

БОЛАТБЕК МИЛАНА АСЛАНБЕКҚЫЗЫ

**Веб-ресурстардағы экстремистік бағыттағы мәтіндерді анықтауға арналған
семантикалық талдау үлгілерін құру және зерттеу**

6D100200 – Ақпараттық қауіпсіздік жүйелері

Философия докторы (PhD)
дәрежесін алу үшін дайындалған диссертация

Ғылыми кеңесшілер:
Мусиралиева Ш.Ж.,
ф.-м.ғ.к., қауымдастырылған профессор
Dieter Gollmann,
профессор

МАЗМҰНЫ

НОРМАТИВТІ СІЛТЕМЕЛЕР	4
БЕЛГІЛЕУЛЕР МЕН ҚЫСҚАРТУЛАР	5
КІРІСПЕ	6
1..... ЭКСТРЕМИСТІК МӘЛІМЕТТЕР ТҮСІНІГІ ЖӘНЕ ЕСЕПТІҢ ҚОЙЫЛЫМЫ	11
1.1 Экстремистік мәліметтер түсінігі	11
1.2 Экстремизмнің жіктелуі	13
1.3 Жаһандық экстремистік ресурстар	14
1.3.1 Жаһандық терроризм дерекқоры (GTD)	14
1.3.2 RAND Database of Worldwide Terrorism Incidents	16
1.4 Экстремизмге қарсы күрес	17
1.4.1 Экстремизммен күресуге арналған жобалар	18
1.4.1 Trase жобасы.....	18
1.4.2 Sharaka жобасы.....	19
1.4.3 Scorpius жобасы.....	20
1.4.4 Dark web project AI Lab Dark Web жобасы	21
1.4.5. «Мәтіндегі экстремистік бағытты анықтау үшін веб-ресурстардағы семантикалық талдау модельдерін, алгоритмдерін құрастыру және кибер-криминалистика құрал-жабдықтарын әзірлеу» жобасы.....	22
2..... ВЕБ-РЕСУРСТАРДАҒЫ ЭКСТРЕМИСТІК МӘЛІМЕТТЕРДІ АНЫҚТАУДЫҢ СЕМАНТИКАЛЫҚ ҮЛГІСІН ҚҰРУҒА ҚАЖЕТТІ КОРПУС ҚҰРУ	23
2.1 Ашық көздерден ақпарат алу. Парсер бағдарламалары	23
2.2..... Экстремистік контентке қол жеткізу және оларды жинақтау әдістері	23
2.3 Экстремистік бағытты (ЭН) анықтау үшін веб-контентті жинауға және талдауға арналған бағдарламалық жабдықтама құрастыру	24
2.3.1 Мәліметтерді алуға дайындық кезеңі.....	24
2.3.2 Мәліметтерді жинау.....	26
2.3.3 Мәліметтерді жинау үшін парсер құрастыру	28
2.4 Веб-ресурстардағы экстремистік мәліметтерді анықтаудың семантикалық үлгісін құруға қажетті корпус құру	29
2.5 Корпус талдауы	30
2.6 Морфологиялық талдау жасауға арналған қосымша құру, кілттік сөздерді анықтау	31
2.6.1 Морфологиялық талдау жасау қосымшасын құрастыру мәселесі.....	31
2.6.2 Бастапқы мәліметтерді сипаттау.....	31
2.6.3 Кілттік сөздерді анықтау мәселесін сипаттау.....	34
3..... ВЕБ-РЕСУРСТАРДАҒЫ ЭКСТРЕМИСТІК МӘТІНДЕРДІ АНЫҚТАУҒА АРНАЛҒАН СЕМАНТИКАЛЫҚ ҮЛГІНІ ЗЕРТТЕУ ЖӘНЕ ҚҰРУ	36
3.1 Мәліметтерді алу және препроцессинг модулі.....	37

3.2 Белгілерді шығару және мәліметтерді белгілеу модулі.....	40
3.2.1 TF-IDF	41
3.2.2 n-грамдар.....	42
3.2.3 Bag-of-words.....	43
3.2.4 Word2vec	43
3.3 Терең оқыту үлгілері арқылы талдау жүргізу модулі.....	44
3.3.1 Терең оқыту үлгілері.....	44
3.3.2 Рекуррентті нейрондық желілер	45
3.4.1.1 LSTM желілері.....	46
.....	46
3.5 Ұсынылатын модель	47
3.5.1 Word Embedding Layer – Сөз ендіру қабаты.....	47
3.5.2 LSTM-Based Representation – Бейнелеу қабаты.	47
3.5.3 Үлгінің гиперпараметрлері.....	49
3.5.4 Үлгіні бағалау параметрлері	49
3.6 Эксперименталды бөлім	50
4..... МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІНЕ САЛЫСТЫРМАЛЫ ТАЛДАУ	60
.....	60
4.1 Тірек векторлар машинасы.....	61
4.2 Шешім ағашы	63
4.3 Кездейсоқ орман.....	65
4.4 k жақын көрші алгоритмі (k-Nearest Neighbors).....	66
4.5 Аңқау Байес классификаторы	68
4.6 Логистикалық регрессия.....	70
4.7 Градиентті бустинг.....	72
ҚОРЫТЫНДЫ.....	75
ҚОСЫМША А.....	84
ҚОСЫМША В.....	86
ҚОСЫМША С.....	92
ҚОСЫМША D.....	94

НОРМАТИВТІ СІЛТЕМЕЛЕР

Бұл диссертацияда келесі стандарттарға сәйкес сілтемелер қолданылды:

1. «Диссертацияларды және авторефераттарды рәсімдеу бойынша нұсқаулық», ҚР БҒМ, Жоғары аттестаттау комитеті, Алматы, 2004
2. ГОСТ 7.32-2001 – Ғылыми-зерттеу жұмысының есебі

БЕЛГІЛЕУЛЕР МЕН ҚЫСҚАРТУЛАР

ЭБ – Экстремистік бағыт

RNN – Recurrent neural network

LSTM – Long short-term memory

КІРІСПЕ

Зерттеу тақырыбының өзектілігі. Қазіргі таңда ақпараттық-коммуникациялық Интернет желісі адамзат өмірінің ажырамас бөлігіне айналды. Адамдар «Твиттер», «ВКонтакте», «Facebook» және т.с.с. әлеуметтік желілерді жаһандық байланыс орнату, пікір алмасу, білім алу және т.б. мақсаттарда пайдалануда. Жеке пайдаланушылардың ғана емес, сонымен қатар ақпараттық ұйымдардың да бүкіл әлемдік кеңістікке белсенді қатысуы ұлттық қауіпсіздікті қамтамасыз ету бойынша ақпараттық-коммуникациялық технологиялар дамуының қазіргі тенденцияларына сәйкес келетін іс-шараларды әзірлеу, атап айтқанда экстремизм мен терроризм идеяларының күшеюіне қарсы тұруға қатысты іс-шараларды ұйымдастыру қажеттілігін анықтайды. Экстремистік ұйымдар жаңа ақпараттық технологияларды қолдана отырып желіде топқа жаңа мүшелер тарту, экстремистік іс-әрекеттерді жоспарлау мен орындау, оқыту жұмыстарын жүргізу, әлеуметке қауіпті әрекеттерді басқару мен координациялауда жасырын ақпарат алмасу, экстремистік іс-әрекеттерді орындау үшін қаржыландыру көздерін іздеу, қолданушыларға, соның ішінде жастарға мақсатты түрде идеологиялық насихат жүргізу мақсатында жабық сайттар құру және т.б. әрекеттерді ұтымды орындауда [1-2]. Мәселе дүниежүзілік сипатқа ие және жаһандық саяси процестің негізгі қатысушыларының бірі ретінде Қазақстан Республикасы үшін де өте өзекті болып табылады.

Интернет ақпараттық кеңістігі әр түрлі ресурстардан тұрады. Сонымен бірге олардың басым көпшілігі бұқаралық ақпарат құралдары болып табылмайды, нәтижесінде бұқаралық ақпарат құралдары туралы заңнаманың нормаларын қолдану мүмкін болмайды. Экстремизм идеяларының таралуына қарсы тұру үшін қазіргі уақытта құқық қорғау органдары қылмыстық заңнаманың «Экстремизмге қарсы іс-қимыл туралы Қазақстан Республикасының 2005 жылғы 18 ақпандағы N 31 Заңы» [3] нормасы, «Қазақстан Республикасында діни экстремизм мен терроризмге қарсы іс-қимыл жөніндегі 2018 – 2022 жылдарға арналған мемлекеттік бағдарламаны бекіту туралы», Қазақстан Республикасы Үкіметінің 2018 жылғы 15 наурыздағы № 124 қаулысы [4] пайдаланылады.

Қазіргі таңда Қазақстан аумағында тыйым салынған террористік құрылымдардың ұлттық тізіміне 22 ұйым енгізілген [5].

2020 жылдың қарашасында ҚР президенті Қ.К.Тоқаев ШЫҰ-ға мүше мемлекеттерді сепаратизм, терроризм мен экстремизммен күреске бағытталған Ақпараттық қауіпсіздік орталығын құруға шақырды [6].

Өкінішке орай, соңғы жылдары қазақстандықтар да экстремистік ұйымдардың қатарына қосылуда. Ұлттық қауіпсіздік комитетінің (ҰҚК) дерегі бойынша, Сирия мен Иракта соғыс басталғалы Таяу Шығысқа 800-ге жуық Қазақстан азаматы кеткен. Олардың көбі – балалар. 2018 жылғы шілдедегі жағдай бойынша, Сирия мен Ирактағы халықаралық террористік ұйымдарда қазақстандық 120 ер адам, 250-ден астам әйел және 500 кәмелетке толмаған бала бар [7].

Елбасы Нұрсұлтан Назарбаевтың тапсырмасымен 2019 жыл қаңтар айынан бастап "Жусан" операциясы аясында Сирия мен Ирак аумағындағы азаматтарын қайтарыла бастады. Комитеттің 2019 жылғы қарашадағы жауабында Сирия мен Ирактан Қазақстанға 277 ересек (57 ер адам, 220 әйел адам) мен 547 кәмелетке жасы толмаған баланың қайтарылғаны, Сирияда әлі 90-нан астам азаматтың бары айтылған [8].

Аталған мәселелерді Қазақстан Республикасының ұлттық қауіпсіздігіне төнетін қатер ретінде қарастыруға болады. Интернеттегі экстремистік іс-әрекеттерге қарсы іс-қимыл саласындағы ахуал күрделі болып қала береді, бұл ғылыми зерттеулер жүргізуді және экстремизмнің кез-келген көріністерін анықтауға, алдын алуға және жолын кесуге бағытталған тиімді және уақытылы шаралар кешенін жүзеге асыруды қажет етеді.

Google, Facebook және Twitter алпауыттары интернеттегі террористік мазмұнды жылдам анықтап, жою үшін жасанды интеллект (AI) технологиясын қолдануға уәде берді [9]. IBM-де жоғарыда аталған әлеуметтік желілердегі барлық деректерді талдай алатын Watson әзірлемесі бар [10]. Ресейде Платонның IT-авторы әлеуметтік желілерді бақылау

және қауіп-қатерлерді болжау жүйесін құруда [11]. Германия үкіметі террористік актілерден кейін Интернеттегі террористермен күресу үшін ZITiS атты жаңа киберқауіпсіздік бөлімшесі құрылғанын жариялады [12]. Мұндай жүйелер әзірге Қазақстанда жоқ. Осы себепті Интернеттегі веб-ресурстарға талдау жүргізу, экстремистік мазмұндағы мәтіндерді уақытылы анықтауды автоматтандыру экстремизмге қарсы күрес ұйымдары үшін аса өзекті болып табылады.

Әлеуметтік желілердің дамуы зорлық-зомбылықты жақтаушы, экстремизм мен радикализмді насихаттаушы топтардың жылдам таралуына әсер етуде. Микроблог сайттары, әлеуметтік желі топтарындағы экстремистік мазмұнды анықтауға арналған жұмыстар күрделі және дамып келе жатқан зерттеу саласы болып табылады. Экстремизм мәселесі XX ғасырдан бастап бүгінгі күнге дейін отандық және шетелдік ғылыми әдебиеттерде зерттелуде. Бүгінгі таңда экстремизм әртүрлі зерттеулердің объектісі болып табылады.

Қазіргі таңда веб-ресурстардағы экстремистік мәтіндерді анықтауға қатысты жұмыстардың басым көпшілігі ағылшын тілі үшін жазылған [13-31]. Ғалымдар веб-ресурстардағы экстремистік бағыттарды анықтау үшін машиналық және терең оқыту әдістерін тиімді пайдалануда [32-46]. Соңғы уақытта веб-ресурстарда неміс [47], орыс [48-52], араб [53-57] тілдерінде жазылған экстремистік мазмұнды қамтитын мәтіндерді анықтауға арналған әр түрлі жүйелер құрылу үстінде. [58-65] жұмыстарда әлеуметтік желі мен микроблогтардан анықталған экстремистік мәтіндердің лингвистикалық ерекшеліктерін анықтауға қатысты зерттеулер жүргізілген, сәйкесінше [66-67] жұмыстар экстремистік мәтіндердің психологиялық тұстарын зерттеуге арналған. [68-71] жұмыстарда веб-ресурстардағы экстремистік мәтіндерді анықтауды сентимент талдау есебі ретінде қарастыру арқылы шешу ұсынылады. [1,72-76] жұмыстарда әлеуметтік желі топтарындағы экстремистік мәтіндерді анықтауға қатысты зерттеулерге шолу келтіріледі. Веб-ресурстардағы экстремистік мәтіндерді стилометриялық құралдар арқылы анықтауға болатындығы [77] жұмыста келтірілген.

Интернеттегі деректер көлемінің экспоненциалды өсуі деректерді жинаудың басқарылатын әдістерін жасау қажеттілігін тудырады. Экстремистік веб-сайттардан деректерді жинау үшін автоматты веб-шолғышты құруға қатысты зерттеулер [78-82] жұмыстарда қарастырылады.

Сонымен қатар, экстремизмді зерттеуші сарапшылар жаһандық коронавирустық пандемия салдарынан Интернетте көп уақыт отыруға мәжбүр болған азаматтардың экстремистік ұйымдар үшін осал тұс екенін көрсетеді және аталған факторлардың үйлесуі зорлық-зомбылық экстремизмі мен терроризмнің өсуіне әкеледі деп болжам жасайды [83-85].

Қазақ тілі үшін қылмыстық сипаттағы мәтіндерді анықтауға және талдауға арналған бірқатар ғылыми зерттеулер жүргізілген. Атап айтатын болсақ, Шәріпбай А.Ә. бастауымен Л.Н. Гумилев атындағы ЕҰУ жанындағы «Жасанды интеллект» ғылыми-зерттеу институтының ғалымдарының, Мамырбаев Ө.Ж. еңбектерін келтіруге болады. [86] жұмыста террористік қауіптерге байланысты қазақ тіліндегі мәтіндердің көңіл-күйін талдау үшін сөздікті қолдана отырып, ережеге негізделген әдісті сипаттайды. Онда полярлықты талдау әдістеріне шолу, деректер базасындағы кілт сөздердің мазмұны бойынша беттерді талдайтын парсер, қазақ тіліндегі мәтіндерге морфологиялық, синтаксистік және сентименталды талдау ұсынылған. Ақпараттық қауіпсіздікті қамтамасыз ету, мониторинг және қауіптердің алдын алу кезінде әлеуметтік желілердің пайдаланушысын сәйкестендіруге арналған бағдарламалық кешенді әзірлеу үшін пайдаланылатын онтологиялық білім базасы құрастырылған [87].

[88] жұмыста web-контенттің қылмыстық боялған мәтіндік ақпаратының түрлері (киберқылмыс, террористік акт немесе қаржылық алаяқтық) қарастырылады және мәтіндердегі құқыққа қарсы ақпаратты анықтауға мүмкіндік беретін қолданыстағы лингвистикалық талдау технологиялары талданады. Қазақ тіліндегі мәтіндердегі

қылмыстық мәнді атаулы коллакцияларды анықтаудың екі кезеңдік әдісі ұсынылады. Қарастырылатын әдіс атаулы сөзтіркестердің әлсіз құрылымдалған мәтіндердегі автоматты танып ерекшелеудің логикалық-лингвистикалық моделін және коллакцияларды анықтау дәлдігін арттыруға арналған сөз тіркестерінің сөздерінің қисындылығын айырудың ықтималды моделін құрайды [89].

Жоғарыда келтірілген тұжырымдарты ескере отырып, веб-ресурстардағы қазақ тіліндегі экстремистік бағыттағы мәтіндерді анықтауға арналған үлгілерді құру тапсырмасы **аса өзекті** деген қорытындыға келуге болады.

Диссертациялық жұмыстың мақсаты – веб ресурстардағы экстремистік мазмұнды анықтау үшін мәліметтерді семантикалық талдау үлгілерін, алгоритмдерін кешенді зерттеу және құру.

Зерттеудің міндеттері. Қойылған мақсатқа қол жеткізу үшін келесі міндеттерді орындау қарастырылады:

1. Интернет желісіндегі экстремистік бағыттағы мәтіндерді анықтауға арналған қолдағы бар жүйелерге шолу жасау;
2. Машиналық оқыту әдістерін оқытуға қажетті қазақ тіліндегі экстремистік мәтіндер корпусын құрастыру;
3. Веб-ресурстардағы қазақ тіліндегі экстремистік бағыттағы мәтіндерді анықтауға арналған семантикалық талдау моделін құру;
4. Веб-ресурстардағы қазақ тіліндегі экстремистік бағыттағы мәтіндерді анықтауға арналған әдістерді құру;
5. Қазақ тіліндегі экстремистік кілт сөздердің мәліметтер қорын құру;
6. Құрастырылған үлгілер мен алгоритмдер негізінде веб-ресурстардағы экстремистік бағыттағы мәтіндерді анықтайтын жүйе құрастыру және оны тестілеу.

Зерттеу нысаны. Веб-ресурстардағы экстремистік бағыттағы мәтіндерді анықтау.

Зерттеу пәні. Веб-ресурстардағы экстремистік бағыттағы мәтіндерді анықтауға арналған машиналық және терең оқыту әдістері

Зерттеу әдісі. Зерттеу әдісі ретінде машиналық және терең оқыту әдістері, мәтіндерді жіктеу әдістері, табиғи тілді өңдеу әдістері, нейрондық желілер, әлеуметтік желілерді талдау әдістері, статистикалық өңдеу әдістері, жүйелік талдау әдістері қолданыс тапты.

Алынған нәтижелердің ғылыми жаңалығы:

1. Алғаш рет қазақ тіліндегі экстремистік мәтіндерді анықтау үшін машиналық оқыту әдістерін оқыту және тестілеу үшін қазақ тіліндегі мәтіндер корпусы құрылды;
2. Алғаш рет қазақ тілінің ерекшеліктеріне бейімделу есебінен веб-ресурстардағы экстремистік мәтіндерді анықтаудың тиімділігін арттыруға мүмкіндік беретін семантикалық талдау моделі жасалды
3. Қазақ тіліндегі экстремистік мәтіндерді анықтаудың тиімділігін арттыру әдісі жасалды
4. Алғаш рет қазақ тілінде экстремистік түйінді сөздердің деректер базасы құрылды;
5. Өзірленген әдістер мен модельдер негізінде веб-ресурстардағы экстремистік мәтіндерді анықтайтын жүйе жасалды.

Жұмыстың теориялық маңыздылығы. Диссертациялық жұмыстың теориялық маңыздылығы экстремистік іс-әрекеттер мен ұйымдарды анықтау әдістері мен алгоритмдері саласындағы білім жиынтығына негізделген. Алынған іргелі нәтижелерді әлемдік ғылыми қауымдастық пайдалана алады.

Жұмыстың практикалық маңызыдылығы. Әдіснама, алгоритмдер, авторлық куәлік түріндегі қолданбалы нәтижелерді ақпараттық қауіпсіздікті, сыни инфрақұрылымды қамтамасыз ету, интернет-экстремизммен күрес жөніндегі уәкілетті органдар пайдалануы мүмкін.

Қорғауға шығарылатын негізгі тұжырым. LSTM үлгісінде мәтін ендірудің TF-IDF және биграмм белгілерімен қатар стемминг алгоритмін қолдану веб-ресурстардағы қазақ тіліндегі экстремистік мәтіндерді анықтау тапсырмасының дәлдігін арттырады.

Сенімділік дәрежесі мен апробациялау нәтижелері. Зерттеудің сенімділігі мен нәтижелерінің негізділігі міндеттерді қоюдың негізделген жауапкершілігімен, критерийлердің және берілген саладағы зерттеулердің жай-күйінің сарапталуымен, жүргізілген эксперименттер санының көптігімен, сондай-ақ олардың практикаға табысты енгізілуімен қамтамасыз етіліп дәйектеледі. Диссертация нәтижелері төмендегі ғылыми-әдістемелік конференцияларда баяндалып, талқыланды:

1. Mussiraliyeva Sh., Bolatbek M., Omarov B., Bagitova K. Detection Of Extremist Ideation On Social Media Using Machine Learning Techniques // 12th International Conference on Computational Collective Intelligence. – Vietnam, 2020. – P.743-752, https://doi.org/10.1007/978-3-030-63007-2_58
2. Mussiraliyeva Sh., Bolatbek M., Omarov B., Medetbek Zh., Baispay G., Ospanov R. On Detecting Online Radicalization and Extremism Using Natural Language Processing // 21st International Arab Conference on Information Technology (ACIT'2020). – Egypt, 2020, DOI: 10.1109/ACIT50332.2020.9300086
3. Mussiraliyeva Sh., Omarov B., Bolatbek M., Ospanov R., Baispay G., Medetbek Zh., Yeltay Zh. Applying Deep Learning for Extremism Detection // International Conference on Advanced Informatics for Computing Research. – Singapore, 2021. – P.597-605. https://doi.org/10.1007/978-981-16-3660-8_56
4. Mussiraliyeva Sh., Bolatbek M., Omarov B., Bagitova K., Alimzhanova Zh. Bigram based Deep Neural Network for Extremism Detection in Online User Generated Contents in the Kazakh Language // International Conference on Computational Collective Intelligence. – Greece, 2021. – P.559-570. https://doi.org/10.1007/978-3-030-88113-9_45
5. Болатбек М.А., Создание словаря экстремистских слов для казахского языка, Международная научная конференция студентов и молодых ученых «ФАРАБИ ӘЛЕМІ», Казахстан, Алматы, 2018
6. Мусиралиева Ш.Ж., Болатбек М.А., Әлеуметтік желідегі экстремистік мәтіндерді жіктеу дәлдігін грамматикалық қателерді анықтау және түзету арқылы арттыру, Международная научно-практическая конференция "Актуальные проблемы информационной безопасности в Казахстане», 2020
7. Болатбек М.А., Экстремизм түсінігі. Экстремистік мәтіндерді анықтауға арналған белгілер жинағына шолу, Международная научная конференция студентов и молодых ученых «ФАРАБИ ӘЛЕМІ», Казахстан, Алматы, 2020
8. Болатбек М.А., Экстремистік мәтіндерді сентимент талдау арқылы анықтау, Международная научная конференция студентов и молодых ученых «ФАРАБИ ӘЛЕМІ», Казахстан, Алматы, 2020
9. Байдулла А.М., Мусиралиева Ш.Ж., Болатбек М.А. Экстремистік топтарды анықтау және талдау // Матер. Междунар. научн. конф. студентов и молодых ученых «Фараби әлемі». – Алматы: Қазақ университеті, 2021. – С. 74.
10. Мусиралиева Ш.Ж., Болатбек М.А. Веб-ресурстардағы экстремистік мәтіндерді анықтаудың семантикалық үлгілерін құру және зерттеу // Матер. Междунар. научн. конф. студентов и молодых ученых «Фараби әлемі». – Алматы: Қазақ университеті, 2021. – С. 77.
11. Маден М.Т., Мусиралиева Ш.Ж., Болатбек М.А. Онлайн ортада экстремизмнің лингвистикалық маркерлерін анықтау // Матер. Междунар. научн. конф. студентов и молодых ученых «Фараби әлемі». – Алматы: Қазақ университеті, 2021. – С. 101.
12. Шәріпбекова С.Е., Мусиралиева Ш.Ж., Болатбек М.А. Қазақ тіліндегі оң қанатты экстремизмді анықтау үшін веб-контентті жинауға арналған

бағдарламалық модуль әзірлеу // Матер. Междунар. научн. конф. студентов и молодых ученых «Фараби әлемі». – Алматы: Қазақ университеті, 2021. – С. 118.

13. Ынтықбай Б.Н., Мусиралиева Ш.Ж., Болатбек М.А. Әлеуметтік желілердегі қауіпсіздік пен конфиденциалдықты машиналық оқыту тәсілдерін қолдану арқылы талдау // Матер. Междунар. научн. конф. студентов и молодых ученых «Фараби әлемі». – Алматы: Қазақ университеті, 2021. – С. 119.

14. Мусиралиева Ш.Ж., Омаров Б.С., Болатбек М.А., Жастай Е. Веб-ресурстардағы қазақ тіліндегі экстремисттік сипаттағы мәтіндерді анықтау // Матер. Междунар. научн. конф. в области информационных технологий, посвященной 75-летию профессора У.А.Тукеева. – Алматы, 2021. – С. 98-104.

Зерттеушінің жеке үлесі. Ізденуші диссертациялық жұмыстың қойылған міндеттерін шешті. Веб-ресурстардағы қазақ тіліндегі экстремистік бағыттағы мәтіндерді анықтаудың семантикалық үлгісі мен алгоритмдері әзірленді. Машиналық оқыту алгоритмдерін оқыту мен тестілеуге арналған қазақ тіліндегі экстремистік мәтіндер корпусы құрастырылды. Әзірленген үлгі мен алгоритмдердің тиімділігін анықтау мақсатында эксперименттер жүргізілді. Қазақ тіліндегі экстремистік кілттік сөздер тізімі құрылды.

Диссертация тақырыбының ғылыми-зерттеу жұмыстарының жоспарларымен байланысы. Берілген жұмыс Қазақстан Республикасының Цифрлық даму, инновациялар және аэроғарыш өнеркәсібі министрлігінің тапсырысы бойынша «Мәтіндегі экстремистік бағытты анықтау үшін веб-ресурстардағы семантикалық талдау модельдерін, алгоритмдерін құрастыру және кибер-криминалистика құрал-жабдықтарын әзірлеу» жобасы аясында жазылды, ЖТН АР06851248.

Нәтиженің жарияланымдары. Диссертация тақырыбы бойынша алынған нәтижелер бес баспалық жұмыста жарияланды. Оның ішінде халықаралық реферативтік мәліметтер қорына енетін басылымдарда жарияланған мақала:

1. Mussiraliyeva Sh., Omarov B., Yoo P., Bolatbek M. Applying Machine Learning Techniques for Religious Extremism Detection on Online User Contents // CMC – Computers, Materials & Continua. – 2021. – Vol. 70. No. 1. P. 915–934. ISSN:1546-2226 (квартиль **Q1**, SJR 2020 0.79-ға тең) <https://doi:10.32604/cmc.2022.019189>

Қазақстан Республикасы Білім және ғылым министрлігі Білім және ғылым саласындағы бақылау комитеті ұсынатын журналдардағы мақалалар:

1. Bolatbek M.A., Mussiraliyeva Sh.Zh., Tukeyev U.A., Creating the dataset of keywords for detecting an extremist orientation in web-resources in the Kazakh language, Al-Farabi Kazakh National University, Journal of Mathematics, Mechanics and Computer Science, No 1 (97), pp.134-142, 2018
2. М.А. Болатбек, Ш.Ж. Мусиралиева, Экстремистік мәтіндерді машиналық оқыту әдістері арқылы анықтау, Вестник КазННТУ №6 (130), 300-304 б., 2018
3. К. Шалабаев, К. Әліпбай, М. Болатбек, Ш. Мусиралиева, Вконтакте әлеуметтік желісіндегі экстремистік мәтіндерді анықтау және жіктеу, Вестник КазННТУ №5 (135), 80-86 б., 2019
4. Мусиралиева Ш.Ж., Болатбек М.А., Зият Б.М., Стемминг алгоритмі арқылы экстремистік мәтіндерді жіктеу дәлдігін арттыру, Вестник КазННТУ, №6, 2020 ж.

Диссертация құрылымы және көлемі. Диссертациялық жұмыс кіріспеден, ... тараудан және қорытындыдан тұрады. Диссертацияның толық көлемі: 97 бет, ... сурет, ... кесте. Әдебиеттер тізімі 122 атаудан тұрады.

1. ЭКСТРЕМИСТІК МӘЛІМЕТТЕР ТҮСІНІГІ ЖӘНЕ ЕСЕПТІҢ ҚОЙЫЛЫМЫ

1.1 Экстремистік мәліметтер түсінігі

Жаһандық желіде агрессивті ақпараттың таралуына қарсы тұру қоғам мен мемлекеттік органдардың өзекті мәселесі болып табылады, аталған тапсырма интернеттің қажетсіз ресурстарын сүзу арқылы шешіледі.

XXI ғасыр технологиялары интернеттегі ақпаратты пайдалануды кеңейткенімен, мәтіндік деректер интернеттегі мазмұнның ең көп таралған түрі болып табылады. Алайда, террористік және экстремистік топтар ақпарат тарату, насихаттау, қаражат жинау және экстремистік миссияларын қоса алғанда, әртүрлі функцияларды орындау үшін веб-технологияларды ұтымды пайдалануда. Мұндай жағдайда интернет ұлттық қауіпсіздікке қауіп-қатер төндіреді.

Интернет экстремистік материалдарды орналастыру үшін белсенді қолданылып келеді. Проблема жалпы әлемдік сипатқа ие және әлемдік саяси процестің басты қатысушыларының бірі ретінде Қазақстан Республикасы үшін өте өзекті. Интернеттің ғаламдық желісін және компьютерлік байланыс мүмкіндіктерін қолдана отырып, экстремистік қозғалыстар мен топтардың идеологтары азаматтардың, ең алдымен жастардың санасына белсенді әсер етеді.

Экстремистер бүгінде қылмыстық іс-әрекетте Интернет желісінің шын мәнінде шексіз мүмкіндіктерін белсенді пайдаланады, оның ішінде: қылмыстарды дайындау және жасау кезінде Интернет желісінің ресурстарын пайдалану; әлеуметтік қауіпті әрекеттерді басқару және ұйымдастыру мақсатында ақпаратпен жасырын алмасу; экстремистік қызметті қаржыландыру үшін иесіздендірілген қаржылық желілік құралдарды қолдану, мысалы Darkcoin төлем жүйелері; арнайы құрылған сайттарда және басқа интернет-ресурстарда белсенді насихаттау үшін жоспарланған ақпараттық операцияларды жүзеге асыру және т.б. нәтижесінде соңғы жылдары экстремизм проблемасы шиеленісе түсуде, ол қазіргі уақытта жалпы мемлекеттік маңызы бар проблема және Қазақстанның ұлттық қауіпсіздігіне қатер ретінде қаралуда. Осылайша, интернет желісін пайдалана отырып, экстремистік көріністерге қарсы іс-қимыл саласындағы ахуал күрделі болып қалуда, бұл, атап айтқанда, экстремизмнің кез келген көріністерін анықтауға, олардың алдын алуға және жолын кесуге бағытталған ғылыми зерттеулерді жүзеге асыру және тиімді әрі уақтылы шаралар кешенін іске асыру қажеттілігін негіздейді.

Экстремизм құбылысы өте серпінді дамып, күн сайын жаңа белгілер мен сипаттамаларға ие болуда. Қазіргі уақытта үгіт-насихат пен экстремистік идеологияның әсерінен террористердің, сондай-ақ желілік және әлсіз байланысқан құрылымы бар ұйымдасқан террористік қауымдастықтардың, террористік шабуылдарының саны артып келеді. Ақпарат алмасудың және осындай құрылымдарды жылжытудың негізгі құралы – интернет, атап айтқанда веб-ресурстар, әлеуметтік желілер және электрондық пошта. Осыған байланысты интернет желісінде террористік және экстремистік ақпаратты генерациялайтын және тарататын жекелеген пайдаланушылардан, топтардан және желілік қоғамдастықтардан туындайтын қатерлерді анықтау, қарым-қатынас тақырыптарын, байланыстарды айқындау, сондай-ақ мінез-құлық мониторингі және болжау міндеті туындайды.

Қазіргі уақытта экстремистік әрекетке қарсы күрес Қазақстан Республикасының аумағында да, одан тыс жерлерде де болып жатқан оқиғалармен анықталған құқық қорғау органдарының басым міндеттерінің бірі болып табылады. Дегенмен, шамамен 15-20 жыл бұрын экстремистік топтар мен қозғалыстардың қызметі қаланың, облыстың немесе ауданның кеңістіктік шекараларымен оқшауланды, ал қазір интернеттің арқасында экстремизм әлем елдерінің ақпараттық күн тәртібінде ауқымды элементке айналууда.

Экстремистік қозғалыстардың мүшелері пікірталастарға қатысуға, олардың идеологиясы мен мүдделерін әртүрлі интернет-ресурстарда қорғауға мүмкіндік алды, онда адамдар саны өте көп және бірнеше ондағаннан жүздеген мың адамға дейін жетеді.

Шетелдік зерттеулерден алынған мәліметтерге сүйене отырып, интернет желісінде он мыңға жуық экстремистік электрондық көздер бар екендігін анық айтуға болады [90]. Бұл жүйенің негізін араб тіліндегі сайттар құрайды, олардың саны шамамен екі-үш мың. Экстремистік желі интернет арқылы насихаттауды таратудың тиімді әдісін жасады. Бұл сайттарға кірушілер экстремистік сипаттағы материалдарды көшіреді, сондай-ақ оларға сілтемелер жасайды, оларды экстремистік және экстремистік емес бағыттағы басқа сайттарға таратады. Деструктивті күштердің қызметін уақтылы анықтауға және жолын кесуге мүмкіндік беретін құралдардың бірі интернеттің ақпараттық ресурстарына мақсатты мониторинг жүргізу болуы тиіс.

Экстремизм (фр. *extrémisme*, лат. *extremus* – төтенше) – бұл қоғамдағы нормалар мен ережелерді түбегейлі жоққа шығаратын экстремалды көзқарастар мен іс-әрекеттерді ұстану. Экстремизмнің негізі – қандай да бір идеялық мазмұнмен және мағынамен толтырылған агрессивтілік. Экстремизмді әр түрлі әлеуметтік немесе мүліктік жағдайы, ұлттық және діни құрамы, кәсіби және жоғары білім деңгейі бар және т.б. бар адамдар жүзеге асыра алады. Қазіргі таңда жастардың экстремистік мінез-құлқының өзіндік ерекшелігі бар: ұлттық, діни және саяси себептермен зорлық-зомбылық жасау.

Экстремизм ауқымдылығы бойынша келесідей ерекшеленеді: жеке индивидтің экстремистік көріністері; шағын топтардың (100 адамға дейін) және ірі топтардың (100 адамнан астам) экстремистік көріністері; мемлекеттер мен ұлтаралық бірлестіктердің саясатындағы экстремистік көріністер.

Экстремизмнің түрлері ортақ белгілермен сипатталады:

- зорлық-зомбылық немесе оның қауіп-қатері (әдетте қарулы күшпен);
- бір өлшемділік, әлеуметтік мәселелерді біржақтылық, сондай-ақ оларды шешу жолдарын іздеу;
- өз принциптері мен көзқарастарын қарсыластарға тануға деген ұмтылыс;
- кез-келген бұйрықтар мен нұсқауларды сөзсіз орындау;
- сезімдер мен инстинкттерге сүйену, бірақ ақылға емес;
- толеранттылыққа, ымыраға келуге немесе оларды толығымен елемегеуге қабілетсіздік.

Экстремизм шектен тыс радикализммен, терроризммен және нигилизммен ұштасады. Экстремизмнің себептері азаматтардың бір бөлігінің әлеуметтік бағдарлануында, тиісті білімнің болмауында, қоғамның дағдарыстық жағдайында, сондай-ақ құқықтық жүйенің тиімсіздігінде жатыр. Экстремизм саяси, экономикалық, әлеуметтік, діни және қоғамдық өмірдің басқа салаларында жиі кездеседі.

Экстремизм – бұл:

- адам мен азаматтың құқықтары мен еркіндігіне қол сұғу, адамдардың наным-сенімдері, нәсілдік немесе ұлттық тиістілігіне, дініне, әлеуметтік жағдайы немесе әлеуметтік шығу тегіне байланысты олардың денсаулығы мен мүлкіне зиян келтіру;
- рұқсат етілмеген баспа, аудио-аудиовизуалды және басқа да материалдарды құру және тарату;
- мемлекеттік немесе қоғамдық қызметкерге оның мемлекеттік немесе басқа да саяси қызметін тоқтату мақсатында немесе кек алу мақсатында шабуыл жасау;
- ҚР конституциялық құрамы мен тұтастылығын күштеп өзгерту;
- Терроризмді ашық түрде қолдау немесе террористік іс-әрекетті орындау;
- Әлеуметтік, нәсілдік, ұлттық немесе діни дауды тудыру;
- Саяси, идеологиялық, нәсілдік, ұлттық немесе діни жеккөрушілік немесе қандай да бір әлеуметтік топқа қарсыласу мотивтері бойынша қылмыс жасау;
- адамның әлеуметтік, нәсілдік, ұлттық, діни немесе тілдік қатыстылығы немесе дінге көзқарасы негізінде оның айрықшалығын, артықшылығын немесе кемтарлығын насихаттау;

- азаматтардың өздерінің сайлау құқықтарын және референдумға қатысу құқықтарын жүзеге асыруына кедергі келтіру немесе зорлық-зомбылықпен не оны қолдану қатерімен ұштасқан дауыс беру құпиясын бұзу;

- мемлекеттік органдардың, жергілікті өзін-өзі басқару органдарының, сайлау комиссияларының, қоғамдық және діни бірлестіктердің немесе өзге де ұйымдардың зорлық-зомбылықпен не оны қолдану қатерімен ұштасқан заңды қызметіне кедергі жасау;

- нацистік атрибутиканы немесе символизмді, нацистік атрибутикаға немесе символизмге ұқсас атрибутиканы немесе символизмді араластыру деңгейіне дейін насихаттау және көпшілікке көрсету немесе экстремистік ұйымдардың атрибуттарын немесе символикасын көпшілікке көрсету;

- көрсетілген іс-әрекеттерді жүзеге асыруға жария түрде шақыру не көрінеу экстремистік материалдарды жаппай тарату, сол сияқты оларды жаппай тарату мақсатында дайындау немесе сақтау;

- ҚР мемлекеттік лауазымын немесе ҚР субъектісінің мемлекеттік лауазымын атқаратын адамды өзінің лауазымдық міндеттерін атқару кезеңінде осы бапта көрсетілген және қылмыс болып табылатын іс-әрекеттер жасады деп көрінеу жалған айыптау;

- көрсетілген іс-әрекеттерді ұйымдастыру және дайындау, сондай-ақ оларды жүзеге асыруға арандату;

- көрсетілген іс-әрекеттерді қаржыландыру не оларды ұйымдастыруға, дайындауға және жүзеге асыруға, оның ішінде оқу, полиграфиялық және материалдық-техникалық базаны, телефондық және байланыстың өзге де түрлерін ұсыну немесе ақпараттық қызметтер көрсету жолымен өзге де жәрдемдесу[91].

1.2 Экстремизмнің жіктелуі

Экстремистік көріністердің қолдану саласының сипаты бойынша келесі жіктелуін бөліп көрсетуге болады: саяси сипатта; экономикалық сипатта; діни сипатта және психологиялық сипатта.

Ең үлкен қауіп – саяси экстремизм. Бұл жағдайда «оң» және «сол» экстремизм ерекшеленеді. Солшыл экстремизмнің негізі – анархизмнің революциялық идеялары, өзін ең дәйекті экспрессор және жұмысшы бұқараның, барлық аз қамтылған және кедей адамдардың қорғаушысы ретінде анықтайды. Оңшыл экстремизмге (фашистік, неофашистік, ультра оңшыл, ұлтшыл, нәсілшіл қозғалыстар, ұйымдар мен партиялар) келетін болсақ, ол халықаралық деңгейде ұйымшылдық пен үйлесімділіктің жоғары деңгейімен сипатталады.

Діни экстремизм конфессиялық принцип бойынша тәуелсіз теократиялық мемлекет немесе аумақтық автономия құруға арналған діни ұстанымдармен алдын ала анықталады.

Ұлттық экстремизм әдетте саяси экстремизмнің және діни экстремизмнің элементтерімен сипатталады. Алайда, саяси экстремизм таза діни идеяны болмаса да, жалған діни идеяны жүзеге асырады. Осылайша, кез-келген экстремистік қозғалыс өзара байланысты және әр нақты жағдайда күшті немесе әлсіз көрінетін әртүрлі элементтерді қамтиды [92].

1-кесте. Экстремизмнің негізгі түрлері

	Экстремизм түрі	Экстремизмнің берілген түрінің негізгі түсінігі
	Сепаратизм	Мемлекеттің бір бөлігін бөліп алып, оны жаңа тәуелсіз мемлекетке немесе автономды бөлікке айналдыруға ұмтылу
	Ксенофобия	Басқа мәдениет, ұлт, мемлекет өкілдеріне деген төзімсіздік
	Ұлтшылдық	Белгілі бір ұлттың артық екендігін айтуға негізделетін идеология, саяси көзқарастар жүйесі

	Шовинизм	Басқа ұлт өкілдерін кемсіту, эксплуатациялау және дискриминациялау мақсатында қандай да бір басқа ұлттық артықшылығын насихаттайтын идеология
	Расизм/нәсілшілдік	Әр түрлі нәсілдердің физикалық және психикалық кемелденбегенін насихаттайтын идеология. Халықты «жоғарыдағылар» және «төмендегілер», «кемелденгендер» мен «кемелденбегендер» деген сияқты топтарға жіктеу, нәсілдік тиістілікке байланысты нәсілдік дискриминация, ұлт геноциді үшін пайдаланылады.
	Фашизм	Әскери расизм, «басқа» ұлттық және әлеуметтік топтарға ксенофобиядан басталып, геноцидке, мистикалық дұшпандыққа, тоталитарлық мемлекетке табынуға ауысатын әлеуметтік-саяси қозғалыстардың жалпы атауы.
	Терроризм	Тек зорлық-зомбылық құралдарын қолдану арқылы орындалатын саясат.

Сонымен экстремизмді келесідей топтарға жіктеп көрсетуге болады, бағыты бойынша:

- экономикалық (бір ғана меншік түрін орнату, бәсекелестікті болдырмау және т.б.);
- рухани (басқа мәдениет өкілдерінің жетістіктерін теріске шығару);
- экологиялық (табиғатты қорғау саясатына қарсы шығу);
- діни (басқа конфессия өкілдеріне деген жеккөрушілік);
- ұлттық (басқа ұлттардың қызығушылықтары мен құқықтарын теріске шығару);
- саяси (үкіметтік құрылымдар, мемлекеттік қызметтерге қарсы шығу).

Іс-әрекеттердің масштабына байланысты:

- мемлекетшілік (өз ұлтына репрессия жасау);
- мемлекетаралық (өз нормалары мен принциптерін әлемдік масштабға орнатуға тырысу).

Өкілетті құрылымдарға байланысты:

- мемлекеттік (репрессияның өкілетті құрылымдары арқылы орындалады);
- мемлекетке оппозициялық (антирежимдік топтар; теракттар).

1.3 Жаһандық экстремистік ресурстар


Экстремизмге қарсы тұру және оның алдын-алу мемлекеттік және жергілікті құқық қорғау органдарының басты міндеті болып табылады. Экстремистер – бұл саяси, әлеуметтік немесе діни мақсаттарға жету үшін идеологиялық негізделген зорлық-зомбылықты қолдайтын немесе жасайтын адамдар. Экстремизмге қарсы күрес жұмысының мақсаты – қоғам жетекшілеріне террористердің қауіп-қатерлерін болдырмауға және азайтуға мүмкіндік беретін қоғамдастықтың әрекет ету шараларының тұрақтылығы мен дамуын жақсарту үшін дәлелдерге негізделген әдістерді ұсыну [93].

1.3.1 Жаһандық терроризм дерекқоры (GTD)

Жаһандық терроризм дерекқоры (GTD) – 1970 жылдан 2019 жылға дейін бүкіл әлем бойынша ішкі және халықаралық террористік шабуылдар туралы ақпаратты қамтитын ашық алғашқы дерекқор қоры және қазіргі уақытта 200 000-нан астам жағдайды қамтиды. Әр оқиға үшін оқиғаның күні мен орны, пайдаланылған қару мен мақсаттың сипаты, құрбан болғандар саны және сәйкестендіру кезінде анықталған топ немесе оған жауапты жеке тұлға туралы ақпаратты қамтиды. Терроризмді зерттеу және терроризмге қарсы іс-қимыл жөніндегі ұлттық консорциум (START) GTD-ді осы онлайн-интерфейс арқылы қол жетімді етеді, террористік зорлық-зомбылық туралы түсінікті кеңейтуге тырысады.

GTD сипаттамалары:

- 200 000-нан астам террористік шабуылдар туралы ақпарат бар;
- Қазіргі уақытта бұл әлемдегі террористік шабуылдар туралы ең толық құпия емес мәліметтер қоры;
- 1970 жылдан бастап 95000-нан астам жарылыс, 20000 кісі өлтіру және 15000 адам ұрлау және барымтаға алу туралы ақпаратты қамтиды;
- Әрбір жағдай үшін кем дегенде 45 айнымалы туралы ақпаратты қамтиды, ал кейінгі оқиғалар 120-дан астам айнымалы туралы ақпаратты қамтиды;
- Тек 1998 жылдан 2019 жылға дейін 4 000 000-нан астам жаңалықтар мақалалары мен 25000 жаңалықтар көздері оқыс оқиғалар туралы мәліметтер жинау үшін талданды.



Терроризм туралы ғаламдық мәліметтер базасы 2001 жылы доктор Гари Лаффри Мэриленд университетіне Пинкертонның Ғаламдық барлау қызметінен (PGIS) қолжазба мұрағатын беруді үйлестірген кезде басталды. 1970 жылдан 1997 жылға дейін PGIS зерттеушілерді негізінен отставкадағы АҚШ әскери күштерін терроризм қаупін бағалау үшін телеграф қызметтерінен, үкіметтік есептерден және ірі халықаралық газеттерден террористік шабуылдар туралы ақпаратты анықтауға және жазуға үйретті. 2005 жылдың желтоқсанына қарай зерттеу тобы түзетулер енгізіп, дерекқорға қосымша ақпарат қосуды аяқтады. 2006 жылдың сәуірінде жаңадан құрылған терроризмді зерттеу және терроризмге қарсы ұлттық консорциум (START), терроризмді зерттеу және барлау орталығымен (CETIS) бірлесе отырып, 1997 жылдан кейін GTD кеңейту процесін бастады. Бұған жиналған мәліметтер түрлерін кеңейту және pgis-тегі терроризм анықтамасын зерттеу тобы 1970 жылға дейін барлық оқиғаларға ретроактивті түрде қолданған жеке енгізу критерийлерінің жиынтығы ретінде талдау кірді. CETIS командасы 1998 жылдың қаңтарынан 2008 жылдың наурызына дейін болған шабуылдар туралы ақпаратты жазды. Олар сонымен бірге 1993 жылы жетіспейтін деректерді қайта жинауға тырысты. Өкінішке орай, бұл әрекет сәтсіз болды, ішінара сол кезеңнің бастапқы құжаттары жеткіліксіз сақталғанына байланысты. 2008 жылдың сәуірінде Нью-Хейвен университетінің зорлық-зомбылық топтарын зерттеу институтының (ISVG) сарапшылары GTD-ге қосылу үшін мәліметтер жинауды бастады. ISVG-дің 2012 жылдың наурызына дейін жалғасқан мәліметтер жинау әрекеті 2008 жылдың сәуірінен 2011 жылдың қазанына дейін болған террористік шабуылдар туралы мәліметтерді қамтиды. GTD зерттеушілері басында бұл деректерді GTD-ге біріктірді және GTD мүмкіндігінше толық және дәл болуын қамтамасыз ету үшін 1970 жылға дейін бұрын анықталған жағдайлар туралы қосымша істер мен қосымша ақпаратты анықтау үшін

көптеген көздерді үнемі қарап отыруды жалғастырды. Аталған процесс GTD құрамына кіретін оқиғаларды анықтау және құжаттау үшін әлемнің әр түрлі бұқаралық ақпарат құралдарынан басталады – күніне екі миллионнан астам мақала қарастырылған. Табиғи тілді өңдеу, атаулы нысандарды алу және машиналық оқыту модельдері террористік шабуылдар туралы ақпаратты қамтитын жаңалықтар мақалаларын анықтауға және ұйымдастыруға көмектеседі. GTD тобы аналитиктерге бірегей шабуылдарды анықтауға, әр оқиғаның егжей-тегжейін жазуға және жаңа ақпарат түскен кезде бұрын тіркелген оқиғалар туралы жазбаларды жаңартуға мүмкіндік беретін жеке деректерді басқару жүйесін жасады. Технологияны жетілдіру және интернетті кеңейту бастапқы материалдардың қол жетімділігін де, жұмыс процестерінің тиімділігін де арттырды [94].

1.3.2 RAND Database of Worldwide Terrorism Incidents

RAND Database of Worldwide Terrorism Incidents бүкіл әлемдегі терроризмге қатысты оқиғалар туралы RAND дерекқоры (RDWTI) – бұл 1968 жылдан 2009 жылға дейінгі мәліметтер жиынтығы, 40 жыл ішінде RAND корпорациясы терроризм мен терроризмге қарсы зерттеулердің алдыңғы қатарында болды. Осы жұмысты қолдау үшін RAND 1968 жылдан бастап халықаралық және ішкі терроризм туралы жан-жақты ақпарат беретін террористік оқиғалар туралы мәліметтер базасын жасап шығарды. Көптеген жылдар бойы көптеген мемлекеттік және жеке демеушілер RDWTI мен оның алдындағы адамдарға, Rand терроризм хронологиясына және Rand-MIPT терроризм оқиғаларының мәліметтер базасына қолдау көрсетті. Аталған мәліметтер қорында 40 000-нан астам терроризм жағдайлары кодталған және егжей-тегжейлі сипатталған. RAND қызметкерлері аймақтық тәжірибесі, тиісті тілдік дағдылары және елдегі жергілікті жерлерде жұмыс тәжірибесі бар қызметкерлерді тарта отырып, ықтимал террористік шабуылдар туралы кең зерттеу жүргізді. RDWTI – бұл пайдаланушыларға сапалы және жан-жақты мәліметтер беруге арналған толық қол жетімді және интерактивті мәліметтер базасы. Деректер базасы зерттеу және талдау үшін ақысыз және қол жетімді. RAND дерекқоры 1968 жылдан 2009 жылға дейінгі уақытты қамтиды. Терроризм орындаушылардың жеке басымен немесе себеп сипатымен емес, әрекеттің сипатымен анықталады; негізгі элементтерге мыналар кіреді:

- Зорлық-зомбылық немесе зорлық-зомбылық қаупі;
- Қорқыныш пен алаңдаушылық тудыруға арналған;
- Белгілі бір әрекеттерге мәжбүрлеуге арналған;
- Мотив саяси мақсатты қамтуы керек;
- Әдетте азаматтық мақсаттарға қарсы бағытталған;
- Террористік инциденттер туралы хабарламалардың анықтамалары;
- Инцидент идентификаторы: есеп жасалғаннан кейін әрбір есепке реттік нөмір беріледі.

Бұл сан RDWTI мәліметтер базасындағы оқиғалардың жалпы санына сәйкес келеді. Оқиға күні: террорлық шабуыл болған күн.

Дереккөз күні: жаңа дереккөздің жарияланған күні.

Ақпарат көзі: ақпарат көзінің атауы. Есептер, әдетте, екі немесе одан да көп дереккөздерге негізделген. Барлық бастапқы құжаттама әр есеп үшін қағаз түрінде сақталады.

Ішкі / халықаралық оқиға: бұл айнымалы үшін әдепкі мән – "ішкі оқиға". "Халықаралық" оқиға деп санау үшін шабуыл элементі шетелдік субъектімен (яғни орындаушы, нысана және т.б.) байланысты болуы керек.

АҚШ-тағы мүлікке/мүлікке шабуыл: әдепкі мән "жоқ"; егер АҚШ азаматы шабуылдың құрбаны болса немесе АҚШ-қа тиесілі мүлік шабуылға ұшыраса немесе бүлінсе, онда "иә" енгізіледі.

Өз-өзіне қол жұмсау миссиясы: әдепкі мән "жоқ"; егер шабуылдаушылар шабуыл аясында "суицид" тактикасын қолданса, онда "иә" енгізіледі.

Шабуыл туралы айтылған: әдепкі мән "жоқ"; егер орындаушылар тобы шабуыл туралы мәлімдесе және бұл мәлімдеме сенімді деп саналса, онда "иә" енгізіледі.

Үйлестірілген шабуыл: әдепкі мән – "жоқ"; егер шабуыл жүйелі түрде жоспарланған жеке шабуылдар сериясының бөлігі болса, онда "иә" енгізіледі.

Ескертпе: бір жерде бір мезгілде болған жарылыстар бір инцидент болып саналады.

Үзілген шабуыл: әдепкі бойынша "жоқ" мәні орнатылған; Егер шабуыл шабуылдаушылар жоспарланған шабуылды жүзеге асырмас бұрын тоқтатылса, онда "иә" енгізіледі.

Ел: шабуыл жасалатын ел.

Қала: шабуыл жасалатын қала.

1-Орындаушы: шабуылға жауапты топ. Жауапкершілікті сенімді мәлімдеме арқылы орнатуға болады немесе талдаушы өзінің аймақтық біліміне сүйене отырып, жауапты топқа кіре алады.

2-Орындаушы: егер екінші топ шабуылға жауапты болса, олар осында тізімделеді; әдепкі мән – «жоқ». Жауапкершілікті сенімді мәлімдеме арқылы орнатуға болады немесе талдаушы өзінің аймақтық біліміне сүйене отырып, жауапты топқа кіре алады.

Бірнеше қылмыскер (>2): әдепкі мән "жоқ" [95].

1.4 Экстремизмге қарсы күрес

Экстремизмге қарсы іс-қимыл мынадай негізгі бағыттар бойынша жүзеге асырылады:

- экстремизмнің алдын алуға, оның ішінде оны жүзеге асыруға ықпал ететін себептер мен жағдайларды анықтауға және кейіннен жоюға бағытталған профилактикалық шаралар қабылдау;
- экстремизмді анықтау және оның жолын кесу;
- экстремизмге қарсы іс-қимыл саласындағы халықаралық ынтымақтастық.

Мемлекеттік органдар өз құзыреті шегінде экстремизмнің алдын алуға бағытталған мынадай профилактикалық шараларды іске асырады:

1) Діни қызмет саласындағы мемлекеттік реттеуді жүзеге асыратын мемлекеттік орган Қазақстан Республикасының аумағында құрылған діни бірлестіктер мен миссионерлердің қызметіне зерделеу және талдау жүргізеді, өз құзыретіне жататын мәселелер бойынша ақпараттық-насихаттау іс-шараларын жүзеге асырады, Қазақстан Республикасының Діни қызмет және діни бірлестіктер туралы заңнамасын бұзуға қатысты мәселелерді қарайды, діни қызметке тыйым салу туралы ұсыныстар енгізеді;

2) бұқаралық ақпарат құралдары істері жөніндегі уәкілетті орган бұқаралық ақпарат құралдары өнімдерінде экстремизмді насихаттауға және ақтауға жол бермеу, олардың Қазақстан Республикасының заңнамасын сақтауы тұрғысынан мониторинг жүргізеді, мемлекеттік тапсырысты орындайтын бұқаралық ақпарат құралдарында ұлтаралық және конфессияаралық келісімді нығайту мәселелерінің жария етілуін қамтамасыз етеді;

3) білім беру саласындағы орталық атқарушы орган білім беру ұйымдарында білім алушылардың экстремизм идеяларын қабылдамауын, халықаралық құқық пен ізгіліктің жалпыға танылған қағидаттарын құрметтеуін қалыптастыруға бағытталған тәрбиелік бағдарламалардың бекітілуін және іске асырылуын қамтамасыз етеді, оқу орындарының студенттер алмасу мәселелері бойынша халықаралық шарттарының сақталуын бақылауды жүзеге асырады;

4) Қазақстан Республикасының Ұлттық қауіпсіздік органдары жедел-ізвестіру, қарсы барлау іс-шараларын жүргізеді және Қазақстан Республикасының заңнамасына сәйкес мемлекеттік органдардың дәлелді қорытындылары бойынша өздерінің іс-әрекеттерімен қоғам мен мемлекеттің қауіпсіздігіне қатер төндіретін немесе нұқсан келтіретін шетелдіктер мен азаматтығы жоқ адамдардың Қазақстан Республикасына келуіне жол бермеу жөніндегі шараларды жүзеге асырады;

5) Қазақстан Республикасының Ішкі істер органдары жедел-іздігі кызметін, қоғамдық тәртіпті қорғау және қоғамдық қауіпсіздікті қамтамасыз ету жөніндегі атқарушылық және өкімдік функцияларды жүзеге асырады, сондай-ақ өз әрекеттерімен қоғам мен мемлекеттің қауіпсіздігіне қатер төндіретін немесе нұқсан келтіретін шетелдіктер мен азаматтығы жоқ адамдарды Қазақстан Республикасының заңнамасына сәйкес Қазақстан Республикасынан шығарып жіберуді жүзеге асырады;

6) облыстардың (республикалық маңызы бар қалалардың, астананың), аудандардың (облыстық маңызы бар қалалардың) жергілікті атқарушы органдары қоғамдық бірлестіктермен өзара іс-қимылды, тиісті аумақтарда құрылған діни бірлестіктер мен миссионерлердің қызметін зерделеуді жүзеге асырады, олар туралы деректер банкі құрады, өздерінің құзыретіне жататын мәселелер бойынша өңірлік деңгейде ақпараттық-насихаттау іс-шараларын жүзеге асырады, Қазақстан Республикасының заңнамасында белгіленген тәртіппен жергілікті атқарушы өңірдегі діни ахуалды зерделеу және талдау тапсырмасын орындайды.

7) Сыртқы барлау субъектілері өз іс-әрекеттерімен қоғам мен мемлекеттің қауіпсіздігіне қатер төндіретін немесе нұқсан келтіретін шет мемлекеттердің ұйымдарына, шетелдіктер мен азаматтығы жоқ адамдарға қатысты Қазақстан Республикасының мемлекеттік органдарын хабардар етуді жүзеге асырады.

Мемлекеттік органдардың экстремизмді анықтау және оның жолын кесу жөніндегі құзыретіне келетін болсақ:

1. Ұлттық қауіпсіздік, ішкі істер органдары және экономикалық тергеу қызметі Қазақстан Республикасының заңнамасымен осы органдардың қарауына жатқызылған қылмыстық құқық бұзушылықтарды анықтайды, жолын кеседі, ашады және тергейді, сондай-ақ Қазақстан Республикасының заңдарында көзделген өзге де өкілеттіктерді жүзеге асырады.

1-1. Экономикалық тергеу қызметі экстремизмді қаржыландыру көздерінің, арналары мен тәсілдерінің алдын алуды, анықтауды, жолын кесуді жүзеге асырады.

2. Прокурорлар жеке және заңды тұлғалардың, олардың құрылымдық бөлімшелерінің (филиалдары мен өкілдіктерінің) Қазақстан Республикасының Экстремизмге қарсы іс-қимыл саласындағы заңнамасын бұзу фактілері анықталған кезде немесе дайындалып жатқан құқыққа қарсы әрекеттер туралы мәліметтер болған кезде, сондай-ақ бұқаралық ақпарат құралдары арқылы адамның және азаматтың құқықтары мен бостандықтарына, сондай-ақ олардың мүдделеріне зиян келтіруі мүмкін экстремистік материалдар таратылған жағдайда экстремизмнің кез келген көріністерін жою туралы прокурорлық қадағалау актілерін енгізеді, жүзеге асыруға ықпал еткен себептер мен жағдайларды ескере отырып, бұзылған құқықтарды қалпына келтіру туралы сотқа ұйымдар экстремизмді жүзеге асырған жағдайда олардың қызметіне тыйым салу туралы өтініш береді, сондай-ақ Қазақстан Республикасының заңдарында белгіленген тәртіппен және шектерде қылмыстық қудалауды жүзеге асырады.


3. Өзге де мемлекеттік органдар экстремизмді анықтауға және оның жолын кесуге Қазақстан Республикасының заңдарында белгіленген өз құзыреті шегінде қатысады [96].

1.4.1 Экстремизммен күресуге арналған жобалар

1.4.1 Трасе жобасы

Трасе жобасының мақсаты – Оңтүстік-Шығыс Азия елдерін терроризмге қарсы тергеулерде онлайн-деректерді қолдануға үйрету. Мерзімі: 2017 жылдың тамызынан 2021 жылдың ақпанына дейін. Бюджет: 2 миллион евро. Трасе жобасы Оңтүстік-Шығыс Азия мемлекеттері қауымдастығының (АСЕАН) 10 елінде: Бруней, Индонезия, Камбоджа, Лаос, Малайзия, Мьянма, Филиппин, Сингапур, Таиланд және Вьетнамда терроризмге қарсы күрес саласындағы әлеует пен сараптамалық білімді нығайту бойынша жұмыс істейді. Жоба терроризммен күрес жөніндегі ұлттық бөлімшелердің қызметкерлеріне, кибернетикалық бөлімшелердің барлау және тергеу бөлімшелерінің қызметкерлеріне және интернетті террористік мақсаттарда пайдалануға қарсы тергеу мен күреске жауапты кез келген басқа

ұлттық мекемелердің қызметкерлеріне бағытталған. Trase жобасы қатысушыларға терроризмге қарсы тергеу жүргізу үшін онлайн платформалардан, соның ішінде әлеуметтік желілерден ақпарат жинауға және пайдалануға қажетті дағдылар, құралдар мен әдістемелерді ұсынды.



Әр цикл келесі әрекеттерді қамтиды:


- Интернетті террористік мақсатта пайдалануға қарсы тұру үшін апталық базалық дайындық;
 - Интернетті террористік мақсатта пайдалануға қарсы тұру бойынша бір апталық біліктілікті арттыру курсы;
 - Бағдарламалық жасақтаманы сыйға тарту және бағдарламалық жасақтаманы мамандандырылған оқыту;
 - Жаттықтырушыға арналған жаттығу;
 - Қатысушыларға практикалық тәжірибе беруге арналған үстелдік жаттығу.
- Аталған жобаның мақсаттары келесідей:
- Қылмыстық тергеу аясында ашық бастапқы (OSINT) және әлеуметтік медиа (SOCMINT) деректер ағындарын қалай пайдалануға болатындығын түсіну;
 - Интерполдың полиция мүмкіндіктерін, соның ішінде әртүрлі мәліметтер базасы мен интерполдың хабарламаларын қалай пайдалану керектігін түсіну;
 - Сандық дәлелдемелерді жинау мен қорғаудың дұрыс әдістерін түсіну;
 - Талдауға көмектесетін құрал ретінде графикалық әдістерді қолдану;
 - Үшінші тараптардан (Интерпол, басқа да құқық қорғау органдары, интернет-провайдерлер, телекоммуникациялық компаниялар және т.б.) ақпаратты қалай сұрау керектігін түсіну [97].

1.4.2 Sharaka жобасы

Sharaka жобасы террористердің шекараны кесуінің алдын алуға бағытталған. Аталған жоба озық агенттіктерді I-24/7 (Интерполдың қорғалған жаһандық полиция коммуникациялық желісі), әсіресе әуежайларда, теңіз порттарында және ұлттық шекараларда қосады. Бұл оларға нақты уақыт режимінде барлауды бөлісуге және қылмыс туралы жаһандық мәліметтер базасына қол жеткізуге мүмкіндік береді.

Террористер, әсіресе қақтығыс аймақтарынан оралған шетелдік содыр-террористер пайдаланатын ұрланған жол жүру құжаттарына байланысты шекара қызметі

қызметкерлерінің ұрланған және жоғалған жол жүру құжаттары туралы интерполдың деректер базасына тікелей қол жеткізуі өте маңызды.



Бұл жоба мақсатты елдердің терроризмге қарсы күрес саласында қажетті білімге, құрал-жабдықтар мен дағдыларға ие болуын қамтамасыз етеді. Алдыңғы қатардағы қызметкерлер аймақтық тергеулер мен операциялар барысында Интерполдың қылмыстық істер бойынша бірқатар жаһандық дерекқорларын пайдалану бойынша дайындықтан өтеді [98].

1.4.3 Scorpius жобасы

Scorpius жобасы терроризм мен онымен байланысты трансұлттық қылмыстың алдын алуға және жолын кесуге бағытталған оңтүстік және Оңтүстік-Шығыс Азиядағы құқық қорғау органдарының әлеуетін арттыру жөніндегі екі жылдық (2017-2019 жж.) бастама болды. Оны интерпол мен Канада үкіметі бірлесіп қаржыландырды.

Біртұтас тәсілді қолдана отырып, жоба құқық қорғау қоғамдастығының тиісті қатысушыларын, соның ішінде негізгі шешім қабылдаушыларды, терроризмге және трансұлттық қылмысқа қарсы күрес жөніндегі тергеушілерді, барлау қызметкерлерін, Интерполдың Ұлттық Орталық Бюросының (ҰОБ) қызметкерлерін, қылмыстық сот төрелігі органдарын, прокурорларды және полицияның оқу орындарын біріктірді.

Жаһандық терроризмге қарсы стратегияны қолдай отырып, жоба келесі бенефициар елдерге бағытталған: Бангладеш, Үндістан, Индонезия, Малайзия, Мальдив, Непал, Пәкістан, Филиппин, Шри-Ланка.

Тергеу семинарлары қылмыстық және террористік іс-әрекеттің алдын алу, анықтау және тергеу үшін қажетті практикалық дағдыларды қамтамасыз етеді:

- Күдікті трансұлттық қылмыстық желілер мен олардың филиалдарын анықтау;
- Ұлттық және халықаралық деңгейлерде тиісті құқық қорғау органдары арасында үйлестіру;
- Интерпол және құлақтандыру дерекқорына террористердің бейіндерімен байланысты биометриялық деректерді жүйелі түрде қосу;
- Қару-жарақ пен материалдардың заңсыз айналымын анықтау, қадағалау және жолын кесу;

- CBRNE инциденттеріне және үйдегі жарылғыш құрылғыларға қатысты заттар мен жұмыс әдістері туралы ақпараттармен бөлісу.

Оқу курстары бағалау кезеңінде анықталған қажеттіліктердің әртүрлі салаларына бағытталған, соның ішінде:

- Ашық бастапқы және әлеуметтік медиа тергеулер – бұл ашық бастапқы барлау және әлеуметтік медиа платформаларын қолдана отырып жүргізілген тергеулер арқылы терроризмнің алдын-алудың және онымен күресудің өзекті және тұрақты әдістері. Сондай-ақ, қатысушылар трансұлттық қылмысқа қарсы терроризмге қарсы және онымен байланысты тергеулер барысында жеке өмірге қол сұқпаушылық, адам құқықтары мен сөз бостандығы туралы білді.

CBRNE қару-жарақтары мен материалдары – мүше елдер арасында жаппай қырып-жою қаруы (ЖҚҚ) және қолдан жасалған жарылғыш құрылғылар (ЖҚҚ) туралы, әсіресе әскери және құқық қорғау органдары арасында барлау алмасуға жәрдемдесу үшін қарастырылады. Сессия сондай-ақ химиялық биологиялық радиологиялық және ядролық және жарылғыш материалдар (CBRNE) туындатқан террористік қатерлер мен инциденттерге ден қою жөніндегі елдердің әлеуетін нығайтуға бағытталған.

Қылмыс орнындағы тергеу және апат құрбандарын анықтау (DVI) – жарылыс орнын тексеру, DVI әдістері және терроризмге қарсы күрес контекстіндегі қылмыс орнындағы жалпы тергеу. Қатысушылар мұндай оқиғаларға тиімді жауап беруді және Террористік актілерді жасағандарды қудалауды қолдау үшін өмірлік дәлелдер жинауды үйренді.

Аналитикалық семинарлар офицерлерге қылмыстық және террористік әрекеттерді тиімді талдау үшін қажет практикалық дағдыларды ұсынады:

- Барлау процесінің тұжырымдамалары мен компоненттерін түсіну;
- Талдамалық бағаларды, баяндамалар мен брифингтер дайындау;
- Ашық бастапқы және әлеуметтік медиа зерттеулерінің тұжырымдамаларын, әдістері мен құралдарын түсіну және қолдану;
- Терроризмді қаржыландыру жағдайларын талдау үшін практикалық ақпарат алу [99].

1.4.4 Dark web project AI Lab Dark Web жобасы

Dark web project AI Lab Dark Web – бұл халықаралық терроризм құбылыстарын (жихадшыларды) зерттеуге және түсінуге бағытталған ұзақ мерзімді ғылыми-зерттеу бағдарламасы. Зерттеушілер халықаралық террористік топтар құрған веб-сайттарды, форумдарды, чаттарды, блогтарды, әлеуметтік желілер сайттарын, бейнелерді, виртуалды әлемді және т. б. қоса алғанда, "бүкіл" веб-контентті жинауға ұмтылады. Олар көп тілді деректерді талдаудың, мәтінді талдаудың және веб-талдаудың әртүрлі әдістерін жасады, сілтемені талдау, мазмұнды талдау, вебкөрсеткіштерді талдау (техникалық күрделілік), көңіл-күйді талдау, авторлықты талдау және зерттеу барысында бейнені талдау есептерін қарастырды. Осы жоба аясында жасалған тәсілдер мен әдістер барлау және қауіпсіздік информатикасы (ISI) саласын дамытуға ықпал етеді. Мұндай жетістіктер тиісті мүдделі тараптарға терроризм саласында зерттеулер жүргізуге және халықаралық қауіпсіздік пен бейбітшілікті қамтамасыз етуге ықпал етуге көмектеседі. Зерттеушілер сандық кітапханадағы алдыңғы зерттеулер негізінде әртүрлі мамандандырылған өрмекшілер/сканерлер жасады. Құрастырылған өрмекшілер парольмен қорғалған сайттарға кіріп, рандомизацияланған (гуманоидты) үлгіні жасай алады. Олар веб-сайттағы барлық html, pdf және word файлдарын, сілтемелерді, PHP, CGI және ASP файлдарын, суреттерді, аудио және бейнелерді шығаруға үйретілген. Жаңалықты қамтамасыз ету үшін әр 2-3 ай сайын таңдалған веб-сайттарды қарап шығады.

Форумдарда өрмекшілерді құруға арналған құрал 15+ форум хостинг бағдарламалық жасақтамасын және олардың форматтарын таниды. Зерттеушілер қатысушылардың өзара әрекеттесуін қайта құруға мүмкіндік беретін авторлар, тақырыптар, жарияланымдар, тақырыптар, уақыт белгілері және т.б. сияқты толық форумды жинайды. Олар форумдардың мерзімді желісін және зерттеу қажеттіліктеріне негізделген біртіндеп

жаңартуды жүзеге асырады. Зерттеушілер форумның мазмұнын араб, ағылшын, испан, француз және қытай тілдерінде компьютерлік лингвистиканың таңдаулы әдістерін қолдана отырып жинады және өңдеді.

Барлық сайттар бірдей радикалды немесе қатал емес. Көңіл-күйді талдау (полярилық: оң/теріс) және әсер ету (эмоциялар: зорлық-зомбылық, нәсілшілдік, ашу және т.б.) әрі қарай зерттеуді қажет ететін радикалды және зорлық-зомбылық сайттарын анықтауға мүмкіндік береді. Сондай-ақ, зерттеушілер радикалды идеялардың мазмұнына, жіберушілеріне және олардың өзара әрекеттесуіне негізделе отырып, олардың қаншалықты "жұқпалы" болатындығын зерттейді. Сондай-ақ, олар уақыт пен адамдардың көңіл-күйін/өзгеруін зерттеу үшін жеке визуализация әдістерін жасады. Зерттеуге әсер ететін бірнеше ықтималды көптілді лексика және өлшемді азайту мен болжаудың таңдалған әдістері (мысалы, негізгі компоненттерді талдау) кіреді.

Авторлықты талдау бойынша зерттеулерге негізделе отырып, анонимді жіберушілерді олардың форумдағы хабарламаларына байланысты қолтаңбалар негізінде бірегей сәйкестендіруге мүмкіндік беретін жазу әдістемесін (кибер) әзірледі. Олар дәстүрлі авторлық талдаудың лексикалық және синтаксистік ерекшеліктерін жүйелік (мысалы, қаріп өлшемі, түс, веб-сілтемелер) және семантикалық (мысалы, зорлық-зомбылық) қамтиды [100].

1.4.5 «Мәтіндегі экстремистік бағытты анықтау үшін веб-ресурстардағы семантикалық талдау модельдерін, алгоритмдерін құрастыру және кибер-криминалистика құрал-жабдықтарын әзірлеу» жобасы

Өл-Фараби атындағы Қазақ ұлттық университетінде Қазақстан Республикасының Цифрлық даму, инновациялар және аэроғарыш өнеркәсібі министрлігінің тапсырысы бойынша «Мәтіндегі экстремистік бағытты анықтау үшін веб-ресурстардағы семантикалық талдау модельдерін, алгоритмдерін құрастыру және кибер-криминалистика құрал-жабдықтарын әзірлеу» жобасы, ЖТН АР06851248 жүргізілуде. Жобаның мақсаты – веб-ресурстардағы экстремистік мазмұнды анықтау үшін мәліметтерді семантикалық талдау үлгілерін, алгоритмдерін және бағдарламалық жабдықтамасын, қатысушы қолданушыларды анықтау әдістерін және байланыстарды графикалық визуалдау алгоритмдерін кешенді зерттеу және құру, қаржыландыру көздерін анықтау үшін Даркоин төлем жүйелеріндегі және олардың бейімдеулеріндегі криптовалюта транзакциясын талдау үлгілерін құру және зерттеу, экстремизмге қарсы күресу үшін кибер-криминалистика құрал-жабдығын әзірлеу болып табылады. Берілген жобаның практикалық маңыздылығы – жоба нәтижелерінің маңыздылығы экстремистік мазмұндағы мәтіндерді анықтауды машинамен оқыту әдістері үшін белгілердің оңтайлы жиынтығын анықтау үшін қазақ және орыс тілдерінде веб ресурстар деректерінің семантикалық талдау модельдерін, алгоритмдерін, қатысушы пайдаланушыларды сәйкестендіру әдістерін, есептеу құрылғылары үшін payload құру және енгізу әдістерін және құрылғыларға қашықтан қол жеткізуді, инновациялық құрылымдық үлгілермен ерекшеленетін Darkcoin сияқты жүйелер үшін кибер-тергеу алгоритмдерін және транзакция графтары мен топологиясын талдау әдістерін, сондай-ақ көпшілік ақпараттың үлкен көлемінен көлеңкелі нысандарды танитын жасанды нейрондық желілерді қолдана отырып, транзакция деректерін іздеу әдісін әзірлеу.

2. ВЕБ-РЕСУРСТАРДАҒЫ ЭКСТРЕМИСТІК МӘЛІМЕТТЕРДІ АНЫҚТАУДЫҢ СЕМАНТИКАЛЫҚ ҮЛГІСІН ҚҰРУҒА ҚАЖЕТТІ КОРПУС ҚҰРУ

2.1 Ашық көздерден ақпарат алу. Парсер бағдарламалары

Ашық дереккөзді зерттеу – мәліметтерді зерттеуде қалыптасқан жаңа әдіс, яғни ашық дереккөздер арқылы зерттеу жүргізу. Яғни, компьютер мен ноутбуктың алдында отырып-ақ, ғаламтордағы анық, фейк емес ақпараттарды пайдалана отырып, зерттеу жасау бағыты. Мұндай зерттеуді жанжал орын алған немесе дау-дамай өршіп тұрған аймақты зерттеу, коррупцияны тексеру мен ашу үшін, адамдарды іздеу мен қылмыстың бетін ашу үшін, экологиялық және тарихи зерттеулерді жасау үшін қолдануға болады. Зерттеуге пайдалануға болатын ресурстар өте көп. Бірақ олардың негізгілерін екі үлкен топқа бөліп қарастыруға болады. Біріншісі – кең таралған материалдар болса, екіншісі – күңгірт ақпараттар.

Парсинг әдетте үлкен көлемде деректерді тез жинау қажет болған кезде қолданылады. Ол арнайы парсер қызметтерінің көмегімен жүзеге асырылады. Парсинг – бұл деректерді автоматты түрде жинау және құрылымдау процесі. Арнайы бағдарламалар немесе парсер қызметтері сайтқа кіріп, берілген шартқа сәйкес келетін деректерді жинайды. Парсинг жасау – процесті автоматтандыратын арнайы бағдарламалардың көмегімен белгілі бір сайттарда орналастырылған ақпаратты жинау және жүйелеу. Парсингтың артықшылығы айқын – егер оны қолмен жинау және деректерді сұрыптаумен салыстыратын болсақ:

- деректерді тез алу мүмкіндігі;
- таңдама жасау үшін ондаған параметрлерді орнатуға болады;
- есепте қателер болмайды;
- парсингты белгілі бір жиілікпен орнатуға болады – мысалы, әр дүйсенбі сайын деректерді жинау;
- көптеген парсерлер деректерді жинап қана қоймай, сайттағы қателерді қалай түзетуге кеңес береді.

Парсинг жасау барысында келесі амалдарды орындауға тыйым салынған:

- сайтты бұзу (яғни пайдаланушылардың жеке кабинеттерінің деректерін алу және т. б.);
- DDOS-шабуылдар (егер деректерді талдау нәтижесінде сайтқа тым жоғары жүктеме түссе);
- авторлық контентті қарызға алу (копирайты бар фотосуреттер, түпнұсқалығы нотариуспен расталған бірегей мәтіндер және т.б. олардың заңды орнында қалдырған дұрыс) [101].

Деректерге парсинг жасау үшін екі форматтың біреуін таңдауға болады:

- нарықта көп кездесетін арнайы бағдарламаларды пайдалану;
- оларды кез-келген бағдарламалау тілінде жазу, мысалы, PHP, C++, Python. Егер парақтағы барлық ақпарат емес, бірақ тек белгілі бір бөлігі ғана қажет болған жағдайда (тауарлардың атаулары, сипаттамалары, бағасы) XPath қолданылады.

2.2 Экстремистік контентке қол жеткізу және оларды жинақтау әдістері

Әлеуметтік медиа идеялармен және қол жетімді және ғаламдық онлайн-коммуникациялармен алмасу алаңын ұсынады. Көптеген адамдар әлеуметтік медианы әртүрлі себептерге қолдау көрсету немесе қарсы пікір білдіру үшін пайдаланады, бұл пайдаланушы мазмұнының көп бөлігі мәтіндік ақпарат болып табылады. Күнделікті өмірдің әртүрлі тақырыптары бойынша нақты уақыт режимінде өз пікірлерін жариялайтын адамдар туралы көптеген мәліметтер болғандықтан, үкіметке дұрыс шешім қабылдау немесе қоғамдық пікірді бақылау үшін пайдалы болуы мүмкін деректерді жинау және талдау үшін зерттеу жүргізген жөн. Әлеуметтік желілерде қол жетімді деректер ықтимал террористік немесе радикалды топты анықтауға тырысқанда қызығушылық тудыруы мүмкін ақпараттың бір түрі ғана болып табылады.

Әлеуметтік медиа оларды қолданудың қарапайымдылығына байланысты көпшілік арасында танымал болды. Миллиондаған хабарламалардың күнделікті пайда болуымен, әлеуметтік медиа, қосымшалар немесе қолданушыларға интернетте өзара әрекеттесуге мүмкіндік беретін қосымшалар соңғы жылдары маңызды бола бастады. Әлеуметтік медианы талдаудың артықшылығы – деректер көпшілікке қол жетімді болады, өйткені қатысушылар осы ортаға белсенді және пассивті пайдаланушылардың толық көрінісінде қатысады. Бұл электрондық пошта немесе Интернет және телефония сияқты басқа сандық байланыс құралдарымен пайдаланушылармен өзара әрекеттесуден ерекшеленеді, мұнда талдаушылар пайдаланушылардың жеке өмірін қорғау үшін тиісті заңдарды ұстануы керек.


Әлеуметтік медиа пікір білдірудің танымал құралына айналды, сондықтан оларды іс жүзінде құнды идеяларды, тіпті ең радикалды идеяларды алуға болатын тірі фокус-топ ретінде пайдалануға болады. Саяси сайлау, дін немесе реалити-шоудың жеңімпазы туралы айтатын болсақ та, әлеуметтік медиа қоғамдық пікірді анықтауда маңызды рөл атқара алады. Бұл адамдар нақты уақыт режимінде өз көзқарастарымен бөлісетін, ұйымдар мен барлауға қоғамдық пікірге баға жетпес көзқарас беретін платформа.

2.3 Экстремистік бағытты (ЭН) анықтау үшін веб-контентті жинауға және талдауға арналған бағдарламалық жабдықтама құрастыру

2.3.1 Мәліметтерді алуға дайындық кезеңі

Веб-ресурстардағы экстремистік мәтіндерді анықтау мақсатында семантикалық талдау үлгілерін құру жұмысын жүргізу үшін ең алдымен үлкен көлемдегі корпус қажет болады. Аталған корпус мәтіндері машиналық оқыту алгоритмдерін үйрету және тестілеу кезеңдерінде қолданылады. Бастапқыда ашық қол жетімді ресурстардағы экстремистік мәтіндер іздестірілді. Қазақ тіліндегі экстремистік мәтіндер негізінен жаңалық порталдарындағы, «Youtube», «ВКонтакте» әлеуметтік желілеріндегі комментарийлер арасынан табылды. Алайда мұндай әдіспен табылған экстремистік мәтіндер машиналық оқыту жүйелерін үйрету үшін жеткіліксіз болды. Ашық дереккөздерден шамамен 4400 сөзді қамтитын 400-ге жуық қазақ тіліндегі экстремистік мазмұндағы мәтіндер табылып, корпусқа енгізілді.

Экстремистік мәтіндерді қамтитын корпусты кеңейту үшін қазақ тілді аудитория арасында белсенді қолданылатын әлеуметтік желі түрін таңдау тапсырмасы қойылды. «ВКонтакте», «Facebook», «Twitter» әлеуметтік желілеріндегі мәтіндерге талдау жасалып, нәтижесінде «ВКонтакте» әлеуметтік желісі таңдалды. Келесі кезекте парсер модулінің кірісіне мәтіндері жүктелуі керек болатын топтардың тізімдерін беру қажет. Әлеуметтік желідегі парсинг жасалатын топтар тізімі ашық дереккөздердегі экстремистік мәтіндерге TF-IDF әдісін қолдану арқылы анықталған кілттік сөздер көмегімен құрылды. Атап айтатын болсақ, әлеуметтік желі топтарын анықтау үшін "соғыс", "жиһад", "джихад", "шам", "сирия" және т.б. сөздер қолданылды (1-сурет). "Регион" өрісінде "Қазақстан" таңдалды.



1-сурет. Әлеуметтік желі топтарын іздеу мысалы

Зерттеу жұмысының бастапқы кезеңінде корпуста экстремистік мәтіндермен қатар бейтарап мазмұндағы мәтіндерді жинау да жоспарланды. Экстремистік мазмұндағы мәтін ретінде экстремистік іс-әрекеттерді орындауға, экстремистік ұйымдарды қаржыландыруға шақыруды, қару-жарақ түрлеріне деген қызығушылықты, қару-жарақ түрлерін қолдан жасауды үйретуді және т.б. қамтитын мәтіндер таңдалды. Бейтарап санаттағы мәтіндерге діни мазмұнды қамтымайтын, қазақстандық аудиторияда кеңінен танымал, жалпы лексикадағы топтар таңдалды.


Бірінші кезекте Қазақстан Республикасының территориясында таратуға тыйым салынған топтарды анықтап, оларға парсинг жасау қажет болды. Мұндай топтарды анықтау үшін жоғарыда келтірілген кілттік сөздер қолданылды және табылған нәтижелер ішінен "Берілген материал Қазақстан Республикасының территориясында Қазақстан Республикасының Ақпарат және коммуникация министрлігінің Байланыс, ақпараттандыру және бұқаралық ақпарат құралдары саласындағы мемлекеттік бақылау комитетінің талабы бойынша бұғатталды" деген жазбаны қамтитын топтар таңдалды.

Іздеу нәтижесінде Қазақстан Республикасының территориясында таратуға тыйым салынған 76 топ анықталды. Алайда кей топтарға мүлдем парсинг жасау мүмкін болмады. Ал кей топтардың ішінде экстремистік мазмұндағы мәтіндер табылмады. Қазақстан Республикасының территориясында таратуға тыйым салынған топтар тізімі А қосымшасында келтірілген.

Діни мазмұндағы топтар да жоғарыда сипатталған әдіс бойынша анықталды. Іздеу нәтижесінде 433 топ табылды. Анықталған топтар ішінен мәтіні жоқ, тек суреттерді қамтитын, мәтіні басқа тілдегі, атаулары қайталанған топтар өшірілді. Нәтижесінде корпуста енгізу мақсатында 265 топ таңдалды. Діни мазмұндағы топтар тізімі В қосымшасында келтірілген.

Жалпы лексикадағы топтар да жоғарыдағы әдіс бойынша анықталды. «ВКонтакте» әлеуметтік желісіндегі 100 топ таңдалды. Жалпы лексикадағы топтар тізімі С қосымшасында келтірілген.

Келесі кезекте Қазақстан Республикасында орын алған экстремистік іс-әрекеттер жайлы жаңалық мақалалары жинақталды. Жаңалықтар порталдарға кіріп, "жиһад", "Сирия", "экстремизм" және т.б. сөздерді енгізу арқылы іздестірілді (2-сурет).




2-сурет. Экстремистік іс-әрекеттер жайлы жаңалықтарды іздеу процессі
Корпус құрастыру барысында қарастырылған экстремистік іс-әрекеттер жайлы жаңалық мақалаларының тізімі D қосымшасында келтірілген.

2.3.2 Мәліметтерді жинау

Ақпаратты экстремистік санатқа жатқызбас бұрын, "қауіп" критерийін анықтау қажет. Шешімдердің бірі – кілт сөздер жиынтығын анықтау. Әзірленген бағдарламалық кешенде ақпарат түрлерін анықтаудың дәл осы әдісі қолданылды.

Анықтау үшін "ВКонтакте" әлеуметтік желісіндегі ақпаратты талдау үшін қолданылатын кілт сөздер жиынтығы жасалды. Бағдарламалық кешен мәтінде көрсетілген кілт сөздердің болуы немесе болмауы негізінде бұл мәтін одан әрі зерттеу үшін жарамды деген қорытынды жасайды. 1-суретте хабарламалар туралы деректерді жинау, талдау және жіктеудің сұлбасы көрсетілген.



1- сурет – деректерді жинау, талдау және жіктеу сұлбасы

Ақпарат алуды жүзеге асыру ақпарат көзіне байланысты өзгеруі мүмкін, бірақ оны құрудың жалпы принципі сақталады. Ашық көздерден ақпарат алуға жауапты бағдарламалық жасақтама бөлігінің негізгі мақсаты – іс-әрекеттерді жылдам және тиімді орындау [ссылка].

Максималды өнімділікке қол жеткізу үшін, ақпарат көздерінен (API) ақпарат алудың кіріктірілген әдістерін қолдану қажет. Егер мұндай әдістер болмаса, HTTP сұраныстары арқылы қажетті ақпаратты алу қажет.


Бағдарламалық кешен үш бөлек модульден тұрады:

1) ақпарат жинау модулі — ашық көздерден ақпаратты қабылдауға және оны әрі қарай өңдеуге беруге жауап береді; «ВКонтакте» әлеуметтік желісінен деректерді талдау үшін Python бағдарламалау тілі қолданылды. Ресми VK API қолдана отырып, қазақстандық профильдерді ішінара талданды, сондай-ақ деректер Solr дерекқорында сақталды.

2) кілт сөздерді іздеу модулі – ақпараттың үлкен көлемінің ішінен кілт сөздерді іздеуге жауап береді,

3) құжаттарды саралау модулі – ақпараттың қауіпті екендігін анықтауға жауап береді. Құжаттарды қауіптілік дәрежесі бойынша саралау үшін Long Short Term Memory (LSTM) терең оқыту алгоритмі қолданылды.

Ақпарат Жинау Модулі. Деректерді жинау үшін Тәуелсіз Мемлекеттер Достастығында кеңінен танымал "ВКонтакте" әлеуметтік желісін пайдаланылды. 2-суретте деректерді жинау процесінің сұлбасы көрсетілген. Деректерді жинау үшін Python 3.6 қолданылады.



2-сурет-деректерді жинау схемасы

Әлеуметтік желінің API-мен өзара әрекеттесуі сұрау кітапханасы арқылы жүзеге асырылды. Pycharm Community Edition 2018 бағдарламалық жасақтамасы құрастыру ортасы ретінде таңдалды. Деректерді алу үшін «ВКонтакте» API-ді қолданылады – серверге [https](https://api.vk.com/method/users.get?user_id=210700286&v=5.92) сұрауларын қолдана отырып, «ВКонтакте» әлеуметтік желісінің мәліметтер базасынан қажетті ақпаратты алуға мүмкіндік беретін дайын интерфейс. 1-кестеде пайдаланушының қарапайым сұрауының компоненттері көрсетілген: 'https://api.vk.com/method/users.get?user_id=210700286&v=5.92'.

1-кесте – Сұраныс компоненттері

Сұраныс параметрі	Түсіндірмесі
Компонент	Компонент мәні
<i>https: //</i>	Қосылу хаттамасы
<i>api.vk.com/method</i>	API қызметінің api.vk.com/method қолданушысы
<i>.получить</i>	API V Kontakte әдісінің атауы
<i>?user_id=210700286&v=5.92</i>	Сұраныс компоненті

Әдістер – бұл белгілі бір дерекқор операциясына сәйкес келетін шартты командалар. Мысалы, пользователи.get – бұл пайдаланушылар, есептік жазба туралы ақпарат алу әдісі, getinfo ағымдағы пайдаланушы туралы ақпаратты және т. б. қайтарады.

Жүйедегі барлық әдістер бөлімдерге бөлінген. Жіберілген сұрауда әдіс атауынан кейін HTTP сұрауында GET параметрлері ретінде кіріс деректерін беру керек. Егер сұраныс сәтті өңделсе, сервер сұралған деректермен JSON нысанын қайтарады. Деректерді талдау үшін pandas, numpy, matplotlib, plotly, bokeh, cufflinks, spacy, googletrans пакеттері бар

Python 3.7 бағдарламалау тілі есептеу және визуализацияның негізгі кітапханалары ретінде қолданылды [ссылка].

Тиісті мәтіндерді іздеу үшін экстремизммен байланысты кілт сөздер анықталды. Мысалы, "кафир", "өлтіру", "жару" және т.б. бұл кілт сөздер әлеуметтік желілердегі экстремистік посттарды табуға көмектеседі.

Экстремистік посттар табылған сайын, кілт сөздер базасы толықтырылып, экстремистік посттардың нақты анықтамасын қамтамасыз етеді.

Деректердің аннотациясы үшін Вконтакте әлеуметтік желісінен экстремистік идеялардың мәтіндерін жиналды және олардың дұрыс таңбаланғанына көз жеткізу үшін барлық хабарламалар қолмен тексерілді. Аннотация ережелері мен хабарлама мысалдары 2-кестеде келтірілген.


2- кесте – Аннотация ережесі

Санаттар	Ережелер	Мысалдар
Экстремистік мәтін	(i) Экстремистік ойларды білдіреді.	Мен сыйға ие болу үшін джихад жасаймын.
	(ii) Орындалуы мүмкін экстремистік іс-әрекеттерді қамтиды.	Мен Сирия жеріне жиһад жасауға келдім.
Бейтарап мәтін	(iii) Экстремизмге қатысы жоқ.	Маған бұл кітап қатты ұнайды.

2.3.3 Мәліметтерді жинау үшін парсер құрастыру

Берілген зерттеу үшін үлкен көлемдегі деректер қажет. Қазақ тілінде дайын экстремистік корпус болмағандықтан, «ВКонтакте», «YouTube», «Твиттер» және елдің жаңалықтар порталдары сияқты ашық ақпарат көздерінен мәлімет жинақтау үшін әр түрлі дереккөздерден ақпарат жинайтын парсер жазылды. Парсердің нәтижесін көрсету үшін шағын веб-қосымша құрылды. 3-суретте әртүрлі ашық көздерден деректерді жинауға арналған парсер бағдарламасы көрсетілген.

Нәтижесінде, әзірленген парсер көмегімен экстремистік бағыттағы мәліметтер жиналды. Жіктеу модельдерін одан әрі оқыту үшін корпус әзірленді, ол "экстремистік" және "бейтарап" бағыт ретіндегі екі класстан тұрады.



VkParser

Введите домен группы или сообщества Вконтакте, которого вы хотите анализировать. Данные сохраняется в csv файл.

Введите домен

Путь

Выберите файл

Файл не выбран

Click

YoutubeParser

Укажите URL-адрес видео, которого вы хотите анализировать комментарии под видео. Введите имя файла для записи данных. Информация сохраняется в csv файл

Введите url видео

Введите имя файла

Путь

Выберите файл

Файл не выбран

Click

3-сурет – Зерттеу жұмысы барысында құрастырылған парсерлер

2.4 Веб-ресурстардағы экстремистік мәліметтерді анықтаудың семантикалық үлгісін құруға қажетті корпус құру

Корпусқа енгізілген экстремистік сипаттағы хабарламалардың жалпы саны 1200-ге жуық, ал корпустағы жалпы сөздер саны шамамен 140 000 сөзді құрайды.

Құрастырылған корпус csv форматындағы құжат түрінде сақталған. Экстремистік мәтіндерді қамтитын құжат 4 бағаннан тұрады: хабарламаның реттік нөмірі, хабарлама, хабарламаның препроцессингтен өтіп, тазартылған нұсқасы және қай классқа тиісті жазба екендігін білдіретін "1/0" атрибуты (2-сурет).

1.	Лива Туввар Сирия АлЛажатта #IslamState-қа қарсы ұрыс бастайды https://t.co/Fm1iTwk0Z8	1
2.	террористік иттер бүлікшілерге айналады! #Turkey #PKK #TwitterKurds https://t.co/v73Gmveabl	1
3.	Әл-Хайрдың Газваты 13 арнайы аймақ. Олардан кейін олар Алеппеге қайтып оралады.	1
4.	Сирия-дағы #Ресей n 'басып кіру' туралы алаңдамаудың кіруі мүмкін емес. Меккедегі бір жұма туралы «Қорғаныс джихад» деп жарияланады ...	1
5.	Ядролық соғыс соғысы келе жатыр !!! https://t.co/v73Gmveabl	1
6.	Давлатул ислам! Баақия! Ансарул Халифа - Оңтүстік-Шығыс Азиядағы барлық мужихидтер топтарын жақсы көремін деп сенемін. https://t.co/KaVLDresnk	1
7.	Орыстар, сириялықтар мен ирандықтар Бағдатта әскери үйлестіру камерасын құруда http://t.co/HYabzUFqZC	1
8.	@WilayatNinawa сізге хрөсе-ді жауларға тапсырма аласыз!	1
9.	Фаллужаның #IS мандаты Фаллужаның солтүстік-шығысында (12,5) мм қару-жарақпен Сафави әскеріне тиесілі Хамвейде #IRAQ.	1
10.	□URGENT #HOMS IS сириялық режимді күшейтеді, 4 сарбазды өлтіруге мүмкіндік береді (Хомс-Пальмира)	1
11.	#Анбар ИСМ басқарылды 2 өлтіру 23 ирак армиясы, Аль-Багдади базасында d әскери жолмен 5 күш жұмсалады	1
12.	Бұл жол #Сириядан емес .. #Фаллужадан #Iraq мен армияны бомбалау. #ISIS http://t.co/Qte40bIUEl	1
13.	Жаңа таңертең Тел-наам ауданында Нусайристе 10 тонна бомба (халаб) бар.	1
14.	Бұл твит (жүктеме #RISia #ISIS бомбалау емес) төңкерушілерге арналады .. Жаңа	1

2-сурет. Экстремистік сипаттағы хабарламалар мысалы

2-суретте келтірілген қазақ тіліндегі экстремистік мәтіндерге талдау жасалып, оларға тән кейбір ерекшеліктер анықталды:


1. Қазақ тілінің төл әріптерінің кирилл әріптерімен алмастырылуы (мысалы, "соғысқа" сөзінің орнына "согыска", "өлтіру" сөзінің орнына "олтиру" және т.б. деп жазу);
2. Биграммалардың жиі кездесуі (мысалы, "жиһад жасау", "Шамға бару", "кәпірлерді қыру" және т.б.);
3. Араб тіліндегі діни терминдердің жиі кездесуі (мысалы, "фард кефайр", "даулатуль ислам" және т.б.);
4. Бір сөздің бірнеше жазылу нұсқасының болуы (мысалы, "джихад", "жиһад", "жихат", "жихад", "джихат");
5. Корпустағы орфографиялық қателердің көп кездесуі (грамматикалық емес, мәтінді теру барысында пайда болатын типографиялық қателер).

Корпустағы экстремистік мәтіндер келесідей мәліметтерді қамтиды:


- Ауғанстандық "Талибан" қозғалысының ресми баяндамалары ("Жиһад дауысы");
- Аль-Каида ұйымының баяндамалары;
- Экстремистік іс-әрекеттер жайлы қызығушылық танытқан, қазақ тіліне қатысты мәтіндер (жазбалардың қазақша аудармасын сұрау, қазақстандық заңнамаларды көрсету);
- Құран кітабының жалған аудармасы;
- Қару-жарақ қолдануды үйрету жаттығуларына қатысты жазбалар;
- Есірткіге қатысты жазбалар;
- Жыныстық кемсітушілік, гомосексуализмге қатысты жазбалар;
- Кавказдық жиһадшылардың тізімі көрсетілген жазбалар;
- Сирияға баруға қызығушылық танытқан қолданушылардың жазбалары (Сирияға жету жолдарын сұрау, жиһадтың қалай болып жатқанын сұрау және т.с.с.).

2.5 Корпус талдауы

5-суретте деректер жиынтығындағы экстремистік және бейтарап мәтіндердің үлестірімі көрсетілген.




а) Экстремистік хабарламалардың үлестірім графигі



б) Бейтарап мәтіндердің үлестірім графигі

5-сурет-корпуста экстремистік және бейтарап мәтіндерді бөлу кестесі

Сөздер бұлты. Деректерді визуалды түрде көрсету үшін сөз бұлттары қолданылды. Үлгімал экстремистік идеялары бар пайдаланушылардың хабарламалары 6-суретте бөлек көрсетілген. Экстремистік посттар пайдаланушылардың экстремистік ойларына тікелей нұсқау бере отырып, "қарсы" (қарсы), "әскери" (әскери) сияқты сөздерді жиі қолданады.



а) Экстремизмге байланысты хабарламалардың сөздер бұлты



б) Экстремизммен байланыссыз хабарламалардың сөздер бұлты

6-сурет-экстремистік және бейтарап мәтіндер корпусын визуализациялау

2.6 Морфологиялық талдау жасауға арналған қосымша құру, кілттік сөздерді анықтау

2.6.1 Морфологиялық талдау жасау қосымшасын құрастыру мәселесі

Табиғи тілді өңдеу саласындағы маңызды мәселелердің бірі – стемминг, яғни кіріс мәтіндегі сөздердің негіздері мен қосымшаларын автоматты түрде анықтау және ажырату. Стемминг кезеңін іске асыруға арналған бірнеше әдістер бар және олардың көбісі бастапқы тілге тәуелді болып келеді. Кіріс мәтінге талдау жасау барысында стемминг тапсырмасының орындалуы жіктеу дәлдігін айтарлықтай жоғарылатуға септігін тигізуі мүмкін, мысалы стемминг тапсырмасы орындалмаған жағдайда классификациялау жүйесі мысал ретінде мәтіндегі «сабаққа», «сабақтың», «сабақта», «сабақ» сөздерін әр түрлі сөз ретінде таниды, ал аталған сөздердің қосымшаларын қарастырмай, стемминг қадамын орындап, сөз негіздерін алатын болсақ, онда қосымшалардың барлығы алынып тасталатындықтан, негізі бір сөздердің барлығы бір сөз ретінде анықталатын болады. Сондай-ақ, стемминг тапсырмасын орындамаған жағдайда мәліметтер қорына сөздіктегі сөздердің барлық морфологиялық нұсқасын енгізу қажет болады, ал бұл өте үлкен жадыны қажет етеді және сәйкесінше жүйенің жұмысын айтарлықтай баяулатады.

2.6.2 Бастапқы мәліметтерді сипаттау

Морфологиялық анализатордың кірісіне қазақ тіліндегі қосымшасы бар сөздер беріледі. Кіріс мәтіндегі сөз негіздерін анықтау үшін қазақ тіліндегі 24 мың және 76 мыңға жуық сөз негіздерін қамтитын екі дерекқор пайдаланылды (19-сурет). Кестеге экстремистік мәтіндерге тән кілт сөздер де енгізілді.

id	kaz	type
Click here to define a filter		
9928	норма	noun
9929	вахабис	noun
9930	жихад	noun
9931	өлтір	verb
9932	жихад	noun
9933	соғыс	noun
9934	қыр	verb
9935	жихад	noun
9936	джихад	noun
9937	джихад	noun
9938	соғыс	noun
9939	шайқас	noun
9940	шайқас	noun
9941	кафир	noun
9942	кафир	noun

19-сурет –76000 сөз негізінен тұратын дерекқор


Стемминг модельді оқыту үшін өзгертілген нысандарды енгізу және үлгі ережелерінің ішкі жиынтығына сәйкес түбірлік нысанды генерациялау арқылы орындалады, ең тиісті ережелерді немесе ережелердің бірізділігін қолданумен, сондай-ақ сөз негіздерін таңдаумен байланысты шешімдер нәтижелік дұрыс сөздің ең жоғары ықтималдығы болуы негізінде қолданылады.

Алайда жоғарыда айтылған және басқа да әдістер қазақ тіліне арналып жасалмаған. Қазақ әліпбиінде кириллицадан бөлек арнайы 9 төл әріп Ә, Ғ, Қ, Ң, Ө, Ү, Ү, Һ, І пайдаланылады. Берілген сөздің алғашқы екі әрпі дерекқордағы сөздермен салыстырыла

бастайды. Сөздің қалған бөлігіне файлдарға ұзындығы бойынша жиналған қосымшалар ішінен іздеу жасалады. Сәйкестік жағдайында олар арнайы тізімге жиналады.

Алгоритм бірнеше кезеңнен тұрады:

1. Сандар мен арнайы таңбалар жойылады. Тек сөздер іріктеледі.
2. Сөздің аяқ жағынан жұрнақ пен жалғауларды алып тастап отырады.
3. Әр жұрнақ не жалғау алынған сөздің деректер қорында бар немесе жоқтығы тексеріледі.
4. Деректер қорында бірнеше сөздер табылған жағдайда олардың ішіндегі ұзын сөз қайтарылады.
5. Деректер қорынынан жоғарыдағы әдістер арқылы сәйкестік болмаса, берілген сөздің басынан бастап деректер қорынан іздестіріледі.
6. Деректер қорынынан табылмаған жағдайда сөздің өзі қайтарылады.



20-сурет – Стеммер алгоритмі

Жалғау — сөз бен сөзді байланыстыратын, сөз аралығындағы қатынастардың көрсеткіші болып табылатын, сөзге грамматикалық мағына үстейтін қосымшалар. Жалғаудың төрт түрі бар: көптік, тәуелдік, септік, жіктік (к.). Жалғаулар бірінен соң бірі жалғана береді. Мұндай жағдайда көбінесе алдымен көптік, онан соң тәуелдік, сөз соңында септік жалғаулары жалғанады, жіктік жалғауы да сөз соңында жалғанады: оқушы-лар-ымыз-ға, бала-мыз, келе-сіз [102].

Жұрнақ – жалғанған сөзінен жаңа сөз тудыратын немесе сөзді түрлендіретін қосымша. Қазақ тіліндегі жұрнақ мағынасы мен қызметіне қарай екіге бөлінеді:

1. сөз тудыратын жұрнақтар өзі жалғанған сөзінен жаңа сөз тудырады. Мысалы, “жылқы-шы”, “біл-ім”, “жасы-қ”, “таға-ла”;
2. сөз түрлендіретін жұрнақтар өзі жалғанған сөзіне үстеме мағына қосып, сөздің тұлғасын өзгертеді. Мысалы, “көк-шіл”, “көк(г)-ірек”, “сары-лау”, “сары-рақ”, “жаз-ып”, “жаз-ғалы”. Жұрнақтар сөзге белгілі бір жүйеде рет-ретімен жалғанады [103].

Қосымшалар ұзындығы бойынша "suffix_13"-тен "suffix_1.tx "-ге дейінгі мәтіндік файлдарда сақталады (21-сурет).

```

49 def openFile(i):
50     if i == 13:
51         f = open("suffix/13zh.txt", 'r', encoding="utf-8")
52     if i == 12:
53         f = open("suffix/13zh.txt", 'r', encoding="utf-8")
54     if i == 11:
55         f = open("suffix/11zh.txt", 'r', encoding="utf-8")
56     if i == 10:
57         f = open("suffix/10zh.txt", 'r', encoding="utf-8")
58     if i == 9:
59         f = open("suffix/9zh.txt", 'r', encoding="utf-8")
60     if i == 8:
61         f = open("suffix/8zh.txt", 'r', encoding="utf-8")
62     if i == 7:
63         f = open("suffix/7zh.txt", 'r', encoding="utf-8")

```

21-сурет – Файлды оқу функциясы

Қазақ тілінде кездесетін жұрнақ пен жалғауларды біріктіре отырып, пайда болған қосымшаларды ұзындығы бойынша файлдарға бөлінді. Қазақ тіліндегі кейбір қосымшалар сөздің түбірін өзгертеді. Түбір сөзге қосымшалар жалғанған кезде түбірегі “б” әрібі “п” әрібіне, “қ” әрібі “ғ” әрібіне және “г” әрібі “к” әрібіне ауысады. Мысалы “кітап” деген сөзге “ы” жалғауы жалғанған кезде “кітабы” деген сөз пайда болады. Осы жағдайды ескере отырып, түбір сөзді дұрыс табу үшін арнайы checkKazChar() әдісіні қолданылады. Жұрнақ не жалғау алынған сөзді деректер қорында бар немесе жоқтығы тексеріледі. Егер деректер қорынан сөз табылмаған жағдайда сөздің соңғы әрібі checkKazChar() әдісі арқылы тексеріледі. Сонда “кітаб” деген сөз “кітап” сөзіне ауыстырылады. chekWord() әдісі арқылы сөздің деректер қорында бар не жоқтығы анықталады.

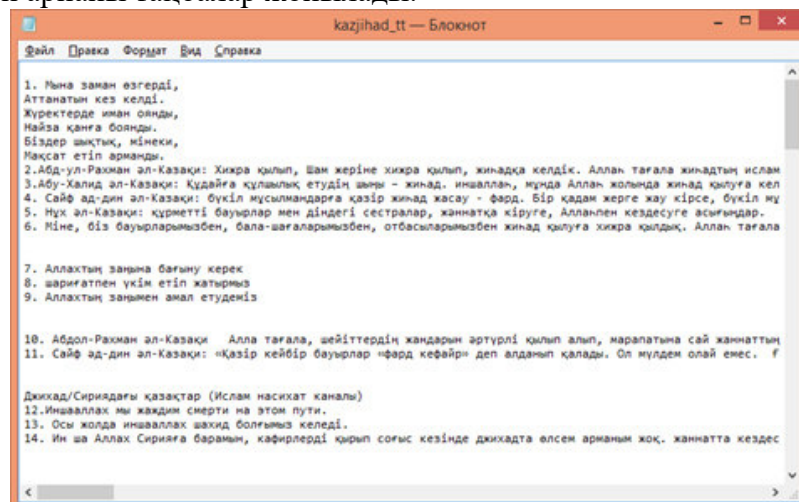
```

6 def checkChar(str):
7     last_char = str[-1]
8     new_str = str[:-1]
9     if last_char == 'б':
10        return new_str + 'п'
11    elif last_char == 'қ':
12        return new_str + 'ғ'
13    elif last_char == 'г':
14        return new_str + 'к'
15    else:
16        return str

```

22-сурет – Қазақ тіліндегі әріптердің өзгеруін тексеру функциясы

Мысал ретінде біз 4400 сөзден тұратын мәтінді қарастырдық (23-сурет). Кіріс мәтіні input.txt файлында сақталады. Арнайы жазылған бағдарлама жоғарыда сипатталғандай, кіріс мәтіндегі сөздердің қосымшаларын бөлу алгоритмін қолданады, алдымен мәтіндегі тыныс белгілері мен арнайы таңбалар жойылады.



23-сурет – Кіріс мәтін

Келесі кезеңде мәтіндегі әр сөздің жұрнағы жоғарыда сипатталған қосымшаларды бөлу алгоритміне сәйкес алынып тасталады, тек негіздер қалады. Кіріс мәтініндегі сөздердің негіздерін анықтау үшін қазақ тіліндегі 24 мың және қазақ тіліндегі 76 мыңға жуық сөздік негіздерден тұратын екі дерекқор пайдаланылды (19-сурет).

салмағы құжаттағы осы сөзді қолдану жиілігіне пропорционал және коллекцияның барлық құжаттарындағы сөзді қолдану жиілігіне кері пропорционал. TF-IDF өлшемі көбінесе мәтінді талдау және ақпаратты іздеу тапсырмаларында, мысалы, кластерлеу кезінде, құжаттардың жақындық өлшемін есептеу кезінде, құжаттың іздеу сұранысына сәйкестігі критерийлерінің бірі ретінде қолданылады. TF-IDF-те белгілі бір құжаттың ішінде жиілігі жоғары және басқа құжаттарда қолдану жиілігі төмен сөздер жоғары мәнге ие болады. TF-IDF әдісі қазақ тілінде құрастырылған корпустық мәтіндердегі кілт сөздерді анықтау үшін қолданылды. Салынған корпуста барлық сөздердің TF-IDF мәндері анықталды. 26-суретте діни сипаттағы сөздер және олардың TF-IDF мәндері көрсетілген.

1	words, TF-IDF
2	алла, 1064.94225986155
3	намаз, 374.3576272057989
4	пайғамбар, 351.0525812347899
5	раббы, 261.4808053326351
6	мұсылман, 229.10748607400885
7	құран, 220.06105622628598
8	аят, 218.08389059261924
9	иман, 208.80295300866857
10	мұхаммед, 199.28104933233564
11	дұға, 181.22857579929922
12	тағала, 178.858674885299
13	ораза, 173.9963381928556
14	дін, 173.26824843258433
15	елші, 172.20982415978003
16	хадис, 171.07026346804878
17	ислам, 160.7247364573076
18	күнә, 157.92112765006047
19	ибн, 145.30556994837147
20	қан, 122.86302521944057
21	тозақ, 116.32048363840886
22	қиямет, 114.50660510201877
23	имам, 112.11613282128268
24	құлшылық, 109.9706927331165
25	сауап, 106.84141213233139
26	періште, 105.84399921405313
27	азап, 102.65485548483262
28	күш, 102.444540432683

26-сурет-TF-IDF мәні бойынша сұрыпталған сөздер


Аталған діни сипаттағы сөздер таңдалды және олар жаңа құжатқа кіріс мәтінді машиналық оқыту әдістерімен жіктеуде маркер ретінде пайдалану үшін сақталды.

3. ВЕБ-РЕСУРСТАРДАҒЫ ЭКСТРЕМИСТІК МӘТІНДЕРДІ АНЫҚТАУҒА АРНАЛҒАН СЕМАНТИКАЛЫҚ ҮЛГІНІ ЗЕРТТЕУ ЖӘНЕ ҚҰРУ

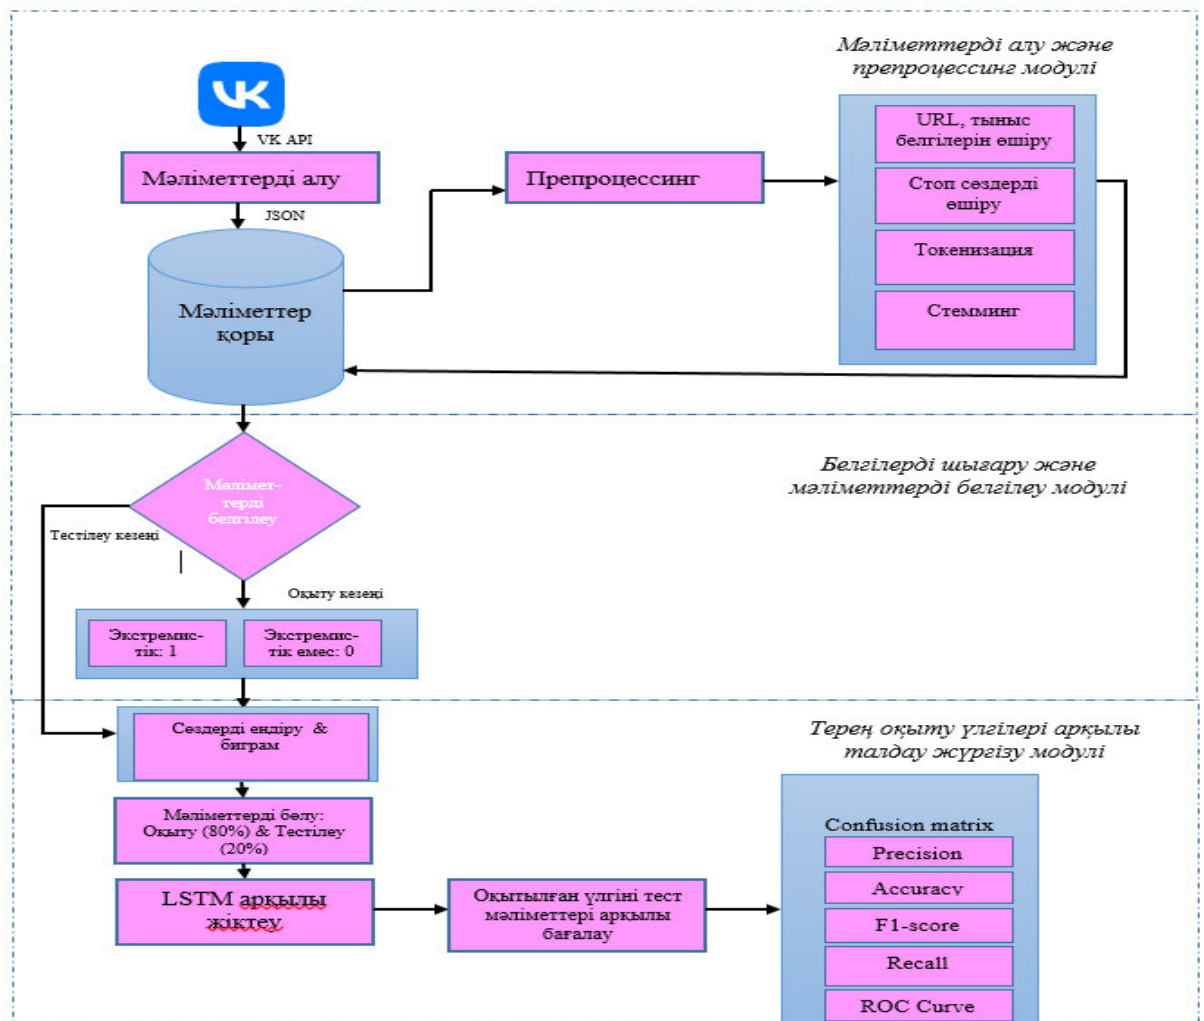
Мәтінді жіктеу – бұл әрбір $(d_j, c_i) \in D \times C$ жұбына логикалық мәнді тағайындау есебі, мұндағы D – құжаттар аймағы, ал $C = \{c_1, \dots, c_{|C|}\}$ – алдын ала анықталған санаттар жиынтығы. (d_j, c_i) -ге тағайындалатын T мәні d_j құжатын c_i -ге жатқызу туралы шешімді, ал F мәні белгілі бір жағдайларға байланысты d_j құжатын c_i -ге жатқызбау туралы шешімді білдіреді. Есептің ресми түрдегі қойылымы белгісіз мақсатты $\Phi: D \times C \rightarrow \{T, F\}$ функциясын (құжаттарды қалай сипаттау керектігін сипаттайтын) классификатор деп аталатын $\Phi: D \times C \rightarrow \{T, F\}$ функциясы арқылы (ереже, гипотеза немесе модель деп аталуы мүмкін) Φ пен Φ «максималды түрде сәйкес келетіндей етіп» жуықтау болып табылады.

$C = \{c_1, \dots, c_{|C|}\}$ бойынша жіктеу D -дағы құжаттарды берілген c_i , мұндағы $i = 1, \dots, |C|$ санатына жіктеудің $|C|$ тәуелсіз есебі ретінде қарастырылады. C_i үшін классификатор деп белгісіз $\Phi_i: D \rightarrow \{T, F\}$ мақсатты функциясын жуықтайтын $\Phi_i: D \rightarrow \{T, F\}$ функциясын атаймыз. (Себастьяни, 2002).- Kennedy

Мәтінді жіктеу есебін шешуге арналған әдістерді келесідей топтарға бөлуге болады:




Бұл бөлімде терең оқыту алгоритмдері көмегімен табиғи тілді өңдеу әдістері негізінде әлеуметтік желідегі қазақ тіліндегі экстремистік бағыттағы мәтіндерді анықтауға арналған жүйенің жалпы архитектурасы келтіріледі. Машиналық және терең оқыту алгоритмдерін оқыту барысында қолданылған белгілерге сипаттама беріледі. Ұсынылған архитектура бірнеше модульдан тұрады: мәліметтерді алу және препроцессинг модулі, белгілерді шығару және мәліметтерді белгілеу модулі және терең оқыту үлгілері арқылы талдау жүргізу модулі.



Ұсынылатын жүйе архитектурасы

3.1 Мәліметтерді алу және преппроессинг модулі

Мәліметтерді алу үшін «ВКонтакте» әлеуметтік желісінің мәліметтер қорынан серверге [https-сұраныстар](https://vk.com/dev/ads) арқылы қажетті ақпаратты алуға мүмкіндік беретін API Вконтакте интерфейсі қолданылды.



Әлеуметтік желі API-мен сұраныстар кітапханасы арқылы байланыс орнатылды. Жұмыс ортасы ретінде Pycharm Community Edition 2018 бағдарламалық жабдықтамасы қолданылды.

Мәтіндегі экстремистік бағытты анықтағанға дейін өңделмеген мәтін бірнеше кадамнан тұратын жіктеуге дейінгі дайындық кезеңдерінен өтуі керек. Берілген архитектура бойынша «ВКонтакте» әлеуметтік желісінен шикі хабарламаларды алу, алдын-ала өңдеу, тазалау, оқыту және тестілеу жинақтарын бөлу, оқыту алгоритмі мен мәтіндерді талдауға арналған табиғи тілді өңдеу үлгісін тестілеу, мәліметтер арасындағы шуды өшіру және мәтінді аннотациялау/белгілеу тапсырмалары орындалады. Мәліметтерді алдын ала өңдеу табиғи тілді өңдеу моделін құрастырудағы өте маңызды кезең болып табылады және бұл кезең үлгінің дәлдігіне тікелей әсер етеді. Бұл шикі мәтіндегі эмоджиларды, пунктуациялық белгілерді, http сілтемелер немесе басқа да әріптік-сандық белгілерге жатпайтын шулы символдарды өшіруді қамтиды. Егер біз кез келген мәтіндік корпусты қарастыратын болсақ, онда ең жиі кездесетін сөздердің ешбір тоналдық күші жоқ стоп сөздер екендігін аңғарамыз. Сол себепті машиналық оқытудың ықтималдық үлгілерімен жұмыс істейтін болғандықтан, аталған сөздерді мәліметтер қорынан өшіру аса маңызды болып табылады. Қазақ тілінен өзге тілген жазылған барлық сөздер, сөйлемдер, сілтемелер, URL мекенжайлары және арнайы белгілер өшірілді.

Бұл жұмыстағы эксперименттерде «ВКонтакте» әлеуметтік желісінен жиналған мәліметтер пайдаланылды. Қосымша ақпаратты пайдаланбай дербес деректердің нақты дербес деректер субъектісіне тиесілігін анықтау мүмкін болмауы үшін дербес деректерді иесіздендірілді.

Мәліметтерге белгі тағайындау үшін эксперттердің көмегі пайдаланылды. Олар әр белгіні тағайындамас бұрын мәліметтер қорындағы әр сөйлемді мұқият оқыды. Бастапқыда мәліметтер қорындағы мәтіндер саны 30000 шамасында болды, алайда кей мәтіндер жіктеу сатысы үшін маңызды мәліметтерді қамтымағандықтан сарапшылар 27000-ға жуық мәтінді өшірді. Мәліметтер қорының көлемі 30000 мәтіннен 2600 мәтінге қысқарды. Ол жердегі мәтіндерге 1 (экстремистік) және 0 (бейтарап) белгілері тағайындалған.

Аталған белгілер эксперт мамандардың көмегімен белгіленді және келесі алгоритм бойынша тағайындалды:

- (1) Әр мәтінді оқып шығып, санат белгісін тағайындау;
- (2) Көп мағыналы мәтіндерді алып тастау;
- (3) Сәйкес мәтіндерді бір санатқа біріктіру, яғни жарылыс, соғысқа қатысу, өлтіру және т.с.с.


(4) Әр мәтінге оқиғалардың екі түрінің бірін, яғни діни экстремизм және бейтарап санаттардың бірін тағайындау.

Әдетте деректердің екі түрі бар: құрылымдалған және құрылымданбаған. Құрылымдық деректерде оның мазмұнын, мағынасын немесе қолданылуын көрсететін әр деректер элементіне қатысты кілттер (атрибуттар, функциялар) бар. Құрылымдық деректердің типтік мысалы – дерекқордағы реляциялық кесте. Атрибут (баған) атауын және оның мәнін ескере отырып, осы мәнді қамтитын түйіндер (жолдар) жиынтығын жасауға болады.

Адамдар күнделікті өмірде пайдаланатын ақпарат негізінен құрылымданбаған түрде болады. Оның көп бөлігі табиғи тілде жазылған мәтіндік құжаттардан (кітаптар, журналдар, газеттер) тұрады.

Мәтінді алу үшін оны деректерді іздеу алгоритмдері қолдана алатын түрге келтіру керек. Олардың қатарына келесі препроцессинг қадамдарын жатқызуға болады: құжатты стандарттау, токенизация, стоп-сөздерді өшіру, стемминг немесе лемматизация және векторлық кеңістік кестесі [104]. Классикалық жіктеу және оқыту алгоритмдері мәтіндік құжаттарды бастапқы түрінде тікелей өңдей алмайды. Осылайша, алдын-ала өңдеу кезеңінде құжаттар басқарылатын түрге келтіріледі.

Деректер жиынтығында жартылай құрылымдалған/құрылымданбаған, көп мөлшердегі қажетсіз мәліметтер бар, олар болжам жасауда маңызды рөл атқармайды. Сонымен қатар, үлкен мәліметтер жиынтығы ұзақ уақыт оқытуды қажет етеді, ал стоп сөздер болжамның дәлдігін азайтады. Сондықтан мәтінді алдын-ала өңдеу есептеу ресурстарын үнемдеу үшін де, болжау дәлдігін арттыру үшін де қажет. Мәтінді алдын-ала өңдеу дәлірек болжауда маңызды рөл атқарады және модельдің жұмысын жоғарылатады. 1-суретте көрсетілгендей алдын-ала өңдеу кезеңінде жүзеге асырылады.



1- сурет. Препроцессинг қадамы

Жіктеу процессіне мағыналық жағынан ықпал етпейтін барлық сөздер стоп сөздер ретінде алынып тасталды, мысалы «және», «ертең», «кеше», «екен» және т.б. Деректерді тазалағаннан кейін және стоп сөздерді өшіргеннен кейін, әр сөйлем бос кеңістік негізінде сөздерге токенизацияланды. Алдыңғы препроцессинг кезеңі көптеген сөйлемдердің ұзындықтарының әр түрлі болатынын көрсетті. Кей сөйлемдер өте қысқа, ал кейбірі өте ұзын болды.

Токенизация: бұл үздіксіз мәтінді сөздерге, символдарға және элементтерге бөлуді (токендер деп аталатын) қамтиды. Бұл кейінгі талдаудың орындалуына айтарлықтай әсер етеді, сондықтан бұл кезең дұрыс және тиімді орындалуы керек.

Стоп сөздерді өшіру: Келесі қадамда мәтіндегі стоп сөздер алынып тасталынады. Стоп сөздер сөйлемдерді оқуды ыңғайлы етсе де, мәтінді талдауда қосымша маңыздылық бермейді. Стоп сөздерді алып тастау жіктеу алгоритмінің тиімділігін арттырады. Көп

жағдайда оларды мәтіннен алып тастауға болады, өйткені олар кейінгі талдау үшін құнды ақпарат бермейді.

Қысқа сөзді өшіру: Мәтіндердегі ұзындығы үштен аспайтын қысқа сөздер алынып тасталады. Кей зерттеулерде оқыту алгоритмдерінің қысқа сөздермен дұрыс жұмыс істемейтіні және егер кіріс мәтінде қысқа сөздер болса, онда ол оның дәлдігіне әсер ететіндігін анықтады. Демек, жіктеуіштердің беріктігі мен тиімділігін арттыру үшін қысқа сөздер алынып тасталады.

Әріпті түрлендіру: қысқа сөздер өшірілгеннен кейін, әлеуметтік желі мәтіндеріндегі әріптер кіші әріпке айналдырылады. Бұл маңызды қадам, өйткені талдау алгоритмі регистрді ескереді. Ықтималдық модельдері, мысалы, «Жаман» және «жаман» сөздерін әр түрлі сөздер деп санайды және олар әр сөздің пайда болуын бөлек-бөлек санайды. Егер сөздер кіші әріпке айналдырылмаса, бұл жіктеуіштің тиімділігін төмендетуі мүмкін. Төменгі регистр - бұл мәтінді алдын-ала өңдеудің кең таралған әдісі. Төменгі регистрды орнату sklearn TfidfVectorizer және Keras Tokenizer сияқты көптеген заманауи векторизаторлар мен токенизаторларда жасалады.

Стемминг: Стемминг – бұл аффикстерді сөздерден алып тастау және сөздерді олардың түбір формасына келтіру процесі. Мысалы, «соғысқа», «соғыста», «соғыстың» дегеніміз бірдей мағынадағы «соғыс» сөзінің морфологиялық өзгерістері болып табылады. Қосымшаларды алып тастау белгілердің күрделілігін азайтуға көмектеседі және жіктеуіштердің оқу қабілетін жақсартады.

@ және басқа да тыныс белгілерін өшіру: мәтінді алдын-ала өңдеудің тағы бір кең таралған әдісі – мәтіндік деректерден тыныс белгілерін жою. Бұл тағы да мәтінді стандарттау процесі, ол "ура" және «ура!» тіркестерін бір тіркес ретінде тану үшін қажет. Сондай-ақ, пайдалану жағдайына байланысты алып тастау үшін тыныс белгілерінің тізімін мұқият таңдау керек. Мысалы, python-да string.punctuation келесі тыныс белгілерін қамтиды: !"#\$%&'()*+,-./:;<=>?@[\\]^_`{|}~. Біздің қажеттіліктерімізге сәйкес көбірек тыныс белгілерін қосуға немесе жоюға болады.

Келесі қадамда мәтіндегі сандық мәндер алынып тасталады, өйткені олар мәтінді талдау үшін ешқандай мәнге ие емес, ал оларды жою модельдерді оқытудың күрделілігін төмендетеді.

3.2 Белгілерді шығару және мәліметтерді белгілеу модулі

Мәтін – ақпарат беру үшін жиі қолданылатын медиа. Көлемді мәтіндердің пайда болуымен ақпараттың шамадан тыс жүктелуі және деректердің артық болуы сияқты проблемалар барған сайын жиі байқалуда. Көрнекі тұрғыдан алғанда, мәтінді визуализациялау – бұл ең маңызды кезең. Осылайша, мәтінді визуализациялау технологиясы мәтіндегі мазмұнды тез алу үшін адамдар визуалды қабылдауға тән параллельді өңдеу мүмкіндіктерін қолдана алатындай етіп, мәтінде айту қиын болатын мазмұн мен ережелерді көрнекі таңбалар түрінде білдіреді.

Мәтінді визуализациялау табиғи тілді өңдеуге негізделген, сондықтан мәтінді талдаудың кең таралған әдістері – сөз теру моделі, аталған нысандарды тану, кілт сөздерді шығару, тақырыпты талдау, тоналдылықты талдау және т. б. Мәтінді талдау процесі негізінен сөздерді сегментациялау, шығару және қалыпқа келтіру сияқты әрекеттерді қолдана отырып, сөздік деңгей мазмұнын шығаратын функцияларды алуды қамтиды, сонымен қатар векторлық кеңістік моделін құру үшін функцияларды қолданады және оны төмен өлшемді кеңістікте көрсету немесе тақырыптарды пайдалану үшін өлшемді азайтады. Модель сипаттамаларды өңдейді және соңында өңделген деректерді визуалды бейнелеу үшін икемді және тиімді түрде ұсынады.

Белгілерді құрастыру – машинаны оқытуға қажетті белгілерді құру үшін пәндік сала мәліметтерін қолдану процесі. Белгілерді құрастыру машиналық оқыту қосымшаларының негізі болып табылады және ол қиын, әрі көп еңбекті талап ететін шара.

Белгі – біз талдайтын немесе болжам жасайтын барлық тәуелсіз нысандарға тән қасиет. Үлгі үшін қажетті кез келген белгі пайдалы болуы мүмкін. Белгі есепті шешуге көмектесетін сипаттама болып табылады.

Мәліметтердегі белгілер болжам жасайтын үлгілер үшін маңызды болып табылады және келешекте алынатын нәтижеге әсер етеді. Белгілердің саны мен сапасы үлгінің сапасына, оның дұрыс болжам жасауына үлкен әсерін тигізеді. Белгі жақсы болған сайын нәтиже де соғұрлым дәлірек болады деуге болады, алайда кей жағдайда нәтиже тек таңдалған белгілерге ғана емес, сонымен қатар үлгі мен мәліметтерге де байланысты болады. Дегенмен, дұрыс белгілерді таңдау өте маңызды.

Белгілерді оқыту – жүйеге белгілерді анықтауға немесе бастапқы (шикі) мәліметтерді жіктеуге қажетті бейнелеулерді автоматты түрде анықтауға мүмкіндік беретін техникалар жинағы. Бұл үдеріс белгілерді қолмен құрастыру есебін алмастырады және машинаға белгілерді зерттеуге де, белгілі бір есептерді шешу үшін оларды пайдалануға да мүмкіндік береді.

Белгілерді оқыту жіктеу сияқты машиналық оқыту есептерінде математикалық және есептеу түрінде өңдеу ыңғайлы болатын кірістің қажет болуымен түсіндіріледі. Алайда сурет, бейнежазба және тетіктердің жазбалары сияқты шынайы мәліметтер аталған есептердің алгоритмдік анықтамасына сай келмейді.

NLP-дағы ең маңызды процесстердің бірі белгілерді таңдау (feature selection) болып табылады. Белгілерді таңдау процесінде модельдің тиімділігі мен өнімділігін арттыру үшін корпустан өзекті және ең пайдалы белгілер алынады. Мәтіндік деректерді бастапқы форматта математикалық алгоритмдерге қолдану мүмкін болмағандықтан, оларды математикалық түрде векторлық форматта ұсынуымыз керек. Белгі мәтінді бірқатар ерекшеліктерге ие векторлық кеңістікке айналдырады. Мәтін форматындағы мәліметтерде көп шу қамтылғандықтан, олар категориялық мәліметтер болып табылады және оны машиналық оқыту негізінде тікелей қолдану мүмкін емес, сондықтан математикалық модельді оқыту кезінде бұл кірістерді тиімді өңдей алатындай етіп мәтіндік деректерді сандық векторлық форматқа ауыстыруымыз керек. Шикі мәтіндік деректерді белгі векторларына (feature vectors) айналдыру белгіні ұсыну (feature representation) деп аталады.

Мәтіндік деректерді векторлық форматта ұсыну үшін сөздердің пакеті Bag of Words (BOW), TF-IDF сияқты көптеген тәсілдер бар. Бұл векторлар тек лексиконға негізделген векторлар, әдетте құжаттағы сөздердің санын немесе оның салыстырмалы салмағын білдіреді. Сөздерді векторлық бейнелеу (word embedding) – тілді модельдеу және табиғи тілді өңдеудегі қандай да бір сөздіктегі сөздерге кішігірім өлшемдегі векторларды сәйкестендіруге бағытталған бейнелеулерді оқытуға арналған әр түрлі тәсілдер кешені.

Кіріс корпусы – пайдаланушылардың хабарламасын білдіретін $D = \{d_1, d_2, d_3 \dots \dots d_n\}$ құжаттар жиынтығы және әр d_i құжатта қолданылатын сөздер саны бойынша әр түрлі ұзындықта болуы мүмкін. Белгілер матрицасында бұл құжаттар ұзындығы $m = |V|$ жоғары өлшемді векторлар ретінде ұсынылған, мұндағы m – сөздік қорының мөлшері.

$d_i = \{w_1, w_2, w_3, \dots \dots w_m\}$, мұндағы w_i d_i құжатында w_i сөзінің бар-жоқтығын көрсететін екілік мәнге ие бола алады.

Белгі векторлары – бұл мәтіннің сандық көрінісі. Бұл машиналық оқыту классификаторы өңдей алатын енгізудің нақты формасы, мәтінді өңдеу үшін қолданылатын белгілерді қалыптастырудың бірнеше әдістері бар. Векторларды жасаудың келесі ерекшеліктері қолданылды.

3.2.1 TF-IDF

Мәтіндік деректерді сандарға ауыстыру қажет және мәтіндік деректерді сандарға өңдеудің кең қолданылатын әдісі – TF-IDF болып табылады. TF-IDF-де мәтіндік мәліметтер векторларға айналады, олар сөздердің реттілігінің нақты дәйектілігін ескермейді. Корпустағы әрбір сөз TF-IDF санымен байланысты, бұл әр сөздің корпус үшін қаншалықты маңызды екендігін көрсетеді.

Сөздерді сандарға айналдырғаннан кейін, TF-IDF сандық мәндері машиналық оқыту әдістері түсіндіре алатын контекстте бақыланатын оқыту жіктеуіштеріне беріледі.

TF-IDF – құжаттағы терминдердің өлшемді векторлық көрінісі. Ол құжатта пайда болған әр терминге салыстырмалы салмақты терминнің дифференциалдау қабілеттілігіне сәйкес тағайындайды, бұл құжатқа тиісті белгіні тағайындауға көмектеседі. TF-IDF бойынша, егер термин корпустағы барлық құжаттарда пайда болса, онда ол онша маңызды емес және оған аз салмақ беру керек, екінші жағынан салыстырмалы түрде аз құжаттарда пайда болса, оған үлкен салмақ беру керек деп есептеледі.

TF (term frequency — сөз жиілігі) — қандай да бір сөздің құжатта кездесуінің құжаттағы барлық сөздер санына қатынасы. t_i сөзінің жеке құжат шеңберіндегі маңыздылығы есептеледі.

$$tf(t, d) = \frac{n_t}{\sum_k n_k}$$

Мұндағы n_t – t сөзінің құжатта кездесу саны, ал бөлімінде берілген құжаттағы сөздердің жалпы саны.

IDF (inverse document frequency — құжаттың кері жиілігі) — қандай да бір сөздің жинақ құжаттарында кездесу жиілігінің инверсиясы. IDF кең қолданылатын сөздердің салмағын азайтады. Нақты бір құжаттар жинағындағы әрбір бірегей сөз үшін бір ғана IDF мәні болады.

$$idf(t, D) = \log \frac{|D|}{|\{d_i \in D \mid t \in d_i\}|}$$

Мұндағы $|D|$ - жинақтағы құжаттар саны, $|\{d_i \in D \mid t \in d_i\}|$ - D жинағындағы t кездесетін құжаттар саны ($n_t \neq 0$) [105-106].

TF-IDF өлшемі екі шаманың көбейтіндісі түрінде есептеледі:

$$tf - idf(t, d, D) = tf(t, d) * idf(t, D)$$

3.2.2 n-грамдар

Берілген жұмыста қолданылған тағы бір белгі – n-грамдық енгізу әдісі. n-gram тиімді техника болып табылады, өйткені ол корпустағы сөздер ретін ұсынады.

N-gram – символдар немесе сөздер қатарынан тұратын токен. Токен мәтіндер корпусы бойымен сырғымалы терезені жылжыту арқылы қалыптасады, терезенің өлшемі токеннің өлшеміне байланысты, ал жылжыту кезең бойынша орындалады, әр кезең сөзге немесе символға сәйкес келеді.

[107] жұмыста n-грам бірнеше сөздің тізбегі ретінде анықталған: 1 грам (униграмма), 2 грам немесе биграмма – екі сөзден құралған тізбек, ал 3 сөз немесе триграмма – үш сөзден құралған тізбек.

Мәтіндік деректерді салмақталған векторға айналдыру және хабарламадағы сөз тізбегіне ықтималдықтарды тиімді бөлу үшін n-граммдық модель қолданылады. N-грамм моделін түсіну үшін хабарламаны мысал ретінде келтірейік, мысалы: «Менің әпкем ауырып жатыр, ол тезірек сауығып кетеді деп үміттенемін». Биграммдық n-граммдық интерпретациясы (бұл жағдай үшін $N - 1 = 1$, сөздің пайда болуын алдыңғы сөзге сүйене отырып болжайды) «менің әпкем», «әпкем ауырып», «ауырып жатыр», «жатыр ол», «ол тезірек», «тезірек сауығып», «сауығып кетеді», «кетеді деп», «деп үміттенемін» түрінде болады.

d_1 және d_2 құжаттарының ұқсастығын олардың n-gram түрінде ұсынулары $S_n(d_1)$ және $S_n(d_2)$ арқылы анықтауға арналған Жаккард коэффициенті келесі теңдеуде келтірілген:

$$sim(d_1, d_2) = \frac{|S_n(d_1) \cap S_n(d_2)|}{|S_n(d_1) \cup S_n(d_2)|}$$

d_1 және d_2 құжаттары бір-бірінің көшірмесі екендігін анықтау үшін шектік мән пайдаланылады. Әрбір қосымша үшін терезенің өлшемі мен ұқсастық шегі тәжірибелер барысында таңдалады [108].

[109] жұмыста n-грам негізіндегі модельді n-грамнің тілдегі ықтималдығын болжау үшін пайдаланылатын ықтималдық моделі деп атаған. Берілген ықтималдықтар негізінде d құжатының белгілі бір c классына тиіс екендігін анықтауға болады:

$$P(c|d) = \prod_{i=1}^n P(w_i|w_{i-n+1}^{i-1})$$

$$P(w_i|w_{i-n+1}^{i-1}) = \frac{freq(w_{i-n+1}^{i-1}w_i)}{freq(w_{i-n+1}^{i-1})}$$

мұндағы freq - n-gram-ның класстағы жиілігін білдіреді.

3.2.3 Bag-of-words

Құжаттар оқыту процесіне жарамды болатын түрде ұсынылуы керек. Мәтінді жіктеуде қолданылатын әдеттегі мәтінді ұсыну схемасы – бұл bag-of-words, ол жерде синтаксис, сөздердің рейтингі және мәтіннің грамматикалық ережелері ескерілмейді. Бұл схема мәтіндік құжаттардың компоненттері арасындағы мағыналық қатынастарды құра алмайды. Берілген әдісті пайдалану барысында құжат әрқайсысы белгілі бір мәліметтер жиынтығынан сөздіктегі терминге немесе сөз тіркесіне сәйкес келетін белгілер векторы түрінде ұсынылады. Белгінің әрбір элементінің мәні терминнің белгінің нақты өлшеміне сәйкес құжаттағы маңыздылығын көрсетеді.

Термин – семантикасы құжаттың негізгі тақырыптарын есте сақтауға мүмкіндік беретін сөз. Әр терминнің салмағы болады. D құжаттар жинағы үшін $V = \{t_1, t_2, \dots, t_{|V|}\}$ – жинақтағы бірегей терминдер жиынтығы, ал t_i – термин болады. V жинағы әдетте жинақ сөздігі деп аталады, $|V|$ - оның көлемі, яғни V-дағы терминдер саны. $d_j \in D$ құжатының әрбір t_i терминінің $w_{ij} > 0$ салмағы болады, d_i құжатында кездеспейтін терминнің салмағы 0-ге тең, $w_{ij} = 0$. Осылайша, әрбір d_j құжаты $d_j = (w_{1j}, w_{2j}, \dots, w_{|V|j})$ терминдер векторы арқылы ұсынылады, мұндағы әрбір w_{ij} салмағы $t_i \in V$ терминіне сәйкес келеді және t_i терминнің d_j құжаттағы маңыздылығын анықтайды [108].

Bag-of-words белгілердің ортогоналдылығына болжам жасайды және сөздердің реті мен грамматиканы елемейді. $C = \{c_1, c_2, \dots, c_{|C|}\}$ – қызығушылық тудыратын класстар, ал $F = \{f_1, f_2, \dots, f_{|F|}\}$ – мәліметтер жинағындағы кем дегенде бір құжатта кем дегенде бір рет кездесетін бірегей функциялар жиынтығы, $T_r = \{d_1, d_2, \dots, d_{|T_r|}\}$ – оқытуға арналған мәтіндік құжаттар жинағы, ал $w(f_i, d_j)$ – d_i құжаттағы f_i нысанының салмағы болсын. d_i құжаты нысанның $d_j = [w(f_1, d_j), \dots, w(f_{|F|}, d_j)]$ салмақ векторы арқылы ұсынылады. Берілген $w(f_i, d_j)$ салмағы d_i құжатын семантикалық сипаттау кезіндегі f_i белгісінің маңыздылығын анықтайды [110].

Мәтіндік құжаттар арасындағы ұқсастық bag-of-words ұсыну негізінде анықталады және мәліметтер қорындағы әрбір құжат пен қолданушы сұранысы көпөлшемді вектор түрінде көрсетілетін векторлық кеңістік моделін пайдаланады.

BOW (Bag of Word) – мәтіндік мәліметтерді N-gram арқылы құжаттар матрицасына түрлендіретін үлгі. N-грамм ықтималдықты тағайындау үшін қарастырылатын сөздердің санына байланысты униграмма, биграмм немесе триграмма болуы мүмкін.

BOW негізіндегі ықтималдық модельдер көбінесе униграмма ерекшеліктерімен жоғары дәлдікке жетеді, бірақ әдетте сөздерді олардың арасындағы қатынастарды ескермей оқшаулайды. BOW-да контекстік ақпаратты қарастырғанмен, биграмм мен триграмма қолданылады, бірақ сөздердің ұзақ мерзімді тәуелділігі жоғалады.

3.2.4 Word2vec

Word2vec – сөз векторларының қысылған кеңістігін құрудың нейрондық желілерді пайдаланатын тәсілі. Ол кіріс ретінде үлкен көлемді мәтіндік корпусты қабылдайды және әр сөзге векторды сәйкестендіреді. Берілген алгоритм бойынша алдымен сөздік құрылады, содан кейін сөздердің векторлық бейнелеуі есептеледі. Векторлық бейнелеу контекстік жақындыққа негізделеді: мәтінде бірдей сөздердің қасында кездесетін (яғни мағыналары ұқсас) сөздер векторлық бейнелеуде жоғары косинустық ұқсастыққа ие болады:

$$\text{similarity}(A, B) = \cos(\theta) = \frac{A * B}{\|A\| \|B\|} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}}$$

Жақында жүргізілген зерттеулерде мәтіндік құжаттарды нейрондық тілдік модельдерді қолдана отырып өңдеу табиғи тілді өңдеу (NLP) тапсырмаларын, оның ішінде сентимент талдау жасауды, лингвистикалық модельдеуді және машиналық аударманы болжау нәтижелерін едәуір арттыра алатынын көрсетеді. Соңғы уақытта мәтіндік бейнелеуді үйрену үшін нейрондық тілдік модельдер қолданылуда, бұл үлкен құрылымданбаған мәтіндік мәліметтерден алынған сөздерді енгізу (word embedding) схемаларының тиімділігіне байланысты болып табылады.

Сөздерді енгізу (word embedding) схемалары аз өлшемді мәтіндік құжаттарды тиімді түрде ұсынуға мүмкіндік береді, осылайша bag-of-words схемасында кездесетін сирек және үлкен өлшемділік проблемаларын жояды, олар мәтіндік мәліметтердің тек синтаксистік қана емес, сонымен қатар семантикалық та ақпаратын қамтиды. Мәтіндік құжаттарды терең оқыту алгоритмдері негізінде жіктеу әдістері белгілерді қалыптастыру кезеңі автоматты түрде орындалатындықтан дәстүрлі машиналық оқыту алгоритмдерімен салыстырғанда тиімді болып келеді.

Word2vec моделі – бұл енгізу қабатынан, шығыс қабатынан және жасырын қабаттан тұратын жасанды нейрондық желіге негізделген сөз ендіру схемасы. Ол белгілі бір сөздің басқа сөздермен еніп кету ықтималдығын анықтау арқылы сөздерді ендіруді үйренуге бағытталған. Модельдің екі негізгі архитектурасы бар, skip-gram (SG) және continuous-bag-of-words (CBOW). CBOW архитектурасы мақсатты сөзді әр сөздің мазмұнын кіріс ретінде қабылдау арқылы анықтайды; SG архитектурасы, керісінше, мақсатты сөзді кіріс ретінде қабылдау арқылы мақсатты сөздің айналасындағы сөздерді болжайды. CBOW архитектурасы мәліметтердің аз мөлшерімен дұрыс жұмыс істей алады.

Осы техникалар арқылы пайда болған векторлар нейрондық желілердің кірістірілген қабатына кіріс ретінде беріледі. Кірістірілген қабаттардың нәтижесі терең оқыту модельдерінің келесі толық қосылған қабатына (тығыз қабат), яғни RNN, CNN және DNN беріледі. Тестілеу / тексеру кезеңінде модельді өңдеу аяқталғаннан кейін әр сөйлемге екі класстан тиісті класс белгісі тағайындалады.

3.3 Терең оқыту үлгілері арқылы талдау жүргізу модулі

3.3.1 Терең оқыту үлгілері

Терең оқыту (ағылш. Deep learning) – машиналық оқыту әдістерінің жиынтығы (оқытушымен, оқытушыны ішінара тарта отырып, оқытушысыз, күшейтілген). Терең оқытудың көптеген әдістері жеткілікті өнімділікке ие және бұрын тиімді шешуге мүмкіндік бермейтін көптеген мәселелерді шешуге мүмкіндік береді, мысалы, компьютерлік көру, машиналық аударма, сөйлеуді тану есептерінде жиі пайдаланылады.

Терең нейрондық желі (ағылш. DNN - deep neural network) – кіру және шығу қабаттары арасындағы бірнеше қабаты бар жасанды нейрондық желі. Терең нейрондық желі сызықтық немесе сызықтық емес корреляцияға қарамастан кірістерді шығысқа айналдыру үшін математикалық түрлендірудің дұрыс әдісін табады. Желі қабаттар бойынша қозғалады, әр қабат үшін шығу ықтималдығын есептейді. Пайдаланушы нәтижелерді қарап, желіні көрсететін ықтималдылықты таңдай алады (мысалы, белгілі бір шектен жоғары) және ұсынылған белгіні желіге қайтара алады. Әрбір математикалық түрлендіру қабаты болып саналады, ал күрделі терең нейрондық желіде көптеген қабаттар бар, сондықтан "терең" желілер деп аталады.

Терең оқыту – бұл көптеген сызықты емес түрлендірулерді қолдана отырып, жоғары деңгейлі абстракцияларды модельдеуге арналған машиналық оқыту алгоритмдері. Ең алдымен терең оқытуға келесі әдістер мен олардың өзгерістері жатады[111-115]:

1. оқытушысыз оқытудың белгілі бір жүйелері, мысалы, Больцманның алдын-ала оқыту машинасы, авто-кодтаушы, терең сенім желісі, генеративті-қарсыласу желісі,


2. оқытушымен бірге оқытудың белгілі бір жүйелері, мысалы, үлгіні тану технологиясын жаңа деңгейге көтерген конвульсиялық нейрондық желі,
3. уақыт өте келе процестерде оқуға мүмкіндік беретін қайталанатын нейрондық желілер,
4. тізбек элементтері мен тізбектер арасындағы кері байланысты қосуға мүмкіндік беретін рекурсивті нейрондық желілер.

Осы әдістерді біріктіре отырып, жасанды интеллекттің әртүрлі міндеттеріне сәйкес келетін күрделі жүйелер жасалады

3.3.2 Рекуррентті нейрондық желілер

Рекуррентті нейрондық желілер (ағылш. Recurrent neural network; RNN) – элементтер арасындағы байланыс бағытталған тізбекті құрайтын нейрондық желілердің түрі. Оның көмегімен уақыт өте келе оқиғалар сериясын немесе дәйекті кеңістіктік тізбектерді өңдеуге болады.


Көпқабатты перцептрондардан ерекшелік ретінде рекуррентті желілер кез келген ұзындықтағы тізбектерді өңдеу үшін өзінің ішкі жадын пайдалана алады. Сол себепті RNN қандай да бір тұтас нәрсе бірнеше сегментке бөлінетін, яғни қолмен жазылған мәтінді тану, тілді тану сияқты есептерді шешуде жиі пайдаланылады. Рекуррентті желілердің бірнеше архитектуралық шешімдері бар. Соңғы уақытта ұзақ және қысқа мерзімдік жады (LSTM) және басқарылатын рекуррентті блок желісі танымалдылыққа ие [116].



Суреттегі нейрондық желінің А бөлігі қандай да Х мәліметтерін кіріс ретінде қабылдайды және қандай да Н мәнін шығыс ретінде қайтарады. Циклдық байланыс желінің алдыңғы қадамындағы ақпаратты келесі қадамға беруге мүмкіндік береді.


Рекуррентті нейрондық желілердің сан алуан түрлері, шешімдері және құрылымдық элементтері бар. Рекурренттік желінің қиындығы егер әрбір уақыт қадамын есепке алу қажет болса, онда әрбір уақыт қадамы үшін жеке нейрондар қабатын құру қажеттілігінде болып табылады, ал бұл өте үлкен есептеу күрделілігін туындатады. Егер есептеуді тіркелген уақыт терезесімен шектейтін болсақ, онда алынған үлгілер трендтің ұзақ мерзімділігін көрсетпейді.

Рекуррентті нейрондық желілер қарапайым нейрондық желілерден аса ерекшеленбейді. Оларды бір желінің бірнеше көшірмесе ретінде елестетуге болады, әрбір көшірме келесі көшірмеге хабарлама жібереді деп есептеледі. Егер циклды ашатын болсақ, ол келесідей көрініске ие болады:



Мұндай «тізбек» рекуррентті нейрондық желілердің тізбектер мен тізімдермен тығыз байланысты екендігіні көрсетеді. Желі әрқайсысы басқа түйіндермен байланысатын түйіндерден тұрады. Уақыт өте келе әр нейронның активация шегі өзгеріп отырады және ол нақты сан болып табылады. Әрбір байланыстың айнымалы нақты салмағы бар. Түйіндер кіріс, шығыс және жасырын болып бөлінеді.


Рекуррентті нейрондық желілердің негізгі артықшылықтарының бірі – ағымдағы есеп үшін бұрын алынған ақпаратты пайдалану мүмкіндігі. Бірақ кей жағдайда ақпарат пен ол қажет етілетін орын арасындағы ара қашықтық алыс болуы мүмкін, өкінішке орай, ара қашықтық ұзарған сайын рекуррентті нейрондық желілер ақпаратты байланыстыруды оқытуға қабілетсіз бола бастайды.




Теориялық тұрғыдан алғанда рекуррентті нейрондық желілер мұндай ұзақ мерзімді тәуелділіктерді өңдей алады, алайда тәжірибелік тұрғыда олар мұндай есептер үшін оқытыла алмайды[116].

3.4.1.1 LSTM желілері

Ұзақ-қысқа мерзімді жады (Long Short Term Memory, LSTM) – рекуррентті нейрондық желілердің ұзақ мерзімді тәуелділіктерді оқуға қабілетті ерекше түрі. Олар көптеген есептерді шешу үшін тиімді пайдаланылады. LSTM ұзақ мерзімді тәуелділіктер мәселесінің алдын алу үшін арнайы жобаланған. LSTM желісі «ұмыту» ұяшығы деп аталатын рекуррентті ұяшықтар арқылы басқарылады. Қателіктер шектелмеген виртуалды қабаттар арқылы уақыт бойынша кері қайтарылады. LSTM-дегі оқыту осылай орындалады, сонымен қатар мыңдаған өткен уақыт мезеттері жайлы ақпарат жадыда сақталады. LSTM желісі 4 нейрондық қабаттан тұрады және олар өзара байланысты болып табылады [116].



Мұнда келесідей белгілеулер енгізілген:




Суреттегі әрбір сызық бір түйіннің шығысындағы векторды келесі түйіндерге кіріс түрінде жібереді. Қызғылт дөңгелектер векторларды қосу сияқты нүктелік операторлар, ал

сары тіктөртбұрыштар нейрондық желінің оқытылған қабаттары болып табылады. Бірігетін сызықтар конкатенацияны, тармақталатын сызықтар олардың көшірілетіндігін және көшірменің әр түрлі орынға жіберілетінін білдіреді.

3.5 Ұсынылатын модель

Ұсынылатын модель – иерархиялық көп сатылы процесс және бірнеше қабаттан тұрады. Бірінші қабат – бұл алдын-ала дайындалған кірістіруді қолдана отырып, сөздерді векторлық кеңістікке бейнелейтін сөз енгізу қабаты. Әрі қарай бейнелеу қабаты орналасады, ол әр мәтінді бейнелеу матрицасын алу үшін LSTM-ді пайдаланады, содан кейін мәтіндер туралы оңтайлы көрініс беру үшін контекст пен ағымдағы сөйлемді бейнелеуді біріктіретін әртүрлі әдістерді қолданады. Келесі қабат – мәтінді жіктеу нәтижесін беретін шығыс деңгей.



3.5.1 Word Embedding Layer – Сөз ендіру қабаты

Сөз ендіру қабаты әр сөзді мағыналық және синтаксистік ақпаратты жинақтай алатын үлкен векторлық кеңістікке бейнелеуге жауапты. Матрицаның әр бағанында сәйкес сөздің ендірілген сөзі сақталады.

Сөздерді векторизациялау (word embedding) – сөздер мен құжаттарды векторлық бейнелеу арқылы ұсынуға арналған әдістер санаты. Вектор сөздің үзіліссіз кеңістікке проекциясын білдіреді. Сөзді векторлық кеңістікте бейнелеу мәтіннен алынады және сөзді пайдалану барысында оның маңында орналасатын сөздерге негізделеді. $X_1, \dots, x_T$ кіріс сөйлемдегі сөздердің тізбегін білдірсін деп есептейік. Біріншіден, біз әр сөздің бекітілген сөзін ендіру үшін сөз векторларын қолданамыз. Осы қабат арқылы сөйлем матрица түрінде ұсынылады: $X \in R_m \times T$, мұндағы m – сөз векторының өлшемі, ал T – сөйлемнің ұзындығы. Біріншіден, сөздерді енгізу модельдерін қолдану арқылы хабарламалардағы сөздер векторларға түрлендіріледі. Содан кейін, сөздер арасындағы контекстік тәуелділіктің қашықтығын зерттеу үшін сөйлемдердегі сөз тізбектері LSTM-ге енгізіледі.

Сөз ендіру қабаты кездейсоқ сандармен инициалданады және оқыту жинағындағы барлық мәліметтер үшін векторизациялау тапсырмасын орындайды. Бұл қабат желідегі алғашқы жасырын қабат және оның үш аргументі бар:

input_dim: мәтіндік мәліметтер сөздігінің өлшемі.


output_dim: сөздер векторизацияланатын векторлық кеңістіктің өлшемі. Ол әрбір сөз үшін осы қабаттағы шығыс векторларының өлшемін анықтайды.

input_length: кіріс тізбектердің ұзындығы.

3.5.2 LSTM-Based Representation – Бейнелеу қабаты.

LSTM желісіндегі негізгі элемент – ұяшық күйі, яғни диаграмманың жоғары жағынан өтетін көлденең сызық. LSTM ұяшық күйіндегі ақпаратты өшіруге немесе оған жаңа ақпаратты қосуға қабілетті, алайда аталған қабілет тетік деп аталатын құрылым арқылы басқарылады. Олар сигмоидтық нейрондық желілерден және нүктелік көбейту операцияларынан тұрады. LSTM-дегі алғашқы қадам ұяшық күйіндегі қай ақпаратты алып тастау қажеттігі туралы шешім қабылдау болып табылады. Бұл шешім «ұмыту тетігі» деп


аталатын сигмоидтық қабат арқылы қабылданады. Оның кірісіне h_{t-1} және x_t мәндері беріледі және шығысында 0 мен 1 арасындағы сан шығарылады.



$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f)$$

Келесі қадам – ұяшық күйінде қандай жаңа ақпаратты сақтау керектігі жайлы шешім қабылдау. Бұл қадам екі бөліктен тұрады. Біріншіден, «кіріс тетігі» деп

аталатын сигмоидтық қабат қандай мәндердің жаңартылатындығы жайлы шешім қабылдайды. Әрі қарай, гиперболалық тангенс қабаты күйге қосылатын жаңа σ_t мәніне үміткерлер векторын құрады және күй үшін жаңартуды алу үшін аталған екі бөлік біріктіріледі.




$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c)$$


Әрі қарай ескі σ_{t-1} ұяшық күйін жаңа σ мәнімен жаңартатын уақыт келеді.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$



Келесі қадамда шығыс ретінде шығарылатын мәндер жайлы шешім қабылданады. Алдымен шығысқа ұяшық күйінің қандай бөліктері жіберілетіні жайлы шешім қабылдайтын сигмоидтық қабат іске

қосылады. Әрі қарай ұяшық күйі гиперболалық тангенс қабатынан өтеді (мәндерді -1 және 1 аралығына сыйдыру үшін) және ол сигмоидтық тетік шығысына көбейтіледі [116].



$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$$

$$h_t = o_t + \tanh(C_t)$$

Берілген LSTM нейрондық желісіндегі гиперболалық тангенс активациялау функциясы келесі формула бойынша есептеледі:

$$\tanh(x) = \frac{2}{1 + e^{-2x}} - 1$$

мұндағы i, f, o, c – кіріс күйі, ұмыту күйі, шығыс күйі, жады ұяшығы, x – ұяшықтарды активациялаудың кіріс векторы, h – жасырын вектор, W_i – жасырын кіріс элементтер матрицасы, W_o – кіріс және шығыс элементтер матрицасы, b – базалық вектор.

Бұл архитектурада бірінші LSTM қабаты екінші LSTM қабатына беріледі, ол жерде бастапқы сөйлемнің тереңдетілген бейнесі құрылады. LSTM қабаттарының ақырғы нәтижесі бір матрицаға біріктіріледі, бұл матрица толық байланысқан қабатқа жіберіледі [116].

3.5.3 Үлгінің гиперпараметрлері

Эмпирикалық түрде әртүрлі гипер-параметрлер тексерілді. LSTM конфигурациясы үшін жасырын күй өлшемі 128-ге тең, активация функциясы ретінде ReLU қолданылған. Барлық сәулеттегі эпохалар саны 200 болып белгіленді.

Оқытудың бірнеше кезеңінен кейін біз мәтінді жіктеу моделін ала аламыз.

Ұсынылған нейрондық желі LSTM жіктеуші арқылы бағаланады. Оңтайландыру ретінде Adam алгоритмі алынды. Жоғалту функциясы – binary_crossentropy. Бинарлы кросс-энтропия келесі формула бойынша есептеледі:

$$H_p(q) = -\frac{1}{N} \sum_{i=1}^N y_i * \log(p(y_i)) + (1 - y_i) * \log(1 - p(y_i))$$

Шығыс қабатта тесттік мәліметтер экстремистік немесе бейтарап класстардың біріне жіктеледі.

3.5.4 Үлгіні бағалау параметрлері

Үлгі құрастырылғаннан кейін оның өнімділігін бағалау керек. Тиісті бағалау өте маңызды, өйткені жіктеушінің дәлдігін білместен оны нақты тапсырмаларда қолдануға болмайды. Жіктеушіні бағалаудың көптеген әдістері, сонымен қатар көптеген көрсеткіштері бар. Негізгі көрсеткіш - бұл тест жиынтығындағы дұрыс жіктелген даналардың саны, ол тест жиынтығындағы даналардың жалпы санына бөлінеді [108].

Машиналық оқыту тапсырмаларында метрикалар модельдердің сапасын бағалау және әр түрлі алгоритмдерді салыстыру үшін қолданылады. Мұнда біз жіктеу мәселелеріндегі кейбір сапа критерийлерін қарастырамыз.

Accuracy

Қарапайым жағдайда, мұндай метрика жіктеуші дұрыс шешім қабылдаған құжаттардың үлесі бола алады.

$$Accuracy = \frac{P}{N}$$

мұндағы, P – жіктеуші дұрыс шешім қабылдаған құжаттар саны, ал N - оқу таңдамасының мөлшері.

Дәлдік және толықтық (Precision and Recall)

Дәлдік пен толықтық – бұл ақпарат алудың көптеген алгоритмдерін бағалауда қолданылатын өлшемдер. Кейде олар өздігінен қолданылады, кейде F-шама немесе R-Precision сияқты туынды метрикаларға негіз бола алады. Дәлдік пен толықтықтың мәні өте қарапайым болып табылады.

Жүйенің дәлдігі дегеніміз – жүйенің берілген санатқа тағайындаған барлық құжаттарының шын мәнінде сол санатқа жататын құжаттар ішіндегі үлесі.

Жүйенің толықтығы дегеніміз – жіктеуші берілген санатқа жатады деп анықтаған құжаттардың тесттік жинақтағы сол санаттың барлық құжаттарына қатынасы.

Бұл мәндерді әр санат үшін бөлек құрастырылатын контингенттік кестесі негізінде оңай есептеуге болады [117].

$$Precision = \frac{TP}{TP+FP}$$

$$Recall = \frac{TP}{TP+FN}$$

мұндағы TP – ақиқат оң нәтиже, классификатор объектіні қарастырылып отырған сыныпқа дұрыс жатқызды.

$$TP_i = T_i$$

FP – жалған оң нәтиже, классификатор объектіні қарастырылып отырған сыныпқа қате жатқызады.

$$FP_i = \sum_{c \in \text{Classes}} F_{i,c}$$

FN – жалған теріс нәтиже, классификатор объект қарастырылып отырған сыныпқа жатпайды деп қате болжам жасайды.

$$FN_i = \sum_{c \in \text{Classes}} F_{c,i}$$

TN – ақиқат теріс нәтиже, классификатор объект қарастырылып отырған сыныпқа жатпайды деп дұрыс болжам жасайды [118].

$$TN_i = All - TP_i - FP_i - FN_i$$

Confusion Matrix (дәлсіздік матрицасы)

Іс жүзінде дәлдік пен толықтық мәндерін дәлсіздік матрицасын пайдаланып есептеу әлдеқайда ыңғайлы (confusion matrix). Егер санаттардың саны салыстырмалы түрде аз болса (100-150 санаттан артық емес), бұл тәсіл классификатор жұмысының нәтижелерін жеткілікті түрде айқын көрсетуге мүмкіндік береді.

Дәлсіздік матрицасы N-ға N матрица, мұндағы N – класстар саны. Бұл матрицаның бағандары сарапшылардың шешімдері үшін, ал жолдар жіктеуіштердің шешімдері үшін сақталған.

Мұндай матрица болған жағдайда әр сынып үшін дәлдік пен толықтық өте қарапайым есептеледі. Дәлдік матрицаның сәйкес диагональды элементінің және санаттың барлық жолдарының қосындысының қатынасына тең. Толықтық – матрицаның диагональды элементінің және сыныптың барлық бағанының қосындысының қатынасына тең. Жіктеуіштің алынған дәлдігі оның барлық кластары үшін дәлдігінің орташа арифметикалық мәні ретінде есептеледі. Толықтық та дәл осылай есептеледі. Техникалық тұрғыдан бұл тәсілді макроорташа деп атайды.

F-өлшем

Дәлдік пен толықтық неғұрлым жоғары болса, соғұрлым жақсы болатыны анық. Бірақ нақты өмірде максималды дәлдік пен толықтыққа бір уақытта қол жеткізу мүмкін емес, сондықтан белгілі бір тепе-теңдікті іздеу керек. Сондықтан, алгоритмнің дәлдігі мен толықтығы туралы ақпаратты біріктіретін қандай да бір көрсеткіш болуы керек. F-өлшем дәл осындай метрика болып табылады.

F өлшем – дәлдік пен толықтық арасындағы гармоникалық орташа мән. Егер дәлдік немесе толықтық нөлге ұмтылса, ол да нөлге ұмтылады.

$$F - \text{Measure} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}}$$

Бұл формула дәлдік пен толықтыққа бірдей салмақ береді, сондықтан F өлшемі дәлдік пен толықтықтың төмендеуімен бірдей болады.

$$F - \text{Measure} = (\beta^2 + 1) * \frac{\text{Precision} * \text{Recall}}{\beta^2 * \text{Precision} + \text{Recall}}$$

Дәлдікке басымдық берілетін жағдайда мұндағы β , $0 < \beta < 1$ диапазонындағы мәндерді қабылдайды, ал $\beta > 1$ толықтыққа басымдық береді. $\beta = 1$ болған кезде формула алдыңғы формулаға келеді және теңдестірілген F өлшемін алынады (оны F1 деп те атайды).

ROC қисығы астындағы аудан (AUC)

ROC қисығы (receiver operating characteristics, қабылдағыштың жұмыс сипаттамасы) – бұл әр түрлі шекті параметрлердегі жіктеу мәселелеріне арналған өнімділікті өлшеу белгісі. ROC – бұл ықтималдық қисығы, ал AUC бөліну дәрежесін немесе өлшемін білдіреді. Бұл өлшем модельдің санаттарды қаншалықты ажырата алатындығын айтады. AUC неғұрлым жоғары болса, модель 0 классты 0 және 1 классты 1 деп болжауды неғұрлым жақсы жүргізеді [117].

3.6 Эксперименталды бөлім

Бұл бөлімде TF-IDF+биграммдар, Word2vec+биграммдар және Bag of Words+биграммдарға негізделіп құрастырылған үш түрлі әдіс бойынша олардың ішіндегі тиімдісін анықтауға қатысты жүргізілген зерттеу нәтижелері келтіріледі.

LSTM негізіндегі терең оқыту үлгісінің кірісіне алдымен Tf-idf және биграммдар комбинациясы берілді. Эксперимент нәтижесінде мәтіндерді экстремистік және бейтарап санаттарға жіктеу дәлдігі 0.87, F1-шама 0.87 құрады.

	precision	recall	f1-score	support
0	0.86	0.91	0.89	293
1	0.88	0.82	0.85	232
accuracy			0.87	525
macro avg	0.87	0.87	0.87	525
weighted avg	0.87	0.87	0.87	525

```
from sklearn.metrics import roc_auc_score
auc = roc_auc_score(y_val, y_pred_bool)
print('AUC: %.3f' % auc)
```

AUC: 0.874

Дәлсіздік матрицасы нақты мақсатты мәндерді машиналық оқыту моделі болжайтын мәндермен салыстырады. Бұл бізге жіктеу моделінің қаншалықты жақсы жұмыс істейтіндігі және қандай қателіктер жіберетіндігі туралы көрініс береді. Мақсатты айнымалының екі мәні бар: оң немесе теріс. Бағандар мақсатты айнымалының нақты мәндерін білдіреді. Жолдар мақсатты айнымалының болжамды мәндерін білдіреді.




Нақты оң (TP) = 2.7e+02 (733); 560 оң класс деректері модель бойынша дұрыс жіктелген.

Нақты теріс (TN) = 1.9e+02 (516); 516 теріс класс деректері модель бойынша дұрыс жіктелген.

Жалған оң (FP) = 25; теріс кластағы 25 дерек модель бойынша оң классқа жатады деп дұрыс жіктелмеген

Жалған теріс (FN) = 42; оң кластағы 42 дерек модель бойынша теріс классқа жатады деп қате жіктелген.

Осы белгілер бойынша жіктеудің AUC-ROC түріндегі нәтижесі төмендегі суретте келтірілген:



AUC мәні 0.87 құрайтындығын көреміз, бұл жіктеуіштің оң сынып мәндерін теріс сынып мәндерінен ажырата алуының үлкен мүмкіндігі бар екендігін көрсетеді.

Келесі кезекте терең оқыту алгоритмдерінің кірісіне Word2vec және биграмдар комбинациясын беру арқылы келесі нәтижелер алынды:


	precision	recall	f1-score	support
0	0.66	0.96	0.78	257
1	0.91	0.40	0.56	217
accuracy			0.71	474
macro avg	0.78	0.68	0.67	474
weighted avg	0.77	0.71	0.68	474

```
from sklearn.metrics import roc_auc_score
auc = roc_auc_score(y_val, y_pred_bool)
print('AUC: %.3f' % auc)
```

AUC: 0.686

Эксперимент нәтижесінде мәтіндерді экстремистік және бейтарап санаттарға жіктеу дәлдігі 0.71, f1-шама 0.68 құрады.

Word2vec және биграмдар нәтижесінде алынған дәлсіздік матрицасы төменде келтірілген.



Нақты оң (TP) = 2.5e+02 (680); оң класстың 680 дерегі модель бойынша дұрыс жіктелген.


Нақты теріс (TN) = 87; 87 теріс класс деректері модель бойынша дұрыс жіктелген.

Жалған оң (FP) = 9; теріс кластағы 9 дерек модель бойынша оң классқа жатады деп дұрыс жіктелмеген

Жалған теріс (FN) = $1.3e+02$ (353) ; оң кластағы 353 дерек модель бойынша теріс классқа жатады деп қате жіктелген.

Матрицадан көріп тұрғанымыздай, Word2vec және биграммдарды қолдану барысында модельдегі жалған теріс нәтижелердің саны өте үлкен (353 дерекке дұрыс жіктеу жасалмаған). Берілген нәтижеге сүйеніп, аталған белгілер комбинациясын экстремистік мәтіндерді жіктеуде қолданудың тиімсіз екендігін көруге болады.

Осы белгілер бойынша жіктеудің AUC-ROC түріндегі нәтижесі төмендегі суретте келтірілген:



AUC шамасы 0.68-ді құрайды, бұл жіктеуіш позитивті және негативті класс нүктелерін ажыратуда жақсы нәтиже көрсетпейтіндігін білдіреді (0.5 шамасына жақын болған сайын, жіктеуіш өнімділігі төмен деп бағаланады). Жіктеуіш барлық деректер үшін кездейсоқ классты немесе тұрақты класты болжайтын болады. Жіктеуіш үшін AUC мәні неғұрлым жоғары болса, оның оң және теріс кластарды ажырата білу қабілеті соғұрлым жоғары болады.


Эксперименттің келесі бөлімінде мәтіндерге терең оқыту алгоритмдері негізінде Bag of words және биграмм белгілерін қолдану арқылы жіктеу жүргізілді, аталған әдіс келесідей нәтижелер көрсетті:

	precision	recall	f1-score	support
0	0.74	0.98	0.85	293
1	0.96	0.57	0.72	232
accuracy			0.80	525
macro avg	0.85	0.78	0.78	525
weighted avg	0.84	0.80	0.79	525

```
from sklearn.metrics import roc_auc_score
auc = roc_auc_score(y_val, y_pred_bool)
print('AUC: %.3f' % auc)
```

AUC: 0.785

Модельдің дәлдігі 0.8, f1-өлшем 0.79 құрайды. Аталған белгілерді қолдану кезіндегі дәлсіздік матрицасы төмендегі суретте келтірілген:




Нақты оң (TP) = 2.9×10^2 (788); оң класстың 788 дерегі модель бойынша дұрыс жіктелген.

Нақты теріс (TN) = 1.3×10^2 (353); теріс класстың 353 дерегі модель бойынша дұрыс жіктелген.

Жалған оң (FP) = 5; теріс кластағы 5 дерек модель бойынша оң классқа жатады деп дұрыс жіктелмеген.

Жалған теріс (FN) = 99 ; оң кластағы 99 дерек модель бойынша теріс классқа жатады деп қате жіктелген.


Bag of words және биграмдар әдісінде да жалған теріс нәтижелердің жиі кездесетінін байқаймыз. Дегенмен, жіктеу нәтижелері бойынша белгілерді экстремистік мәтіндерді анықтау есебіне пайдалануға болады деп есептейміз. Аталған белгілер комбинациясы кезіндегі AUC-ROC нәтижесі төмендегі суретте келтірілген:



AUC шамасы 0.78 құрайды, бұл жіктеуіштің Word2vec және биграмдар әдісімен салыстырғанда Bag of words және биграмдар әдісі негізінде жақсырақ жұмыс істейтіндігін көрсетеді.

Мәтінді TF-IDF, Word2vec, Bag of words және биграмдар әдісі негізінде жіктеудің салыстырмалы нәтижелері кестеде және диаграмма түрінде көрсетілген.

Терең оқыту алгоритмінде қолданылған белгілер	Accuracy	F1-Score	AUC
Tf-idf+bigram	0.87	0.87	0.87
Word2vec+bigram	0.71	0.68	0.68
Bag of words+bigram	0.80	0.79	0.78




Кестеден көріп тұрғанымыздай, Tf-idf+bigram әдісі барлық бағалау параметрлері бойынша ең жақсы нәтижені көрсетті (модель дәлдігі 0.87, f1-шама 0.87 және AUC мәні 0.87). Эксперимент нәтижелері бойынша екінші кезектегі тиімді үлгі Bag of words+bigram негізіндегі үлгі болып есептеледі, модель дәлдігі 0.8, f1-шама 0.79, AUC мәні 0.78 құрайды. Ал Word2vec+bigram негізіндегі үлгі берілген тапсырма үшін аса тиімді болмайды, себебі жіктеу нәтижелері төмен көрсеткіштерді көрсетті, соның ішінде AUC мәні 0.68 құрайды, ал бұл берілген үлгінің оң және теріс класс деректерін айқын ажырату қабілетінің төменірек екендігін көрсетеді.

Аталған алгоритмдердің дәлдігін арттыру мақсатында қазақ тіліне арналған стемминг алгоритмі қолданылды. Стемминг алгоритмін қолдану нәтижесінде Tf-idf+bigram белгілерінің комбинациясы келесідей нәтиже көрсетті.

	precision	recall	f1-score	support
0	0.89	0.95	0.92	293
1	0.93	0.84	0.88	232
accuracy			0.90	525
macro avg	0.91	0.90	0.90	525
weighted avg	0.90	0.90	0.90	525

Яғни, стеммерсіз жіктеумен салыстырғанда үлгінің дәлдігі 0.87-ден 0.9-ға, f1-өлшемнің 0.87-ден 0.9-ға жоғарылағандығын байқаймыз. Tf-idf+bigram+стемминг нәтижесінде алынған дәлсіздік матрицасы төменде келтірілген:



Нақты оң (TP) = 2.8e+02 (761); оң класстың 761 дерегі модель бойынша дұрыс жіктелген.


Нақты теріс (TN) = $2e+02$ (544); теріс класстың 544 дерегі модель бойынша дұрыс жіктелген.

Жалған оң (FP) = 15; теріс кластағы 15 дерек модель бойынша оң классқа жатады деп дұрыс жіктелмеген.

Жалған теріс (FN) = 36 ; оң кластағы 36 дерек модель бойынша теріс классқа жатады деп қате жіктелген.

Нақты оң, нақты теріс, жалған оң және жалған теріс нәтижелердің стеммерсіз жағдаймен салыстырғанда жақсарғандығын аңғарамыз.

AUC шамасы 0.90 құрайды, берілген шама стеммерсіз жағдаймен салыстырғанда 0.87-ден 0.90 шамасына дейін артқан.




Бұл нәтиже жіктеуіштің оң және теріс класстарды ажырату өнімділігінің жоғарылағандығын білдіреді.

Келесі кезекте белгілеріне стеммер қосылып, келесідей нәтиже алынды.

	precision	recall	f1-score	support
0	0.65	0.94	0.77	262
1	0.85	0.42	0.56	228
accuracy			0.69	490
macro avg	0.75	0.68	0.66	490
weighted avg	0.74	0.69	0.67	490

Модельдің дәлдігі 0.69, f1-шама 0.67 құрайды. Бұл әдісте стеммерсіз жағдаймен салыстырғанда керісінше модель нәтижелерінің төмендегенін байқаймыз.



Нақты оң (TP) = $2.4e+02$ (652); оң класстың 652 дерегі модель бойынша дұрыс жіктелген.


Нақты теріс (TN) = 95; теріс класстың 95 дерегі модель бойынша дұрыс жіктелген.

Жалған оң (FP) = 17; теріс кластағы 17 дерек модель бойынша оң классқа жатады деп дұрыс жіктелмеген.

Жалған теріс (FN) = $1.3e+02$ (353) ; оң кластағы 353 дерек модель бойынша теріс классқа жатады деп қате жіктелген.

Стеммерсіз жағдаймен салыстырғанда нақты оң, нақты теріс нәтижелердің төмендеп, жалған оң және жалған теріс нәтижелердің артқанын аңғарамыз.

AUC шамасы 0.68 құрайды, берілген нәтиже стеммер қолданылған жағдайда да Word2vec+bigram комбинациясының мәтінді жіктеуде әлі де төмен нәтиже көрсететінін білдіреді.



Келесі кезекте Bag of words+bigram белгілерімен қатар стеммерді қолдану келесідей нәтиже көрсетті. Үлгінің дәлдігі 0.80-нен 0.84-ке, f1-шама 0.79-дан 0.84-ке дейін көтерілді.

precision recall f1-score support

0	0.80	0.96	0.87	293
1	0.93	0.69	0.79	232

accuracy			0.84	525
macro avg	0.86	0.82	0.83	525
weighted avg	0.86	0.84	0.84	525



Нақты оң (TP) = 2.8e+02 (761); оң класстың 761 дерегі модель бойынша дұрыс жіктелген.


Нақты теріс (TN) = 1.6e+02 (435); теріс класстың 435 дерегі модель бойынша дұрыс жіктелген.

Жалған оң (FP) = 12; теріс кластағы 12 дерек модель бойынша оң классқа жатады деп дұрыс жіктелмеген.

Жалған теріс (FN) = 72; оң кластағы 72 дерек модель бойынша теріс классқа жатады деп қате жіктелген.

Стеммерсіз Bag of words+bigram жағдайымен салыстырғанда нақты оң және жалған теріс нәтижелердің азайып, нақты теріс және жалған оң нәтижелердің артқанын байқаймыз.

AUC шамасы стеммерсіз жағдаймен салыстырғанда 0.78-ден 0.82-ге көтерілді.




Берілген нәтиже стеммерді қолданған жағдайда Bag of words+bigram белгілері әдісі модельдің жұмыс өнімділігінің жақсара түсетіндігін көрсетеді.

Мәтінді TF-IDF, Word2vec, Bag of words және биграммдар әдісі және стемминг алгоритмі негізінде жіктеудің салыстырмалы нәтижелері кестеде көрсетілген.

Терең оқыту алгоритмінде қолданылған белгілер	accuracy	F1-Score	AUC-ROC
Tf-idf+bigram+стемминг	0.90	0.90	0.90
Word2vec+bigram+стемминг	0.68	0.67	0.68
Bag of words+ bigram +стемминг	0.84	0.84	0.82

Кестеден көріп тұрғанымыздай, TF-IDF, Word2vec, Bag of Words және биграммалармен қатар стемминг алгоритмін қолдану мәтінді терең оқыту үлгісі негізінде жіктеу есебінің дәлдігін жоғарылататындығы анықталды. Атап айтатын болсақ, стемминг алгоритмін қосу модель дәлдігін Tf-idf+bigram жағдайында 0.87-ден 0.90-ға дейін, f1-шама мәнін 0.87-ден 0.90-ға дейін, AUC мәнін 0.87-ден 0.897-ге дейін және Bag of words+ bigram жағдайында модель дәлдігін 0.80-нен 0.84-ке дейін, f1-шама мәнін 0.79-дан 0.84-ке дейін, AUC мәнін 0.78-ден 0.82-ге дейін арттыруға мүмкіндік берді. Ал Word2vec+bigram жағдайында керісінше модель дәлдігі 0.71-ден 0.68-ге, f1-шама мәні 0.68-ден 0.67-ге дейін төмендесе, AUC мәні 0.68 деңгейінде сақталды.



Қорытындылай келе айтатын болсақ, экстремистік мәтіндерді анықтауға арналған үш түрлі үлгі құрылды. Ұсынылған үлгілер бойынша бірқатар эксперименттер орындалды. Жүргізілген эксперименттер нәтижесінде веб-ресурстардағы экстремистік мазмұндағы мәтіндерді анықтау үшін TF-IDF+биграммалар белгілерімен қатар стеммер

алгоритмі көмегімен терең оқыту алгоритмдеріне негізделетін үлгі ұсынылады. Аталған белгілер комбинациясы эксперименттер барысында барлық бағалау параметрлері бойынша жоғары нәтиже көрсетті.

4. МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІНЕ САЛЫСТЫРМАЛЫ ТАЛДАУ

Машиналық оқыту (ағылш. machine learning, ML) - жасанды интеллект әдістерінің класы, оған тән белгі мәселені тікелей шешу емес, көптеген ұқсас мәселелердің шешімдерін қолдану арқылы оқыту болып табылады. Мұндай әдістерді құру үшін математикалық статистика, сандық әдістер, математикалық талдау, оңтайландыру әдістері, ықтималдықтар теориясы, графикалық теориялар, сандық түрдегі деректермен жұмыс істеудің әртүрлі әдістері қолданылады [119].

Мәліметтерді талдауға негізделген машиналық оқыту технологиясы 1950 жылы, дойбы ойынына арналған алғашқы бағдарламалар жасала бастаған кезден басталады. Компьютерлердің есептеу күшінің өсуіне байланысты олардың құратын заңдылықтары мен болжамдары бірнеше есе күрделене түсті және машиналық оқытудың көмегімен шешілетін мәселелер мен есептер ауқымы кеңейді.

Оқытудың келесідей түрі бар:

1. Прецеденттер бойынша оқыту немесе индуктивті оқыту деректердегі эмпирикалық заңдылықтарды анықтауға негізделген.

2. Дедуктивті оқыту сарапшылардың білімін формализациялауды және оларды білім базасы түрінде компьютерге беруді қамтиды.

Бақыланатын оқыту – бұл ең көп таралған жағдай. Әр жағдай "объект, жауап" жұбы болып табылады. Жауаптардың объектілердің сипаттамаларына функционалды тәуелділігін табу және объектінің сипаттамасын кіріс ретінде қабылдап, шығыста жауап қайтаратын алгоритм құру қажет болады. Сапа функционалы әдетте барлық үлгі объектілері үшін алгоритм құрған жауаптардың орташа қателігі ретінде анықталады.

○ Жіктеу есебі мүмкін болатын жауаптар жиынтығының ақырлы болуымен ерекшеленеді. Оларды класс белгілері деп атайды. Класс - бұл белгі мәліметі бар барлық объектілер жиынтығы.

○ Регрессия есебі жауаптың нақты сан немесе сандық вектор болуымен ерекшеленеді.

○ Дәреже тағайындау (learning to rank) есебі жауаптардың бірден объектілер жиынтығында алынып, содан кейін жауаптардың мәндері бойынша сұрыпталуымен ерекшеленеді. Жіктеу немесе регрессия есептеріне дейін қысқартылуы мүмкін. Ол көбінесе ақпаратты іздеуде және мәтінді талдауда қолданылады.

○ Болжау есебі (forecasting) объектілердің болашаққа болжам жасау қажет болған уақыт қатарының сегменттері болуымен ерекшеленеді. Болжау есебін шешу үшін регрессияны немесе жіктеу әдістерін бейімдеуге болады.

Бақыланбайтын оқыту. Бұл жағдайда жауаптар берілмейді және объектілер арасындағы тәуелділікті іздеу керек болады.

○ Кластерлеу есебі объектілердің жұптық ұқсастығы туралы деректерді қолдану арқылы оларды кластерге топтастыруды қарастырады. Сапа функционалын әр түрлі әдіспен, мысалы, орташа кластераралық және кластерішілік арақашықтықтардың қатынасы ретінде анықтауға болады.

○ Қауымдастық ережелерін іздеу есебі (association rules learning).

Бастапқы мәліметтер сипаттамалар түрінде ұсынылады.

Бекіту арқылы оқыту. Нысан ретінде «жағдай, қабылданған шешім» жұптары қарастырылады, жауаптар - қабылданған шешімдердің дұрыстығын сипаттайтын функционалды сапа мәндері (қоршаған ортаның реакциясы). болжау есебіндегідей, мұнда да уақыт факторы маңызды рөл атқарады. Қолданбалы есептердің мысалдары: инвестициялық стратегияларды қалыптастыру, технологиялық процестерді автоматты басқару, роботтарды өздігінен оқыту және т.б. [120]

Оқыту барысында пайдаланылатын мәліметтер жинағы $A = \{A_1, A_2, \dots, A_{|A|}\}$ атрибуттар жиынтығы арқылы сипатталады, мұндағы $|A|$ атрибуттар санын немесе A жинағының өлшемін білдіреді. Сонымен қатар, мәліметтер жинағында класс атрибуты деп

аталатын арнайы мақсатты C атрибуты болады. C класс атрибуты дискретті мәндер жинағына ие, яғни $\{c_1, c_2, \dots, c_{|C|}\}$, мұндағы $|C|$ - класстар саны және $|C| \geq 2$. Класс мәні класс белгісі деп те аталады.

Оқытуға арналған мәліметтер жинағы – реляциялық кесте. Әрбір мәліметтер жазбасы машиналық оқыту тілінде мысал, экземпляр, оқиға немесе вектор деп аталады.

Мәліметтер жинағы негізінен мысалдардан тұрады. Оқыту мақсаты – D мәліметтер жинағын ескере отырып, A -дағы атрибуттар мен C -дағы класстардың мәндерін сәйкестендіруге арналған жіктеу/болжау функциясын құру болып табылады. Аталған функция болашақта кездесетін жаңа мәліметтердің класстарының мәндерін болжау үшін пайдаланылады. Бұл функция жіктеу моделі немесе классификатор деп аталуы да мүмкін.

Оқыту үшін қолданылатын мәліметтер жиынтығы оқыту деректері (немесе оқыту жиынтығы) деп аталады. Модель оқыту алгоритмі арқылы оқыту деректері негізінде зерттелгеннен немесе құрастырылғаннан кейін, модельдің дәлдігін бағалау үшін тестілік мәліметтер жиынтығымен (немесе көрінбейтін мәліметтермен) бағаланады. Тест деректері жіктеу моделін зерттеуде пайдаланылмайды.

Тестілік деректердегі мысалдарда әдетте класс белгілері болады. Оқыту және тестілеу үшін қол жетімді мәліметтер (класстары бар) әдетте екі қиылыспайтын ішкі жиындарға бөлінеді: оқыту жиынтығы (оқыту үшін) және тест жиынтығы (тестілеу үшін) [108].

Диссертациялық жұмыстың мақсатына сай дәстүрлі машиналық оқыту әдістерін қолдану арқылы эксперименттер жүргізілді. Веб-ресурстардағы экстремистік мәтіндерді анықтау үшін шешім ағашы (DT), мультиномиялық Naive Bayes (NBM), кездейсоқ орман (RF), сызықтық регрессия (LR) және тірек векторлар машинасы (SVM) сияқты дәстүрлі әдістер қолданылып, олардың жіктеу нәтижелері салыстырылды.

4.1 Тірек векторлар машинасы.

Тірек векторлар машинасы – жіктеу және регрессиялық талдау мәселелерін шешуге қажетті алгоритмдердің жиынтығы. N өлшемді кеңістіктегі нысан екі класстың біріне жататындығына сүйене отырып, тірек векторлық машинасы барлық объектілер екі топтың біреуінде болатындай етіп ($N - 1$) өлшемі бар гиперкеңістік тұрғызады. Тірек векторлар машинасын қолдану барысында келесі екі шектеу қанағаттандырылуы керек:

$$wx_i - b \geq +1, \text{ егер } y_i = +1$$


$$wx_i - b \leq -1, \text{ егер } y_i = -1$$

Гиперкеңістік әр класстың ең жақын мәліметтерінен бірдей қашықтыққа алыстауы үшін $\|w\|$ мәні минимизациялануы керек, оның минимизациясы $\frac{1}{2} \|w\|^2$ минимизациясына пара-пар. Тірек векторлар машинасындағы оңтайландыру есебі келесі сипатта болады [117]:

$$\min \frac{1}{2} \|w\|^2, y_i(x_i w - b) - 1 \geq 0, i = 1, \dots, N$$

Тәжірибе үшін берілген алгоритмді қолдану барысында келесідей нәтижелер алынды:

Accuracy	0,73
Precision	0,99
Recall	0,36
F1	0,53
AUC	0,68



Нақты оң (TP) = 142; 142 оң класс деректері модель бойынша дұрыс жіктелген.


Нақты теріс (TN) = 61; 61 теріс класс деректері модель бойынша дұрыс жіктелген.

Жалған оң (FP) = 16; теріс кластағы 16 дерек модель бойынша оң классқа жатады деп

дұрыс жіктелмеген


Жалған теріс (FN) = 44; оң кластағы 44 дерек модель бойынша теріс классқа жатады деп қате жіктелген.

Осы белгілер бойынша жіктеудің ROC қисық түріндегі нәтижесі төмендегі суретте келтірілген:



ROC мәні 0.77 құрайтындығын көреміз, бұл жіктеуіштің оң сынып мәндерін теріс сынып мәндерінен ажырата алу мүмкіндігінің жақсы екендігін көрсетеді.

AUC



4.2 Шешім ағашы

Шешім ағашы (жіктеу ағашы немесе регрессия ағашы деп те аталады) – шешім қабылдау үшін пайдаланылатын ациклді граф. Графтың әрбір бұтақты түйінінде белгілер векторындағы j -шы белгі зерттеледі. Егер белгінің мәні берілген шектен төмен болса, сол жақ бұтақ, кері жағдайда оң жақ бұтақ таңдалады. Жапырақ түйініне жеткен кезде берілген дана тиісті болатын класс жайлы шешім қабылданады.

Мәліметтерді талдау барысында шешімдер ағашын математикалық және есептеу әдістері ретінде мәліметтер жинағын сипаттау, жіктеу және жалпыландыру үшін пайдалануға және келесі түрде жазуға болады [117]:

$$(x, Y) = (x_1, x_2, x_3 \dots, x_k, Y)$$

Тәуелді Y айнымалысы талдануы және жіктелуі тиіс мақсатты айнымалы болып табылады. x векторы x_1, x_2, x_3 және т.с.с. кіріс айнымалыларынан тұрады.

Шешімдер ағашы арқылы талдау кезінде бәсекелес баламалардың күтілетін мәндерін (немесе күтілетін пайдасын) есептеу үшін шешімдерді қолдаудың визуалды және аналитикалық құралы қолданылады.

Берілген алгоритмдегі оңтайландыру критерийі орташа логарифмдік шындыққа ұқсастық болып табылады:

$$\frac{1}{N} \sum_{i=1}^N [y_i \ln f_{ID3}(x_i) + (1 - y_i) \ln(1 - f_{ID3}(x_i))]$$

мұндағы f_{ID3} - шешімдер ағашы.

S белгіленген мәліметтер жиынтығы болсын. Бастапқыда шешімдер ағашында барлық мәліметтерді қамтитын жалғыз түйін болады: $S \stackrel{\text{def}}{=} \{(x_i, y_i)\}$

f_{ID3}^S тұрақты моделі келесідей анықталады:

$$f_{ID3}^S = \frac{1}{|S|} \sum_{(x,y) \in S} y$$

$f_{ID3}^S(x)$ моделі кез келген x үшін бірдей болжам қайтарады. Әрі қарай $j=1, \dots, D$ белгілері мен t шектері ізделеді және S жиыны екі ішкі жиынға бөлінеді:

$$S_- \stackrel{\text{def}}{=} \{(x, y) | x, y \in S, x^{(j)} < t\}$$

$$S_+ \stackrel{\text{def}}{=} \{(x, y) | x, y \in S, x^{(j)} \geq t\}$$


Берілген екі ішкі жиын жаңа жапырақтық түйіндерді құрайды. Модель нәтижесінің дұрыстығы энтропия арқылы бағаланады. Энтропия – кездейсоқ шаманың белгісіздік шамасы. Барлық кездейсоқ шама мәндерінің ықтималдықтары тең болған кезде энтропия

өз максимумына жетеді және кездейсоқ шама тек бір мәнге ғана ие болған кезде энтропия өз минимумына жетеді. S жиынының энтропиясы келесідей анықталады [117]:

$$H(S) \stackrel{\text{def}}{=} -f_{ID3}^S \ln f_{ID3}^S - (1 - f_{ID3}^S) \ln(1 - f_{ID3}^S)$$

Мәтіндерді экстремистік және бейтарап класстарға бөлу есебі үшін шешімдер ағашы әдісін қолдану барысында келесідей нәтижелер алынды:

Accuracy	0,77
Precision	0,95
Recall	0,49
F1	0,64
AUC	0,73




Нақты оң (TP) = 131; 131 оң класс деректері модель бойынша дұрыс жіктелген.

Нақты теріс (TN) = 75; 75 теріс класс деректері модель бойынша дұрыс жіктелген.


Жалған оң (FP) = 27; теріс кластағы 27 дерек модель бойынша оң классқа жатады деп

дұрыс жіктелмеген

Жалған теріс (FN) = 30; оң кластағы 30 дерек модель бойынша теріс классқа жатады деп қате жіктелген.



AUC




4.3 Кездейсоқ орман

Кездейсоқ орман – бұл Лео Брейман және Адель Катлер ұсынған машиналық оқыту алгоритмі, берілген алгоритм шешімдер ағашы ансамблін пайдаланады. Алгоритм екі негізгі идеяны қамтиды: Брейманның бэггинг әдісі және Тин Кам Хо ұсынған кездейсоқ ішкі кеңістіктер әдісі. Алгоритмнің негізгі идеясы әрқайсысы өте аз жіктеу дәлдігін беретін, бірақ олардың санының көп болуы арқасында нәтиженің жағсы болуына әсер ететін шешімдер ағашының өте көп ансамблін пайдалануға негізделеді.

Кездейсоқ орман әдісі жағдайында келесідей нәтижелер алынды:

Accuracy	0,73
Precision	1,0
Recall	0,36
F1	0,52
AUC	0,68




Нақты оң (TP) = 134; 134 оң класс деректері модель бойынша дұрыс жіктелген. Нақты теріс (TN) = 81; 81 теріс класс деректері модель бойынша дұрыс жіктелген.

Жалған оң (FP) = 24; теріс кластағы 24 дерек модель бойынша оң классқа жатады деп


дұрыс жіктелмеген

Жалған теріс (FN) = 24; оң кластағы 24 дерек модель бойынша теріс классқа жатады деп қате жіктелген.

Осы белгілер бойынша жіктеудің ROC қисық түріндегі нәтижесі төмендегі суретте келтірілген:



AUC



4.4 k жақын көрші алгоритмі (k-Nearest Neighbors)


k жақын көрші алгоритмі (k-Nearest Neighbors, k-NN) – оқытудың параметрлік емес алгоритмі. Басқа машиналық оқыту алгоритмдерінен ерекшелік ретінде берілген алгоритм барлық оқыту мысалдарын жадыда сақтайды. Бұрын кездеспеген жаңа x данасы пайда болған кезде k-NN алгоритмі x-ке ең жақын k оқыту мәліметтерін табады және ең жиі кездесетін белгіні қайтарады. Екі мәліметтің жақындығы ара қашықтық функциясы арқылы анықталады. Әдетте евклидтік ара қашықтық немесе теріс косинустық ұқсастық пайдаланылады. Косинустық ұқсастық келесі формула бойынша есептеледі [117]:

$$s(x_i, x_k) \stackrel{\text{def}}{=} \cos(\angle(x_i, x_k)) = \frac{\sum_{j=1}^D x_i^{(j)} x_k^{(j)}}{\sqrt{\sum_{j=1}^D (x_i^{(j)})^2} \sqrt{\sum_{j=1}^D (x_k^{(j)})^2}}$$

Егер векторлар арасындағы бұрыш 0 градуска тең болса, онда бұл олардың бағыттас екендігін білдіреді және косинустық ұқсастық 1-ге тең болады. Егер векторлар ортогональ болса, косинустық ұқсастық 0-ге тең. Кері бағыттас векторлардың косинустық ұқсастығы -1-ге тең [117].

Экстремистік және бейтарап мәтіндерді жіктеу үшін берілген әдісті қолдану барысында келесідей нәтижелер алынды:

Accuracy	0,78
Precision	0,96
Recall	0,49
F1	0,66
AUC	0,5



Нақты оң (TP) = 136; 136 оң класс деректері модель бойынша дұрыс жіктелген.


Нақты теріс (TN) = 77; 77 теріс класс деректері модель бойынша дұрыс жіктелген.

Жалған оң (FP) = 22; теріс кластағы 22 дерек модель бойынша оң классқа жатады деп


дұрыс жіктелмеген

Жалған теріс (FN) = 28; оң кластағы 28 дерек модель бойынша теріс классқа жатады деп қате жіктелген.

Осы белгілер бойынша жіктеудің ROC қисық түріндегі нәтижесі төмендегі суретте келтірілген:



AUC



4.5 Аңқау Байес классификаторы

Аңқау Байес классификаторы – Байес теоремасын тәуелсіздік жайлы қатаң ұсыныстармен қатар қолдануға негізделетін қарапайым ықтималдық классификаторы. Берілген алгоритмнің артықшылығы – оқытуға, параметрлерді бағалауға және жіктеуге қажетті мәліметтер көлемінің аздығы. Классификатордың ықтималдық үлгісі – келесі шартты үлгі болып табылады,

$$p(C | F_1, \dots, F_n)$$

мұндағы C - класс, $F_1, \dots, F_n$ - айнымалылар. Байес теоремасын қолдану арқылы келесі теңдеуді алуға болады:

$$p(C | F_1, \dots, F_n) = \frac{p(C)p(F_1, \dots, F_n | C)}{p(F_1, \dots, F_n)}$$

Тәжірибеде бөлшектің алымы қызықтырады, себебі бөлімі C -ға тәуелді емес және F_i мәндері берілген, сол себепті бөлшектің бөлімі – тұрақты шама.

Бөлшектің алымы $p(C | F_1, \dots, F_n)$ біріккен ықтималдық үлгісіне пара-пар және оны шартты ықтималдықтың анықтамаларын пайдалану арқылы келесі түрде жазуға болады:

$$p(C | F_1, \dots, F_n) = p(C)p(F_1, \dots, F_n | C) = p(C)p(F_1 | C)p(F_2, \dots, F_n | C, F_1) = p(C)p(F_1 | C)p(F_2 | C, F_1)p(F_3, \dots, F_n | C, F_1, F_2) = p(C)p(F_1 | C)p(F_2 | C, F_1) * \dots * p(F_n | C, F_1, F_2, F_3, \dots, F_{n-1}) \text{ және т.с.с.}$$

Әрі қарай шартты ықтималдықтың «аңқау» ұсыныстарын пайдалануға болады: әрбір F_i қасиеті кез келген басқа F_j , $i \neq j$ қасиетінен шартты тәуелсіз деп есептейік, бұл

$p(F_i | C, F_j) = p(F_i | C)$ екендігін білдіреді, осылайша біріккен үлгіні келесі түрде өрнектеуге болады:

$$p(C, F_1, \dots, F_n) = p(C)p(F_1 | C)p(F_2 | C)p(F_3 | C) * \dots * p(F_n | C) = p(C) \prod_{i=1}^n p(F_i | C)$$

Бұл тәуелсіздік жайлы ұсыныстарды, C класстық айнымалысы бойынша шартты үлестірімді келесі түрде өрнектеуге болатындығын білдіреді:


$$p(C | F_1, \dots, F_n) = \frac{1}{Z} p(C) \prod_{i=1}^n p(F_i | C)$$

мұндағы $Z = p(F_1, \dots, F_n)$ – бұл тек $F_1, \dots, F_n$ – ге тәуелді масштабтық көбейткіш, яғни айнымалылардың мәндері белгілі болған жағдайда тұрақты шама болып табылады. Ықтималдық үлгісі бойынша классификатор құрылады [121]:

$$classify(f_1, \dots, f_n) = \underset{c}{\operatorname{argmax}} p(C = c) \prod_{i=1}^n p(F_i = f_i | C = c)$$

Аңқау Байес классификаторы бойынша мәтіндерді экстремистік және бейтарап санатқа жіктеу барысында келесідей нәтижелер алынды:

Accuracy	0,86
Precision	0,80
Recall	0,89
F1	0,84
AUC	0,86




Нақты оң (TP) = 151; 151 оң класс деректері модель бойынша дұрыс жіктелген.

Нақты теріс (TN) = 51; 51 теріс класс деректері модель бойынша дұрыс жіктелген.


Жалған оң (FP) = 7; теріс кластағы 7 дерек модель бойынша оң классқа жатады деп дұрыс жіктелмеген

Жалған теріс (FN) = 54; оң кластағы 54 дерек модель бойынша теріс классқа жатады деп қате жіктелген.

Аңқау Байес алгоритмі бойынша жіктеу барысында төмендегідей ROC қисық алынды:



AUC



4.6 Логистикалық регрессия

Логистикалық регрессия – y_i -ді x_i -ге тәуелді сызықты функция түрінде модельдеуге мүмкіндік беретін машиналық оқыту әдісі. Белгілердің $w x_i + b$ түріндегі сызықты комбинациясы – теріс шексіздіктен оң шексіздікке дейін созылатын функция, ал y_i тек екі мәннің біріне ғана ие бола алады. Егер модельдің x данасы үшін қайтаратын мәні 0-ге жуық болса, онда оған теріс белгі тағайындалады; кері жағдайда берілген данаға оң белгі тағайындалады. Мұндай қасиеттерге ие функциялардың бірі стандартты логистикалық функция (логистикалық сигмоид) болып табылады:

$$f(x) = \frac{1}{1 + e^{-x}}$$

мұндағы e – натурал логарифм негізі. Логистикалық регрессия моделі келесідей болады:

$$f_{w,b}(x) = \frac{1}{1 + e^{-(wx+b)}}$$


Егер w және b мәндері сәйкесінше оңтайландырылатын болса, онда $f(x)$ нәтижесін y_i -тің оң мәнге ие болу ықтималдығы ретінде ұсынуға болады.

Логистикалық регрессия моделіндегі оңтайландыру критерийі максималды шындыққа ұқсастық (maximum likelihood) деп аталады. Оқытушы мәліметтердің шындыққа ұқсастығы модельге сәйкес максималдандырылады [117]:

$$L_{w,b} \stackrel{\text{def}}{=} \prod_{i=1 \dots N} f_{w,b}(x_i)^{y_i} (1 - f_{w,b}(x_i))^{(1-y_i)}$$

Веб-ресурстардағы қазақ тіліндегі экстремистік мәліметтерді анықтау тәжірибелерінде логистикалық регрессия әдісін қолдану нәтижелері төмендегі кесте мен суреттерде көрсетілген:

Accuracy	0,77
Precision	0,98
Recall	0,46
F1	0,63
AUC	0,86




Нақты оң (TP) = 152; 152 оң класс деректері модель бойынша дұрыс жіктелген.

Нақты теріс (TN) = 52; 52 теріс класс деректері модель бойынша дұрыс жіктелген.


Жалған оң (FP) = 6; теріс кластағы 6 дерек модель бойынша оң классқа жатады деп дұрыс жіктелмеген

Жалған теріс (FN) = 53; оң кластағы 53 дерек модель бойынша теріс классқа жатады деп қате жіктелген.

Мәтіндерді логистикалық регрессия бойынша жіктеу нәтижесінде алынған ROC қисық төмендегі суретте келтірілген:



AUC



4.7 Градиентті бустинг

Градиентті бустинг – бұл жіктеу мен регрессияның есептерін шешуге арналған, әдетте шешімдер ағашы сияқты әлсіз болжаушы үлгілер ансамблінен тұратын болжам үлгісін құрастыратын машиналық оқыту техникасы. Кез келген оқытушымен оқытылатын алгоритмнің мақсаты - жоғалту функциясын анықтау және оны минимизациялау. Жоғалту функциясы ретінде орташа квадраттық қате (MSE) таңдалған жағдайда

$$Loss = MSE = \sum (y_i - y_i^p)^2$$

мұндағы y_i -ші мақсатты шама, y_i^p -ші болжам, $L(y_i, y_i^p)$ – жоғалту функциясы.

Градиенттік жылжуды қолдана отырып, оқыту жылдамдығына негізделетін мәндерді жаңарту арқылы MSE минималды болатын мәндер ізделеді.

$$y_i^p = y_i^p + \alpha * \delta \sum \frac{(y_i - y_i^p)^2}{\delta y_i^p}$$

Берілген өрнек келесі түрге енеді:


$$y_i^p = y_i^p - \alpha * 2 \sum (y_i - y_i^p)$$

мұндағы α -оқыту жылдамдығы және $(y_i - y_i^p)$ -қалдықтар.

Осылайша, болжамдар ауытқулардың сомасы нөлге ұмтылып, болжанатын мәндер нақты мәндерге жақын болғанға дейін жаңартылып отырады [122].

Берілген алгоритмді экстремистік және бейтарап мәтіндерді жіктеу есебіне қолдану нәтижесі төменде келтірілген.

Accuracy	0,75
Precision	0,99
Recall	0,41
F1	0,58
AUC	0,71



Нақты оң (TP) = 138; 138 оң класс деректері модель бойынша дұрыс жіктелген.


Нақты теріс (TN) = 74; 74 теріс класс деректері модель бойынша дұрыс жіктелген.

Жалған оң (FP) = 20; теріс кластағы 20 дерек модель бойынша оң классқа жатады деп


дұрыс жіктелмеген

Жалған теріс (FN) = 31; оң кластағы 31 дерек модель бойынша теріс классқа жатады деп қате жіктелген.

Градиентті бустинг алгоритмі бойынша жіктеу барысында төмендегідей ROC қисық алынды:




AUC



Қорытындылай келе айтатын болсақ, берілген тарауда бірнеше машиналық оқыту әдістері көмегімен мәтінді экстремистік және бейтарап санаттарға жіктеу есебі шешілді. Эксперимент нәтижесі келесі кестеде келтірілген:

Машиналық/терең оқыту әдісі	Accuracy	F1-Score	AUC
Logistic regression	0.77	0.63	0.86
k-nearest neighbors	0.78	0.66	0.5
Decision Tree	0.77	0.64	0.73
Random Forest	0.73	0.52	0.68
Gradient Boosting	0.75	0.58	0.71
SVM	0.73	0.53	0.68
Naïve Bayes	0.86	0.84	0.86
Ұсынылатын модель	0.9	0.90	0.90



Қорытындылай келе, ұсынылатын модель машиналық оқыту әдістерімен салыстырғанда барлық бағалау параметрлері бойынша жоғары екендігін байқаймыз және нәтижесінде ұсынылатын модель веб-ресурстардағы қазақ тіліндегі экстремистік мәтіндерді жоғары дәлдікпен анықтай алады деген қорытындыға келеміз.

ҚОРЫТЫНДЫ

Диссертациялық жұмыс нәтижесінде экстремистік мәтіндердің мазмұнын анықтау мақсатында қазақ тіліндегі қысқа хабарламаларды жинау және талдау үшін бағдарламалық кешен құрылды. Бағдарламалық жасақтама көмегімен Вконтакте әлеуметтік желісінің хабарламалары негізінде жиналған мәтіндер корпусы құрылды. Корпустар екі классқа бөлінеді: экстремистік бағыттағы және бейтарап мәтіндер. Корпустағы әрбір мәтінде мәлімдеменің өзектілігі және оның оқырмандарға әсер ету күші, хабарламаның маңыздылығы туралы қорытынды жасауға мүмкіндік беретін атрибуттар бар. Бұл зерттеудің жаңалығы қазақ тіліндегі экстремистік мәтіндерді анықтау үшін терең нейрондық желі моделін жасау болып табылады. Біз биграмм негізінде терең нейрондық желі моделін жасадық және нәтижелер қазақ тіліндегі экстремизмді анықтау міндеті үшін 88% дәлдікпен классикалық Машиналық оқыту және терең оқыту әдістерімен салыстырғанда экстремистік мәтіндерді анықтауда ұсынылған модельдің тиімділігін көрсетеді. Ұсынылған нәтижелердің тиімділігін тексеру үшін біз классикалық бақыланатын оқыту алгоритмдері мен lstm-ді оқыттық. Бақыланатын оқыту алгоритмдері ұсынылған модельге қарағанда дәлірек болды. Осылайша, экстремизмге байланысты қазақ тіліндегі мәтіндерді табу міндеті үшін биграммалар негізіндегі терең нейрондық желі жоғары өнімділік беріп, өзінің тиімділігін көрсетті.

Диссертациялық жұмыстың теориялық маңыздылығы экстремистік іс-әрекеттер мен ұйымдарды анықтау әдістері мен алгоритмдері саласындағы білім жиынтығына негізделген. Алынған іргелі нәтижелерді әлемдік ғылыми қауымдастық пайдалана алады.

Әдіснама, алгоритмдер, авторлық куәлік түріндегі қолданбалы нәтижелерді ақпараттық қауіпсіздікті, сыни инфрақұрылымды қамтамасыз ету, интернет-экстремизммен күрес жөніндегі уәкілетті органдар пайдалануы мүмкін.

ПАЙДАЛАНЫЛҒАН ӘДБИЕТТЕР ТІЗІМІ

1. Gaikwad, Mayur & Ahirrao, Swati & Phansalkar, Shraddha & Kotecha, Ketan. (2021). Online Extremism Detection: A Systematic Literature Review With Emphasis on Datasets, Classification Techniques, Validation Methods, and Tools. IEEE Access. PP. 1-1. 10.1109/ACCESS.2021.3068313.
https://www.researchgate.net/publication/350338351_Online_Extremism_Detection_A_Systematic_Literature_Review_With_Emphasis_on_Datasets_Classification_Techniques_Validation_Methods_and_Tools/citation/download
2. Cristina Sánchez-Rebollo, Cristina Puente, Rafael Palacios, Claudia Piriz, Juan P. Fuentes, Javier Jarauta, "Detection of Jihadism in Social Networks Using Big Data Techniques Supported by Graphs and Fuzzy Clustering", *Complexity*, vol. 2019, Article ID 1238780, 13 pages, 2019. <https://doi.org/10.1155/2019/1238780>
<https://www.hindawi.com/journals/complexity/2019/1238780/>
3. <https://adilet.zan.kz/kaz/docs/Z050000031>
4. <https://adilet.zan.kz/kaz/archive/docs/P1800000124/15.03.2018>
5. https://egov.kz/cms/kk/articles/religion/zaprewennye_organizacii?mobile=no
6. <https://egemen.kz/article/255352-aqparattyq-qauipsizdik-ortalyghyn-quruymyz-kerek-toqaeu>
7. <https://ult.kz/post/siriya-men-irakta-kansha-kazakstandyk-kamauda-otyr>
8. <https://www.azattyq.org/a/31085416.html>
9. https://blog.twitter.com/en_us/topics/company/2019/addressing-the-abuse-of-tech-to-spread-terrorist-and-extremist-c
10. <https://www.ibm.com/watson>
11. <https://www.vedomosti.ru/technology/articles/2016/06/17/645694-it-soavtor-platona-sozdaet-sistemu-monitoringa-sotssetei-predskazaniya-ugroz>
12. https://www.zitis.bund.de/DE/Home/home_node.html
13. Sharif, W.; Mumtaz, S.; Shafiq, Z.; Riaz, O.; Ali, T.; Husnain, M.; Choi, G.S. An Empirical Approach for Extreme Behavior Identification through Tweets Using Machine Learning. *Appl. Sci.* 2019, 9, 3723. <https://doi.org/10.3390/app9183723>
14. Zahrah, Fatima ; Nurse, Jason R. C. ; Goldsmith, Michael, #ISIS vs #ActionCountersTerrorism: A Computational Analysis of Extremist and Counter-extremist Twitter Narratives, In the proceedings of the 2020 IEEE European Symposium on Security and Privacy Workshops (EuroS&PW), eprint arXiv:2008.11808, <https://doi.org/10.48550/arXiv.2008.11808>
15. Alizadeh, M., Weber, I., Cioffi-Revilla, C. et al. Psychology and morality of political extremists: evidence from Twitter language analysis of alt-right and Antifa. *EPJ Data Sci.* 8, 17 (2019). <https://doi.org/10.1140/epjds/s13688-019-0193-9>
16. Benigni, M., Joseph, K. & Carley, K.M. Mining online communities to inform strategic messaging: practical methods to identify community-level insights. *Comput Math Organ Theory* 24, 224–242 (2018). <https://doi.org/10.1007/s10588-017-9255-3>
17. M. Ashcroft, A. Fisher, L. Kaati, E. Omer and N. Prucha, "Detecting Jihadist Messages on Twitter," 2015 European Intelligence and Security Informatics Conference, 2015, pp. 161-164, doi: 10.1109/EISIC.2015.27.
18. Enghin Omer, Using machine learning to identify jihadist messages on Twitter,
19. Ahmad, S., Asghar, M.Z., Alotaibi, F.M. et al. Detection and classification of social media-based extremist affiliations using sentiment analysis techniques. *Hum. Cent. Comput. Inf. Sci.* 9, 24 (2019). <https://doi.org/10.1186/s13673-019-0185-6>

20. Mitts T. Countering Violent Extremism and Radical Rhetoric (2022) International Organization, 76 (1), pp. 251 - 272, Cited 1 times. DOI: 10.1017/S0020818321000242
21. Gaikwad M., Ahirrao S., Phansalkar S., Kotecha K. 57222563864; Multi-ideology isis/jihadist white supremacist (Miws) dataset for multi-class extremism text classification (2021) Data, 6 (11), art. no. 117, DOI: 10.3390/data6110117
22. Aryuni M., Miranda E., Fernando Y., Kibtiah T.M. An early warning detection system of terrorism in indonesia from twitter contents using naïve bayes Algorithm (2020) Proceedings of 2020 International Conference on Information Management and Technology, ICIMTech 2020, art. no. 9211261, pp. 555 - 559, DOI: 10.1109/ICIMTech50083.2020.9211261
23. Fernandez M., Asif M., Alani H. Understanding the roots of radicalisation on twitter
24. (2018) WebSci 2018 - Proceedings of the 10th ACM Conference on Web Science, pp. 1 - 10, DOI: 10.1145/3201064.3201082
25. Wei Y., Singh L. Detecting Users Who Share Extremist Content on Twitter
26. (2018) Advanced Sciences and Technologies for Security Applications, pp. 351 - 368, DOI: 10.1007/978-3-319-68533-5_17
27. López-Sánchez D., Revuelta J., de la Prieta F., Corchado J.M Towards the automatic identification and monitoring of radicalization activities in twitter (2018) Communications in Computer and Information Science, 877, pp. 589 - 599, DOI: 10.1007/978-3-319-95204-8_49
28. Benigni M., Carley K.M. From tweets to intelligence: Understanding the Islamic Jihad supporting community on twitter (2016) Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 9708 LNCS, pp. 346 - 355, DOI: 10.1007/978-3-319-39931-7_33
29. Ahmed I. A. Abd-Elaal, Ahmed Z. Badr and Hani M. K. Mahdi, "Detecting Violent Radical Accounts on Twitter" International Journal of Advanced Computer Science and Applications(IJACSA), 11(8), 2020. <http://dx.doi.org/10.14569/IJACSA.2020.0110865>
30. Mashechkin, Igor & Petrovskiy, Mikhail & Tsarev, Dmitry & Chikunov, M.. (2019). Machine Learning Methods for Detecting and Monitoring Extremist Information on the Internet. Programming and Computer Software. 45. 99-115. 10.1134/S0361768819030058.
31. Kotzé, Eduan, Senekal, Burgert A., & Daelemans, Walter. (2020). Automatic classification of social media reports on violent incidents in South Africa using machine learning. South African Journal of Science, 116(3-4), 1-8. <https://dx.doi.org/10.17159/sajs.2020/6557>
32. Soliman, G.M.A., Abou-El-Enien, T.H.M. (2019). Terrorism prediction using artificial neural network. Revue d'Intelligence Artificielle, Vol. 33, No. 2, pp. 81-87. <https://doi.org/10.18280/ria.330201>
33. Malek Al-Zewairi, Ghazi Naymat, Spotting the Islamist Radical within: Religious Extremists Profiling in the United State, Procedia Computer Science, Volume 113,
34. 2017, Pages 162-169, ISSN 1877-0509, <https://doi.org/10.1016/j.procs.2017.08.336>. (<https://www.sciencedirect.com/science/article/pii/S1877050917317465>)
35. Ferrara, Emilio & Wang, Wen-Qiang & Varol, Onur & Flammini, Alessandro & Galstyan, Aram. (2016). Predicting Online Extremism, Content Adopters, and Interaction Reciprocity. 10.1007/978-3-319-47874-6_3.

36. Clemmow, Caitlin & Schumann, Sandy & Salman, Nadine & Gill, Paul. (2020). The Base Rate Study: Developing Base Rates for Risk Factors and Indicators for Engagement in Violent Extremism. *Journal of Forensic Sciences*. 65. 10.1111/1556-4029.14282.
37. Pelzer, Robert. (2018). Policing of Terrorism Using Data from Social Media. *European Journal for Security Research*. 3. 10.1007/s41125-018-0029-9.
38. Bouchard, Martin & Davies, Garth & Frank, Richard & Wu, Edith & Joffres, Kila. (2019). 8. The Social Structure of Extremist Websites. 10.3138/9781487514112-010.
39. al-khoury, Dareen. (2020). Radicalisation: old and new a comparative analysis of the Red Brigades and the Islamic State. *Quality & Quantity*. 54. 10.1007/s11135-020-00963-1.
40. H. Chen, S. Thoms and T. Fu, "Cyber extremism in Web 2.0: An exploratory study of international Jihadist groups," *2008 IEEE International Conference on Intelligence and Security Informatics*, 2008, pp. 98-103, doi: 10.1109/ISI.2008.4565037.
41. Scanlon, Jacob & Gerber, Matthew. (2014). Automatic detection of cyber-recruitment by violent extremists. *Security Informatics*. 3. 10.1186/s13388-014-0005-5.
42. Aldera S., Emam A., Al-Qurishi M., Alrubaiyan M., Alothaim A. Online Extremism Detection in Textual Content: A Systematic Literature Review (2021) *IEEE Access*, 9, art. no. 9371676, pp. 42384 - 42396, DOI: 10.1109/ACCESS.2021.3064178
43. Mouhssine E., Khalid C. Social Big Data Mining Framework for Extremist Content Detection in Social Networks (2018) *International Symposium on Advanced Electrical and Communication Technologies, ISAECT 2018 - Proceedings*, art. no. 8618726, DOI: 10.1109/ISAECT.2018.8618726
44. O. Araque and C. A. Iglesias, "An Approach for Radicalization Detection Based on Emotion Signals and Semantic Similarity," in *IEEE Access*, vol. 8, pp. 17877-17891, 2020, doi: 10.1109/ACCESS.2020.2967219.
45. Hashemi, Mahdi & Hall, Margeret. (2018). Visualization, Feature Selection, Machine Learning: Identifying The Responsible Group for Extreme Acts of Violence. *IEEE Access*. PP. 1-1. 10.1109/ACCESS.2018.2879056.
46. Scrivens, Ryan, Steven Windisch, and Pete Simi. 2020. "Former Extremists in Radicalization and Counter-Radicalization Research." In *Radicalization and Counter-Radicalization*, eds. Derek M.D. Silva and Mathieu Deflem. Bingley, UK: Emerald Publishing Limited, 209-224. <https://www.emerald.com/insight/content/doi/10.1108/S1521-613620200000025012/full/html>
47. Koehler, Daniel. "Recent Trends in German Right-Wing Violence and Terrorism: What Are the Contextual Factors behind 'Hive Terrorism'?" *Perspectives on Terrorism*, vol. 12, no. 6, Terrorism Research Institute, 2018, pp. 72-88, <https://www.jstor.org/stable/26544644>.
48. Deviatkin, Dmitrii & Smirnov, Ivan & Solovyev, Fyodor & Suvorova, Margarita & Andrey, Chepovskiy. (2019). EXTREMIST TEXT DETECTION IN SOCIAL WEB. 344-350. 10.33965/wbc2019_201908L041.
49. [Ананьева М.И.](#)¹, [Девяткин Д.А.](#)¹, [Кобозева М.В.](#)¹, [Смирнов И.В.](#)¹, Лингвостатистический анализ текстов экстремистской направленности [Ситуационные центры и информационно-аналитические системы класса 4i для задачи мониторинга и безопасности \(SCVRT2015-16\) : труды международной конференции. Том 1](#), 2016 стр 210-213
50. Ананьева М. И., Кобозева М. В., Соловьев Ф. Н., Поляков И. В., [Чеповский А. М.](#), О проблеме выявления экстремистской направленности в

текстах, Вестник Новосибирского государственного университета. Серия: Информационные технологии. 2016. Т. 14. № 4. С. 5-13.

51. D. Devyatkin, I. Smirnov, M. Ananyeva, M. Kobozeva, A. Chervovskiy and F. Solovyev, "Exploring linguistic features for extremist texts detection (on the material of Russian-speaking illegal texts)," *2017 IEEE International Conference on Intelligence and Security Informatics (ISI)*, 2017, pp. 188-190, doi: 10.1109/ISI.2017.8004907.

52. Бердникова Т.В. Определение адресованности побуждения в экстремистских материалах (на примерах из интернета). Теория и практика судебной экспертизы. 2019;14(3):34-39. <https://doi.org/10.30764/1819-2785-2019-14-3-34-39>

53. A. Abbasi and H. Chen, "Applying authorship analysis to extremist-group Web forum messages," in *IEEE Intelligent Systems*, vol. 20, no. 5, pp. 67-75, Sept.-Oct. 2005, doi: 10.1109/MIS.2005.81.

54. AlGhamdi, M.A., Khan, M.A. Intelligent Analysis of Arabic Tweets for Detection of Suspicious Messages. *Arab J Sci Eng* **45**, 6021–6032 (2020). <https://doi.org/10.1007/s13369-020-04447-0>

55. Aldera S., Emam A., Al-Qurishi M., Alrubaian M., Alothaim A Exploratory Data Analysis and Classification of a New Arabic Online Extremism Dataset (2021) *IEEE Access*, 9, pp. 161613 - 161626, DOI: 10.1109/ACCESS.2021.3132651

56. Alraddadi R.A., Ghembaza M.I.E.-K. Anti-Islamic Arabic Text Categorization using Text Mining and Sentiment Analysis Techniques (2021) *International Journal of Advanced Computer Science and Applications*, 12 (8), pp. 776 – 785 DOI: 10.14569/IJACSA.2021.0120889

57. Alghofaili H., Almishari M. Countering Terrorism Incitement of Twitter Profiles in Arabic-Context (2018) 21st Saudi Computer Society National Computer Conference, NCC 2018, art. no. 8592985, DOI: 10.1109/NCC.2018.8592985

58. Scanlon, J.R., Gerber, M.S. Automatic detection of cyber-recruitment by violent extremists. *Secur Inform* 3, 5 (2014). <https://doi.org/10.1186/s13388-014-0005-5>

59. Cohen, Katie & Johansson, Fredrik & Kaati, Lisa & Clausen Mork, Jonas. (2013). Detecting Linguistic Markers for Radical Violence in Social Media. *Terrorism and Political Violence*. 26. 2014. 10.1080/09546553.2014.849948.

60. Johansson, Fredrik & Kaati, Lisa & Sahlgren, Magnus. (2017). Detecting Linguistic Markers of Violent Extremism in Online Environments. 10.4018/978-1-5225-1759-7.ch118.

61. Prentice, S., Taylor, P.J., Rayson, P. et al. Analyzing the semantic content and persuasive composition of extremist media: A case study of texts produced during the Gaza conflict. *Inf Syst Front* 13, 61–73 (2011). <https://doi.org/10.1007/s10796-010-9272-y>

62. Gelber, K. Terrorist-Extremist Speech and Hate Speech: Understanding the Similarities and Differences. *Ethic Theory Moral Prac* 22, 607–622 (2019). <https://doi.org/10.1007/s10677-019-10013-x>

63. Ul Rehman Z., Abbas S., Khan M.A., Mustafa G., Fayyaz H., Hanif M., Saeed M.A., Understanding the language of ISIS: An empirical approach to detect radical content on twitter using machine learning (2020) *Computers, Materials and Continua*, 66 (2), pp. 1075 - 1090, DOI: 10.32604/cmc.2020.012770

64. Nouh M., Jason Nurse R.C., Goldsmith M. Understanding the radical mind: Identifying signals to detect extremist content on Twitter (2019) 2019 *IEEE International Conference on Intelligence and Security Informatics, ISI 2019*, art. no. 8823548, pp. 98 - 103, DOI: 10.1109/ISI.2019.8823548

65. Rekik A., Jamoussi S., Hamadou A.B. Violent Vocabulary Extraction Methodology: Application to the Radicalism Detection on Social Media (2019) *Lecture*

Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 11684 LNAI, pp. 97 - 109, DOI: 10.1007/978-3-030-28374-2_9

66. Kinnvall, C., & Capelos, T. (2021). The psychology of extremist identification: An introduction [Editorial]. *European Psychologist*, 26(1), 1–5. <https://doi.org/10.1027/1016-9040/a000439>

67. Smith, Laura & Wakeford, Laura & Cribbin, Timothy & Barnett, Julie & Hou, Wai Kai. (2020). Detecting psychological change through mobilizing interactions and changes in extremist linguistic style. *Computers in Human Behavior*. 108. 106298. 10.1016/j.chb.2020.106298.

68. A. Bermingham, M. Conway, L. McInerney, N. O'Hare and A. F. Smeaton, "Combining Social Network Analysis and Sentiment Analysis to Explore the Potential for Online Radicalisation," *2009 International Conference on Advances in Social Network Analysis and Mining*, 2009, pp. 231-236, doi: 10.1109/ASONAM.2009.31.

69. Scrivens, Ryan & Frank, Richard. (2016). Sentiment-based Classification of Radical Text on the Web. 10.1109/EISIC.2016.027.

70. Sofea Azrina Azizan and Izzatdin Abdul Aziz, Terrorism Detection Based on Sentiment Analysis Using Machine Learning, *Journal of Engineering and Applied Sciences*, 2017, Volume: 12, Issue:3, Page No. 691 – 698, DOI: 10.36478/jeasci.2017.691.698

71. Muhammad Asif, Atiab Ishtiaq, Haseeb Ahmad, Hanan Aljuaid, Jalal Shah, Sentiment analysis of extremism in social media from textual information, *Telematics and Informatics*, Volume 48, 2020, 101345, ISSN 0736-5853, <https://doi.org/10.1016/j.tele.2020.101345>

72. Aditi Saraf Jain, 2Dr. Shikha Agarwal, 3Dr. Jitendra Agarwal, A Survey Over Violent Extremist Detection in Social Media Websites, *IJCST Vol. 8, Issue 1, Jan - March 2017* www.ijcst.com *International Journal of Computer Science And Technology* 71 I, ISSN : 0976-8491 (Online) | ISSN : 2229-4333 (Print)

73. Alvari, Hamidreza & Sarkar, Soumajyoti & Shakarian, Paulo. (2019). on Violent Extremists in Social Media.

74. Correa, Denzil & Sureka, Ashish. (2013). Solutions to Detect and Analyze Online Radicalization : A Survey.

75. Arpinar I.B., Kursuncu U., Achilov D. Social media analytics to identify and counter islamist extremism: Systematic detection, evaluation, and challenging of extremist narratives online (2016) *Proceedings - 2016 International Conference on Collaboration Technologies and Systems, CTS 2016*, art. no. 7871051, pp. 611 - 612, DOI: 10.1109/CTS.2016.113

76. Torregrosa López, Francisco Javier & Bello Orgaz, Gema & Martínez-Cámara, Eugenio & Del Ser, Javier & Camacho, David & López, Francisco. (2022). A survey on extremism analysis using natural language processing: definitions, literature review, trends and challenges. *Journal of Ambient Intelligence and Humanized Computing*. 10.1007/s12652-021-03658-z.

77. Litvinova, Tatiana & Litvinova, Olga. (2020). Analysis and Detection of a Radical Extremist Discourse Using Stylometric Tools. 10.1007/978-3-030-37737-3_3.

78. Elovici, Yuval & Shapira, Bracha & Last, Mark & Zaafrany, Omer & Friedman, Menahem & Schneider, Moti & Kandel, Abraham. (2009). Detection of Access to Terror-Related Web Sites Using an Advanced Terror Detection System (ATDS). *JASIST*. 61. 405-418. 10.1002/asi.21249.

79. J. Mei and R. Frank, "Sentiment crawling: Extremist content collection through a sentiment analysis guided web-crawler," *2015 IEEE/ACM International*

Conference on Advances in Social Networks Analysis and Mining (ASONAM), 2015, pp. 1024-1027, doi: 10.1145/2808797.2809373.

80. Yulei Zhang, Shuo Zeng, Li Fan, Yan Dang, C. A. Larson and H. Chen, "Dark web forums portal: Searching and analyzing jihadist forums," *2009 IEEE International Conference on Intelligence and Security Informatics*, 2009, pp. 71-76, doi: 10.1109/ISI.2009.5137274.

81. Bouchard, Martin & Joffres, Kila & Frank, Richard. (2014). Preliminary Analytical Considerations in Designing a Terrorism and Extremism Online Network Extractor. 10.1007/978-3-319-01285-8_11.

82. Scrivens, Ryan & Gaudette, Tiana & Davies, Garth & Frank, Richard. (2019). Searching for Extremist Content Online Using The Dark Crawler and Sentiment Analysis. 10.1108/s1521-613620190000024016.

83. Muhammad Akram, Asim Nasar, Abid Rehman, Misuse of charitable giving to finance violent extremism; A futuristic actions study amidst COVID-19 pandemic, *Social Sciences & Humanities Open*, Volume 4, Issue 1, 2021, 100140, ISSN 2590-2911, <https://doi.org/10.1016/j.ssaho.2021.100140>.

84. <https://www.justsecurity.org/75064/covid-19-and-terrorism-in-the-west-has-radicalization-really-gone-viral/detect>

85. [Francesco Marone](#), Hate in the time of coronavirus: exploring the impact of the COVID-19 pandemic on violent extremism and terrorism in the West, *Secur J.* 2021 Jan 7 : 1–21. doi: [10.1057/s41284-020-00274-y](https://doi.org/10.1057/s41284-020-00274-y)

86. Bekmanova, Gulmira & Yelibayeva, Gaziza & Aubakirova, Saltanat & Dyussupova, Nurgul & Sharipbay, Altynbek & Nyazova, Rozamgul. (2019). Methods for Analyzing Polarity of the Kazakh Texts Related to the Terrorist Threats. 10.1007/978-3-030-24289-3_53.

87. Aktayeva, A., Niyazova, R., Muradilova, G., Makatov, Y., & Kusainova, U. (2018). Cognitive Computing Cybersecurity: Social Network Analysis.

88. О.Ж. МАМЫРБАЕВ, К.Ж. МУХСИНА, Н.Ф. ХАЙРОВА, А.С. КОЛЕСНИК, ЛИНГВИСТИЧЕСКИЕ ИНСТРУМЕНТЫ ВЫЯВЛЕНИЯ КРИМИНАЛЬНО ОКРАШЕННОЙ ТЕКСТОВОЙ ИНФОРМАЦИИ ВЕБ-КОНТЕНТА, ВЕСТНИК КАЗАХСТАНСКО-БРИТАНСКОГО ТЕХНИЧЕСКОГО УНИВЕРСИТЕТА, №3 (46), 2018, 112-117 б.

89. О.Ж.Мамырбаев, Н.Ф. Хайрова, Қ.Ж.Мухсина, Қазақ тіліндегі мәтіндердегі қылмыстық мәнді коллацияларды анықтау, М.Тынышбаев атындағы Қазақ көлік және коммуникациялар академиясының хабаршысы, №3(110), 2019 жыл, 170-175 б.

90. 1

91. 2

92. 3

93. 4

94. <https://www.start.umd.edu/gtd/>

95. <https://www.rand.org/nsrd/projects/terrorism-incidents.html>

96. https://online.zakon.kz/Document/?doc_id=30004865&pos=93;-23#pos=93;-23

97. <https://www.interpol.int/Crimes/Terrorism/Counter-terrorism-projects/Project-Trace2>

98. <https://www.interpol.int/Crimes/Terrorism/Counter-terrorism-projects/Project-Sharaka>

99. <https://www.interpol.int/Crimes/Terrorism/Counter-terrorism-projects/Project-Scorpius>

100. Chen, H. (2012). Dark Web: Exploring and Mining the Dark Side of the Web. In: Domenach, F., Ignatov, D.I., Poelmans, J. (eds) Formal Concept Analysis.

- ICFCA 2012. Lecture Notes in Computer Science(), vol 7278. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-29892-9_1
101. <https://blog.ringostat.com/ru/parsing-dannyh-s-saytov-chto-eto-i-zachem-on-nuzhen/>
 102. Тіл білімі терминдерінің түсіндірме сөздігі — Алматы. «Сөздік-Словарь», 2005 жыл. ISBN 9965-409-88-9
 103. Қазақ тілі. Энциклопедия. Алматы: Қазақстан Республикасы Білім, мәдениет және денсаулық сақтау министрлігі, Қазақстан даму институты, 1998 жыл, 509 бет. ISBN 5-7667-2616-3
 104. M. N. Swamy, M. Hanumanthappa and N. M. Jyothi, "Indian Language Text Representation and Categorization Using Supervised Learning Algorithm," *2014 International Conference on Intelligent Computing Applications*, 2014, pp. 406-410, doi: 10.1109/ICICA.2014.89.
 105. [Jones K. S. A statistical interpretation of term specificity and its application in retrieval](#) (англ.) // *Journal of Documentation* : журнал. — MCB University: MCB University Press, 2004. — Vol. 60, no. 5. — P. 493—502. — ISSN 0022-0418.
 106. [Солтон Дж.](#) (англ.)[рус.](#) Динамические библиотечно-поисковые системы. М.: — Мир, 1979.
 107. Description. *Speech and Language Processing* (2nd Edition): Daniel Jurafsky, James H. Martin: 9780131873216
 108. Liu, B. (2007). *Web Data Mining: Exploring Hyperlinks, Contents, and Usage Data*, New Jersey: Prentice Hall.
 109. van Dam, J. K., & Zaytsev, V. (2016). Software Language Identification with Natural Language Classifiers. In *2016 IEEE 23rd International Conference on Software Analysis, Evolution, and Reengineering (SANER)*, (vol.1, pp. 624-628). IEEE.
 110. Pramokchon, P., & Piamsa-nga, P. (2014). A Feature Score for Classifying Class-Imbalanced Data. In *Computer Science and Engineering Conference (ICSEC)*, 2014 International (pp. 409 - 414). IEEE
 111. Deng, L.; Yu, D. [Deep Learning: Methods and Applications](#) (неопр.) // *Foundations and Trends in Signal Processing*. — 2014. — Т. 7, № 3—4. — С. 1—199. — doi:10.1561/20000000039.
 112. Bengio, Yoshua. [Learning Deep Architectures for AI](#) (неопр.) // *Foundations and Trends in Machine Learning*. — 2009. — Т. 2, № 1. — С. 1—127. — doi:10.1561/22000000006.
 113. Schmidhuber, J. Deep Learning in Neural Networks: An Overview (неопр.) // *Neural Networks*. — 2015. — Т. 61. — С. 85 — doi:10.1016/j.neunet.2014.09.003. — arXiv:1404.7828. — PMID 25462637.
 114. Bengio, Y.; Courville, A.; Vincent, P. Representation Learning: A Review and New Perspectives (англ.) // [IEEE Transactions on Pattern Analysis and Machine Intelligence](#)^[en] : journal. — 2013. — Vol. 35, no. 8. — P. 1798—1828. — doi:10.1109/tpami.2013.50. — arXiv:1206.5538.
 115. ↑ Bengio, Yoshua; LeCun, Yann; Hinton, Geoffrey. Deep Learning (англ.) // *Nature*. — 2015. — Vol. 521. — P. 436—444. — doi:10.1038/nature14539. — PMID 26017442.
 116. Гафаров Ф.М Искусственные нейронные сети и приложения: учеб. пособие / Ф.М. Гафаров, А.Ф. Галимянов. – Казань: Изд-во Казан. ун-та, 2018. – 121 с.
 117. Бурков Андрей. Машинное обучение без лишних слов, СПб.: Питер, 2020. — 192 с. — (Библиотека программиста). — ISBN 978-5-4461-1560-0.
 118. http://neerc.ifmo.ru/wiki/index.php?title=%D0%9E%D1%86%D0%B5%D0%BD%D0%BA%D0%B0_%D0%BA%D0%B0%D1%87%D0%B5%D1%81%D1%88

[2%D0%B2%D0%B0_%D0%B2_%D0%B7%D0%B0%D0%B4%D0%B0%D1%87%D0%B0%D1%85_%D0%BA%D0%BB%D0%B0%D1%81%D1%81%D0%B8%D1%84%D0%B8%D0%BA%D0%B0%D1%86%D0%B8%D0%B8](#)

119. https://ru.wikipedia.org/wiki/%D0%9C%D0%B0%D1%88%D0%B8%D0%BD%D0%BD%D0%BE%D0%B5_%D0%BE%D0%B1%D1%83%D1%87%D0%B5%D0%BD%D0%B8%D0%B5

120. http://www.machinelearning.ru/wiki/index.php?title=%D0%9C%D0%B0%D1%88%D0%B8%D0%BD%D0%BD%D0%BE%D0%B5_%D0%BE%D0%B1%D1%83%D1%87%D0%B5%D0%BD%D0%B8%D0%B5

121. https://en.wikipedia.org/wiki/Naive_Bayes_classifier

122. <https://neurohive.io/ru/osnovy-data-science/gradientyj-busting/#:~:text=%D0%93%D1%80%D0%B0%D0%B4%D0%B8%D0%B5%D0%BD%D1%82%D0%BD%D1%8B%D0%B9%20%D0%B1%D1%83%D1%81%D1%82%D0%B8%D0%BD%D0%B3%20%E2%80%94%D1%8D%D1%82%D0%BE%20%D1%82%D0%B5%D1%85%D0%BD%D0%B8%D0%BA%D0%B0%20%D0%BC%D0%B0%D1%88%D0%B8%D0%BD%D0%BD%D0%BE%D0%B3%D0%BE,%D0%BF%D1%80%D0%B5%D0%B4%D1%81%D0%BA%D0%B0%D0%B7%D1%8B%D0%B2%D0%B0%D1%8E%D1%89%D0%B8%D1%85%20%D0%BC%D0%BE%D0%B4%D0%B5%D0%BB%D0%B5%D0%B9%2C%20%D0%BE%D0%B1%D1%8B%D1%87%D0%BD%D0%BE%20%D0%B4%D0%B5%D1%80%D0%B5%D0%B2%D1%8C%D0%B5%D0%B2%20%D1%80%D0%B5%D1%88%D0%B5%D0%BD%D0%B8%D0%B9.>

ҚОСЫМША А

Қазақстан Республикасының аумағында таратуға тыйым салынған

топтар

1. islam1allah1
2. islam_0
3. uhibbyl.islam
4. islamk4z
5. dnevnikuhti
6. medinaschool
7. umma.muslim
8. malabis_man
9. muslim_humor
10. islam_today_ru
11. el.islam
12. schastya_v_islame
13. islam_world
14. in_islams
15. hikmaislamicshop
16. islam.muslims
17. zcalm
18. ilovemuhammadiloveislam
19. risalatru
20. intimislam
21. islam_alhamdulillah
22. my.religion.islam
23. mydinislam
24. muslimsislam
25. islamideology
26. islamy
27. m.dinimislam
28. koran.sunna
29. islam_obshina
30. prayness
31. one.ummah
32. muslim_records
33. yes_islam
34. taqwaonline
35. cumalar_islam
36. istina.v.islame
37. v_islame
38. islamnapominanie
39. muslim_record
40. raballahal
41. dostovernye.hadisyy
42. annisa_today_ru
43. muslimir
44. xijra
45. uhybbil.islam
46. darulkufaridarulislamakhkami
47. Өлім-бар ұмытпа!!
48. Өлім Мен Өмірдің Арасы
49. Өмір мен өлім

50. Аллаһты Ұлықтау
51. Құран_Хадис_Ислам.
52. Құран,хадис және мәтіндер жаттау
53. Ислам - әлемдерге мейірім
54. Джихад ﷲ
55. Аль Джихад
56. КНУ Джихад
57. КНУ Джихад
58. Rasta джихад
59. الجهاد Джихад
60. ДЖИХАД!
61. джихад
62. Джихад-OnLine
63. Такфир (резерв)
64. Шахид
65. СУБХАН-АЛЛАХ
66. АНТИ-ХАРИДЖИЗМ. ИГИЛ (ИГИШ), аль-Каида
67. ДЖИХАД!!!!
68. Аль-Каида
69. Subhan'Allah.
70. СубхъанАллахl
71. ALLAHU АКВАР
72. АЛЛАХ АКБАР
73. Islam
74. ИСЛАМ
75. Islamic Dinn
76. Шейх уль Ислам Ибн Теймия

ҚОСЫМША В
Діни мазмұндағы топтар

1. abu_ali_al_hanafi
2. al_quran_kz
3. alhamdulilax.musilmanmin
4. aliislam0014
5. allah_5
6. allahuakbar_1
7. allatagala
8. allhamdulillahmusilman
9. arman_ustaz
10. atyraumuslims
11. bakhyt_islamda
12. club_musilman
13. clubmuslim121212
14. cvetok40717
15. darulahnaf_com
16. diary_muslimah_kz
17. dinislam.kz_toby_писто
18. dinislamdinim
19. erkanat77777
20. hadis110786788
21. hadister
22. 23_hanafi_kz
23. hanafi_muslims
24. hanafi.aktau
25. imankz12
26. imannyry
27. immusulman1
28. islaaaaaam
29. islam_1223
30. islam_2017
31. islam_oraza
32. islam.offical
33. islam2282774
34. islamandmuslim
35. islamnegizi
36. islamsunetti
37. issledovanie_s
38. jannatka_bir_kadam
39. jannatkabirgeinshaallah
40. jeckiechankz01
41. karagur00
42. kausar_kz
43. kaz_kaz1
44. kazakh.muslim
45. kazmuslims
46. kuran_jane_sunnet
47. kuran_tadjuid
48. kuran.hadis
49. kurannury
50. kz__sabr

51. kz_musilman_kz
52. love.south
53. m_bauyrlar
54. m_kundeligi
55. m.b.s.kz1111
56. makatmeshiti
57. medreseskz
58. men_musilmanmyn
59. men.musylmanmyn
60. menmuslim
61. mirosulanbiakz
62. mkk_kz
63. muhammad_kz
64. musulman_bauirlar
65. musulman_bauirlarim
66. musulman_kyndeligi
67. musulman.hanshaimi
68. musulman.korgani
69. musulman.otbasilar.ushin
70. musulmanbauirlar
71. musulmanbolubakhyt
72. musulmandar_mekeni
73. musulmandar_mekenu7117
74. muslimannin_sozderi
75. muslim_kazakh
76. muslim362
77. muslim118104283
78. muslim12345678910
79. musliman_kundelygi
80. muslimdiarykz
81. muslimdnevnik
82. muslimjamagat
83. muslimpar
84. musulman.mekeni.jumak
85. musulman_alemi_kz
86. musulman_allhamdulillah
87. musulman_kundeligi
88. musulman_kz99
89. musulmandar_ordasi
90. musylman_kz
91. musylman_paryzy
92. musylman_sipaty
93. musylmandar_parakshasi
94. musylmankaz
95. musylmanmyn_02
96. muxammedumati
97. mysilman_ainasi
98. namaz_xanafi
99. oraza2017
100.paigambar_mektebi
101.paigambar_omiri
102.ppageofamuslim

103.pub.paigambar
104.quran_hadith
105.sizder_uwin
106.story_kaz
107.surak_jauap_hanafi_mazhabi
108.tatti_sezim
109.wearemuslima
110.yaasinn
111.yqylas_musylman
112.zhanm_zhanm
113.alhamdulillah_musylmanbyz
114.musulman.adebi
115.musulman.kundeligi
116.lslam_dlnl
117.abu_hanifa000
118.adamzattanu
119.ahlusunna_99
120.alhalimu
121.asildin
122.asyl_din
123.baxonbbb
124.beineu_kausar
125.clubislamzhumak
126.clubmuxambet
127.din_islam_dingegim
128.din_jane_dastur
129.din_nasihati
130.din.isla
131.din.islam_dingegim
132.din.islam.dingegim
133.din.zholy
134.dinangimeleri
135.dindastyr
136.dini_angymeler
137.dini_zhazylymdar
138.dini_gibratnama
139.dinim.islam
140.dintiregi
141.dinturaly
142.dinykitaptar
143.enu.dt_kz
144.f4zhigitteri
145.iman_zhuregimde
146.imandyadam
147.imannegizderi
148.immusulman
149.inshaalla_sabr
150.islam___dini___0001
151.islam___kz
152.islam_abu_hanifa
153.islam_akikat_dini
154.islam_akikat

155.islam_dini_jaiynda
156.islam_dini1
157.islam_dini7
158.islam_dinim
159.islam_haqq_din
160.islam_iman_kz
161.islam_kazakh
162.islam_kzt
163.islam_the_best2
164.islam_the
165.islam.dini.alemi
166.islam.dini00
167.islam.islam.dini
168.islam.xadis
169.islam120603
170.islam97925649
171.islam134849541
172.islama_kz
173.islamdini2015
174.islamdinikzz
175.islamdinim
176.islamdinimiz
177.islamgrupp
178.islamjumak0
179.islamkuran
180.islamkz01
181.islamkz1400
182.islammadenieti
183.islamqazaqstan
184.jan_top
185.jannatka_asigindar
186.k_qasqyr
187.menin_dinim_islam_kz
188.menin_dinimislam
189.musilman_balasi_kz
190.musilman_dini
191.musylman_kz01
192.namaz_dinnin_tiregy
193.namaz161566269
194.namazdintiregi
195.okomeshit
196.qissa_angimeler
197.sabr_kzz
198.sovkaz
199.sura114_hadis6666
200.taza_din_islam
201.tuka00
202.allahulyq
203.almaty_din
204.asyldinislamkz
205.atadinimislam
206.barlygy_islam_dini_jainda

207.birikken.odak
208.d_islam
209.darul_kitab
210.dasturlydinislam
211.din.alemi
212.din.islam.dingegum
213.din.religion.semey
214.din_islam_1
215.dini.angimeler
216.dini_angimeler147684564
217.diniangimeler
218.dinim_islam
219.dinimislam
220.dinisauat
221.dinislam231217
222.dinkgu_oral
223.dintanym
224.dintube
225.en.taza.islam.dini
226.gibryatnama_dini_angimeler
227.idkontrol00
228.iman_islam0
229.islam_dini_2019
230.islam_dini_alla_zholyinda
231.islam_dini_taza_din
232.islam_dini.khak
233.islam_the_best
234.islam7242
235.islam011111
236.islam84550948
237.islameli2015
238.Islamikz
239.Islamjoly
240.Islamjumak
241.Islamsunnakz
242.islamtv2
243.Jamagatkz
244.kalash_kz
245.kaz.uagiz
246.kazakhmuslim
247.kitap_alemi
248.kmdb_vk
249.menim_dinim_islam
250.menin_dinim_islam_1
251.muslums010
252.Musulmanyislam
253.namaz_dinnin_tiregi
254.namaz.dinnin.tiregi
255.Namaz zaman
256.ne_poim
257.official_kz
258.qazaq_islam

259.qiziktv77777
260.qmdb_dinikitaptar
261.trapmuz_kz
262.tur_dmzo
263.udralmatinskayaoblast
264.xktu_din_teo
265.yslamdini_kz

ҚОСЫМША С

Жалпы лексиканы қамтитын топтар

- 1.Пайдалы Кеңестер pajdaly_kenester_kz
- 2.ӘЗІЛ ӘЛЕМІ azil_qz
- 3.Әзіл әлемі azil.alemi2015
- 4.Әзілдер azil__der
- 5.Әзіл-қалжың kalzhin
- 6.ӘЗІЛ ӘЛЕМІ kazworld
- 7.Жынды әзілдер z_azilder
- 8.ӘЗІЛ ОРДАСЫ azilo_kz
- 9.Ең үздік әзілдер enuzdikazilder
- 10.Қазақ жігіттері kazakh_kz_jigitter
- 11.Неке Қазақстан nikah_kazahstan
- 12.Жаңа қазақша әндер порталы!!! newmusic_kz
- 13.Қазаққа жақпайың... kazakka_jakpaisyn
- 14.Қазақша есімдер kaz.esimder
- 15.Қазақша анекдоттар anekdottar_goi
- 16.Қазақстан Вконтакте kz
- 17.Менің ойларым|Қазақша Бот azil_mekeni
- 18.Қазақ Футболы qazaq_football
- 19.Тек қана қазақша әзілдер tek.kz_azil
- 20.Әйелдерге арналған ayelge
- 21.Өз қолыңмен/ Пайдалы кеңестер oz_kolinmenn
- 22.Фактілер Әлемі kz_logick
- 23.Психология әлемі aleyu
- 24.Әлем тарихы alem.history
- 25.Футбол Әлемі footballinkz
- 26.Әйелдер әлемі ayelderaleyu
- 27.Аспазшылар әлемі! as_xanakz
- 28.Поэзия әлемі kazpoetry
- 29.Философия Әлемі kzphylosophy
- 30.Әлем Футболы footballinqaz
- 31.Жұлдыздар әлемі starsalem
- 32.Кітаптар әлемі kitaptar
- 33.Әлем Кереметтері kazakh_alm
- 34.Дәмхана damxana
- 35.Жалғыздық jalgyz_dyk
- 36.Махаббат|Отбасы|Балалар maxabbat_balalar
- 37.Отбасы сырлары otbasysyrlary
- 38.DalaFilm | DF dalafilm
- 39.TOMPI tompi06021995
40. TOMPI tompi__tompi
- 41.5 қызықты фактілер 5kizik
- 42.Мектеп қызықтары mektep_kyzyktary
- 43.Ұлы сөздер U.S uly_sozder
- 44.Махаббат,қызық мол жылдар maxabbat_kz
- 45.Сіз білмейтін қызықтар kzktar
- 46.ҚызықТАЙМЫЗ kiziqtaimiz_100k
47. Сіз білмейтін қызықтар kiziktar
- 48.Бір миллион қызық оқиға millionokiga
49. Сіз білмейтін қызықтар sbkiziktar
- 50.Қызықты Дерктер |KD kz_facts

- 51.Қызықтың бәрі осында kyzyktynbary
- 52.Әлем қызықтары alemkyzyktari
- 53.Қызықсыз факттер quirdaq
- 54.Бекболат Тілеухан btleukhan
- 55.Ағылшын тілін үйрен|QAZENG qazeng
56. Ағылшын тілін үйренейік) publicgreatbl7
57. Ағылшын тілі| Күн сайын engkazlanguage
- 58.ҰБТ Академиясы ubt_akademiyasy
- 59."QAZENT" –новый формат ЕНТ 2020 ҰБТ|Kazent kazent
- 60.АБАЙ ҚҰНАНБАЙҰЛЫ/ABAY QUNANBAYULY abay_qunanbayuly
- 61.Омар Хайям және ұлы философтар omarzhene
- 62.Анекдоттар мен приколдар kz_version
- 63.Мықты приколдар myktyprikol
- 64.Жынды приколдар станциясы JPS jpskz
- 65.Қош махаббат qoshmahabbat
- 66.Бітпейтін махаббат bitpeityn_maxabbat
- 67.Сұлу махаббат sulumahabbat
- 68.Махаббат сезімі mahabbat_sezymi
- 69.Махаббат кілті –жүректе mahabbat_kilti
- 70.Өмір және Махаббат... kaz__world
- 71.Мөлдір Махаббат hubbi
- 72.Тентек Сезім tenteksezym
- 73.Сезім sezim
- 74.Әйел сезімі ayelsezymy
- 75.Қыз сезімі qiz_sezimi
- 76.NUR.KZ-жаңалықтар portalnurkz_kaz
- 77.Push-Жаңалықтар push_kz
- 78.Жаңалықтар qazaqshanews
79. Жаңалықтар KZ qazaq_news
- 80.Өмірден алынған omirden_allingan
- 81.Өмір күнделігі omirkundeligy
- 82.Өмірде бәрі мүмкін kzomirde
- 83.Өмірлік кеңестер omir_kenes
- 84.Өмірде солай omirdesolay
- 85.Өмір жайлы... omirj_kz
- 86.Жұлдыздардың өмірі juldyzomir
87. Өмір lifeomir
- 88.Өмір аялдмасы omirayaldama
- 89.Өмірғой omirlik.sirlasyn
- 90.Өмір omir_7
- 91.Менің өмірім omirimgoi
- 92.Өмір жайлы бірер сөз omirzhaily
- 93.Менің өмірім omir02
- 94.Есіндеме достым e_dostym
- 95.Өмірдің ащы шындық shindik_awi
- 96.Өмірдегі сөздер omirdegi_sozder
- 97.Өмірлік кеңестер omirlyk_kenester
- 98.Жұлдызды әлем zh_alem
99. Жұлдыз жорамал|Күн сайын zhuldiz.zhoranal
- 100.Үздік жұлдыз жорамал|Күн сайын juldiz_joramall

ҚОСЫМША D

Экстремистік әрекет туралы жаңалықтар мақалаларына сілтеме

1. <https://qazaquni.kz/2019/10/12/105733.html>
2. <https://qazaquni.kz/2019/09/20/104819.html>
3. <https://qazaquni.kz/2019/06/03/100587.html>
4. <https://qazaquni.kz/2019/04/06/98048.html>
5. <https://qazaquni.kz/2019/01/09/94470.html>
6. <https://qazaquni.kz/2018/10/29/91726.html>
7. <https://qazaquni.kz/2018/01/30/80985.html>
8. <https://qazaquni.kz/2017/08/10/73397.html>
9. <https://qazaquni.kz/2017/04/07/67449.html>
10. <https://qazaquni.kz/2016/12/25/62454.html>
11. <https://qazaquni.kz/2016/12/21/62341.html>
12. <https://qazaquni.kz/2016/10/11/59057.html>
13. <https://qazaquni.kz/2016/09/26/58512.html>
14. <https://qazaquni.kz/2016/09/26/58484.html>
15. <https://qazaquni.kz/2016/08/31/57154.html>
16. <https://qazaquni.kz/2016/07/22/55667.html>
17. <https://24.kz/kz/zha-aly-tar/sayasat/item/363424-m-zhilis-shy-ekstremizmmen-k-res-konventsiasyn-ma-ldady>
18. <https://24.kz/kz/zha-aly-tar/o-am/item/349748-sham-eline-kelgenderdi-shuly-soty-li-de-zhal-asady>
19. <https://24.kz/kz/zha-aly-tar/o-am/item/348370-aza-standa-22-dini-a-ymny-taraluyna-git-nasikhatyna-ata-tyjym-salyn-an>
20. <https://24.kz/kz/zha-aly-tar/o-am/item/277572-sarapshylar-ekstremizmni-aldyn-aluda-da-bilimni-lesi-zor>
21. <https://24.kz/kz/zha-aly-tar/o-am/item/273840-ma-ystau-oblysynda-y-t-zetu-mekemesinde-o-shaulan-an-ajma-ryldy>
22. <https://24.kz/kz/zha-aly-tar/o-am/item/247224-sarapshy-zhastardy-ziyandy-ideologiyany-serinen-or-audy-zholy-bilim-beru>
23. <https://24.kz/kz/zha-aly-tar/o-i-a/item/238961-alardy-tarat-an-8-azamat-staldy>
24. <https://24.kz/kz/zha-aly-tar/o-am/item/227531-almatyda-studentterge-dini-ekstremizmni-aupi-zh-ne-onymen-k-res-zholdary-t-sindirildi>
25. <https://24.kz/kz/zha-aly-tar/o-am/item/216913-kadam-shakh-shakhim-aza-stan-au-anstan-m-selesin-sheshu-shin-ta-y-bir-lken-adam-zhasady>
26. <https://24.kz/kz/zha-aly-tar/o-am/item/212185-aza-stan-men-t-rikmenstan-khaly-araly-terrorizmge-arsy-k-reste-riptestikti-k-shejtppek>
27. <https://24.kz/kz/zha-aly-tar/o-am/item/210501-astanada-ba-kilderi-men-memlekettik-yzmetkerler-bas-osty>
28. <https://24.kz/kz/zha-aly-tar/lemde/item/184204-tmd-zhastaryny-parlamentaraly-assambleyasyn-da-terrorizmge-arsy-t-ru-arastyryldy>
29. <https://24.kz/kz/zha-aly-tar/o-am/item/177894-ekstremizmdi-nasikhattajty-n-300-sajt-zhabyldy>
30. <https://24.kz/kz/archive/zha-aly-tar/item/150878-ekstremizidi-zhe-uge-bolady>
31. <https://24.kz/kz/archive/zha-aly-tar/item/145664-zirbajzhan-diasporasyny-zhastary-kazakhstan-for-peas-oz-aly-syna-osyldy>
32. <https://24.kz/kz/archive/zha-aly-tar/item/145420-ibitsa-aralynda-zhastardy-terrorister-ataryna-tart-an-imamdar-staldy>
33. <https://24.kz/kz/archive/zha-aly-tar/item/144231-khaly-araly-konferentsiya-bastaldy>
34. <https://24.kz/kz/archive/zha-aly-tar/item/143013-nigeriyada-boko-kharam-21-yzdy-bosatty>

35. <https://sn.kz/sn-akparat-agyny/63556-almatyda-en-uzdik-leumettik-rolik-avtorlary-marapattaldy>
36. <https://sn.kz/sn-zan-zaman/56462-ruk-sat-etilmegen-miting-otkizuge-daiyndalghan-dvk-kozgalysynyn-tort-belsendisi-kamauga-alyndy>
37. <https://sn.kz/sn-sayasat/51122-yr-yzstanda-ekstremistik-sipatta-y-36-sajt-b-attaldy>
38. <https://sn.kz/b-gingi-s-z/43617-elimizdegi-bajsaldy-salafilardi-bir-mezette-radikaldy-salafilerge-ajnalyp-ketui-m-mkin>
39. <https://sn.kz/sn-zan-zaman/40463-a-t-bede-tabli-i-zhama-at-jymyny-7-m-shesi-sottaldy>
40. <https://sn.kz/o-am/37484-shymkentte-terrorizm-babymen-sottal-an-adamny-tuystary-shu-shy-ardy>
41. <https://sn.kz/o-am/37050-o-o-da-zh-rtty-terrorizmge-gittegen-ta-y-2-adam-staldy>
42. <https://sn.kz/o-am/36503-o-o-da-zh-rtty-terakt-zhasau-a-ndep-zh-rngen-sa-aldylar-staldy>
43. <https://sn.kz/sn-akparat-agyny/32341-t-zhikstanda-70-zhasta-y-zhej-nemerelerimen-birge-siriya-a-so-ys-a-attanba-bol-an>
44. <https://sn.kz/sn-zan-zaman/31086-terrorizmdi-nasikhattady-dep-ajyptal-an-shymkenttik-zhigit-asyl-arnadan-o-yl-an-s-reni-zh-ktep-al-anyn-ajtty>
45. <https://sn.kz/bilik/30021-nazarbaev-auipsizdik-ke-esin-zhinap-o-o-da-y-dini-ekstremizm-m-selesin-tal-ylady>
46. <https://sn.kz/b-gingi-s-z/29845-atyrauda-sottal-an-salafit-daryn-m-b-rovty-ty-damau-a-sha-yrdy>
47. <https://sn.kz/bilik/29745-nazarbaev-pen-m-simov-dini-radikaldar-zhajynda-gimelesti>
48. <https://sn.kz/sn-zan-zaman/29169-ltty-auipsizdik-komiteti-o-o-da-bir-top-sa-aldy-azamaty-stady>
49. <https://sn.kz/b-gingi-s-z/28835-za-ger-salafittik-a-ym-a-erip-ketken-zhastardy-obaly-e-birinshiden-daryn-basta-an-topty-mojnynda>
50. <https://sn.kz/o-am/8539-prokuror-ruslan-k-lekbaev-a-lim-zhazasyn-s-rady>
51. <https://sn.kz/o-am/7966-elimizdi-batysynda-la-kestik-zhasama-bol-an-21-adam-staldy>
52. <https://sn.kz/sn-akparat-agyny/6768-siriyada-birneshe-zharylys-bolyp-119-adam-aza-tapty>
53. <https://sn.kz/sn-akparat-agyny/6703-astanada-siriya-a-otbasymen-attanba-bol-an-eki-t-r-yn-sottaldy>
54. <https://sn.kz/sn-akparat-agyny/6570-ekstremistik-k-z-arasta-y-ta-y-bir-aza-standy-saudiya-koroldiginde-ol-a-t-sti>
55. <https://sn.kz/sn-akparat-agyny/6385-islam-memleketi-400-adamdy-t-t-yn-a-aldy>
56. <https://sn.kz/sn-akparat-agyny/6289-l-kaida-italiya-men-ispaniya-a-shabuyl-zhasaudy-zhosparlap-otyr>
57. <https://sn.kz/sn-akparat-agyny/6214-sh-yl-saud-arabiyasynda-ekstremistik-k-z-arasta-y-aza-stan-azamattary-staldy>
58. <https://sn.kz/sn-akparat-agyny/5977-islam-memleketini-kapitaly-1-5-mlrd-dollardy-rajdy>
59. <https://sn.kz/sn-akparat-agyny/5875-islam-memleketi-zhas-sodyrlardy-dayarlajty-zh-je-rma>
60. <https://sn.kz/o-am/5550-m-zhilis-deputaty-k-rim-m-simovten-la-kestikke-arsy-k-resti-k-shejtudi-s-rady>
61. <https://sn.kz/o-am/1806-ekstremizmni-aldyn-aludy-y-ty-negizderi>
62. <https://sn.kz/o-am/1804-ara-andyly-meditsina-yzmetkerlerine-dini-radikalizmge-arsy-t-ru-zholdary-t-sindirildi>

63. <https://sn.kz/sn-zan-zaman/1687-temirtauda-terrorizm-zh-ne-ekstremizmmen-k-res-m-seleleri-tal-ylandy>
64. <https://sn.kz/o-am/541-a-yz-adam-zhurnalyny-redaktoryna-ekstremizmdi-a-tady-degen-zha-a-ajyp-ta-yldy>
65. https://www.inform.kz/kz/ekstremizm-terrorizm-separatizm-dinge-zhat-ugym_a3572197
66. <http://prokuror.gov.kz/kaz/baspasoz/makalalar/ekstremizm-men-terrorizmge-karsy-kimyl-kogam-turaktylygynyn-kepili>
67. <https://azh.kz/kz/news/view/8318>
68. https://www.inform.kz/kz/zhastar-arasyndagy-dini-ekstremizmnin-kalay-aldyn-aluga-bolady_a3572203
69. https://kaz.tengrinews.kz/kazakhstan_news/sagyintaev-ekstremizm-men-terrorizmge-karsyi-s-kimyl-275091/
70. <https://ustinka.kz/kz/kazakhstan/politics/35278.html>
71. <https://sputniknews.kz/incidents/20190602/10353234/Almaty-ekstremizm-ush-er-adam.html>
72. https://kazakh-tv.kz/kz/view/news_kazakhstan/page_172092_ekstremizm-men-terrorizmge-toskauyl-koyu-kazhet
73. <http://www.nkzu.kz/news/view?id=6593>
74. <https://www.ktk.kz/kz/programs/novosti/70984/>
75. <https://adyrna.kz/post/20826>
76. <https://egemen.kz/article/167748-ekstremizm-men-terrorizmninh-aldyn-alu-dgayy-talqylandy>
77. https://www.kt.kz/kaz/state/kazakstanda_ekstremizm_zhane_terrorizm_kilmisina_k_ars_i_kilmistik_zhauapkershilik_kushejtilei_1153626546.html
78. <https://www.vuzkunaeva.kz/index.php/kz/main-news-kz/666-otchet-o-provedenii-kruglogo-stola-na-temu-protivostoyanie-religioznomu-ekstremizmu-i-terrorizmu-problemy-i-puti-resheniya-kz>
79. https://mks.gov.kz/press-sluzhba/novosti_ministerstva/?cid=0&rid=1703
80. <https://khabar.kz/kk/muragat-ajbyn/item/69847-ajbyn-aza-standa-ekstremizm-zh-ne-terrorizmmen-k-resetin-arnajy-zhasa-tar>
81. http://old.baq.kz/kk/news/aimaktik_bak_muragat/regmedia-43237
82. https://kaz.tengrinews.kz/kazakhstan_news/kazakstanda-biyil-3-terraktnn-jolyi-kesld-ukk-303537/
83. https://kaz.tengrinews.kz/kazakhstan_news/jusan-operatsiyasyi-jalgasadyi-303348/
84. <https://kaz.tengrinews.kz/crime/turkstanda-lankestkke-undegen-turgyin-sottaldyi-301212/>
85. https://kaz.tengrinews.kz/kazakhstan_news/kazakstanda-yakyin-inkar-uyyimy-ekstremistk-dep-tanyldyi-292726/
86. <https://kaz.tengrinews.kz/crime/shyimkentte-terakt-jaylyi-jalgan-habar-bergen-er-adam-297604/>
87. <https://egemen.kz/article/200109-saqshy>
88. <https://egemen.kz/article/179465-islam-dgane-terrorizm-odaqtas-pa-alde-qarsylas-pa>
89. <https://egemen.kz/article/168315-qostanayda-telefon-terroristerininh-qonhyrauynan-kelgen-shyghyn-35-million-tenhg>
90. <https://egemen.kz/article/163332-terrorizmmen-kures-%E2%80%93-barshanynh-mindeti>
91. <https://egemen.kz/article/165064-bylytyr-zorlyq-zombylyqty-nasikhattaytyyn-9-mynhgha-dguyq-sayt-dgumysy-toqtatyldy>
92. <https://holanews.kz/view/news/19435>
93. <https://holanews.kz/view/news/15040>

94. https://kaz.tengrinews.kz/kazakhstan_news/sak-bolyinyizdar-ukk-youtube-jelsnde-video-jariyaladyi-304143/
95. https://kaz.tengrinews.kz/kazakhstan_news/40-kazakstandyik-shetelde-sodyirlar-kataryinda-jur-ukk-303347/
96. <https://www.ktk.kz/kz/blog/article/2016/10/05/72691/>
97. <https://www.ktk.kz/kz/blog/article/2016/07/25/71025/>
98. <https://www.ktk.kz/kz/news/video/2015/01/23/56859/>
99. <https://www.ktk.kz/kz/news/video/2018/03/13/91918/>
100. <https://kaz.nur.kz/1825896-abaev-elimizde-kimderge-ekstremizm-kaupi-tnip-trganyin-mlimdedi.html>
101. <https://informburo.kz/kaz/azastan-islamny-ltty-modeln-zhasau-kerek.html>
102. <https://www.zakon.kz/4848681-terrorizm-elge-t1257ngen-1179au1110p.html>
103. <https://www.zakon.kz/video/v/73690.html>
104. <https://www.zakon.kz/video/v/13765.html>
105. <https://www.zakon.kz/video/v/3983.html>
106. <https://www.zhasalash.kz/article/5657-uqk-qazaqstanda-20-mynhnan-astam-adam-ekstremizmdi-dgaqtaydy>
107. <https://www.zhasalash.kz/article/685-alla-men-adam-arasyn-saudalap-dgurgenderdinh-maqsaty-ne>
108. <https://www.zhasalash.kz/article/1021-eklektika-ekstremizmi>
109. <http://kazaknews.kz/okiga/jekstremizm-men-terrorizm-m-seleleri/>
110. <http://kazaknews.kz/tehnologiya/aza-standa-tyjym-salyn-an-18-my-sajt-belgili-boldy/>
111. <http://kazaknews.kz/okiga/a-t-be-oblysynda-bylytyrdan-beri-terrorizm-ajybymen-13-adam-t-rmege-amaldy/>
112. <http://kazaknews.kz/okiga/k-radikalizmge-arsy-sharalar-zhasa-tajdy-2018-de-3-la-kestik-reketti-aldy-alyn-an/>
113. <http://kazaknews.kz/kogam/sirija-auma-ynan-kelgen-balalal-dn-synamasynan-tedi/>
114. https://www.azattyq.org/a/kazakhstan_students_are_warned_about_foreign_enemies_and_terrorist_plots/24538460.html
115. <https://www.azattyq.org/a/kazakhstan-chinese-kazakhs-who-cross-the-border/30391639.html>
116. <https://www.azattyq.org/a/30011733.html>
117. <https://www.azattyq.org/a/kazakhstan-aktobe-syria/29998676.html>
118. <https://qazaqtimes.com/article/12721>