



ӘОЖ 004.891

ҒТАХА 28.23.27

https://doi.org/10.53364/24138614_2026_41_2_17

И.Б.Карымсакова¹, Д. Б.Бекенова^{2*}, Л.М. Абдибекова³,
З.С.Ерсултанова⁴, М.А.Сексембаева³

¹«Шәкәрім университет» коммерциялық емес акционерлік қоғам, Семей, Қазақстан

² «Тұран-Астана» университеті, Астана, Қазақстан

³Esil University, Астана, Қазақстан

⁴Ахмет Байтұрсынұлы атындағы Қостанай өңірлік университеті, Қостанай, Қазақстан

*E-mail: dariyba@mail.ru

НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ ҚОЛДАНУ АРҚЫЛЫ НЕГІЗГІ ҚАУІП ФАКТОРЛАРЫ БОЙЫНША ӨКПЕ ОБЫРЫН ЕРТЕ ДИАГНОСТИКАЛАУ

Аңдатпа. Қазіргі уақытта онкологиялық аурулардың жиілігі қазіргі қоғамның маңызды мәселелерінің бірі болып қала береді. Өкпенің қатерлі ісігі онкопатологияның ең өлімге әкелетін түрлерінің бірі болып табылады, бұл көбінесе ісік процесінің кеш кезеңдерінде анықталуына байланысты. Скринингтік және ерте диагностикалық бағдарламалардың тиімділігі аурудың болжамына және пациенттердің өмір сүру деңгейіне тікелей әсер етеді. Осыған байланысты соңғы жылдары терең оқыту әдістеріне негізделген интеллектуалды сараптамалық жүйелерді, соның ішінде конволюциялық нейрондық желілерді (CNN), трансформаторлық архитектураларды және олардың гибриді шешімдерін дамытуға ерекше назар аударылды.

Бұл жұмыс терең оқытудың нейрондық желілік модельдерін қолдана отырып, өкпенің қатерлі ісігін ерте диагностикалау міндетін қарастырады. Зерттеу машиналық оқытудың келесі әдістерін қолдана отырып модельдерді әзірледі және талдады: логистикалық регрессия, кездейсоқ орман классификаторы, тірек векторы әдісі (SVM), экстремалды ағаш классификаторы, XGBoost, CatBoost, градиентті күшейту және көп қабатты перцептрон (MLP). Нейрондық желі моделіне кіріс факторлары ретінде тұқым қуалайтын бейімділік көрсеткіштері, пациенттің жынысы және темекі шегу тәжірибесі пайдаланылды.

Ең жақсы нәтижелерді 93%-дан жоғары дәлдік деңгейінде 0,9405-ке тең ROC-AUC метрикасының максималды мәніне жеткен көп қабатты перцептрон (MLPClassifier) негізіндегі модель көрсетті. Алынған көрсеткіштер модельдің пациенттерді тәуекел топтары бойынша дұрыс саралау қабілетінің жоғары екендігін көрсетеді. Салыстырмалы нәтижелер жіктеу сапасы бойынша екінші орында тұрған RandomForest және SVM алгоритмдерін көрсетті.

Әзірленген нейрондық желі үлгісі өкпенің қатерлі ісігінің даму ықтималдығын бағалауға, сондай-ақ таралған өкпе туберкулезі, саркоидоз, пневмония және өкпе тінінің фиброзы сияқты қатар жүретін аурулардың болуы мүмкін екендігі туралы ұсыныстар жасауға мүмкіндік береді.

Болашақта медициналық бейнелерді тану модулін біріктіру арқылы жүйенің функционалдығын кеңейту жоспарлануда, бұл өкпе обырын ерте диагностикалау үшін кешенді шешім жасауға мүмкіндік береді.

Түйін сөздер: *ақпараттық жүйелер, жасанды интеллект, терең оқыту әдістері, деректерді өндіру, интеллектуалды жүйе, мәліметтер базасы, конволюциялық нейрондық желі, трансформаторлар, гибриді модельдер, explainable AI.*

Кіріспе. Қазіргі уақытта онкологиялық аурулардың жоғары таралуы медициналық-әлеуметтік проблемалардың бірі болып табылады және халықтың барлық жас топтарына әсер етеді. Осыған байланысты онкологиялық ауруларды ерте анықтауға және алдын алуға бағытталған шаралар денсаулық сақтау жүйесін дамытудың негізгі бағыттарына айналууда. Клиникалық деректерді уақтылы диагностикалау және дұрыс түсіндіру емдеудің тиімділігін едәуір арттырады және пациенттердің өмір сүру ұзақтығын арттыруға ықпал етеді.

Өкпенің қатерлі ісігі-бұл көптеген жағдайларда патологиялық процестің кеш кезеңдерінде анықталатын қатерлі ісік ауруларының бірі, бұл жағымсыз болжамды тудырады. Осыған байланысты бұл ауруды ерте диагностикалау міндеті ерекше маңызға ие.

Қазіргі заманғы медицина ақпараттық технологияларды белсенді енгізумен сипатталады, олардың даму қарқыны тұрақты өсуде. Қазіргі уақытта медицинаның әртүрлі салаларында қолданылатын медициналық шешімдерді қолдау жүйелерінің едәуір бөлігі әзірленіп, қолданылууда. Мұндай технологиялар онкологияда кеңінен қолданылады, онда ауруларды диагностикалау және болжау үшін мамандандырылған сараптамалық жүйелер белсенді түрде құрылады. Өкпенің қатерлі ісігінің даму қаупін болжау жүйелерін әзірлеу маңызды әлеуметтік мәнге ие. Тәуекел факторларын анықтау және тиісті белгілерді ескере отырып модельдер құру аурудың даму ықтималдығын бағалауға мүмкіндік береді. Терең оқыту әдістеріне негізделген жүйенің прототипін жасау оң сыныпты жіктеудің жоғары дәлдігін қамтамасыз етуге және болжаудың абсолютті қателіктерін азайтуға мүмкіндік береді.

Зерттеу материалдары мен әдістері.

Осы зерттеу аясында ғылыми талдау, жіктеу, синтездеу, модельдеу әдістері қолданылады.

Жаһандық онкологиялық есептерге сәйкес, өкпенің қатерлі ісігі ең көп таралған қатерлі ісіктердің бірі болып табылады және ерлер мен әйелдердегі қатерлі ісік өлімінің жетекші себебі болып қала береді. Пациенттердің едәуір бөлігі хирургиялық емдеу мүмкін болмаған кезде және бес жылдық өмір сүру деңгейі өте төмен болған кезде анықталады. Тиімді ерте диагностика-өлім-жітімді азайтудың негізгі құралы; оның негізі төмен дозалы компьютерлік томография көмегімен скрининг болды [1-3].

Терең оқыту әдістерінің дамуымен соңғы 5-7 жылда компьютерлік томография кескіндерін автоматты түрде талдайтын, түйіндерді анықтайтын және сегменттейтін, қатерлі ісік ықтималдығын бағалайтын, тәуекелдің сандық көрсеткіштерін қалыптастыратын және нәтижелердің интерпретациясын арттыру үшін назар аудару аймақтарын визуализациялайтын нейрондық желілерге негізделген сараптамалық жүйелердің жаңа класы қалыптасты [4-6]. Бірқатар зерттеулер мұндай жүйелердің тәжірибелі рентгенологтардың жұмысымен салыстырылатын ROC-AUC дәлдігі мен көрсеткіштеріне қол жеткізетінін және стандартталған эксперименттер мен клиникалық сценарийлер жағдайында сезімталдық пен репродуктивтілік бойынша олардан асып түсетінін көрсетеді.

Жарияланған шолу зерттеулерінің салыстырмалы талдауы бірқатар тұрақты тенденцияларды көрсетеді. Көптеген жұмыстарда терең оқыту модельдері SVM, k-жақын көршілер және кездейсоқ орман сияқты классикалық машиналық оқыту алгоритмдерінен негізгі сапа көрсеткіштері, соның ішінде жіктеу дәлдігі және ROC қисығы (AUC) астындағы аумақ мәні бойынша артықшылықты көрсететіні атап өтілген. Шағын өкпе түйіндерін

талдау және үш өлшемді медициналық деректерді өңдеу кезінде ең үлкен тиімділікті 3D-CNN және 3D-U-Net-ке ұқсас модельдерге негізделген архитектуралар көрсетеді. Сонымен қатар, гибриді және көп тапсырмалы нейрондық желі шешімдері жалпылау қабілетінің жақсаруымен және компьютерлік томография хаттамаларының өзгеруіне төзімділіктің жоғарылауымен сипатталады.

Қол жеткізілген жетістіктерге қарамастан, өкпенің қатерлі ісігін ерте диагностикалау міндеттерінде нейрондық модельдерді қолдану бірқатар шектеулермен келеді. Негізгі мәселелердің бірі модельдердің шектеулі жалпылануы болып қала береді. Қолданыстағы шешімдердің көпшілігі LIDC-IDRI, LUNA16 және сирек NLST сияқты стандартты деректер жиынтығында оқытылады және сыналады. Модельдерді басқа медициналық орталықтардың, сканерлердің және пациенттер популяцияларының деректеріне көшіру кезінде болжау сапасының төмендеуі жиі байқалады, бұл компьютерлік томография хаттамалары бойынша көп орталықты және гетерогенді деректер жиынтығын қалыптастыру қажеттілігін көрсетеді. Сыныптардың теңгерімсіздігі және клиникалық жағдайлардың сирек болуы да маңызды күрделілік болып табылады. Аурудың ерте кезеңдері, шағын түйіндік түзілімдер және қатерлі ісіктің сирек морфологиялық кіші түрлері шектеулі көлемде оқу үлгілерінде ұсынылған. Тіпті генеративті әдістерді қолдану әрқашан нақты клиникалық деректердің тапшылығын толық өтеуге мүмкіндік бермейді.

Кескінді өңдеудің бірыңғай құбырларының болмауы ерекше назар аударуды қажет етеді. Әр түрлі зерттеулер қарқындылықты қалыпқа келтіру, контрастты күшейту, шуды басу және кіріс патчтарын қалыптастырудың өзіндік тәсілдерін қолданады, бұл нәтижелерді сәйкестендіруді және эксперименттердің қайталануын айтарлықтай қиындатады.

Сонымен қатар, мультимодальды және көп тапсырмалы тәсілдердің дәлелденген тиімділігіне қарамастан, компьютерлік томография, позитронды эмиссиялық томография деректерін, клиникалық және молекулалық белгілерді біріктіретін зерттеулер саны шектеулі болып қалады. Мұндай шешімдерді жүзеге асыру күрделі есептеу инфрақұрылымын және деректер форматтарының дәйектілігін талап етеді.

Нейрондық желі модельдерінің шешімдерін түсіндіру және клиниктердің сенім деңгейі маңызды мәселе болып қала береді. Grad-CAM және SHAP сияқты түсіндірілетін жасанды интеллект әдістерін қолданған кезде де, жеке болжамдарды түсіндіру қиын болып қалады, бұл жасанды интеллект жүйелерін қолданудың клиникалық жауапкершілігі мен заңды аспектілері мәселелерін тудырады.

Сонымен қатар, реттеуші және этикалық мәселелер айтарлықтай маңызға ие. Клиникалық практикаға жасанды интеллект шешімдерін енгізу үшін нақты пайдалану жағдайларында модельдерді валидациялау, сапа мониторингі және қауіпсіздігін бағалау рәсімдерін айқындайтын нақты нормативтік негіздер қажет. Бірқатар шолулар жауапкершілік, репродуктивтілік және реттеуші талаптарға сәйкестік принциптерін сақтау, сондай-ақ жүйелердің тиімділігін маркетингтен кейінгі үздіксіз бақылауды ұйымдастыру қажеттілігін көрсетеді [7-9].

Әдеби дереккөздерді талдау әрі қарайғы зерттеулердің бірнеше перспективалық бағыттарын анықтауға мүмкіндік береді. Дамудың негізгі векторларының бірі мультимодальды жасанды интеллект болып табылады, ол компьютерлік томография және позитронды эмиссиялық томография кескіндерін клиникалық, зертханалық және молекулалық деректермен терең оқытудың бірыңғай моделі шеңберінде біріктіруді көздейді. Бұл тәсіл тәуекелді дәлірек стратификациялауға және диагностика мен терапияны жекелендіру деңгейін арттыруға ықпал етеді.

Перспективалық бағыт сонымен қатар self-supervised және semi-supervised оқытуларын қолдану болып табылады, бұл модельдерді алдын ала оқыту үшін белгіленбеген компьютерлік томография деректерінің үлкен көлемін пайдалануға мүмкіндік береді, бұл әсіресе өкпе түйіндерінің мұқият аннотацияланған үлгілерінің

тапшылығына қатысты. Пациенттердің жеке өмірін сақтай отырып, оқыту деректерінің өзгергіштігін арттыра отырып, кескінді тікелей алмасусыз әртүрлі медициналық орталықтардың деректерінде модельдерді бірлесіп оқыту мүмкіндігін қамтамасыз ететін федеративтік оқыту да айтарлықтай әлеуетті көрсетеді.

Үш өлшемді деректермен жұмыс істеуге және клиникалық жұмыс станцияларына (PACS) интеграциялауға бағытталған түсіндірмелі жасанды интеллект әдістерін дамытуға, сондай-ақ рентгенологтардың модельдерді қайта конфигурациялау және валидациялау процесіне белсенді қатысуына ерекше назар аударылады. Ақырында, терең оқыту жүйелерін нақты клиникалық процестерге біріктіру маңызды бола түсуде. Бірқатар зерттеулер DL-CAD шешімдерінің күнделікті диагностикада практикалық пайда әкелетінін көрсетеді, олардың дамуының келесі кезеңі сапаны тұрақты бақылаумен және медициналық мамандардан кері байланыс алумен ауқымды енгізу болып табылады [10-12].

Нәтижелері және оларды талқылау.

Қатерлі ісікті ерте диагностикалау жүйесін құру кезеңдері:

1. Осы саладағы сарапшылардың сұрақтары мен жауаптары негізінде білім базасын құру, жауаптарды саралау. Бұл кезеңде онколог-дәрігерлердің өкпе обырына шалдыққан науқастардың ауру тарихы бойынша білім базасы құрылады. Сондай-ақ, сұрақтарға жауаптар белгілі бір фактордың әсер етуінің үлес салмағына байланысты ұйымдастырылады.

2. Қатысушылардың кіріс деректерін алу үшін сауалнамадан өтуі. Білім қорынан сұрақтар мен жауаптар бойынша сауалнама жасалды. 1000-нан астам респонденттердің жауаптары алынады.

3. Алынған жауаптарды болжау моделіне жүктеу. Алынған мәндер оқыту үшін нейрондық желі моделіне жүктеледі.

4. Өкпенің қатерлі ісігіне шалдығу қаупі бойынша нәтиже алу. Нейрондық желінің шығуында өкпенің қатерлі ісігіне бейімділіктің болжамды мәндері алынады.

5. Нәтиженің мәні жоғары болған жағдайда респондент одан әрі іс-әрекеттер бойынша ұсыныс алады.

Осы саладағы сарапшылардың сұрақтары мен жауаптары негізінде білім базасын құру, жауаптарды саралау.

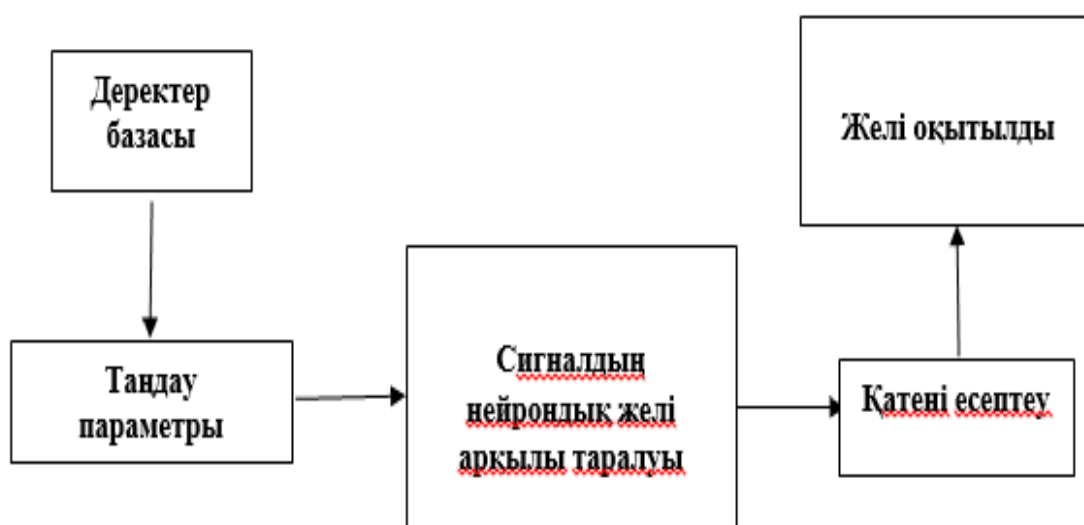
Сараптамалық жүйені құрудың бірінші кезеңі-пәндік саланы зерттеу, онкологтардан пәндік саланың білім базасын құру. Өкпенің қатерлі ісігін диагностикалау саласындағы онкологиялық дәрігерлердің ойлауын модельдеу үшін медициналық сарапшылардың пікірі негізінде ережелер базасы ретінде алынған 21 ереже қолданылды. Әр ережеде 2-ден 5-ке дейін жауап бар. Әрбір жауап жауаптың меншікті салмағына қарай бағаланды (1-кестені қараңыз).

Кесте 1 – Сараптама жүйесінің білім базасы

Сұрақ	Жауаптар			
	1 жауап	2 жауап	3 жауап	4 жауап
Жасы	30-40	40-50	50-60	60 и выше
	0,2	0,5	0,5	0,5
Жынысы	Еркек	Әйел		
	1	0,6		
Сіз темекі тартасыз ба?	Иә	Жоқ		
	1	0,5		
Темекі шегу тәжірибесі	10 жылға дейін	10 жылдан 20 жылға дейін	20 жылдан 30 жылға дейін	30 жылдан жоғары
	0,7	0,9	1	1
Күніне қанша қорап/дана темекі тартасыз?	10 дана темекіге дейін	1 қорапқа дейін	1 қорап	1 қораптан көп
	0,8	1	1	1

ЖРВИ жылына қанша рет ауырсыз?	1 рет	2 рет	мерзімді түрде	ауырмаймын	
	0,4	0,5	0,8	0,4	
Ата-аналар мен жақын туыстардағы онкоанамнез	1 ата-анада	Екі ата-анада	Ана жағынан жақын туыстарында	Әке жағынан жақын туыстарында	
	0,9	0,9	0,5	0,5	
Сізде қан құсу болды ма?	Иә	Жоқ			
	0,9	0,4			
Сізде ентігу, ауа жетіспейтін сезім бар ма?	мерзімді түрде	Жиі	Жаттыгу кезінде		
	0,5	1	1		
Дауыста өзгеріс болды ма?	Иә	Жоқ			
	0,8	0,2			
Сізде ештеңеге байланысты емес әлсіздік бар ма?	мерзімді түрде	Жиі	жоқ		
	0,3	0,5	0,2		
Жөтел бар ма?	болмаған	аздап	аз емес	өте қатты	
	0,2	0,2	0,3	0,8	
Сізде жұтылу проблемалары болды ма?	болмаған	аздап	аз емес	өте қатты	
	0,3	0,3	0,4	1	
Сізде кеуде ауыруы болды ма?	болмаған	аздап	аз емес	өте қатты	
	0,5	0,6	1	1	
Қолыңызда немесе иығыңызда ауырсыну болды ма?	болмаған	аздап	аз емес	өте қатты	
	0,5	0,5	0,7	1	
Сізде құрғақ жөтел болды ма?	болмаған	аздап	аз емес	өте қатты	
	0,4	0,6	0,8	0,8	
Сізде ештеңеге байланысты емес салмақ жоғалту болды ма?	болмаған	аздап	аз емес		
	0,5	0,5	1		
Сізде тәбеттің төмендеуі болды ма?	болмаған	аздап	аз емес	өте қатты	
	1	1	1	1	
Өкпенің басқа аурулары бойынша пульмонологтың "Д" есебінде тұрсыз ба?	иә	жоқ			
	1	0,5			
Туған жері	Аймақ 1	Аймақ 2	Аймақ 3	Аймақ 4	Басқа
Тұрғылықты жері	Аймақ 1	Аймақ 2	Аймақ 3	Аймақ 4	Басқа

Нейрондық желіні оқыту процесі 1 суретте көрсетілген.



Сурет 1 – Нейрондық желіні оқыту процесі

Нейрондық желіні оқыту процесін келесідей ұсынуға болады:

1. Алынған сауалнама деректерінен мәліметтер базасы толтырылады;
2. Деректер базасынан параметр таңдалады;
3. Таңдалған параметр берілген белсендіру функциясы бойынша нейрондық желі арқылы таралады;

4. Модель қатесі есептеледі;

5. Егер қате аз болса, онда желі оқытылған болып саналады;

Алынған жауаптарды болжау моделіне жүктеу.

Бұл кезеңде алынған жауаптар болжау моделіне жүктеледі. Алынған мәндер оқыту үшін нейрондық желі моделіне жүктеледі.

Модельдерді тестілеу

1. Модельдердің тұрақтылығы мен нәтижелердің қайталануын қамтамасыз ету үшін ColumnTransformer архитектурасын қолдана отырып, бірыңғай алдын ала өңдеу құбыры жүзеге асырылды.

2. Деректер жиынтығы 80/20 қатынасында стратификацияланған бөлуді (stratify=y) пайдалана отырып, оқыту және сынақ үлгілеріне бөлінді.

3. Белгілі бір гиперпараметрлері бар келесі алгоритмдер конфигурацияланды және оқытылды:

- Ағаш негізіндегі ансамбльдер: RandomForestClassifier және ExtraTreesClassifier 400 бағалаушымен оқытылды. Градиентті күшейту шеңберлері (XGBoost, CatBoost) 0,05 оқыту кадамымен реттелді.

- Нейрондық желілер: MLP классификаторы 500-ге дейін қайталануға үйретілген екі жасырын қабатпен (128 және 64 нейрон) салынған.

Модельдердің 8 түрінің нәтижелері 2-9 суреттерде көрсетілген.

A.1 Logistic Regression Output

===== FIGURE 1: Logistic Regression =====

A) PREDICTION EXAMPLES (first 10 rows):

actual	proba_class1	pred_thr_0_50	pred_thr_0_29
0.000000	0.000104	0.000000	0.000000
1.000000	0.999872	1.000000	1.000000
1.000000	0.946793	1.000000	1.000000
0.000000	0.398043	0.000000	1.000000
1.000000	0.953142	1.000000	1.000000
1.000000	0.609356	1.000000	1.000000
1.000000	0.851567	1.000000	1.000000
1.000000	0.999983	1.000000	1.000000
1.000000	0.895451	1.000000	1.000000
1.000000	0.999272	1.000000	1.000000

B) CLASSIFICATION REPORT:

0: precision=0.994186, recall=0.990347, f1=0.992263, support=518.000000
 1: precision=0.982394, recall=0.989362, f1=0.985866, support=282.000000
 macro_avg: precision=0.988290, recall=0.989855, f1=0.989064, support=800.000000
 weighted_avg: precision=0.990029, recall=0.990000, f1=0.990008, support=800.000000

C) PERFORMANCE METRICS:

- Accuracy: 0.990000
- Precision: 0.982394
- Recall: 0.989362
- F1-score: 0.985866
- ROC-AUC: 0.996844
- Log Loss: 0.066389

Сурет 2 – Logistic Regression Output

A.2 Random Forest Classifier Output

===== FIGURE 2: RandomForestClassifier =====

A) PREDICTION EXAMPLES (first 10 rows):

actual	proba_class1	pred_thr_0_50	pred_thr_0_29
0.000000	0.077500	0.000000	0.000000
1.000000	0.997500	1.000000	1.000000
1.000000	0.982500	1.000000	1.000000
0.000000	0.235000	0.000000	0.000000
1.000000	0.982500	1.000000	1.000000
1.000000	0.757500	1.000000	1.000000
1.000000	0.422500	0.000000	1.000000
1.000000	0.960000	1.000000	1.000000
1.000000	0.930000	1.000000	1.000000
1.000000	0.937500	1.000000	1.000000

B) CLASSIFICATION REPORT:

0: precision=0.982857, recall=0.996139, f1=0.989453, support=518.000000
 1: precision=0.992727, recall=0.968085, f1=0.980251, support=282.000000
 macro_avg: precision=0.987792, recall=0.982112, f1=0.984852, support=800.000000
 weighted_avg: precision=0.986336, recall=0.986250, f1=0.986210, support=800.000000

C) PERFORMANCE METRICS:

- Accuracy: 0.986250
- Precision: 0.992727
- Recall: 0.968085
- F1-score: 0.980251
- ROC-AUC: 0.995523
- Log Loss: 0.101495

Cyper 3 – RandomForestClassifier Output

A.3 Support Vector Machine (SVM) Output

===== FIGURE 3: SVM =====

A) PREDICTION EXAMPLES (first 10 rows):

actual	proba_class1	pred_thr_0_50	pred_thr_0_29
0.000000	0.000034	0.000000	0.000000
1.000000	1.000000	1.000000	1.000000
1.000000	0.994762	1.000000	1.000000
0.000000	0.779353	1.000000	1.000000
1.000000	0.997005	1.000000	1.000000
1.000000	0.918230	1.000000	1.000000
1.000000	0.740769	1.000000	1.000000
1.000000	1.000000	1.000000	1.000000
1.000000	0.972712	1.000000	1.000000
1.000000	1.000000	1.000000	1.000000

B) CLASSIFICATION REPORT:

0: precision=0.986513, recall=0.988417, f1=0.987464, support=518.000000
 1: precision=0.978648, recall=0.975177, f1=0.976909, support=282.000000
 macro_avg: precision=0.982580, recall=0.981797, f1=0.982187, support=800.000000
 weighted_avg: precision=0.983740, recall=0.983750, f1=0.983743, support=800.000000

C) PERFORMANCE METRICS:

- Accuracy: 0.983750
- Precision: 0.978648
- Recall: 0.975177
- F1-score: 0.976909
- ROC-AUC: 0.995263
- Log Loss: 0.081262

Cyper 4 – Support Vector Machine (SVM) Output

A.4 ExtraTrees Classifier Output

===== FIGURE 4: ExtraTreesClassifier =====

A) PREDICTION EXAMPLES (first 10 rows):

actual	proba_class1	pred_thr_0_50	pred_thr_0_29
0.000000	0.090000	0.000000	0.000000
1.000000	0.995000	1.000000	1.000000
1.000000	0.987500	1.000000	1.000000
0.000000	0.302500	0.000000	1.000000
1.000000	0.987500	1.000000	1.000000
1.000000	0.777500	1.000000	1.000000
1.000000	0.395000	0.000000	1.000000
1.000000	0.975000	1.000000	1.000000
1.000000	0.937500	1.000000	1.000000
1.000000	0.962500	1.000000	1.000000

B) CLASSIFICATION REPORT:

0: precision=0.984645, recall=0.990347, f1=0.987488, support=518.000000
 1: precision=0.982079, recall=0.971631, f1=0.976827, support=282.000000
 macro_avg: precision=0.983362, recall=0.980989, f1=0.982158, support=800.000000
 weighted_avg: precision=0.983740, recall=0.983750, f1=0.983730, support=800.000000

C) PERFORMANCE METRICS:

- Accuracy: 0.983750
- Precision: 0.982079
- Recall: 0.971631
- F1-score: 0.976827
- ROC-AUC: 0.995725
- Log Loss: 0.094586

Cyper 5 – ExtraTrees Classifier Output

A.5 XGBoost Classifier Output

===== FIGURE 5: XGBoostClassifier =====

A) PREDICTION EXAMPLES (first 10 rows):

actual	proba_class1	pred_thr_0_50	pred_thr_0_29
0.000000	0.000007	0.000000	0.000000
1.000000	0.999948	1.000000	1.000000
1.000000	0.998728	1.000000	1.000000
0.000000	0.005955	0.000000	0.000000
1.000000	0.998738	1.000000	1.000000
1.000000	0.982967	1.000000	1.000000
1.000000	0.203819	0.000000	0.000000
1.000000	0.999929	1.000000	1.000000
1.000000	0.998290	1.000000	1.000000
1.000000	0.999952	1.000000	1.000000

B) CLASSIFICATION REPORT:

0: precision=0.988528, recall=0.998069, f1=0.993276, support=518.000000
 1: precision=0.996390, recall=0.978723, f1=0.987478, support=282.000000
 macro_avg: precision=0.992459, recall=0.988396, f1=0.990377, support=800.000000
 weighted_avg: precision=0.991299, recall=0.991250, f1=0.991232, support=800.000000

C) PERFORMANCE METRICS:

- Accuracy: 0.991250
- Precision: 0.996390
- Recall: 0.978723
- F1-score: 0.987478
- ROC-AUC: 0.999945
- Log Loss: 0.016491

Cyper 6 – XGBoost Classifier Output

A.6 CatBoost Classifier Output

===== FIGURE 6: CatBoostClassifier =====

A) PREDICTION EXAMPLES (first 10 rows):

actual	proba_class1	pred_thr_0_50	pred_thr_0_29
0.000000	0.000035	0.000000	0.000000
1.000000	0.999914	1.000000	1.000000
1.000000	0.998637	1.000000	1.000000
0.000000	0.002271	0.000000	0.000000
1.000000	0.998420	1.000000	1.000000
1.000000	0.976426	1.000000	1.000000
1.000000	0.852638	1.000000	1.000000
1.000000	0.999964	1.000000	1.000000
1.000000	0.998589	1.000000	1.000000
1.000000	0.999927	1.000000	1.000000

B) CLASSIFICATION REPORT:

0: precision=0.994231, recall=0.998069, f1=0.996146, support=518.000000
 1: precision=0.996429, recall=0.989362, f1=0.992883, support=282.000000
 macro_avg: precision=0.995330, recall=0.993716, f1=0.994514, support=800.000000
 weighted_avg: precision=0.995005, recall=0.995000, f1=0.994996, support=800.000000

C) PERFORMANCE METRICS:

- Accuracy: 0.995000
- Precision: 0.996429
- Recall: 0.989362
- F1-score: 0.992883
- ROC-AUC: 0.999959
- Log Loss: 0.010003

Cyper 7 – CatBoost Classifier Output

A.7 Gradient Boosting Classifier Output

===== FIGURE 7: GradientBoostingClassifier =====

A) PREDICTION EXAMPLES (first 10 rows):

actual	proba_class1	pred_thr_0_50	pred_thr_0_29
0.000000	0.005465	0.000000	0.000000
0.000000	0.000032	0.000000	0.000000
0.000000	0.000044	0.000000	0.000000
0.000000	0.000044	0.000000	0.000000
0.000000	0.257882	0.000000	0.000000
0.000000	0.000026	0.000000	0.000000
0.000000	0.000062	0.000000	0.000000
0.000000	0.000044	0.000000	0.000000
0.000000	0.000020	0.000000	0.000000
0.000000	0.001660	0.000000	0.000000

B) CLASSIFICATION REPORT:

0: precision=0.954545, recall=1.000000, f1=0.976744, support=42.000000
 1: precision=0.000000, recall=0.000000, f1=0.000000, support=2.000000
 macro_avg: precision=0.477273, recall=0.500000, f1=0.488372, support=44.000000
 weighted_avg: precision=0.911157, recall=0.954545, f1=0.932347, support=44.000000

C) PERFORMANCE METRICS:

- Accuracy: 0.954545
- Precision: 0.000000
- Recall: 0.000000
- F1-score: 0.000000
- ROC-AUC: 0.726190
- Log Loss: 0.418973

Cyper 8 – Gradient Boosting Classifier Output

A.8 MLP Classifier (Neural Network) Output

===== FIGURE 8: MLPClassifier =====

A) PREDICTION EXAMPLES (first 10 rows):

actual	proba_class1	pred_thr_0_50	pred_thr_0_29
0.000000	0.000272	0.000000	0.000000
0.000000	0.001324	0.000000	0.000000
0.000000	0.002433	0.000000	0.000000
0.000000	0.001238	0.000000	0.000000
0.000000	0.216389	0.000000	0.000000
0.000000	0.000239	0.000000	0.000000
0.000000	0.000694	0.000000	0.000000
0.000000	0.000944	0.000000	0.000000
0.000000	0.000222	0.000000	0.000000
0.000000	0.605130	1.000000	1.000000

B) CLASSIFICATION REPORT:

```
0: precision=0.953488, recall=0.976190, f1=0.964706, support=42.000000
1: precision=0.000000, recall=0.000000, f1=0.000000, support=2.000000
macro_avg: precision=0.476744, recall=0.488095, f1=0.482353, support=44.000000
weighted_avg: precision=0.910148, recall=0.931818, f1=0.920856, support=44.000000
```

C) PERFORMANCE METRICS:

```
- Accuracy: 0.931818
- Precision: 0.000000
- Recall: 0.000000
- F1-score: 0.000000
- ROC-AUC: 0.940476
- Log Loss: 0.229548
```

Сурет 9 – MLP Classifier (Neural Network) Output

Эксперимент ең жақсы нәтижелерді нейрондық желіге негізделген модель — MLPClassifier көрсеткенін растады. Ол 93%-дан жоғары дәлдікпен ROC-AUC (0.9405) метрикасының ең жоғары мәнін көрсетті. Бұл модель пациенттерді тәуекел топтары бойынша сенімді түрде бағалайтынын көрсетеді. Екінші орынды ұқсас нәтижелер көрсеткен RandomForest және SVM алгоритмдері бөлісті.

Осы зерттеу аясында қолданыстағы шолу жұмыстарына салыстырмалы талдау жүргізілді, оның барысында онкологиялық ауруларды ерте анықтау үшін нейрондық желі әдістерін қолданудың негізгі мәселелері бөлінді. Негізгі шектеулерге модельдердің жалпылау қабілетінің жеткіліксіздігі, сыныптардың айқын теңгерімсіздігі және оң клиникалық жағдайлардың сирек ұсынылуы, деректерді өндеудің бірыңғай тәсілдерінің болмауы, мультимодальды және көп тапсырмалы архитектураларды қолданатын зерттеулердің шектеулі саны, сондай-ақ интерпретация, сенім, реттеуші сүйемелдеу және жасанды интеллектті қолданудың этикалық аспектілерінің шешілмеген мәселелері жатады. Жүргізілген талдау негізінде осы саланы одан әрі дамытудың перспективалық бағыттары айқындалды. Біріктірілген тәсілдерді қолдана отырып, өкпенің қатерлі ісігін ерте диагностикалау міндеттеріне бағытталған білім моделі құрылды. Өзірленген болжамды модельдер машиналық оқыту әдістеріне негізделген, соның ішінде логистикалық регрессия, кездейсоқ орман, тірек векторлық әдіс (SVM), ExtraTrees, XGBoost, CatBoost, градиентті күшейту және көп қабатты перцептрон (MLP). Кіріс белгілері ретінде тұқым қуалайтын бейімділік, науқастың жынысы және темекі шегу тәжірибесі сияқты факторлар қолданылды.

Ең жоғары сапа көрсеткіштерін нейрондық желіге негізделген модель-MLPClassifier көрсетті, ол ROC-AUC метрикасының максималды мәніне 0,9405-ке жетті, Дәлдік деңгейі 93% - дан жоғары. Бұл модельдің пациенттерді тәуекел топтары бойынша дұрыс саралау қабілетінің жоғары екендігін көрсетеді. Салыстырмалы нәтижелер жіктеу тиімділігі

бойынша екінші орынды бөлетін RandomForest және SVM алгоритмдерін көрсетті. Көрсеткіштердің қол жеткізілген мәндеріне қарамастан, жүйені іс жүзінде енгізу үшін модельдің сирек кездесетін жағдайларға сезімталдығын арттыру мақсатында сыныптарды қосымша теңгерімдеу ұсынылады.

Әзірленген модель өкпенің қатерлі ісігінің даму ықтималдығын бағалауға, сондай-ақ өкпе туберкулезі, саркоидоз, пневмония және өкпе фиброзын қоса, қатар жүретін патологиялардың болуы мүмкін екендігі туралы ұсыныстар жасауға мүмкіндік береді.

Сонымен қатар, жұмыста ұсынылған модельді клиникалық тәжірибеде нақты пациенттердің үлгісінде қолдану мысалдары келтірілген, бұл оның әлеуетті қолданбалы маңыздылығын растайды.

Қорытынды.

Онкологиялық аурулар қазіргі заманғы денсаулық сақтаудың маңызды мәселелерінің бірі болып қала береді. Өкпенің қатерлі ісігі өлім-жітім бойынша жетекші орынға ие, бұл көбінесе оны аурудың соңғы сатысында анықтауға байланысты. Бұл жағдайда терең оқыту әдістеріне, ең алдымен конволюциялық нейрондық желілерге (CNN), трансформаторлық архитектураларға және олардың гибридті модификацияларына негізделген интеллектуалды сараптамалық жүйелер ерекше дамиды.

Осы зерттеу аясында нейрондық желі технологияларын қолдана отырып, өкпе обырын ерте анықтау тәсілдері қарастырылды. Онкологиялық ауруларды диагностикалау міндеттеріне сәйкес келетін бірқатар критерийлер бойынша нейрондық желілердің әртүрлі түрлерін жіктеу орындалды.

Өкпенің қатерлі ісігін ерте диагностикалау жүйесін құрудың негізгі кезеңдері анықталды және тиісті пәндік саланың білім базасы құрылды. Негізгі қауіп факторларын ескере отырып, нейрондық желінің математикалық моделі және білім моделі жасалды. Өкпенің қатерлі ісігін диагностикалау саласындағы онкологиялық дәрігерлердің клиникалық ойлау процесін ресімдеу үшін медициналық мамандармен кеңесу негізінде құрылған 21 сараптамалық ереженің жиынтығы қолданылды. Әрбір ереже олардың салыстырмалы маңыздылығына сәйкес екі-бес ықтимал жауаптарды қамтыды.

Зерттеу логистикалық регрессия, кездейсоқ орман, тірек векторлық әдіс (SVM), ExtraTrees, XGBoost, CatBoost, градиентті күшейту және көп қабатты перцептрон (MLP) сияқты әртүрлі машиналық оқыту әдістеріне негізделген модельдерді әзірледі және талдады. Кіріс белгілері ретінде тұқым қуалайтын бейімділік көрсеткіштері, пациенттің жынысы және темекі шегу тәжірибесі пайдаланылды. Эксперименттік зерттеулердің нәтижелері қарастырылып отырған деректер жиынында ең жақсы сапа көрсеткіштерін ROC-AUC метрикасының максималды мәніне 0,9405-ке жеткен көп қабатты перцептрон (MLPClassifier) негізіндегі модель 93% - дан жоғары дәлдік деңгейінде көрсеткенін көрсетті. Бұл модельдің пациенттерді тәуекел топтары бойынша дұрыс саралау қабілетінің жоғары екендігін көрсетеді. Салыстырмалы нәтижелер жіктеу тиімділігі бойынша екінші орында тұрған RandomForest және SVM алгоритмдерін көрсетті. Сонымен қатар, жүйені іс жүзінде енгізу үшін модельдің сирек кездесетін жағдайларға сезімталдығын арттыруға бағытталған сыныптарды теңестіру бойынша қосымша жұмыс ұсынылады. Әзірленген модель өкпенің қатерлі ісігінің даму ықтималдығын бағалауға, сондай-ақ өкпе туберкулезі, саркоидоз, пневмония және өкпе фиброзын қоса, қатар жүретін аурулардың болуы мүмкін екендігі туралы ұсыныстар жасауға мүмкіндік береді. Сондай-ақ, жұмыста өкпенің қатерлі ісігін ерте диагностикалау жүйесінің архитектурасы мен құрылымдық схемасы ұсынылған, сонымен қатар оны пациенттер тобында клиникалық тәжірибеде қолдану мысалдары келтірілген. Болашақта өкпенің қатерлі ісігін ерте анықтау үшін кешенді шешім жасауға мүмкіндік беретін медициналық бейнені тану модулін біріктіру арқылы жүйенің функционалдығын кеңейту жоспарлануда.

Әдебиеттер тізімі

1. Freddie Bray, Mathieu Laversanne, Hyuna Sung, Jacques Ferlay, Rebecca L. Siegel, Isabelle Soerjomataram & Ahmedin Jemal (2024). Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. A Cancer Journal for Clinicians published by Wiley Periodicals LLC on behalf of American Cancer Society. № 3, 229–263. <https://doi.org/10.3322/caac.21834>
2. de Koning, H.J., van der Aalst, C.M., de Jong, P.A., Scholten, E.T., Nackaerts, K. & Heuvelmans, M.A. (2020). Reduced lung-cancer mortality with volume CT screening in a randomized trial. The New England Journal of Medicine, 382(6), 503-513. <https://doi.org/10.1056/nejmoa1911793>
3. Mohammad, A Thanoon, Mohd Asyraf Zulkifley, Muhammad Ammirul Atiqi Mohd Zainuri & Siti Raihanah Abdani (2023). A Review of Deep Learning Techniques for Lung Cancer Screening and Diagnosis Based on CT Images. Diagnostics (Basel), 13. <https://doi.org/10.3390/diagnostics13162617>
4. John T. Murchison, Gillian Ritchie, David Senyszak, Jeroen H. Nijwening & Edwin J.R. van Beek (2022). Validation of a deep learning computer aided system for CT based lung nodule detection, classification, and growth rate estimation in a routine clinical population. PLOS ONE. Public Library of Science, № 5. <https://doi.org/10.1371/journal.pone.0266799>
5. Abhishek Mahajan, Rajat Agarwal, Ujjwal Agarwal, Renuka M Ashtekar, Bharadwaj Komaravolu, Apparao Madiraju, Richa Vaish, Vivek Pawar, Vivek Punia, Vijay Maruti Patil & Vanita Noronha (2025). A Novel Deep Learning-Based (3D U-Net Model) Automated Pulmonary Nodule Detection Tool for CT Imaging. MDPI Current Oncology, № 2. <https://doi.org/10.3390/curroncol32020095>
6. Mohammad Khalid Faizi, Yan Qiang, Yangyang Wei, Ying Qiao, Juanjuan Zhao, Rukhma Aftab & Zia Urrehman (2025). Deep learning-based lung cancer classification of CT images. BMC Cancer, № 1. <https://doi.org/10.1186/s12885-025-14320-8>
7. Salama, W. M., Shokry, A. & Aly, M. H. (2022). A generalized framework for lung Cancer classification based on deep generative models. Multimedia Tools and Applications, 81(11). <https://doi.org/10.1007/s11042-022-13005-9>
8. Ling Ma, Chuangye Wan, Kexin Hao, Annan Cai & Lizhi Liu. (2023). A novel fusion algorithm for benign-malignant lung nodule classification on CT images. BMC Pulmonary Medicine, № 1. <https://doi.org/10.1186/s12890-023-02708-w>
9. Wang, X., Sharpnack, J. & Lee T. C. M. (2025). Improving lung cancer diagnosis and survival prediction with deep learning and CT imaging. PLOS ONE, № 6. <https://doi.org/10.1371/journal.pone.0323174>
10. Runhan Li & Barmak Honarvar Shakibaei Asli. (2025). Multi-Task Deep Learning for Lung Nodule Detection and Segmentation in CT scans: A Review. Electronics, № 15. <https://doi.org/10.3390/electronics14153009>
11. Noor, S. Jozi & Ghaida, A. Al-Suhail. (2025). LCxNet: An Explainable CNN Framework for Lung Cancer Detection in CT Images Using Multi-Optimizer and Visual Interpretability. Applied System Innovation, 8(5), 153. <https://doi.org/10.3390/asi8050153>
12. Michaela Cellina & Laura Maria Cacioppa. (2023). Artificial Intelligence in Lung Cancer Screening: The Future Is Now. Cancers, № 17. <https://doi.org/10.3390/cancers15174344>

РАННЯЯ ДИАГНОСТИКА РАКА ЛЕГКИХ ПО БАЗОВЫМ ФАКТОРАМ РИСКА ПРИ ПОМОЩИ НЕЙРОННЫХ СЕТЕЙ

Аннотация. Заболеваемость онкологическими заболеваниями в настоящее время остается одной из наиболее значимых проблем современного общества. Рак легких относится к числу наиболее летальных форм онкопатологии, что во многом обусловлено его выявлением на поздних стадиях опухолевого процесса. Эффективность программ

скрининга и ранней диагностики оказывает непосредственное влияние на прогноз заболевания и показатели выживаемости пациентов. В связи с этим особое внимание в последние годы уделяется развитию интеллектуальных экспертных систем, основанных на методах глубокого обучения, включая сверточные нейронные сети (CNN), трансформерные архитектуры и их гибридные решения.

В данной работе рассматривается задача ранней диагностики рака легких с применением нейросетевых моделей глубокого обучения. В ходе исследования были разработаны и проанализированы модели с использованием следующих методов машинного обучения: логистическая регрессия, классификатор случайных лесов, метод опорных векторов (SVM), классификатор экстремальных деревьев, XGBoost, CatBoost, градиентный бустинг и многослойный перцептрон (MLP). В качестве входных факторов в нейросетевую модель были использованы показатели наследственной предрасположенности, пол пациента и стаж курения. Наилучшие результаты продемонстрировала модель на основе многослойного перцептрона (MLPClassifier), достигшая максимального значения метрики ROC-AUC, равного 0,9405, при уровне точности свыше 93%. Полученные показатели свидетельствуют о высокой способности модели к корректному ранжированию пациентов по группам риска. Сопоставимые результаты показали алгоритмы RandomForest и SVM, занявшие вторую позицию по качеству классификации. Разработанная нейросетевая модель позволяет оценивать вероятность развития рака легких, а также формировать рекомендации относительно возможного наличия сопутствующих заболеваний, таких как диссеминированный туберкулез легких, саркоидоз, пневмония и фиброз легочной ткани.

В дальнейшем планируется расширение функциональности системы за счет интеграции модуля распознавания медицинских изображений, что позволит создать комплексное решение для ранней диагностики рака легких.

Ключевые слова: информационные системы, искусственный интеллект, методы глубокого обучения, интеллектуальный анализ данных, интеллектуальная система, базы данных, сверточная нейронная сеть, трансформеры, гибридные модели, explainable AI.

EARLY DIAGNOSIS OF LUNG CANCER BASED ON BASIC RISK FACTORS USING NEURAL NETWORKS

Abstract. *The incidence of cancer currently remains one of the most significant problems of modern society. Lung cancer is one of the most lethal forms of oncopathology, which is largely due to its detection in the late stages of the tumor process. The effectiveness of screening and early diagnosis programs has a direct impact on disease prognosis and patient survival rates. In this regard, special attention has been paid in recent years to the development of intelligent expert systems based on deep learning methods, including convolutional neural networks (CNN), transformer architectures and their hybrid solutions.*

This paper considers the problem of early diagnosis of lung cancer using deep learning neural network models. During the research, models were developed and analyzed using the following machine learning methods: logistic regression, random forest classifier, support vector machine (SVM), extreme tree classifier, XGBoost, CatBoost, gradient boosting and multilayer perceptron (MLP). The indicators of hereditary predisposition, the patient's gender and smoking experience were used as input factors to the neural network model. The best results were demonstrated by a model based on a multilayer perceptron (MLPClassifier), which reached the maximum value of the ROC-AUC metric, equal to 0.9405, with an accuracy level of over 93%. The obtained indicators indicate the high ability of the model to correctly rank patients by risk groups. The randomForest and SVM algorithms, which took the second position in classification quality, showed comparable results. The developed neural network model makes it possible to assess the likelihood of developing lung cancer, as well as to make recommendations regarding

the possible presence of concomitant diseases such as disseminated pulmonary tuberculosis, sarcoidosis, pneumonia and pulmonary fibrosis.

In the future, it is planned to expand the functionality of the system by integrating a medical image recognition module, which will create a comprehensive solution for early diagnosis of lung cancer.

Keywords: *information systems, artificial intelligence, deep learning methods, intelligent data analysis, intelligent system, databases, convolutional neural network, transformers, hybrid models, explicable AI.*

Авторлар туралы мәліметтер

Карымсакова Индира Бекеновна	PhD, «Автоматтандыру және ақпараттық технологиялар» кафедрасының қауымдастырылған профессорының м.а., «Шәкәрім университет» коммерциялық емес акционерлік қоғам, Семей, Қазақстан Республикасы e-mail: karymsakova.indira@mail.ru
Бекенова Дарига Бекенқызы	математика магистры, «Ақпараттық технологиялар» кафедрасының аға оқытушысы, «Тұран-Астана» университеті, Астана, Қазақстан Республикасы e-mail: dariy6a@mail.ru
Абдибекова Лязат Муратовна	магистр, «Ақпараттық жүйелер және технологиялар» кафедрасының аға оқытушысы, Esil University, Астана, Қазақстан Республикасы e-mail: moimir85@bk.ru
Ерсултанова Зауреш Сапарғалиевна	т.ғ.к., «Физика, математика және цифрлық технологиялар кафедра профессорының ассистенты, Ахмет Байтұрсынұлы атындағы Қостанай өңірлік университеті, Қостанай, Қазақстан Республикасы e-mail: ersul_67@mail.ru
Сексембаева Манара Ануаровна	магистр, «Ақпараттық жүйелер және технологиялар» кафедрасының аға оқытушысы, Esil University, Астана, Қазақстан Республикасы e-mail: anuarkizi@gmail.com

Сведения об авторах

Карымсакова Индира Бекеновна	PhD, и.о.ассоциированного профессора кафедры «Автоматизация и информационные технологии», Некоммерческое акционерное общество "Шәкәрім университет", Семей, Республика Казахстан e-mail: karymsakova.indira@mail.ru
Бекенова Дарига Бекеновна	магистр математики, старший преподаватель кафедры «Информационные технологии», Университет «Тұран-Астана», Астана, Республика Казахстан e-mail: dariy6a@mail.ru
Абдибекова Лязат Муратовна	магистр, старший преподаватель кафедры «Информационные системы и технологии», Esil University, Астана, Республика Казахстан e-mail: moimir85@bk.ru
Ерсултанова Зауреш Сапарғалиевна	к.т.н., ассистент профессора кафедры «Физики, математики и цифровых технологий», Костанайский региональный университет имени Ахмета Байтұрсынұлы, Костанай, Республика Казахстан e-mail: ersul_67@mail.ru
Сексембаева Манара Ануаровна	магистр, старший преподаватель кафедры «Информационные системы и технологии», Esil University, Астана, Республика Казахстан e-mail: anuarkizi@gmail.com

Information about the authors

Karymsakova Indira	PhD, acting associate professor of the department of "Automation and information technologies", Non-profit Joint-stock company "Shakarim University", Semey, Republic of Kazakhstan, e-mail: karymsakova.indira@mail.ru
Bekenova Dariga	master of mathematics, senior lecturer at the department of Information technologies, "Turan-Astana" University, Astana, Republic of Kazakhstan e-mail: dariy6a@mail.ru

Abdibekova Lyazat	master, senior lecturer at the department of Information systems and technologies, Esil University, Astana, Republic of Kazakhstan, e-mail: moimir85@bk.ru
Yersultanova Zauresh	candidate of technical sciences, assistant of professor of the department of Physics, Mathematics and digital technologies, Kostanay regional university named after Akhmet Baitursynuly, Kostanay, Republic of Kazakhstan, e-mail: ersul_67@mail.ru
Seksembayeva Manara	master, senior lecturer at the department of Information systems and technologies, Esil University, Astana, Republic of Kazakhstan, e-mail: anuarkizi@gmail.com