



ӨОЖ 004.89

ҒТАХА 28.23.25

https://doi.org/10.53364/24138614_2026_41_2_21

Б.Е.Айдәулет¹, Ж.Д.Изтаев^{1*}, П.А.Кожобекова¹, К.А.Утебаев¹

¹М.Әуезов атындағы Оңтүстік Қазақстан университеті, Шымкент, Қазақстан

*E-mail: zhalgasbek71@mail.ru

ТҮСІНДІРЕЛЕТІН ЖАСАНДЫ ИНТЕЛЛЕКТ АРҚЫЛЫ БІЛІМ БЕРУДЕГІ ҚҰРЫЛЫМДЫҚ САУАЛНАМА ДЕРЕКТЕРІН ТАЛДАУ ҮШІН МАШИНАЛЫҚ ОҚЫТУ МОДЕЛЬДЕРІН САЛЫСТЫРМАЛЫ БАҒАЛАУ

Аңдатпа. Құрылымдалған сауалнама деректерін талдауда машиналық оқыту модельдерін қолдану деректерге негізделген аналитикалық жүйелерді дамытуда маңызды бағыттардың бірі болып табылады. Алайда көптеген классификациялық алгоритмдер жоғары болжам дәлдігін көрсеткенімен, олардың шешім қабылдау логикасының жеткіліксіз түсіндірілетіндігі практикалық қолданылуын шектейді. Осыған байланысты құрылымдалған деректерді талдауда өнімділік пен интерпретациялану деңгейін бірлесе бағалау өзекті мәселе болып табылады. Бұл зерттеуде құрылымдалған сауалнама деректері негізінде классикалық машиналық оқыту классификаторларының салыстырмалы талдауы жүргізілді. Зерттеу барысында логистикалық регрессия, k -жақын көршілер (kNN), шешім ағашы және Gaussian Naive Bayes модельдері қарастырылды. Модельдер стратификацияланған оқыту және тестілеу жиынтықтарында оқытылып, олардың өнімділігі Accuracy, Precision, Recall, F1-score, ROC-AUC және LogLoss көрсеткіштері арқылы бағаланды. Модельдердің тек болжам дәлдігі ғана емес, шешім қабылдау логикасы да талданды. Осы мақсатта түсіндірілетін жасанды интеллект әдісі ретінде SHAP (Shapley Additive Explanations) қолданылды. SHAP негізіндегі жаһандық және локальды интерпретация нәтижелері модель болжамдары бірнеше негізгі белгілердің жиынтық әсеріне негізделетінін көрсетті. Эксперименттік нәтижелер логистикалық регрессия моделінің өнімділік пен ықтималдықтық калибрлеу тұрғысынан ең теңгерімді және сенімді әдіс екенін көрсетті. Сонымен қатар, түсіндірмелі талдау модель шешімдерінің деректердегі мағыналы факторларға сүйеніп қабылданатынын дәлелдеді. Ұсынылған нәтижелерді құрылымдалған деректерге негізделген аналитикалық және шешімдерді қолдау жүйелерін әзірлеуде қолдануға болады.

Түйін сөздер: машиналық оқыту, классификация, түсіндірілетін жасанды интеллект, құрылымдық сауалнама, логистикалық регрессия, шешім ағашы, kNN , Naive Bayes, SHAP.

Кіріспе.

Жоғары білім беру қызметіне жасанды интеллект технологияларын интеграциялау кезінде студенттердің үлгерімін, мінез-құлқы мен білім беру қызметінің сапасына қанағаттануын талдау маңызды бағыттардың бірі болып есептеледі. Бүгінде білім беру ұйымдары мыңдаған студенттің деректерін талдауды автоматтандыратын технологияларды қажет етіп отыр [1]. Осындай жағдайда жоғары оқу орындарындағы студенттердің пәндерге деген кері байланысын өңдеу де өзекті мәселелердің бірі. Кері байланыс жинау және оны

тиімді өңдеу курстың сапасын жақсартуға, тиімді білім беру бағдарламалары мен оқу жоспарларын әзірлеуге мүмкіндік береді. Бірақ бүгінге дейін көптеген жоғары оқу орындағы кері байланыс деректерін өңдеуде жасанды интеллект технологияларын енгізе алмай келеді [2].

Машиналық оқытудың заманауи әдістері студенттердің кері байланыс деректерін талдауға және заңдылықтарды анықтауға мүмкіндік береді. Логистикалық регрессия, кездейсоқ орман, тірек векторлық машиналар, градиентті күшейту және нейрондық желілер сияқты алгоритмдер студенттердің сауалнама деректері арқылы модель құрып, курстардың сапасы туралы деректердің заңдылықтарын анықтауға және қатерлерді алдын-ала болжауға мүмкіндік береді [3].

Машиналық оқытуға негізделген жіктеу әдістері құрылымдық сандық деректерді модельдеудегі тиімділігіне байланысты соңғы жылдары жан-жақты зерттелді. Классикалық бақыланатын оқыту алгоритмдері, соның ішінде логистикалық регрессия, шешім қабылдау ағаштары, кездейсоқ ормандар, тірек векторлық машиналар және ансамбльді оқыту әдістері олардың сенімділігіне, есептеу тиімділігіне және нақты әлем қолданбаларында интерпретациялануына байланысты кеңінен қолданылады [4].

Соңғы зерттеулерде машиналық оқыту модельдерінің интерпретациялануына, әсіресе шешімдерді қолдау мен аналитикалық жүйелерге көбірек көңіл бөлінді. Ашықтық пен сенімділікті арттыру үшін ерекшеліктердің маңыздылығын талдау және модельдік-агностикалық түсіндіру әдістері ұсынылды. Дегенмен, көптеген қолданыстағы жұмыстар бірдей эксперименттік жағдайларда классикалық алгоритмдерді жүйелі түрде салыстыруды қамтамасыз етпей, болжамды өнімділікке немесе оқшауланған интерпретацияға бағытталған [5].

Алайда қарастырылған зерттеулердің көпшілігі:

- модельдердің тек болжам дәлдігіне бағытталған;
- интерпретация мен өнімділікті бірге қарастырмайды;
- бірдей эксперименттік ортада бірнеше алгоритмді толық салыстырмайды [6].

Сонымен қатар, қолданбалы аналитикада сауалнамаларға негізделген құрылымдық деректер жиыны жиі кездесетініне қарамастан, мұндай деректер бойынша бірнеше жіктеу алгоритмдерін бағалайтын кешенді салыстырмалы зерттеулер шектеулі болып қала береді. Атап айтқанда, жеке белгілердің жіктеу нәтижелеріне әсері және олардың модельдік болжамдарға қосқан үлесі жиі талданбайды [7].

Осыған байланысты бұл зерттеу аталған олқылықтарды толтыруға бағытталған.

Бұл зерттеуде біз «Жасанды интеллект негіздері» курсын оқыған бірінші курс білім алушыларының деректерін зерттеу үшін бірқатар машиналық оқыту алгоритмдерін қолданамыз. Зерттеу барысында осы деректерді бірнеше алгоритмдер арқылы талдап, нәтижелерін салыстыру арқылы қай алгоритмнің білім берудің аналитикалық жүйелерінде қолдануға тиімді екенін және болжауға қандай факторлар әсер ететінін анықтаймыз.

Бұл зерттеудің ғылыми жаңалығы келесідей:

- 1) Құрылымдалған білім беру сауалнама деректерінде классикалық ML модельдерінің өнімділігі мен интерпретациялануын бір уақытта кешенді бағалау ұсынылды;
- 2) Модельдерді тек дәстүрлі метрикалар арқылы емес, ықтималдықтық калибрлеу (LogLoss) және XAI (SHAP) негізінде біріктірілген тәсілмен салыстыру жүзеге асырылды;
- 3) Модель таңдау кезінде сандық көрсеткіш (ассигасу) қана емес, шешімнің түсіндірілуі (explainability + calibration) маңызды екенін дәлелдейтін практикалық ұсыныс берілді.

Бұл зерттеу әртүрлі білім берудегі құрылымдық сауалнама деректерін талдау үшін машиналық оқыту алгоритмдерін қалай таңдауға болатынын көрсетеді және сол арқылы білім берудегі жасанды интеллект бағытына елеулі практикалық үлес қосады. Зерттеу нәтижелері білім беру бағытындағы аналитикалық жүйелерді әзірлеушілерге, деректерді

талдаушыларға, сондай-ақ жасанды интеллект негіздері курсы құрастырушыларға практикалық дәлелденген қорытындылар ұсынады.

Бұл зерттеу құрылымдық сауалнама деректер жинағында бірнеше классикалық машиналық оқыту алгоритмдерін жүйелі салыстырмалы бағалауды жүргізу арқылы осы шектеулерді жояды. Өнімділікті болжамды бағалаудан басқа, талдау аналитикалық шешімдерді қолдау жүйелерінде алгоритмді таңдау үшін практикалық түсініктер бере отырып, мүмкіндіктердің үлесі мен интерпретациялануына баса назар аударады.

Зерттеу материалдары мен әдістері.

Зерттелетін тапсырма құрылымдық сауалнама деректері негізінде бақыланатын екілік жіктеу мәселесі ретінде тұжырымдалған.

Деректер жиынтығы берілген $X \in \mathbb{R}^{n \times d}$ сандық белгілерден және екілік мақсатты айнымалыдан $y \in \{0,1\}$ тұрады. Мақсаты – жіктеу функциясын үйрену $f: X \rightarrow y$ бұл модельдердің интерпретациялануын сақтай отырып, классқа мүшелікті жоғары дәлдікпен болжайды.

Зерттеу құрылымдық зерттеуге негізделген жіктеу тапсырмалары үшін классикалық машиналық оқыту алгоритмдерінің тиімділігін бағалауға және нәтижелерді болжауға ықпал ететін ықпалды белгілерді ХАІ әдістері арқылы түсіндіруге бағытталған.

Бұл зерттеуде машиналық оқыту алгоритмдерін салыстыруға қолданылған деректер жинағы М.Әуезов атындағы Оңтүстік Қазақстан университеті білім алушыларының семестр соңындағы пән мен оқытушыға кері байланыс сауалнамасының жауаптарынан тұрады. Респонденттердің жалпы саны – 2125. Сауалнама 14 сұрақтан тұрады және ондағы 13 сұрақ 5 балдық Лайкерт шкаласы бойынша бағаланады (1 = өте төмен, 5 = өте жоғары). Сауалнаманың қорытынды сұрағы «Сіз осы оқытушының әрі қарай сабақ жүргізуін қалайсыз ба?». Бұл сұрақта респонденттер «Иә» немесе «Жоқ» жауаптарының біреуін таңдайды. Осы екілік жіктеу модельдерінің мақсатты айнымалысы ретінде қолданылады.

Мақсатты айнымалының таралуы деректер жиынтығында орташа деңгейде теңгерімсіз болып табылады: оң класс («Иә») 1343 студентті (63,2%), ал теріс класс («Жоқ») 782 студентті (36,8%) құрайды. Кластар арасындағы пропорцияны сақтау мақсатында стратификацияланған бөлу әдісі қолданылды. Нәтижесінде оқыту жиынтығына 1700 студент енгізілді, оның ішінде 1075-і «Иә», 625-і «Жоқ» класына жатады. Тестілеу жиынтығы 425 студенттен тұрады, олардың 268-і «Иә», 157-сі «Жоқ» класын құрайды. Бұл модельдердің әділ және салыстырмалы түрде бағалануына мүмкіндік береді.

Сипатталған деректер жиынтығы негізінде студенттердің қанағаттану деңгейін болжауға бағытталған машиналық оқыту модельдері құрастырылды. Зерттеу барысында төрт классикалық машиналық оқыту алгоритмі қолданылды: Decision Tree, Gaussian Naive Bayes, Logistic Regression және k-Nearest Neighbors.

Шешім ағашы (Decision Tree). Бинарлық жіктеу есебін шешу үшін Decision Tree классификаторы қолданылды. Кластар арасындағы теңгерімсіздікті ескеру мақсатында модельде `class_weight = "balanced"` параметрі қолданылды.

Наивті Байес (Naive Bayes). Gaussian Naive Bayes моделі сандық белгілерге негізделген базалық ықтималдық классификаторы ретінде қолданылды. Бұл әдіс салыстыру үшін эталондық модельдердің бірі ретінде қарастырылды.

Логистикалық регрессия. Масштабқа сезімталдығын ескере отырып, модельді оқыту алдында белгілер StandardScaler әдісі арқылы стандартталды және бұл қадам Pipeline құрылымына енгізілді. Кластар арасындағы теңгерімсіздікті ескеру үшін `class_weight = "balanced"` параметрі қолданылып, модель lbfgs шешушісімен (solver) және `max_iter = 2000` итерация шегімен оқытылды.

k-Жақын көршілер әдісі (k-Nearest Neighbors, kNN). kNN классификаторы қашықтыққа негізделген әдіс ретінде қолданылды. kNN алгоритмі қашықтықтарды есептеуге тәуелді болғандықтан, модельді оқыту алдында белгілер StandardScaler әдісі арқылы

стандартталды. Классификатор параметрлері ретінде $k = 5$, салмақтау тәсілі $weights = "distance"$, қашықтық метрикасы Minkowski ($p = 2$) таңдалды [8].

Машиналық оқыту модельдерінің тиімділігін жан-жақты және әділ бағалау мақсатында бірнеше статистикалық көрсеткіштер қолданылды. Әрбір метрика модельдің болжам жасау сапасының әртүрлі қырларын сипаттайды, сондықтан оларды бірге пайдалану модельдердің артықшылықтары мен кемшіліктерін толық ашуға мүмкіндік береді.

Accuracy (1) модель жасаған барлық болжамдардың ішіндегі дұрыс болжамдардың үлесін көрсетеді. Бұл көрсеткіш модельдің жалпы өнімділігін сипаттайды және келесі түрде анықталады:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

мұндағы:

- TP (True Positive) – дұрыс анықталған оң кластар,
- TN (True Negative) – дұрыс анықталған теріс кластар,
- FP (False Positive) – қате оң болжамдар,
- FN (False Negative) – қате теріс болжамдар.

Accuracy көрсеткіші деректер теңгерімді болған жағдайда пайдалы, алайда кластар теңгерімсіз болған кезде жалғыз метрика ретінде жеткіліксіз болуы мүмкін.

Precision көрсеткіші (2) модель оң класс деп болжаған нәтижелердің қаншасы шын мәнінде дұрыс екенін сипаттайды. Бұл метрика жалған оң нәтижелердің үлесін азайту маңызды болған жағдайда ерекше мәнге ие. Жоғары Precision мәні модельдің оң классқа жатқызуда қателеспейтінін білдіреді.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

Recall (3) – нақты оң кластардың модель тарапынан қаншасы дұрыс анықталғанын көрсетеді. Бұл көрсеткіш маңызды объектілерді өткізіп алмау қажет болған жағдайларда аса маңызды. Recall мәні жоғары болған сайын, модель оң кластарды толық қамти алады.

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

F1-score (4) – Precision мен Recall арасындағы үйлесімділікті сипаттайтын интегралды көрсеткіш. Бұл көрсеткіш кластар теңгерімсіз болған жағдайда модельдің жалпы сапасын бағалау үшін кеңінен қолданылады. Ол екі метриканың гармониялық орташа мәні ретінде есептеледі.

$$F1\ score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

ROC-AUC көрсеткіші (5) модельдің оң және теріс кластарды ажырату қабілетін бағалайды. Ол әртүрлі шекті мәндер (threshold) үшін дұрыс және жалған оң болжамдар арасындағы қатынасты сипаттайды. ROC-AUC көрсеткіші модельдің оң және теріс кластарды ажырату қабілетін сипаттайды және ROC қисығының астындағы аудан ретінде анықталады. Бұл көрсеткіш FPR мәні 0-ден 1-ге дейін өзгерген жағдайда TPR функциясының интегралы арқылы есептеледі.

$$ROC\ AUC = \int_0^1 TPR(FPR) d(FPR) \quad (5)$$

Мұндағы:

- TPR (True Positive Rate) – шынайы оң нәтижелер коэффициенті (Recall)
- FPR (False Positive Rate) – жалған оң нәтижелер коэффициенті

ROC-AUC мәні: 0.5 – кездейсоқ болжау, 1.0 – мінсіз ажырату қабілеті. Бұл метрика модельдің ықтималдықтық болжамдарының сапасын бағалау үшін қолданылады.

LogLoss метрикасы (6) модельдің ықтималдық негізіндегі болжамдарының дәлдігін өлшейді. Бұл көрсеткіш модельдің өз болжамдарына қаншалықты сенімді екенін көрсетеді. LogLoss мәні төмен болған сайын модельдің ықтималдықтық болжамдары шынайы деректерге жақын болады. Басқа метрикалардан айырмашылығы, LogLoss қателіктерді қатты жазалайды, сондықтан ол модель сапасын терең бағалауға мүмкіндік береді.

$$\text{LogLoss} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (6)$$

Мұндағы:

- N – бақылаулар (үлгілер) саны;
- y_i – нақты класс мәні, $y_i = \begin{cases} 1, & \text{егер объект оң классқа жатса} \\ 0, & \text{егер объект теріс классқа жатса} \end{cases}$
- p_i – модельдің i -ші объект үшін оң классқа тиесілі болу ықтималдығы.

Зерттеуде көрсетілген барлық метрикалар бірге қолданылды, себебі бір ғана көрсеткіш модельдің сапасын толық сипаттай алмайды. Accuracy жалпы өнімділікті көрсетсе, Precision мен Recall қателіктердің сипатын ашады, F1-score олардың теңгерімін бағалайды, ROC-AUC класстарды ажырату қабілетін сипаттайды, ал LogLoss ықтималдықтық болжамдардың сапасын көрсетеді [9].

Түсіндірілетін AI (XAI) әдістері. Модельдің ашықтығы мен интерпретациясын арттыру үшін SHAP (Shapley Additive Explanations) қолданылды. SHAP мәндері кооперативтік ойын теориясының принциптеріне негізделген мүмкіндіктер үлестерін сандық бағалаудың бірыңғай негізін қамтамасыз етеді.

Талдау мыналарға бағытталған:

- Жаһандық ерекшеліктердің маңыздылығы, барлық болжамдар бойынша ең ықпалды белгілерді анықтау.
- Жергілікті түсініктемелер, жеке модельдік шешімдерді түсіндіру.
- Мүмкіндік мәндерінің болжау нәтижелеріне қалай әсер ететінін көрсететін мүмкіндік әсерінің бағыттылығы.

Өнімділікті болжамды бағалауды SHAP негізіндегі интерпретациямен интеграциялау модельдің мінез-құлқын да, мүмкіндік деңгейіндегі әсерді де тереңірек түсінуге мүмкіндік береді [10].

Барлық эксперименттер Python 3.13 көмегімен жүргізілді. Келесі кітапханалар пайдаланылды: scikit-learn, pandas, numpy, matplotlib.

Зерттеу пайплайны келесі кезеңдерден тұрады:

- 1) деректерді алдын ала өңдеу (стандарттау, стратификация);
- 2) модельдерді оқыту;
- 3) болжам жасау;
- 4) бағалау метрикаларын есептеу;
- 5) SHAP негізіндегі интерпретация.

Қолданылған модельдердің барлығы бірдей оқыту және тестілеу жиынтығында және бірдей алдын-ала өңдеу жағдайында құрылды, бұл эксперимент нәтижесінде модельдерді әділ салыстыруды қамтамасыз етеді.

Нәтижелер және оларды талқылау.

Бұл бөлімде студенттердің оқытушымен әрі қарай оқуды жалғастыру ниетін болжау үшін қолданылған машиналық оқыту модельдерінің эксперименттік нәтижелері ұсынылады.

Жеке модельдердің нәтижелері. Decision Tree моделі тест жиынында орташа өнімділік көрсетті: Accuracy = 0.744 және F1-score = 0.793. ROC-AUC мәні 0.766, яғни модельдің класстарды ажырату қабілеті шектеулі деңгейде. Модельдің интерпретациялануы жоғары болғанымен, ықтималдықтық болжам сапасы төмен екенін LogLoss = 6.803 мәні

көрсетеді, бұл шешім ағашының ықтималдықтарды калибрлеуде тұрақсыз болуы мүмкін екенін білдіреді.

Gaussian Naive Bayes Decision Tree-мен салыстырғанда жақсырақ нәтижелерге қол жеткізді: Accuracy = 0.837, Precision = 0.857, Recall = 0.889, F1-score = 0.873. Сонымен қатар ROC-AUC көрсеткіші 0.847, бұл модельдің ажырату қабілетінің салыстырмалы түрде жоғары екенін көрсетеді. Дегенмен, LogLoss = 1.895 Logistic Regression-ге қарағанда жоғары, яғни ықтималдықтық болжам дәлдігі бойынша әлсіздеу.

Logistic Regression моделінде Accuracy = 0.861 және F1-score = 0.897. Бұл модельдің Recall = 0.963 мәні ең жоғары болып, оң класты анықтауда сезімталдығы басым екенін білдіреді. ROC-AUC 0.806 болғанымен, LogLoss = 0.442 мәнінің ең төмен болуы модельдің ықтималдықтық болжамдарының неғұрлым сенімді және жақсы калибрленгенін көрсетеді.


k-Nearest Neighbors (kNN) классификаторы тест жиынында орташа өнімділік көрсетті: Accuracy = 0.744 және F1-score = 0.793. Precision (0.808) және Recall (0.778) мәндерінің теңгерімді болуы модельдің жалған оң және жалған теріс қателіктер арасында айқын артықшылыққа ие еместігін көрсетеді. ROC-AUC көрсеткіші 0.831, бұл kNN моделінің кластарды ажырату қабілеті Decision Tree және логистикалық регрессия моделдеріне қарағанда жоғары екенін білдіреді. Алайда LogLoss = 2.753 мәнінің салыстырмалы түрде жоғары болуы ықтималдықтық болжамдардың тұрақсыз екенін және модельдің confidence calibration деңгейінің жеткіліксіз екенін көрсетеді. Барлық әдістер бойынша бағалау метрикаларының нәтижелері 1-кестеде көрсетілген.

Кесте 1 – Қарастырылған әдістер бойынша бағалау метрикаларының көрсеткіштері

Әдіс	Accuracy	Precision	Recall	F1-score	ROC AUC	LogLoss
Decision Tree	0.744	0.808	0.778	0.793	0.766	6.803
Naive Bayes	0.837	0.857	0.889	0.873	0.847	1.895
Logistic Regression	0.861	0.839	0.963	0.897	0.806	0.442
kNN	0.744	0.808	0.778	0.793	0.831	2.753


Эксперименттік нәтижелерді интерпретациялау және модельдердің мінез-құлқын түсіндіру мақсатында қателер құрылымын талдауға арналған Confusion Matrix және модельдердің ажырату қабілетін бағалауға арналған ROC қисықтары арқылы нәтижелерді визуализациялау жүргізілді.

2-суреттегі confusion matrix талдауы модельдердің қателер құрылымын (false positives және false negatives) зерттеуге мүмкіндік береді. Атап айтқанда, Logistic Regression моделі оң класты анықтауда жоғары сезімталдық көрсетті (Recall = 0.963), бұл оның жалған теріс қателерді азайтатынын білдіреді. Бұл нәтиже модельдің жоғары F1-score және төмен LogLoss мәндерімен үйлесіп, оның шешім шегінің тұрақтылығын растайды.



Сурет 2 – Модель нәтижелері бойынша шатасу матрицасы

ROC қисықтары Decision Tree, Gaussian Naive Bayes, Logistic Regression және k-Nearest Neighbors модельдерінің әртүрлі шекті мәндер кезінде шынайы оң нәтижелер коэффициенті (TPR) мен жалған оң нәтижелер коэффициенті (FPR) арасындағы тәуелділікті көрсетеді. Кескіндегі диагональ сызық кездейсоқ болжау деңгейін білдіреді. 3-суретте көрсетілген ROC қисықтары модельдердің кластарды ажырату қабілетін көрнекі түрде салыстыруға мүмкіндік береді [11].



Сурет 3 – Әр модель үшін ROC қисықтары

Gaussian Naive Bayes және kNN модельдері ROC кеңістігінде диагональ сызықтан айқын жоғары орналасып, салыстырмалы түрде жақсы ажырату қабілетін көрсетеді.


Decision Tree моделінің ROC қисығы диагональдан жоғары болғанымен, оның қисығының бастапқы бөлігінде TPR өсімі баяу, бұл төмен FPR аймағында модельдің сезімталдығы шектеулі екенін білдіреді.

Logistic Regression моделінің ROC қисығы бірқалыпты өсіп, орташа ROC-AUC мәніне сәйкес келетін тұрақты ажырату қабілетін көрсетеді. ROC кеңістігінде кейбір модельдерге қарағанда жоғарырақ қисық көрсетпегенімен, Logistic Regression моделі F1-score және LogLoss метрикалары бойынша басымдық көрсетті, бұл ықтималдықтық болжамдардың жақсы калибрленгенін және шешім шегінің практикалық тұрғыдан тиімді екенін көрсетеді. Бұл визуализация бір ғана ROC-AUC көрсеткішіне сүйеніп модель таңдаудың жеткіліксіз екенін және ажырату қабілеті мен ықтималдықтық болжамдардың сенімділігі арасында trade-off бар екенін айқын көрсетеді [12].

Модельдердің өнімділігін 6 метрика арқылы кешенді бағалау нәтижелері олардың келесі ретпен орналасатынын көрсетті: Decision Tree → kNN → Naive Bayes → Logistic Regression.

Бұл нәтиже қарапайым ережелік және instance-based әдістердің (Decision Tree және kNN) құрылымдалған сауалнама деректерінде шектеулі тиімділік көрсеткенін білдіреді. Gaussian Naive Bayes ықтималдықтық модель ретінде салыстырмалы түрде тұрақты нәтиже көрсетті, алайда белгілер арасындағы тәуелділіктер оның өнімділігін шектеді. Ал Logistic Regression жоғары F1-score және ең төмен LogLoss мәні арқылы қарастырылған модельдердің ішінде ең теңгерімді және сенімді модель ретінде анықталды. Осы нәтижелерге сүйене отырып, логистикалық регрессия әрі қарай талдау мен түсіндірудің негізгі моделі ретінде таңдалды.

4-суретте логистикалық регрессия моделі үшін алынған SHAP summary plot көрсетілген. Бұл визуализация әр белгінің модель болжамына қосқан үлесін және әсер ету бағытын бір уақытта көрсетеді. Түстер белгілер мәндерінің жоғары (қызыл) немесе төмен (көк) деңгейін, ал ось бойындағы орналасу SHAP мәндерінің оң немесе теріс әсерін білдіреді [13].




Сурет 4 –SHAP summary plot

SHAP summary plot нәтижелері бойынша Q7, Q6 және Q13 белгілері модель болжамына ең үлкен әсер ететін факторлар ретінде анықталды. Бұл белгілердің жоғары мәндері оң класстың ықтималдығын арттырып, ал төмен мәндері кері әсер көрсетеді. Төмен ранкті белгілер (мысалы, Q3 және Q4) модель шешіміне шектеулі ықпал етеді. Бұдан модельдің болжамдары бірнеше критерийдің кешенді әсеріне негізделетінін және жеке сұрақтардың әсері деректер контекстіне байланысты өзгеруі мүмкін екенін байқауға болады.

Белгілердің жаһандық маңыздылығы $\text{mean}(|\text{SHAP}|)$ мәндері бойынша есептелді. Нәтижелерге сәйкес, Q7 (0.57) ең маңызды фактор болып табылады, одан кейін Q6 (0.51) және Q13 (0.48) белгілері орналасқан. Бұл белгілер модель болжамына ең үлкен орташа үлес қосып, шешім қабылдау логикасының негізгі драйверлері ретінде ерекшеленеді. Орташа деңгейдегі маңыздылыққа Q9, Q12 және Q3 белгілері ие, ал Q5, 11 және Q4 белгілерінің үлесі салыстырмалы түрде төмен. Бұл талдау модельдің болжамдары бір ғана көрсеткішке емес, бірнеше белгінің жиынтық әсеріне негізделетінін көрсетеді.

5-суретте жеке объект үшін алынған SHAP waterfall plot көрсетілген. Бұл визуализация нақты бір бақылау үшін модельдің базалық мәнінен бастап соңғы болжамға дейінгі шешім қабылдау жолын бейнелейді.

Нәтижелер көрсеткендей, кейбір белгілер (мысалы, Q6 және Q5) оң бағытта әсер етіп, модель болжамын оң класқа қарай жылжытса, басқа белгілер (Q8 және Q11) кері бағытта әсер етіп, болжамды төмендетеді. Бұл локальды талдау модельдің шешімдері жеке студенттердің жауаптарына тәуелді түрде өзгертетінін және модельдің интерпретациялану деңгейінің жоғары екенін дәлелдейді [14].



Сурет 5 – SHAP waterfall plot

Жүргізілген SHAP негізіндегі түсіндірмелі талдау логистикалық регрессия моделінің интерпретациялану мүмкіндігі жоғары екенін және оның шешімдері деректердегі маңызды белгілерге сүйеніп қабылданатынын көрсетті. Корреляциялық талдау белгілер арасындағы тәуелділіктерді анықтаса, SHAP әдісі әр белгінің модель болжамына қосқан нақты үлесін ашып көрсетті.

Бұл нәтижелер Explainable AI тәсілдерінің құрылымдалған сауалнама деректерін талдауда тиімді екенін және алынған болжамдардың сенімді әрі түсіндірілетін екенін көрсетеді. Бұл нәтижелер модельдің шешім қабылдауы кездейсоқ емес, деректердегі мағыналы паттерндерге негізделгенін көрсетеді, яғни модель ХАІ талаптарына сәйкес келеді [15].

Модельдердің салыстырмалы өнімділігі. Зерттеу нәтижелері төрт классификациялық модельдің өнімділігі арасында айқын айырмашылық бар екенін көрсетті. Логистикалық регрессия моделі ең теңгерімді және сенімді нәтижелерді көрсетті, бұл оның жоғары F1-score және ең төмен LogLoss мәндерімен сипатталады. Бұл модель сызықтық тәуелділіктерді тиімді игеріп, ықтималдықтық болжамдарды жақсы калибрлей алатынын көрсетті.

k-Nearest Neighbors (kNN) моделі кейбір көрсеткіштер бойынша қанағаттанарлық нәтиже көрсеткенімен, оның жалпы өнімділігі логистикалық регрессиямен салыстырғанда төмен болды. kNN әдісінің нәтижелері деректер кеңістігінде айқын кластерлік құрылымның болмауына және қашықтыққа негізделген тәсілдің шуға сезімталдығына байланысты тұрақсыздық көрсетті.

Decision Tree моделі интерпретациялануы жоғары болғанымен, оның модельдік күрделілігінің шектеулі болуы кейбір күрделі үлгілерді толық қамтуға мүмкіндік бермеді. Ал Naive Bayes моделі белгілер арасындағы тәуелсіздік болжамына байланысты ең төмен нәтижелерді көрсетті, бірақ оның есептеу тұрғысынан қарапайымдылығы оны базалық салыстыру әдісі ретінде қолдануға мүмкіндік береді.

Бағалау метрикалары тұрғысынан талдау. Модельдердің өнімділігі бірнеше метрика арқылы бағаланғаны нәтижелердің объективтілігін арттырды. F1-score және LogLoss метрикалары тұрғысынан логистикалық регрессия моделі айқын басымдық көрсетті, бұл

оның жалған оң және жалған теріс қателіктер арасындағы оңтайлы тепе-теңдікті сақтайтынын білдіреді.

ROC-AUC көрсеткіштері логистикалық регрессия мен kNN модельдерінің кластарды ажырату қабілетінің жеткілікті екенін көрсеткенімен, ROC-AUC мәндерінің өздігінен модель сапасын толық сипаттай алмайтыны анықталды. Бұл LogLoss және F1-score сияқты метрикалармен бірге қарастырғанда ғана модельдің практикалық тиімділігі дұрыс бағаланатынын көрсетті.

Түсіндірмелі (XAI) талдау. SHAP негізіндегі түсіндірмелі талдау модельдердің шешім қабылдау логикасын терең түсінуге мүмкіндік берді. Логистикалық регрессия моделі үшін бірнеше негізгі белгілердің (Q1–Q13 ішінен) модель болжамына елеулі әсер ететіні анықталды. Бұл модельдің шешімдері деректердегі мағыналы белгілерге сүйенетінін және интерпретациялану деңгейінің жоғары екенін көрсетті.

Decision Tree моделінде белгілер арасындағы өзара әрекеттесудің әлсіздігі оның құрылымдық қарапайымдылығымен және тереңдіктің шектелуімен түсіндіріледі. Бұл интерпретациялануы жоғары, бірақ икемділігі төмен модельдердің жалпы ерекшелігін көрсетеді.

Зерттеудің шектеулері. Зерттеудің бірқатар шектеулері бар. Біріншіден, деректер бір ғана университет аясында жиналған, бұл нәтижелердің жалпыламалығын шектейді. Екіншіден, деректер студенттердің субъективті бағаларына негізделген. Үшіншіден, деректер көлемінің салыстырмалы түрде шағын болуы күрделі терең оқыту модельдерін қолдануға мүмкіндік бермеді. Себебі қазақстандық білім беру ұйымдары үшін білім алушылардың анағұрлым көп емес санында тек үлкен көлемді деректермен жұмыс істей алатын модельдерді пайдалану зерттеу нәтижелерінің практикалық құндылығын шектейді деп есептелді.

Дегенмен, талқылау нәтижелері деректер құрылымына сәйкес дұрыс таңдалған машиналық оқыту әдістері білім беру сапасын болжауда жоғары тиімділік көрсете алатынын дәлелдеді. Логистикалық регрессия моделі ең сенімді және интерпретацияланатын әдіс ретінде ерекшеленді, ал басқа модельдер салыстырмалы немесе базалық әдістер ретінде қолданылуы мүмкін.

Қорытынды.

Бұл құрылымдық сауалнама деректерін қолданып классификацияны болжау үшін машиналық оқыту әдістерін қолданудың тиімділігі қарастырылды. Зерттеу барысында студенттердің сауалнама деректеріне негізделген құрылымдалған деректер жиынтығы пайдаланылып, бірнеше классикалық классификациялық модельдер салыстырмалы түрде талданды.

Эксперименттік нәтижелер көрсеткендей, қарастырылған модельдердің өнімділігі айтарлықтай ерекшеленеді. Логистикалық регрессия моделі ең теңгерімді және сенімді нәтиже көрсетіп, жоғары F1-score және ең төмен LogLoss мәндері арқылы зерттеудегі ең тиімді әдіс ретінде анықталды. Бұл модель ықтималдықтық болжамдарды жақсы калибрлей алатынын және құрылымдалған сауалнама деректеріндегі сызықтық тәуелділіктерді тиімді игеретінін көрсетті.

kNN моделі кейбір көрсеткіштер бойынша қанағаттанарлық нәтиже көрсеткенімен, оның жалпы өнімділігі логистикалық регрессиямен салыстырғанда төмен болды. Decision Tree моделі интерпретациялануы жоғары болғанымен, күрделі үлгілерді толық қамти алмады және орташа нәтижелер көрсетті. Ал Naive Bayes моделі белгілер арасындағы тәуелсіздік болжамына байланысты салыстырмалы түрде төмен нәтиже көрсетті, алайда ол салыстыру үшін маңызды базалық әдіс ретінде қарастырылды.

Зерттеу барысында модельдердің тек сандық көрсеткіштері ғана емес, олардың шешім қабылдау логикасы да талданды. SHAP негізіндегі түсіндірмелі талдау модель болжамдарының негізгі факторларын анықтауға мүмкіндік беріп, алынған нәтижелердің

интерпретациялануын арттырды. Бұл зерттеу нәтижелері Explainable AI әдістерін қолдану тек модель сапасын арттыру ғана емес, сонымен қатар шешімдердің сенімділігі мен түсіндірілетіндігін қамтамасыз ететінін көрсетті.

Практикалық тұрғыдан алғанда, ұсынылған әдістеме университеттерге студенттердің пікірлерін жүйелі түрде талдауға, оқыту сапасын алдын ала болжауға және деректерге негізделген басқарушылық шешімдер қабылдауға мүмкіндік береді. Мұндай тәсілдер оқыту процесін жетілдіруге және білім беру сапасын басқарудың аналитикалық жүйелерін дамытуға ықпал етеді.

Болашақ зерттеулерде деректер жиынтығын кеңейту, бірнеше пәндер мен оқу орындарын қамту, сондай-ақ ансамбльдік және терең оқыту модельдерін қолдану арқылы болжам дәлдігін арттыру мүмкіндігі бар. Сонымен қатар, уақыттық динамиканы ескеретін модельдерді енгізу білім беру сапасын ұзақ мерзімді перспективада бағалауға жол ашады.

Әдебиеттер

1. Romero, C. & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *WIREs Data Mining and Knowledge Discovery*, 10, e1355. <https://doi.org/10.1002/widm.1355>
2. Vieriu, A. M. & Petrea, G. (2025). The impact of artificial intelligence (AI) on students' academic development. *Education Sciences*, 15(3), 343. <https://doi.org/10.3390/educsci15030343>
3. Nawaz, R., Sun, Q., Shardlow, M., Kontonatsios, G., Aljohani, N. R., Visvizi, A. & Hassan, S.-U. (2022). Leveraging AI and machine learning for national student survey: Actionable insights from textual feedback to enhance quality of teaching and learning in UK's higher education. *Applied Sciences*, 12(1), 514. <https://doi.org/10.3390/app12010514>
4. Shah, K., Patel, H., Sanghvi, D. et al. (2020). A comparative analysis of logistic regression, random forest and KNN models for the text classification. *Augmenting Human Research*, 5, 12. <https://doi.org/10.1007/s41133-020-00032-0>
5. Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1, 206–215. <https://doi.org/10.1038/s42256-019-0048-x>
6. Saarela, M. & Podgorelec, V. (2024). Recent applications of explainable AI (XAI): A systematic literature review. *Applied Sciences*, 14(19), 8884. <https://doi.org/10.3390/app14198884>
7. Linardatos, P., Papastefanopoulos, V. & Kotsiantis, S. (2021). Explainable AI: A review of machine learning interpretability methods. *Entropy*, 23(1), 18. <https://doi.org/10.3390/e23010018>
8. Moghimi, M. & Varjani, A. Y. (2016). New rule-based phishing detection method. *Expert Systems with Applications*, 53, 231–242. <https://doi.org/10.1016/j.eswa.2016.01.028>
9. Sujon, K. M., Hassan, R., Choi, K. et al. (2025). Accuracy, precision, recall, F1-score, or MCC? Empirical evidence from advanced statistics, ML, and XAI for evaluating business predictive models. *Journal of Big Data*, 12, 268. <https://doi.org/10.1186/s40537-025-01313-4>
10. Lubo-Robles, D., Devegowda, D., Jayaram, V., Bedle, H., Marfurt, K. J. & Pranter, M. J. (2020). Machine learning model interpretability using SHAP values: Application to a seismic facies classification task. *SEG Technical Program Expanded Abstracts*. <https://doi.org/10.1190/SEGAM2020-3428275.1>
11. Li, J. (2024). Area under the ROC Curve has the most consistent evaluation for binary classification. *PLoS ONE*, 19(12), e0316019. <https://doi.org/10.1371/journal.pone.0316019>
12. Chicco, D. & Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*, 21, 6. <https://doi.org/10.1186/s12864-019-6413-7>
13. Lundberg, S. M., Erion, G., Chen, H. et al. (2020). From local explanations to global understanding with explainable AI for trees. *Nature Machine Intelligence*, 2, 56–67. <https://doi.org/10.1038/s42256-019-0138-9>

14. Bacanin, N., Jovanovic, L., Zivkovic, M., Kandasamy, V., Antonijevic, M., Deveci, M. et al. (2023). Multivariate energy forecasting via metaheuristic tuned long-short term memory and gated recurrent unit neural networks. *Information Sciences*, 642, 119122. <https://doi.org/10.1016/j.ins.2023.119122>
15. White, D. S., Chowdhury, S., Idikuda, V. et al. (2021). cAMP binding to closed pacemaker ion channels is non-cooperative. *Nature*, 595, 606–610. <https://doi.org/10.1038/s41586-021-03686-x>

СРАВНИТЕЛЬНАЯ ОЦЕНКА МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ С ПРИМЕНЕНИЕМ EXPLAINABLE AI ДЛЯ АНАЛИЗА СТРУКТУРИРОВАННЫХ ОБРАЗОВАТЕЛЬНЫХ АНКЕТНЫХ ДАННЫХ

Аннотация. Применение моделей машинного обучения для анализа структурированных анкетных данных является одним из ключевых направлений развития аналитических систем, основанных на данных. Однако, несмотря на высокую точность прогнозирования многих классификационных алгоритмов, недостаточная интерпретируемость их решений ограничивает практическое применение. В этой связи актуальной задачей является комплексная оценка как производительности моделей, так и их интерпретируемости. В данной работе проведен сравнительный анализ классических классификаторов машинного обучения на основе структурированных анкетных данных. В исследовании рассмотрены модели логистической регрессии, *k*-ближайших соседей (*k*NN), дерева решений и Gaussian Naive Bayes. Обучение моделей осуществлялось на стратифицированных обучающих и тестовых выборках, а их эффективность оценивалась с использованием метрик Accuracy, Precision, Recall, F1-score, ROC-AUC и LogLoss. Помимо точности прогнозирования, проанализирована логика принятия решений моделей. Для этого применен метод объяснимого искусственного интеллекта SHAP (Shapley Additive Explanations). Результаты глобальной и локальной интерпретации показали, что прогнозы моделей формируются на основе совокупного влияния ключевых признаков. Экспериментальные результаты показали, что модель логистической регрессии является наиболее сбалансированной и надежной с точки зрения производительности и вероятностной калибровки. Кроме того, интерпретируемый анализ подтвердил, что решения модели основываются на значимых факторах данных. Полученные результаты могут быть использованы при разработке аналитических и систем поддержки принятия решений на основе структурированных данных.

Ключевые слова: машинное обучение, классификация, объяснимый искусственный интеллект, структурированные анкетные данные, логистическая регрессия, дерево решений, *k*NN, Naive Bayes, SHAP.

COMPARATIVE EVALUATION OF MACHINE LEARNING MODELS USING EXPLAINABLE AI FOR ANALYZING STRUCTURED EDUCATIONAL SURVEY DATA

Abstract. The application of machine learning models for the analysis of structured survey data is one of the key directions in the development of data-driven analytical systems. However, despite the high predictive performance of many classification algorithms, the lack of interpretability of their decision-making processes limits their practical applicability. Therefore, the joint evaluation of model performance and interpretability is an important research problem. In this study, a comparative analysis of classical machine learning classifiers was conducted using structured survey data. The models considered include Logistic Regression, *k*-Nearest Neighbors (*k*NN), Decision Tree, and Gaussian Naive Bayes. The models were trained on stratified training and test datasets, and their performance was evaluated using Accuracy, Precision, Recall, F1-

score, ROC-AUC, and LogLoss metrics. In addition to predictive performance, the decision-making logic of the models was analyzed. For this purpose, the explainable artificial intelligence method SHAP (Shapley Additive Explanations) was applied. The results of global and local interpretations showed that model predictions are driven by the combined influence of several key features. Experimental results demonstrated that Logistic Regression provides the most balanced and reliable performance in terms of both predictive accuracy and probabilistic calibration. Furthermore, the explainability analysis confirmed that model decisions are based on meaningful data-driven factors. The proposed approach can be applied in the development of analytical and decision support systems based on structured data.

Keywords: machine learning, classification, explainable artificial intelligence, structured survey data, logistic regression, decision tree, kNN, Naive Bayes, SHAP.

Авторлар туралы мәлімет

Айдаулет Бекарыс Ерланұлы	Техника ғылымдарының магистрі, М.Әуезов атындағы Оңтүстік Қазақстан университеті «Ақпараттық жүйелер және модельдеу» кафедрасының оқытушысы, Шымкент, Қазақстан, e-mail: bekarys.aidaulet@mail.ru
Изтаев Жалғасбек Дулатович	Педагогика ғылымдарының кандидаты, қауымдастырылған профессор, М.Әуезов атындағы Оңтүстік Қазақстан университеті «Ақпараттық жүйелер және модельдеу» кафедрасының меңгерушісі, Шымкент, Қазақстан, e-mail: zhalgasbek71@mail.ru
Кожобекова Пернекул Акбердиевна	Техника ғылымдарының кандидаты, М.Әуезов атындағы Оңтүстік Қазақстан университеті «Ақпараттық жүйелер және модельдеу» кафедрасының доценті, Шымкент, Қазақстан, e-mail: pernesh-63@mail.ru
Утебаев Калмурат Абдразахович	Экономика ғылымдарының кандидаты, М.Әуезов атындағы Оңтүстік Қазақстан университеті «Ақпараттық жүйелер және модельдеу» кафедрасының доценті, Шымкент, Қазақстан, e-mail: kalmuratutebaev@mail.ru

Сведения об авторах

Айдаулет Бекарыс Ерланұлы	магистр технических наук, преподаватель кафедры «Информационные системы и моделирование» Южно-Казахстанского университета имени М.Ауезова, Шымкент, Казахстан, e-mail: bekarys.aidaulet@mail.ru
Изтаев Жалғасбек Дулатович	кандидат педагогических наук, ассоциированный профессор, заведующий кафедрой «Информационные системы и моделирование» Южно-Казахстанского университета имени М.Ауезова, Шымкент, Казахстан, e-mail: zhalgasbek71@mail.ru
Кожобекова Пернекул Акбердиевна	кандидат технических наук, доцент кафедры «Информационные системы и моделирование» Южно-Казахстанского университета имени М.Ауезова, Шымкент, Казахстан, e-mail: pernesh-63@mail.ru
Утебаев Калмурат Абдразахович	кандидат экономических наук, доцент кафедры «Информационные системы и моделирование» Южно-Казахстанского университета имени М.Ауезова, Шымкент, Казахстан, e-mail: kalmuratutebaev@mail.ru

Information about the authors

Bekarys Aidaulet	Master of Technical Sciences, Lecturer at the Department of Information Systems and Modeling, M. Auezov South Kazakhstan University, Shymkent, Kazakhstan, e-mail: bekarys.aidaulet@mail.ru
Zhalgasbek Iztaev	Candidate of Pedagogical Sciences, Associate Professor, Head of the Department Information Systems and Modeling, M. Auezov South Kazakhstan University, Shymkent, Kazakhstan, e-mail: zhalgasbek71@mail.ru
Pernekul Kozhabekova	Candidate of Technical Sciences, Associate Professor of the Department Information Systems and Modeling, M. Auezov South Kazakhstan University, Shymkent, Kazakhstan, e-mail: pernesh-63@mail.ru
Kalmurat Utebayev	Candidate of Economical Sciences, Associate Professor of the Department Information Systems and Modeling, M. Auezov South Kazakhstan University, Shymkent, Kazakhstan, e-mail: kalmuratutebaev@mail.ru