

ИНФОРМАТИКА COMPUTER SCIENCE

МРНТИ 20.53.21
УДК 004:371.315.7

<https://doi.org/10.51889/2959-5894.2023.81.1.014>

А.С. Баймаханова^{1*}, К.М. Беркимбаев¹, А.К. Жумадилаева², Г.Д. Кошанова¹

¹Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті, Түркістан қ. Қазақстан

²Л.Н.Гумилев атындағы Еуразия ұлттық университеті, Астана қ. Қазақстан

*e-mail: aygerim.baymakhanova@ayu.edu.kz

ТЕРЕҢ ОҚЫТУДЫҢ КОНВОЛЮЦИЯЛЫҚ НЕЙРОНДЫҚ ЖЕЛІЛЕРМЕН ӨЗАРА БАЙЛАНЫСЫ

Аңдатпа

Мақалада нақты тапсырмалар үшін терең оқыту алгоритмдерін қолдану қарастырылды және осы процестерде қолданылатын әдістер зерттелді. Ұсынылған зерттеу «терең оқыту» машиналық оқыту қауымдастығына қатысты деген түсінікке негізделген және соған сай ғалымдардың зерттеу жұмыстары қарастырылған. Терең оқытудың нейрондық желілерінің өзара байланысы зерттелді. Машиналық оқыту жиынтықтарын терең оқыту жиыны ретінде тұжырымдауға болады, ал жасанды интеллект жиынтықтары ішкі жиынтықты білдіреді.

Сонымен қатар терең оқытуда, әсіресе кескіндерді классификациялауда ауқымды тапсырмаларды орындаудың тиімді және заманауи әдісі ретінде конволюциялық нейрондық желілерді (CNN) пайдалану деп тұжырымдалады. Болжауды үйретуге арналған құрастырылған тапсырмалардың мысалдары келтірілген және терең оқыту моделін енгізу нәтижелері талданған. 11 000 құжат сканерленіп, Python бағдарламасының көмегімен атаулары бойынша жіктелді. Tensorflow, Keras кітапханаларының көмегімен құжаттар қалыпты үлгіге түрлендірілді. Нәтижесінде деректер жинақталып, талданды.

Түйін сөздер: жасанды интеллект, машиналық оқыту, терең оқыту, CNN, Python бағдарламасы, keras.

Аннотация

А.С. Баймаханова¹, К.М. Беркимбаев¹, А.К. Жумадилаева², Г.Д. Кошанова¹

¹Международный казахско-турецкий университет имени Ходжи Ахмеда Ясави, г. Туркестан, Казахстан

²Евразийский национальный университет имени Л.Н. Гумилева, г.Астана, Казахстан

ВЗАИМОДЕЙСТВИЕ ГЛУБОКОГО ОБУЧЕНИЯ СО СВЕРТОЧНЫМИ НЕЙРОННЫМИ СЕТЯМИ

В статье рассматривается применение алгоритмов глубокого обучения для конкретных задач и исследуются методы, используемые в этих процессах. Представленное исследование основано на представлении о том, что «глубокое обучение» имеет отношение к сообществу машинного обучения, и исследовательская работа ученых рассматривается соответствующим образом. Исследована взаимосвязь нейронных сетей глубокого обучения. Наборы машинного обучения могут быть концептуализированы как наборы глубокого обучения, а наборы искусственного интеллекта представляют собой подмножества.

В статье также утверждается, что использование сверточных нейронных сетей (CNN) является эффективным и современным методом для выполнения крупномасштабных задач в области глубокого обучения, особенно классификации изображений. Представлены примеры построенных задач для прогнозного обучения и проанализированы результаты реализации модели глубокого обучения. 11 000 документов были отсканированы и классифицированы по заголовкам с помощью Python. Документы были преобразованы в обычную модель с использованием библиотеки Tensorflow и Keras. В результате данные были собраны и проанализированы.

Ключевые слова: искусственный интеллект, машинное обучение, глубокое обучение, CNN, программа Python, keras.

Abstract

INTERACTION OF DEEP LEARNING WITH CONVOLUTIONAL NEURAL NETWORKS

Baimakhanova A.S.¹, Berkimbaev K.M.¹, Zhumadillayeva A.K.², Koshanova G.D.¹

¹*Khoja AkhmetYassawi International Kazakh-Turkish University, Turkistan, Kazakhstan*

²*L.N Gumilyov Eurasian National University, Astana, Kazakhstan*

This article discusses the application of deep learning algorithms to specific problems and explores the methods used in these processes. The presented research is based on the notion that "deep learning" is relevant to the machine learning community, and the research work of scientists is treated accordingly. The interconnection of deep learning neural networks has been investigated. And machine learning sets can be conceptualized as deep learning sets and artificial intelligence sets are subsets.

It also claims that the use of Convolutional Neural Networks (CNN) is an efficient and modern method for performing large-scale tasks in deep learning, especially image classification. Examples of constructed tasks for predictive learning and analyzes the results of implementing a deep learning model. 11 000 documents were scanned and classified by title using Python. The documents have been converted to a regular model using the Tensorflow library and Keras. As a result, the data was collected and analyzed.

Keywords: artificial intelligence, machine learning, deep learning, CNN, python program, keras.

Кіріспе

Бейнелерді тануға негізделген терең оқыту (глубинное обучение; ағылш. Deep learning) – машиналық оқытудың әдістердің жиынтығы болып табылады. Терең оқытуға негізделген бейнені тану оқытушының көмегімен (бақылаумен оқыту), оқытушысыз (бақылаусыз оқыту) және шектеулі бақылаумен (жартылай бақылау арқылы оқыту) жүзеге асырылуы мүмкін. Ерекшелік/бейнелеуді оқыту (ағылш. feature/representation learning) нақты тапсырмаларға арналған алгоритмдердің негізін құрайды. Бейнені тану үшін терең оқыту әдістерінің негізгі ерекшеліктерінің бірі – қолдан жасап емес, бастапқы деректерді қолдана отырып автоматты түрде өзінше үйрену мүмкіндігі болып табылады.

Терең оқыту әдістерінің даму тарихына үңілетін болсақ, терең оқытудың әдістерінің көп бөлігі 1980-ші жылы белгілі болғаны мәлім (Шектеулі Больцман машинасы нейрондық желілерді арнайы бағытталмаған графикалық модельмен алдын ала оқытуды ұсынды). Алайда, олардың нәтижелері басып шығарылмайтын болғандықтан, жасанды-нейрондық желілердің теориясында алға жылжуына кедергі келтірді. Ал, 2000 жылдардың ортасындағы есептеуіш нейрондық желілердің күрделі техникалық архитектурасын әзірлеу, өнімділікті қамтамасыз ету және көптеген ықтимал мәселелерді шешу үшін графикалық үдеткіштер, пайдаланушы бағдарламалайтын клапан матрицасының әртүрлі формаларын пайдаланды. Нәтижесінде тиімді шешілмеген тапсырма түрлері анықталды. Атап айтқанда, компьютерлік енгізу, машиналық аударма және т.б. мәселелердің сапасы мен тиімділігі төмен нәтиже көрсеткендігі анықталған [1].

1986 жылы Dekhter, R. жұмысынан кейін машиналық оқытудың ғылыми қауымдастығындағы "терең оқыту" терминін ғалымдар А. Г. Иваненко мен В. Григорьевич енгізді, олардың кітабында терең қабатты қабылдауды тікелей тарату бойынша алғашқы жұмыстардың бірі жарық көрді және оған алгоритм жасалды. Сонымен қатар, тану секілді тереңірек архитектураларға мамандану себепті 1980 жылы К. Fukushima ұсынған неокогнитроннан бас тартты [2].

Jan LeCun 1989 жылы қателерді тарату алгоритмін қолданып, терең нейрондық желіні қолжазба пошталық кодтарды тануға үйрету үшін модельді оқытуға үш күн жұмсады. Дегенмен, бұл әдісті практикалық қолдану компьютерлердің баяу оқу жылдамдығына байланысты шектелді, бұл бірнеше факторларға, соның ішінде 1991 жылы Jorgen Schmidhuber және Sepp Hochreiter талданған градиентті жоғалту мәселесіне байланысты болды, олар осы мәселелерге жауап ретінде 1990 жылдары векторлық нейрондық желілерді әзірледі.

1991 жылы мұндай жүйе жеке екі өлшемді қолжазба сандарын көрсету үшін пайдаланылды, ал үш өлшемді нысандарды тану екі өлшемді кескінді қолмен салынған үш өлшемді нысан үлгісімен салыстыру арқылы жүзеге асырылды. 1992 жылы үш өлшемді нысандардағы белгісіз белгілерді тану үшін Crecerptron моделі құрылды [3].

1994 жылы Andre de Carvalho, Mike Fairhurst және David Bissett бірлесіп отырып үш деңгейлі ұйымдық нейрондық желі (SOFT) модулінен иерархиялық классификациялық нейрондық желіге (GSN) түрлендірілген көп деңгейлі логикалық нейрондық желінің эксперименттік нәтижелерін жариялады. Әр модуль бөлек оқытылады. Модульдегі әрбір деңгей алдыңғы деңгейге қарағанда күрделірек элементтерді шығарады.

1995 жылы Geoff Hinton, Peter Dayan, Brendan Frey және Radford Neal бірлесіп әзірленген ұйқы-ояту алгоритмін алты барлық қосылған қабаттар мен жүздеген бірліктері бар желіні оқыту үшін пайдалануға болатынын көрсетті [4].

1990-2000 жылдары жасанды нейрондық желілердің есептеу құны Габор сүзгілері және тірек векторлық машиналар (ins, ENG. ANN) сияқты қарапайым үй модельдерін танымал етті. Мидың биологиялық желілерін қосу қажеттілігі туралы қате түсінікті түбегейлі жойды. Бұл әдіс гетерогенді Гаусс және Марков модельдерін ажыратуға үйретілген жасырын генеративті сөйлеу модельдеріне сүйенбейді. Нейрондық болжау модельдеріндегі градиенттің төмендеуі және уақыттық корреляцияның әлсіз құрылымы сияқты негізгі мәселелер талданды [5]. Одан бөлек мәселелер оқу деректері мен есептеулердің шектеулілігінде болды.

2000-шы жылдардың ортасында терең оқыту бірнеше факторларға байланысты танымалдылыққа ие болды. Біріншіден, компьютерлер өте үлкен нейрондық желілерді жаттықтыру үшін жеткілікті қуатты болды, бұл оқу процесін жеделдету үшін GPU пайдалануды қажет етті. Екіншіден, бұл желілерді масштабта оқыту үшін қол жетімді көптеген үлкен деректер жинақтары болды. Ал, жасанды нейрондық желілер саласында маңызды теориялық жаңалықтар болды. Осындай дамудың бірі Hinton, G. E., Osindero, S. және Teh, Y. жұмысында көрсетілді, онда олар көп деңгейлі нейрондық желінің әрбір қабатындағы шектеулер оны Больцман машинасы ретінде дербес оқыту үшін пайдаланылуы мүмкін екенін көрсетті. Бұл керітаратуды қолдану арқылы осы желілерді тиімді зерттеуге мүмкіндік берген.

2012 жылы George E. Dahl бастаған топтардың жеке дәрі-дәрмектердің биомолекулалық мақсаттарын болжау үшін көп мақсатты нейрондық желілерді қолдануының нәтижесінде, Merck Molecular Activity Challenge-де жеңіске қол жеткізді.

2014 жылы Хохрейтер АҚШ химиялық заттардың, қоректік заттардың, үй бұйымдарының және фармацевтикалық препараттардың қоршаған ортаға әсерлерін анықтау үшін терең оқытуды қолданып, NCATS денсаулық сақтау институтының "Tox21 Data Challenge" марапатына ие болды [6].

Дегенмен, машиналық оқыту алгоритмдерінің құрылымдық күрделілігі және тірі тіршілік иелерінің интеллектінің күрделілігі, әсіресе жасанды интеллект (AI) тұрғысынан зерттеудің маңызды тақырыптарына айналды. Объектілерді тану алгоритмдерін дамыту 2011 жылдан 2012 жылға дейін айтарлықтай прогреске қол жеткізді, конвульсиялық нейрондық желілердің (CNN) ондаған жылдарда болған және GPU көптеген нейрондық желілердің бойы, яғни CNN -ді енгізгенімен, GPU-де іске асыру компьютерлік көруді жылдамдату үшін қолданылған. Көптеген жылдар бойы конволюциялық нейрондық желілердің (CNN) болуына және компьютерлік көруді жеделдету үшін GPU арқылы көптеген нейрондық желілердің (соның ішінде CNN) енгізілуіне қарамастан, 2011 және 2012 жылдар аралығында объектілерді тану алгоритмдерін әзірлеуде айтарлықтай прогреске қол жеткізілді. 2011 жыл бұл әдістердің визуалды үлгіні тану конкурсында, атап айтқанда ICDAR қолжазбалар байқауында бірінші жетістігін атап өтті, содан кейін 2012 жылдың мамырында ISBI кескін сегментациясының байқауында бас жүлдені жеңіп алған болатын.

2013 жылдан 2014 жылға дейін Deep Learning қосымшаларының дамуы ImageNet тапсырмаларының қателік жылдамдығының айтарлықтай төмендеуіне әкелді, бұл сөйлеуді тану үрдісінің артуына әкелді. Stephen Wolfram да өзінің кескінді сәйкестендіру жобасында бұл жақсартуды сынап көрді. Сонымен қатар, кескінді жіктеу үшін қолтаңбаларды жасау сияқты күрделі әдістерді пайдалану осы уақыт ішінде конволюциялық нейрондық желілер (CNN) және ұзақ қысқа мерзімді жад (LSTM) үлгілерін пайдалануға баса назар аудара бастады [7]. Көптеген сарапшылар ImageNet-тің 2012 жылдың қазан айындағы жетістігі жасанды интеллект саласын түбегейлі өзгерткен «Терең оқу төңкерісі» деп аталатын маңызды кезең болды деп санайды. Терең нейрондық желілермен есептеудің негізгі элементі ретінде концептуализациялауға қосқан үлесі үшін Joshua Bengio, Jeffrey Hinton және Ian LeCun 2019 жылдың наурыз айында Тьюринг сыйлығымен марапатталды. Deep Learning алгоритмдері – жоғары деңгейлі абстракцияларды модельдеу үшін сызықтық емес түрлендірулер сериясын пайдаланатын машиналық оқытудың бір түрі [8]. Терең оқыту әдістерін дамыту үлгілердің дәлдігі мен тиімділігін арттыру үшін үздіксіз зерттеулер жүргізуді қажет етеді. Банк, денсаулық, көлік, қауіпсіздік және басқа да маңызды болып табылатын салалардағы бейнені тану мүмкіншіліктерін кеңінен пайдалану жаңа заман талабына сай болып тұр. Мысалы, банк қосымшалары ұсынатын «тұтынушы карточкасының 12-сандық нөмірін» бейнесі арқылы енгізу мүмкіншілігі бірден бір себеп. Осыған орай, терең оқытудың нақты тапсырмаларға арналған алгоритмдері, оның көптеген әдістерінде қолданылатын қадамдарды қарастыру маңызды мәселе болып отыр.

Зерттеу әдіснамасы

Зерттеу кескінді тану, тілді өңдеу, сөйлеуді тану және биоинформатика сияқты әртүрлі қолданбаларға арналған терең оқыту және машиналық оқыту әдістеріне сүйенеді. Конволюциялық нейрондық желілер (CNN) кескінді жіктеу тапсырмалары үшін ең көп қолданылатын терең оқыту алгоритмі зерттеудің басты әдісі ретінде қолданылды. Нейрондық желілердің жұмысын жақсарту үшін таңбаланбаған деректерден үйренуді қамтитын бақылаусыз оқыту жолдары қолданылды. Сонымен қатар, зерттеуді жүзеге асыру барысында табиғи тілді өңдеу (NLP) құжаттарды автоматты түрде жіктеу және өңдеу үшін тиімді әдістердің бірі болып табылды. Соңында, әртүрлі жасанды интеллект мәселелерін шешуге арналған күрделі жүйелерді жасау үшін Больцманның машиналық оқытуы, автокодерлер, терең сенім желілері, генеративті-қарсылас желілер және сарапшылық оқыту жүйелері сияқты әртүрлі әдістер пайдаланылды.

Зерттеу материалдары ретінде 11 000-нан астам сканерленген құжаттар қолданылды. Деректермен жұмыс жасау барысында, деректерді өңдеу, талдау және бейнелерді жинақтау секілді зерттеу әдістері де орын алды. Нәтижесінде, құжаттар Python бағдарламасы арқылы жіктелді және сақталды, ал құжаттар Tensorflow және Keras кітапханасын қолданатын стандартты пішімге түрлендірілді.

Зерттеу нәтижелері мен талқылау

Конволюциялық нейрондық желілер (CNN) компьютерлік тапсырмаларды, әсіресе кескіндерді тиімді және заманауи классификациялау үшін терең оқытуда кеңінен қолданылады. Бейне талдау әдістерінен айырмашылығы, CNN қабаттардан қажетті мүмкіндіктерді алуды автоматтандырады, құжаттарды қолмен жіктеуді қажет етпейді. Терең оқытудың алғашқы күндерінде Больцманның машиналық оқытуы, автокодерлер, терең нейрондық желілер, генеративті-қарсылас желілер, оқытушы дайындаған сараптамалық оқыту жүйелері, конволюциялық нейрондық желілер және нейрондық желілерді пайдаланып бақылаусыз оқыту сияқты әртүрлі әдістер мен олардың вариациялары әзірленді. Осы әдістерді біріктіру тізбек элементтері мен тізбектерді қайталанатын жүйеде қосу арқылы жасанды интеллект мәселелерінің ауқымын шешуге қабілетті күрделі жүйелерді жасайды.

Құжаттарды классификациялауға жататын кластары белгілі объектілернегізінде жүргізіледі. Біздің зерттеуіміздегі цифрлық мұрағаттардағы құжаттар ең алдымен визуальды түрде, онан соң, жіктелмейтін құжаттар табиғи тілде өңдеу (NLP) арқылы кластарға жіктеледі. Оның ішінде әртүрлі бөлімдерге сәйкес классификацияланған құжаттардың кластар саны – 10 шамасында, ал жинақталған құжаттар саны – 11000 нан аса болды. Құжаттардың кластары: Студенттердің бұйрығы, өндірістік бұйрықтар, өкімдер, Мемлекеттік органдардың студенттің университетте оқуы жайлы мәлімет, қызмет хат, Жоғарғы білім туралы жеке атпен берілген дипломдар, жеке іс-құжаты, диплом қосымшасы дубликаты, диплом, антиплагиат тексеру болып жіктелді (сурет 1).

Студенттердің бұйрықтары оқу жылының бұйр...	я	4 июн. 2022 г. я
Өндірістік бұйрықтар	я	29 мар. 2022 г. я
Өкімдер	я	4 июн. 2022 г. я
Мемлекеттік органдардан студенттің университе...	я	7 дек. 2022 г. я
Қызмет хат	я	4 июн. 2022 г. я
Жоғарғы білім туралы жеке атпен берілген дипл...	я	16 мар. 2022 г. я
Жеке іс-құжат	я	14 июл. 2022 г. я
Диплом қосымшасы дубликаты	я	24 нояб. 2022 г. я
Диплом	я	4 июн. 2022 г. я
Антиплагиат тексеру 2021-2022 Дипломдық жұм...	я	7 дек. 2022 г. я

Сурет 1. Жинақталған құжаттардың кластары

Терең оқыту - бұл тапсырмаға қатысты деректерді ұсынумен айналысатын машиналық оқыту әдістерінің жиынтығы. Кескін контекстінде пикселдер мәндердің интенсивтілік векторлары, дерексіз примитивтер немесе белгілі бір пішіннің аймақтары сияқты әртүрлі пішіндерде ұсынылуы мүмкін.

Терең оқыту жүйелері тиімді алгоритмдерді және мүмкіндіктерді иерархиялық алуды қолдану арқылы мүмкіндіктерді таңдау және баптау процесін оқытушының аз немесе мүлде енгізуінсіз немесе ішінара оқытушы деңгейінде автоматтандырады. Осы саладағы анықталмаған деректер жұмыс модельдерін нақтылау үшін ауқымды зерттеулер жүргізуге мүмкіндік берді. Кейбір тәсілдерге нейрондық жетістіктер, ақпаратты өңдеудің сәтті сипаттамасы, жүйке жүйесінің модельдерін құрудағы байланыс, жүйке қозғыштығы мен реакция арасындағы байланыс және электрлік белсенділікті анықтайтын нейрондық кодтар нәтижесінде мидағы жүйке жүйесінің дамуы жатады.

Терең оқыту қосымшалары айтарлықтай жетістікке жеткенімен, білу керек негізгі шектеулер де бар. Терең оқыту үлгілері нақты мақсаттарды ескере отырып жасалған және деректер алуан түрлілігінің үздіксіз геометриялық көрсетілімдері үшін әрқашан қолайлы бола бермейді.


Терең оқыту жүйелері компьютерлік тілді өңдеу, сөйлеуді тану, кескінді тану, дыбысты өңдеу және биоинформатика сияқты әртүрлі салаларда қолданылды және алдыңғы әдістермен салыстырғанда өнімділіктің айтарлықтай жақсарғанын көрсетті [9]. Терең оқытудың қалай қызмет ететінін түсіну үшін терминологиядағы кейбір негізгі айырмашылықтарды түсіну қажетті. Нейрондық желілер компьютердегі жасанды нейрондардың қабаттарын пайдалана отырып, адам миының жұмысын қайталауға бағытталған. Жасанды интеллект машинасы немесе бағдарламасы есептеулерді орындау арқылы шешімдер таба алады. ЖИ зерттеулерінің алғашқы кезеңдерінде ғалымдар адамның интеллектісін арттыру мәселесінің ойнау арқылы шешуге тырысты. Олар компьютер ұстануға тиіс көптеген ережелерді енгізді, бұл оған ықтимал әрекеттердің нақты тізімінесәйкес шешім қабылдауға мүмкіндік берді. Екінші жағынан, машиналық оқыту компьютерлерді алдын ала анықталған ережелерге сүйенбей, деректердің үлкен көлемінен өздігінен үйренуге үйретуді қамтиды.

Бақыланатын оқыту кірістер мен сәйкес күтілетін нәтижелерден тұратын алдын ала анықталған деректер жиынтығын пайдалануды талап етеді. Бұл тәсіл оқытушы басшылығымен нейрондық желіні оқыту кезінде кіріс және шығыс мәндерін қамтамасыз етеді [10]. Итеративті процесс желі жұмыс істеп тұрған кезде жүреді және аяқталады.

Бақыланатын оқу тапсырмасының типтік мысалы ауа-райын болжау болып табылады, мұнда нейрондық желілер тарихи деректерді пайдалана отырып, ауа райын болжауды үйренеді. Жаттығу деректері қысым, ылғалдылық және жел жылдамдығы сияқты кіріс айнымалыларын, сондай-ақ сәйкес шығыс мәндерін қамтиды. Керісінше, бақылаусыз оқыту (supervised learning) машиналық оқытуда белгісіз құрылымның бірыңғай деректер жиынтығы болып табылады.

Нейрондық желі бақылаусыз оқытылатын болса, ол деректердің логикалық жіктелуін дербес орындауға қабілетті. Бұл тәсіл әсіресе интернет-дүкенге келушілер сияқты бақыланбайтын оқу әрекеттерін болжауда пайдалы. Мұндай жағдайларда желіні үйрету үшін тұрақты деректер болмауы мүмкін. Оның орнына ол кірісті санаттайды және пайдаланушылардың әртүрлі өнімдерді қаншалықты жиі пайдаланатынын егжей-тегжейлі көрсетеді.

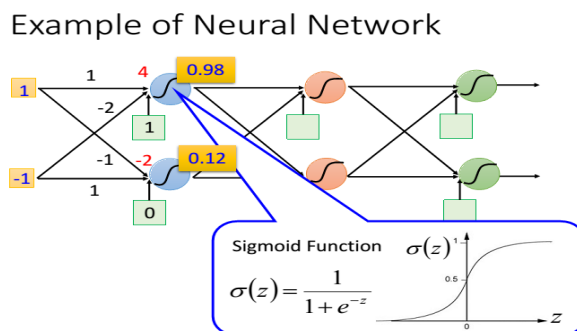
Терең оқыту – модель енгізу нәтижелерін пайдаланып болжау жасауға мүмкіндік беретін машиналық оқыту әдісінің белгілі бір түрі. 2-суретте деректер желісін бақылаудатерең оқытуды қолдану үшін оның жасырын қабаттары көрсетілген.



Сурет 2. Терең оқытудың жасырын қабаттары

Терең оқытудың нейрондық желілерін екі негізгі бөлікке бөлуге болады: көрінетін қабат және жасырын қабат. Көрінетін қабат кіріс деректерін қабылдап, кескіндегі жиектердің орналасуын анықтайтын жасырын қабатқа жібереді.

Содан кейін келесі қабат нейрондардың комбинациясы арқылы жасалған пішіндерді анықтауға тырысады және бұл процесс оқу деректеріне негізделген ұсынылған сыныптағы кескінді анықтау үшін көптеген қабаттар арқылы жалғасады (3-сурет).



Сурет 3. Жасанды нейрондық желілердің өзарабайланыстынейрондары

Нейрондық желіде нейрондардың үш түрлі қабаты бар:

- Кіріс қабаты;
- Жасырын қабаттар;
- Шығыс қабаты.

Бұл мысалда кіріс қабаты үшу әуежайын, тағайындалған әуежайды, ұшу күнін және әуе компаниясын көрсететін төрт нейроннан тұрады. Содан кейін бұл деректер кірісте математикалық есептеулерді орындайтын бірінші жасырын қабатқа жіберіледі. Әрбір қабат үшін жасырын қабаттар мен нейрондардың сәйкес санын анықтау - нейрондық желіні құрудағы маңызды міндет болып табылады.

«Терең оқыту» термині бірнеше жасырын қабаттардың болуын көрсету үшін «терең» сөзін қолданады, ал шығыс қабаты түпкілікті нәтиже береді, бұл біздің жағдайда болжамды билет бағасы. Бағаны есептеу терең оқыту тетіктерін қолдануды көздейді. Желідегі нейрондарға кіріс элементтерінің маңыздылығын анықтайтын арнайы тапсырмалар тағайындалады. Бастапқыда бұл тапсырмалар кездейсоқ түрде тағайындалады [11].

Әрбір нейронның іске қосылу функциясын математикалық тәсілсіз түсіну қиын. Оның мақсаттарының бірі нейрондардың шығуын «стандарттау» болып табылады. Кіріс жинағы нейрондық желінің барлық қабаттарын басып өткеннен кейін, белсендіру функциясы шығыс қабаты арқылы соңғы нәтижені көрсетеді. Нейрондық желіні оқыту терең оқытудың ең қиын аспектісі болып табылады, өйткені ол үлкен деректер жиынтығы мен айтарлықтай өңдеу қуатын қажет етеді.

Билеттердің бағасын анықтау үшін билет бағасының тарихи деректері, әуежайлар мен ұшып шығу күндерінің көптеген комбинацияларына байланысты кең ауқымдағы баға тізімдері қажет.

Нейрондық желіні оқыту үшін оны оқытылған деректермен қамтамасыз ету керек, содан кейін нәтижелерді сынақ деректер жинағымен салыстыру керек. Танымалмаған құжаттарға арналған үлгіні танумен жұмыс істегенде, дұрыс емес нәтижелерді алу қаупі бар [12].

Түпкі мақсат – 100% дәлдікке қол жеткізу, бұл желінің шығыс нәтижелері сынақ деректер жинағының нәтижелеріне дәл сәйкес келетінін білдіреді. Дегенмен, нөлдік қателікке жету үшін нейрондарды кездейсоқ реттеу әрқашан тиімді шешімге әкелмеуі мүмкін [13].

Біз функцияның минимумын табу үшін қажет градиентті түсіру әдісін қолдандық. Біздің жағдайда дәлдік тұрғысынан минимумды іздейміз. Бұл әдістеменің негізгі принципі әрбір итерация үшін шағын масштабтау коэффициентін қамтиды. Берілген салмақ жиынтығын қолдана отырып, шығын функциясының туындысын есептеу арқылы біз минимумның қай бағытта екенін анықтай аламыз. Шығындарды азайтуға қол жеткізу үшін деректерді бірнеше рет сұрыптау қажет, бұл айтарлықтай есептеу қуатын қажет етеді. Салмақты реттеу градиентті сақтай отырып, автоматты түрде жүзеге асады, бұл контексте терең оқытудың маңыздылығын көрсетеді.

Тест трайн процесі модельдің дәлдігін бағалау үшін пайдаланылады, мұнда параметрлер бірінші және екінші айналымдар арасында тұрақты болып қалады. Бірақ 1000 датамен тексерілу нәтижесінде CNN шығады.

Деректерді өңдеу талдау үшін маңызды қадам болып табылады. Бастапқыда бейнелер жинақталып, қазіргі таңда 11 мың құжат сканерленіп, құрастырылған. Құжаттар олардың атаулары бойынша сақталды және сұрыпталды, ал іздеу процесі Python бағдарламасының көмегімен жеңілдетілді (4-суретте көрсетілгендей). Ақырында, құжаттар Tensorflow және Keras кітапханасын қолданатын стандартты пішімге түрлендірілді.

```
#install
!pip install pdf2image

Looking in indexes: https://pypi.org/simple, https://us-python.pkg.dev/colab-wheels/public/simple/
Collecting pdf2image
  Downloading pdf2image-1.16.0-py3-none-any.whl (10 kB)
Requirement already satisfied: pillow in /usr/local/lib/python3.7/dist-packages (from pdf2image) (7.1.2)
Installing collected packages: pdf2image
Successfully installed pdf2image-1.16.0

[ ] !apt-get install poppler-utils

Reading package lists... Done
Building dependency tree
Reading state information... Done
The following package was automatically installed and is no longer required:
  libnvidia-common-460
Use 'apt autoremove' to remove it.
The following NEW packages will be installed:
  poppler-utils
0 upgraded, 1 newly installed, 0 to remove and 49 not upgraded.
Need to get 154 kB of archives.
After this operation, 613 kB of additional disk space will be used.
Get:: http://archive.ubuntu.com/ubuntu bionic-updates/main amd64 poppler-utils amd64 0.62.0-2ubuntu2.12 [154 kB]
Fetched 154 kB in 0s (2,396 kB/s)
Selecting previously unselected package poppler-utils.
(Reading database ... 155639 files and directories currently installed.)
Preparing to unpack .../poppler-utils_0.62.0-2ubuntu2.12_amd64.deb ...
```

Сурет 4. Құжаттарды іздеу барысы

Зерттеудің нәтижесінде келесі терең оқытуды пайдалану арқылы әуе билеттерінің бағасын болжау үшін пайдалануға болатын жолдар ұсынылды.

- Нейрондық желілер машиналардың интеллектін арттыру үшін терең оқытуда қолданылды.
 - Нейрондық желілер үш типті қабаттардан тұрады, атап айтқанда кіріс қабаты, жасырын қабаттар және шығыс қабаты.
 - Нейрондар арасындағы байланысқа кіріс компонентінің маңыздылығына негізделген тапсырма тағайындалды.
 - Терең нейрондық желіні үйрету үшін айтарлықтай үлкен көлемде деректер жинақталды.
- Шығыс нәтижелерін кіріс деректерімен салыстыру арқылы алгоритмнің қателік деңгейін көрсету үшін «жоғалту функциясы» есептелінді.

Әрбір итерациядан (epoch) кейін жоғалту функциясын азайту үшін нейрондар арасындағы салмақтар градиенттің түсуі арқылы реттелінді. Осыған орай, 1-кестеде дәлдік тұрғысынан таңба деңгейімен CNN-ді пайдаланудың тиімділігі көрсетілген.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Accuracy – барлық класстар бойынша үлгінің жалпы болжамды дәлдігін сипаттайтын көрсеткішке ие. Дұрыс болжамдар санының олардың жалпы санына қатынасы ретінде есептеледі.

Кесте 1. CNN қолдану нәтижесі

Алгоритм классификациясы	Дәлдік тұрғысынан
Терең оқыту (CNN)	0,96

Соған қоса, Hikvision DeepinView IP камералары және DeepinMind сериялы NVR құрылғылары сияқты смарт бейнебақылау құрылғыларының жұмыс принциптері терең оқыту технологиясына қатты сүйенеді. Бұл технология әртүрлі салаларда кең қолданыс тапты. Осы камералардың жинақталған құжаттарды зерттеу барысында сканерлеу және жинақтауға үлкен көмегі тиді.

Қорытынды

Қорытындылай келе, терең оқыту технологиясының дамуы адам миының құрылымы мен функцияларынан шабыттанды, оның мақсаты мидың оқу және есте сақтау процестеріне еліктейтін нейрондық желілерді құру.

Терең оқыту – бұл адамның оқуына ұқсас қадамдық процесс және ол компьютерлердің өздігінен білім алуының қуатты құралына айналды. Бұл үлкен деректер жиынын оңай өңдей алатын заманауи компьютерлердің орасан зор есептеу қуатының арқасында мүмкін болды.

Терең оқыту технологиясы дәстүрлі бейне-аналитикалық алгоритмдермен салыстырғанда күрделі құрылымға ие. Ол бастапқы сигналды өңдеу қабаттарынан өтеді, кейде мұндай қабаттар жүздеген болуы мүмкін. Қабат деңгейі неғұрлым жоғары болса, тану объектісі соғұрлым нақты болады. 2017 жылы Hikvision терең оқыту мүмкіндіктері бар әлемдегі бірінші IP DVR шығарды, бұл қауіпті емес объектілердің қозғалысынан туындаған жалған дабылдарды дәл сүзуге мүмкіндік берді.

Өндіруші DeepinMind бейне анализатор серверіне және DeepinView желілік бейне камераларының сериясына терең оқыту технологиясын енгізді. Бейнебақылау жүйелеріне арналған бұл интеллектуалды жабдық адамның араласуын қажет етпей, бейнебақылау камераларының назарына түсетін әртүрлі нысандарды «үйренеді».

Терең оқыту адамның араласуын қажет етпейді, технология функцияларды өздігінен алу үшін жасанды интеллектке сүйенеді - өзін-өзі оқыту арқылы дамиды. Нәтижесінде, ерекшеліктер базасы кеңейген сайын, тану мен жіктеу дәлірек болады.

Пайдаланылған әдебиеттер тізімі:

- 1 Alladi, T., Kohli, V., Chamola, V., & Yu, F. R. A deep learning based misbehavior classification scheme for intrusion detection in cooperative intelligent transportation systems. // *Digital Communications and Networks*. – 2022. <https://doi.org/10.1016/j.dcan.2022.06.018>
- 2 Snorek, M. Alexey Grigorevich Ivakhnenko. // *Индуктивне моделювання складних систем*. – 2013. – №5. – P. 87-89.
- 3 Fujimoto, Y., Fukushima, K., & Murase, K. Mapping neutron star data to the equation of state using the deep neural network. // *Physical Review D*. – 2020. – №101(5). – P.1-17
- 4 Hinton, G. E., Dayan, P., Frey, B. J., & Neal, R. M. The "Wake-Sleep" Algorithm For Unsupervised Neural Networks. // *Science*. – 1995. – Vol. 268(5214). -P. 1158-1161. <https://doi.org/10.1126/science.7761831>
- 5 Serte, S., & Demirel, H. Gabor wavelet-based deep learning for skin lesion classification. // *Computers in biology and medicine*. – 2019. – Vol113. – Article 103423. <https://doi.org/10.1016/j.combiomed.2019.103423>
- 6 Unterthiner, T., Mayr, A., Klambauer, G., Steijaert, M., Wegner, J. K., Ceulemans, H., & Hochreiter, S. Deep learning as an opportunity in virtual screening. // *In Proceedings of the deep learning workshop at NIPS*. – 2014. – Vol. 27. – P. 1-9
- 7 Levine, S., Pastor, P., Krizhevsky, A., Ibarz, J., & Quillen, D. Learning hand-eye coordination for robotic grasping with deep learning and large-scale data collection. // *The International journal of robotics research*. – 2018. – Vol37(4-5). P. 421-436. <https://doi.org/10.48550/arXiv.1603.02199>
- 8 LeCun, Y., Bengio, Y., & Hinton, G. Deep learning. // *Nature* 521. – 2015. – Vol521(7553). – P. 436-444. <https://doi.org/10.1038/nature14539>
- 9 Li, S., Song, W., Fang, L., Chen, Y., Ghamisi, P., & Benediktsson, J. A. Deep learning for hyperspectral image classification: An overview. // *IEEE Transactions on Geoscience and Remote Sensing*. – 2019. – Vol57(9). – P. 6690-6709. <https://doi.org/10.48550/arXiv.1910.12861>
- 10 Obaid, K. B., Zeebaree, S., & Ahmed, O. M. Deep learning models based on image classification: a review. // *International Journal of Science and Business*. – 2020. - №4(11). P. 75-81. <https://doi.org/10.5281/zenodo.4108433>
- 11 Schmidhuber, J. Deep learning in neural networks: An overview. // *Neural networks*. – 2015. – Vol61. – P. 85-117. <https://doi.org/10.48550/arXiv.1404.7828>
- 12 Nielsen, M. A. *Neural networks and deep learning*. - San Francisco, CA, USA: Determination press. – 2015. <http://neuralnetworksanddeeplearning.com/>
- 13 Choi, R. Y., Coynor, A. S., Kalpathy-Cramer, J., Chiang, M. F., & Campbell, J. P. Introduction to machine learning, neural networks, and deep learning. // *Translational Vision Science & Technology*. – 2020. – V.9(2):14. doi:[10.1167/tvst.9.2.14](https://doi.org/10.1167/tvst.9.2.14)

References:

- 1 Alladi, T., Kohli, V., Chamola, V., & Yu, F. R. (2022) A deep learning based misbehavior classification scheme for intrusion detection in cooperative intelligent transportation systems. // *Digital Communications and Networks*. <https://doi.org/10.1016/j.dcan.2022.06.018>
- 2 Snorek, M. Alexey Grigorevich Ivakhnenko. (2013) *Индуктивне моделювання складних систем*. – Vol. 5. – C. 87-89.

- 3 Fujimoto, Y., Fukushima, K., & Murase, K. (2020) Mapping neutron star data to the equation of state using the deep neural network. // *Physical Review D*. – №101(5). – P.1-17
- 4 Hinton, G. E., Dayan, P., Frey, B. J., & Neal, R. M. (1995) The "Wake-Sleep" Algorithm For Unsupervised Neural Networks. // *Science*. – Vol. 268(5214). -P. 1158-1161. <https://doi.org/10.1126/science.7761831>
- 5 Serte, S., & Demirel, H. Gabor (2019) wavelet-based deep learning for skin lesion classification. // *Computers in biology and medicine*. – Vol. 113. – Article 103423. <https://doi.org/10.1016/j.combiomed.2019.103423>
- 6 Unterthiner, T., Mayr, A., Klambauer, G., Steijaert, M., Wegner, J. K., Ceulemans, H., & Hochreiter, S. (2014) Deep learning as an opportunity in virtual screening. // *In Proceedings of the deep learning workshop at NIPS*. Vol. 27. P. 1-9
- 7 Levine, S., Pastor, P., Krizhevsky, A., Ibarz, J., & Quillen, D. (2018) Learning hand-eye coordination for robotic grasping with deep learning and large-scale data collection. // *The International journal of robotics research*. – Vol. 37(4-5). P. 421-436. <https://doi.org/10.48550/arXiv.1603.02199>
- 8 LeCun, Y., Bengio, Y., & Hinton, G. (2015) Deep learning. // *Nature* 521. – Vol. 521(7553). – P. 436-444. <https://doi.org/10.1038/nature14539>
- 9 Li, S., Song, W., Fang, L., Chen, Y., Ghamisi, P., & Benediktsson, J. A. (2019) Deep learning for hyperspectral image classification: An overview. // *IEEE Transactions on Geoscience and Remote Sensing*. – Vol. 57(9). – P. 6690-6709. <https://doi.org/10.48550/arXiv.1910.12861>
- 10 Obaid, K. B., Zeebaree, S., & Ahmed, O. M. (2020) Deep learning models based on image classification: a review. // *International Journal of Science and Business*. – Vol. 4(11). – P. 75-81. <https://doi.org/10.5281/zenodo.4108433>
- 11 Schmidhuber, J. (2015) Deep learning in neural networks: An overview. // *Neural networks*. – Vol. 61. – P. 85-117. <https://doi.org/10.48550/arXiv.1404.7828>
- 12 Nielsen, M. A. (2015) *Neural networks and deep learning*. - San Francisco, CA, USA: Determination press. <http://neuralnetworksanddeeplearning.com/>
- 13 Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., & Campbell, J. P. (2020) Introduction to machine learning, neural networks, and deep learning. // *Translational Vision Science & Technology*. – Vol. 9(2):14. doi:10.1167/tvst.9.2.14