in Computer Science, Springer, Cham., Vol 12525, P. 267–280, 2020.

7 **Shi, X.; Shao, X.; Zheng, B.; Zhang, R.** 6DMA-Aided Cell-Free Massive MIMO Communication. IEEE Wirel. Commun. Lett. 2025. Early Access.

8 **Fang, Z., Wang, Y., Peng, L.** Hong, H. Predicting flood susceptibility using LSTM neural networks. J. Hydrol. 2021, 594, 125734.

REFERENCES

1 **Ferreira, A. Mendes, L. Dias, W.; Marins, T.; Gaspar, D. Matos, A. Silva, C. Sokal, B.** 5G-RANGE Project Field Trial. In Proceedings of the 2019 European Conference on Networks and Communications (EuCNC), Valencia, Spain, 18–21 June 2019; P. 490–494.

2 **Mwanje, S.** «Network management automation in 5G: challenges and opportunities,» / Mwanje, S., Decarreau, G., Mannweiler, C., Naseer-ul-Islam, M., and Schmelz, L. C. // IEEE 27th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC) (Valencia), P.1–6, 2016, <https://doi.org/10.1109/PIMRC.2016.7794614>.

3 **Sun, Y.** «Application of Machine Learning in Wireless Networks: Key Techniques and Open Issues,» / Y. Sun, M. Peng, Y. Zhou, Y. Huang and S. Mao // in IEEE Communications Surveys & Tutorials, Vol. 21, No. 4, P. 3072–3108, Fourthquarter 2019, <https://doi.org/10.1109/COMST.2019.2924243>.

4 **Abdellah, A. R.** Deep Learning for IoT Traffic Prediction Based on Edge Computing. / Abdellah, A. R., Artem, V., Muthanna, A., Gallyamov, D., Koucheryavy, A. // In: Vishnevskiy, V.M., Samouylov, K. E., Kozyrev, D.V. (eds) Distributed Computer and Communication Networks: Control, Computation, Communications. DCCN 2020. Communications in Computer and Information Science, Springer, Cham. Vol 1337. P. 18–29, 2020.

5 Fe lix Gomez, Marmol «TRIP, a trust and reputation infrastructure-based proposal for vehicular ad hoc networks,» / Fe lix Gomez, Marmol, Gregorio, Martinez Perez // Journal of Network and Computer Applications, Vol. 35, Issue. 3, P. 934 941, May 2012.

6 **Ali R. Abdellah**, «Deep Learning with Long Short-Term Memory for IoT Traffic Prediction» / Ali R. Abdellah, Andrey Koucheryavy, // Galinina, O., Andreev, S., Balandin, S., Koucheryavy, Y. (eds) Internet of Things, Smart Spaces, and Next Generation Networks and Systems (NEW2AN /SMART), Lecture Notes in Computer Science, Springer, Cham., Vol 12525, P. 267–280, 2020.

7 **Shi, X.; Shao, X.; Zheng, B.; Zhang, R.** 6DMA-Aided Cell-Free Massive MIMO Communication. IEEE Wirel. Commun. Lett. 2025. Early Access.

8 **Fang, Z. Wang, Y.; Peng, L. Hong, H.** Predicting flood susceptibility using LSTM neural networks. J. Hydrol. 2021, 594, 125734.

17.04.25 ж. баспаға түсті.

28.04.25 ж. түзетулерімен түсті.

05.09.25 ж. басып шығаруға қабылданды.

*К. Н. Тайсариева¹, *Е. Таштай², Е. Бекенов³, А. Джахметов⁴*

^{1,2,4}Казахский национальный исследовательский технический университет имени К. И. Сатпаева, Республика Казахстан, г. Алматы;

³RTEL Telecom, Республика Казахстан, г. Алматы.

Поступило в редакцию 17.04.25

Поступило с исправлениями 28.04.25

Принято в печать 05.09.25

ИССЛЕДОВАНИЕ ИСПОЛЬЗОВАНИЯ АЛГОРИТМА LSTM ДЛЯ ПРОГНОЗИРОВАНИЯ ПРОПУСКНОЙ СПОСОБНОСТИ ТРАФИКА IOT В СЕТЯХ 5G

В данной научной работе пропускная способность трафика Интернета вещей (IoT) в сети 5G была смоделирована во времени, и сравнительно проанализированы три конфигурации LSTM-модели (с 50, 100 и 500 скрытыми нейронами). Согласно результатам исследования, модель LSTM со 100 нейронами показала наименьшее значение RMSE и сохранила хорошую способность к обобщению без переобучения. Модель с 50 нейронами отличалась недостаточной точностью прогноза и не смогла уловить сложные изменения трафика. Модель с 500 нейронами продемонстрировала хорошие результаты, однако её сложность увеличилась, что привело к

переобучению и может стать препятствием для планирования в реальном времени.

Модель LSTM представляет собой разновидность рекуррентных нейронных сетей, широко применяемую для обработки данных с временной зависимостью. Для оценки точности прогнозирования LSTM-моделей часто используется метрика RMSE – среднеквадратическая ошибка. Низкое значение RMSE указывает на высокую близость прогноза модели к реальным данным.

В ходе исследования были проанализированы возможности методов машинного и глубокого обучения, включая обучение с учителем и без, обучение с подкреплением, а также рекуррентные и прямо распространяющиеся нейронные сети. Определены рамки задач прогнозирования характеристик трафика (потери пакетов, задержки и пропускная способность) в сетях 5G/6G, Интернете вещей и тактильном интернете.

Данное исследование финансируется Комитетом науки Министерства науки и высшего образования Республики Казахстан рамках проекта BR24993051-ОТ-24«Разработка интеллектуальной городской системы на основе IoT и анализа данных».

Ключевые слова: IoT, 5G, искусственный интеллект, LSTM, пропускная способность, трафик.

*K. N. Taissariyeva¹, *E. Tashtay², Y. Bekenov³, A. Jakhmetov⁴*

^{1,2,4}K. Satpayev Kazakh National Research Technical University, Republic of Kazakhstan, Almaty;

³RTEL Telecom, Republic of Kazakhstan, Almaty.

Received 17.04.25.

Received in revised form 28.04.25.

Accepted for publication 05.09.25.

STUDY OF THE USE OF THE LSTM ALGORITHM TO PREDICT THE THROUGHPUT OF IOT TRAFFIC IN 5G NETWORKS

In this scientific study, the throughput capacity of Internet of Things (IoT) traffic in a 5G network was modeled over time, and three different configurations of the LSTM model (with 50, 100, and 500 hidden neurons) were comparatively analyzed. According to the research results, the LSTM model with 100 neurons demonstrated the lowest RMSE value and maintained good generalization ability without overfitting. The model with 50 neurons showed insufficient prediction accuracy and failed to capture

complex traffic variations. Although the 500-neuron model produced strong results, its increased complexity led to overfitting, which could hinder real-time planning.

The LSTM model is a type of recurrent neural network (RNN) widely used for processing time-dependent data. The RMSE (Root Mean Square Error) metric is often used to evaluate the accuracy of LSTM model predictions. A lower RMSE value indicates that the model's forecast is closer to the actual data.

During the study, the capabilities of machine and deep learning methods were analyzed, including supervised and unsupervised learning, reinforcement learning, as well as recurrent and feed forward neural networks. The scope of traffic prediction tasks (packet loss, delays, and throughput) in 5G/6G networks, the Internet of Things, and the Tactile Internet was defined.

This research was funded by the Science Committee of the Ministry of Science and Higher Education of the Republic of Kazakhstan under project BR24993051-OT-24, «Development of an Intelligent City System Based on IoT and Data Analysis».

Keywords: IoT, 5G, artificial intelligence, LSTM, bandwidth, traffic.

Теруге 09.09.2025 ж. жіберілді. Басуға 30.09.2025 ж. қол қойылды.

Электронды баспа

29.9 Mb RAM

Шартты баспа табағы 22,2. Таралымы 300 дана. Бағасы келісім бойынша.

Компьютерде беттеген: А. К. Мыржикова

Корректор: А. Р. Омарова, Д. А. Кожас

Тапсырыс № 4447

Сдано в набор 09.09.2025 г. Подписано в печать 30.09.2025 г.

Электронное издание

29.9 Mb RAM

Усл. печ. л. 22,2. Тираж 300 экз. Цена договорная.

Компьютерная верстка: А. К. Мыржикова

Корректор: А. Р. Омарова, Д. А. Кожас

Заказ № 4447

«Toraighyrov University» баспасынан басылып шығарылған

Торайғыров университеті

140008, Павлодар қ., Ломов к., 64, 137 каб.

«Toraighyrov University» баспасы

Торайғыров университеті

140008, Павлодар қ., Ломов к., 64, 137 каб.

67-36-69

E-mail: kereku@tou.edu.kz

www.vestnik-energy.tou.edu.kz