

**А. С. БАЙМАХАНОВА<sup>1\*</sup>, К. М. БЕРКИМБАЕВ<sup>1</sup>, А. К. ЖУМАДИЛЛАЕВА<sup>2</sup>,  
Э. Т. АБДРАШОВА<sup>3</sup>**

<sup>1</sup>*Қожа Ахмет Ясауи атындағы Халықаралық қазақ-түрік университеті,  
Түркістан, Қазақстан*

<sup>2</sup>*Л.Н.Гумилев атындағы Еуразия ұлттық университеті, Астана, Қазақстан*

<sup>3</sup>*Мұхтар Әуезов атындағы Оңтүстік Қазақстан Университеті,*

*Шымкент, Қазақстан  
aygerim.baymakhanova@ayu.edu.kz*

## **DEEP LEARNING АЛГОРИТМДЕРІН ҚОЛДАНУ ТЕХНОЛОГИЯСЫ**

*Терең оқыту – бұл машиналық оқытудың зерттеу саласы (machine learning-ML). Терең оқыту әдістемесі үлкен дерекқорларда сызықтық емес түрлендірулердің жоғары деңгейлі үлгі абстракцияларын қолданады. Басқада салаларда терең оқыту архитектурасын енгізу жасанды интеллекттің дамуына айтарлықтай үлес қосуда. Бұл мақалада терең оқытудың жаңа қолданбалы алгоритмдері туралы соңғы зерттеулер ұсынылған. Терең оқытуда конволюционды нейрондық желіні пайдаланылуы көрсетіледі. Мәліметтер қорын басқару жүйесі – PostgreSQL объектінің реляциялық дерекқоры.*

*Жүзеге асыру нәтижесінде алға қойылған мақсаттар мен міндеттерге қол жеткізілді. Мақалада кірістерді талдау әдістері қарастырылады, машиналық және терең оқыту арасындағы айырмашылықтар сипатталған, сондай-ақ терең оқыту алгоритмдерінің бірін, атап айтқанда жестілеу тілінің кескіндерін білдіретін кескіндерді жіктеу үшін логистикалық регрессияны қолдану мысалын енгізу келтірілген. Терең нейрондық желілердің альтернативті тәсілдерге қарағанда қол жетімді деректердің барлық жиынтығымен жұмыс істей алады. Оқыту үрдісінде нейрондық желінің өзі деректердегі қандай белгілер маңызды және қандай белгілер керек болмайтынын анықтайды. Жасанды нейрондық желілер адамдардың болжай алмайтын белгілерін болжай алады. Сондықтан терең нейрондық желілердің көмегімен машиналық оқытудың дәстүрлі алгоритмдері орындай алмайтын міндеттерін шеше алады. Тексеру негізінде қол жеткізуді басқаруды басқару жүйесін құрылады.*

***Түйін сөздер:** терең оқыту, әдістеме, жасанды интеллект, машиналық оқыту, нейрондық желі, объектіні тану.*

**Кіріспе.** Deep Learning немесе терең оқыту – қолданыстағы ақпараттық технологиялар инфрақұрылымына біріктіруге болатын жасанды интеллект саласындағы тұжырымдамалардың бірі болып табылады. Ол қауіпсіздіктің жоғары деңгейімен, кең функционалдылығымен ерекшеленеді. Құрылымдалған деректерді оқыту машиналық оқыту әдістерінің жиынтығы. Әр түрлі салаларда қолдануға болатын әмбебап өнім алынады: дауысты тану, суреттер, мәтіндік зерттеулер және т. б. [1].

Deep Learning технологиясы жасанды нейрондық желілерге негізделген. Оларға алгоритмнің өзі де, осы тренингті өткізу үшін мәліметтер де беріледі, олардың көлемін үнемі көбейтеді. Нейрондық желілер ақпаратты неғұрлым көп алса, оқыту үрдісі соғұрлым тиімді болады [2].

---

\* E-mail корреспондирующего автора: [aygerim.baymakhanova@ayu.edu.kz](mailto:aygerim.baymakhanova@ayu.edu.kz)

Терең оқыту – бұл машиналық оқытудың (ML) жаңа саласы. Ол жасанды нейрондық желілердің бірнеше жасырын қабаттары мен жұмыс жасайды. Терең оқыту әдістемесі сызықты емес түрлендірулерді және үлкен дерекқорларда жоғары деңгейлі модельдік абстракцияларды пайдаланады. Көптеген салалардағы терең білім беру архитектурасындағы соңғы жетістіктер жасанды интеллектке айтарлықтай үлес қосты. Сонымен қатар, терең оқыту әдістемесінің және оның деңгейлердегі және сызықтық емес операциялардағы иерархиясының артықшылықтары мен кемшіліктері ұсынылған және әдеттегі қолданбалардағы дәстүрлі алгоритмдермен салыстырылады [3].

Deep learning қолданбасы imagenet жобасындағы суреттердегі нысандарды тану қателерінің үлесін 16%-ға дейін төмендетуге мүмкіндік берді. Бүгінгі таңда нейрондық желілер мұндай тапсырмаларды 94-99% дәлдікпен орындайды, бұл адамның мүмкіндіктерінен асып түседі [4].

Deep Learning оқыту үрдісі 2 кезеңге бөлінеді:

Тікелей оқыту. Бұл кезеңде деректердің үлкен көлемі белгіленеді, олардың негізгі сипаттамалары анықталады. Содан кейін жүйе оларды салыстырады, есте сақтайды.

Қорытындыларды қалыптастыру. Келіп түскен сұраныс туралы терең ақпаратқа ие бола отырып, жүйе өз бетінше интеллектуалды қорытынды жасай алады.

Deep Learning оқыту үрдісінде үлкен деректер қорымен жұмыс жасау өте тиімді нәтиже көрсетеді.

Deep Learning жүйесі өзінің эталондық нәтижесін қалыптастыру үшін кірістерді дербес бөлуі керек. Бұл опцияның мысалы ретінде интернет-дүкен пайдаланушыларының белгілі бір критерийлерге сәйкес бөлінуін атауға болады: жынысы, жасы, сатып алу белсенділігі деңгейі және т. б. [5].

Deep Learning пайдалану аймақтары.

Терең машиналық оқыту тәжірибеде келесі салаларда кеңінен қолданылды:

Машиналық аударма. Мұнда нейрондық желілер миллиондаған мысалдармен оқытылады. Мәтін фрагменттерінің жұптары және олардың аудармасы көрсетіледі. Deep Learning тек аударманы механикалық түрде ғана емес, сонымен қатар мәтінді талдауға, грамматикаға, белгілі бір сөздерді қолдану маңыздылығына назар аударуға қабілеттілігі жоғары.

Компьютерлік көру. Бұл жағдайда терең оқыту суреттердегі объектілерді тануға қабілетті. Нейрондық желілер фотосуретті бөлімдерге бөлу, үлгілерді табу арқылы мүмкіндігінше егжей-тегжейлі зерттеуге үйретеді. Іс жүзінде Deep Learning компьютерлік көру Яндекс, Google іздеу жүйелерінде қолданылады.

Сөйлеуді өндіру және тану. Өте жоғары дәлдікпен дайындалған жасанды нейрондық желілер сөйлеу ерекшеліктеріне назар аудара отырып, дауыстарды (кез-келген тілде) тани алады [6]. Machine Learning және Deep Learning-бұл жасанды интеллект саласындағы екі ұғым, бүгінде тәжірибеде өте қарқынды қолданылады [7]. Табиғи тілді өңдеу Natural Language Processing (NLP) әр түрлі қосымшаларда жазу сапасын тиімді етіп жақсартады. NLP-дегі ең классикалық бөлім-бұл машиналық аудармалар, оны тілдер арасындағы аударма деп түсінеді [8].

**Зерттеудің әдістемесі және нәтижелері.** Машиналық оқытудағы жиі кездесетін мәселе-ML модельдерінің тану кезінде кездескендерге қарағанда әртүрлі мысалдарда дұрыс жұмыс істей алмауы.

Шешімін күтетін бірнеше маңызды, ашық мәселелер бар. Айта кету керек үлкен мәселе-орнықтылық әсері. Дж. Гудфеллоу мен авторлардың жұмысында алғаш рет келесі әсер байқалды: адамның кішкентай, көрінбейтін көзімен суреттің бұзылуы, нейрондық желіні болжау танылған үлгіні басқа класқа аударады [9].

Әрине, Машиналық оқыту проблемалары мұнымен шектелмейді, сонымен қатар модельдерді түсіндіруде қиындықтар, біржақтылық пен этика мәселелері, оқытудың ресурс сыйымдылығы және басқалар бар [10]. Табиғи тілді тану машиналық оқыту алгоритмдерін зерттеудің маңызды саласы болып табылады. Жаңа табиғи сөйлеумен жұмыс істеудің технологиялары мен әдістері пайда болады, бұл оның қажеттілігін білдіреді осы технологиялардың аналитикалық зерттеулерін жүргізу және олардың танымал салаларда қолданылуын іздеу ескірген алгоритмдерді алмастыратын ғылыми өрістер [11].

Машиналық оқыту атқара алатын әртүрлі әрекеттерді ескере отырып, белгілі бір тапсырма үшін қандай нақты машинаны оқыту архитектурасын пайдалану керек деген сұрақ туындауы мүмкін. Оңтайландыруға арналған тегін түскі ас теоремасын ескере отырып, 63 көптеген алгоритмдер өзара ауыстырылады [12].

Машиналық оқытудың мақсаты - адамдардың қызметінің әртүрлі салаларында күрделі кәсіби мәселелерді толық шешеді.

Машиналық оқытудың көптеген қосымшалары:

- Сөйлеуді тану
- Қимылдарды тану
- Қолжазбаны тану
- Үлгіні тану
- Техникалық диагностика
- Құжаттарды санаттау
- Ақпараттық іздеуде рейтингті оқыту

Машиналық оқытуды қолданудың аясы үнемі кеңейіп келеді [13]. Барлық жерде ақпараттандыру ғылымда, өндірісте, бизнесте, көлікте, денсаулық сақтауда үлкен көлемдегі деректердің жинақталуына әкеледі. Міндеттер мүлдем қойылмаған немесе мүлдем басқа әдістермен шешілген [14].



Сурет 1 – Жасанды интеллект (ЖИ) саласындағы зерттеулер

Бөлшектерді сүзу және сенімді тарату алгоритмін қолдану (Bayesian – belief propagation). Бұл қосымшаның негізгі тұжырымдамасы адам бет кескінінің жартысын ғана байқау арқылы басқа адамның бетін тани алады деп санайды, сондықтан компьютер кесілген кескіннен бет кескінін қалпына келтіре алады [15]. Мысалы, түрлі түсті қабықшаларды тану үшін конволюциялық нейрондық желілерді (convolutional Neural Networks — CNN) қолдану әдеттегі сенсорларды қолданудан гөрі тиімдірек болуы мүмкін. CNN тиімділігі 99,35% дәлдікке жетуі мүмкін.

Артықшылықтары мен кемшіліктері

Дегенмен, deep learning-ті объективті бағалау үшін артықшылықтар мен кемшіліктерді салыстыру маңызды. DL ерекшеліктері:

- Қолданыстағы IT инфрақұрылымына интеграциялау мүмкіндігі;
- Қауіпсіздіктің жоғары деңгейі;
- Нейрондық желілерді дамытудың қажетті бағытында ғана жұмыс істейтін оқытудың кең мүмкіндіктері;
- Нақты өмірде терең оқытуды енгізудің көптеген сәтті мысалдары.

Шындығында, артықшылықтарды көбірек бөлуге болады. Олардың арасында жоғары икемділік және TensorFlow, Keras, PyTorch, Caffe және т.б. мысалында ойластырылған оқу құралдарына қол жеткізу бар [16].

Бірақ бұл технологияның кемшіліктері де жоқ емес. Мысалы, әзірге жүйені қолайсыз мақсаттарда қолданудан қорғану қиын. Енді DeepFake және басқа аналогтар жиі кездеседі, олар қабаттасқан беттермен немесе басқа элементтермен фотосуреттер мен бейнематериалдар жасауға ықпал етеді. Техникалық іске асыру тұрғысынан кемшіліктер жоқ. Дегенмен, технологияны толық қолдану үшін GPU негізіндегі қуатты компьютерлік қор қажет [17].

Технологияның қолданылуын талдау. Мақалада IT-технологиялар саласында терең оқытуды қолданудың негізгі аспектілері қарастырылады. Нейрондық желілерді пайдаланудың негізгі модельдері мен алгоритмдері, сондай-ақ жестілеу (қолмен іс-қимыл) тіліндегі арнайы белгілерді тану мысалында оларды жаңарту қарастырылады [18].

Терең оқыту-бұл үлкен көлемдегі деректермен жұмыс істеу кезінде үлкен өнімділік пен дәлдіктің арқасында басқа әдістерден асып түсетін машиналық оқыту әдістерінің бірі. Мақалада терең оқыту технологиясын іс жүзінде қолдануды қарастырамын [19].

Терең оқыту модельденетін деректердің негізгі таралу көріністерінің бірнеше деңгейлерін автоматты түрде үйренуге мүмкіндік береді [20]. Бұл қарым-қатынас стилінде нөлден тоғызға дейінгі сандар қолданылады, яғни он ерекше таңба қолданылады. 2-суретте индекстері сәйкесінше 260 және 900 болатын бірлік пен нөл белгісі көрсетілген.

Қолданыстағы dataset-тің проблемасы-үш өлшемді кескіндердің болуы, нәтижесінде оларды екі өлшемді ету қажет. Нәтижесінде «x» жиынтығында 64-тен 64 пиксельге дейінгі 410 сурет бар, ал «y» жиынтығында нөл немесе бір дегенді білдіретін 410 белгі бар (сурет.3).



Сурет 2 – Dataset демонстрациясы

```
print("X shape: ", X.shape)
print("Y shape: ", Y.shape)
```

X shape: (410, 64, 64)  
Y shape: (410, 1)

Сурет 3 – Кіші үлгіні көрсету

Logistic Regression. Екілік классификация деп аталатын ең тиімді алгоритм-логистикалық регрессия. Шын мәнінде, логистикалық регрессия қарапайым нейрондық желінің типтік мысалы болып табылады, нәтижесінде кіріске dataset-тен кескіндер жіберіледі және әр кескін пикселдерден тұрады, нәтижесінде әр пиксель өзінің бастапқы салмағына ие болуы керек. Осылайша, біз әр пиксельдің салмағын 0.01 деп инициализациялаймыз, ал бастапқы орын ауыстыру 0 болады:

```
def initialize_weights_and_bias(dimension):
    w = np.full((dimension, 1), 0.01)
    b = 0.0
    return w, b
```

Содан кейін кіріс матрицасын ауыстырып, оны сигма тәрізді функцияға беру керек, бұл белгілі бір сыныпқа түсу ықтималдығын қайтарады. Қолданылатын әдістің орындылығын қатенің мәнін анықтау арқылы тексеруге болады. Егер сіз теңдеуге бір белгісі бар суретті және бірлікке тең белгіні берсеңіз, онда қате нөлге тең болады, бұл таңдалған алгоритмнің дұрыс қолданылуын білдіреді.

Метрикалық өлшемдерге Accuracy, Precision и Recall қарастырсақ. Accuracy - барлық сыныптар бойынша үлгінің жалпы болжамды дәлдігін сипаттайтын көрсеткіш. Дұрыс болжамдар санының олардың жалпы санына қатынасы ретінде есептеледі.

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

Precision – оң ретінде дұрыс жіктелген үлгілер санының дәлдік позитивті классты анықтау кезінде үлгінің дәлдігін өлшейді.

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

Recall - оң үлгілердің жалпы санына қатынасы ретінде есептеледі. Позитивті класқа жататын үлгілерді анықтау мүмкіндігін өлшейді. Қайта шақыру неғұрлым жоғары болса, соғұрлым оң үлгілер табылды.

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

```

def metrics(test_data, model):
    data = test_data[... , 0]
    observations = test_data[... , 1]
    prediction = model.predict(data)
    true_positive = np.logical_and(prediction, observations)
    false_positive = np.logical_and(prediction, np.logical_not(observations))
    true_negative = np.logical_and(np.logical_not(prediction), np.logical_not(observations))
    false_negative = np.logical_and(np.logical_not(prediction), observations)
    tp, fp, tn, fn = (x.sum() for x in (true_positive, false_positive, true_negative, false_negative))
    accuracy = (tp + tn) / (tp + fp + fn + tn)
    precision = tp / (tp + fp)
    recall = tp / (tp + fn)
    f1_score = 2 * (recall * precision) / (recall + precision)
    #dump(data, observations, prediction, true_positive, false_positive, true_negative, false_negative)
    return tp, fp, tn, fn, accuracy, precision, recall, f1_score

def dump(temp, obs, pred, tp, fp, tn, fn):
    print('{:5} {}'.format('Temp', ' '.join(map(str, temp))))
    for name, v, comment in (
        ('Obs', obs, '(TP+FN)'),
        ('Pred', pred, '(TP+FP)'),
        ('TP', tp, ''),('FP', fp, ''),
        ('TN', tn, ''),('FN', fn, '')):
        print('{:5} {}'.format(name, ' '.join([False: '.', True: 'T']*[bool(x) for x in v], sum(v), comment)))
    pass
print(' T TP FP TN FN Accur Prec Recll F1')
for model_param in range(10):
    m = metrics(TEST, Model(model_param))
    print('{:2d} {:2d} {:2d} {:2d} {:2d} {:.3f} {:.3f} {:.3f} {:.3f}'.format(model_param, *m))

```

Сурет 4 – Метрикалық өлшемдер нәтижесі

Бұл деректер мен жоғары өңдеу қуаты қазір көпшілікке қол жетімді, бұл IT технологиясының үлкен өсуіне ықпал етеді. Reinforcement learning – оқытуды күшейту әдісі. Қоршаған ортаны қабылдауға және түсіндіруге, әрекеттер жасауға және сынақ пен қателік арқылы үйренуге қабілетті. Deep learning және Reinforcement learning үшін жаңа мүмкіндіктер береді. IT индустриясындағы жылдам өзгерістер жағдайында озық технологияларға ілесу оңай емес. PostgreSQL, MySQL басқару жүйелерімен өзара әрекеттесу үшін стандартты тіл – SQL (Structured Query Language) тіліне

сүйенеді. PostgreSQL деректер қоры негізі үшін жасалған. Берклидегі Калифорний университетінде 1986 жылы Postgres жобасы бастау алған.

Майкл Стоунбрейкер компьютерлік серіктестікке қатысты «Post Ingres» және Postgres бағдарламасымен көптеген зерттеулерді іске асырған.

Deep learning және Reinforcement learning екеуі де машиналық оқыту мүмкіндіктері болып табылады, олар өз кезегінде жасанды интеллект құралдарының кең ауқымының бөлігі болып табылады. Ең қызығы, Deep learning және Reinforcement learning екеуі де компьютерге есептерді шешу алгоритмін өз бетінше жасауға мүмкіндік береді. Іс жүзінде Deep learning-тің жарқын мысалы - Apple 's Face ID. Телефонды орнату кезінде алгоритмге сіз бетіңізді сканерлеу арқылы үйретесіз. Face ID көмегімен кірген сайын TrueDepth камерасы сіздің бетіңіздің егжей-тегжейлі бейнесін жасайтын мындаған деректер нүктелерін түсіреді, ал кіріктірілген нейрондық желі кіруге тырысып жатқанындығын талдайды.

**Қорытындылар.** Терең оқыту-бұл машиналық оқытудың шынымен тез өсіп келе жатқан қолданысы болып табылады. Жоғарыда сипатталған көптеген қосымшалар оның бірнеше жыл ішінде қарқынды дамуын дәлелдейді. Бұл алгоритмдерді әртүрлі салаларда қолдану оның әмбебаптығын көрсетеді. Осы зерттеуде жасалған басылымдарды талдау осы технологияның өзектілігін анық көрсетеді және терең оқытудың өсуі мен осы саладағы болашақ зерттеулерге қатысты тенденциялардың нақты суретін береді.

Терең оқытудың негізгі құндылығы инновациялық иерархиялық өңдеу арқылы машиналық оқытудағы бар қолданбаларды оңтайландыру болып табылады. Терең оқыту сандық кескінді өңдеу және сөйлеуді тану кезінде тиімді нәтижелерге қол жеткізе алады. Қателер пайызының төмендеуі (10-нан 20% - ға дейін) қолданыстағы және дәлелденген әдістердің жақсарғанын анық растайды.

Мақалада кірістерді талдау әдістері қарастырылады, машиналық және терең оқыту арасындағы айырмашылықтар сипатталған, сондай-ақ терең оқыту алгоритмдерінің бірін, атап айтқанда жестілеу тілінің кескіндерін білдіретін кескіндерді жіктеу үшін логистикалық регрессияны қолдану мысалын енгізу келтірілген. Ұсынылған алгоритм алдын-ала қолданылған шығындар функциясын азайту алгоритмі, жіктеудің жоғарғы дәлдігін көрсетті.

Осы себепті және шынайы оңтайландыруды дәлелдей отырып, терең оқыту жасанды интеллектті дамытудың заманауи және қызықты пән болып табылады.

## ӘДЕБИЕТ

1 Abdel-Hamid, O., Mohamed, A. R., Jiang, H., & Penn, G. (2012, March). Applying convolutional neural networks concepts to hybrid NN-HMM model for speech recognition. In 2012 IEEE international conference on Acoustics, speech and signal processing (ICASSP) (pp. 4277-4280). IEEE.

2 Kussul, N., Lavreniuk, M., Skakun, S., & Shelestov, A. (2017). Deep learning classification of land cover and crop types using remote sensing data. IEEE Geoscience and Remote Sensing Letters, 14(5), 778-782.

3 VARGAS, R., & Lourdes, R. U. Í. Z. (2017). Deep learning: previous and present applications. Journal of awareness, 2(Special 3), 11-20.

- 4 Ismail Fawaz, H., Forestier, G., Weber, J., Idoumghar, L., & Muller, P. A. (2019). Deep learning for time series classification: a review. *Data mining and knowledge discovery*, 33(4), 917-963.
- 5 Mosavi, A., & Varkonyi-Koczy, A. R. (2017). Integration of machine learning and optimization for robot learning. In *Recent Global Research and Education: Technological Challenges* (pp. 349-355). Springer, Cham.
- 6 Allam, A., Nagy, M., Thoma, G., & Krauthammer, M. (2019). Neural networks versus Logistic regression for 30 days all-cause readmission prediction. *Scientific reports*, 9(1), 1-11.
- 7 Rajesh, G., & Chaturvedi, A. (2019). Correlation analysis and statistical characterization of heterogeneous sensor data in environmental sensor networks. *Computer Networks*, 164, 106902.
- 8 Rybalov, A. (2020). On generic NP-completeness of the graph clustering problem. In *Journal of Physics: Conference Series* (Vol. 1441, No. 1, p. 012167). IOP Publishing.
- 9 Vercio, L. L., Amador, K., Bannister, J. J., Crites, S., Gutierrez, A., MacDonald, M. E., ... & Forkert, N. D. (2020). Supervised machine learning tools: a tutorial for clinicians. *Journal of Neural Engineering*, 17(6), 062001.
- 10 Bannister, F. (2005). When paradigms shift: IT evaluation in a brave new world. *The Electronic Journal of Information Systems Evaluation*, 8(1), 21-30.
- 11 Bannister, F. (2012). When Paradigms Shift: IT Evaluation in a Brave New. *Leading Issues in ICT Evaluation*, 1, 145.
- 12 Chumakov, V. E. (2020). Techniques for hybridization of intelligent methods for detecting malicious traffic. *Информатика, телекоммуникации и управление*, 13(3), 31-43.
- 13 Bengio, Y.: Learning deep architectures for AI. *Foundations and trends in Machine Learning* 2, 1-127 (2009).
- 14 Mosavi, A., Varkonyi-Koczy, A. R., Fullsack, M.: Combination of Machine Learning and Optimization for Automated Decision-Making. *MCDM* (2015).
- 15 Deng L, Yu D Deep learning: methods and applications. *Foundations and Trends in Signal Processing* 7, 197-387 (2014)
- 16 Coudray, N., Ocampo, P. S., Sakellaropoulos, T., Narula, N., Snuderl, M., Fenyö, D., ... & Tsigos, A. (2018). Classification and mutation prediction from non-small cell lung cancer histopathology images using deep learning. *Nature medicine*, 24(10), 1559-1567.
- 17 Chen, Z., Andrejevic, N., Drucker, N. C., Nguyen, T., Xian, R. P., Smidt, T., ... & Li, M. (2021). Machine learning on neutron and x-ray scattering and spectroscopies. *Chemical Physics Reviews*, 2(3), 031301.
- 18 Safaryan, O., Cherckesova, L., Korochentsev, D., Zelensky, A., Revyakina, Y., Chumakov, V., ... & Lobodenko, A. (2021, December). Development of Semantic Analysis Software Tool for Solving Problems of Text Formalization. In *Journal of Physics: Conference Series* (Vol. 2131, No. 2, p. 022100). IOP Publishing.
- 19 Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., & Gao, J. (2021). Deep learning--based text classification: a comprehensive review. *ACM Computing Surveys (CSUR)*, 54(3), 1-40.
- 20 Lauzon, F. Q. (2012, July). An introduction to deep learning. In *2012 11th International Conference on Information Science, Signal Processing and their Applications (ISSPA)* (pp. 1438-1439). IEEE.

## REFERENCES

- 1 Abdel-Hamid, O., Mohamed, A. R., Jiang, H., & Penn, G. (2012, March). Applying convolutional neural networks concepts to hybrid NN-HMM model for speech recognition. In *2012 IEEE international conference on Acoustics, speech and signal processing (ICASSP)* (pp. 4277-4280). IEEE.



2 Kussul, N., Lavreniuk, M., Skakun, S., & Shelestov, A. (2017). Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778-782.

3 VARGAS, R., & Lourdes, R. U. Í. Z. (2017). Deep learning: previous and present applications. *Journal of awareness*, 2(Special 3), 11-20.

4 Ismail Fawaz, H., Forestier, G., Weber, J., Idoumghar, L., & Muller, P. A. (2019). Deep learning for time series classification: a review. *Data mining and knowledge discovery*, 33(4), 917-963.

5 Mosavi, A., & Varkonyi-Koczy, A. R. (2017). Integration of machine learning and optimization for robot learning. In *Recent Global Research and Education: Technological Challenges* (pp. 349-355). Springer, Cham.

6 Allam, A., Nagy, M., Thoma, G., & Krauthammer, M. (2019). Neural networks versus Logistic regression for 30 days all-cause readmission prediction. *Scientific reports*, 9(1), 1-11.

7 Rajesh, G., & Chaturvedi, A. (2019). Correlation analysis and statistical characterization of heterogeneous sensor data in environmental sensor networks. *Computer Networks*, 164, 106902.

8 Rybalov, A. (2020). On generic NP-completeness of the graph clustering problem. In *Journal of Physics: Conference Series* (Vol. 1441, No. 1, p. 012167). IOP Publishing.

9 Vercio, L. L., Amador, K., Bannister, J. J., Crites, S., Gutierrez, A., MacDonald, M. E., ... & Forkert, N. D. (2020). Supervised machine learning tools: a tutorial for clinicians. *Journal of Neural Engineering*, 17(6), 062001.

10 Bannister, F. (2005). When paradigms shift: IT evaluation in a brave new world. *The Electronic Journal of Information Systems Evaluation*, 8(1), 21-30.

11 Bannister, F. (2012). When Paradigms Shift: IT Evaluation in a Brave New. *Leading Issues in ICT Evaluation*, 1, 145.

12 Chumakov, V. E. (2020). Techniques for hybridization of intelligent methods for detecting malicious traffic. *Informatika, telekommunikacii i upravlenie*, 13(3), 31-43.

13 Bengio, Y.: Learning deep architectures for AI. *Foundations and trends in Machine Learning* 2, 1-127 (2009).

14 Mosavi, A., Varkonyi-Koczy, A. R., Fullsack, M.: Combination of Machine Learning and Optimization for Automated Decision-Making. *MCDM* (2015).

15 Deng L, Yu D Deep learning: methods and applications. *Foundations and Trends in Signal Processing* 7, 197-387 (2014)

16 Coudray, N., Ocampo, P. S., Sakellaropoulos, T., Narula, N., Snuderl, M., Fenyö, D., ... & Tsirigos, A. (2018). Classification and mutation prediction from non-small cell lung cancer histopathology images using deep learning. *Nature medicine*, 24(10), 1559-1567.

17 Chen, Z., Andrejevic, N., Drucker, N. C., Nguyen, T., Xian, R. P., Smidt, T., ... & Li, M. (2021). Machine learning on neutron and x-ray scattering and spectroscopies. *Chemical Physics Reviews*, 2(3), 031301.

18 Safaryan, O., Cherkesova, L., Korochentsev, D., Zelensky, A., Revyakina, Y., Chumakov, V., ... & Lobodenko, A. (2021, December). Development of Semantic Analysis Software Tool for Solving Problems of Text Formalization. In *Journal of Physics: Conference Series* (Vol. 2131, No. 2, p. 022100). IOP Publishing.

19 Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., & Gao, J. (2021). Deep learning--based text classification: a comprehensive review. *ACM Computing Surveys (CSUR)*, 54(3), 1-40.

20 Lauzon, F. Q. (2012, July). An introduction to deep learning. In *2012 11th International Conference on Information Science, Signal Processing and their Applications (ISSPA)* (pp. 1438-1439). IEEE.

**A. S. БАЙМАХАНОВА, К. М. БЕРКИМБАЕВ, А. К. ЖУМАДИЛЛАЕВА,  
Э. Т. АБДРАШОВА**

*Khoja Akhmet Yassawi International Kazakh-Turkish University, Turkistan, Kazakhstan  
L.N Gumilyov Eurasian National University, Astana, Kazakhstan  
South Kazakhstan University named after Mukhtar Auezov, Shymkent, Kazakhstan*

## **TECHNOLOGY OF USING DEEP LEARNING ALGORITHMS**

*Deep learning is a branch of machine learning (machine learning-ML). Deep learning methods utilize high-level model abstraction of nonlinear transformations in large databases. In other areas, the implementation of deep learning architectures has contributed significantly to the development of artificial intelligence. This paper presents recent research on newly applied deep learning algorithms. Convolutional Neural Networks are used in deep learning. Database Management System - PostgreSQL object-relational database.*

*The implementation resulted in achieving the set goals and objectives. The method of analyzing the input data is described, the differences between machine learning and deep learning are explained, and an example of classifying an image representing a sign language image using logistic regression, one of the deep learning algorithms, is presented. Deep neural networks can work with the full set of available data better than alternative approaches. During the learning process, the neural network itself determines which features in the data are important and which are not. Artificial neural networks can predict symptoms that humans cannot. Thus, with the help of deep neural networks, we can solve problems that traditional machine learning algorithms cannot perform.*

**Key words:** *deep learning, methodology, artificial intelligence, machine learning, neural network, object recognition.*

**А. С. БАЙМАХАНОВА, К. М. БЕРКИМБАЕВ, А. К. ЖУМАДИЛЛАЕВА,  
Э. Т. АБДРАШОВА**

*Международный казахско-турецкий университета имени Ходжи Ахмеда Ясави,  
Туркестан, Казахстан  
Евразийский национальный университет имени Л.Н. Гумилева, Астана, Казахстан  
Южно-Казахстанский университет имени Мухтара Ауэзова,  
Шымкент, Казахстан*

## **ТЕХНОЛОГИЯ ИСПОЛЬЗОВАНИЯ АЛГОРИТМОВ ГЛУБОКОГО ОБУЧЕНИЯ**

*Глубокое обучение – это ветвь машинного обучения (машинное обучение – ML). Методы глубокого обучения используют абстракции моделей высокого уровня нелинейных преобразований в больших базах данных. В других областях внедрение архитектуры глубокого обучения вносит значительный вклад в развитие искусственного интеллекта. В этой статье представлены недавние исследования новых прикладных алгоритмов глубокого обучения. Сверточная нейронная сеть используется в глубоком обучении. Система управления базами данных – объектно-реляционная база данных PostgreSQL.*

*В результате реализации поставленные цели и задачи были достигнуты. В статье обсуждаются методы анализа входных данных, описываются различия между машинным обучением и*

глубоким обучением, а также приводится пример использования одного из алгоритмов глубокого обучения, а именно логистической регрессии для классификации изображений, представляющих изображения языка жестов. Глубокие нейронные сети могут работать со всем набором доступных данных, чем альтернативные подходы.

В процессе обучения нейронная сеть сама определяет, какие признаки в данных важны, а какие нет. Искусственные нейронные сети могут предсказать симптомы, которые люди не могут. Поэтому с помощью глубоких нейронных сетей они могут решать задачи, которые не могут выполнить традиционные алгоритмы машинного обучения.

**Ключевые слова:** глубокое обучение, методология, искусственный интеллект, машинное обучение, нейронная сеть, распознавание объектов.