

ҚАЗАҚСТАН РЕСПУБЛИКАСЫНЫҢ ҒЫЛЫМ ЖӘНЕ ЖОҒАРЫ БІЛІМ МИНИСТРЛІГІ

Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті

Автоматика және ақпараттық технологиялар институты

Электроника, телекоммуникация және ғарыштық технологиялар кафедрасы

Сембаев Диас Берикказыұлы

«Жасанды интеллект технологиясына негізделген 5G желілері үшін трафиктің сипаттамаларын болжау»

ДИПЛОМДЫҚ ЖҰМЫС

6B06201 «Телекоммуникация» білім беру бағдарламасы

Алматы 2023 ж.

ҚАЗАҚСТАН РЕСПУБЛИКАСЫНЫҢ ҒЫЛЫМ ЖӘНЕ ЖОҒАРЫ БІЛІМ МИНИСТРЛІГІ

Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті

Автоматика және ақпараттық технологиялар институты

Электроника, телекоммуникация және ғарыштық технологиялар кафедрасы



ДИПЛОМДЫҚ ЖҰМЫС


Тақырыбы: «Жасанды интеллект технологиясына негізделген 5G желілері үшін трафиктің сипаттамаларын болжау»

6B06201 «Телекоммуникация» білім беру бағдарламасы

Орындаған:

Д.Б. Сембаев

Пікір беруші
ҚазҰАЗУ, PhD докторы,
Энергия үнемдеу және
автоматика кафедрасының меңгерушісі



Молдажанов А. К.

Ғылыми жетекші
ҚазҰТЗУ, т.ғ.м., Электроника,
телекоммуникация және ғарыштық
технологиялар кафедрасының
аға оқытушысы

С. Марксұлы
«25» 05 2023 ж.

Алматы 2023 ж.

ҚАЗАҚСТАН РЕСПУБЛИКАСЫНЫҢ ҒЫЛЫМ ЖӘНЕ ЖОҒАРЫ БІЛІМ МИНИСТРЛІГІ

Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті

Автоматика және ақпараттық технологиялар институты

Электроника, телекоммуникация және ғарыштық технологиялар кафедрасы

6B06201 Телекоммуникация

БЕКІТЕМІН

Кафедра меңгерушісі

Е. Таптай Е. Таптай

«*21*» _____ *05* 2022 ж.

**Дипломдық жұмыс орындауға
ТАПСЫРМА**

Білім алушы *Сембаев Диас Берикказыұлы*

Тақырыбы *«Жасанды интеллект технологиясына негізделген 5G желілері үшін трафиктің сипаттамаларын болжау»*

Университет ректорының *«23» қараша 2022 ж. №408-П/Ө бұйрығымен* бекітілген.

Аяқталған жұмысты тапсыру мерзімі *«30» сәуір 2023 ж.*

Дипломдық жұмыстың бастапқы берілістері:

1) *Бесінші буын байланыс желілерінің тұжырымдамасы;*

2) *IMT-2020 жүйелік талаптары;*

3) *Жасанды нейрондық желілер (ANNs);*

4) *Тікелей тарату нейрондық желісінің архитектурасы.*

Дипломдық жұмыста қарастырылатын мәселелер тізімі:

а) *Ұялы байланыс желілерінің дамуын талдау;*

б) *Айналадағы VANET желісін модельдеу;*

в) *Машиналық оқыту негізінде бесінші және одан кейінгі буындардың байланыс желілеріндегі шығындар мен кедергілерді болжау;*

г) *Левенберг-Марквардт Алгоритмі (Trainlm);*

д) *Жаңартулары бар Флетчер-РИВС конъюгаттық градиент алгоритмі (Traincgf).*



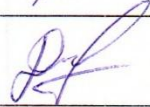
Сызбалық материалдар тізімі (міндетті сызбалар дәл көрсетілуі тиіс):

Ұсынылатын негізгі әдебиеттер: 1) *Jiyu Jiao, Xuehong Sun, Liang Fang, Jiafeng Lyu, An overview of wireless communication technology using deep learning, China Communications 2021.* 2) *Fei Shu, ShuTing Chen, Feng Li, JianYe Zhang, Jia Chen, Research and implementation of network attack and defense countermeasure technology based on artificial intelligence technology, 2020 IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC)* 3) *Zewei He Communication Engineering Application System Based on Artificial Intelligence*

ДИПЛОМДЫҚ ЖҰМЫСТЫ (ЖОБАНЫ) ДАЙЫНДАУ
КЕСТЕСІ

Бөлімдер атауы, қарастырылатын мәселелер тізімі	Ғылыми жетекшіге және кеңесшілерге көрсету мерзімі	Ескерту
Диплом жұмысының тақырыбын талдау	04.01.2023 - 01.02.2023	Орындалды
Теориялық ақпарат	01.02.2023 - 01.03.2023	Орындалды
Жабдықтар жұмысының есебі және жұмысты рәсімдеу	01.03.2023 - 30.05.2023	Орындалды

Дипломдық жұмыс (жоба) бөлімдерінің кеңесшілері мен норма бақылаушының аяқталған жұмысқа(жобаға) қойған қолтаңбалары

Бөлімдер атауы	Кеңесшілер (аты, әкесінің аты, тегі, ғылыми дәрежесі, атағы)	Қол қойылған күні	Қолы
Диплом жұмысының тақырыбын талдау	Марксұлы С. ЭТЖҒТ каф.аға оқытушысы, т.ғ.м.	16.01.2023	
Теориялық ақпарат	Марксұлы С. ЭТЖҒТ каф.аға оқытушысы, т.ғ.м.	18.04.2023	
Норма бақылау	Досбаев Ж.М. ЭТЖҒТ каф.аға оқытушысы, т.ғ.м.	25.05.2023	

Ғылыми жетекшісі

Тапсырманы орындауға алған білім алушы




Марксұлы С.

Сембаев Д. Б.

Күні «22» желтоқсан 2022 ж.

АНДАТПА

Дипломдық жұмыста «интернет заттарын» енгізу, бесінші және одан кейінгі байланыс желілеріндегі жоғалтулар мен кешігулер контекстінде бесінші және кейінгі буынның байланыс желілерінің өткізу қабілетін болжау мәселелерін шешу үшін машиналық оқыту мен терең оқытуды пайдалану ұсынылады. Заттар интернеті және тактильді интернет желілеріне қатысты ұрпақтар, VANET автомобиль желілеріндегі өткізу қабілеті мен жоғалтулары.

Жоғарыда айтылғандардың негізінде жасанды интеллект технологияларына негізделген бесінші буын байланыс желілеріндегі трафик сипаттамаларын болжау әдістерін зерттеуге арналған дипломдық жұмыстың тақырыбы өзекті болып көрінеді.

АННОТАЦИЯ

В дипломной работе предлагается использовать машинное обучение и глубокое обучение для решения задач внедрения «Интернета вещей», прогнозирования пропускной способности коммуникационных сетей пятого и последующих поколений в контексте потерь и задержек в сетях связи пятого и последующих поколений. Поколения, связанные с интернетом вещей и тактильными сетями интернета вещей, пропускная способность и потери в автомобильных сетях VANET.

На основании вышеизложенного представляется актуальной тема дипломной работы по изучению методов прогнозирования характеристик трафика в сетях связи пятого поколения, основанных на технологиях искусственного интеллекта.

ANNOTATION

In the thesis, it is proposed to use machine learning and deep learning to solve the problems of implementing the "Internet of Things", forecasting the bandwidth of communication networks of the fifth and subsequent generations in the context of losses and delays in communication networks of the fifth and subsequent generations. Generations related to the Internet of Things and tactile networks of the Internet of Things, bandwidth and losses in VANET car networks.

Based on the above, the topic of the thesis on the study of methods for predicting traffic characteristics in fifth-generation communication networks based on artificial intelligence technologies seems relevant.

МАЗМҰНЫ

Кіріспе	7
1 5G желілерінде жасанды интеллект технологияларын пайдалануды талдау	8
1.1 Ұялы байланыс желілерінің дамуын талдау	8
1.2 Бесінші буынның байланыс желілері	11
1.3 5G желілерінде жасанды интеллект қолдану перспективалары	13
2 VANET желілеріне ROBUST M-ESTIMATES пайдалану және машиналық оқуды қолдану	14
2.1 Кіріспе	14
2.2 Транспорттық желілері	17
2.3 Айналадағы VANET-ті модельдеу	19
2.4 Жасанды нейрондық желіні оқыту	21
2.5 Таза деректер болған кезде транспорттық желілерінде сенімді ANN пайдалану (шу жоқ)	28
3 Машинады оқыту негізіндегі бесінші және келесі ұрпақ байланыс желілерін болжау	34
3.1 Кіріспе	34
3.2 Уақыт қатарларын болжау үшін машиналық оқыту	40
3.3 Мәселені құрастыру және жүйе моделі	44
3.4 Модельдеу нәтижелері	51
3.5 LSTM тренингі	56
3.6 Қолданбалар және модельдеу нәтижелері	59
Қорытынды	62
Пайдаланылған әдебиеттер тізімі	64

КІРІСПЕ

Трафик сипаттамаларын болжау мәселелері әрқашан байланыс желілерін зерттеуде басым орынға ие болды және алуда. Шынында да, коммуникациялық желілердің жұмыс істеу тиімділігі көп дәрежеде трафикке қызмет көрсету үшін желілік ресурстарды бөлуге байланысты және трафиктің сипаттамаларын білмей және олардың өзгерістерін болжаусыз желінің тиімді жұмыс істеуіне қол жеткізу іс жүзінде мүмкін емес. Бесінші және одан кейінгі буындардың гетерогенді байланыс желілеріне көшу кезінде трафик сипаттамаларын болжау рөлі одан да артады. Шынында да, мұндай желілердің гетерогенді сипаты трафик сипаттамаларын болжауға сараланған тәсілді де талап етеді. Жол қозғалысы сипаттамаларын болжау үшін, мысалы, мұндай міндеттерді шешу өте ұзақ уақытты қажет етіп қана қоймай, мұндай күрделі гетерогенді желілер үшін шешімдерді біріктіру өте күмәнді болып көрінеді. Дегенмен, қазіргі уақытта экономикалық қызметтің әртүрлі салаларында әртүрлі тапсырмаларды орындауда қолданбалы жасанды интеллект технологияларын қолдану қарқын алуда. Бұл жерде табиғи таңдау жасанды интеллект технологиялары негізінде бесінші және одан кейінгі буындардың гетерогенді байланыс желілері үшін трафикті болжау мәселелерін зерттеу болып табылады.

Дипломдық жұмыста «Интернет заттарын» енгізу, бесінші және одан кейінгі байланыс желілеріндегі жоғалтулар мен кешігулер контекстінде бесінші және кейінгі буынның байланыс желілерінің өткізу қабілетін болжау мәселелерін шешу үшін машиналық оқыту мен терең оқытуды пайдалану ұсынылады. Интернет заттары және тактильді интернет желілеріне қатысты ұрпақтар, VANET автомобиль желілеріндегі өткізу қабілеті мен жоғалтулары жоғарыда айтылғандардың негізінде жасанды интеллект технологияларына негізделген бесінші буын байланыс желілеріндегі трафик сипаттамаларын болжау әдістерін зерттеуге арналған дипломдық жұмыстың тақырыбы өзекті болып көрінеді.

1 5G желілерінде жасанды интеллект технологияларын пайдалануды талдау

1.1 Ұялы байланыс желілерінің дамуын талдау

Соңғы онжылдықтарда мобильді сымсыз желілер айтарлықтай өзгеріске ұшырады. Сонымен қатар, мобильді сымсыз желілердің генерациясы (G) әдетте келесі көрсеткіштер негізінде анықталады: жылдамдық, технология, жиілік, деректер көлемі, кідіріс, пайдаланушы тығыздығы және т.б. Әрбір ұрпақтың алдыңғы буыннан ерекшеленетін кейбір ерекшеліктері, стандарттары, әртүрлі мүмкіндіктері, жаңа әдістері, жаңа сипаттамалары бар.

Бірінші буынды 1980 жылдары Токиода Nippon Telegraph and Telephone (NTT) компаниясы әзірледі. Осылайша, Жапония 1G-ді коммерциялық мақсатта қолдана бастаған бірінші ел болды. 1G AMPS (Жетілдірілген ұялы телефон қызметі) негізіндегі аналогтық сигналдарға негізделген және тек дауыстық қоңыраулар үшін пайдаланылды. 1G енгізу үшін FDMA (Frequency Division Multiple Access) мультиплексірлеу схемалары қолданылды [1,2].

Төмен өткізу қабілеттілігі және аналогтық технология сияқты 1G кемшіліктеріне байланысты 2G желісінің генерациясы Финляндияда 1990 жылдары GSM негізінде енгізілді. 2G көптеген артықшылықтарға ие болды, мысалы, 2G радиосигналдары сандық болды, 1G-ге қарағанда жақсы қауіпсіздікті ұсынды, қолжетімді спектрді жақсырақ және тиімдірек пайдалануға мүмкіндік берді және мәтіндік қызметтер үшін қосымша опцияны ұсынды. Жақсартылған нұсқа сонымен қатар Интернетке қол жеткізуді қамтамасыз ететін GPRS (General Packet Radio Service) қызметін қамтиды.

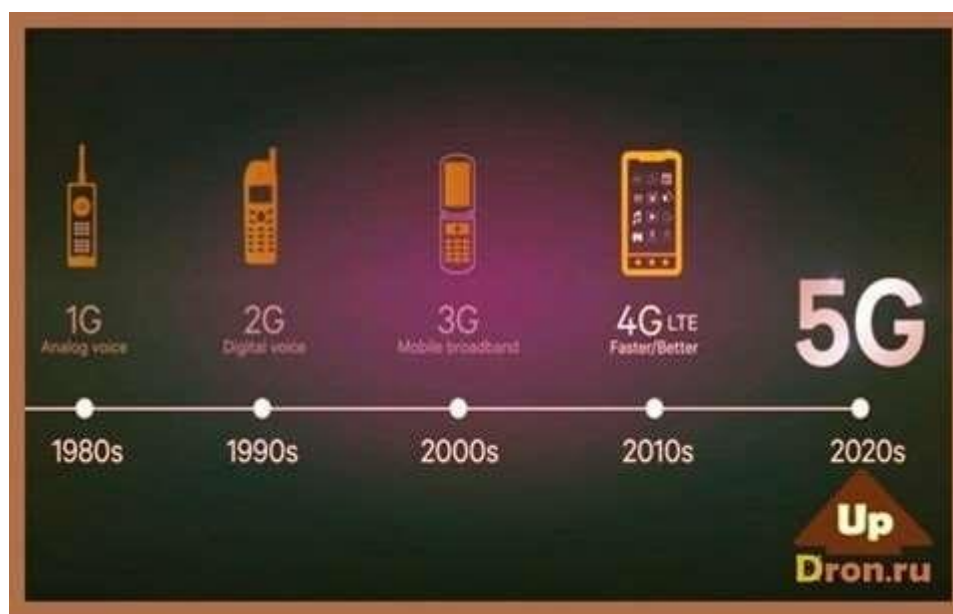
Көптеген пайдаланушылар Интернетке кіру үшін ұялы телефондарды пайдаланған сайын, жылдамырақ және сенімдірек Интернетке қосылып, 3G стандарты енгізілді. 3G CDMA (Code Division Multiple Access) және WCDMA (Wideband Code Division Multiple Access) ұғымдарын енгізді. NTT DoCoMo оны алғаш рет 2000 жылдардың басында Жапонияда коммерциялық түрде енгізді. 3G алдыңғы 2G жүйелерімен кері үйлесімділік артықшылығына да ие болды [1,2].

4G – 2010 жылы Финляндияда алғаш рет енгізілген мобильді кең жолақты технологияның төртінші буыны. Ол мобильді технологияның эволюциясы болып табылатын және 3G шектеулерін еңсеретін сымсыз мобильді интернетті қолдау үшін 3G-ді тіркелген Интернетпен біріктіреді. Ол сондай-ақ өткізу қабілеттілігін арттырады және ресурстардың құнын төмендетеді. 4G OFDM (ортогональды жиілікті бөлу мультиплексі) тұжырымдамасын пайдаланады. 4G желісіндегі интернет жылдамдығы 100 Мбит/с жетуі мүмкін. Онлайн ойындар, HD бейне ағыны және интерактивті теледидар сияқты өте жоғары жылдамдықты қажет ететін қолданбаларды пайдалануға болады [1,2].

Сымсыз мобильді технологиялар зерттеулер мен инновациялар арқылы жылдар бойы дамып, айтарлықтай жетілдірілді. Біз әртүрлі сымсыз технологияларды, желілерді және қолданбаларды бір уақытта қоса алатын уақыт келді. Бұл соңғы технология 5G. 5G 5-ші буын ұялы байланыс технологиясын

білдіреді. 5G – қазіргі 4G шеңберінен шығып, ұялы байланыс стандарттарын дамытудың жаңа кезеңі. Ұялы байланыс нарығындағы жаңа революция өткізу қабілеті өте жоғары ұялы телефондарды пайдалануды өзгертеді. Қолданушы мұндай жоғары сапалы технологиялармен, оның ішінде озық мүмкіндіктермен және ең қуаттыға айналатын және жақын арада үлкен сұранысқа ие болатын 5G технологиясымен ешқашан кәсіпқой бола алмайды.

1.1-суретте. 1G-ден 5G-ге дейінгі мобильді ұялы желілердің эволюциясын көрсетеді.



1.1-сурет – Мобильді желілердің эволюциясы.

5G желілерін дамыту ауқымды, көп деңгейлі, өте күрделі, динамикалық және гетерогенді болады. Сонымен қатар, 5G желілері кемсітпейтін қосылымды қолдауы және көптеген құрылғылар үшін QoS бірнеше талаптарына кепілдік беруі және физикалық орталар жасаған деректердің үлкен көлемін өңдеуі керек. Қуатты аналитика, оқыту, оңтайландыру және интеллектуалды ашу мүмкіндіктері бар жасанды интеллект (AI) әдістерін 5G желілерінде өнімділікті интеллектуалды жақсарту, білімді кеңейту, жан-жақты оқыту, ұйымдық құрылым және күрделі шешімдер қабылдау үшін пайдалануға болады.

Жасанды интеллект (AI) - «интеллектуалды машиналарды» құруды мақсат ететін информатика саласы. AI сымсыз желілерден (мысалы, заттар интернеті) деректерді келесі салаларда талдауға көмектеседі: деректерді дайындау, деректерді табу, деректер ағынын визуализациялау, уақыт сериялары деректерінің дәлдігі, болжамды және кеңейтілген аналитика, нақты уақыттағы геокеңістіктік деректер мен орналасу (логистика) деректер.

Машиналық оқыту – бұл жүйелерге тәжірибеден үйренуге және нақты автоматты бағдарламалаусыз жақсартуға мүмкіндік беретін AI саласы. Ол деректерге қол жеткізе алатын және оларды оқу үшін пайдалана алатын компьютерлік бағдарламаларды жасауға бағытталған. Машиналық оқыту 5G

желілерінде жұмыс істеуге толығымен сәйкес келеді, өйткені ол әрекеттерді дәл болжау үшін ауқымды деректерді қажет етеді. Бұл 5G үшін өте қолайлы жағдай, себебі бұл желі деректердің үлкен көлемін бар желілерге қарағанда жылдамырақ тасымалдай алады.

Келесі буын мобильді және сымсыз технологиялар белгілі бір мақсаттық функцияларды азайту немесе барынша арттыру үшін оңтайландыруды қажет етеді. Кейбір мобильді және сымсыз байланыс мәселелері сызықты емес, сондықтан шамамен шешімдерді қажет етеді. Жасанды нейрондық желілер (ANN) – оңтайландыруды қажет ететін сызықты емес есептің мақсаттық функциясын модельдеу үшін ұсынылған жасанды интеллект әдісі [3].

Терең оқыту – машиналық оқыту процесін жүзеге асыру үшін жасанды нейрондық желілердің иерархиялық құрылымын пайдаланатын машиналық оқыту класы (ML). Жасанды нейрондық желілер адам миына ұқсайды және желіге қосылған нейрондық түйіндерден тұрады. Дегенмен, дәстүрлі бағдарламалар тек сызықтық деректерді талдауды орындайды. Терең оқыту жүйелерінің иерархиялық функциясы машиналарға сызықтық емес тәсілді қолдана отырып деректерді өңдеуге мүмкіндік береді. Терең оқыту - бұл шешім қабылдау үшін деректерді өңдеу кезінде адам миының функцияларына ұқсайтын жасанды интеллект мүмкіндігі. Жасанды интеллектті терең меңгеруді құрылымдалмаған деректерге үйретуге болады [4,5]. 1.2-суретте жасанды интеллект, машиналық оқыту және терең оқыту арасындағы байланыс көрсетілген.



1.2-сурет – Жасанды интеллекттің негізгі технологиялары.

1.2 Бесінші буынның байланыс желілері

5G сымсыз желілері кеңінен қолданысқа жақын. Қазіргі уақытта 5G желілері бірқатар елдерде ендірілді. Олар аса жоғары жылдамдықты мүмкіндіктерді, үлкен құрылғы қосылымы үшін ультра жоғары тығыздықты, ультра төмен кідірісті, ультра жоғары сенімділікті, жоғары ұтқырлықты қолдауды және қолданыстағы сымсыз желілермен салыстырғанда жақсартылған қуат тиімділігін қамтамасыз етеді. 5G ұялы байланысы күнделікті өміріміздің әртүрлі салаларында, үйден жұмысқа және демалыстан көлікке дейін әртүрлі қызмет көрсету талаптарына жауап береді деп күтілуде. Пайдаланушы тәжірибесіне, тиімділігіне, өнімділігіне және күрделі желілік ортаға қойылатын 5G талаптарының максималды көлеміне байланысты 5G желілерін жобалау және оңтайландыру өте күрделі білімді қажет ететін міндетке айналды [16].

5G қолдану арқылы ғаламдық мобильді деректер трафигі 2023 жылға қарай 31,6 миллиард мобильді құрылғыдан айына 100 экзабайтқа дейін артады, бұл қазіргі деңгейден екі есе дерлік. Болашақ 5G желілерінде желі архитектурасы мен сымсыз байланыстың күрделілігі күрт артады. Екінші жағынан, бір пайдаланушыға/құрылғыға орташа қолжетімді ресурс аздап шектеледі; сондықтан деректер мен пайдаланушы құрылғыларының күрт көбеюі желілік трафикті басқару және оңтайландыру үшін үлкен қиындыққа айналады [17].

Дәстүрлі мағынада 5G желілік трафикті басқару саласындағы қазіргі зерттеулер өзін-өзі таусты. 5G трафикті басқару мәселесін шешу және бүкіл желіні жаһандық оңтайландыруға қол жеткізу оңай болмайды. Бұл жаңа шешімдерді қолдану қажеттілігін көрсетеді [17,18]. Халықаралық электрбайланыс одағының (ХЭО) мәліметтері бойынша, болашақ 5G жүйелері ең маңызды үш құрамдас бөлікке ие болады [19].

- Жетілдірілген мобильді кең жолақты (eMBB) 5G NR және 4G LTE желілерінде төмен кідіріспен толықтырылған деректер өткізу қабілетінің жоғарылауын қамтамасыз етеді. Бұл қазіргі заманғы мобильді кең жолақты пайдалану жағдайларын дамытуға және 3D, мультимедиялық және ультра жоғары ажыратымдылықтағы (UHD) AR/VR қолданбалары, сондай-ақ бейне жіберу сияқты жаңа қызметтерге жоғары жылдамдықты деректерге қол жеткізу қажеттіліктерін қанағаттандыру үшін өте жоғары деректер жылдамдығын мақсат етуге көмектеседі. eMBB жылдамырақ қосылымдарды, жоғары өткізу қабілеттілігін және көбірек сыйымдылықты қамтамасыз етеді. Бұл стадиондар, қалалар және концерттік орындар сияқты көлік қозғалысы көп аймақтарға пайдалы болады.

- Machine Type Massive Communications (MTC), ол төмен қуат тұтынумен (бір құрылғыға 1-ден 100 кбит/с дейін) төмен деректер жылдамдығымен (1 000 000 құрылғы/км² дейін) өте көп құрылғыларға қосылу үшін жоғары арна тығыздығын қамтамасыз етуге бағытталған. батареяның қызмет ету мерзімі 15 жылға дейін) смарт қала, Интернет заттары (IoT) [25] және киілетін құрылғылар желілері үшін пайдаланылатын сенсорлық желілердің қажеттіліктерін қанағаттандыру үшін.

- Ультра төмен кідіріс ультра сенімді байланыс (URLLC) смарт есептегіштер, жоғары жылдамдықты пойыздарды басқару, қозғалыс қауіпсіздігі сияқты басқару желілері үшін пайдаланылатын сымсыз қызметтер үшін ультра жоғары сенімділікті (99,9999 пайыз) және ультра төмен кідірісті (1 мс) қамтамасыз етуге бағытталған. басқару, қашықтықтан медициналық қызмет көрсету және өнеркәсіптік роботтарды басқару.

Сонымен қатар, өздігінен ұйымдастырылатын желілерді, жасанды интеллектті (AI) 5G желілерімен біріктіру желінің интеллектуалды және автономды жұмыс істеуіне мүмкіндік береді. Жасанды интеллект 5G-ге ішінара ғана кірсе де, келесі 5 буындағы коммуникация желілерінде AI толық іске асырылатын болады. 5G желілеріндегі жасанды интеллект интеллектуалды және автономды жұмыс істеуге мүмкіндік береді, бұл ағымдағы және болашақ қолданбалар үшін өте маңызды [20].

1.3 5G желілерінде жасанды интеллект қолдану перспективалары

5G және одан тыс байланыс желілері желілік протоколдарды бейімдеу және әртүрлі сценарийлерде әртүрлі қызметтер үшін ресурстарды басқару үшін сенімді интеллектуалды алгоритмдерді қажет етеді. Жасанды интеллект (AI) қоршаған ортаны танытын және белгілі бір алдын ала белгіленген мақсат үшін табысқа жету мүмкіндігін барынша арттыратын әрекеттерді орындайтын кез келген процесс немесе құрылғы ретінде анықталатын, қалыптасып келе жатқан күрделі байланыс жүйесінің әрекетін болжаудың практикалық шешімі болып табылады. Терең оқытудағы, конволюционды нейрондық желілердегі және күшейтілген оқытудағы соңғы жаңалықтар бұрын шешілмейтін деп саналатын күрделі мәселелерді шешуде айтарлықтай прогреске уәде береді [23,24].

Жасанды интеллект ресурстарды белсенді және динамикалық бөлуге мүмкіндік береді, бұл желіге нақты уақыт режимінде ресурстарды қажетті орындарға бөлуге мүмкіндік береді, бұл қолданыстағы желілерде басым болатын статикалық ресурстарды бөлуге қарсы [25]. Бұл RAN қол жеткізу желісі мен транзиттік желіге қысым жасайтын пандемиядан туындаған қала орталықтарынан тұрғын аудандарға трафикке сұраныстың кенеттен өзгеруін шешуге көмектеседі. Сонымен қатар, AI трафикті болжауға және бағалауға, сәтсіздіктерді анықтауға және жеткіліксіз пайдаланылған базалық станцияларды өшіру немесе өзін-өзі ұйымдастырушы желінің өзін-өзі қалпына келтіру функцияларын автоматты түрде іске қосу арқылы желіні қайта конфигурациялауға мүмкіндік береді [26].

Бұл пандемия кезінде өте маңызды, өйткені желіні қолдау үшін қол жетімді адам ресурстары күрт азаяды. Сонымен қатар, AI пандемия кезінде пайда болатын денсаулық мәселелерін шешу үшін қажетті проактивті тапсыруды оңтайландыруға мүмкіндік береді, бұл кезде ауыр науқастар үзілістерді болдырмау үшін ауруханада және ауруханаға барар жолда денсаулық сақтау мамандарымен бейне/дыбыстық байланыс арқылы қашықтан емделуі қажет.

қызмет көрсету немесе қосылымдарды бір базалық станциядан екіншісіне ауыстыру нәтижесінде туындаған үзілістер [20].

Сонымен қатар, жасанды интеллект технологиясын бесінші және кейінгі буынның байланыс желілеріне біріктіру физикалық деңгейді оңтайландыру, күрделі шешімдер қабылдау, желіні басқару және осы желілердегі ресурстарды оңтайландыру мәселелерін шешуге мүмкіндік береді. Дамып келе жатқан үлкен деректер технологиясы бізге сымсыз желілердің негізгі сипаттамаларын зерттеуге тамаша мүмкіндік береді және 5G сымсыз желілерінің әрекеті туралы дәлірек және тереңірек білім алуға көмектеседі. Сымсыз технологиялар мен 5G байланыс жүйелерін зерттеуде AI қуатты құрал және сымсыз сигналдарды өңдеу, арналарды модельдеу және ресурстарды басқару сияқты көптеген әлеуетті қолданбалары бар қызықты зерттеу тақырыбы болады [27].

Сондықтан дипломдық жұмыста негізгі міндеттердің бірі AI-ны 5G желісіне интеграциялаудың желілік технологияларды енгізудің жаңа нақты салаларындағы мәселелер мен міндеттерді шешудегі рөлін дәлелдеу болып табылады, атап айтқанда: жол көлік желілері (VANET), Заттар интернеті (IoT) және өте кішкентай кідірістері бар байланыс желілері (uRLLC). 5G және келесі буын желілерінде AI және машиналық оқыту (ML) әдістерін қолдану туралы бірнеше мақалалар бар [28]. Дипломдық жұмыстың мақсаты - қолданыстағы желілерде кездесетін нақты желілік проблемаларды анықтау және 5G желілері мен келесі ұрпақтарға осындай проблемаларды жеңуге көмектесетін машиналық және терең оқыту шешімдерін пайдалану.

Алдымен машиналық және терең оқыту әдістерінің мүмкіндіктерін талдап көрейік.

2 VANET желілеріне ROBUST M-ESTIMATES пайдалану және машиналық оқуды қолдану

2.1 Кіріспе

Алдыңғы тарауда 5G желілеріндегі жасанды интеллект әдістеріне талдау жасалды. Бұл тарауда машиналық оқыту әдістерін автомобиль желілерінде қолдану ұсынылады; оқыту кері таралу оқыту алгоритмін және жаңа сенімді жоғалту функциясын пайдаланады, атап айтқанда: сенімді оқыту үшін ең танымал дәстүрлі MSE жоғалту функциясының орнына жаңа сенімді жоғалту функциялары (өнімділік функциялары) ретінде есептер деп аталатын сенімді статистикалық бағалаулар тобы. нейрондық желі және шығарындылар болған кезде максималды өнімділікті алу.

Көпқабатты алға бағытталған нейрондық желілер әдетте нақты және болжамды нәтижелер арасындағы орташа квадраттық қатені (MSE) азайту үшін көпқабатты нейрондық желілерді үйретуге арналған кері таралуды оқыту алгоритмі арқылы оқытылады. Деректерді өңдеудегі MSE әдетте ең кіші квадраттар (LMS) ретінде белгілі. LMS-тің негізгі идеясы қалдық квадратын азайту арқылы модельдің оқу деректеріне сәйкестігін оңтайландыру болып табылады. MSE бағалау сапасының өлшемі болып табылады және деректерді өңдеудің көптеген әдістерінде таңдаулы өлшем болып саналады. Дәстүр мен есептеудің қарапайымдылығы MSE танымалдығының себептері болып табылады. Өкінішке орай, MSE оқу деректерін ластайтын шектен тыс көрсеткіштерге қарсы тұра алмайды. Сондықтан, M бағалары деп аталатын тұрақты жоғалту функцияларының жаңа тобы ұсынылады, жоғалту функциясы ретінде дәстүрлі MSE жоғалту функциясын ауыстыру және осылайша оқу процесін жақсарту. [11].

Кедергілердің немесе шудың болуы көлік желісіндегі трафикті басқару мәселелерін тудырады, себебі олар желінің өнімділігіне әсер етеді және қауіпсіз және сенімсіз қосылымдарға әкеледі. Жақында жүргізілген зерттеулер сымсыз желілердегі жарылыстардың әсерін азайту үшін әртүрлі әдістерді қолданды. Осы әдістердің ішінде машиналық оқыту алгоритмдері ең перспективалы болып табылады және оларды шектен тыс көрсеткіштердің әсерін азайту арқылы жақсартуға болады. ML үлгісі деректер жинауға байланысты жаңа желі үлгісіне бейімделуі мүмкін. Сондықтан, бұл дипломдық жұмыста DL-негізделген сенімді M-бағалау жоғалту функциялары таңдалды, өйткені олар шектен тыс көрсеткіштерге сезімтал емес. Дегенмен, сенімді ML баллдық схемасын жүзеге асырған кезде, мұқият бақылау және деректер көлемін, түсінуді және қауіп моделін азайту үшін қажетті шаралар қажет.

Өнеркәсіптік модельдеу сияқты көптеген салаларда әртүрлі қолданбалар үшін кеңейтілген шешімдерді қамтамасыз ету үшін процесті болжаушылар ретінде көпқабатты беріліс нейрондық желілер (MFNNs) немесе терең нейрондық желілер (DNNs) пайдаланылады. DNN оқыту үшін, әдетте, дәстүрлі MSE жоғалту функциясын азайтуға негізделген стандартты қатені кері тарату

алгоритмі пайдаланылады. Өкінішке орай, бұл алгоритм оқу деректерін бұрмалайтын шектен тыс көрсеткіштерге бейім және сезімтал. Нәтижесінде, оқу деректері шектен тыс көрсеткіштермен ластанған, нәтижесінде алынған модельдің сенімділігі төмендейді және дұрыс емес үлгілерді тудыруы мүмкін, бұл рұқсат етілмейтін өнімділікке әкеледі [14].

М-бағалаушылары - сенімді статистикаға жататын және максималды ықтималдық бағалаушылары болып табылатын бағалаушылардың кең класы. М-бағалаушылары шағын шудың бұзылуына және деректерде шектен тыс мәндердің болуына төзімді болу үшін жасалған. Бірқатар жұмыстардағы М бағалаулар ауытқулары бар қиғаш деректер болған жағдайда NN оқу үдерісі үшін өнімділік функциясы ретінде ұсынылған. М-бағалаушылары квадраттық қалдықты басқа қалдық функциямен ауыстыру арқылы шектен тыс мәндердің әсерін азайтуға тырысады [8,9].

Көптеген зерттеушілер машиналық оқыту әдістерін қолдана отырып, автомобиль байланысы желілерінің өнімділігін арттыруға, сенімді қосылымды орнату кезінде қозғалыс қауіпсіздігіне, энергия тиімділігіне және трафик тиімділігіне қойылатын QoS талаптарын айтарлықтай арттыруға назар аударады. Шеткі көрсеткіштерге төзімдірек сенімді оқыту алгоритмін алудың негізгі тәсілдерінің бірі MSE өнімділігін жоғалту функциясын шектен тыс көрсеткіштер болған кезде өнімділікті жақсарту үшін басқа сенімді функциямен ауыстыру болып табылады [8].

Бұл дипломдық жұмыс тарауында машиналық оқыту әдістері автомобиль желілерінің өнімділігін бағалау үшін қолданылады. М-бағалаушылары деп аталатын сенімді статистикалық бағалаушылар жиынтығы оқу процесін жақсарту үшін дәстүрлі жоғалту функциясын және оқу деректері шусыз және шектен тыс мәндерді қамтитын кезде машиналық оқытудың роботтық оқыту моделін ауыстыру үшін сенімді жоғалту функциясы ретінде ұсынылады.

Осы тарауда келтірілген зерттеу нәтижелерін төмендегідей қорытындылауға болады:

1. Біріншіден, таза деректер жағдайында дәстүрлі MSE жоғалту функциясын ауыстыру үшін жоғалту функциясы ретінде М-баллдары бар көпқабатты алға бағытталған нейрондық желі (MFNN) ұсынылады. MFNN архитектурасы пайдаланылады, ол 20 жасырын нейроннан тұратын жасырын қабаты бар үш деңгейлі алға топологиядан тұрады.

Ұсынылған әдіс VANET желісінің екі қосымшасында қолданылады:

- VANET өнімділігі үшін қуатты нейрондық желіні оқыту негізінде бағалау.

- Нейрондық желіні оқыту негізінде VANET өнімділігі үшін пакет жоғалуын бағалау.

Бұл RMSE орташа квадраттық қатесін және үйрену жылдамдығы мәндерін қолданатын М-бағалау жоғалту функциялары мен дәстүрлі MSE жоғалту функциясы арасындағы салыстырмалы зерттеуді қамтамасыз етеді.

2. Жаттығу деректерін бұрмалайтын ауытқулар болған кезде дәстүрлі MSE жоғалту функциясының орнына VANET өнімділігін бағалау үшін терең

оқытуға негізделген жаңа алгоритм ұсынылды. Бұл жағдайда желі үш қабаттан тұрады, жасырын қабатта 100 жасырын нейрон бар.

M-бағалау жоғалту функциялары мен стандартты MSE жоғалту функциясын жаңа салыстыру RMSE және MAPE тұрғысынан және VANET трафик деректер жиынындағы әртүрлі шектен тыс жиындарда қолданылды және ұсынылған әдістің тиімділігін дәлелдеу үшін пайдаланылды.

3. Модельдеу негізіндегі сынақтардың нәтижелері M-сметалық сенімді жоғалту функциялары барлық жағдайларда ең жақсы өнімділікке ие және деректер таза болған кезде де, оның құрамында шектен тыс мәндер болған кезде де дәстүрлі MSE жоғалту функциясынан асып түсетінін көрсетеді.

Сонымен қатар, оқу процесінің сенімділігі ауытқуларға байланысты маңызды оқу қателерінің әсерін азайту және таза деректер немесе шектен тыс көрсеткіштер жағдайында өнімділікті жақсарту арқылы қамтамасыз етілді.

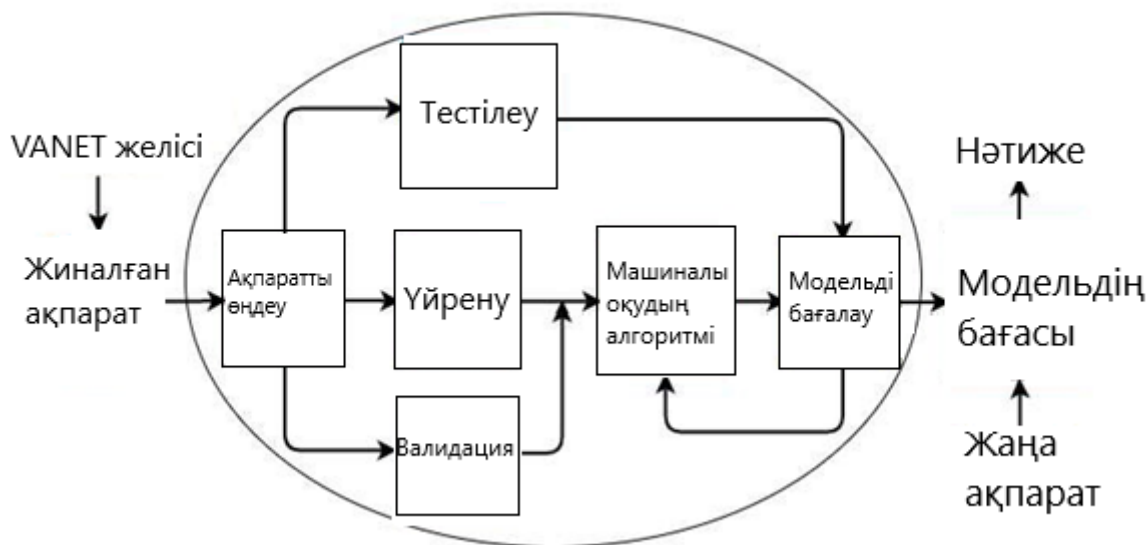
Жаттығу деректер жинағын алу үшін автомобиль желісінің моделі жасалды және желілік жүйе MATLAB көмегімен модельденді. Деректер жиынын жинап, талдап, өңдегеннен кейін бұл деректер жинағы балл қою процесі үшін машиналық оқыту үлгісіне кіріс ретінде пайдаланылды. Деректер жиынын желіге кіріс ретінде жүктегеннен кейін деректер жиыны Кіріс (I) және Шығыс (O) бағандарындағы екі ішкі жиынға бөлінеді, содан кейін тиісінше оқыту, тестілеу және тексеру ішкі жиындарына бөлінеді. Енгізілген деректерді нормалау нақты максимум немесе ең аз мәндермен үйлесімді $[-1, 1]$ аралықта жүзеге асырылады. Жасырын қабаттардағы барлық нейрондар үшін белсендіру функциясы ретінде сигма тәрізді функция (Tansig) таңдалды, ал шығыс қабатындағы нейрон үшін белсендіру функциясы ретінде сызықтық белсендіру функциясы таңдалды. Мұнда пайдаланылатын желілік оқыту функциясы Traincgf (Флетчер-Ривес жаңартуларымен біріктірілген градиенттік кері таралу). Жаттығуға болатын дәуірлердің ең көп саны - 5000 дәуір. Мақсатты өнімділік (өнімділіктің ең аз жоғалуы) $1e-3$.

ANN әдетте стандартты кері таралу алгоритмі (BPLA) арқылы оқытылады. Бұл әдіс ең танымал бақыланатын оқыту алгоритмі болып табылады, мұнда енгізу/шығару жұптары желіге берілген және дельта ережелеріне негізделген жоғалту функциясын пайдалана отырып, нақты және болжалды желі шығыстары арасындағы қатені азайту үшін салмақтар түзетілген. Жаттығу кезінде жаттығу моделі орнатылады, жоғалту функциясының градиенті есептеледі, содан кейін градиенттерге жауап ретінде желі салмақтары мен қиғаштықтары жаңартылады. Бұл операция ең аз шығыс қатесіне жеткенше қайталанатын.

ANN стандартты MSE жоғалту функциясын барынша азайтатын дәстүрлі кері таралу (BP) оқыту алгоритмі арқылы оқытылады. Дегенмен, бұл дәстүрлі кері таралу оқыту алгоритмі оқу ақпаратын бүлдіруі мүмкін, шектен тыс көрсеткіштерге сезімтал. Кейде оны шусыз деректер үшін немесе орташа нөлге тең болған кезде Гаусс таралымынан туындаған қателермен бүлінген деректер үшін ғана оңтайлы деп санауға болады [10]. Деректер қателіктермен немесе шектен тыс көрсеткіштермен бүлінсе, бұл сенімсіз әдіске әкеледі. Шектеулі мәселені шешу үшін M-бағалаушылары [8], R-бағалаушылары, L-

бағалаушылары, LMedS және LTS сияқты бірнеше сенімді статистикалық бағалаушылар бақылаулардан ауытқулардан қатты әсер етпейді.

Келесі деңгейде сынақ желісі тестілеу топтарынан бағаланатын модельдің өнімділігін бағалауды талап етеді және сынақ жиынында қате оқу кезінде байқалады. Бастапқы оқыту кезеңі әдетте валидация қатесін жаттығу жиынының қатесі ретінде азайтады. Дегенмен, желі оқытудан асып кеткенде, валидация қатесі әрқашан арта бастайды. Дипломдық жұмыста желі параметрлері тексеру үшін ең аз орнатылған қатемен сақталды. 2.1-суретте VANET өнімділігін бағалау үшін ұсынылған машиналық оқыту алгоритмдерінің блок диаграммасы көрсетілген.



2.1-сурет – VANET өнімділігін бағалау үшін ұсынылған алгоритмдердің блок-схемасы

2.2 Транспорттық желілері

Сымсыз байланыс пен сымсыз құрылғыларға өсіп келе жатқан сұраныс желілік зерттеулерді өздігінен ұйымдастыруға үлкен қызығушылық тудырды. Automotive Target Network (VANET) – MANET мобильді бір-теңімен желілерінің ерекше түрі. VANET желілері интеллектуалды көлік жүйелерін (ITS) құруды қамтамасыз ететін озық технология болып табылады. Олар тиімді және қауіпсіз көлік желісін қамтамасыз ету үшін IEEE 802.11р стандартына сәйкес көліктер арасында және жол бойындағы блоктар (RSU) және көлік құралдары арасындағы сымсыз байланысты қамтамасыз етеді. VANET кең ауқымды қауіпсіздік және қауіпсіздік емес қолданбаларды ұсынады. Қауіпсіздік қолданбалары жүргізуші мен жолаушылардың қауіпсіздігін қамтамасыз етуге арналған, мысалы, жолақты өзгерту туралы ескерту, соқтығысуды анықтау және т.б..

Әдетте, VANET көліктер пакеттерді әуе арқылы басқа көліктерге жіберу қажет болғанда жасалады. Сондықтан көліктер желі түйіндері ретінде әрекет ету үшін сымсыз қабылдағыштармен және компьютерлік модульдермен жабдықталуы керек. Бірнеше мүмкіндіктер VANET-ті тең дәрежелі желілердің басқа түрлерінен ажыратады. Түйіндердің қозғалысы мен жылдамдығына байланысты VANET топологиясы дәстүрлі MANET-пен салыстырғанда өте динамикалық, сондықтан VANET желісі үнемі жаңартылып отырады, әсіресе көліктің төмен тығыздығы кезінде. Кәдімгі MANET-тен айырмашылығы, VANET-те қуат немесе сақтау шектеулері жоқ, себебі VANET түйіндері портативті құрылғылар емес, көліктер болып табылады. VANET-ті MANET-тен ерекшелендіретін басқа ерекшеліктер - қосылымның географиялық сипаты, VANET сонымен қатар жол пайдаланушыларға электронды ақы алу, аудио/бейне алмасу, электронды төлем, бағытты бағдарлау, ауа райы туралы ақпарат, мобильді электрондық коммерция, Интернетке қосылу және т.б. сияқты ыңғайлы коммерциялық қолданбаларды ұсынады.

VANET архитектурасының мақсаты көліктер арасында немесе көліктер мен тұрақты жол бойындағы құрылғылар арасында байланысты қамтамасыз ету болып табылады, нәтижесінде келесі негізгі мүмкіндіктер пайда болады [16]:

- Мақсатты көліктен көлікке (V2V) желілер негізінен қауіпсіздік және тарату қолданбалары үшін тіркелген инфрақұрылымға сүйенбестен көліктер арасында тікелей байланысты қамтамасыз етеді.

- Көліктен инфрақұрылымға (V2I) өзара әрекеттесу көлікке ақпарат пен деректерді жинау қолданбалары үшін ең алдымен жол бойындағы құрылғымен байланысуға мүмкіндік береді.

- Гибридті архитектура V2I және V2V байланысын біріктіреді. Бұл сценарийде көлік қашықтыққа байланысты жол бойындағы инфрақұрылыммен не мульти-секпті немесе бір рет секіру арқылы байланыса алады. Бұл интернетпен немесе қашықтағы көліктермен ұзақ қашықтықта байланысты жеңілдетеді.

VANET жүйесінде түйіндер RSU (Roadside Unit) және басқа түйіндермен сымсыз байланысады. Осылайша, олар жол қозғалысы туралы, жолдың жабылуы немесе жолдағы жұмыстар, жол-көлік оқиғалары және т.б. туралы деректерді жылдам ала алады. Осы ақпарат негізінде жүргізушілер жол жағдайына байланысты ақылды шешім қабылдай алады, мысалы, межелі жерге бағытты өзгерту, жылдамдықты төмендету және т.б. Сонымен қатар, олар РМУ-дан баратын жеріне бағытты, тұрақтардың, қонақүйлердің, жанармай құю станцияларының және белгісіз аймақтағы ауруханалардың болуын сұрай алады. 2.2-суретте VANET архитектурасы көрсетілген.

- VANET тез өзгереді, бірақ біршама болжауға болатын топологиямен сипатталады.

- Желінің топологиясы өте тез өзгереді, сондықтан фрагментация жүйелі түрде жүреді.

- Түйіндердің жоғары жылдамдығына байланысты VANET-тегі кластер диаметрі салыстырмалы түрде аз.

- Брондау уақыты мен функциялары бойынша шектелген
- Инфрақұрылым қажет емес
- Болжалды топология (сандық карталарды пайдалану).
- Электрмен жабдықтауда проблемалар жоқ.



2.2-сурет – VANET желі архитектурасы.

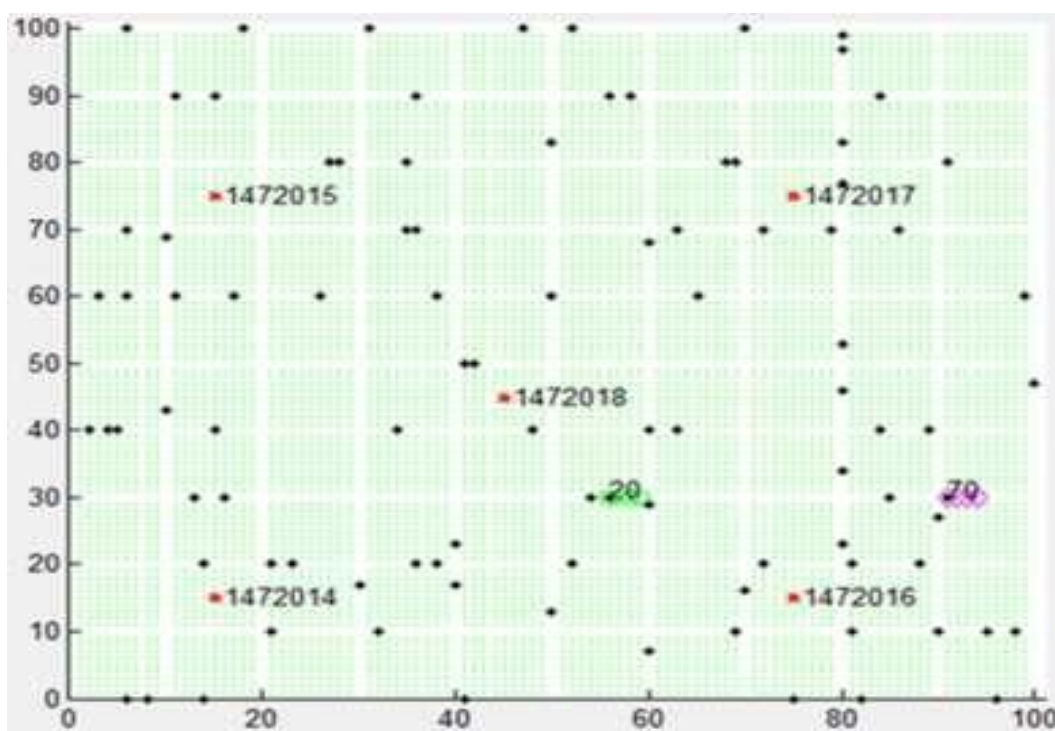
2.3 Айналадағы VANET-ті модельдеу

VANET өнімділігі мен басқа сипаттамаларын нақты жол жағдайында өлшеуге болады, бірақ қиын жағдайларда нәтижелердің құны мен дәлсіздігі теріс факторлар болып табылады. Сондықтан нақты ортаны адекватты түрде көрсететін модельдеуді жүргізген дұрыс. VANET-тің MANET-тен айырмашылығы, түйіндер қозғалыс ережелерін сақтауы керек, ал түйіндердің трафик үлгілері өте күрделі. Нақты желілердегі нәтижелерге жақын VANET модельдеу нәтижелерін алу үшін барабар ұтқырлық моделін құру өте маңызды. Қозғалыс үлгісі VANET тең дәрежелі желісіндегі түйіндердің қозғалыс үлгілерін анықтайтын ережелер жиынтығы болып табылады. VANET жүйесінде қозғалыс модельдерінің қашықтық, кедергілер, басқа көліктер, көлік қозғалысы және көліктен көлік арасындағы өзара әрекеттесу сияқты сипаттамалары мен шектеулері болады. Осындай ақылға қонымды дәл үлгіні жасаудың бір жолы - ізден нақты үлгіні жасау. Дегенмен, қазіргі уақытта VANET-ті кеңінен енгізудің болмауына байланысты нақты ізді алу мүмкін емес. [8,9].

Сондықтан, әрі қарай MATLAB ортасы арқылы ақылды қаладағы VANET желісі модельденді. Алдымен VANET үшін ұтқырлық картасы жасалды. AODV маршруттау хаттамасы оның өнімділігін зерттеу және бағалау үшін виртуалды

ұтқырлық картасы ретінде дайындалған. Жол желісі негізгі мүмкіндіктерді қамтитын ұтқырлық карталарын жасау арқылы әзірленді: қала геометриясы, түйіндер және RSU (Жол бойындағы бірлік). Қаланың өлшемі AODV енгізу үшін VANET түйіндері кездейсоқ бағытта қозғалатын шектерді анықтау үшін қажет. AODV маршруттау хаттамасын іске асыру қаланың максималды өлшемін және бірнеше түйіндерді қажет етеді және бірнеше RSU орнатылуы керек. Егер қала өлшемі қажетті модельдеу уақытынан үлкен болса, ол автоматты түрде кеңейтіледі. Бұл ретте бұл болжанады қаланың өлшемі ху осі бойынша 100x100. Ұтқырлық моделінде қаланың шетіндегі түйіндер бекітілген маршруттар бойынша кез келген бағытта қозғала алады.

2.3-суретте нүктелер желі дизайны мен конфигурациясына сәйкес оларға тағайындалған сәйкестендіру нөмірлері арқылы жеке түйіндер мен RSU орындарын көрсетеді. Бұл модельдің басталуы мен аяқталуы 20 және 70 түйін нөмірлері арқылы ретімен белгіленеді. Модельдеу модулі желі архитектурасын визуализациялайды және модельдеудің басталу және аяқталу уақытын таңдайды. Модельдеу картасындағы RSU орны кездейсоқ қозғалатын түйіндерге белгілі бір түйіннен алыс орналасқан басқа түйіндермен байланысуға көмектеседі. RSU қозғалыстағы көліктермен, соның ішінде қауіпсіздік ескертулері мен жол қозғалысы туралы ақпаратты қосуға және хабар алмасуға мүмкіндік береді; олар сондай-ақ тікелей немесе мульти-хоп қосылымдары арқылы қосыла алады. 2.3-суретте ақылды қаладағы VANET симуляциясы көрсетілген.



2.3-сурет – Қала орталығындағы VANET желісінің ортасын модельдеу

2.4 Жасанды нейрондық желіні оқыту

Жасанды нейрондық желіні оқыту – бұл нейрондық желі тапсырманы мүмкіндігінше дәл орындай алатындай желілік нейрондардың параметрлерін бағалаудың алгоритмдік процесі. Көптеген нейрондық желілер модельдері желі қателерін азайтатын оңтайлы салмақтар мен қиғаштықтардың жиынтығын табу арқылы оқытылады.

Жаттығу алгоритмдерін бастапқы оқыту деректерінің желіге беру жолына қарай жіктеуге болады.

Оқытудың екі түрі бар: бақыланатын оқыту және бақылаусыз оқыту. Біз бұл дипломдық жұмыста тек бақылаудағы оқытуға қызығушылық танытамыз. Бақыланатын оқытуда қосылым салмақтары болжамды нәтиже мен нақты нәтиже арасындағы айырмашылық негізінде реттеледі. Алға бағытталған нейрондық желі өзінің кіріс деректерінің сызықты емес функциясын есептейді. Сондықтан мұндай желіге нақты сызықтық емес функцияны есептеу тапсырмасын беруге болады. Бұл жағдайда екі жағдай туындауы мүмкін.

Біріншіден, сызықты емес функция аналитикалық жолмен белгілі болса; содан кейін нейрондық желі функцияны жуықтау тапсырмасын орындайды. Екінші жағдайда, сызықты емес функция аналитикалық түрде белгілі емес, бірақ функцияның сандық мәндерінің соңғы саны белгілі. Сонымен қатар, көптеген қолданбаларда бұл мәндер нақты белгісіз, өйткені өлшемдер оларды физикалық, химиялық, қаржылық, экономикалық, биологиялық және т.б. процестерде қабылдайды. Содан кейін желінің міндеті өлшенетін мәліметтердің регрессия функциясын жуықтау, процестің статистикалық моделі болу.

Қолданбаларының көпшілігінде екінші класты есептер үшін алға бағытталған нейрондық желілер және бақыланатын оқыту қолданылады. Оқытуды «қадағаланатын» деп санауға болады, өйткені желі орындауы тиіс функция кейбір немесе барлық жағынан белгілі: «мұғалім» кіріс мәндері мен сәйкес (болжамды) шығыс мәндерінің «мысалдарын» береді [20]. Бақыланатын алгоритмдер дельтаны оқыту ережесін және кері таралу алгоритмін қамтиды. 1.4-суретте бақылаудағы оқытудың блок-схемасы көрсетілген.

Оңтайлы салмақтар мен қиғаштықтарды табу үшін оқыту алгоритмдерінің екі санаты бар. Бұл категориялау мақсатты жаһандық минимумды табудағы оқыту алгоритмінің әрекетіне негізделген.

2.4.1 Қолданыстағы кері таралуды оқыту алгоритмдері.

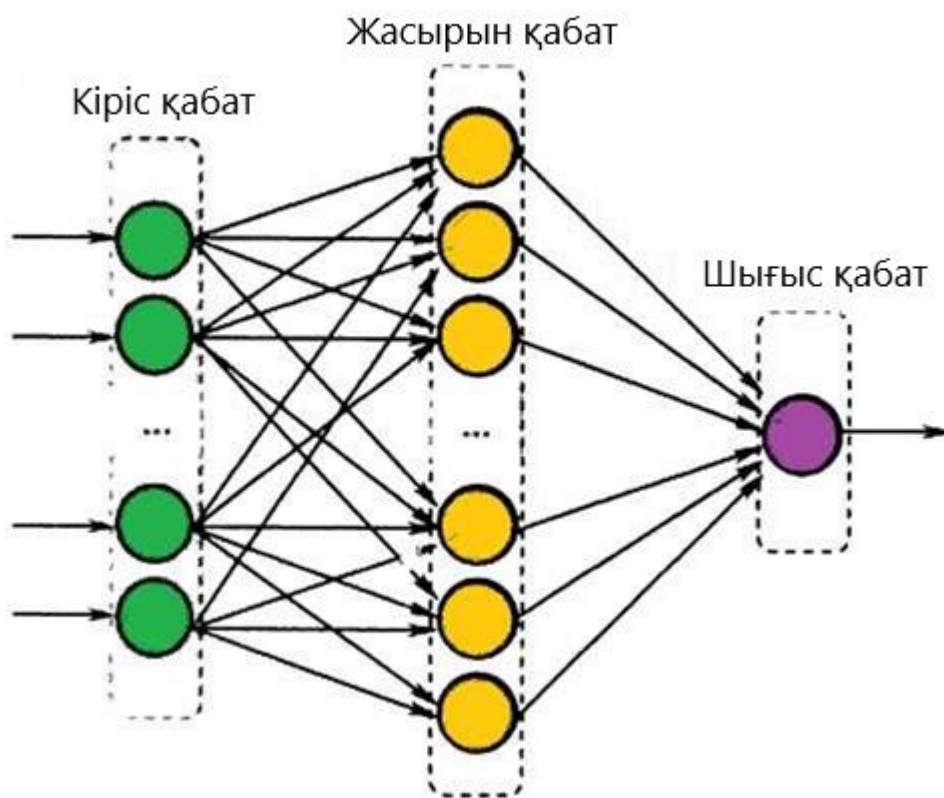
Машиналық оқытуда кері таралу (BP) алгоритмі алға қарай берілетін нейрондық желілерді үйрету үшін кеңінен қолданылады. Басқа жасанды нейрондық желілер (ANN) және жалпы функциялар үшін кері таралудың жалпыламалары бар. Нейрондық желіні орнату кезінде кері таралу желінің салмақтарына қатысты жоғалту функциясының градиентін тиімді есептейді.

Осы тиімділіктің арқасында көп қабатты желілерді жаттықтыру үшін градиент әдістерін қолдануға және жоғалтуларды азайту үшін салмақтарды

жаңартуға болады; әдетте градиенттің түсуі немесе стохастикалық градиенттің түсуі сияқты нұсқалар қолданылады. Кері таралу алгоритмі тізбек ережесін пайдалана отырып, әрбір салмаққа қатысты жоғалту функциясының градиентін есептейді. Ол тізбек ережесіндегі аралық терминдердің артық есептеулерін болдырмау үшін градиент қабатын қабат бойынша есептеуді және соңғы қабаттан артқа қарай қайталауды қамтиды. Мұндай тапсырмалар динамикалық бағдарламалау деп аталады.

Қатені кері тарату – бұл желі салмағына қатысты нейрондық желінің қателік функциясының бірінші жартылай туындыларын шығаратын әдіс. Осының негізінде оқыту ережелері салмақтарды реттеу арқылы желіні оңтайландырады, осылайша желі шығыстары мен сәйкес бақылау арасындағы айырмашылықтар орташа есеппен минималды болады.

Бұл бөлімде біз стандартты кері таралу алгоритмімен айналысамыз. Жеңілдету үшін 2.4-суретте көрсетілген желі архитектурасын қарастырайық.



2.4-сурет – Тікелей таратудың үш қабатты нейрондық желісі.

Суреттегі нейрондық желінің кіріс, жасырын және шығыс қабаттарын i , h және o индекстері арқылы белгілейік. 2.4. Кез келген нейронның кірісі I және шығысы O деп белгіленеді. Таңдалған i жағдайы үшін тәуелсіз айнымалының мәндері -1 мен 1 аралығында қалыпқа келтірілген, диаграмманың сол жағындағы кіріс нейрондарына ұсынылған. Егер x k -нұсқа болса, онда $I \in \{1, k\}$. Әр бақылауды желі келесідей өңдейді. Кіріс қабатының нейрондары бақылауды

жасырын қабатқа тарату үшін қызмет етеді, сондықтан кіріс қабатының нейронының шығысы $O_i = I_i$ болады. Бұл 2.4-суретте бейнеленген жасырын нейрондар мен шығыс нейрондардың сигма тәрізді мінез-құлқын қоспағанда; жасырын қабаттың h -ші нейронының кірісі барлық желілік кірістер бойынша өлшенген қосынды болып табылады. Әр бақылауды желі келесідей өңдейді:

$$I_h = \sum_i W_{hi} O_i \quad (2.1)$$

Жалғау нейрондарын жасырын және шығыс нейрондарға қосатын салмақтар осы нейрондар үшін шекті білдіреді, яғни нейронның жалпы кірісі нейрон кез келген маңызды шығысты алғанға дейін шекті мәнге жетуі керек. Кәдімгі статистикалық модельдерде қиғаш нейрон кесу (немесе тұрақты) ретінде қызмет етеді. O_h жасырын нейронының шығысы (2.1) арқылы берілген кіріске қолданылатын сигма тәрізді функция:

$$O_h = \frac{1}{1 + \exp(-\sum_i W_{hi} O_i)} \quad (2.2)$$

Жасырын қабат іске қосылғаннан кейін оның шығысы ағымдағы бақылау үшін желі шығысын жасау үшін өңделетін шығыс деңгейіне беріледі:

$$I_o = \sum_h W_{oh} O_h \quad (2.3)$$

$$O_o = \frac{1}{1 + \exp(-\sum_i W_{hi} O_i)} \quad (2.4)$$

Нейрондық желілердің үлкен пайдасы мен икемділігі желіге дұрыс салмақтарды, демек, бақылаулардың берілген жиынтығы үшін қажетті функцияны жасауға мүмкіндік беретін оқыту алгоритмдерін қолданудан туындайды. Желіде енгізу-шығару векторлары $(x_1, x_2, x_3 \dots x_k, y)$ ұсынылғандықтан, оқу алгоритмі жүйе шығысты дұрыс шығаратын функцияға жақындағанша қосылым салмақтарын реттейді. Оқыту алгоритмдерінің бірнеше нұсқалары бар болса да, біз оңтайлы біріктіру салмақтарын анықтау үшін бір дәстүрлі градиент әдісін және қатенің кері таралуын қолданамыз. Оқыту алгоритмінің мақсаты желі шығысындағы қателер қосындысының квадраттық функциясын азайту үшін әрбір циклден кейін қосылым салмақтарын реттеу болып табылады:

$$E = MSE = \frac{1}{N} \sum_n \sum_o \frac{1}{2} (O_o - y_o)_n^2 \quad (2.5)$$

Мұнда y_o тәуелді айнымалылардың белгілі мәндері, n -ден асатын қосынды- жалпы бақылаулар, O_o - салмақтарға E тәуелділігінің шығысы, ал O_{th} шығыс нейроны есептеледі және $(O_o - y_o) = r_i$ – қалдық, яғни i -ші бақылау мен оның таңдалған мәні арасындағы айырмашылық. Тұрақты $1/2$ келесі

есептеулерді жеңілдетеді. Кері таралу E әр салмақпен қалай өзгеретінін анықтау үшін сәйкес жартылай туындыларды пайдаланады. Содан кейін салмақтар пропорционалды түрде өзгертіледі $\frac{\partial E}{\partial W}$, сонымен қатар алдыңғы циклдегі салмақтың өзгеруіне пропорционалды. Ағымдағы желі циклі кезіндегі салмақтың өзгеруі с мына формуламен анықталады:

$$\Delta W(c) = -\alpha \frac{\partial E}{\partial W} \quad (2.6)$$

мұндағы α – оқу жылдамдығының параметрі.

Үш қабаты бар нейрондық желі жағдайында кері таралу алгоритмі екі қадамнан тұрады: біріншіден, желінің жасырын және шығыс қабаттары арасында орналасқан W_{oh} салмақтары бойынша ішінара туындыларды (2.5-теңдеу) есептейміз. Ол үшін тізбек ережесін қолданамыз.

Екіншіден, тізбек ережесін қайта қолдану арқылы кірісті жасырын қабатқа қосатын W_{hi} салмақтарына қатысты жартылай туындыны (2.5 теңдеу) есептейміз. Кері таралу алгоритмінің бірінші қадамына жақындай отырып, W_{oh} салмақтарына қатысты желілік қателік функциясының ішінара туындысы (2.5-теңдеу) келесідей есептеледі:

$$\frac{\partial MSE}{\partial W_{oh}} = \frac{1}{N} \sum_{n=1}^N (O_o - y_o) \frac{\partial O_o}{\partial I_o} \frac{\partial I_o}{\partial W_{oh}} \quad (2.7)$$

Жасырын қабаттағы h нейрондары o шығыс нейрондарымен толық байланысқан деп есептесек, қателік функциясының жартылай туындыларының жиыны (o, h) болады (2.5 теңдеу). Ішінара туындылар үшін қарапайым белгілер (2.7-теңдеу) көмекші мүшені (Теңдеу 2.8):

$$\delta_o = (O_o - y_o) f'(I_o) \quad (2.8)$$

мұндағы δ_o - жеке желі қатесінің туындысы (O_o - y_o) және белгілі бір салмаққа қатысты f белсендіру функциясының ішінара туындысы W_{oh} . Осыған байланысты f тікелей I_o шығыс қабатының кірісіне байланысты. Көмекші δ_o (2.8-теңдеу) мүшесін (2.7-теңдеу) орнына қою мынаны береді:

$$\frac{\partial MSE}{\partial W_{oh}} = \frac{1}{N} \sum_{n=1}^N \delta_o O_h \quad (2.9)$$

Осылай жалғастыра отырып, біз желінің екінші деңгейінің жиынтық градиентін аламыз, яғни W_{oh} салмақтарына қатысты ішінара туынды (2.5-теңдеу). (2.9-теңдеу) сәйкес жартылай туындылар жасырын нейрондардың Oh шығысының және δ_o көмекші терминінің туындысы ретінде анықталады (2.8-теңдеу).

W_{hi} салмақтарына қатысты желілік қателік функциясының (2.5-теңдеу) жартылай туындыларын есептеу тізбек ережесін қайта орындауды талап етеді. Тізбек ережесін екі рет қолданатын болсақ, W_{hi} салмақтарына қатысты жартылай туындылар (2.5-теңдеу):

$$\frac{\partial MSE}{\partial W_{hi}} = \frac{1}{N} \sum_{n=1}^N \sum_{o=1}^k (O_o - y_o) \frac{\partial O_o}{\partial I_o} \frac{\partial I_o}{\partial O_h} \frac{\partial O_h}{\partial I_h} \frac{\partial I_h}{\partial W_{hi}} \quad (2.10)$$

$$\frac{\partial MSE}{\partial W_{hi}} = \frac{1}{N} \sum_{n=1}^N \sum_{o=1}^k (O_o - y_o) f'(I_o) W_{oh} f'(I_h) O_i \quad (2.11)$$

(2.7 теңдеу) δ_o көмекші мүшесін (теңдеу) орнына қою келесі теңдеуге әкеледі:

$$\frac{\partial MSE}{\partial W_{hi}} = \frac{1}{N} \sum_{n=1}^N \sum_{o=1}^k \delta_o W_{oh} f'(I_h) O_i \quad (2.12)$$

i -ші кіріс қабатының нейрондары жасырын қабаттың нейрондарымен толық байланысқандықтан, ішінара туындылар жиынын (I_h) аламыз. Қайтадан, (2.12) тармақтағы жартылай туындылар үшін белгілеуді δ_h көмекші шамасының көмегімен жеңілдетеміз, ол келесідей анықталады:

$$\delta_h = f'(I_h) \sum_{o=1}^k W_{oh} \delta_o \quad (2.13)$$

Көмекші δ_h термині (2.13-теңдеу) екі мультипликативті блоктан тұрады, бірінші блок W_{hi} үлес салмағына қатысты f' жасырын қабатты белсендіру функциясының ішінара туындысы болып табылады.

Біз қазір желінің бірінші деңгейін қарастырып жатқандықтан, белсендіру функциясы I_h кірісіне байланысты. Екінші блок - W_{oh} бойынша өлшенген δ_o көмекші мәндерінің қосындысы. (2.13-теңдікті) (2.12-теңдеу) орнына қою желінің бірінші деңгейінің жиынтық градиентін береді:

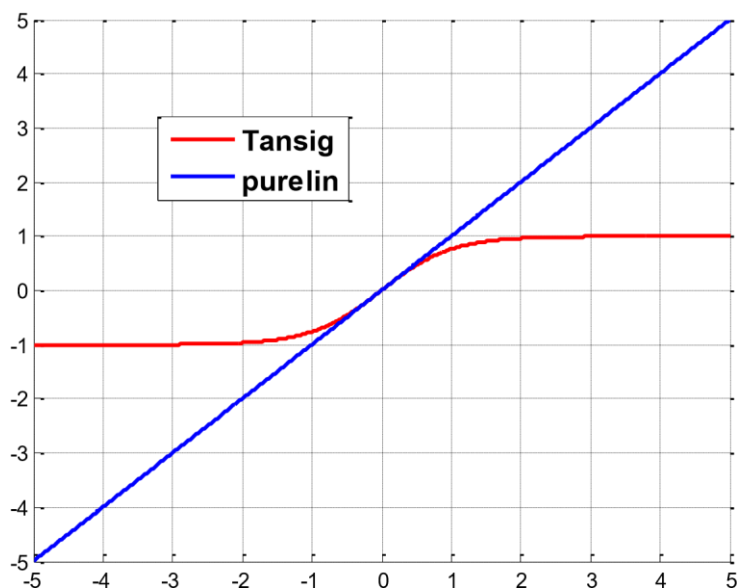
$$\frac{\partial MSE}{\partial W_{hi}} = \frac{1}{N} \sum_{n=1}^N \delta_h O_i \quad (2.14)$$

Әрі қарай, кері таралу алгоритмін бір оқыту үлгісі жағдайында 3-қабатты нейрондық желіге қолдану арқылы қарастырайық (2.6-сурет), көрсетілгендей кері таралу алгоритмінен туындаған қателер ағыны желінің тікелей ақпараттық жолына қайшы келеді. Бұл тура және кері жолдардың қосындыларын кері индекстеумен түсіндіріледі.

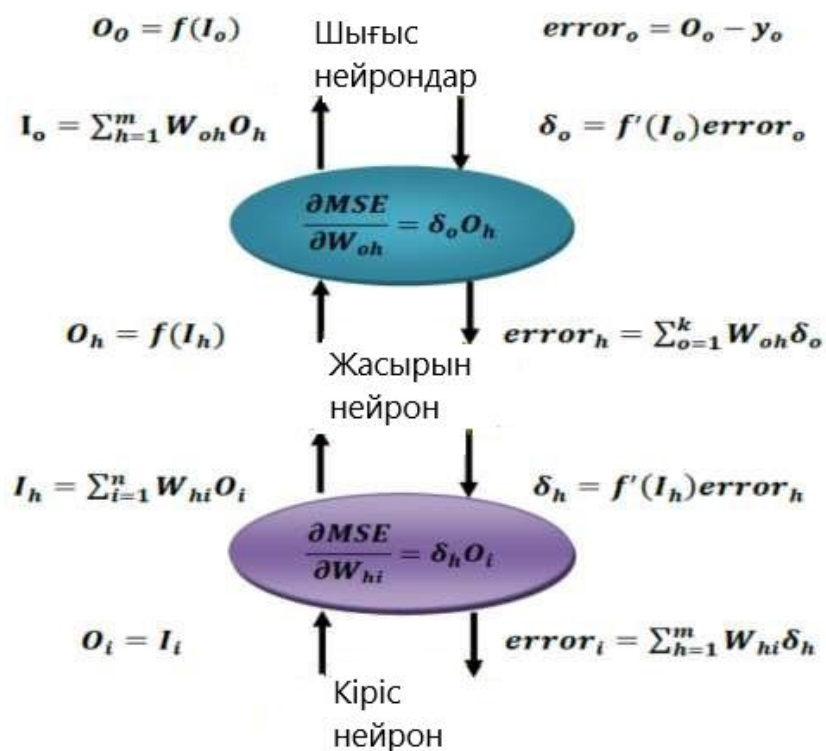
Кумулятивтік градиенттер (2.9-теңдеу) және (2.14-теңдеуі) қатенің тура және кері таралу жолдары арасындағы қиылысу. Алға таралу арқылы есептелетін O_i және O_h шығыстары δ_h және δ_o кері таралу көмекші мүшелеріне көбейтіледі, ішінара туындыларды есептеу тәсілі.

Көмекші δ_o және δ_h (2.10-теңдеу) және (2.13-теңдеуі) қате туралы ақпаратты желі арқылы жасырын түрде таратады. Дегенмен, қателердің нақты


ағыны желінің артқы жолы бойынша error, error_h және error_i таралуынан туындайды.




2.5-сурет – Нейрондық желілер үшін қолданылатын белсендіру функциялары (гиперболалық тангенс және сызықтық).



2.6-сурет – Оңай оқу үшін кері таралу алгоритмі.



2.7-сурет – GM және Huber бағалауларына әсер ету функциялары.



2.8-сурет – L2, L1 және LMLS ұпайларына әсер ету функциялары

Бұрын талқыланған M-балл концепциясына негізделген дәстүрлі кері таралуды оқыту алгоритмін күшейту және осылайша шеткі мәндердің әсерін азайту үшін r_i^2 квадраттарын басқа қалдық функциямен ауыстыру қажет, бұл келесіге әкеледі:

$$E = \sum r_i \rho(r_i) \quad (2.20)$$

мұндағы $\rho(r_i)$ - нөлге тең бірегей минимумы бар асимметриялық, оң-анықталған функция және квадраттық функциядан аз өсетін етіп таңдалған. Бұл жағдайда біз оқыту алгоритмінің бір түрі ретінде градиенттің түсуіне негізделген салмақ

жаңартуын аламыз. Мұны кез келген басқа ұқсас оқыту алгоритміне (конъюгаттық градиент сияқты) кеңейтуге болады. Салмағы (Вт) жаңартылды.

$$\Delta W_{ok} = -\alpha \frac{\partial E}{\partial W_{ok}} = \frac{\partial \rho(r_i)}{\partial W_{ok}}, \quad (2.21)$$

$$\Delta W_{ok} = -\alpha \frac{\partial \rho(r_i)}{\partial o_o} \cdot \frac{\partial \rho(f_s)}{\partial v_o} \cdot O_h, \quad (2.22)$$

мұндағы O_h – жасырын қабаттың шығысы, O_o – шығыс қабатының шығысы, v_o – нейронмен (О) байланысты активтендіру функциясының кірісінде генерацияланған жергілікті өріс, ал f_s – нейрондардың активтендіру функциясы. Бұл жұмыста шығыс қабатының нейрондары белсендіру функциясын пайдаланады. Мұнда кіріс қабатының кірісін, кіріс қабатының шығысын және жасырын қабаттағы нейрондардың белсендіру функциясын байқаймыз. Бұл жағдайда жасырын қабаттардағы нейрондар үшін Tansig (гиперболалық тангенс) функциясы қолданылды. Суретте. 2.4 екі функцияны да көре аламыз: сызықтық және гиперболалық тангенс. Сигма тәрізді функция гиперболалық тангенс функциясының ерекше жағдайы екенін ескеріңіз.

$$\Delta W_{ki} = -\alpha \frac{\partial E}{\partial W_{ki}} = \frac{\partial \rho(r_i)}{\partial W_{ki}}, \quad (2.23)$$

$$\Delta W_{ki} = -\alpha \frac{\partial \rho(r_i)}{\partial o_o} \frac{\partial f_s}{\partial \vartheta_o} W_{ki} \frac{\partial f}{\partial o_i} I_i \quad (2.24)$$

2.5 Таза деректер болған кезде транспорттық желілерінде сенімді ANN пайдалану (шу жоқ)

Бұл бөлімде таза деректер болған кезде нейрондық желілерді пайдалану арқылы VANET модельдеуінің нәтижелері берілген. Деректер жинағы сәйкесінше 70%, 15% және 15% пайыздық мөлшерлемелермен оқыту, тестілеу және тексеру ішкі жиындарына бөлінді. VANET трафигінің өнімділігін бағалау үшін жасанды нейрондық желі моделі жасалды. Күшті кері таралу алгоритмімен үйретілген ANN сенімді жоғалту функциялары ретінде М-бағалауларды да, дәстүрлі MSE жоғалту функциясын да пайдаланады. Жоғарыда аталған барлық жоғалту функциялары шусыз деректер болған кезде оңтайлы VANET өнімділігін табуға тырысады. Мақсат - таза деректерді (шу жоқ) пайдалана отырып, VANET өнімділігін бағалау үшін сенімді ANN әзірлейді.

Модельдеу нәтижелеріне сүйене отырып, жоғарыда аталған барлық М-бағалауыштары мен дәстүрлі қолданылатын MSE тиімділігі салыстырылды. Күшті және дәстүрлі бағалаушылардың тиімділігін салыстыру үшін біз MSE (RMSE) квадрат түбірін және барлық зерттелген М-бағалауыштары үшін оқу жылдамдығын қолданамыз:

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^N (t_i - y_i)^2}{N}} \quad (2.25)$$

мұндағы t_i - x_i -ның нақты мәні, ал y_i - нейрондық желінің шығысындағы нәтиже кірістегі x_i мәні.

Бұл бөлімде біз ұсынылған және дәстүрлі сияқты барлық жоғалту функциялары үшін оңтайлы VANET өнімділігін табамыз.

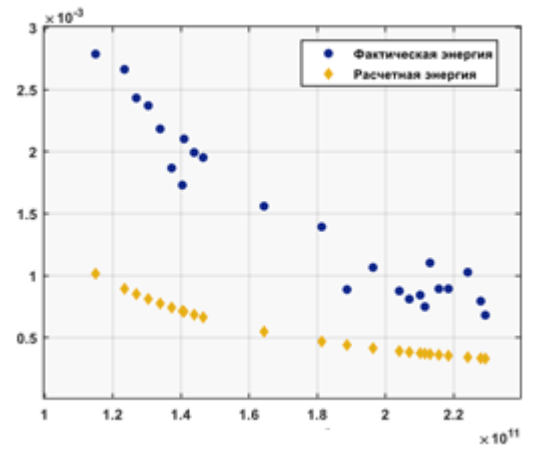
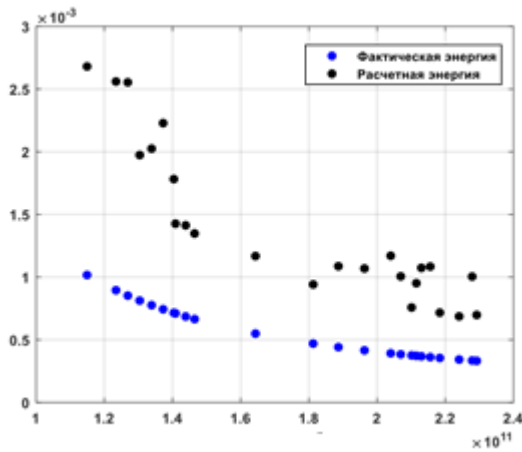
Ол үшін біз оқыту деректер жинағын құру және MATLAB көмегімен VANET жүйесін имитациялау үшін VANET желісінің моделін құрастырамыз. Деректер жиынтығын жинап, талдап, өңдегеннен кейін оны бағалау процесі үшін ANN-ге кіріс ретінде пайдаланамыз. Деректер жиынын желіге кіріс ретінде жүктегеннен кейін, кіріс (I) және шығыс (O) бағандарында деректер жиынын екі ішкі жиынға бөлеміз, мұнда кіріс VANET өткізу қабілеттілігі болып табылады. Энергияны тұтыну ретінде ANN пайдаланудың болжамды нәтижесін көрсетейік және алдымен оқу үдерісі үшін дәстүрлі және сенімді бағалаулардың тиімділігін салыстырайық.

2.2-кестеде келтірілген нәтижелер бүкіл оқу процесі бойынша орташа алынған.



Кесте 2.2 - Тұрақты және дәстүрлі бағалауларды салыстыру

Баға	RMSE	Өңдеу уақыты
MSE	6.1706e-004	2.6875
Коши	5.0916e-004	2.4844
GM	4.4933e-004	2.7500
әділ	4.8975e-004	2.5000
L1	4.8023e-004	6.0469
LMLS	4.8023e-004	2.5000
Хубер	5.0048e-004	2.4531

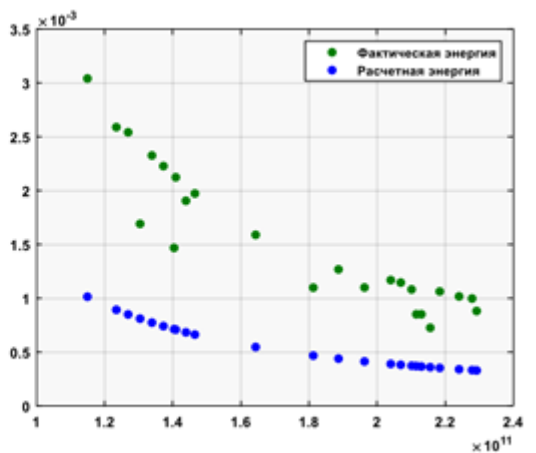
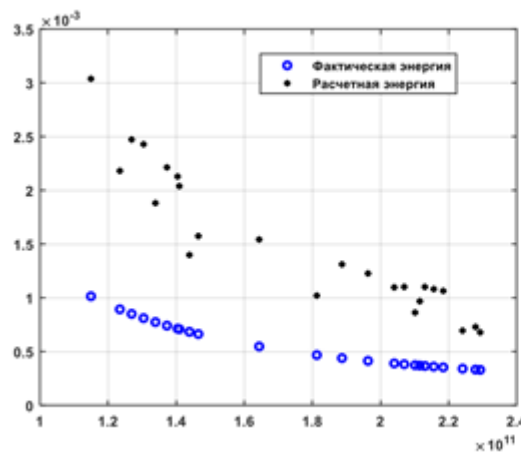
Модельдеу нәтижелеріне сүйене отырып, Geman-McLure (GM) M-бағалаушысы басқа M-бағалаушылармен және MSE пайдаланумен салыстырғанда 4,4933e-004 мәні бар RMSE тұрғысынан ең жақсы өнімділікке ие деп айтуға болады. Сонымен бірге, L1 және LMLS M-бағалаулары үшін RMSE мәндері GM бағалауы үшін RMSE-мен RMSE 4.8023e-004 өте жақын мәнге ие екенін атап өткен жөн. Бұған қоса, «әділ» бағалаулар, сондай-ақ Хубер және Коши бағалаулары да дәстүрлі MSE метрикасын пайдаланудан айтарлықтай жақсырақ нәтижелер береді. Оқу жылдамдығы бойынша ең жақсы нәтижелер Huber M-балы – 2,4531 с.




2.9-сурет – Болжау нәтижелері: MSE бағалаулары (а), «әділ» М-бағалау (б).



2.10-сурет – Нәтижелерді болжау: М-балы L1 (а), М-балы GM (б).



2.11-сурет – Болжау нәтижелері: Коши М-бағалаушысы (а), LMLS М-бағалаушысы (б).

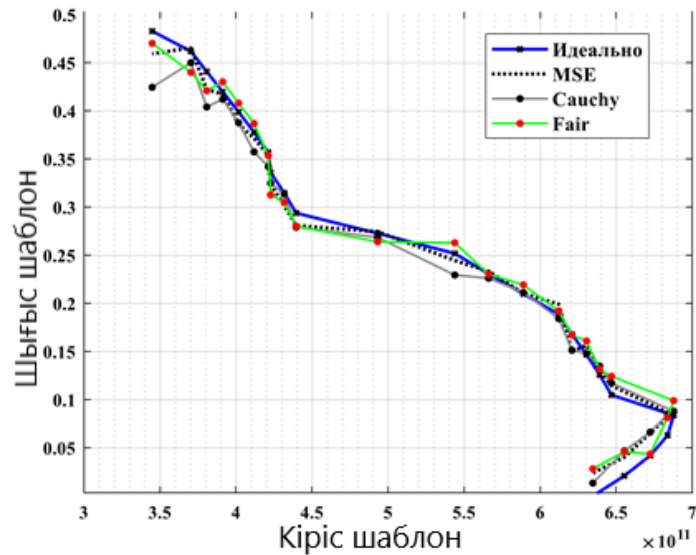


2.12-сурет – Хьюбердің М-бағасын болжаудың нәтижесі


2.12-суретте жоғарыда аталған барлық бағалаулар бойынша өткізу қабілетіне байланысты энергия тұтынуды болжау нәтижелері көрсетілген. Бұл жағдайда нақты қуат тұтыну шеңбер белгішесімен, ал болжамды мән нүктемен немесе басқа таңбамен көрсетіледі. Айта кету керек, барлық бағалаулар нейрондық желінің шығысында жеткілікті жақсы нәтиже береді, бірақ VANET желілерінде машиналық оқыту үшін жоғарыда келтірілген сандық нәтижелерді ескере отырып, сенімді Moests пайдалану ұсынылады.

2.17-суретте А жинағын жоғары сапалы шусыз деректермен пайдаланған кезде сенімді және дәстүрлі жоғалту функцияларымен үйретілген барлық модельдер шамамен баламалы идеалды үлгі жауаптарына ие екенін көрсетеді. Енгізу үлгісі ұлғайған сайын болжалды үлгі бірте-бірте азаятынын ескеріңіз.

2.18 суретте сәйкесінше MSE, Cauchy және Fairness жоғалту функциясына сәйкес үш жағдайда DNN оқыту кезінде әр модельді сынау кезіндегі жоғалту көрсетілген. Біз барлық жағдайларда көп оқу дәуірлерінен кейін қатенің бірте-бірте төмендейтінін анықтадық. Ең жақсы тексеру өнімділігі сәйкесінше дәстүрлі Коши және Fair MSE жоғалту функцияларын пайдаланатын оқыту желісінің 63 дәуірінде 0,015838, 45 дәуірде 0,0012387 және 43 дәуірінде 0,018973 болып табылады.



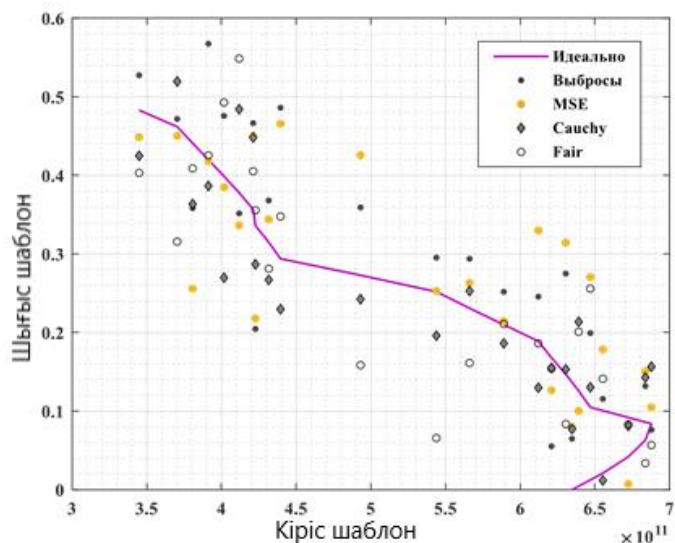
2.17-сурет – А деректер жиынына арналған дәстүрлі MSE функциясымен салыстырғанда сенімді Коши функциясын және сенімді әділ функциясын пайдалану кезіндегі жоғалтулар.



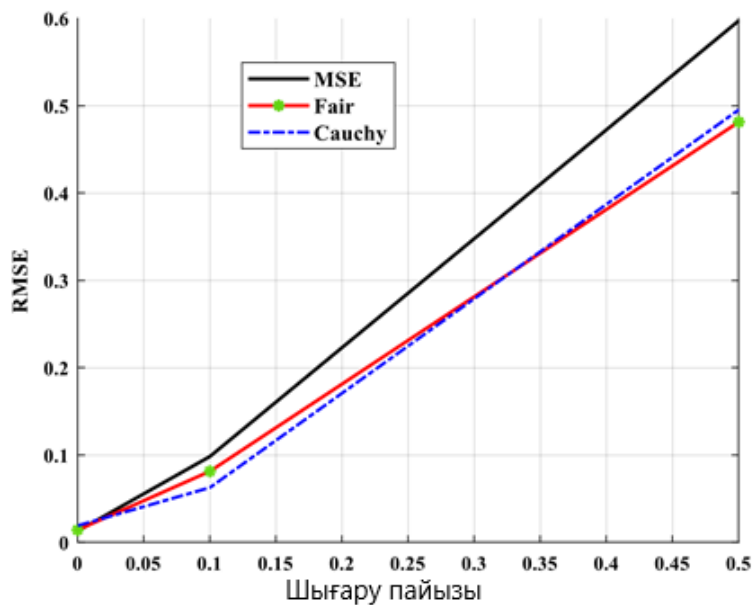
2.18-сурет – А деректер жинағы үшін тренингтен кейінгі DNN тексеру нәтижелері.

2.19-суретте В жиынын Гаусс шуымен бұрмаланған деректерде пайдаланған жағдайда, Коши жоғалту функцияларын және әділ жоғалту функциясын пайдалана отырып болжау нәтижелері әлдеқайда жақсырақ және идеалды үлгіге жақын болады, ал дәстүрлі MSE жоғалту функциясын пайдалану айтарлықтай болады. Бұл жағдайда оқыту нәтижесі 2.20-суретте көрсетілген. Дәуір саны артқан сайын шығын азая беретінін байқауға болады. Дәстүрлі MSE жоғалту функциясын қолданатын ең жақсы тексеру өнімділігі 46-шы дәуірде 0,06399 болып табылады. Күшті әділ жоғалту функциясы жағдайында ең жақсы

сынақ өнімділігі 44-ші дәуірде 0,07479 болып табылады. Сондай-ақ, сенімді Коши жоғалту функциясын қолданатын ең жақсы сынақ өнімділігі 54-ші дәуірде 0,0040613 болып табылады.



2.19-сурет – В деректер жиынына арналған дәстүрлі MSE функциясымен салыстырғанда сенімді Коши функциясын және сенімді әділ функциясын пайдалану кезіндегі жоғалтулар.



2.20-сурет – RMSE-нің шығарындылар пайызына тәуелділігі.

3 Машинады оқыту негізіндегі бесінші және келесі бұрпақ байланыс желілерін болжау

3.1 Кіріспе

Жасанды интеллект (AI) жиналатын деректердің үлкен көлемін өңдеу және оған тиісті мән беру үшін қажетті негізгі құрамдасқа айналуға. AI жүйе тапсырмаларды орындай алатын немесе интеллектуалды ақпаратты жақсартып алатын Интернет заттарының (IoT) деректер талдауын қолдай алады. Осылайша, IoT құрылғысы үшін AI адамның араласуынсыз деректерді талдай алады, шешім қабылдай алады және осы ақпаратпен жұмыс істей алады [27].

Machine Learning ML – ақпараттан үйренетін және болжам жасай алатын алгоритмдерді әзірлеумен айналысатын әдіс. Заманауи технологиялар AI алгоритмдерін өте тиімді енгізуге мүмкіндік береді. Дегенмен, трафик көлемі артып, қозғалыстың біркелкі еместігі де артып келеді. Заттар интернеті және өте төмен кідіріс ультра сенімді байланыстар QoS шешімдерін қабылдауда жоғары тиімділікті талап ететін көптеген талаптарды ұсынады, өйткені қолданыстағы QoS технологиялары қажетті сапа деңгейін қамтамасыз ете алмайды. Көптеген шаралар географиялық орналасу және жазылушы трафигі және жоғары жылдамдықты саяхат сияқты динамикаға байланысты сайтқа тән жүктеме мен кешіктіруді болжау үшін қажет. Операторлардың ортақ жүйесі болуы керек, AI интернет заттары және тактильді интернет сияқты 5G желілерінде маңызды рөл атқарады, өйткені ол деректерден құнды түсініктерді жылдам ала алады. ML температура, қысым, ылғалдылық, ауа сапасы, діріл және дыбыс сияқты сенсорлар мен смарт құрылғылар арқылы жасалған ақпараттағы ауытқуларды автоматты түрде анықтай алады. AI технологиялары тану, өзін-өзі үйрену, өзін-өзі емдеу, контекстен хабардар болу және автономды шешім қабылдау үлгілеріне негізделген күрделі шешімдер қабылдау үшін IoT смарт құрылғыларына қолданылатын машиналық оқыту стратегияларын кеңейтеді. AI сандық егіздердің болашақ қолданбаларына және автономды көлікте, IoT және болжамды техникалық қызмет көрсету қолданбаларында рөл атқаратын үздіксіз оқытуға үлкен әсер етеді [20].

AI ақпарат пен деректер ағындарын өңдеу және табу сияқты сымсыз желілер үшін әртүрлі пайдалану жағдайларында кеңінен қолданылады. Ол сонымен қатар уақыттық қатарлар деректерін болжау және өңдеу үшін, сондай-ақ барлық дерлік технология салаларында маңызды рөл атқаратын нақты уақыттағы географиялық және позициялық ақпарат үшін пайдаланылуы мүмкін. Ол ақпараттандырудың барлық дерлік салаларындағы қолданбаларға, бағалау құралдарына, есептеу әдістеріне, деректерді өңдеу әдістеріне және интерфейсті басқару параметрлеріне әсер етеді. 5G жаңа технологиялардың (гетерогенді желілер) жылдамдығы мен комбинациясын арттырады, ал AI машиналар мен жүйелерге адамдар сияқты интеллектуалды жұмыс істеуге мүмкіндік береді. Осылайша, 5G бұлптағы қызметтерді ұсынуды тездетеді, сонымен бірге сол деректерді тезірек талдайды және үйренеді [8,9].

Сымсыз байланыс экономикалық, техникалық, әлеуметтік жағдайларды, қауіпсіздік және білім беру жағдайларын дамытудың қозғаушы күші болып табылады. Ол сондай-ақ жаңа ұрпақтың қажеттіліктерін қанағаттандыру үшін өсу факторын қолдайды. Зерттеушілер адам өмірін жақсартуға көмектесетін жаңа сымсыз технологиялар мен механизмдерді, мысалы, заттар интернетін, 5G, автокөлік желілерін, тактильді интернетті және т.б. дамыту үшін үнемі ұмтылуда. Терең оқыту сияқты есептеу қуаты мен машиналық оқыту әдістеріндегі жетістіктердің арқасында AI қауіпсіздік, желі құру, ақпаратты іздеу және т.б. сияқты әртүрлі қолданбаларда тамаша нәтижелер береді. Сөзсіз, AI пайдаланушының араласуын азайтады және тақырыптық аймаққа қарамастан сенімді нәтижелер береді. Осылайша, жасанды интеллектті дамыту сонымен қатар желіні тиімді басқару үшін 5G желілері үшін инновациялар мен жаңалықтарды ұсына алады. Жасанды интеллект пен автоматтандырудың қосымша қабаттарымен контактісіз және түпкілікті байланысқа мүмкіндік беретін 5G операторларға табыстарын арттыруға тамаша мүмкіндіктер береді. AI және сымсыз байланысты біріктіру үшін машиналық оқыту тәсілі соңғы жылдары көптеген зерттеушілердің назарын аударды, бұл стандарттау бойынша ұсыныстарда көрініс тапты [30].

IoT өсуі күрделі операциялық талаптары бар әртүрлі қолданбаларды орнатуды талап етеді. Кешігу IoT үшін ең маңызды көрсеткіштердің бірі болып табылады, әсіресе желілік трафикті болжауда және маңызды жағдайларды басқару қажет болатын денсаулық сақтау мониторингінде. IoT қолданбаларында интеллектуалды өңдеу және үлкен деректерді талдау дамудың негізгі драйверлері болып табылады. Интернеттегі деректерді өңдеу негізінен көлемді, жылдамдықты және үлгіні тануға қатысты әртүрлі салаларда қолданылады. Машиналық оқыту арқылы негізделген болжамды аналитиканың көмегімен бағдарламалық құрал қалаған және қалаусыз кіріс оқиғаларын болжай алады. Осылайша, машиналық оқыту жүйесі аномальды мінез-құлықты анықтайды және ұзақ мерзімді трендтерді түсінуге және орнатуға көмектеседі, IoT және AI арасында айқын конвергенция бар. Заттар интернеті осы құрылғылар арқылы жасалған деректерді пайдалану үшін нысандар мен құрылғыларды қоса алады, ал AI құрылғылардың барлық түрлерінің интеллектуалды әрекетін модельдей алады. IoT жүйелері үлкен деректер жиынтығын жасайтындықтан, жасанды интеллект ақпаратты өңдеуге және түсінуге көмектеседі. Дегенмен, құрылымдық деректерді өңдеудің дәстүрлі әдістері, талдаушылар IoT құрылғыларынан нақты уақытта келетін үлкен деректерді тиімді басқара алмайды. Интернет заттары құрылғыларды, осы құрылғылармен жасалған деректерді қоса алады және жасанды интеллект құрылғылардың барлық түрлерінің интеллектуалды әрекетін модельдеу үшін қолданылады. IoT құрылғылары ақпараттың үлкен көлемін шығаратындықтан, жасанды интеллект бұл ақпаратты өңдейді және түсінеді. Дегенмен, ақпаратты құрылымдауға, аналитикаға және нақты процестерге дәстүрлі тәсілдер арқылы сіз нақты уақытта IoT құрайтын нысандар туралы барлық ақпаратты тиімді басқара алмайсыз. AI негізіндегі талдау және жауап, егер бар болса, ақпараттың оңтайлы мәнін алу үшін пайдаланылуы мүмкін. ML

және IoT алгоритмдерінің таралуы қолданбалы инфрақұрылымды айтарлықтай жақсарта алады. Машиналық оқытуды пайдалану кептелістерді болдырмау, ресурстарды бөлуді оңтайландыру және шешім қабылдау немесе жүктеу үшін нақты уақыттағы деректерді талдау үшін желіні басқаруды жақсартады. Машиналық оқыту әдістері, соның ішінде ANN негізіндегі әдістер үлкен көлемдегі деректерді тиімді сақтауға және өңдеуге мүмкіндік береді [14]. Дегенмен, ақпаратты құрылымдауға, аналитикаға және нақты процестерге дәстүрлі тәсілдер арқылы сіз нақты уақытта IoT құрайтын нысандар туралы барлық ақпаратты тиімді басқара алмайсыз. AI негізіндегі талдау және жауап, егер бар болса, ақпараттың оңтайлы мәнін алу үшін пайдаланылуы мүмкін. ML және IoT алгоритмдерінің таралуы қолданбалы инфрақұрылымды айтарлықтай жақсарта алады. Машиналық оқытуды пайдалану кептелістерді болдырмау, ресурстарды бөлуді оңтайландыру және шешім қабылдау немесе жүктеу үшін нақты уақыттағы деректерді талдау үшін желіні басқаруды жақсартады. Машиналық оқыту әдістері, соның ішінде ANN негізіндегі әдістер үлкен көлемдегі деректерді тиімді сақтауға және өңдеуге мүмкіндік береді [14]. Дегенмен, ақпаратты құрылымдауға, аналитикаға және нақты процестерге дәстүрлі тәсілдер арқылы сіз нақты уақытта IoT құрайтын нысандар туралы барлық ақпаратты тиімді басқара алмайсыз. AI негізіндегі талдау және жауап, егер бар болса, ақпараттың оңтайлы мәнін алу үшін пайдаланылуы мүмкін. ML және IoT алгоритмдерінің таралуы қолданбалы инфрақұрылымды айтарлықтай жақсарта алады. Машиналық оқытуды пайдалану кептелістерді болдырмау, ресурстарды бөлуді оңтайландыру және шешім қабылдау немесе жүктеу үшін нақты уақыттағы деректерді талдау үшін желіні басқаруды жақсартады. Машиналық оқыту әдістері, соның ішінде ANN негізіндегі әдістер үлкен көлемдегі деректерді тиімді сақтауға және өңдеуге мүмкіндік береді [14]. Аналитика және нақты процестер, сіз нақты уақытта IoT құрайтын нысандар туралы барлық ақпаратты тиімді басқара алмайсыз. AI негізіндегі талдау және жауап, егер бар болса, ақпараттың оңтайлы мәнін алу үшін пайдаланылуы мүмкін. ML және IoT алгоритмдерінің таралуы қолданбалы инфрақұрылымды айтарлықтай жақсарта алады. Машиналық оқытуды пайдалану кептелістерді болдырмау, ресурстарды бөлуді оңтайландыру және шешім қабылдау немесе жүктеу үшін нақты уақыттағы деректерді талдау үшін желіні басқаруды жақсартады. Машиналық оқыту әдістері, соның ішінде ANN негізіндегі әдістер үлкен көлемдегі деректерді тиімді сақтауға және өңдеуге мүмкіндік береді [14]. Аналитика және нақты процестер, сіз нақты уақытта IoT құрайтын нысандар туралы барлық ақпаратты тиімді басқара алмайсыз. AI негізіндегі талдау және жауап, егер бар болса, ақпараттың оңтайлы мәнін алу үшін пайдаланылуы мүмкін. ML және IoT алгоритмдерінің таралуы қолданбалы инфрақұрылымды айтарлықтай жақсарта алады. Машиналық оқытуды пайдалану кептелістерді болдырмау, ресурстарды бөлуді оңтайландыру және шешім қабылдау немесе жүктеу үшін нақты уақыттағы деректерді талдау үшін желіні басқаруды жақсартады. Машиналық оқыту әдістері, соның ішінде ANN негізіндегі әдістер үлкен көлемдегі деректерді тиімді сақтауға және өңдеуге мүмкіндік береді [14].

AI негізіндегі талдау және жауап, егер бар болса, ақпараттың оңтайлы мәнін алу үшін пайдаланылуы мүмкін. ML және IoT алгоритмдерінің таралуы қолданбалы инфрақұрылымды айтарлықтай жақсарта алады. Машиналық оқытуды пайдалану кептелістерді болдырмау, ресурстарды бөлуді оңтайландыру және шешім қабылдау немесе жүктеу үшін нақты уақыттағы деректерді талдау үшін желіні басқаруды жақсартады. Машиналық оқыту әдістері, соның ішінде ANN негізіндегі әдістер үлкен көлемдегі деректерді тиімді сақтауға және өңдеуге мүмкіндік береді [14]. AI негізіндегі талдау және жауап, егер бар болса, ақпараттың оңтайлы мәнін алу үшін пайдаланылуы мүмкін. ML және IoT алгоритмдерінің таралуы қолданбалы инфрақұрылымды айтарлықтай жақсарта алады. Машиналық оқытуды пайдалану кептелістерді болдырмау, ресурстарды бөлуді оңтайландыру және шешім қабылдау немесе жүктеу үшін нақты уақыттағы деректерді талдау үшін желіні басқаруды жақсартады. Машиналық оқыту әдістері, соның ішінде ANN негізіндегі әдістер үлкен көлемдегі деректерді тиімді сақтауға және өңдеуге мүмкіндік береді [14]. Ресурстарды бөлуді оңтайландыру және шешім қабылдау немесе түсіру үшін нақты уақыттағы деректерді талдау. Машиналық оқыту әдістері, соның ішінде ANN негізіндегі әдістер үлкен көлемдегі деректерді тиімді сақтауға және өңдеуге мүмкіндік береді [14]. ресурстарды бөлуді оңтайландыру және шешім қабылдау немесе түсіру үшін нақты уақыттағы деректерді талдау. Машиналық оқыту әдістері, соның ішінде ANN негізіндегі әдістер үлкен көлемдегі деректерді тиімді сақтауға және өңдеуге мүмкіндік береді [14].

Трафикті болжау коммуникациялық желілерге арналған AI зерттеулерінің ең жақсы бағыттарының бірі болып табылады. Қазіргі уақытта оны әртүрлі қолданбаларда қолдануға болады және көптеген зерттеушілердің назарын көбірек аударады. Ақпаратты болжау - таңдалған желілердің қауіпсіздігін, сенімділігін және қосылуын қамтамасыз етудің тиімді жолы. Желілік трафикті болжаудың көптеген әдістері, соның ішінде Интернеттен деректерді алу әдістері ұсынылды және сыналған. Маңызды нәтижелерге қол жеткізу үшін көптеген қызықты желілік болжау стратегиялары әзірленді [23]. 3.1-суретте машиналық оқыту әдістерін пайдалана отырып, IoT трафигі деректерін болжау мысалы көрсетілген.



3.1-сурет – «Интернет заттары» трафикті болжау үшін машиналық оқыту.

Уақыт қатарларын болжау алдыңғы және ағымдағы ақпарат негізінде жүйенің келесі мәндерін болжауды білдіреді. Әдетте күтілетін деректерді алу үшін алдын ала анықталған есептеу модельдеу (немесе гибридті модельдеу) қолданылады. Уақытқа тәуелді мақсаттарды болжай алатын жады бар RNN қажет. RNNs болашақ уақыт қадамын анықтау үшін кірістердің бұрын ашылған күйін сақтай алады. Жақында қайталанатын желілерді әртүрлі домендерге бейімдеудің көптеген нұсқалары енгізілді. Сыртқы кірістері бар сызықты емес авторегрессия (NARX) – сызықтық емес уақыт қатарларының есептерін шешу үшін қолданылатын динамикалық RNN. Осы зерттеулерде талқыланғандай, кеңінен қолданылатын NARX моделі уақыт қатарларының есептері үшін перспективалы нәтижелер береді, кіріс және шығыс айнымалылардың артта қалуына және болжау қателеріне негізделген. Кәдімгі қайталанатын нейрондық желіден (RNN) айырмашылығы, NARX желісі кез келген дерлік сызықтық емес функциялар үшін шамалы немесе жоқ есептеулермен болжау өнімділігін қамтамасыз етеді. NARX моделі [32] алдыңғы зерттеулерде әртүрлі қолданбалар үшін қолданылған.

Болашақ ақпаратты болжауға болатын NARX желісінің бірнеше қолданбалары бар. Оны таза деректер қалаған нәтиже болатын сызықты емес тазалау операциялары үшін пайдалануға болады. NARX желісін пайдалану динамикалық жүйелерді көрсету үшін тиімді. ANN ақпараттың әртүрлі қабаттардың нейрондары арасында өтуіне мүмкіндік беретін кері байланыс және кідірту механизмін қамтиды. Кері байланыс – желіге бұрын белгілі деректерді алуға мүмкіндік беретін уақытша жады сақтау тәсілі. Кешіктіру ағымдағы кезең үшін өткен деректердің тікелей жиынын қамтамасыз етсе, жауап беру әдістері бұрын белгілі деректерді өңдеуді (сүзуді) жүзеге асырады [32].

Трафик сипаттамаларын дәл болжау тиісті QoS өнімділігін қамтамасыз ету үшін ресурстарды тиімді басқаруға мүмкіндік береді. Трафикті болжау желіні бақылау, ресурстарды басқару, кептелістерді бақылау, желілік өткізу қабілеттілігін бөлу және желіге енуді анықтау (мысалы, аномалияны анықтау) сияқты әртүрлі қолданбаларда қолданылуы мүмкін. 5G желілерін енгізумен трафик көлемі мен желінің күрделілігі артты. Трафик пен желінің күрделілігінің артуына байланысты желідегі ауытқуларды анықтау және алдын алу барған сайын қиындай түсуде. Желідегі зиянды әрекеттерден қорғау құралдарының бірі желілік трафикті болжауға негізделген аномалияны анықтау болып табылады. Белгілі трафик пішінінен елеулі ауытқу шабуылды анықтау үшін пайдаланылуы мүмкін. Шығарылымның дәл сәйкестігін анықтағаннан кейін, шығыс және кіріс деректері аномалияны анықтауға арналған болжамды деректермен салыстырылуы мүмкін. Осылайша, аномалияны анықтау өнімділігі қозғалыс сипаттамаларын болжау дәлдігіне негізделген. ARIMA, Кальман сүзгісі, бөлшектер сүзгісі және трафикті таратудың теориялық әдістері сияқты трафик сипаттамаларын болжауға арналған көптеген алгоритмдер ұсынылды. Бірақ бесінші буын байланыс желілері үшін бұл әдістер қажетті тиімділікті көрсетпейді [33]. Сондықтан, бұл жұмыста желілік трафикті дәл болжау үшін NARX-RNN көмегімен бір секірмелі және көп септі болжау тәсілі қолданылды.

ARIMA, Кальман сүзгісі, бөлшектер сүзгісі және трафикті таратудың теориялық әдістері сияқты трафик сипаттамаларын болжауға арналған көптеген алгоритмдер ұсынылды. Бірақ бесінші буын байланыс желілері үшін бұл әдістер қажетті тиімділікті көрсетпейді [33]. Сондықтан, бұл жұмыста желілік трафикті дәл болжау үшін NARX-RNN көмегімен бір секірмелі және көп септі болжау тәсілі қолданылды. ARIMA, Кальман сүзгісі, бөлшектер сүзгісі және трафикті таратудың теориялық әдістері сияқты трафик сипаттамаларын болжауға арналған көптеген алгоритмдер ұсынылды. Бірақ бесінші буын байланыс желілері үшін бұл әдістер қажетті тиімділікті көрсетпейді [33]. Сондықтан, бұл жұмыста желілік трафикті дәл болжау үшін NARX-RNN көмегімен бір секірмелі және көп септі болжау тәсілі қолданылды.

Бұл зерттеудің негізгі қозғаушы күштері:

-Ресурстарды басқару және қауіпсіздік қауіптерін анықтау үшін қызмет көрсету сапасын (QoS) талаптарын және желі мониторингін оңтайландырыңыз.

-Аномалияларды, соның ішінде қауіпсіздік және операциялық мәселелерді анықтау үшін желінің қолжетімділігін және әрекетті бақылаңыз.

-NARX-RNN әдісі уақыттық қатарлар деректерін болжайды, деректерді есте сақтайды және болашақ уақыт серияларының деректерін жеткілікті дәл бағалайды. Сондай-ақ оның басқа уақыттық қатарларды болжау тәсілдеріне қарағанда артықшылығы бар, өйткені ол оқыту итерацияларымен салыстырғанда оқыту әдісінің дәлдігін барынша арттыруға қызмет етеді. Модельге көбірек деректер қосылған сайын, ол ақылдырақ болады және трафик көлемін жақсы бағалай алады, бұл нақты уақыттағы трафик болжамдары үшін маңызды.

-IoT байланыс параметрлерін жеткіліксіз білу.

-Болжаудың орынды дәлдігіне қол жеткізу үшін машиналық оқытуды дәл талдаудың болмауы.

-QoS өлшемдерін оңтайландырудың күрделі есептерінің есептеу күрделілігі.

Қолданыстағы шешімдердің шектеулеріне байланысты дипломдық жұмыстың негізгі бағыты IoT және тактильді Интернетте трафикті болжауға бағытталған. Кейбір қолданбалар пакетті жоғалтуға, кешігуге және миссия үшін маңызды қолданбаларға (денсаулық, қауіпсіздік және төтенше жағдайға жауап беру сияқты) сезімтал. Науқасқа қарқынды дистанциялық көмек көрсету сияқты қолданбаларда тиісті әрекеттерді шешу үшін белгілі бір уақыт ішінде маңызды оқиға туралы хабарлау қажет. Сонымен қатар, бұл бақылаулардың саны мен түріне байланысты әртүрлі деректер көлеміне әкелуі мүмкін. Біз күту уақытын болжау үшін бір қадамдық және бірнеше қадамдық алдын ала болжау тәсілі бар NARX-RNN үлгісі сияқты машиналық оқытуға негізделген технологияларды пайдалануды ұсынамыз.

Негізгі күтілетін нәтижелер төмендегідей қорытындыланады:

-IoT және тактильді вебте трафикті болжау үшін NARX қосылған RNN көмегімен $\{mұнда k=1,2,3\dots\}$ k-қадам алға уақыт қатарын болжау тәсілі ұсынылады. Бұл ретте трафик сипаттамалары оның параметрлеріне байланысты екі жағдайда болжанады:

1. Біріншіден, желілік трафикті болжау (пакеттерді жоғалту жылдамдығы) NARX-RNN уақыт серияларына негізделген көп сатылы алға болжау (MSP) тәсілін қолдану арқылы орындалады. Болжаудың дәлдігі MSE, SSE және MAE жоғалту функциялары арқылы бағаланады. Сонымен қатар, болжам дәлдігінің тағы бір өлшемі бар — пайыздағы орташа абсолютті қателік (MAPE) [28].

2. Екіншіден, IoT және тактильді интернеттегі кідірістерді болжау NARX қайталанатын нейрондық желісі бар көп қадамды алға болжау (MSP) және бір қадам алға болжау (SSP) көмегімен орындалады. Бұл жағдайда болжамның дәлдігі үш нейрондық желіні оқыту алгоритмі арқылы бағаланады: Trainlm, Traincgf, Trainrp бар MSE бар орташа квадраттық қате (RMSE) және болжам дәлдігінің өлшемі ретінде орташа абсолютті пайыздық қате (MAPE) [34].

Осы тараудың қалған бөлігі келесідей ұйымдастырылған. Бөлім (3.1) уақыттық қатарларды болжау үшін машиналық оқытуды ұсынады; Бөлім (3.2) мәселенің қойылымы және жүйе моделі; (3.3) тарауда модельдеу нәтижелері бар.

3.2 Уақыт қатарларын болжау үшін машиналық оқыту

Уақыт қатарларын болжау деректер ғылымында кеңінен қолданылатын әдістердің бірі болып табылады және әртүрлі салаларда қолданылады. Бұл сонымен қатар машиналық оқытудың (ML) маңызды саласы. Бұл бақылаудағы оқыту мәселесі ретінде қарастырылуы мүмкін; біз уақыттық қатарларды болжау үшін регрессия, ANN, KNN, SVM, Random Forest және XGBoost сияқты бірнеше ML әдістерін пайдалана аламыз. Машиналық оқытуға негізделген болжау модельдері уақыт пен ресурстарды болжамды бөлуді жеңілдету үшін әртүрлі ұйымдар талап ететін уақыт қатарларын пайдаланатын жобаларда кеңінен қолданылды.

ANN ауқымды жұмыс процестеріне, деректерді масштабтау процедураларына және уақытша сериялар деректерінің стационарлық және дифференциациясына деген қажеттілікті жою арқылы уақыттық қатарларды болжауда пайдалы болуы мүмкін. РНН деректер жинағы дәйекті болған кезде бақыланатын оқу тапсырмалары үшін өте қолайлы. RNN - жадты сақтайтын ANN және олар уақытша тапсырмаларды болжауға көмектесетін алдыңғы деректерден деректерді қайтара алады. RNN алгоритмі кіріс деңгейінде алдыңғы уақыт қатарларының деректеріне үйретіледі. Желі қосылымы нақты және болжамды желі шығысы арасындағы айырмашылыққа (қате) байланысты реттеледі. Желіні орнату алдында оператор желінің жасырын қабаттарының өлшемін және оқыту алгоритмін тоқтату критерийлерін көрсетуі керек.

Болжау белгілі деректерге сәйкестендіру үшін үлгілерді пайдалануды және оларды болашақ бақылауларды болжау үшін пайдалануды қамтиды. Болған оқиға негізінде болашақ болжамдалады немесе бағаланады. Уақыт қатарлары бақылаулар арасында уақытқа тәуелділікті қосады. Бұл тәуелділік шектеулі және қосымша ақпарат көзін қамтамасыз ететіндей құрылымдалған. Уақыт тізбегін болжау – бұрын белгілі реттілік арқылы ақпаратты болжау әдісі. Ол болашақ

тенденциялар сол уақытқа дейін өткен трендтерге ұқсайтын кезде өткен тенденцияларды талдау арқылы болашақ оқиғаларды болжайды. Ол ресурстарды бөлу, желілік трафик, ауа-райын болжау, басқару инженериясы, статистика сияқты әртүрлі қолданбаларда зерттеудің көптеген салаларында қолданылады. сигналдарды өңдеу және бизнес-жоспарлау. Бұл уақыттық қатарларды болжауға арналған көптеген мүмкін қосымшалардың кейбірі ғана.

Ауа райы, ауа сапасы және желілік трафикті болжау сияқты нақты уақыт серияларында сценарийлер детекторлар, аномалиялар, жетіспейтін деректер, жоғары шу деңгейлері, күрделі көп өзгермелі корреляциялар және классикалық болжау әдістерінің ағымдағы шектеулері сияқты IoT құрылғыларына негізделген. Мұндай әдістер әдетте жақсы өнімділік үшін үнсіз және дәл ақпаратқа байланысты: жетіспейтін деректерге, шектен тыс көрсеткіштерге және басқа қате мүмкіндіктерге әдетте қолдау көрсетілмейді. Уақыт қатарын болжау белгілі уақыт реттілігінен басталады және сарапшылар бұл ақпаратты және трендтер, маусымдық үлгілер, мерзімді үлгілер және симметрия сияқты уақытты бөлу үлгілерін зерттейді. Сауда, қаржы және сату сияқты әртүрлі жүйелер, әлеуетті техникалық күрделілік пен тұтынушылардың қажеттіліктерін бағалау үшін уақыттық қатарларды болжауды пайдаланыңыз. Уақыт қатарларының деректер үлгілері көптеген вариацияларға ие болуы және әртүрлі кездейсоқ процестерді көрсетуі мүмкін.

3.2.1 NARX нейрондық желісі

NARX – сыртқы кірістері бар сызықты емес авторегрессивті нейрондық желі. NARX - бұл RNN динамикалық қайталанатын нейрондық желілер. NARX желілері ARX уақыт серияларының үлгілеріне негізделген, олар уақыттық қатар операциялары үшін әдетте пайдаланылады және ARX моделінің сызықтық емес түрі болып саналады. NARX модельдері әртүрлі сызықтық емес динамикалық әдістерді имитациялай алады; олар уақыттық қатарларды модельдеуді қоса алғанда, әртүрлі есептерді шешу үшін пайдаланылды. NARX желісі болжам жасау үшін бұрыннан бар уақыт қатарларының алдыңғы өлшемдерін және уақыттық қатарға болжам жасау үшін басқа кірістердің алдыңғы мәндерін пайдаланады. NARX - сызықты емес модельдеу жүйелері үшін жарамды сенімді құрал. Сонымен қатар, NARX градиентті төмендету бойынша оқыту алгоритмін пайдалана отырып, басқа уақыттық қатарлар нейрондық желілеріне қарағанда тиімдірек оқытылады.

NARX желілері болжамды нәтиже өткен уақыттағы кірістерге байланысты болған кезде болжамды жақсырақ орындайды. NARX сонымен қатар оқыту деректері таза кіріс деректерімен оқытылатын сызықты емес сүзгі болып табылады. Уақыт тізбегі [21] үшін $y(n+1)$ уақыт тізбегі үшін әлеуетті мәндер сол уақыт тізбегі үшін өткен мәндерге және $u(n)$ уақыт тізбегі үшін соңғы өлшемге негізделеді. Модель математикалық түрде келесідей ұсынылған:

$$y(n+1)=f(y(n),y(n-1),\dots,y(n-dy),u(n),u(n-1),\dots,u(n-du))+e(n) \quad (3.1)$$


Ықшам түрде 1-теңдеуді келесідей қайта жазуға болады.

$$y(n+1)=f[y(n);u(n)] \quad (3.2)$$

Мұнда $y(n) \in \mathbb{R}$ және $u(n) \in \mathbb{R}$ сәйкесінше (n) уақытындағы модельдің кіріс және шығыс параметрлерін анықтайды. Сонымен қатар, $y(n)$ және $y(n+1)$ сәйкесінше ақиқат және болжамды нәтижелер болып табылады.

Сәйкесінше, dy және du – шығыс және кіріс айнымалыларының уақыттық кешігулері (z^{-1} = уақыт кідірісі бірлігі), ал $e(n)$ – ақиқат және болжамды шығыс арасындағы үлгі қатесі [25].

3.2-суретте NARX нейрондық желісінің архитектурасы көрсетілген.



3.2-сурет – NARX нейрондық желінің архитектурасы.

3.2.2 Алда k-қадамды болжау

Модельдеудің негізгі мақсаты – бағалау бірлігінің алдыңғы және ағымдағы мәндерін пайдалана отырып, кейінгі шығыс мәндерін болжау. Бұл бірлік алдымен оңтайлысы таңдалған белгілі мәндерге негізделген деректер жиынына бірнеше үлгілерді сәйкестендіру арқылы сынақ ақпаратын пайдалану арқылы анықталды. Содан кейін жаңа деректер жинағы пайдаланылады және болжау нәтижелері салыстырылады. Модельдің шығыс мәніне қалай бейімделуі талданады. Бұл зерттеу осы алгоритмдерді пайдалану кезінде қандай оңтайлы өнімділік жасалатынын анықтау үшін әртүрлі оқыту алгоритмдерін пайдалана отырып, k қадам алға (бір қадам..., k қадам) болжайтын көптеген болжамды модельдерді салыстырады.

Әдетте, уақыт қатарын болжау келесі уақыт қадамы үшін нақты деректер болжамын анықтайды. Бұл бір қадамды болжау, ашық цикл немесе бір қадам алға болжау (SSP) деп аталады, себебі тек бір уақыт қадамын болжауға болады. Бір сатылы $(n+1)$ болжау ағымдағы және алдыңғы деректер нүктелерін $(n, n-1, \dots, nk)$ өту арқылы орындалады.

Бұл әдісте ағымдағы үлгі әрқашан жаңартылған кіріс мәндерімен ауыстырылады. Яғни, конфигурацияланған параметр мәндеріне байланысты модель үнемі өзгеріп отырады. Көп сатылы болжамдар үшін бірдей үлгі барлық нәтижелерді болжау үшін қайта пайдаланылады.

Ең қарапайым жағдайда бір сатылы болжау үлгілері келесідей пішінге ие:

$$y(n+1) = f(y(n), y(n-1), u(n), u(n-1) \dots (nk)) \quad (3.3)$$

мұндағы $y(n+1)$ болжамды нәтиже, $y(n)$ және $u(n)$ тиісінше мақсатты және экзогендік енгізулердің бақылаулары; n – уақыт қадамы және k – кірістер саны (k -ші қадамды болжау); $f(.)$ – модель үйренетін болжау функциясы.

Көп сатылы немесе K -қадамды болжауда бір модель барлық шығыс мәндерін болжау үшін қайта-қайта пайдаланылады. Бұл әдістегі болжау моделін келесі теңдеу арқылы сипаттауға болады:

$$y(n+k) = f(y(n), y(n-1), \dots, y(n-ku), u(n), u(n-1), \dots, u(n-ku)) \quad (3.4)$$

мұндағы $y(n+k)$ болжамды нәтиже, ku – енгізу саны, кешігулер (бір реттік кідіріс) және ku - шығу кідірістерінің саны.

Алдын ала болжау әдісі белгілі уақыт тізбегінің болашақ мәндерін кезең-кезеңімен болжайды. Алдымен, $u(n+1)$, x , $u(n+1-x)$, ..., $u(n-1)$, $u(n)$, содан кейін $u(n+2)$ мәндерінің алдыңғы мәндері негізінде болжанады. $u(n+1)$ үшін болжамды мәнін қамтитын өткен x мәндеріне байланысты болжанады. Процесс соңғы $u(n+h)$ мәні есептелгенше қайталаынады.

Уақыт қатарларына қатысты кейбір тапсырмалар бар, оларда бірнеше уақыт қадамдарын болжау қажет. Бір сатылы болжаудан айырмашылығы олар көп сатылы алға болжау (MSP) немесе көп сатылы уақыт қатарын болжау есептері деп аталады. MSP – болжамда тұйық циклді қалыптастыру үшін авторегрессивті үлгіні пайдаланатын болжау әдісі. Ол өткен мәндерге негізделген уақыт қатарындағы әлеуетті мәндерді болжайды. Көп сатылы болжау әдісі келесі қадамда олардың мәнін анықтау үшін ағымдағы уақыт қадамындағы күтілетін мәндерді пайдаланатын қадамдық болжау үлгісін қолданады. Уақыт қатарларының көптеген мәселелері тек алдыңғы мәндерді пайдалана отырып, әлеуетті мәндер тізбегін болжауды қамтиды, мысалы, MSP, ол сымсыз желі трафигі, қуат тұтыну және т.б. сияқты көптеген мәселелердің уақыт реттілігін болжайды. Кейінгі мәндердің қатарын біле отырып, біз күтілетін өткізу қабілеттілігі, кідіріс, өткізу қабілеті, қуат тұтынуы, белгісіздік және т.б. сияқты уақыт реттілігінің мүмкіндіктерін анықтай аламыз. Атап айтқанда, бірнеше қадам алға қарай уақыт ретін болжау келесі жылдың егін жинау маусымын, келесі сағаттағы сымсыз кідірістерді, келесі айлардағы төмен және жоғары ауа райы температурасын және т.б. болжайды. Бұл проблемаларды шешудің стандартты әдісі белгілі уақыт қатарларының мәндерінен белгілі бір модельді құру және олардың әлеуетті мәндерін болжау үшін оны кезең-кезеңімен қолдану болып табылады. Бұл әдіс көп сатылы болжау деп аталады. Ол алдыңғысынан

күтілетін ақпаратты пайдаланатындықтан, көп сатылы болжамның дөңгелектеу қателеріне бейім екенін тәжірибе жүзінде көрсетуге болады, яғни алдыңғы болжамда жіберілген қателер келесі болжамға ауыстырылады [32].

3.3 Мәселені құрастыру және жүйе моделі

Жақында трафик сипаттамаларын болжау үшін Random Forest [31], ARIMA [32], LSTM [30] және т.б. сияқты әртүрлі ML алгоритмдері IoT және Tactile Internet үшін пайдаланылды.

Біріншіден, деректер жинағын алу үшін IoT моделі жасалды; модель AnyLogic симуляторы арқылы зерттелді. Екіншіден, деректер жиынтығын жинап, талдап, өңдегеннен кейін ол болжау процесі үшін ANN-ге кіріс ретінде пайдаланылды. Деректер жиынын желіге кіріс ретінде жүктегеннен кейін деректер жиыны Кіріс (I) және Шығыс (O) бағандарында екі ішкі жиынға бөлінеді, содан кейін тиісінше поездық, сынақ және тексеру жиындарына бөлінеді. Кіріс деректерінің нормалануы нақты максималды немесе ең төменгі мәндерге сәйкес [-1, 1] аралықта болуы керек.

3.3.1 IoT жүйесінің моделі

Бұл бөлім 3.3-суретте көрсетілген ML оқыту деректер жинағын жасау үшін пайдаланылатын IoT моделімен таныстырады. IoT жүйесі дискретті оқиғаларды модельдеуді қолдайтын AnyLogic Simulation көмегімен құрастырылған [28].

3.3-суретте. машиналық оқыту негізінде IoT және TI (Тактильді Интернет) желілеріндегі трафикті болжау үшін трафик қызметінің зерттелген моделі көрсетілген. Модель екі көзден тұрады: IoT трафигі және дауысты да, TI трафигін де тудыратын трафик [27, 28]. 3.3-суреттегі H2H (Адамнан адамға) дауыстық трафикті білдіреді. Жол қозғалысына қызмет көрсету моделі біріктірілген қызмет көрсету тәртібі бар жүйе ретінде ұсынылған, яғни. күтумен және шығындармен. Бұл жағдайда пакеттік қызмет көрсетудің орташа уақыты \square мәніне тең

Кіріс IoT трафигінің қарқындылығы сәйкесінше λ_{IoT} , H2H трафигі λ_{H2H} , аралас трафик λ_{H2H+TI} . Қызмет көрсетуден бас тарту қызмет көрсетуге жаңа пакет келгенде кезектегі барлық орындардың толтырылуы р ықтималдығымен орын алады. Жалпы трафик ағынының қарқындылығы λ . Жалпы ағынның сипаттамалары көлік ағыны мен біріктірілген H2H +TI ағынынан ерекшеленеді.

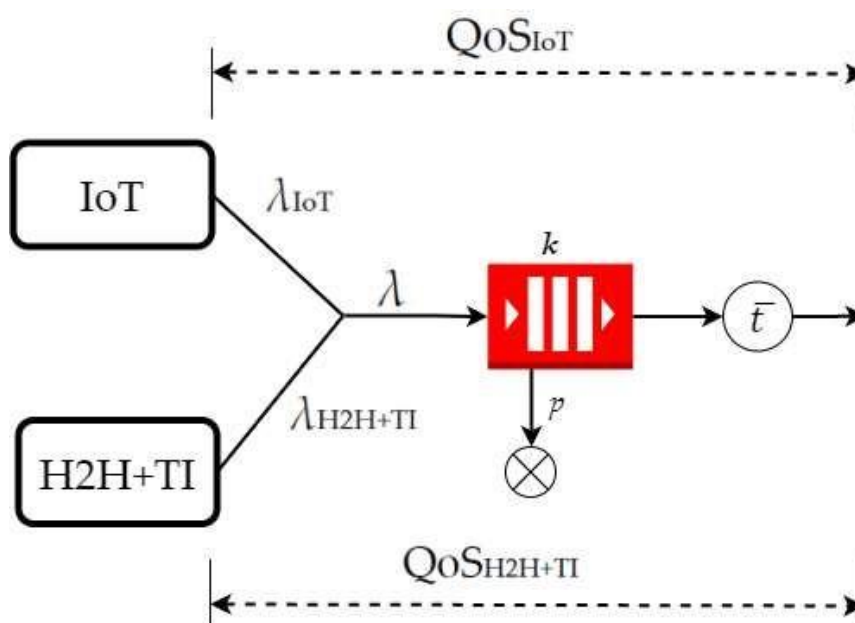
Бұл жүйе үшін пакеттің жоғалу ықтималдығын және жеткізудің кешігуін (кезекте күту уақыты) бағалаудың нақты аналитикалық шешімдері жоқ.

Диффузиялық жуықтау әдісі [30], [31] кіріс трафикті және пакеттерге қызмет көрсету процесін сипаттайтын белгілі тарату параметрлері үшін пакеттердің жоғалу ықтималдығын бағалау үшін қолданылады. Шамамен бағалау үшін келесі өрнек алынады:

$$\rho = \frac{1-\rho}{\frac{2}{1-\rho}(c_a^2+c_s^2)n_b+1}} \rho^{\frac{2}{c_a^2+c_s^2}n_b} \quad (3.5)$$

мұндағы C_a2 және C_s2 сәйкесінше кіріс ағыны мен қызмет көрсету ұзақтығы үшін квадраттық өзгеру коэффициенттері; n_b – буфер өлшемі. Пакетті жеткізудің орташа ұзақтығын шамамен бағалауды келесі формула бойынша анықтауға болады:

$$T = \frac{\rho t}{2(1-\rho)} \left(\frac{\sigma_a^2+\sigma_s^2}{t^2} \right) \left(\frac{t^2+\sigma_s^2}{a^2+\sigma_s^2} \right) + t \quad (3.6)$$



3.3-сурет – IoT жүйесінің моделі.

Өздігінен ұқсас ағынды имитациялау үшін тәуелсіз оқиғалар тізбегінің генераторы пайдаланылды, олардың арасындағы уақыт аралықтары кездейсоқ және Парето үлестірімі бар.

IoT моделін жобалау үшін AnyLogic имитациялық жүйесі пайдаланылды, ол дискретті-оқиғалық модельдеу үлгілерін жасауға мүмкіндік береді. Өздігінен ұқсас ағынды имитациялау үшін тәуелсіз оқиғалар тізбегінің генераторы пайдаланылды, олардың арасындағы уақыт аралықтары кездейсоқ және Парето үлестірімі бар.

$$f_x(x) = \begin{cases} \frac{kx_m^\alpha}{x^{\alpha+1}} & x \geq x_m \\ 0 & x < x_m \end{cases} \quad (3.7)$$

мұндағы x_m және α тарату параметрлері.

Кездейсоқ шаманың күтілетін мәні мен вариациясы келесідей анықталады:


$$E(x)=\frac{ax_m}{a-1}, \quad D(x)=\left(\frac{x_m}{a-1}\right)^2 \frac{a}{a-2} \quad (3.8)$$

3.3.2. Жасанды нейрондық желіні оқыту

IoT кідірісін болжау үшін NARX-RNN пайдаланыңыз. NARX-RNN жаттықтыру үшін біз жаттығу деректерін жүктейміз және екі кіріс және шығыс кідірісі бар кідірту сызығын (TDL) қолданамыз. Дипломдық жұмыста шығыс және кіріс кідірістері бірдей деп есептелді, мұндағы $dy = du = d$; NARX желісіне де екі кіріс бар: $u(n)$ және $y(n)$.

NARX желісі `narxnet` функционалдығын пайдалану арқылы жасалған. Осыдан кейін біз тапсырмалар үшін `Trainlm`, `Traincgf` және `Trainrp` көмегімен жасырын қабаттағы 20 нейронды қолданамыз. Оқыту, содан кейін деректерді дайындау үшін дайындау функциясы. Соңында, біз IoT және тактильді интернетте күту уақытын болжауды бір қадамдық және көп сатылы болжау тәсілін қолдана отырып орындаймыз.

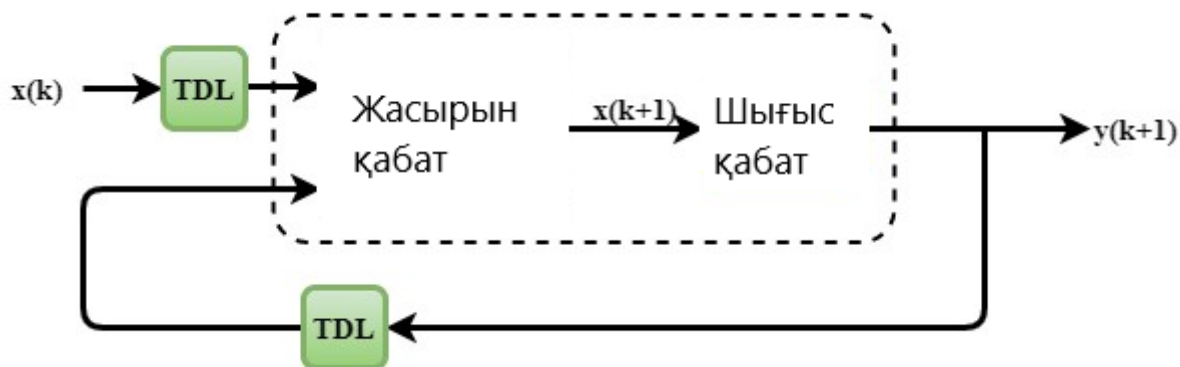
NARX нейрондық желілерін екі түрлі жолмен оқытуға болады: ашық циклды оқыту архитектурасын және жабық циклды оқыту архитектурасын пайдалану. Кері байланыс желілері көп сатылы болжамды жасайды. Басқаша айтқанда, олар ішкі ресурстар сыртқы нәтижелерді (жауаптарды) жоғалтқан кезде болжауды жалғастырады. Көп сатылы алға болжау әдісі көбінесе шығыс белгілі болатын ашық цикл түрінде желіні модельдеу үшін пайдалы, содан кейін нәтиже NARX желісі арқылы желілік кіріске қайтарылатын кері байланыс пішініне көшу үшін көп мүмкіндікті жүзеге асыру үшін пайдалы. -кезенді болжау, бірақ кері байланыс тек берілген нәрсе. Біріншіден, ашық цикл архитектурасында желіні модельдеу үшін енгізу реті мен шығыс реттілігінің k -уақыт қадамдарынан басқа барлық қадамдар пайдаланылады, 3.4-суретте көрсетілгендей шығыс ретін енгізу арқылы қамтамасыз етілген жоғары дәлдіктің артықшылығын пайдалану. Содан кейін желі және оның соңғы сатысы суретте көрсетілгендей жабық цикл архитектурасына түрлендіріледі. 3,5 тек k кіріспен k -қадамды болжау үшін.



3.4-сурет – NARX нейрондық желісі ашық циклды форма болып табылады.

Шығыс қалыпты NARX құрылымында желіге бірлік енгізу кідірісімен қайтарылады.

Мұнда желі тек жабық желі ретінде модельденеді. ANN сыртқы кіріс тізбегі мен бастапқы шарттар үшін бірнеше болжам жасайды, себебі кіріс реттіліктерінің кезеңдері болады.



3.5-сурет – NARX нейрондық желісі жабық нысаны.

у тізбегі де шығарылатын жауап екенін ескеріңіз. Жауап жолын жапқаннан кейін сәйкес шығыс сәйкес кіріске жеткізіледі. у шығысы қалыпты NARX құрылымында желіге бірлік кіріс кідірісімен қайтарылатын кіріс болып табылады.

Бір қадамдық көп даналық болжау сізге жылдам уақыт қадамын болжауға көмектеседі. Келесі уақыт қадамында нақты деректер болжамы жоқ, себебі тек бір уақыт қадамын болжауға болады. Бір сатылы (t+1) болжам ағымдағы және өткен бақылауларды (t, t-1...,tk) өткізу және болжамды нәтижені у(t+1) алу арқылы жүзеге асады.

Шешім қабылдау сияқты көптеген жағдайларда, нақты у(t+1) пайда болғанша у(t) болған кезде у(t+1) болжамы болуы пайдалы болар еді. Желі кідірісті жою арқылы өзінің шығысын ертерек кезеңге қайтара алады, осылайша оның ең аз кідіріс бірлігі 1 орнына 0 болады. Ағымдағы желі бастапқы желіден бірдей шығысты шығарады, бірақ шығыс бір қадамға ауыстырылады. 3.4 суретте көрсетілгендей.

Algorithm1: NARX Neural Network Training

```
1  Load the IoT data sets.
2  InputSeries: Time series training data  $u = \{u_1, u_2, \dots, u_n\}$ 
3  TargetSeries: Time series training data  $y = \{y_1, y_2, \dots, y_n\}$ 
4  Outputs: the predicted output  $\hat{y} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n\}$ 
5  Error (e)  $\leftarrow (y - \hat{y})$ 
6  Initialize: the weights and biases randomly and threshold
7  Divide: the dataset into 70% training, 15% validation, and 15% test sets
8  Normalize: the dataset into values between [-1,1].
9  Specify: the predictors (u) and target (y)
10 Define: NARX neural network model architecture
11 Choose: the performance function
12 Choose trainingfcn (Training algorithm).
13 Define: input Delays, feedback Delays
14 Define: HiddenLayerSize
15 for n epochs and  $i^{\text{th}}$  iterations do
16   for k-step Prediction
17     for i = 1: N (N = numTimesteps)
18       Train: the network (NARX)
19       Test: network(net)
20       Evaluate: the prediction
21       if e < threshold
22         Calculate: the predicted output
23       else
24         Update: the network weights (Repeat the operation)
25     End for.
26   End for
27 End for
```

3.3.3 Жасанды нейрондық желілерді оқыту алгоритмдері.

Бақыланатын көпқабатты нейрондық желілерді үйрету үшін Back-Propagation әдісі [11, 20] қолданылады. Кері таралу алгоритмі ретінде де белгілі, қатені түзететін оқыту ережесіне негізделген; бұл нейрондық желілерде ең жиі қолданылатын оқыту алгоритмі. Ол жалғыз және көп пайдаланушы үлгілері үшін үздіксіз деректермен және дифференциалданатын мүмкіндіктермен айналысады. Әдетте, кері таралуды оқыту алгоритмі желінің өнімділігін арттыру мақсатында оқыту кезінде желі салмағын жаңарту үшін пайдаланылады.

Дипломдық жұмыста үш оқыту алгоритмі берілген [11].

Левенберг-Марквардт алгоритмі (Trainlm). Бұл Левенберг-Марквардт оңтайландыруына сәйкес салмақ пен қиғаштық мәндерін жаңартатын желіні оқыту функциясы. Квази-Ньютондық әдістер сияқты, Левенберг-Марквардт алгоритмі де Гессиан матрицасын есептемей-ақ екінші ретті оқу жылдамдығын

жуықтауға арналған. Егер жоғалту функциясы квадраттардың қосындысы ретінде ұсынылса (бұл алға жіберу желілерін жаттықтыру кезінде тән), онда Гессиан матрицасын келесідей жуықтауға болады.

$$H = JtJ \quad (3.9)$$

Содан кейін градиентті келесідей есептеуге болады:

$$g = JTe \quad (3.10)$$

мұндағы J - салмақтар мен қиғаштықтарға қатысты желі қателерінің бірінші туындыларын қамтитын якобиялық матрица, ал e - желі қателерінің векторы. Якобиялық матрицаны стандартты кері таралу әдісі арқылы есептеуге болады, бұл Гессиан матрицасын есептеуге қарағанда әлдеқайда күрделі.

Левенберг-Маркварт алгоритмі бұл жуықтауды келесі Ньютондық жаңартуда Гессиан матрицасына қолданады:

$$X_{k+1} = X_k - [J^T J + \mu I]^{-1} J^T e \quad (3.11)$$

Скаляр μ нөлге тең болғанда, бұл шамамен Гессиан матрицасын қолданатын Ньютон әдісі. μ үлкен болғанда, ол шағын қадам өлшемімен градиенттің төмендеуіне айналады. Ньютон әдісі қателік минимумына жақынырақ жылдамырақ және дәлірек, сондықтан мақсат Ньютон әдісіне мүмкіндігінше тез жету. Сондықтан, μ әрбір сәтті қадамнан кейін төмендейді (жоғалту функциясын азайтады) және қадам жоғалту функциясын жақсартқанда ғана артады. Осылайша, жоғалту функциясы алгоритмнің әрбір итерациясында үздіксіз төмендейді.

Trainlm көбінесе құралдар жинағындағы ең жылдам кері таралу алгоритмі болып табылады және басқа алгоритмдерге қарағанда көбірек жадты қажет ететініне қарамастан, бірінші таңдау бақыланатын алгоритм ретінде ұсынылады. Trainlm алгоритмі орташа өлшемді алға таралу (бірнеше жүз салмаққа дейін) бар нейрондық желілерді оқытудың ең жылдам әдісі болып шықты. Жаттығу жиыны үлкен болған кезде оның жадты азайту мүмкіндігі бар.

Жаңартылған Fletcher-Reeves конъюгаттық градиент алгоритмі (Traincgf). Бұл Флетчер-Ривес жаңартуларымен конъюгаттық градиент кері таралуына сәйкес салмақ пен қиғаштық мәндерін жаңартатын желілік оқыту функциясы.

Конъюгаттық градиент алгоритмдері бірінші итерацияда ең тік түсу (теріс градиент) бағытында іздейді.

$$P_0 = -g_0 \quad (3.12)$$

Содан кейін ағымдағы іздеу бағытында жылжу үшін оңтайлы қашықтықты анықтау үшін сызықтық іздеу орындалады.

$$x_{k+1} = x_k - \alpha_k P_k \quad (3.13)$$

Содан кейін келесі іздеу бағыты алдыңғы іздеу бағыттарымен жұптастырылатындай анықталады. Жаңа іздестіру бағытын анықтаудың жалпы тәртібі жаңа ең тік түсу бағытын соңғы бағытты іздеумен біріктіру болып табылады:

$$P_k = -g_k + \beta_k P_{k-1} \quad (3.14)$$

Конъюгаттық градиенттің әртүрлі нұсқалары β_k тұрақтысы қалай есептелетінімен ерекшеленеді. Флетчер-Ривс процедурасын жаңарту үшін:

Конъюгаттық градиент алгоритмдері, әдетте, ауыспалы оқыту жылдамдығының кері таралуынан әлдеқайда жылдам, ал кейде trainp (қатты кері таралу) қарағанда жылдамырақ. Дегенмен, нәтижелер бір мәселеден екіншісіне қарай өзгереді. Конъюгаттық градиент алгоритмдері қарапайымға қарағанда біршама көбірек жадты қажет етеді, сондықтан олар жиі ауыр салмақты желілер үшін қолайлы.

3.3.3 Берік кері таралуды үйрену алгоритмі.

Көпқабатты желілер әдетте жасырын қабаттарда сигма тәрізді тасымалдау функцияларын пайдаланады. Бұл функциялар жиі «сығу» деп аталады, өйткені олар шексіз кіріс ауқымын соңғы шығыс диапазонына қысады. Сигмоидты функциялар кіріс үлкен болған кезде олардың көлбеулері нөлге бейім болуымен сипатталады. Бұл сигма тәрізді функциялары бар көпқабатты желіні жаттықтыру үшін ең тік түсіру әдісін пайдаланған кезде қиындық тудырады. Градиент ең төменгі мәнге ие болуы мүмкін, сондықтан олар оңтайлы мәндерден алыс болса да, салмақтар мен қиғаштықтарда шағын өзгерістерді тудыруы мүмкін.

Икемді кері таралу ($Rprop$) оқыту алгоритмінің мақсаты ішінара туынды мәндердің осы зиянды әсерлерін жою болып табылады. Салмақ жаңартуының бағытын анықтау үшін тек туындының белгісі қолданылады; туындының мәні салмақты жаңартуға әсер етпейді. Жеке жаңарту мәні салмақ өзгерісінің мөлшерін анықтайды. Дегенмен, қате мақсаты азайған сайын өнімділік төмендейді.

$Rprop$ әдетте стандартты ең тік түсу алгоритмінен әлдеқайда жылдамырақ. Сондай-ақ оның жақсы қасиеті бар, ол жад талаптарын сәл ғана арттыруды талап етеді. Әрбір салмақ пен қиғаштық үшін жаңартылған мәндерді сақтасаңыз пайдалы болар еді, бұл градиентті сақтауға тең.

3.3.4 Болжаудың тиімділігін бағалау.

Машиналық оқыту алгоритмдері трафик сипаттамаларын тиімді болжайтыны дәлелденді. Болжау қатесі – бұл нашар болжамның бір түрі, дәлірек айтсақ, егер өлшеу қателері болмаса, онда болжау әдісі оңтайлы болады.

Сондықтан қосылым салмақтарын реттегеннен кейін қателерді азайту мақсатын қателерді азайту ретінде бағалауға болады.

Бұл тарауда болжау дәлдігін өлшеу үшін келесі ML негізіндегі функцияларды қолданамыз: Орташа квадрат қатесі (MSE) (3.16 теңдеу), квадраттық қателер сомасы (SSE) (3.17 теңдеу), орташа абсолютті қате (MAE) (3.18 теңдеу), Болжамның дәлдігін бағалау үшін түбірлік квадрат қатесі (RMSE) (3.19 теңдеу) және орташа абсолютті пайыздық қате (MAPE) (3.20 теңдеу). MSE - орташа квадраттық қатені өлшейтін жоғалту функциясы, мұнда қате күтілетін және нақты мәндер арасындағы айырмашылық болып табылады. RMSE (3.19) теңдеуде көрсетілгендей MSE квадрат түбіріне тең.

3.4 Модельдеу нәтижелері

3.4.1 IoT және тактиль үшін пакеттердің жоғалуын болжау

Бұл бөлімде біз NARX-RNN уақыт қатарын пайдаланып MSP көмегімен уақыттық қатарларды болжауды орындаймыз. Деректер жиыны IoT трафик генераторынан алынады және IoT моделі AnyLogic симуляторы арқылы модельденеді. Деректер жиынын жинап, өңдегеннен кейін оқыту, тексеру және тестілеу үшін кездейсоқ түрде 75%, 15% және 15% бөлінді. Болжаудың дәлдігі MSE, SSE және MAE жоғалту функциялары арқылы бағаланды. Сонымен қатар болжау дәлдігінің тағы бір өлшемі бар, орташа абсолютті пайыздық қателік (MAPE).

3.1-кестеде жоғарыда аталған жоғалту функцияларын және MAPE өнімділігінің дәлдік өлшемін пайдалана отырып, IoT пакетінің жоғалу жылдамдығын болжау дәлдігі көрсетілген.

Кесте 3.1- Болжамдық модель үшін өлшеу дәлдігі

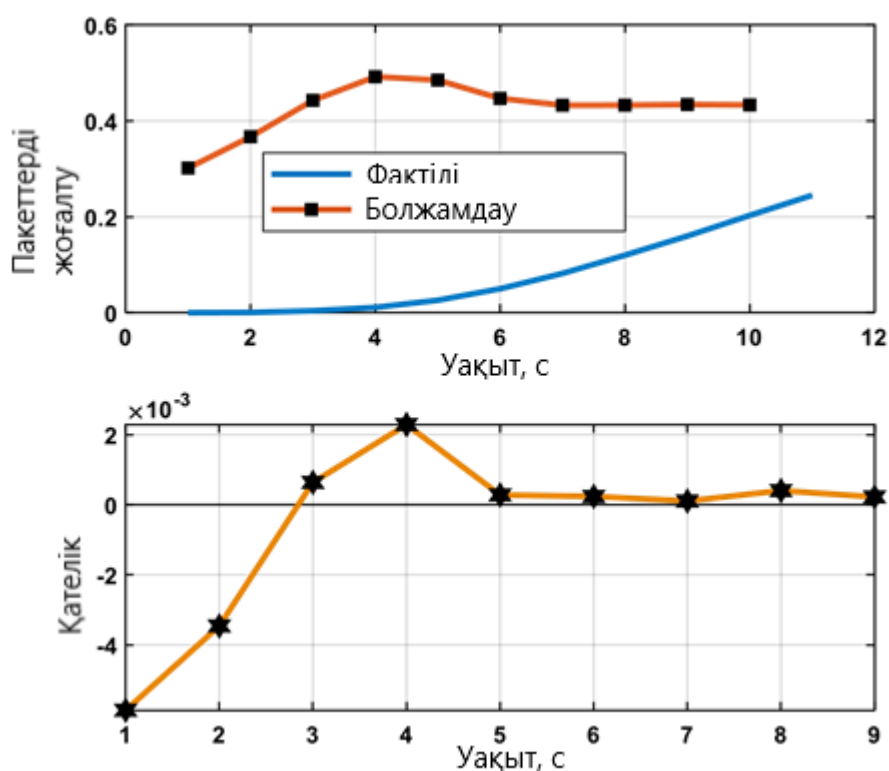
Дәлдік				
Пакет/с	MSE	SSE	MAE	MAPE
2 пакет/с	5.8208e-06	5.2387e-05	0,0015	00,18%
10 пакет/с	1.1145e-05	1.0030e-04	0,0015	6,18%

3.1-кестеде пакеттер саны 2 пакет/с және 10 пакет/с болған кезде IoT трафиінің өнімділігін болжау көрсетілген. Болжамның дәлдігін бағалау үшін дәстүрлі жоғалту функциялары MSE, MAE, SSE және MAPE болжамы пайдаланылады.

Кестедегі нәтижелер MSE жоғалту функциясы негізінде болжанған өнімділік 2 prs және 10 prs жағдайында олардың аналогтарымен салыстырғанда ең жақсы мәнге ие екенін көрсетеді. SSE сипаттамалары да MSE жоғалту функцияларымен бірдей. Сонымен бірге, MAE жоғалту функциясымен болжау

өнімділігі MSE және SSE көрсеткіштерінен нашар. Екінші жағынан, MAPE ең жақсы болжау дәлдігіне 2 пакет/с 0,18%, ал 10 пакет/с ең төмен болжау дәлдігі 6,18%.

3.6-суретте екі қисық сызық көрсетілген. Бірінші қисық жіберілген пакеттер саны 2 пакет/с болған жағдайда ANN-нің IoT трафигі пакеттерінің жоғалуын болжау мүмкіндігін тексеру үшін IoT трафигін уақыт бойынша бірнеше қадам алға болжауды көрсетеді. Нәтиже нақты және болжамды модельдер үшін пакетті жоғалту жылдамдығы уақыт өткен сайын арта түсетінін анық көрсетеді. Біз болжамды пакетті жоғалту жылдамдығы 1-ден 4-ке дейін өсетінін, содан кейін 10-ға дейін төмендейтінін анықтадық, бұл ең жақсы болжау дәлдігін қамтамасыз етеді. Екінші қисық уақыт бойынша болжамның болжамды қателігін (күтілетін және болжанған нәтиже арасындағы айырмашылық) көрсетеді.



3.6-сурет – Пакеттердің жоғалуы және 2 пакет/с пакеттер жағдайында уақыттық қатарларды болжау қателері.

3.7-суретте екі қисық сызық көрсетілген. Бірінші қисық IoT трафигін уақыт бойынша бірнеше қадам алға болжауды және жіберілген пакеттер саны 10 пакет/с болған жағдайда ANN-нің IoT трафигі пакеттерінің жоғалуын болжау мүмкіндігін көрсетеді. Бірінші график нәтижені суреттейді және нақты және болжамды модельдер үшін пакетті жоғалту жылдамдығы уақыт өте келе өсетінін анық көрсетеді. Болжамды пакетті жоғалту жылдамдығы 1-ші уақыттан 4-ке дейін өсетінін, содан кейін 6-уақыт 10-уақытқа тұрақты болғанша аздап

төмендейтінін ескеріңіз, бұл ең жақсы болжау дәлдігін береді. Екінші қисық уақыт бойынша болжамдық қатенің өзгеруін көрсетеді.

3.4.2. NARX қайталанатын нейрондық желісіне негізделген IoT және тактильді Интернет үшін бір қадамдық және көп қадамдық алға болжауды пайдалана отырып, кешіктіру болжамы.

Модельдеу 2,40 ГГц жиілігі және 6 ГБ жады бар Intel(R) Core™ I5-3210M процессорында орындалды. Matlab R2020a симуляциялық пакеті NARX қайталанатын нейрондық желілерді пайдалана отырып, бір қадам алға болжау (SSP) және бірнеше қадам алға болжау (MSP) арқылы кідірісті болжау үшін пайдаланылды.

Болжаудың дәлдігі үш нейрондық желіні оқыту алгоритмі арқылы бағаланды: Trainlm, Traincgf және Trainrp, пайдалану тұрғысынан және орташа квадраттық қате (RMSE) және орташа абсолютті қате В пайыз (MAPE) В сапасы шаралар болжау дәлдігі.

Деректер жиындары AnyLogic модельдеу жүйесін пайдалана отырып, IoT моделінің 3.3-суретінде көрсетілген модель үшін жасалды. Деректер жиынтығын жинап, дайындағаннан кейін ол сәйкесінше оқыту үшін 70%, тестілеу үшін 15% және валидация үшін 15% бөлінді.

3.2-кестеде болжау дәлдігінің өлшемдері ретінде RMSE және MAPE көмегімен Trainlm, Traincgf және Trainrp оқыту алгоритмдеріне сәйкес үш жағдайда кешіктіру мәнін болжау дәлдігі көрсетілген.

Кесте 3.2 - Болжамның дәлдігі

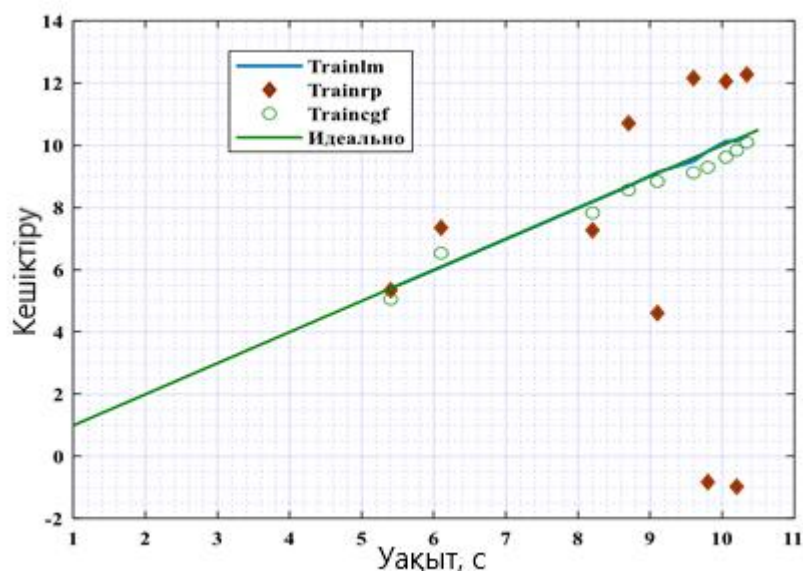
Оқу алгоритмі	Бір қадам алға болжау		Бірнеше қадам алға болжау	
	RMSE	MAPE	RMSE	MAPE
trainlm	0,0551	0,0429	0,0521	0,1301
Traincgf	0,2163	0,5178	0,3704	3.2367
Trainrp	1,4734	0,7245	0,6996	4.7953

Көріп отырғаныңыздай, Trainlm кері таралуы бар Левенберг-Марквардт нейрондық желісінің жаттығу алгоритмі бір қадам алға болжау кезінде де, бірнеше қадамды болжау кезінде де RMSE және MAPE екеуінде де ең жақсы болжау дәлдігіне ие.

Кері таралу және Traincgf жаңартулары бар нейрондық желіні оқыту үшін Fletcher-Reeves конъюгаттық градиентті оқыту алгоритмін пайдалану жағдайында болжау дәлдігі аралық орынды алады, ал Trainrp кері таралу арқылы нейрондық желіні оқыту үшін сенімді оқыту алгоритмін пайдаланған кезде біз аламыз. RMSE және MAPE екеуінде де бір қадам алға болжауда және бірнеше қадам алға болжауда ең төменгі болжау дәлдігі.

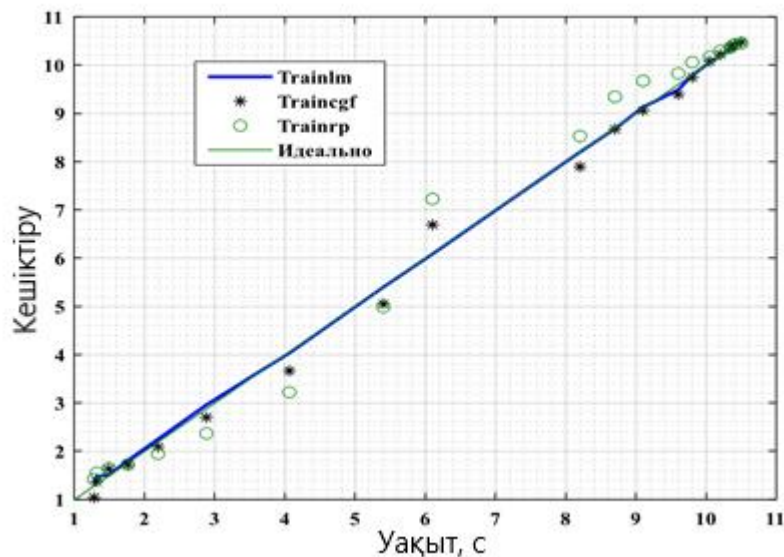
3.8-сурет және 3.9-суретте сәйкесінше бір қадам алға болжау және бірнеше қадамды болжау кезінде жоғарыда аталған барлық оқыту алгоритмдері үшін болжау дәлдігі көрсетілген.

3.8-суреттен көріп отырғанымыздай, Trainlm оқыту алгоритмі идеалды үлгіге өте жақын болжау дәлдігіне ие. Trainrp оқыту алгоритміне келетін болсақ, бұл модель идеалдан айтарлықтай ауытқулар береді.



3.8-сурет – Бір қадам алға болжау нәтижелері.

3.9-суретте көрсетілгендей, барлық оқыту алгоритмдері бір қадам алға болжауға қарағанда, бірнеше қадамды болжау кезінде жақсырақ дәлдікке ие. Сонымен қатар, Trainlm кері таралуы бар Левенберг-Марквардт нейрондық желісін оқыту алгоритмі әлі де қарастырылғандардың ең жақсысы болып табылады.




3.9-сурет – Алдағы бірнеше қадамдарды болжау нәтижелері.

Кесте 3.3 - LSTM айнымалыларының тізімі

$x_t \in \mathbb{R}d$	LSTM бірлігіне векторды енгізу
$f_t \in (0,1)h$	Қақпаның белсендіру векторын ұмытыңыз
$i_t \in (0,1)h$	Енгізу/жаңарту қақпасының белсендіру векторы
$o_t \in (0,1)h$	Шығару қақпасының активтендіру векторы
$h_t \in (-1,1)h$	Жасырын күй векторы LSTM бірлігінің шығыс векторы ретінде де белгілі
$C_t \in (-1,1)h$	Үміткер ұяшық күйі ұяшықты енгізу белсендіру векторы ретінде де белгілі
$C_t \in \mathbb{R}h$	жасуша күйінің векторы
$C-1 \in \mathbb{R}h-1$	Алдыңғы ұяшық күйінің векторы
$W \in \mathbb{R}h \times d, U \in \mathbb{R}h \times h$ and $b \in \mathbb{R}h$	Жаттығу кезінде үйрену қажет салмақ матрицалары мен ауытқу векторының параметрлері
σ	Сигмоидты функция.
\tan	Гиперболалық тангенс функциясы.

d және h үстіңгі әріптері сәйкесінше енгізу мүмкіндіктерінің санын және жасырын бірліктердің санын білдіреді.



3.10-сурет – Ұяшығының негізгі құрылымы.

3.5 LSTM тренингі

LSTM терең оқыту ұяшықтары LSTM желісінің әрбір салмағын қатенің туындысына пропорционалды өзгерту үшін оңтайландыру процесінде қажетті градиенттерді есептеу кезінде кері таралумен біріктірілген градиенттің түсуі сияқты оңтайландыру алгоритмін пайдаланып оқыту реттері тобында оқытылатын бақылауға болады. (LSTM желілерінің шығыс қабатында) сәйкес салмағы бар. RNN-де градиенттің түсу мәселесі мынада: қате градиенттер нақты оқиғалар арасындағы уақыт аралығының өлшемімен тез жоғалады. Қайталанатын желілер қашықтағы кірістерді қосудың қаншалықты маңызды екенін түсіну мүмкін болмас бұрын, соңғы нәтиже мен оқиғалар арасында байланысты орнатуға тырысады. Қате мәндері шығыс қабатынан кері таралса, қате LSTM бірлік ұяшығында қалады.

Кіріс және шығыс уақыт қатарын болжау басқа уақыт қатары берілген бір уақыт қатарының болашақ мәнін болжауға байланысты. Уақыт қатарын болжау үшін екі қатардың да өткен мәндерін (дәлірек болу үшін) немесе бір ғана (қарапайым жүйе үшін) пайдалануға болады.

Жаттығу деректерінің жиынын жасау үшін сымсыз желілер салынды. Жаттығу кезеңі үшін деректер жинағын жинап, талдап, өңдегеннен кейін ол болжау үшін ML үлгісін енгізу үшін пайдаланылды.

Содан кейін деректер жиынын желіге кіріс ретінде жүктегеннен кейін деректер жинағы «Кіріс сериялары» және «Мақсатты сериялар» бағандарындағы екі ішкі жиынға бөлінеді, содан кейін сәйкесінше 70% оқыту және 30% тестілеуге бөлінеді.

Кіріс деректерінің нормалануы нақты максималды немесе ең төменгі мәндерге сәйкес $[-1, 1]$ аралықта болуы керек.

Терең нейрондық желінің оқыту процесі дәуірлер деп аталатын бірнеше итерациялардан тұрады. Ол кездейсоқ инициализация мәндерін салмаққа (w) тағайындаудан және бірінші дәуірдегі b мәндерін ауыстырудан басталады. Белгілі белгі мәндері бар деректерді бақылау мүмкіндіктері кіріс деңгейіне жіберіледі. Әдетте бұл бақылаулар партияларға топтастырылады (көбінесе шағын топтамалар деп аталады). Содан кейін нейрондар өз функцияларын қолданады және егер белсендірілсе, шығыс қабаты болжам жасағанша нәтижені келесі қабатқа береді.

Болжам нақты белгілі мәнмен салыстырылады және болжамды және нақты мәндер арасындағы ауытқу есептеледі (оны біз шығын деп атаймыз). Нәтижелер негізінде жоғалтуды азайту үшін қайта қаралған салмақтар мен қиғаштық мәндері бағаланады және бұл түзетулер желілік қабаттардағы нейрондарға таралады. Келесі дәуір модификацияланған салмақ және қиғаштық мәндері бар алдын ала пакеттік оқыту қадамын қайталайды, бұл модель дәлдігін жақсартуы керек (жоғалтуды азайту арқылы).

Оқыту үшін ең көп дәуір саны 1000 дәуір. Бастапқы оқу көрсеткіші 0,005. Оқыту жылдамдығының төмендеу жылдамдығы 0,2 және оқу жылдамдығының түсу кезеңі 125. Қабаттың түсуін анықтау кезінде біз 0,2 мәнін көрсетеміз, бұл қабаттардың 20% төмендейді дегенді білдіреді. Осыдан кейін біз шығысты 1 бірлікке орнататын тығыз қабатты қосамыз. Осыдан кейін біз белгілі Адам оптимизаторы арқылы модельді құрастырамыз және шығынды орташа квадраттық қате ретінде анықтаймыз. Бұл квадраттық қателердің орташа мәнін есептеуге мүмкіндік береді. Содан кейін біз 32 партия өлшемімен 1000 дәуірге арналған үлгіні орнаттық. Компьютердің техникалық сипаттамаларына байланысты есептеуді аяқтауға бірнеше минут кетуі мүмкін.

Algorithm1: Prediction using Deep Learning-LSTM network

```
1 InputSeries: Time series training data  $D = \{D_1, D_2, \dots, D_t\}$ 
2 TargetSeries: Time series training data  $t = \{t_1, t_2, \dots, t_n\}$ 
3 Outputs: the predicted output  $y = \{y_1, y_2, \dots, y_n\}$ 
4 Initialize: the weights and biases randomly
5 Split: data into 70% training and 30% testing data
6 size  $\leftarrow$  length(series) * 0.70
7 Train  $\leftarrow$  series[0...size]
8 Test  $\leftarrow$  series[size...length(size)]
9 Normalize: the dataset ( $D_i$ ) into values from 0 to 1
10  $10 \leftarrow$  nRepeatModel {e.g., Repeat each model 10 times}
11  $1 \leftarrow$  nDataTypes
12  $1 \leftarrow$  nDataCount
13  $32 \leftarrow$  batch size
14  $1000 \leftarrow$  number of epochs
15 Select: training window size (tw) and organize  $D_i$  accordingly
16 Define: LSTM Network Architecture
17 while nDataCount  $\leq$  nDataTypes do
18     XTrain, YTrain, XTest, YTest, YPred  $\leftarrow$  loadInputData()
19     count  $\leftarrow$  1
20     for all nEpoch do
21         for all nBatch do
22             while count  $\leq$  nRepeatModel do
23                 define DL Model()
24                 compile Model()
25                 fit Model()
26                 train Model()
27                 evaluate Model()
28                 save model ()
29                 makePredictions()
30                 save Predicted Values()
33                 save AccuracyLoss()
34                 count  $\leftarrow$  count + 1
35             end while
36         count  $\leftarrow$  1 {Reset repeat counter}
37         end for
38     end for
39     nDataCount  $\leftarrow$  nDataCount + 1
40 end while
```

Терең оқыту алгоритмдері әдетте болжау қателерінің мәндері арқылы бағаланады. Қате – жаман болжам; үлгінің болжамы мінсіз болса, қате мәні нөлге тең болады. Сондықтан мақсат қатені азайтуға көмектесетін салмақтар мен қиғаштықтардың жиынтығын анықтау арқылы қате мәндерін азайту болып табылады. Терең оқыту алгоритмдері пайдаланатын жоғалтулардан басқа, зерттеушілер болжау өнімділігін бағалау үшін жиі орташа квадраттық қатені (RMSE) және орташа абсолютті пайыздық қатені (MAPE) пайдаланады.

RMSE нақты және болжамды мәндер арасындағы айырмашылықты өлшейді. Стандартты ауытқуды (RMSE) есептеу формуласы (4.9-тендеу). MAPE тендеуі (4.10) (пайыздық орташа абсолютті қате) абсолютті мәндерді қолданатын салыстырмалы қателік өлшемі болып табылады. MAPE екі артықшылығы бар. Біріншіден, абсолютті мәндер оң және теріс қателердің бір-бірін жоюына

мүмкіндік бермейді. Екіншіден, салыстырмалы қателер тәуелді айнымалы масштабтаудан тәуелсіз болғандықтан, әртүрлі масштабтағы уақыт қатарларының деректері арасындағы болжам дәлдігін салыстыру үшін осы өлшемді пайдалануға болады.

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (4.9)$$

$$MAPE = \frac{100}{N} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (4.10)$$

мұндағы N – бақылаулардың жалпы саны, y_t – санның нақты мәні, \hat{y}_t болжамды мән болып табылады.

3.6 Қолданбалар және модельдеу нәтижелері

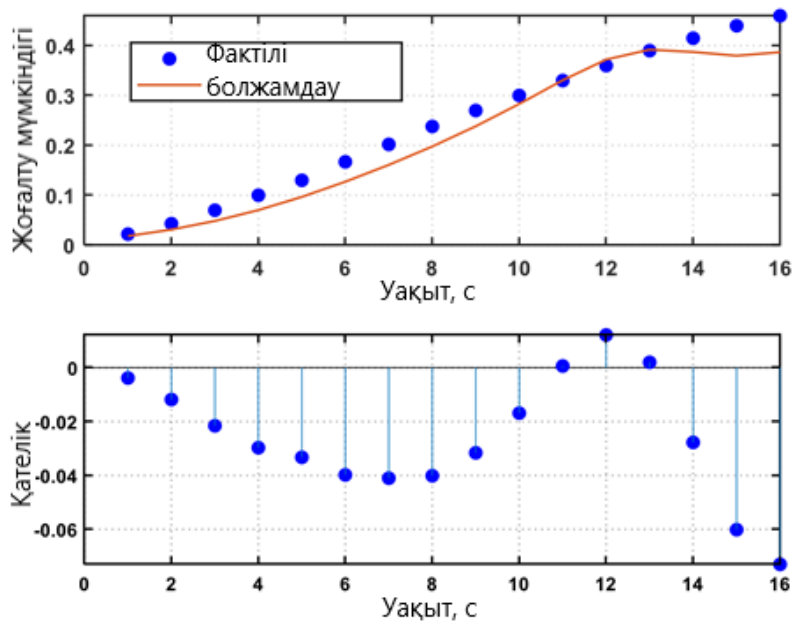
IoT трафигін болжау LSTM желісімен Deep Learning Neural Networks (DNN) көмегімен орындалады. Модельдеу тактілік жиілігі 2,40 ГГц және жады 6 ГБ Intel (R) Core(TM) I5-3210M процессорында орындалды. Модельдеу MATLAB R2020a ортасында LSTM Deep Learning көмегімен IoT трафигін болжауға арналған.

DNN алгоритмін үйрету үшін (3.2) бөлімде көрсетілгендей IoT үлгісімен жасалған деректер жиынын пайдаланды. Біз LSTM желісіндегі жасырын нейрондардың санына байланысты өнімділікті үш жағдайда зерттейміз. Жасырын нейрондардың санына байланысты болжау үшін үш жағдайды таңдап алайық: сәйкесінше 500, 100 және 50. LSTM деңгейіндегі жасырын нейрондар санының өзгеруі болжау дәлдігін оңтайландыруға қалай әсер ететінін зерттеу үшін LSTM қабатындағы жасырын нейрондар санына байланысты терең оқытудың үш моделі ұсынылады. Болжамның дәлдігі RMSE және MAPE көмегімен бағаланады.


500 жасырын нейроны бар 3.11-суреттегі болжау үлгісі $RMSE = 0,0298$ кезінде ең жақсы болжау дәлдігіне ие, ұқсас модельдермен салыстырғанда 11,74% жақсарды. Болжау процесіндегі уақыт 16 с. Модельдеу нәтижелері жеткілікті дәрежедегі дәлдікпен нақты үлгіге сәйкес келетінін суреттен көруге болады.

3.12-суретте 200 жасырын нейрондары бар IoT трафигін болжау көрсетілген. Болжау үлгісі 500 жасырын нейрондары бар модельге қарағанда дәлірек емес; RMSE мәні 0,1029 дейін төмендеп, басқа үлгілермен салыстырғанда 5,23%-ға жақсарды. Сонымен қатар, бұл жағдайда болжау процесіндегі уақыт 16 с. Бірінші қисық болжау үлгісінің 3 секундқа дейінгі нақты модельге ұқсас екенін көрсетеді, содан кейін ең жақсы болжау дәлдігі қамтамасыз етілетін нақтыдан 16 секундқа дейін біртіндеп ауытқиды. Бұл модель

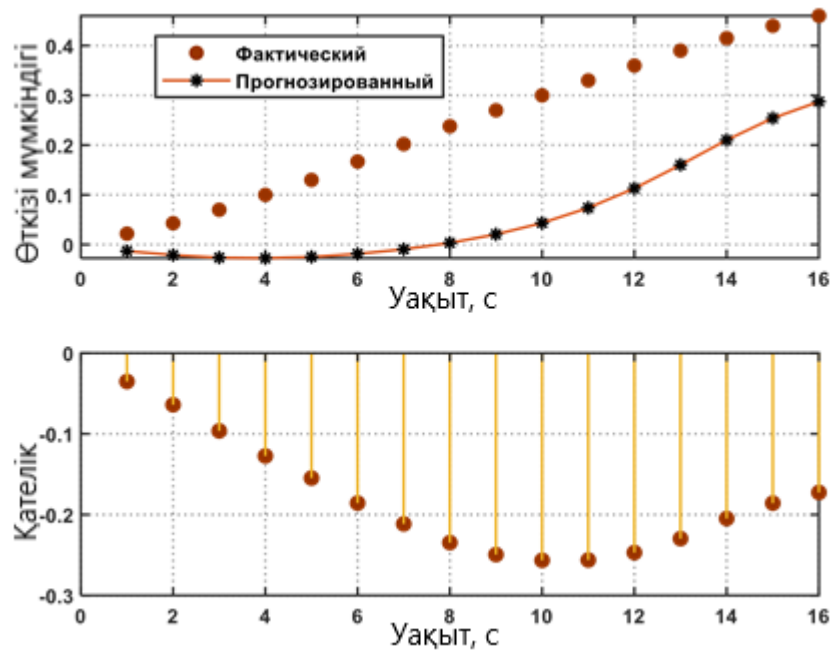
ең төмен болжау дәлдігіне ие: оның әріптестерімен салыстырғанда $RMSE = 0,16939$. 3.13-суреттің біріншісінде көрсетілгендей болжау моделі нақты үлгіден ауытқиды. Сонымен қатар, ол 2 с уақытқа дейін аздап төмендейді, содан кейін 5 с дейін тұрақты болады, содан кейін бірте-бірте 16 с уақытқа дейін артады, бұл жерде ең жақсы болжау дәлдігі алынады.



3.11-сурет – LSTM қабатындағы 500 жасырын нейрондағы болжамды және нақты өткізу қабілеті және RMSE.



3.12-сурет – LSTM қабатындағы 200 жасырын нейрондағы болжамды және нақты өткізу қабілеті және RMSE.



3.13-сурет – Болжалды және нақты өткізу қабілеті және LSTM қабатындағы 50 жасырын нейрондағы RMSE.

ҚОРЫТЫНДЫ

1. Ұялы желілердің дамуын және бесінші және кейінгі буынның байланыс желілерін құру ерекшеліктерін талдау ультра тығыз желілерге және өте төмен кідіріспен желілерге көшу кезінде желіде ресурстарды бөлу міндеттерінің күрделілігі ғана емес екенін көрсетеді. айтарлықтай артады, сонымен қатар жиналуы және өңделуі тиіс деректер көлемі де өзгереді. Желілерде ресурстарды тиімді бөлу негізінде жатқан трафикті болжау үшін. Сонымен қатар, қозғалыс сипаттамаларын болжау үшін жасанды интеллект технологияларын пайдалану ұтымды ғана емес, сонымен қатар қажет.

2. Трафикті болжау есептерін шешу үшін машиналық оқыту және терең оқыту мүмкіндіктері, бақыланатын, бақыланбайтын, күшейтілген оқыту әдістері, алға таралатын нейрондық желілер, кері таралатын қайталанатын нейрондық желілер талданады және трафик сипаттамаларын болжаудың бірқатар мәселелері анықталды, онда машиналық оқытуды және терең оқытуды тиімді пайдалану мүмкін. бесінші және одан кейінгі буындардың коммуникациялық желілерінде оқыту. Бұл міндеттерге VANET желісіндегі пакеттердің жоғалуын болжау, заттар интернеті және тактильді интернет үшін 5G байланыс желілеріндегі пакеттердің жоғалуын, заттар интернеті мен тактильді интернет үшін 5G байланыс желілеріндегі кідірістерді және 5G байланыс желілеріндегі өткізу қабілеттілігін болжау кіреді. заттар интернеті үшін.

3. Транспорттық желілері сияқты коммуникациялық желілерде күрделі қалалық жағдайларда желілік түйіндердің қозғалыс жылдамдығының жоғары болуына байланысты, сондай-ақ заттар Интернет желілерінде түйіндерді жоғары тығыздықта және өте тығыз орналастыру мүмкіндігіне байланысты жиналған деректер болжау үшін Гаусс шу деректерін де, кездейсоқ шығарындыларды да қамтуы мүмкін. Осыған байланысты трафик сипаттамаларын болжау мәселелерінде сенімді максималды ықтималдық бағалауларын – M-бағалауыштарын пайдалану мүмкіндігі мен тиімділігін зерттеу қажет.

4. Оқу процесін жақсарту және оқу деректері таза және таза болған кезде сенімді машиналық оқыту үлгісін жасау үшін дәстүрлі жоғалту функциясын ауыстыру үшін сенімді жоғалту функциясы ретінде M-баллдары деп аталатын сенімді статистикалық бағалаулар жиынтығын пайдалану ұсынылады. Гаусс шуы мен шектен тыс мәндерді қамтиды.

5. Таза деректер жағдайында дәстүрлі MSE жоғалту функциясын ауыстыру үшін жоғалту функциясы ретінде M-баллдары бар көпқабатты алға бағытталған нейрондық желі (MFNN) ұсынылады. MFNN архитектурасы пайдаланылады, ол 20 жасырын нейроннан тұратын жасырын қабаты бар үш деңгейлі алға топологиядан тұрады. Ұсынылған әдіс VANET желісінің екі қосымшасында қолданылады:

- Нейрондық желіні оқыту негізінде VANET үшін энергияны бағалау.

- Нейрондық желіні оқытуға негізделген VANET пакетінің жоғалуын бағалау.

6.VANET желілерінде терең оқытуға және көпқабатты нейрондық желіге негізделген деректер Гаусс шуы мен кездейсоқ шеткі мәндермен бұрмаланған жағдайда сенімді әділ бағалау және сенімді Коши бағалауы арқылы пакеттердің жоғалуын болжау әдісі әзірленді. орташа квадраттық қателік бес еседен астам, ал абсолютті қателік ең кіші квадраттар әдісін қолданумен салыстырғанда шамамен 2 есе.

7.NARX-RNN сыртқы кірістері бар қайталанатын сызықты емес авторегрессивті нейрондық желіні пайдалана отырып, уақыт қатарларына негізделген көп сатылы болжау (MSP) тәсілін пайдалана отырып, пакеттердің жоғалуын болжау әдісі әзірленді.

8.NARX-RNN пайдалану негізінде бір және бірнеше қадам алға болжау арқылы заттар интернеті және тактильді интернет желілеріндегі кідірісті болжау әдісі әзірленді. Болжаудың дәлдігі үш нейрондық желіні оқыту алгоритмі арқылы бағаланды: Trainlm, Traincgf, Trainrp және орташа квадраттық қате (RMSE) және абсолютті қателік (MAPE) мәндері.

9.NARX сызықты емес қайталанатын авторегрессивті нейрондық желісі негізіндегі заттар интернеті және тактильді интернет желілеріндегі кідіріс пен жоғалуды болжаудың әзірленген әдісі, ол Флетчерден озып, Левенберг-Марквардт алгоритмімен жаттықтыру кезінде ең жақсы нәтиже береді. - Reeves оқыту алгоритмін және тұрақты оқыту алгоритмін бір қадамда болжау кезінде де, бірнеше қадамда болжау кезінде де шама немесе одан да көп реттілік бойынша RMS және абсолютті қателер.

10.Ұзақ мерзімді қысқа мерзімді жады (LSTM) алгоритмі негізінде 500 жасырын нейронмен тәжірибе үшін қолайлы дәлдікпен болжау нәтижелерін қамтамасыз ететін "Заттардың интернеті" трафигі үшін 5G/6G желілерінің өткізу қабілеттілігін болжау әдісі әзірленді.

11.LSTM ұзақ мерзімді қысқа мерзімді жақты пайдалану арқылы терең оқыту негізінде VANET желісінің өткізу қабілеттілігін болжау әдісі әзірленді. Болжау сипаттамалары жіберілген пакеттер санына байланысты зерттелді: 4 пакет/с, 6 пакет/с, 8 пакет/с, 10 пакет/с, 12 пакет/с және 14 пакет/с. 4 пакет/с пайдаланған кезде болжау дәлдігі барлық қарастырылған нұсқалардың ішінде ең жақсысы, ал 14 пакет/с арқылы болжанған модельдің болжау дәлдігі ең төмен екендігі анықталды. Болжаудың дәлдігі RMSE және MAPE мәндерімен бағаланды.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

1. Q. K. Ud Din Arshad, "A Review on the Evolution of Cellular Technologies" / Q. K. Ud Din Arshad , Ahsan Ullah Kashif , Ijaz Mansoor Quershi // 16th International Bhurban Conference on Applied Sciences and Technology (IBCAST), PP. 989-993, Islamabad, Pakistan, Jan. 2019.
2. Bharti kalra, "A Comparative Study of Mobile Wireless Communication Network: 1G to 5G" / Bharti kalra, Dr. D.K. Chauhan // International Journal of Computer Science and Information Technology Research ISSN 2348-120X, Vol. 2, Issue 3, PP.430-433, Sept 2014.
3. G. Villarrubia, "Artificial neural networks used in optimization problems," / G. Villarrubia, J. F. De Paz, P. Chamoso, and F. D. la Prieta // Neurocomputing, vol. 272, pp. 10–16, 2018.
4. Jürgen Schmidhuber, "Deep learning in neural networks: An overview"/ Jürgen Schmidhuber // Elsevier, Neural Networks, vol.61, pp. 85-117, 2015.
5. X. Du, "Stacked LSTM Deep Learning Model for Traffic Prediction in Vehicle-to-Vehicle Communication,"/ X. Du, H. Zhang, H. V. Nguyen and Z. // 2017 IEEE 86th Vehicular Technology Conference (VTC-Fall), 2017, pp. 1-5, doi:10.1109/VTCFall.2017.8288312.
6. A. R. Abdellah, "IoT traffic prediction using multi-step ahead prediction with neural network," / A. R. Abdellah, O. A. K. Mahmood, A. Paramonov and A. Koucheryavy // 2019 11th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT), 2019, pp. 1-4, doi: 10.1109/ICUMT48472.2019.8970675.
7. M. Chen, "Artificial Neural Networks-Based Machine Learning for Wireless Networks: A Tutorial," / M. Chen, U. Challita, W. Saad, C. Yin and M // IEEE Communications Surveys & Tutorials, vol. 21, No. 4, pp. 3039-3071, Fourthquarter 2019, doi: 10.1109/COMST.2019.2926625.
8. Abdellah A.R. Robust Estimation of VANET Performance-Based Robust Neural Networks Learning. / Abdellah A.R., Muthanna A., Koucheryavy A. // In: Galinina O., Andreev S., Balandin S., Koucheryavy Y. (eds) Internet of Things, Smart Spaces, and Next Generation Networks and Systems. NEW2AN 2019, ruSMART 2019. Lecture Notes in Computer Science, Springer, Cham. vol 11660, pp. 402–414, 2019, https://doi.org/10.1007/978-3-030-30859-9_34.
9. Abdellah A.R. Energy Estimation for VANET Performance Based Robust Neural Networks Learning. / Abdellah A.R., Muthanna A., Koucheryavy A. // In: Vishnevskiy V., Samouylov K., Kozyrev D. (eds) Distributed Computer and Communication Networks. DCCN 2019. Communications in Computer and Information Science, Springer, Cham. vol 1141, pp. 127–138, 2019, https://doi.org/10.1007/978-3-030-36625-4_11.
10. Peter J. Huber, "Robust Statistics," / Peter J. Huber, Elvezio M. Ronchetti // John Wiley and Sons, New York, 2nd Edition, March 2009.
11. Ali R. Abd Ellah, "Comparison of Different Backpropagation Training Algorithms Using Robust M-Estimators Performance Functions"/ Ali R. Abd Ellah,

Mohamed H. Essai, Ahmed Yahya // the IEEE 2015 Tenth International Conference on Computer Engineering & Systems (ICCES), PP. 384-388, December 23-24, Cairo, Egypt, 2015.

12. Mohamed M. Zahra, Mohamed H. Essai, Ali R. Abd Ellah, "Performance Functions Alternatives of Mse for Neural Networks Learning", International Journal of Engineering Research & Technology (IJERT), Vol. 3, Issue 1, pp. 967-970, January 2014.

13. Jagannath J. Machine learning for wireless communications in the Internet of Things: A comprehensive survey / Jagannath J., Polosky N., Jagannath A., Restuccia F., Melodia T. // Elsevier, Ad Hoc Networks, Vol. 93, pp. 1-46, Article 101913, 2019, <https://doi.org/10.1016/j.adhoc.2019.101913>.

14. M. E., "Machine Learning for 5G/B5G Mobile and Wireless Communications: Potential, Limitations, and Future Directions," / M. E. Morocho-Cayamcela, H. Lee and W. Lim // in IEEE Access, Vol. 7, pp. 137184-137206, 2019, doi: 10.1109/ACCESS.2019.2942390.

15. A. R. Mohammed, "Machine Learning and Deep Learning Based Traffic Classification and Prediction in Software Defined Networking," / A. R. Mohammed, S. A. Mohammed and S. Shirmohammadi // 2019 IEEE International Symposium on Measurements & Networking (M&N), 2019, pp. 1-6, doi: 10.1109/IWMN.2019.8805044.

16. O'Connell, Eoin, "Challenges Associated with Implementing 5G in Manufacturing" / O'Connell, Eoin; Moore, Denis; Newe, Thomas // MDPI, Telecom, Vol. 1, No. 1, pp. 48-67, 2020, <https://doi.org/10.3390/telecom1010005>.

17. Y. Fu, "Artificial Intelligence to Manage Network Traffic of 5G Wireless Networks," / Y. Fu, S. Wang, C. Wang, X. Hong, and S. McLaughlin // in IEEE Network, vol. 32, no. 6, pp. 58-64, November/December 2018, doi: 10.1109/MNET.2018.1800115.

18. Andrea Biral, "The challenges of M2M massive access in wireless cellular networks" / Andrea Biral, Marco Centenaro, Andrea Zanella, Lorenzo Vangelista, Michele Zorzi // Elsevier, Digital Communications and Networks, Vol. 1, Issue 1, PP. 1-19, 2015, <https://doi.org/10.1016/j.dcan.2015.02.001>.

19. P. Popovski, "5G Wireless Network Slicing for eMBB, URLLC, and mMTC: A Communication-Theoretic View," / P. Popovski, K. F. Trillingsgaard, O. Simeone and G. Durisi // in IEEE Access, vol. 6, pp. 55765-55779, 2018, doi: 10.1109/ACCESS.2018.2872781.

20. Attai Ibrahim Abubakar, "The Role of Artificial Intelligence Driven 5G Networks in COVID-19 Outbreak: Opportunities, Challenges, and Future Outlook" / Attai Ibrahim Abubakar, Kenechi G. Omeke, Metin Ozturk, Sajjad Hussain and Muhammad Ali Imran // Frontiers in Communications and Networks, Vol. 1, pp.1-22, Article. 575065, Nov 2020, <https://doi.org/10.3389/frcmn.2020.575065>.

21. 5G/IMT-2020, Требования к системе тестирования сетей 5G.

22. Varga P., "5G support for Industrial IoT Applications—Challenges, Solutions, and Research gaps" / Varga P., Peto J., Frankó A., Balla D., Haja D., Janky

F., Soos G., Ficzer D., Maliosz M., Toka L // MDPI, Sensors, Vol. 20, Issue 3, pp. 1-43, article. 828, 2020, doi: 10.3390/s20030828.

23. 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, pp. 267–280, 2020. https://doi.org/10.1007/978-3-030-65726-0_24.

24. Ali R. Abdellah, "VANET Traffic Prediction Using LSTM with Deep Neural Network Learning" / 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/ruSMART). Lecture Notes in Computer Science, Springer, Cham. Vol 12525, pp. 281–294, 2020, https://doi.org/10.1007/978-3-030-65726-0_25.

25. Y. L. Lee, "A Survey on Applications of Deep Reinforcement Learning in Resource Management for 5G Heterogeneous Networks," / Y. L. Lee and D. Qin // 2019 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC), Lanzhou, China, 2019, pp. 1856-1862, doi: 10.1109/APSIPAASC47483.2019.9023331.

26. P. V. Klaine, "A Survey of Machine Learning Techniques Applied to SelfOrganizing Cellular Networks," / P. V. Klaine, M. A. Imran, O. Onireti and R. D. Souza // in IEEE Communications Surveys & Tutorials, vol. 19, No. 4, pp. 2392-2431, Fourthquarter 2017, doi: 10.1109/COMST.2017.2727878.

27. A. Abdellah, A. Koucheryavy," SURVEY ON ARTIFICIAL INTELLIGENCE TECHNIQUES IN 5G NETWORKS" / A. Abdellah, A. Koucheryavy // Информационные технологии и телекоммуникации, СПбГУТ, Россия, Vol. 8, Issue. 1, pp. 1-10, April 2020.

28. 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), pp.1–6, 2016, doi: 10.1109/PIMRC.2016.7794614.

29. Y. Sun, "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, pp. 3072-3108, Fourthquarter 2019, doi: 10.1109/COMST.2019.2924243.

30. 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. pp. 18-29, 2020, https://doi.org/10.1007/978-3-030-66242-4_2.

31. M. Chen, "Artificial Neural Networks-Based Machine Learning for Wireless Networks: A Tutorial," / M. Chen, U. Challita, W. Saad, C. Yin and M.

Debbah // in IEEE Communications Surveys & Tutorials, Vol. 21, No. 4, pp. 3039-3071, Fourthquarter 2019, doi: 10.1109/COMST.2019.2926625.

32. Volkov A. IoT Traffic Prediction with Neural Networks Learning Based on SDN Infrastructure. / Volkov A., Abdellah A.R., Muthanna A., Makolkina M., Paramonov A., Koucheryavy A. // In: Vishnevskiy V.M., Samouylov K.E., Kozyrev D.V. (eds) Distributed Computer and Communication Networks. DCCN 2020. Lecture Notes in Computer Science, Springer, Cham. Vol 12563. pp. 64-76, 2020, https://doi.org/10.1007/978-3-030-66471-8_6 .

33. Boutaba, R. A comprehensive survey on machine learning for networking: evolution, applications, and research opportunities. / Boutaba, R., Salahuddin, M.A., Limam, N. et al. // J Internet Serv Appl., Vol. 9, Article number. 16, pp. 1-99, 2018. <https://doi.org/10.1186/s13174-018-0087-2>.

34. Nour Alqudah, "Machine Learning for Traffic Analysis: A Review" / Nour Alqudah, Qussai Yaseen // Elsevier, Procedia Computer Science, Vol. 170, pp. 911-916, 2020, ISSN 1877-0509, <https://doi.org/10.1016/j.procs.2020.03.111>.

СЫН – ПІКІР

Дипломдық жоба

Сембаев Диас Берикказыұлы

6B06201 «Телекоммуникация» білім беру бағдарламасы

Тақырыбы: **«Жасанды интеллект технологиясына негізделген 5G желілері үшін трафиктің сипаттамаларын болжау»**

Орындалды:

- а) графикалық бөлімі 11 бет;
- б) түсіндірме жазбасы 69 бет.

ЖҰМЫСҚА ЕСКЕРТУ ЖАСАУ

Дипломдық жұмыста «интернет заттарын» енгізу, бесінші және одан кейінгі байланыс желілеріндегі жоғалтулар мен кешігулер контекстінде бесінші және кейінгі буынның байланыс желілерінің өткізу қабілетін болжау мәселелерін шешу үшін машиналық оқыту мен терең оқытуды пайдалану ұсынылған. Заттар интернеті және тактильді интернет желілеріне қатысты ұрпақтар, VANET автомобиль желілеріндегі өткізу қабілеті мен жоғалтулары.

Сондай-ақ, қзақ мерзімді және қысқа мерзімді жады (LSTM) алгоритмі негізінде 500 жасырын нейронмен тәжірибе үшін қолайлы дәлдікпен болжау нәтижелерін қамтамасыз ететін "Заттардың интернеті" трафигі үшін 5G/6G желілерінің өткізу қабілеттілігін болжау әдісі әзірленген. LSTM ұзақ мерзімді қысқа мерзімді жадты пайдалану арқылы терең оқыту негізінде VANET желісінің өткізу қабілеттілігін болжау әдісі әзірленді. Болжау сипаттамалары жіберілген пакеттер санына байланысты зерттелген

Жұмыс бағасы

Жалпы, дипломдық жұмыс 95 "өте жақсы" деген бағаға, ал студент Сембаев Диас Берикказыұлына 6B06201 «Телекоммуникация» білім беру бағдарламасы бойынша техника және технологиялар «бакалавр» академиялық дәрежесіне ұсынылады.

Сын – пікір беруші

ҚазҰАЗУ, PhD докторы,

Энергия үнемдеу және

автоматика кафедрa меңгерушісі

Молдажанов А.К.



Дипломдық жұмысқа
ҒЫЛЫМИ ЖЕТЕКШІНІҢ ПІКІРІ

Сембаев Диас Берикказыұлы

6B06201 Телекоммуникация

Тақырыбы: Жасанды интеллект технологиясына негізделген 5G желілері үшін трафиктің сипаттамаларын болжау

Дипломдық жұмыста «интернет заттарын» енгізу, бесінші және одан кейінгі байланыс желілеріндегі жоғалтулар мен кешігулер контекстінде бесінші және кейінгі буынның байланыс желілерінің өткізу қабілетін болжау мәселелерін шешу үшін машиналық оқыту мен терең оқытуды пайдалану ұсынылады. Заттар интернеті және тактильді интернет желілеріне қатысты ұрпақтар, VANET автомобиль желілеріндегі өткізу қабілеті мен жоғалтулары.


Бірінші бөлімде зерттелген ғылыми жұмыстың теориясына шолу жасалынды, қолданылу аясы мен жетілдіру технологиялары жазылды. Бұл жобада кәсіби әдебиеттерден үзінділер келтіріліп, 5G және кейінгі ұрпақ желілерінің артықшылықтары мен кемшіліктеріне талдау жасалынды.


Екінші бөлімде VANET желілеріне robust m-estimates пайдалану және машиналық оқуды қолдану туралы жазылған.

Үшінші бөлімде машинады оқыту негізіндегі бесінші және келесі ұрпақ байланыс желілеріндегі шоғалу және кідергіні болжау жүргізілді. LSTM коды бойынша модельдері алынды.

Студент Сембаев Диас Берикказыұлы дипломдық жұмысты жазу барысында жетекші нұсқаулығымен өз бетінше жұмыс істеу қабілетін көрсетті. Дипломдық жұмыс 95 А өте жақсы деп бағаланды, ал студент Сембаев Диас Берикказыұлына 6B06201 «Телекоммуникация» білім беру бағдарламасы бойынша «техника және технологиялар» бакалавры академиялық дәрежесіне ұсынылады.

Ғылыми жетекші
ЭТЖҒТ кафедрасының аға оқытушысы,
техника ғылымдарының магистрі


С. Марксұлы
«25» 05 2023 ж.



**Университеттің жүйе администраторы мен Академиялық мәселелер департаменті
директорының ұқсастық есебіне талдау хаттамасы**

Жүйе администраторы мен Академиялық мәселелер департаментінің директоры көрсетілген еңбекке қатысты дайындалған Плагиаттың алдын алу және анықтау жүйесінің толық ұқсастық есебімен танысқанын мәлімдейді:

Автор: Сембаев Диас Берикказыұлы

Тақырыбы: Жасанды интеллект технологиясына негізделген 5G желілері үшін трафиктің сипаттамаларын болжау

Жетекшісі: Сұңғат Марқсұлы

1-ұқсастық коэффициенті (30): 1.5

2-ұқсастық коэффициенті (5): 0.4

Дәйексөз (35): 2.8

Әріптерді ауыстыру: 18

Аралықтар: 0

Шағын кеңістіктер: 6

Ақ белгілер: 0

Ұқсастық есебін талдай отырып, Жүйе администраторы мен Академиялық мәселелер департаментінің директоры келесі шешімдерді мәлімдейді :

Ғылыми еңбекте табылған ұқсастықтар плагиат болып есептелмейді. Осыған байланысты жұмыс өз бетінше жазылған болып санала отырып, қорғауға жіберіледі.

Осы жұмыстағы ұқсастықтар плагиат болып есептелмейді, бірақ олардың шамадан тыс көптігі еңбектің құндылығына және автордың ғылыми жұмысты өзі жазғанына қатысты күмән тудырады. Осыған байланысты ұқсастықтарды шектеу мақсатында жұмыс қайта өңдеуге жіберілсін.

Еңбекте анықталған ұқсастықтар жосықсыз және плагиаттың белгілері болып саналады немесе мәтіндері қасақана бұрмаланып плагиат белгілері жасырылған. Осыған байланысты жұмыс қорғауға жіберілмейді.

Негіздеме:

2023-05-25

Күні

Кафедра меңгерушісі



Протокол

о проверке на наличие неавторизованных заимствований (плагиата)

Автор: Сембаев Диас Берикказыұлы

Соавтор (если имеется):

Тип работы: Дипломная работа

Название работы: Жасанды интеллект технологиясына негізделген 5G желілері үшін трафиктің сипаттамаларын болжау

Научный руководитель: Сұңғат Маркесұлы

Коэффициент Подобия 1: 1.5

Коэффициент Подобия 2: 0.4

Микропробелы: 6

Знаки из других алфавитов: 18

Интервалы: 0

Белые Знаки: 0

После проверки Отчета Подобия было сделано следующее заключение:

Заимствования, выявленные в работе, является законным и не является плагиатом. Уровень подобия не превышает допустимого предела. Таким образом работа независима и принимается.

Заимствование не является плагиатом, но превышено пороговое значение уровня подобия. Таким образом работа возвращается на доработку.

Выявлены заимствования и плагиат или преднамеренные текстовые искажения (манипуляции), как предполагаемые попытки укрытия плагиата, которые делают работу противоречащей требованиям приложения 5 приказа 595 МОН РК, закону об авторских и смежных правах РК, а также кодексу этики и процедурам. Таким образом работа не принимается.

Обоснование:

2023-05-25

Дата

Заведующий кафедрой



Протокол

о проверке на наличие неавторизованных заимствований (плагиата)

Автор: Сембаев Диас Берикказыұлы

Соавтор (если имеется):

Тип работы: Дипломная работа

Название работы: Жасанды интеллект технологиясына негізделген 5G желілері үшін трафиктің сипаттамаларын болжау

Научный руководитель: Сұңғат Марқсұлы

Коэффициент Подобия 1: 1.5

Коэффициент Подобия 2: 0.4

Микропробелы: 6

Знаки из других алфавитов: 18

Интервалы: 0

Белые Знаки: 0

После проверки Отчета Подобия было сделано следующее заключение:

Заимствования, выявленные в работе, является законным и не является плагиатом. Уровень подобия не превышает допустимого предела. Таким образом работа независима и принимается.

Заимствование не является плагиатом, но превышено пороговое значение уровня подобия. Таким образом работа возвращается на доработку.

Выявлены заимствования и плагиат или преднамеренные текстовые искажения (манипуляции), как предполагаемые попытки укрытия плагиата, которые делают работу противоречащей требованиям приложения 5 приказа 595 МОН РК, закону об авторских и смежных правах РК, а также кодексу этики и процедурам. Таким образом работа не принимается.

Обоснование:

2023-05-25

Дата


Сұңғат Марқсұлы

проверяющий эксперт