

Баубекова Гаухар Коныспаевна* – магистр педагогического образования, старший преподаватель, заведующая кафедрой естественно-научных дисциплин, Костанайский региональный университет имени Ахмет Байтұрсынұлы, Республика Казахстан, 110000 г. Костанай, мкрн. Наурыз д.2., кв. 51, тел.: 87787408873, e-mail: baubekova_31@mail.ru.

Omarova Kunsulu Izbassarovna – Master of Geographical Sciences, Senior Lecturer of the Department of natural sciences, Akhmet Baitursynuly Kostanay Regional University, Republic of Kazakhstan, 100000, Kostanay, 18/2 Sokolovskaya Str., tel.: 87752662798, e-mail: kunsulu_omarova@mail.ru.

Kuanyshbayev Seitbek Bekenovich – Doctor of Geographical Sciences, Associate Professor, Akhmet Baitursynuly Kostanay Regional University, Republic of Kazakhstan, 110000, Kostanay, 47 Baitursynov Str., tel.: 87012339199, e-mail: kuanyshbayev65@bk.ru.

Suyundikova Zhanar Tuleutayevna – Candidate of Biological Sciences, Senior Lecturer, L.N. Gumilyov Eurasian National University, Republic of Kazakhstan, 010000, Astana, 2/6 B.Momyshuly Ave., apt. 10, tel.: 87018577710, e-mail: forwork.zhanar@mail.ru.

Baubekova Gaukhar Konyspayevna* – Master of Pedagogical Education, Senior Lecturer, Head of the Department of natural sciences, Akhmet Baitursynuly Kostanay Regional University, Republic of Kazakhstan, 110000, Kostanay, Nauryz microdistrict, bld. 2, apt. 51, tel.: 87787408873, e-mail: baubekova_31@mail.ru.

XFTAP 20.01.07

ӨОЖ 378.004

<https://doi.org/10.52269/SRDG2612240>

ЖАСАНДЫ ИНТЕЛЛЕКТКЕ НЕГІЗДЕЛГЕН ЕРТЕ ЕСКЕРТУ ЖҮЙЕСІ (EWS): LEARNING ANALYTICS ДЕРЕКТЕРІ БОЙЫНША DROPOUT ЖӘНЕ ТӨМЕН ҮЛГЕРІМ ТӘУЕКЕЛІН БОЛЖАУ

Рахметов М.Е. – PhD, қауымдастырылған профессор. Х. Досмұхамедов атындағы Атырау университеті, Атырау қ., Қазақстан Республикасы.

Куанбаева Б.У.* – педагогика ғылымдарының кандидаты, профессор, Х. Досмұхамедов атындағы Атырау университеті, Атырау қ., Қазақстан Республикасы.

Мақалада *learning analytics* тәсілдеріне негізделген оқу тәуекелін ерте болжау міндеті қарастырылады. Қашықтықтан оқыту жағдайында білім алушының оқу траекториясы LMS-та қалатын цифрлық іздер арқылы сипатталады; Осы деректерді жүйелі талдау үлгермеушілік (*dropout*) немесе төмен үлгерім қаупін алдын ала анықтауға мүмкіндік береді. Зерттеудің мақсаты – ерте ескерту жүйесінің (*Early Warning System, EWS*) құрылымдық-әдіснамалық моделін ұсыну және алғашқы апталардағы белсенділік көрсеткіштері арқылы тәуекелі жоғары білім алушыларды жіктейтін болжау моделін салыстырмалы түрде бағалау. Материалдар ретінде нақты тұлғаларды сәйкестендірмейтін, LMS логтарының құрылымын сақтайтын анонимдендірілген синтетикалық деректер жиыны ($N=260$) қолданылды. Фича-инжиниринг арқылы қатысу, уақыт, бағалау және әлеуметтік белсенділік метрикалары қалыптастырылды. Модельдер ретінде логистикалық регрессия, *Random Forest* және *Gradient Boosting* салыстырылды; Бағалау метрикалары ретінде ROC-AUC, *accuracy*, *precision*, *recall* және F1 пайдаланылды. Нәтижелер бойынша логистикалық регрессия ең жоғары ажырату қабілетін көрсетті ($AUC=0.897$; $F1=0.774$), бұл ерте кезеңде тәуекелді сенімді бағалауға мүмкіндік беретінін дәлелдейді. Талқылауда интервенция дизайны, этикалық және педагогикалық шектеулер, сондай-ақ модельдің түсіндірмелігін (XAI) оқытушылық шешім қабылдауға енгізу тәсілдері негізделді.

Түйінді сөздер: *learning analytics*; *dropout prediction*; ерте ескерту жүйесі; тәуекел скорингі; LMS логтары; интервенция; ROC-AUC; түсіндірмелі AI (XAI).

СИСТЕМА РАННЕГО ПРЕДУПРЕЖДЕНИЯ (EWS) НА ОСНОВЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА: ПРОГНОЗИРОВАНИЕ РИСКА ОТЧИСЛЕНИЯ (DROPOUT) И НИЗКОЙ УСПЕВАЕМОСТИ ПО ДАННЫМ LEARNING ANALYTICS

Рахметов М.Е. – PhD, ассоциированный профессор., Атырауский университет имени Х. Досмұхамедова, г. Атырау, Республика Казахстан.

Куанбаева Б.У.* – кандидат педагогических наук, профессор Атырауский университет имени Х. Досмұхамедова, г. Атырау, Республика Казахстан.

В статье рассматривается задача раннего прогнозирования учебных рисков на основе подходов *learning analytics*. В условиях дистанционного обучения образовательная траектория обучающегося описывается цифровыми следами, фиксируемыми в LMS; систематический анализ

этих данных позволяет заранее выявлять риск досрочного прекращения обучения (dropout) либо низкой успеваемости. Цель исследования – предложить методологическую модель системы раннего предупреждения (Early Warning System, EWS) и выполнить сравнительную оценку прогностической модели, классифицирующей обучающихся группы риска по показателям активности первых недель обучения. В качестве материалов использован анонимизированный синтетический набор данных ($N=260$), сохраняющий структуру LMS-логов и исключающий идентификацию конкретных лиц; посредством feature engineering сформированы метрики посещаемости, учебного времени, оценивания и социальной активности. В качестве моделей сравнивались логистическая регрессия, Random Forest и Gradient Boosting; в качестве метрик качества применялись ROC-AUC, accuracy, precision, recall и F1. По результатам логистическая регрессия продемонстрировала наивысшую различающую способность ($AUC=0.897$; $F1=0.774$), что подтверждает возможность надежной оценки риска на раннем этапе. В обсуждении обоснованы дизайн интервенций, этические и педагогические ограничения, а также подходы к интеграции объяснимости модели (XAI) в процесс принятия педагогических решений.

Ключевые слова: learning analytics; прогнозирование dropout; система раннего предупреждения; скоринг риска; логи LMS; интервенция; ROC-AUC; объяснимый ИИ (XAI).

AI-BASED EARLY WARNING SYSTEM (EWS): PREDICTING DROPOUT AND LOW ACADEMIC PERFORMANCE RISK USING LEARNING ANALYTICS DATA

Rakhmetov M.Ye. – PhD, Associate Professor, Kh. Dosmukhamedov Atyrau University, Atyrau, Republic of Kazakhstan.

Kuanbayeva B.U.* – Candidate of Pedagogical Sciences, Associate Professor, Kh. Dosmukhamedov Atyrau University, Atyrau, Republic of Kazakhstan.

This paper addresses the problem of early prediction of educational risk using learning analytics approaches. In distance education settings, a learner's educational trajectory is reflected in digital traces recorded in an LMS; systematic analysis of these data enables early identification of the risk of dropout or low academic performance. The study aims to propose a data- and methodology-driven model of an Early Warning System (EWS) and to comparatively evaluate predictive models that classify at-risk learners based on engagement indicators from the first weeks of study. As research materials, an anonymized synthetic dataset ($N=260$) was used; it preserves the structure of LMS logs while preventing personal identification. Through feature engineering, metrics of participation, learning time, assessment performance, and social activity were constructed. Logistic regression, Random Forest, and Gradient Boosting were compared; evaluation metrics included ROC-AUC, accuracy, precision, recall, and F1. The results show that logistic regression achieved the highest discriminative performance ($AUC=0.897$; $F1=0.774$), demonstrating that learning risk can be assessed reliably at an early stage. The discussion substantiates the intervention design, ethical and pedagogical constraints, and approaches for integrating model explainability (XAI) into instructional decision-making.

Key words: learning analytics, dropout prediction, early warning system, risk scoring, LMS logs, intervention, ROC-AUC, explainable AI (XAI).

Кіріспе. Қашықтықтан оқыту мен аралас форматтың кең таралуы білім алушылардың оқу белсенділігін цифрлық ортада жүйелі бақылауды маңызды міндетке айналдырды. Дәстүрлі аудиториялық оқытуда оқытушы қатысу, белсенділік, тапсырмаларды орындау тәртібі сияқты индикаторларды тікелей бақылай алады, ал онлайн ортада бұл индикаторлар көбіне платформада сақталатын оқу журналдарына (логтарға) «жасырын» түрде түседі. Осыған байланысты learning analytics (оқу аналитикасы) білім алушының оқу әрекетінің іздерін өңдеп, педагогикалық шешім қабылдауға қажетті деректік дәлелдер ұсынатын ғылыми-тәжірибелік бағыт ретінде өзектені түсті өзекті болып табылады [1].

Оқу тәуекелі бұл жұмыста екі негізгі нәтижемен операцияланады: (i) курсты аяқтамай шығу (dropout) және/немесе (ii) қорытынды бақылауда төмен үлгерім көрсету. Мұндай тәуекелдер білім алушы үшін де, білім беру ұйымы үшін де тиімсіз: оқу мотивациясының төмендеуі, уақыттық ресурстардың тиімсіз жұмсалыуы, курстың аяқталу көрсеткіштерінің нашарлауы, оқытушының қолдау ресурстарының дұрыс бөлінбеуі сияқты мәселелер туындайды. MOOCs және LMS негізіндегі оқытуда dropout феномені жүйелі түрде зерттеліп, білім алушылардың қатысу үлгілері мен disengagement типтері сипатталған [2].

Ерте ескерту жүйелері (Early Warning Systems, EWS) – оқу барысында тәуекелі жоғары білім алушыларды алдын ала анықтап, мақсатты интервенциялар арқылы оқу нәтижесін жақсартуға бағытталған тәсілдер жиынтығы. Қазіргі зерттеулерде EWS-тің тиімділігі деректер сапасына, фишалардың мағыналылығына, модельдің дәлдігі мен түсіндірмелігіне және интервенция дизайнының педагогикалық қисындылығына тәуелді екені көрсетіледі [3-5]. Оқу тәуекелін ерте болжауда фича таңдауы деректердің қолжетімділігімен ғана емес, білім алушының оқу үдерісіндегі мінез-құлықтық және академиялық қатысуын түсіндіретін теориялық модельдермен негізделуі тиіс. Осы тұрғыдан, зерттеуде

қолданылған айнымалылар үш теориялық бағытқа сүйеніп операцияланды. Біріншіден, академиялық және әлеуметтік интеграция идеясына сәйкес LMS-тағы қатысу қарқыны мен үзіліс индикаторлары (w1_logins, w2_logins, w3_logins, idle_days) студенттің курспен байланысының әлсіреуін ерте көрсететін сигнал ретінде қарастырылады. Екіншіден, өзін-өзі реттеу (self-regulated learning) логикасы бойынша оқу уақытын жоспарлау және тапсырманы уақытында орындау оқу нәтижесіне тікелей әсер етеді; сондықтан time-on-task (time_w1_min, time_w2_min, time_w3_min), тапсырма тапсыру үлесі (assign_submit_rate) және кешігу көрсеткіші (late_ratio) тәуекелді түсіндіретін негізгі фичалар ретінде енгізілді. Үшіншіден, оқу әрекетінің когнитивтік қатысуын сипаттайтын көрсеткіштер (quiz_mean, video_completion) үлгерімнің ерте маркерлері ретінде қарастырылып, “төмен үлгерім” тәуекелімен байланысты айнымалыларға енгізілді. Осылайша, әдебиетте көрсетілген факторлар зерттеуде үш фича тобына жүйеленді: қатысу/қолжетім, өзін-өзі реттеу және уақыт метрикалары, бағалау мен контентті тұтыну көрсеткіштері. Гипотеза (H1) дәл осы теориялық байланысқа сүйенеді: оқудың алғашқы 1-3 аптасындағы қатысу, өзін-өзі реттеу және бағалау индикаторлары тәуекел тобын ерте кезеңде ажыратуға жеткілікті болжамдық күш береді және $AUC \geq 0.80$ деңгейіне жеткізеді.

Модель құруда стандартталған деректер алмасу тәсілдері де маңызды. Мысалы, Experience API (xAPI) спецификациясы оқу әрекеттерін әр түрлі жүйелерден жинап, Learning Record Store (LRS) арқылы сақтауға мүмкіндік береді; бұл learning analytics үшін дерек көздерін кеңейтеді [6].

Біздің зерттеулеріміздің ғылыми жаңалығы – оқу тәуекелін ерте болжаудың толық циклын (деректерден интервенцияға дейін) біріктіретін құрылымдық-әдіснамалық модельді ұсыну және алғашқы апталардағы агрегатталған белсенділік көрсеткіштері негізінде әр түрлі ML модельдерінің нәтижесін салыстыра бағалау. Практикалық маңызы – кафедра/факультет деңгейінде оқытушыға арналған тәуекел панелін (dashboard) құруға негіз болатын нақты метрикалар мен рәсімдерді жүйелеу [7].

Зерттеу сұрағы: learning analytics деректері бойынша курстың бастапқы кезеңінде тәуекелі жоғары білім алушыларды қаншалықты дәл анықтауға болады?

Гипотеза (H1): алғашқы 1–3 аптадағы белсенділік және бағалау фичалары тәуекел тобын анықтауда статистикалық мәнді болжамдық күшке ие және $AUC \geq 0.80$ нәтижесіне жеткізеді.

Зерттеу міндеттері:

- 1) оқу логтары негізінде тәуекелді сипаттайтын фича топтарын негіздеу және есептеу;
- 2) EWS құбырын және архитектуралық шешімді ұсыну;
- 3) логистикалық регрессия, Random Forest және Gradient Boosting модельдерін салыстыру;
- 4) ROC-AUC, F1, калибрация және қателер құрылымы арқылы тиімділікті талдау;
- 5) нәтижелерді педагогикалық интервенцияға айналдыру қағидаларын ұсыну.

Зерттеу материалдары мен әдістері. Зерттеу деректерге негізделген модельдеу тәсілін қолданады және оқу тәуекелін ерте кезеңде болжауға бағытталған. Нақты оқу жағдайларында dropout/ төмен үлгерім тәуекелін болжау үшін LMS-та жиналатын әрекет логтары, тапсырма статусы, тест нәтижелері және форум белсенділігі секілді деректер пайдаланылады. Біздің зерттеулерімізде әдістемені толық әрі қайта өндіруге ыңғайлы көрсету үшін оқу логтарының құрылымы мен таралуын сақтайтын анонимдендірілген синтетикалық деректер жиыны (N=260) қолданылды. Мұндай тәсіл этикалық тәуекелдерді азайтып, есептеу қадамдарын демонстрациялауға мүмкіндік береді [8].

1 кесте – Деректер жиынының сипаттамасы


Параметр	Сипаттама
N (оқушылар саны)	260
Мақсат айнымалысы (label)	Тәуекел (1) = dropout немесе төмен үлгерім; 0 = қалыпты
Ерте болжау терезесі	Алғашқы 3 аптадағы белсенділік агрегаттары
Негізгі дереккөздер	LMS логтары, тест нәтижелері, тапсырма статусы, форум әрекеттері
Бөлу әдісі	Stratified train/test split (75/25)

Labeling және синтетикалық дерек генерациясы

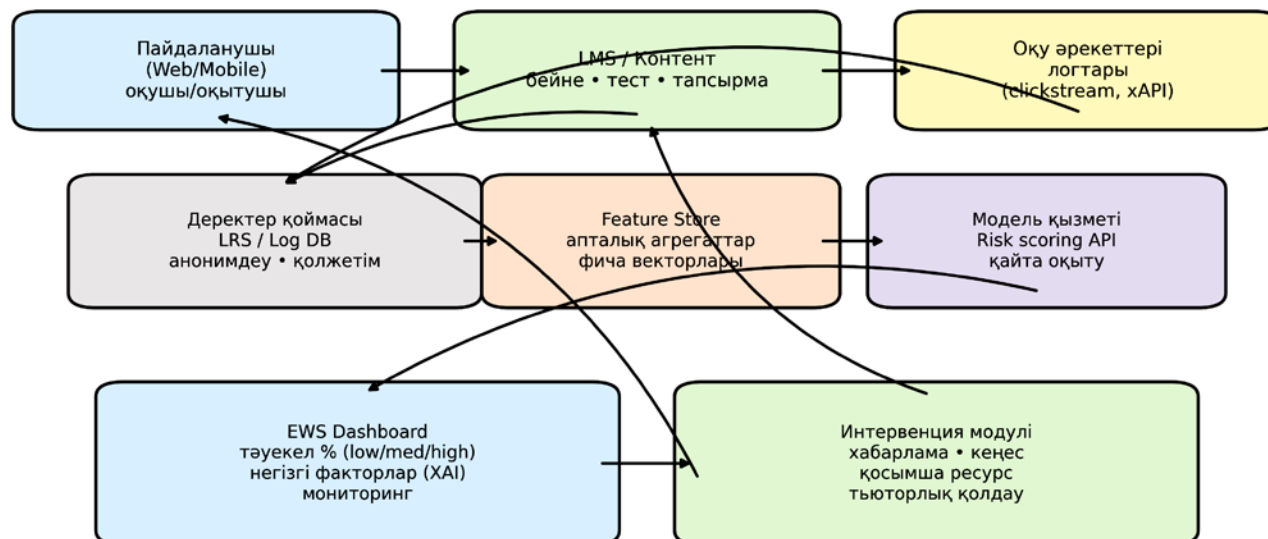
Бұл зерттеуде мақсат айнымалысы (label) синтетикалық деректер генерациясының екі сценарийіне сүйене отырып қалыптастырылды: dropout және төмен үлгерім. Төмен үлгерім (low performance) қорытынды нәтижесі шекті мәннен төмен болған жағдай ретінде операцияланды: final_score < 25. Dropout жағдайы курстың соңғы кезеңінде оқу белсенділігінің тоқтауымен модельденді: жүйеге кіру жиілігінің нөлге/өте төмен мәнге түсуі (logins≈0), тапсырмалардың орындалмауы (assign_submit_rate төмен), сондай-ақ оқу уақытының күрт төмендеуі (time-on-task азаюы) қатар байқалғанда “dropout=1” ретінде белгіленді. Осылайша, тәуекел=1 егер (dropout=1) OR (low_performance=1), ал қалғандары тәуекел=0 ретінде кодталды. Деректер жиынында класстар үлесі: тәуекел=1: n=28 (10.77%), тәуекел=0: n=232 (89.23%).

EWS ұсынған жүйе (1 сурет) деректер көздерінен бастап интервенцияға дейінгі кезеңдерді жүйелейді: деректерді жинау, тазалау/ETL, фича-инжиниринг, модельдеу және тәуекел панелі арқылы

оқытушылық әрекетке айналдыру [9-10]. Архитектуралық тұрғыдан (2 сурет) жүйе клиент қабаты, LMS/контент сервисі, әрекет логтары (xAPI), деректер қоймасы (LRS/Log DB), feature store, модель қызметі және dashboard+интервенция модулінен тұрады. Мұндай қабатты дизайн деректердің қайта қолданылуын, масштабталуын және модельдің қайта оқытылуын жеңілдетеді.



1-сурет – Learning analytics негізіндегі ерте ескерту (EWS) жүйесі



2-сурет – Ерте болжау моделі бар оқу аналитика жүйесінің архитектурасы

Фича-инжиниринг және белгілеу (labeling)

2 кесте – Фичалар топтары және негізгі айнымалылар


Фича тобы	Айнымалылар (мысал)
Қатысу/қолжетім	w1_logins, w2_logins, w3_logins, idle_days
Уақыт метрикалары	time_w1_min, time_w2_min, time_w3_min
Бағалау/нәтиже	quiz_mean, assign_submit_rate, late_ratio
Контент тұтыну	video_completion
Әлеуметтік белсенділік	forum_reads, forum_posts

Фича-инжиниринг кезеңінде оқудың алғашқы апталарындағы белсенділік апта бойынша агрегатталады. Жүйелік енгізуде бұл агрегаттар event-level логтарды (мысалы, xAPI statements) оқу әрекетінің мағыналы өлшемдеріне айналдырады: апталық логин саны, оқу уақытын бағалау (time-on-task), тапсырманы тапсыру, кешігу, қатысу үзілісі, бейнесабақты игеру, форум оқылым/жазба саны. Мақсат айнымалысы «тәуекел» ретінде анықталады: «1» – курсты аяқтамау немесе қорытынды нәтиженің төмен болуы, «0» – қалыпты аяқтау.

Деректер ағымы (pipeline) келесі қадамдармен орындалды: (1) ETL және біріктіру: LMS логтары мен бағалау деректері апта бойынша агрегатталып, бірегей идентификатор арқылы біріктірілді; дубликат жазбалар жойылды. (2) Missing values: сандық айнымалылардағы жетіспейтін мәндер медианамен алмастырылды (tree-негізді модельдер үшін әсері минимал). (3) Outliers: time-on-task секілді айнымалыларда шектен тыс мәндер перцентильдік қысқарту (winsorization) арқылы тұрақтандырылды. (4) Scaling: Logistic Regression үшін StandardScaler қолданылды, ал Random Forest және Gradient Boosting модельдеріне масштабтау қолданылған жоқ. (5) Leakage тәуекелін басқару: барлық фичалар тек W1–W3 ерте терезелерінен есептелді; label қалыптасатын кейінгі кезең көрсеткіштері фича ретінде енгізілмеді. Мысалы, quiz_mean айнымалысы тек алғашқы 1–3 аптадағы тест нәтижелерінен агрегатталды және финалдық нәтижелермен “ақпарат ағуын” (information leakage) болдырмау қағидасы сақталды. Барлық түрлендірулер train ішінде fit жасалып, test жиынына transform ретінде қолданылды.

Эксперимент жоспары және ерте болжау терезелері.

Ерте болжау міндетінің ерекшелігі – болжам жасау сәті мен нәтиженің (label) кейінірек қалыптасуы. Сондықтан уақыттық (W- апта): дизайн қолданылады: W1, W1–W2 және W1–W3 сияқты фича терезелері арқылы тәуекелді ерте бағалау жүргізіледі (3 сурет). Бұл тәсіл оқытушыға ең ерте кезеңде әрекет етуге мүмкіндік беретін «ең қысқа, бірақ жеткілікті» деректер терезесін табуға жағдай жасайды.



3-сурет – Эксперимент дизайны: ерте болжау терезелері және нәтиже айнаымалысы

Модельдер, бағалау және статистикалық сенімділік

3 кесте – Модельдер және параметрлер

Модель	Қысқаша сипаттама	Параметрлер
Logistic Regression	StandardScaler + L2 regularization	max_iter=4000
Random Forest	Ensemble (bagging)	n_estimators=700, class_weight=balanced
Gradient Boosting	Additive trees	random_state=22

4 кесте – Ерте болжау терезелері бойынша AUC (Logistic Regression)

Ерте болжау терезесі	Фича саны	AUC
W1	9	0.789
W1–W2	11	0.826
W1–W3	13	0.897

Деректер 75/25 қатынасымен стратификация арқылы train/test жиындарына бөлінді. Модельдер сапасы ROC-AUC, accuracy, precision, recall және F1 арқылы бағаланды. ROC-AUC мәнінің 0.80-ден жоғары болуы ерте болжау жүйелері үшін тәжірибелік деңгейде қанағаттанарлық ажырату қабілетін білдіреді. Қосымша ретінде модельдің калибрациясы тексерілді: болжанған ықтималдықтың (p) нақты тәуекел үлесіне сәйкестігі dashboard-та тәуекелді пайыз түрінде көрсетудің дұрыстығын арттырады.

Мақсат класстарында дисбаланс байқалады (**тәуекел=1: 10.77%, тәуекел=0: 89.23%**), сондықтан бағалауда accuracy көрсеткішімен шектелмей, **precision/recall/F1 және ROC-AUC** бірге қарастырылды. Random Forest моделінде class_weight=balanced параметрінің қолданылуы тәуекел класын “жоғалтып алмау” ықтималдығын азайтуға бағытталды. Дисбаланс жағдайында жалған теріс (false negative) қателердің педагогикалық құны жоғары болғандықтан, интерпретацияда recall көрсеткіші негізгі индикаторлардың бірі ретінде қарастырылды.

Этикалық және педагогикалық талаптар.

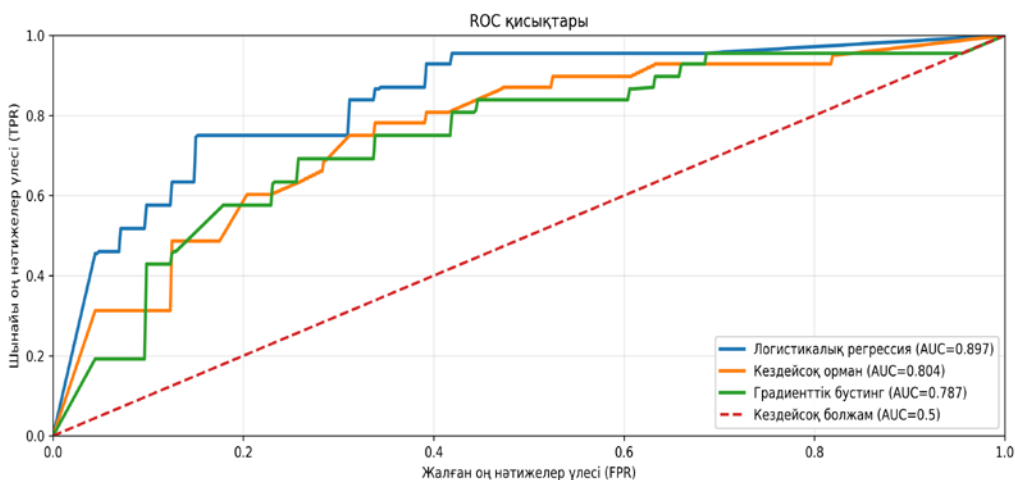
EWS енгізілгенде этикалық талаптар сақталуы тиіс: дербес деректерді анонимдеу, қол жеткізу құқықтарын бөлу, тәуекел ұпайын студентті «таңбалау» емес, қолдау құралы ретінде пайдалану, сондай-ақ қателесудің салдарын басқару. Практикалық протокол ретінде 3 деңгейлі интервенция ұсынылады: төмен тәуекел (ақпараттық хабарлама), орта тәуекел (ресурс/қосымша тапсырма/оқу жоспарлау), жоғары тәуекел (оқытушы/тьютормен жеке байланыс, кеңес беру).

Зерттеу нәтижелері және оларды талқылау.


5 кесте – Модельдердің сапа көрсеткіштері (test жиыны)

Rank	Model	AUC	Accuracy	Precision	Recall	F1
1	Logistic Regression	0.897	0.785	0.774	0.774	0.774
2	Random Forest	0.804	0.708	0.731	0.613	0.667
3	Gradient Boosting	0.787	0.723	0.71	0.71	0.71


5 кесте нәтижелері бойынша логистикалық регрессия ең жоғары ROC-AUC көрсетті (AUC=0.897) және F1=0.774 мәніне қол жеткізді. Бұл H1 гипотезасын қолдайды: алғашқы 1–3 аптадағы белсенділік және бағалау фишалары тәуекелді ерте кезеңде ажыратуға жеткілікті.



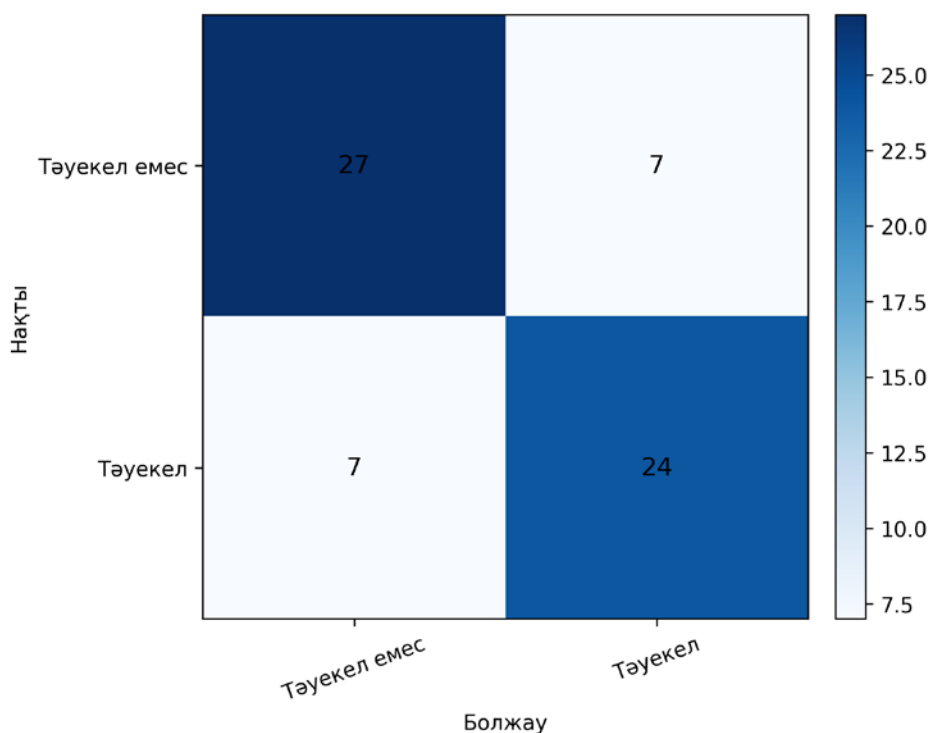
4-сурет – Модельдерді салыстыру: ROC-қысықтары



5-сурет – Ерте болжау терезелері бойынша AUC салыстыру




6-сурет – Фичалардың үлесі (Top-10): Logistic Regression



7-сурет – Confusion matrix (Logistic Regression, threshold=0.5)

Confusion matrix үшін бастапқыда threshold = 0.5 қолданылды, алайда оқу тәуекелі міндетінде шек мәні ресурс көлеміне және қате жіктеудің құнына тәуелді. Практикалық енгізуде threshold таңдауды ROC-қисық негізінде Youden index ($J = TPR - FPR$) арқылы немесе “cost-sensitive” тәсілмен негіздеу ұсынылады: егер университетте қолдау ресурсы жеткілікті болса, false negative (тәуекелді студентті өткізіп алу) қымбат болғандықтан, recall-ды арттыру үшін threshold төмендетіледі; ал ресурс шектеулі болса, жалған дабылды азайту үшін threshold жоғарырақ алынады. Сонымен қатар, тәуекел класы салыстырмалы түрде аз болған жағдайда PR-қисық (precision–recall) threshold таңдауда ақпараттырақ болуы мүмкін; сондықтан енгізу кезінде ROC және PR қисықтарын бірге қарап, мақсатты режимге (recall-бағытталған немесе precision-бағытталған) сәйкес шек бекітіледі.



8-сурет – Калибрация қисығы (Logistic Regression, W1–W3)

Терезелер бойынша салыстыру (Кесте 4, Сурет 5) оқудың алғашқы апталары деректерінің біртіндеп жиналуымен модель ажырату қабілетінің артатыдығын көрсетеді: W1 кезінде $AUC \approx 0.789$, W1–W2 кезінде $AUC \approx 0.826$, W1–W3 кезінде $AUC \approx 0.897$. Бұл тәжірибеде «ең ерте әсер ету» мен «ең

дәл болжау» арасындағы компромисті басқаруға мүмкіндік береді: мысалы, W1 нәтижесімен жеңіл интервенция, ал W1–W3 нәтижесімен мақсатты интервенция жасау.

Ұсынылған EWS моделін шынайы оқу үдерісіне енгізу Х.Досмұхамедов атындағы Атырау университеті, Информатика кафедрасы деңгейінде дерек сапасы–техникалық инфрақұрылым–педагогикалық процедура қағидасымен регламенттелуі тиіс. Біріншіден, дерек сапасына қойылатын ең төмен талаптар анықталады: (a) LMS-та логин/қатысу журналдарының тұрақты жазылуы; (b) оқу уақыты (time-on-task) есептеу ережесінің бірізденуі; (c) тапсырма статусының (submitted/late/missed) бір форматта тіркелуі; (d) қысқа бағалау нәтижелерінің (апталық quiz/тапсырма) дер кезінде енгізілуі. Екіншіден, техникалық шектеулер есепке алынады: логтардың кешігіп түсуі, пәндер арасындағы бағалау құрылымының айырмашылығы, және деректерді жинау арнасы (xAPI/LRS бар болса – автоматты жинау, болмаса – LMS API/экспорт арқылы ETL). Үшіншіден, педагогикалық процедура нақты қадамдармен бекітіледі: (1) аптасына бір рет (мысалы, дүйсенбі) тәуекел скорингін қайта есептеу; (2) тәуекел деңгейін 3 санатқа бөлу (төмен/орта/жоғары); (3) әр деңгей үшін интервенция пакетін бекіту (ақпараттық хабарлама → қосымша ресурс/жоспарлау → оқытушы/тьютормен жеке байланыс); (4) интервенция фактісін журналдау (күні, жауапты тұлға, әрекет түрі); (5) келесі аптада жауап әсерін мониторингтеу (engagement, submit rate, late ratio динамикасы). Осы регламент EWS-ті тек “модель” ретінде емес, кафедра деңгейінде студентті қолдаудың қайталанатын және өлшенетін процесі ретінде іске асыруға мүмкіндік береді.

6 кесте – Ablation талдауы (маңызды фичаларды алып тастаудың әсері)

Тәжірибе	Өзгеріс	AUC
Толық модель	Барлық фича	0.897
Ablation-1	Drop: time_w2_min	0.871
Ablation-2	Drop: time_w2_min, time_w3_min	0.813
Ablation-3	Drop: time_w2_min, time_w3_min, time_w1_min	0.792

Ablation талдауы тәуекелді түсіндіретін негізгі факторлардың әсерін көрсетеді: ең маңызды фичаларды алып тастағанда ROC-AUC төмендейді. Демек, платформада тапсырма тапсыру үлесі, кешігу үлесі және оқу уақыты сияқты индикаторларды сапалы тіркеу EWS сенімділігінің негізгі шарты.

Нәтижелер learning analytics негізіндегі ерте болжау тәсілінің практикалық қолданбалы әлеуетін көрсетеді. Логистикалық регрессияның жоғары ROC-AUC мәні және калибрация қисығының қанағаттанарлығы ықтималдықты пайыз түрінде көрсетуге мүмкіндік береді (мыс., $p=0.72 \rightarrow 72\%$ тәуекел). Мұндай интерпретация оқытушыға тәуекел деңгейін интуитивті түсінуге көмектеседі.

Сонымен бірге, болжау сапасы интервенция тиімділігімен тең емес: EWS-ті енгізуде педагогикалық сценарийлерді нақтылау қажет. Интервенцияның түрлері (ресурс ұсынымы, қысқа кеңес, жеке консультация, қосымша тапсырма) тәуекел себептеріне сәйкестендірілуі тиіс. Бұл жерде XAI (коэффициенттер/маңыздылық) оқытушыға не үшін жеке білім алушыны қолдау қажет екенін түсіндіреді.

Интервенцияның тиімділігін дәлелдеу үшін келесі кезеңде қысқа протокол ұсынылады. Дизайн ретінде (a) квазиэксперимент (matched control) немесе (ә) stepped-wedge тәсілі қолданылады: бірдей пәннің бірнеше тобында EWS кезең-кезеңімен енгізіліп, енгізілген және енгізілмеген кезеңдер салыстырылады. Негізгі нәтижелік көрсеткіштер: completion rate, final_score, кешігу үлесінің төмендеуі, және апталық engagement өсімі. Интервенция “қашан/кім/қандай қолдау көрсетті” түрінде журналданады, ал әсері pre/post айырмасымен және топаралық салыстырумен тексеріледі (мысалы, Δ final_score, Δ dropout үлесі). Осылайша, EWS құндылығы тек AUC/F1 емес, оқу нәтижесін нақты жақсартатын интервенция механизмімен дәлелденеді.

Қателер құрылымын басқару маңызды: жалған оң (false positive) нәтижелер оқытушы жүктемесін арттыруы мүмкін, ал жалған теріс (false negative) нәтижелер тәуекелі бар студентті қолдаусыз қалдыру қаупін туғызады. Сондықтан шешім шегін (threshold) университеттің ресурсына және курс ерекшелігіне қарай бейімдеу ұсынылады (мыс., жоғары ресурс болса – recall-ды арттыру үшін threshold төмендетіледі). Болашақ зерттеулерімізде нақты LMS деректерімен уақыттық валидация, кросс-курс генерализациясы және интервенцияның себеп-салдарлық әсерін бағалау (A/B немесе stepped-wedge) ұсынылады.

Қорытынды. Жұмыста learning analytics деректері негізінде оқу тәуекелін ерте болжаудың құрылымдық-әдіснамалық моделі ұсынылды және ерте ескерту жүйесінің (EWS) деректерді жинау–өңдеу–фича-инжиниринг–модельдеу–шешім қабылдау–интервенция кезеңдері бірізді түрде сипатталды. Салыстырмалы модельдеу нәтижелері синтетикалық деректер жиыны (N=260) шеңберінде логистикалық регрессия моделінің тәуекелі жоғары білім алушыларды ажыратуда ең жоғары тиімділікті көрсеткенін көрсетті (ROC-AUC = 0.897; F1 = 0.774). Бұл нәтиже оқудың алғашқы кезеңіндегі мінезқұлықтық және академиялық индикаторлардың (қатысу қарқыны, time-on-task, тапсырманы тапсыру үлесі, кешігу үлесі, тест нәтижелері, форум белсенділігі) тәуекелді ерте кезеңде ажыратуға жеткілікті болжамдық сигнал бере алатынын демонстрациялық-әдістемелік деңгейде негіздейді. Алайда алын-

ған тұжырымдар синтетикалық деректердің табиғатына байланысты шектеледі: модельдің практикалық “сенімділігін” бекіту үшін нақты LMS деректерімен сыртқы валидация (кемінде бір курс/бір семестр) және уақыттық тұрақтылықты (drift) тексеру келесі кезеңнің міндеті болып табылады.

Ерте болжау терезелері бойынша талдау ақпараттың жинақталуына қарай болжам дәлдігінің жүйелі түрде артатынын көрсетті: W1 деңгейінде модель бастапқы скрининг үшін жеткілікті сигнал берсе, W1–W3 агрегаттары тәуекелді бағалауда ең жоғары ажырату қабілетіне жеткізеді. Осыған сүйене отырып, практикалық енгізуде екі сатылы басқару логикасын қолдану ғылыми тұрғыдан негізді: (1) W1 нәтижесімен төмен ресурсты, автоматтандырылған қолдау (қысқа нұсқаулық, оқу жоспарын құруға кеңес, микро-ресурс ұсыну), (2) W1–W3 нәтижесімен дәлелге негізделген мақсатты интервенция (тьюторлық қолдау, жеке консультация, тапсырмаларды бейімдеу). Бұл тәсіл жалған дабыл тәуекелін азайтып, оқытушының уақыттық ресурсын тәуекел деңгейіне пропорционал бөлуге мүмкіндік береді.

Зерттеу нәтижелері EWS тиімділігі тек модель метрикаларымен шектелмейтінін нақтылайды: жүйенің практикалық құндылығы тәуекелді түсіндіру (XAI) және интервенция протоколын стандарттау арқылы артады. Тәуекел скорингімен қатар шешімге ықпал еткен негізгі факторларды көрсету (мысалы, кешігу, қатысу үзілісі, тапсырманы тапсыру қарқыны, оқу уақытының төмендеуі) педагогикалық шешім қабылдауды дәлелге негізделген форматқа көшіреді және қолдауды “жазалау” емес, оқу жетістігін сақтап қалуға бағытталған көмек механизмі ретінде іске асыруға жағдай жасайды. Сонымен бірге, әділдік пен этика талаптарын сақтау (анонимдеу, қолжетімділік құқықтарын бөлу, нәтижені стигматизацияға қолданбау, қателер құнын басқару) EWS енгізуді білім беру ұйымының жауапты цифрлық трансформация қағидаттарымен үйлестіреді.

Практикалық ұсыныстар: Деректер сапасы және регламент: LMS-та қатысу (logins/engagement), time-on-task, тапсырма статусы (submit rate), кешігу үлесі (late ratio), тест нәтижелері және форум әрекеттері бойынша метрикаларды бірдей форматта тұрақты жинау; missing/outlier мониторингі және апта сайынғы дерек сапасы тексерісін бекіту. Екі сатылы интервенция протоколы:

а) W1 – төмен ресурсты автоматтандырылған қолдау (оқу жоспары, қысқа нұсқаулық, базалық ресурс ұсыну);

ә) W1–W3 – мақсатты қолдау (оқытушы/тьютор консультациясы, тапсырманы бейімдеу, қосымша түсіндіру), интервенция фактісін журналдау.

Тәуекелді ұсыну форматы: тәуекел ықтималдығын пайызбен шығарып, 3 деңгейлі протокол (төмен/орта/жоғары) бекіту және әр деңгей үшін нақты әрекет пакетін (қадамдар тізімі, жауапты тұлға, уақыт) регламенттеу.

Модельді сүйемелдеу: модельді әр семестр сайын қайта оқыту, деректер/мінез-құлық өзгерісін (drift) бақылау және сапа метрикаларын (ROC-AUC, F1, recall, қажет болса PR-AUC) тұрақты есептеу.

Түсіндірмелілік және этика: тәуекел ұпайымен бірге XAI-түсіндірме факторларды көрсету, қолжетімділік деңгейлерін бөлу, студентті “таңбалауға” жол бермейтін коммуникация стандартын енгізу.

Осылайша, ұсынылған тәсіл learning analytics негізіндегі ерте болжауды институционалдық деңгейде ұйымдастыруға бағытталған әдістемелік негіз ұсынады және тәуекелді дер кезінде анықтау арқылы оқу нәтижелерін тұрақтандыруға мүмкіндік береді. Сонымен қатар, оны нақты LMS деректерімен сыртқы валидациялау және интервенцияның әсерін квазиэксперименттік дизайн арқылы бағалау – жұмыстың келесі, практикалық құндылығын күшейтетін міндетті кезеңі болып табылады.

Қаржыландыру туралы ақпарат: Мақала 2025-2027 жылдарға арналған «Жас ғалым» жобасы бойынша гранттық қаржыландыру аясында жазылды. Зерттеуді Қазақстан Республикасы Ғылым және жоғары білім министрлігінің Ғылым комитеті қаржыландырды (AP25796073).

ӘДЕБИЕТТЕР:

1 Macfadyen L.P., Dawson S. Mining LMS data to develop an “early warning system” for educators: A proof of concept [Text] / L. P. Macfadyen, S. Dawson // *Computers & Education*. – 2010. – Т. 54. – № 2. – P. 588–599. DOI: <https://doi.org/10.1016/j.compedu.2009.09.008>.

2 Long P., Siemens G. Penetrating the Fog: Analytics in Learning and Education [Text] / P. Long, G. Siemens // *EDUCAUSE Review*. – 2011. – Т. 46. – № 5. – P. 31-40.

3 Arnold K.E., Pistilli M.D. Course Signals at Purdue: Using learning analytics to increase student success [Text] / K.E. Arnold, M.D. Pistilli // *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (LAK '12)*. – 2012. – P. 267-270. DOI: <https://doi.org/10.1145/2330601.2330666>.

4 Jayaprakash S.M., et al. Early Alert of Academically At-Risk Students: An Open Source Analytics Initiative [Text] / S. M. Jayaprakash, et al. // *Journal of Learning Analytics*. – 2014. – Т. 1. – № 1. – P. 6-47. DOI: <https://doi.org/10.18608/jla.2014.11.3>.

5 Papamitsiou Z., Economides A. A. Learning Analytics and Educational Data Mining in Practice: A Systematic Literature Review of Empirical Evidence [Text] / Z. Papamitsiou, A.A. Economides // *Educational Technology & Society*. – 2014. – Т. 17. – P. 49-64.

6 Kloft M., Stiehler F., Zheng Z., Pinkwart N. Predicting MOOC dropout over weeks using machine learning methods [Text] / M. Kloft, F. Stiehler, Z. Zheng, N. Pinkwart // *Proceedings of the EMNLP*

2014 Workshop on Analysis of Large Scale Social Interaction in MOOCs. – 2014. – P. 60-65. DOI: <https://doi.org/10.3115/v1/W14-4111>.

7 Knowles J.E. Of Needles and Haystacks: Building an Accurate Statewide Dropout Early Warning System in Wisconsin [Text] / J.E. Knowles // *Journal of Educational Data Mining*. – 2015. – Т. 7. – № 3. – P. 18-67. DOI: <https://doi.org/10.5281/zenodo.3554725>.

8 Baker R., Lindrum D., Lindrum M.J., Perkowski D. Analyzing Early At-Risk Factors in Higher Education e-Learning Courses [Text] / R. Baker, D. Lindrum, M. J. Lindrum, D. Perkowski // *Proceedings of the 8th International Conference on Educational Data Mining (EDM 2015)*. – 2015. – P. 150-155.

9 Xing W., Chen X., Stein J., Marcinkowski M. Temporal prediction of dropouts in MOOCs: reaching the low hanging fruit through stacking generalization [Text] / W. Xing, X. Chen, J. Stein, M. Marcinkowski // *Computers in Human Behavior*. – 2016. – Т. 58. – P. 119-129. DOI: <https://doi.org/10.1016/j.chb.2015.12.007>.

10 Aulck L., Velagapudi N., Blumenstock J., West J. Predicting Student Dropout in Higher Education [Text] / L. Aulck, N. Velagapudi, J. Blumenstock, J. West // *arXiv*. – 2016. – arXiv:1606.06364. DOI: <https://doi.org/10.48550/arXiv.1606.06364>.

REFERENCES:

1. Macfadyen L.P., Dawson S. Mining LMS data to develop an “early warning system” for educators: A proof of concept. *Computers & Education*, 2010, vol. 54, no. 2, pp. 588-599. <https://doi.org/10.1016/j.compedu.2009.09.008>.

2. Long P., Siemens G. Penetrating the Fog: Analytics in Learning and Education. *EDUCAUSE Review*, 2011, vol. 46, no. 5, pp. 31-40.

3. Arnold K.E., Pistilli M.D. Course Signals at Purdue: Using learning analytics to increase student success. *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (LAK '12)*, 2012, pp. 267-270. <https://doi.org/10.1145/2330601.2330666>.

4. Jayaprakash S.M., et al. Early Alert of Academically At-Risk Students: An Open Source Analytics Initiative. *Journal of Learning Analytics*, 2014, vol. 1, no. 1, pp. 6-47. <https://doi.org/10.18608/jla.2014.11.3>.

5. Papamitsiou Z., Economides A. A. Learning Analytics and Educational Data Mining in Practice: A Systematic Literature Review of Empirical Evidence. *Educational Technology & Society*, 2014, vol. 17, pp. 49-64.

6. Kloft M., Stiehler F., Zheng Z., Pinkwart N. Predicting MOOC dropout over weeks using machine learning methods. *Proceedings of the EMNLP 2014 Workshop on Analysis of Large Scale Social Interaction in MOOCs*, 2014, pp. 60-65. <https://doi.org/10.3115/v1/W14-4111>.

7. Knowles J.E. Of Needles and Haystacks: Building an Accurate Statewide Dropout Early Warning System in Wisconsin. *Journal of Educational Data Mining*, 2015, vol. 7, no. 3, pp. 18-67. <https://doi.org/10.5281/zenodo.3554725>.

8. Baker R., Lindrum D., Lindrum M.J., Perkowski D. Analyzing Early At-Risk Factors in Higher Education e-Learning Courses. *Proceedings of the 8th International Conference on Educational Data Mining (EDM 2015)*, 2015, pp. 150-155.

9. Xing W., Chen X., Stein J., Marcinkowski M. Temporal prediction of dropouts in MOOCs: reaching the low hanging fruit through stacking generalization. *Computers in Human Behavior*, 2016, vol. 58, pp. 119-129. <https://doi.org/10.1016/j.chb.2015.12.007>.

10. Aulck L., Velagapudi N., Blumenstock J., West J. Predicting Student Dropout in Higher Education. *arXiv*, 2016, arXiv:1606.06364, pp. 16-20. <https://doi.org/10.48550/arXiv.1606.06364>.

Авторлар туралы мәліметтер:

Рахметов Максот Елеусизович – PhD, «Информатика» кафедрасының қауымдастырылған профессоры, Х. Досмұхамедов атындағы Атырау университеті, Қазақстан Республикасы, 000006, Атырау қ., Баймұханов көш. 17, тел.: 87756408814; e-mail: maksot.raxmetov.96@mail.ru.

Куанбаева Баян Улжағалиевна* – педагогика ғылымдарының кандидаты, «Физика және техникалық пәндер» кафедрасының профессоры, Х. Досмұхамедов атындағы Атырау университеті, Қазақстан Республикасы, 000006, Атырау қ., Геолог 1 ы/а, №1 үй, тел.: 87025001069, e-mail: Bayan_Kuanbaeva@mail.ru.

Рахметов Максот Елеусизович – PhD, ассоциированный профессор кафедры информатики, Атырауский университет имени Х. Досмұхамедова, Республика Казахстан, 000006, г. Атырау, ул. Баймұханова 17, тел.: 87756408814, e-mail: maksot.raxmetov.96@mail.ru.

Куанбаева Баян Улжағалиевна* – кандидат педагогических наук, профессор кафедры физики и технических дисциплин, Атырауский университет имени Х. Досмұхамедова, Республика Казахстан, 000006, г. Атырау, мкр. Геолог, №1, тел.: 87025001069, e-mail: Bayan_Kuanbaeva@mail.ru.

Rakhmetov Maxot Yeleussizovich – PhD, Associate Professor of the Department of computer science, Kh.Dosmukhamedov Atyrau University, Republic of Kazakhstan, 000006, Atyrau, 17 Baimukhanov Str., tel.: 87756408814, e-mail: maksot.raxmetov.96@mail.ru.

Kuanbayeva Bayan Ulzhagaliyevna – Candidate of Pedagogical Sciences, Professor of the Department of physics and technical disciplines, Kh.Dosmukhamedov Atyrau University, Republic of Kazakhstan, 000006, Atyrau, Geolog microdistrict no. 1, tel.: 87025001069, e-mail: Bayan_Kuanbaeva@mail.ru.*

МРНТИ 14.35.01

УДК 378.145

<https://doi.org/10.52269/SRDG2612250>

ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ ВОКАЛЬНО-ИСПОЛНИТЕЛЬСКОЙ ПОДГОТОВКИ БАКАЛАВРОВ МУЗЫКАЛЬНОГО ОБРАЗОВАНИЯ НА ОСНОВЕ СИГНАТУРНОЙ ПЕДАГОГИКИ ШУЛЬМАНА В ФОРМАТЕ SPOC: МЕТОДОЛОГИЧЕСКИЙ АСПЕКТ

Рахметов Т.Б. – PhD докторант, Казахский национальный педагогический университет им. Абая, г. Алматы, Республика Казахстан.

Момбек А.А. – кандидат педагогических наук, ассоциированный профессор кафедры музыкального образования, Казахский национальный педагогический университет им. Абая, г. Алматы, Республика Казахстан.*

Баймухамбетова Б.Ш. – PhD, ассоциированный профессор кафедры педагогического образования и менеджмента, Восточно-Казахстанский университет им. С. Аманжолова, г. Усть-Каменогорск, Республика Казахстан.

Султанова Ж.С. – PhD, старший преподаватель кафедры музыкального образования, Казахский национальный педагогический университет им. Абая, г. Алматы, Республика Казахстан.

В данной статье представлены результаты оценки эффективности вокально-исполнительской подготовки бакалавров музыкального образования на основе сигнатурной педагогики Шульмана в формате SPOC. Актуальность исследования обусловлена необходимостью поиска педагогических подходов, способствующих повышению качества вокально-исполнительской деятельности будущих учителей музыки. В фокусе научного исследования рассмотрены следующие вопросы: восприятие студентами бакалавриата музыкального образования традиционной формы вокально-исполнительской подготовки; разработка онлайн-курса в формате SPOC, интегрирующего фундаментальные принципы сигнатурной педагогики Шульмана, а также оценка его эффективности. Для этого использовались следующие методы: анкетирование, количественно-качественный метод, сравнительный анализ средних значений, дисперсионный анализ ANOVA. Результаты свидетельствовали о повышении академических показателей обучающихся и значительном развитии их вокально-исполнительских компетенций. Однако значительных различий в выраженности мотивации к учебной деятельности среди студентов, обучавшихся в электронном формате, на основе сигнатурной педагогики Шульмана и традиционной формы обучения выявлено не было. Вместе с тем, полученные результаты расширяют теоретическую базу, необходимую для дальнейших научных исследований в области влияния факторов на имплицитный уровень фундаментальных составляющих сигнатурной педагогики Шульмана с применением цифровых технологий. Проведенное исследование вносит теоретический вклад в решение вопросов обеспечения качества профессиональной подготовки бакалавров музыкального образования.

Ключевые слова: вокально-исполнительская подготовка, сигнатурная педагогика Шульмана, онлайн-курс, музыкальное образование, традиционная форма подготовки.

ШУЛЬМАННЫҢ СИГНАТУРАЛЫҚ ПЕДАГОГИКАСЫ НЕГІЗІНДЕ МУЗЫКАЛЫҚ БІЛІМ БАКАЛАВРЛАРЫНЫҢ ВОКАЛДЫҚ-ОРЫНДАУШЫЛЫҚ ДАЯРЛЫҒЫНЫҢ ТИІМДІЛІГІН SPOC ФОРМАТЫНДА ЗЕРТТЕУ: ӘДІСНАМАЛЫҚ АСПЕКТ

Рахметов Т.Б. – PhD докторанты, Абай атындағы Қазақ ұлттық педагогикалық университеті, Алматы қ., Қазақстан Республикасы.

Момбек А.А. – педагогика ғылымдарының кандидаты, музыкалық білім беру кафедрасының қауымдастырылған профессоры, Абай атындағы Қазақ ұлттық педагогикалық университеті, Алматы қ., Қазақстан Республикасы.*

Баймұхамбетова Б.Ш. – PhD, педагогикалық білім және менеджмент кафедрасының қауымдастырылған профессоры, С. Аманжолов атындағы Шығыс Қазақстан университеті, Өскемен қ., Қазақстан Республикасы.

Султанова Ж.С. – PhD, музыкалық білім беру кафедрасының аға оқытушысы, Абай атындағы Қазақ ұлттық педагогикалық университеті, Алматы қ., Қазақстан Республикасы.