

**І.А.Олжатай**

магистрант

М.Х.Дулати атындағы Тараз университеті

Тараз қ., Қазақстан

[inkaroljataeva@gmail.com](mailto:inkaroljataeva@gmail.com)

**Ж.К. Тасжурекова** 

Техника ғылымдарының кандидаты

М.Х.Дулати атындағы Тараз университеті

Тараз қ., Қазақстан

[zhk.taszhurekova@dulaty.kz](mailto:zhk.taszhurekova@dulaty.kz)

**М.А.Ахметжанов**

физика-математика ғылымдарының кандидаты

М.Х.Дулати атындағы Тараз университеті

Тараз қ., Қазақстан

[ma.akhmetzhanov@dulaty.kz](mailto:ma.akhmetzhanov@dulaty.kz)

## ПСИХИКАЛЫҚ ДЕНСАУЛЫҚ КӨРСЕТКІШТЕРІН ТАЛДАУ: ДЕПРЕССИЯ БОЛЖАМЫН ИНТЕРПРЕТАЦИЯЛАУ ҮШІН МАШИНАЛЫҚ ОҚЫТУДЫ ҚОЛДАНУ

**Аңдатпа.** Бұл мақалада психикалық денсаулық көрсеткіштерін талдау кезінде түсіндірілетін машиналық оқыту (Explainable AI) әдістерін қолданудың маңыздылығы қарастырылады. Зерттеудің негізгі мақсаты – әртүрлі машиналық оқыту алгоритмдерінің (логистикалық регрессия, Random Forest, XGBoost және нейрондық желілер) дәлдігі мен интерпретацияланғыштығын салыстыру арқылы клиникалық шешім қабылдау сапасын арттыру. SHAP әдісі модель нәтижелерін түсіндіру және маңызды белгілердің (feature importance) үлесін анықтау үшін қолданылды. Зерттеу нәтижелері күрделі модельдер (мысалы, нейрондық желілер) жоғары дәлдік көрсеткенімен, олардың түсіндірімділігі төмен екенін көрсетті. Ал Random Forest және XGBoost алгоритмдері дәлдік пен түсіндірілетіндік арасында оңтайлы тепе-теңдікке ие болды. Бұл әдістердің көмегімен психиатрлар мен клиникалық мамандардың жасанды интеллектке деген сенімі арта түсетіні анықталды.

**Тірек сөздер:** машиналық оқыту, интерпретация, SHAP әдісі, XGBOOST, нейрондық желілер, логистикалық регрессия.

**Кіріспе.** Қазақстан 180 ел арасында депрессияның таралу деңгейі бойынша 93-ші орынды иеленді. Депрессиялық бұзылудан зардап шегетін Қазақстандықтардың үлесі 4,4% құрайды. Әлемдік көрсеткіш айтарлықтай аз: 3,9%. Бағалауға сәйкес, депрессияға ұшыраған еліміздің азаматтарының саны 732,7 мың адамға жетеді [1].

Бұл мәліметтер депрессияны ерте кезеңде анықтай алатын интеллектуалды диагностикалық жүйелерді

әзірлеудің және енгізудің қажеттілігін айқын көрсетеді. Осы тұрғыда түсіндірілетін машиналық оқыту (Explainable AI) модельдерін психиатриялық диагностикалауда қолдану – мамандарға клиникалық шешім қабылдау кезінде маңызды көмек құралы бола алады.

Машиналық оқытуда (Machine Learning) күрделі статистикалық және ықтималдық әдістер қолданылады, олар тәжірибе негізінде үйреніп, уақыт өте келе өз жұмысын жетілдіре

алатын жүйелерді құруға мүмкіндік береді. Бұл құралды пайдалану психикалық денсаулықты болжау сапасын едәуір арттыра алады.

Мұндай тәсілдер арқылы зерттеушілер үлкен көлемдегі деректерден жаңа ғылыми білім ала алады, науқастарға жекелендірілген тәжірибе ұсына алады, сондай-ақ интеллектуалды алгоритмдер әзірлеу мүмкіндігіне ие болады. Психикалық денсаулықты болжау және болашақтағы оқиғаларды жіктеу саласында ең жиі қолданылатын машиналық оқыту алгоритмдеріне тірек векторлық машиналар (Support Vector Machines, SVM), кездейсоқ ормандар (Random Forests) және жасанды нейрондық желілер (Artificial Neural Networks, ANN) жатады [2].

Машиналық оқытудың заманауи әдістері медициналық диагностика мен психикалық бұзылуларды болжау мәселелерін шешуде жоғары дәлдік көрсеткіштерін көрсетеді. Дегенмен, онымен бірге күрделі мәселе туындайды. Ол модельдердің шектеулі интерпретациясы. Дәрігерлер мен психикалық денсаулық мамандары көбінесе "қара жәшіктерге" сенуге дайын емес, олар нәтижелерді олардың негізінде жатқан себептерді ашық түсіндірмей береді. Интерпретацияның болмауы жасанды интеллект жүйелеріне деген сенім деңгейін төмендетеді және олардың клиникалық тәжірибеге енуіне жол бермейді.

**Зерттеудің негізгі мақсаты** – Психикалық денсаулық көрсеткіштерін яғни депрессия деңгейін болжау міндетіндегі Дәлдік деңгейі бойынша машиналық оқытудың әртүрлі алгоритмдеріне салыстырмалы талдау жүргізу, сондай-ақ алынған модельдердің түсіндірілуін және оның медицина мамандарының сеніміне әсерін бағалау.

**Зерттеу міндеттері:** Психикалық көрсеткіштерді талдау арқылы депрессия деңгейін болжау үшін бірнеше Машиналық оқыту алгоритмдерін (мысалы, логистикалық регрессия, кездейсоқ орман, XGBoost және нейрондық желілер) оқыту және сынау.

Стандартты көрсеткіштерді (Accuracy, Precision, Recall, F1-score, AUC) қолдана отырып, модельдердің дәлдігін салыстыру.

Модельдердің шешім қабылдау-ға қосқан үлесін талдау үшін SHAP (Shapley Additive exPlanations) интерпретация әдісін қолдану.

Психиатриялық болжау тапсырмалары үшін модельдердің дәлдігі мен ашықтығының оңтайлы үйлесімі бойынша ұсыныстар жасау.

**Күтілетін нәтижелер.** Машиналық оқыту әдістерін (Explainable AI) пайдалану алгоритмдердің жұмысының ашықтығын арттыруға, сондай-ақ оларды клиникалық және психиатриялық практикада кеңінен қолдануға мүмкіндік береді.

**Зерттеу әдістері.** Зерттеу барысында «Mental Health» атты Kaggle платформасында жарияланған ашық қолжетімді деректер жиынтығы қолданылды. Деректер жинағы психикалық денсаулыққа қатысты әртүрлі факторларды зерттеу үшін жасалған. Деректер жинағы әртүрлі демографиялық, әлеуметтік және кәсіби мәліметтерді қамтиды (1-кесте).

Әрбір CSV файлдан барлық бірегей көрсеткіштерді ортақ идентификаторлар бойынша біріктіріп, бір үлкен деректер жинағы жасалды. Біріктірілген деректер жинағы 57207 жолдан және 18 бағаннан тұрады. Деректер жиынтығында қатысушылардың жас ерекшеліктері әртүрлі, яғни барлық жас тобын қамтитын немесе жас бойынша стандартталған мәндер. Қатысушылардың жыныстық құрамы

ерлер мен әйелдерден тұрады. Деректер географиялық, демографиялық және клиникалық / эпидемиологиялық көрсеткіштерді қамтиды.

Деректер жинағында көптеген бағандар категориялық, ал кейбірі сандық болып келеді.

Кесте 1

Деректер жинағының құрылымы

Файл атауы	Негізгі бағандар	Деректер түрі	Мазмұны/ Пайдасы
mental-and-substance-use-as-share-of-disease.csv	Entity, Year, share_mental_and_substance	Сандық, категориялық (Entity)	Елдер мен жылдар бойынша психикалық және затқа байланысты бұзылулардың жалпы аурулар ішіндегі үлесі
prevalence-by-mental-and-substance-use-disorder.csv	Entity, Year, prevalence_disorder	Сандық	Әр түрлі психикалық және затқа байланысты бұзылыстардың таралу көрсеткіштері
prevalence-of-depression-males-vs-females.csv	Entity, Year, sex, prevalence_depression	Сандық, категориялық	Ерлер мен әйелдер арасындағы депрессияның таралу көрсеткіштері
share-with-depression.csv	Entity, Year, share_depression	Сандық	Жалпы психикалық бұзылыстар ішіндегі депрессия үлесі
share-with-mental-and-substance-disorders.csv	Entity, Year, share_mental_and_substance	Сандық	Психикалық және затқа байланысты бұзылыстары бар қатысушылардың үлесі
share-with-mental-or-substance-disorders-by-sex.csv	Entity, Year, sex, share_mental_or_substance	Сандық, категориялық	Жынысқа байланысты психикалық немесе затқа байланысты бұзылыстардың үлесі

Деректерді алдын-ала өңдеу кезеңінде сандық белгілердегі жоғалған мәндер медиана арқылы толтырылып, стандартты шкалаға келтірілді (орташа мәні 0, стандартты ауытқуы 1). Категориялық айнымалылардағы жоғалған мәндер ең жиі кездесетін категориямен ауыстырылып, One-Hot кодтау арқылы бинарлы форматқа түрлендірілді.

**Қолданылған модельдер.** Жұмыс барысында күрделілігі мен интерпретация деңгейімен ерекшеленетін машиналық оқытудың төрт моделі таңдалды:

Logistic Regression (LR) – белгілер арасындағы сызықтық қатынастарды қолданатын қарапайым және түсіндірілетін модель. Логистикалық регрессия моделі келесі параметрлермен іске асырылды:

- max\_iter = 1000 - оңтайландыру алгоритмінің толық конвергенциясын қамтамасыз ету үшін итерациялар саны арттырылды;

- class\_weight = 'balanced' - мақсатты айнымалыдағы ықтимал класс теңсіздігін өтеу мақсатында қолданылды;

Бұл параметрлер модельдің тұрақты оқытылуын және сирек кездесетін класты (депрессия деңгейі жоғары топ) дұрыс тануын жақсартуға бағытталған.

Random Forest (RF) – дәлдікті жақсарту үшін көптеген шешуші ағаштарды біріктіруге негізделген ансамбльдік әдіс. Random Forest алгоритмі келесі гиперпараметрлермен оқытылды:

- n\_estimators = 200 – ансамбльдегі ағаштар саны, модельдің дисперсиясын төмендету және

жалпылау қабілетін арттыру үшін таңдалды;

- `class_weight = 'balanced'` – деректердегі класс теңсіздігін ескеру үшін;

XGBoost - жоғары жылдамдық пен тұрақтылықпен сипатталатын градиентті күшейтудің жетілдірілген нұсқасы. XGBoost моделі төмендегі параметрлермен іске асырылды:

- `objective = "binary:logistic"` – бинарлы классификация міндетіне сәйкес;

- `eval_metric = "logloss"` – ықтималдықтық қателікті бағалау үшін;

- `num_boost_round = 200` – градиентті бустинг итерацияларының саны;

XGBoost моделі DMatrix құрылымы арқылы оқытылды, бұл жадты тиімді пайдаланып, есептеу жылдамдығын арттыруға мүмкіндік берді.

Neural Network (NN) – күрделі сызықтық емес тәуелділіктерді модельдеуге қабілетті. Көпқабатты перцептрон (MLP) моделі келесі архитектурада іске асырылды:

- `hidden_layer_sizes = (64, 32)` – екі жасырын қабаттан тұратын архитектура, күрделі бейсызық тәуелділіктерді үйрену үшін;

- `max_iter = 500` – оқыту процесінің толық аяқталуын қамтамасыз ету үшін;

**Оқыту және тексеру.** Деректер 70/30 қатынасында оқыту және сынақ үлгілеріне бөлінді.

Модельдердің сапасы Accuracy, Precision, Recall, F1-score және ROC-

AUC классикалық көрсеткіштері арқылы бағаланды. Бұл тәсіл әртүрлі алгоритмдердің өнімділігін объективті салыстыруға мүмкіндік берді.

Модельдердің интерпретациясы

Интерпретацияны талдау үшін SHAP (SHapley Additive Explanations) әдісі қолданылды, бұл әр белгінің модельдің қорытынды болжамына қосқан үлесін сандық бағалауға мүмкіндік береді.

Жаһандық талдау (summary plot) нәтижеге әсер ететін ең маңызды факторларды көрсетті.

Жеке түсініктемелер (force plot) қандай белгілер белгілі бір пациент үшін қауіпті болжауға шешуші әсер еткенін көрсетті.

**Зерттеу нәтижелері.** Зерттеу нәтижесінде 2-кестеге сәйкес мәндер алынды. Нәтижелерге сәйкес, XGBoost моделі барлық көрсеткіштер бойынша ең жоғары өнімділікті көрсетті: Accuracy, Precision, Recall, F1-score және ROC-AUC мәндері бірдей 1.0 болып, толық дұрыс классификацияны қамтамасыз етті.

XGBoost моделі ең сенімді және жоғары дәлдікпен жұмыс істейтін модель ретінде таңдалды. Барлық модельдердің ROC-AUC көрсеткіштері өте жоғары болғандықтан, деректерді бөлуді дұрыс жүргізу және модельдердің дискриминациялық қабілеті жақсы екенін көрсетеді. Бұл нәтижелер машиналық оқыту модельдерінің клиникалық немесе психикалық денсаулыққа қатысты деректерде қолдануға жарамдылығын растайды және зерттеудің ғылыми негізділігін арттырады.

## Кесте 2

Модельдердің сапасын бағалау көрсеткіштері

Model	Accuracy	Precision	Recall	F1	ROC-AUC
LogisticRegression	0.999359	0.993197	0.996101	0.994647	0.999983
RandomForest	0.999942	0.999026	1.000000	0.999513	1.000000
NeuralNetwork	0.999359	0.989392	1.000000	0.994668	0.999999
XGBoost	1.000000	1.000000	1.000000	1.000000	1.000000

**SHAP талдау және интерпретация.** Зерттеу нәтижелеріне сәйкес, XGBoost моделі барлық негізгі бағалау көрсеткіштері бойынша (Accuracy, Precision, Recall, F1-score және ROC-AUC) ең жоғары мәндерге ие болды. Бұл модельдің жалпылау қабілетінің жоғары екенін және деректер құрылымын тиімді

игергенін көрсетеді. Сондықтан интерпретация ең сенімді және тұрақты модельге қолданылды.

**Summary plot** модельдің депрессия ықтималдығын болжау кезінде қандай белгілер (features) ең маңызды рөл атқарғанын және олардың әсер ету бағытын көрсетеді (1-сурет).



Сурет 1 – Summary plot нәтижесі

1-суретте:

- Y осі – модель үшін маңыздылығы бойынша сұрыпталған белгілер
- X осі (SHAP value) – белгінің модель шешіміне әсері

Оң мәндер → депрессия ықтималдығын арттырады

Теріс мәндер → депрессия ықтималдығын төмендетеді

Түстер шкаласы:

- Қызыл – белгінің жоғары мәні
- Көк – белгінің төмен мәні

SHAP summary plot нәтижелері модель үшін ең маңызды белгілер ретінде депрессивті бұзылыстардың таралуымен байланысты көрсеткіштерді анықтады. Атап айтқанда, жынысына қарамастан депрессивті бұзылыстардың жас бойынша стандартталған таралуы, сондай-ақ ерлер мен әйелдер арасындағы депрессия көрсеткіштері модель шешіміне ең жоғары әсер ететін факторлар болып табылды. Бұл белгілердің жоғары мәндері депрессия

ықтималдығын арттыру бағытымен байланысты екені анықталды.

Сонымен қатар, шизофренияның таралуы және психикалық бұзылыстарға қатысты DALYs (Disability-Adjusted Life Years) көрсеткіштері де модель болжамына елеулі әсер етті. Бұл факторлардың оң SHAP мәндері олардың депрессия тәуекелінің артуымен өзара байланысын көрсетеді, яғни ауыр психикалық аурулардың жиілігі артқан сайын депрессияның ықтималдығы да жоғарылайды.

Ал мазасыздық, биполярлық бұзылыс, алкоголь және есірткі қолданумен байланысты бұзылыстардың әсері салыстырмалы түрде төмен болды. Бұл көрсеткіштер модельде қосымша факторлар ретінде көрініс тауып, негізгі анықтаушы белгілермен салыстырғанда әлсіз әсер етті.

SHAP мәндерінің таралуы белгілердің әсері барлық бақылаулар

үшін біркелкі емес екенін көрсетті. Кейбір аймақтарда бірдей белгілер депрессия ықтималдығын арттырса, басқа жағдайларда олардың әсері

әлсіз немесе нейтралды болды. Бұл деректердің гетерогенділігін және модельдің күрделі өзара байланыстарды ескеретінін дәлелдейді.



Сурет 2 – Force plot нәтижесі

Жеке бейнелеу (force plot) модельді әрбір нақты пациент үшін жоғары немесе төмен тәуекел шешіміне әкелетін нақты факторларды көрсетті, бұл модельді клиникалық тәжірибеде пайдалырақ етеді (2-сурет).

Қызыл көрсеткілер болжамды мәнді жоғарылататын белгілерді, ал көк көрсеткілер оны төмендететін белгілерді көрсетеді.

**Қорытынды.** Зерттеу барысында деректерді сақтау, өңдеу және талдау кезінде:

- тек статистикалық және модельдік талдау жүргізілді;
- жеке немесе сезімтал ақпаратты қайта құруға мүмкіндік беретін әдістер қолданылған жоқ;
- алынған нәтижелер тек ғылыми және қоғамдық денсаулық сақтау саласындағы талдамалық мақсаттарда пайдаланылды.

Машиналық оқыту модельдерінің нәтижелері диагностикалық немесе клиникалық шешім қабылдау құралы

ретінде емес, керісінше қауіп факторларын түсіндіруге және популяциялық деңгейдегі үрдістерді талдауға арналған зерттеу құралы ретінде қарастырылды.

SHAP талдауымен толықтырылған машиналық оқытудың интерпретацияланған модельдері мамандардың сенімін арттыруға және болжау жүйелерінің клиникалық қолданылуын жақсартуға мүмкіндік береді. Дәлдік пен түсіндірімділік арасындағы тепе-теңдікті қамтамасыз ететін модельдерді қолдану, сондай-ақ нәтижелерді түсіндіру механизмдерін клиникалық жүйелердің пайдаланушы интерфейстеріне қосу ұсынылады.

Болашақта деректер жиынтығын кеңейту (мысалы, генетикалық, мінез-құлық және әлеуметтік факторларды қосу), көп орталықты зерттеулер жүргізу және психиатриялық тәжірибеде түсіндірілетін AI-нің ұзақ мерзімді шешім қабылдауға әсерін зерттеу ұсынылады.

#### Әдебиеттер тізімі

1. Среди казахстанцев растёт распространение депрессии [Электронный ресурс] // Forbes.kz. – Режим доступа: [https://forbes.kz/articles/sredi\\_kazahstantsev\\_rastet\\_rasprostranenie\\_depressii](https://forbes.kz/articles/sredi_kazahstantsev_rastet_rasprostranenie_depressii). – Дата доступа: 30.10.2025.
2. Battineni G., Mittal M., Chintalapudi N., редакторы. Computational Methods in Psychiatry. – Springer, 2022. – 350 с.
3. Lundberg S.M., Lee S.-I. A unified approach to interpreting model predictions (SHAP). – 2017. – URL: <https://arxiv.org/abs/1705.07874>
4. Chattopadhyay A., et al. Neural network interpretability for mental health prediction // Frontiers in Psychiatry. – 2020. – Vol. 11. – Article 579. – DOI: 10.3389/fpsy.2020.00579.

5. Zhang Z., et al. Explainable artificial intelligence for suicide risk prediction: A systematic review // Journal of Affective Disorders. – 2023. – Vol. 332. – P. 82–95. – DOI: 10.1016/j.jad.2023.01.015.

I.A.Олжатай, Ж.К.Тасжурекова, М.А.Ахметжанов  
Таразский университет имени М.Х. Дулати, Тараз, Казахстан

## АНАЛИЗ ПОКАЗАТЕЛЕЙ ПСИХИЧЕСКОГО ЗДОРОВЬЯ: ИСПОЛЬЗОВАНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ИНТЕРПРЕТАЦИИ ПРОГНОЗА ДЕПРЕССИИ

**Аннотация.** В этой исследовательской работе исследуется теоретическая и прикладная важность использования методов искусственного интеллекта, которые объясняются при анализе показателей психического здоровья. Основная цель исследования-провести сравнительную оценку как предполагаемой эффективности, так и интерпретации нескольких моделей машинного обучения с целью повышения общего качества принятия клинических решений. Для этого были выбраны широко используемые алгоритмы машинного обучения, включая логистическую регрессию, случайный лес, методы градиентного усиления и модели нейронных сетей. Метод SHAP использовался для определения того, как модели генерируют прогнозы, и для определения наиболее влиятельных переменных. Этот подход позволяет количественно определить вклад каждой характеристики в конечный результат модели и предоставляет механизм для интерпретации внутренней логики алгоритмических предположений. Разложив результаты модели на индивидуальные описательные эффекты, SHAP способствует открытому пониманию сложных прогнозных систем. Эмпирические данные показывают, что модели, характеризующиеся более сложной архитектурой, в частности нейронные сети, достигают относительно высокого уровня точности прогнозирования. Кроме того, эти модели демонстрируют ограниченную интерпретацию, что затрудняет интерпретацию их логики прогнозирования. Другими словами, такие алгоритмы могут давать очень точные результаты, но их процесс принятия решений часто остается неясным для клинических специалистов. Напротив, ансамблевые алгоритмы, такие как случайный лес и градиентное усиление, показали благоприятный баланс между эффективностью прогнозирования и прозрачностью модели. Эти методы обеспечили надежные результаты при применении к наборам клинических данных, что позволило осмысленно объяснить влияние различных переменных на прогнозы. Анализ также показывает, что интеграция интерпретируемых методов машинного обучения в анализ медицинских данных может повысить доверие психиатров и медицинских работников к инструментам поддержки принятия решений на основе искусственного интеллекта. Поэтому повышение прозрачности прогнозных моделей является важным шагом на пути ответственного и эффективного внедрения технологий искусственного интеллекта в клиническую практику.

**Ключевые слова:** машинное обучение, ИНТЕРПРЕТАЦИЯ, SHAP, ДЕПРЕССИЯ, XGBOOST, нейронные сети, логистическая РЕГРЕССИЯ.

I.A. Olzhatai, Zh.K. Tashurekova, M.A. Akhmetzhanov  
M.Kh. Dulaty Taraz University, Taraz, Kazakstan

## MENTAL HEALTH INDICATORS ANALYSIS: APPLICATION OF MACHINE LEARNING FOR DEPRESSION PREDICTION INTERPRETATION

**Abstract.** This research paper explores the theoretical and applied importance of using artificial intelligence methods to analyze mental health indicators. The main objective of the study is to conduct a comparative evaluation of the effectiveness and interpretation of several machine learning models in order to improve the overall quality of clinical decision-making. To achieve this, widely used machine learning algorithms, including logistic regression, random

forest, gradient boosting methods, and neural network models, have been selected. The SHAP method has been used to determine how models generate predictions and to identify the most influential variables. This approach allows for the quantification of each feature's contribution to the model's final outcome and provides a mechanism for interpreting the internal logic of algorithmic assumptions. By decomposing the model's results into individual descriptive effects, SHAP facilitates an open understanding of complex predictive systems. Empirical evidence suggests that models with more complex architectures, particularly neural networks, achieve relatively high levels of prediction accuracy. In addition, these models exhibit limited interpretability, making it difficult to understand their prediction logic. In other words, while these algorithms may produce highly accurate results, their decision-making process often remains unclear to clinical professionals. In contrast, ensemble algorithms such as random forests and gradient boosting have shown a favorable balance between predictive performance and model transparency. These methods have provided reliable results when applied to clinical data sets, allowing for meaningful explanations of the impact of various variables on predictions. The analysis also shows that integrating interpretable machine learning methods into medical data analysis can increase the trust of psychiatrists and healthcare professionals in AI-based decision support tools. Therefore, improving the transparency of predictive models is an important step towards the responsible and effective implementation of AI technologies in clinical practice.

Keywords: machine learning, interpretation, SHAP, depression, XGBOOST, neural networks, logistic regression.

#### References

1. Battineni G., Mittal M., Chintalapudi N., редакторы. Computational Methods in Psychiatry. – Springer, 2022. – 350 с.
2. Lundberg S.M., Lee S.-I. A unified approach to interpreting model predictions (SHAP). – 2017. – URL: <https://arxiv.org/abs/1705.07874>.
3. Chattopadhyay A., et al. Neural network interpretability for mental health prediction // Frontiers in Psychiatry. – 2020. – Vol. 11. – Article 579. – DOI: 10.3389/fpsy.2020.00579.
4. Zhang Z., et al. Explainable artificial intelligence for suicide risk prediction: A systematic review // Journal of Affective Disorders. – 2023. – Vol. 332. – P. 82–95. – DOI: 10.1016/j.jad.2023.01.015.

15.02.2026 ж. баспаға түсті  
30.03.2026 ж. басыл шығаруға қабылданды

*Мақалаға сілтеме:*



Copyright: © 2024 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY NC) license (<https://creativecommons.org/licenses/by-nc/4.0/>).