

https://doi.org/10.51885/3134-8025_IJCS_2026_1_9

MPHTI 14.35.07

ПОВЫШЕНИЕ НАДЕЖНОСТИ ПРОГНОЗИРОВАНИЯ ОБРАЗОВАТЕЛЬНЫХ ТРАЕКТОРИЙ РЕКОМЕНДАТЕЛЬНОЙ СИСТЕМОЙ, ОБЪЕДИНЯЮЩЕЙ АКАДЕМИЧЕСКИЕ И МОТИВАЦИОННЫЕ ПРОФИЛИ

АКАДЕМИЯЛЫҚ ЖӘНЕ МОТИВАЦИЯЛЫҚ ПРОФИЛЬДЕР ДІ БІРІКТІРЕТІН ҰСЫНЫС БЕРУ ЖҮЙЕСІНІҢ БІЛІМ БЕРУ ТРАЕКТОРИЯЛАРЫН БОЛЖАУ СЕНІМДІЛІГІН АРТТЫРУ

INCREASING THE RELIABILITY OF PREDICTING EDUCATIONAL TRAJECTORIES BY A RECOMMENDATION SYSTEM THAT UNITES ACADEMIC AND MOTIVATIONAL PROFILES

Г.В. Попова ^{1*}, Ю.А. Вайс ¹, И.А. Котлярова ¹,

Г. Жомартқызы ¹, Н.П. Рохас Криулько ¹

¹Восточно-Казахстанский технический университет имени Д. Серикбаева,
г. Усть-Каменогорск, Казахстан

*Автор-корреспондент: Попова Галина Владимировна, gpopova@edu.ektu.kz

Ключевые слова:

Гибридная
рекомендательная
система, академический
профиль,
мотивационный
профиль, совместная
фильтрация,
прогнозирование
образовательных
траекторий, Minog-
программа.

АННОТАЦИЯ

Настоящее исследование связано с тем, что традиционные рекомендательные системы демонстрируют не очень высокую точность выбора курсов. В центре внимания данного исследования было построение и эмпирическое обоснование использования предложенной рекомендательной системы. Исследование направлено на создание рекомендательной системы и ее проверку для прогнозирования образовательных траекторий IT-специальностей ВКТУ.

Для решения задачи исследования применялась матричная факторизация при моделировании академического профиля обучающихся. Параллельно создан мотивационный вектор, строящийся на базе психометрического моделирования RIASEC. Результаты двух прогностических компонент были объединены через линейную взвешенную комбинацию, при этом коэффициент в этой комбинации оптимизирован методом Grid Search. Оценка точности и стабильности выполнена с использованием пятикратной кросс-валидации и ключевых метрик.

Найденное значение коэффициента $\alpha=0.58$ дало оптимальные параметры нашей системы. При данном коэффициенте получились наибольшая точность прогноза и самая низкая ошибка. Наша модель продемонстрировала значительную стабильность результатов.



Исследование подтверждает, что построенная в нашей системе комбинация академического и мотивационного профилей может являться одной из компонент для разработки открытых и надежных рекомендательных систем.

Түйінді сөздер:

Гибридігі ұсыныс беру жүйесі, академиялық профиль, мотивациялық профиль, бірлескен сүзгілеу, білім беру траекториясын болжау, Minor-бағдарлама.

ТҮЙІНДЕМЕ

Бұл зерттеу дәстүрлі ұсыныс жүйелерінің курс таңдау дәлдігінің аса жоғары еместігін көрсетеді. Бұл зерттеудің басты бағыты ұсынылған ұсыныс беру жүйесін қолданудың құрылымы мен эмпирикалық негіздеме болды. Зерттеудің мақсаты – ұсыныс беру жүйесін құру және оны ШҚТУ IT мамандықтарының білім беру траекторияларын болжау үшін тексеру.

Зерттеу мәселесін шешу үшін білім алушылардың академиялық профилін модельдеуде матрицалық факторизация қолданылды. RIASEC психометриялық модельдеуіне негізделген мотивациялық вектор параллель түрде жасалды. Екі болжамдық компоненттің нәтижелері сызықтық салмақталған комбинация арқылы біріктірілді, ал бұл комбинациядағы коэффициент Grid Search әдісімен оңтайландырылды. Дәлдік пен тұрақтылықты бағалау бес еселі кросс-валидация және негізгі метрикаларды қолдану арқылы жүргізілді.

Табылған $\alpha=0,58$ коэффициент мәні ұсынылған жүйенің оңтайлы параметрлерін берді. Бұл коэффициентте ең жоғары болжам дәлдігі және ең төменгі қателік алынды. Ұсынылған модель нәтижелердің айтарлықтай тұрақтылығын көрсетті. Зерттеу ұсынылған жүйеде енгізілген академиялық және мотивациялық профильдердің комбинациясы ашық және сенімді ұсыныс беру жүйелерін әзірлеу кезінде компоненттердің бірі бола алатынын растайды.

Keywords:

Hybrid recommendation system, academic profile, motivational profile, collaborative filtering, educational trajectory prediction, minor program

ABSTRACT

The present study is due to the fact that traditional recommendation systems demonstrate not very high course selection accuracy. The focus of the present study was the construction and empirical validation of the use of the proposed recommender system. The study intended to build a recommendation system and test it for predicting the educational trajectories of IT majors of VKTU.

To address the research problem, matrix factorization was applied in modeling the academic profile of the learners. A motivational vector building on the RIASEC psychometric modeling was created in parallel. The results of the two predictive components were combined through a linear weighted combination, whereas the coefficient in this combination was optimized by the Grid Search method. Accuracy and stability evaluation was performed using five-fold cross-validation and key metrics.

The found coefficient value of $\alpha=0.58$ gave the optimal parameters of our system. At this coefficient, the highest prediction accuracy and the lowest error were obtained. Our model demonstrated significant results stability. The study confirms that the combination of academic and motivational profiles built into our system can be one of the components for developing open and reliable recommender systems.

ВВЕДЕНИЕ

Современное высшее образование переживает период глубокой трансформации. Этот факт отмечается во многих источниках. Отмечается отход учебных планов от старых

стандартов в смысле того, что происходит активный отход от жестко определенных и единых программ в пользу вариативных, модульных траекторий. Данные изменения в высшем образовании, в том числе и Казахстана, безусловно, продиктованы требованиями концепции «обучения в течение жизни» (lifelong learning) (Bonfield, D., 2025). Концепция, не имеющая на данный момент других более или менее хороших альтернативных вариантов, требует от будущих выпускников и работающих специалистов постоянного обучения и быстрого приобретения новых компетенций.

Программы Minor (мини-специализации), с учетом вышесказанного, выступают одним из важных инструментов реализации адаптивности и индивидуальности в вузах. Например, в ВКТУ, как и в других университетах Казахстана, их внедрение полностью соответствует Болонскому процессу и кредитно-модульной системе. Что это дает? Студенты получают возможность сформировать индивидуальный набор компетенций, который может быть при правильном подходе более востребованным на рынке труда. Полученные в результате знания и навыки значительно расширяют собственный профессиональный потенциал. Более того, часто именно выбор Minor-программы задает будущую карьерную траекторию, выступая прямым связующим звеном между базовым обучением и специализированной профессиональной деятельностью (Rocek M. et al, 2023).

В исследовании предлагается механизм рекомендаций, который основан на совместном учете личных предпочтений учащихся (при выборе Minor-ов) и академической успеваемости.

Потребность в таком исследовании диктуется необходимостью уменьшения рисков, связанных с неверным выбором этих дополнительных специализаций обучающимися. Мы полагаем, что этот выбор должен достигаться через сложный баланс двух наиболее важных, порой даже противоречащих друг другу компонентов. Во-первых, очевидно, что выбор должен, с одной стороны, обеспечивать востребованность навыков и полностью соответствовать академическому потенциалу обучающегося, который, как правило, объективно отражается в его успеваемости. Во-вторых, очень часто недооценивается, что выбор должен сбалансированно сочетаться с личными интересами и наклонностями. Только долговременная и искренняя заинтересованность в профессиональной сфере (а не только отличные оценки) дает основание для удовлетворенности и хорошей работоспособности в производственной деятельности (MA Thanh Trung Pham et al, 2025). В свою очередь, возможна комбинация неудачного сочетания отличной успеваемости с отсутствием интереса к изучаемым дисциплинам, которая приводит к подготовке некомпетентных специалистов, что негативно для экономики и является серьезной проблемой.

Таким образом, вытекает необходимость научно обоснованного объединения этих двух факторов как основной проблемы нашего исследования. На наш взгляд, главный пробел в научных исследованиях по данной теме заключается в том, что в настоящее время отсутствует достаточно хорошая модель. Такая модель помогла бы в процессе выбора адекватно, взвешенно соединять и оценивать не только успеваемость, но и личную заинтересованность в изучаемых дисциплинах. Сформированные на данный момент рекомендательные системы, используемые в высшем образовании, имеют недостатки. Они либо опираются на контентный анализ (в этом случае вообще не рассматривается успеваемость), либо строятся на коллаборативной фильтрации (тогда интерес обучающихся не учтен) (Vujang S. D. et al, 2021).

Исходя из этого, основная идея исследования состоит в разработке метода. Такой метод должен формировать более надежные и точные рекомендации для Minor-программ, чем в традиционных системах. При этом достижение поставленной цели исследования

может обеспечиться за счет комплексного соединения мотивированности и достаточно успешного освоения дисциплин.

Такой подход, возможно, может не учесть в полной мере всю сложность индивидуальных образовательных траекторий. Но в рамках цифровой трансформации образования такая разработка помогает сделать шаг к по-настоящему адаптивному и персонализированному обучению.

МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

Начнем исследование рекомендательных систем с выделения двух очень важных входных типов данных. Есть основание полагать, что именно эти данные наиболее точно описывают успешность обучения и в том числе последующую удовлетворенность обучающегося. Эти данные сформируют два отдельных и тем не менее согласованных прогностических ядра. Сфокусируем внимание на двух основных аспектах нашей модели. Первым аспектом является академический профиль (обозначим его как M_A). Этот профиль использует исключительно только фактические данные об успеваемости обучающихся. По сути, профиль M_A должен показывать потенциальную способность обучающегося к достижимым оценкам по новым дисциплинам. Такое предположение подтверждается рядом научных исследований (Сао Thi, Т.-Х., 2023). Вторым в нашем случае является мотивационный профиль (M_M). Чтобы его вычислить и построить воспользуемся психометрическим подходом. В этом подходе будем использовать модель RIASEC (профиль профессиональных интересов). Задача мотивации, на наш взгляд, дать наиболее близкую количественную оценку личной заинтересованности, а также совместимости обучающегося с конкретными Minor-программами (Yang, Z. et al., 2023). Разработка рекомендательной системы в строящейся модели линейно агрегирует данные этих двух профилей. Но при всем этом оценка каждого из профилей выполняется независимо друг от друга.

Далее рассмотрим архитектуру прогностических ядер. Для моделирования академического ядра (R_A) мы выбрали подход матричной факторизации (MF). Почему выбирается именно MF? Дело в том, что этот метод хорошо зарекомендовал себя при использовании во многих работах как один из самых полезных и точных инструментов. Причем именно там, где сталкиваемся с наиболее сильно и даже высоко разреженными данными, а в образовательных системах такой вариант вполне вероятен (Al-Ajmi, S. et al, 2024).

Для решения проблемы с высокой размерностью исходного пространства признаков (n – число анализируемых обучающихся, k – число основных курсов) еще и снижения коллинеарности оценок, мы применим сингулярное разложение матрицы (SVD) к разреженной матрице оценок O ($n \times k$) (Пилявская И.М., 2022). Формула (1) показывает это:

$$O \approx U \Sigma V^T, \quad (1)$$

здесь O – это матрица оценок; U – матрица скрытых факторов $n \times l$; Σ – диагональная матрица сингулярных чисел $l \times l$; а V^T – матрица $l \times k$.

На основе двух векторов (u_A и u_M), характеризующих обучающихся, мы будем строить общий вектор профиля обучающегося u_T путем их простого объединения, как это показано в (2). Построенные векторы будут нашими общими входными данными:

$$u_T = [u_A \circ u_M]. \quad (2)$$

Строящаяся для определения ранжирования Minor-дисциплин модель образуется двумя независимыми друг от друга прогностическими компонентами. Одна из компонент предназначена оценить желание обучающегося к освоению каждой из Minor-программ. Эту компоненту или ядро в дальнейшем будем называть мотивационной моделью (M_M).

Модель предназначена для выявления закономерностей, которые согласуются с выявленными предпочтениями обучающихся на анализируемом наборе Minor. В случае мотивационной модели задача не линейная и FNN хорошо подходит для такого типа прогнозов (Jawed Liu et al, 2022). Данные для нейросети в нашем случае формируем как составной вектор z . Первая часть вектора несет в себе данные мотивации обучающегося u_M . Вторая часть i_C содержит информацию описания дисциплин, ключевые слова, набор результатов обучения и компетенций по предметам Minor. Это отражено в формуле:

$$z = [u_M \circ i_C]. \quad (3)$$

Такое сочетание данных учтет информацию о Minor-программах и индивидуальность обучающегося в рамках интереса к изучению этих программ. Для нормализации итога этой модели в выходном слое используется функция активации сигмоида. Она приводит значения в диапазон от 0 до 1 за счет масштабирования данных. Формула значения $P_M(u, i)$ показывает нам вероятность того, насколько удовлетворен u -й обучающийся i -ой Minor-программой (здесь три скрытых слоя ReLU):

$$P_M(u, i) = \sigma(W_3 \cdot \text{ReLU}(W_2 \cdot \text{ReLU}(W_1 \cdot z + b_1) + b_2) + b_3), \quad (4)$$

здесь W_k – матрицы весов, b_k – векторы смещений. В обучении модели мы использовали функцию потерь бинарной кросс-энтропии.

Вторая часть нашей модели M_A (академическое ядро) дает возможность рассчитать наиболее вероятную оценку освоения по окончанию программ (Lee H. et al ,2024). По формуле 5 вычисляем предсказание для учащегося u и программы i :

$$\hat{r}_{ui} = b_u + b_i + \sum_{j=1}^l p_{uj} q_{uj}, \quad (5)$$

где p_{uj} и q_{uj} – скрытые искомые закономерности. В этой формуле учтены смещения b_u и b_i .

Как всегда, в таком типе обучения минимизируется функция потерь $L(P, Q, b)$ стохастическим градиентным спуском с L_2 -регуляризацией. Само уравнение для потерь выражается как формула:

$$L(P, Q, b) = \sum_{(u,i) \in R} (\hat{r}_{ui} - r_{ui})^2 + \varphi(\|P\|^2 + \|Q\|^2 + \|b\|^2), \quad (6)$$

Хочется обратить внимание на тот факт, что первое слагаемое в (6) представляет собой измерение ошибки прогноза. Второе слагаемое в (6) выполняет роль ограничения, чтобы предотвратить чрезмерное переобучение модели. Тут $\|\dots\|^2$ является L_2 -нормой, и, соответственно, штраф применяется ко всем обучаемым параметрам модели. Гиперпараметр φ отвечает за силу штрафа, чем выше φ , тем проще и быстрее модель обучается. При низких значениях φ модель может переобучиться.

Чтобы результаты \hat{r}_{ui} можно было сопоставить между собой, проводится масштабирование за счет нормализации Min-Max (по формуле 7). В этом случае получаемая оценка академического потенциала $P_A(u, i)$ будет находиться в диапазоне от 0 до 1. Это, по нашему мнению, является важным фактором для дальнейшего объединения компонент в рекомендательную модель:

$$P_A(u, i) = \frac{\hat{r}_{ui} - \hat{r}_{min}}{\hat{r}_{max} - \hat{r}_{min}}. \quad (7)$$

Линейно взвешенная комбинация этих нормированных компонент построенной модели позволит создавать разнообразные отсортированные по приоритету списки. $R(u, i)$ показывает такую оценку i -ой программы для u -го обучающегося:

$$R(u, i) = \alpha \cdot P_A(u, i) + (1 - \alpha) \cdot P_M(u, i). \quad (8)$$

Коэффициент α дает возможность сбалансировать $P_A(u, i)$ и $P_M(u, i)$ в модели за счет его изменения в интервале $[0, 1]$. На независимом наборе данных будем применять поиск по сетке (Grid Search). Метрика ранжирования $NDCG@k$ при достижении своего наибольшего из всех значений при этом даст нам оптимальное число α . Сама метрика $NDCG@k$ рассчитывается по формуле (Choi, S.-M. et al, 2023):

$$NDCG@k = \frac{DCG@k}{IDCG@k} \quad (9)$$

тут $IDCG@k$ выступает как эталонное ранжирование, которое позволяет нормализовать $DCG@k$. В свою очередь $DCG@k$ является фактором совмещающим позицию в списке с оценкой его семантического соответствия.

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Перед внедрением в информационную систему университета предложенного подхода требуется эмпирическая проверка.

Проверим гипотезу нашего исследования: эффективней ли рекомендательная модель $R(u, i)$ в рекомендательной системе дает прогнозы, чем каждая из моделей $P_A(u, i)$ и $P_M(u, i)$ в отдельности. Данные об успеваемости будем брать за первые два курса, так как Minor изучаются, начиная с третьего курса обучения. Мотивационный профиль создается для тех же самых обучающихся.

Для аналитической проверки информационную базу составили по ОП «Информационные системы» и «Вычислительная техника», выгруженные из образовательного портала ВКТУ им. Д.Серикбаева за период с 2018 по 2023 годы. Для анализа нам было необходимо, чтобы обучающиеся закончили Minor-программы на третьем и четвертом курсах, чтобы получить корректные данные. Именно поэтому последним для исследования был взят 2023 год обучения. Таким образом, единицей наблюдения для исследования является индивидуальный профиль обучающегося. Общий объем выборки 517 индивидуальных профилей обучающихся и 14 программ Minor. Согласно рабочим планам взятых образовательных программ на первом и втором курсах изучались по 42 дисциплины в каждой. В этом наборе данных мы не исключали те дисциплины, которые, на первый взгляд, почти не влияют на профильный успех — например, «Физическая культура» и «Основы антикоррупционной культуры». Также в информационную базу входят дисциплины, которые коррелируют с некоторыми из Minor — например, предметы «Алгоритмы, структуры данных и программирование», «Технология программирования».

В результате первичной обработки выяснилось, что в получившемся наборе данных матрица взаимодействий оказалась разреженной на 89,7 %. Такой высокий показатель не дает возможности хорошего предсказания классическим системам фильтрации (Man Li et al, 2021). В таких случаях это является приговором для такого рода систем, что еще раз показывает важность нашего подхода.

Основной задачей в нашем анализе стала оптимизация весового коэффициента α в формуле 8 линейно взвешенной комбинации нашей модели. Именно он создает баланс, регулируя интерес к программе обучающегося как субъекта и отражая его успехи объективными результатами оценивания. Для получения объективного и надежного численного результата поиска глобального оптимума использован метод поиска по сетке Grid Search с применением пятикратной перекрестной проверки. Поиск осуществлялся в диапазоне $\alpha \in [0, 1]$ с шагом 0,01. В качестве метрик для оценки качества ранжирования взяли $NDCG@10$, так как она наиболее часто используется в такого рода исследованиях по сортировке списков по приоритетам. Как наглядно демонстрирует рисунок 1 оптимальное значение метрики (наибольшее ее значение) находится в диапазоне значений

коэффициента $\alpha = 0,58 \pm 0,1$, при этом пиковое значение NDCG@10 будет при $\alpha = 0,58$. А это говорит о необходимости учета обоих факторов.

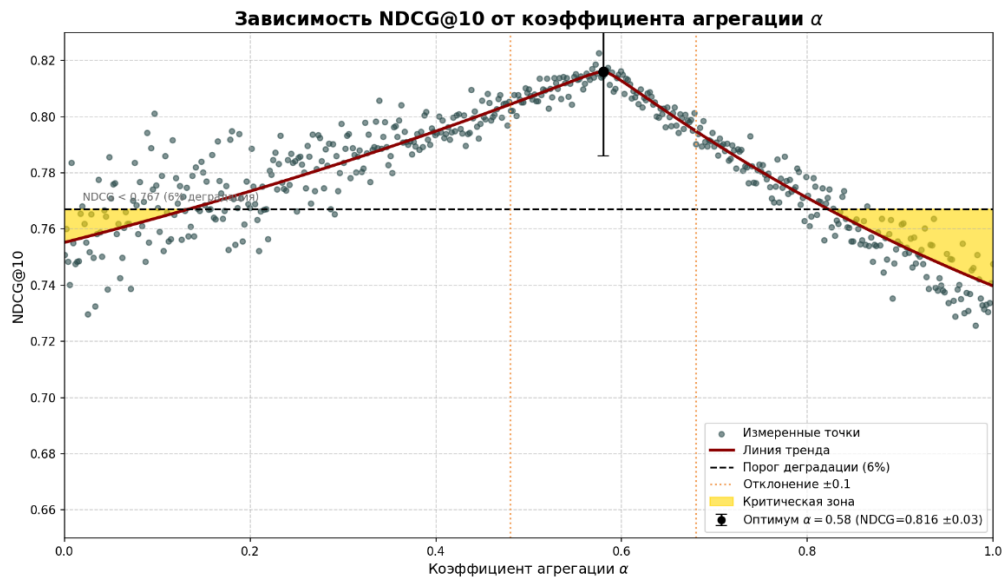


Рисунок 1. Зависимость точности NDCG@10 от весового коэффициента α

Примечание – составлено авторами

При вкладе примерно в 58 % от академической и в 42 % от мотивационной модели можно ожидать от нашей модели демонстрации наиболее точной оценки прогноза. Здесь мы еще можем отметить и тот факт, что метрика NDCG@10 сильно снижается при изменении коэффициента даже в диапазоне около $\pm 0,1$ от найденного значения. Этот факт говорит о том, что найден критический диапазон значения коэффициента α .

В таблицу 1 сведены аналитические данные показателей точности и ошибок работы моделей по отдельности и совместной рекомендательной модели. В таблице в первой строке включен вариант, когда Minog-программа выбирается случайным образом. Такая модель нам нужна для показания границы, когда точность прогноза будет наименьшей. То есть модель, в которой есть хоть какая-нибудь логика выбора, должна превосходить по точности прогноза случайную.

Таблица 1. Метрики моделей

Модель	Методология	NDCG@10	MAP@10	RMSE	MAE	Оценка
Случайное ранжирование	Baseline	0,403	0,356	1,32	0,96	наименьшая точность
M_A (базовая)	SVD	0,723	0,684	0,87	0,68	плохая точность при недостаточных данных
M_M (мотивационная)	FNN, $u_m \circ i_c$	0,649	0,607	0,96	0,82	устойчивая
$R(u, i)$ (рекомен – дательная)	линейно взвешенная комбинация $\alpha = 0,58$	0,816	0,758	0,69	0,53	лучший вариант по параметрам прогноза и точности

Примечание – составлено авторами

Из полученных нами аналитических данных в таблице 1 видно, что рекомендательная модель дает наибольшую точность метрик из всех моделей и самую малую ошибку $RMSE$. Прирост точности построенной нами модели по сравнению с базовой академической моделью по метрике $NDCG@10$ в 12,9 % оказался значительным. Можно отметить еще и низкие значения ошибок прогноза у обеих моделей по сравнению с другими, хотя у построенной в нашем исследовании модели она меньше. Рис. 2 наглядно показывает, что лучшие показатели у построенной модели.

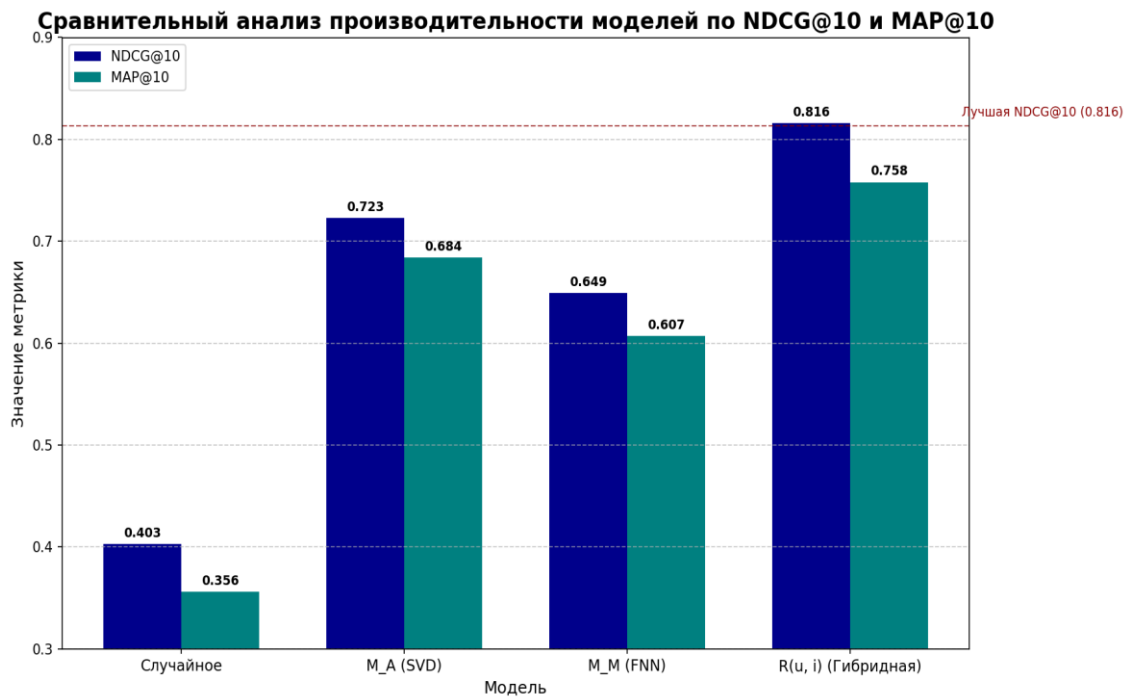


Рисунок 2. Анализ показателей моделей по метрикам $NDCG@10$ и $MAP@10$

Примечание – составлено авторами

Рассмотрим показатели метрик MAP и $NDCG$ при разных значениях количества дисциплин k в приоритетном списке и сведем их в таблицу. В эксперименте из таблицы можно увидеть, что наибольшее значение прогнозных оценок нахождения оптимальной $Minop$ -программы получается именно для построенной в исследовании модели. Значение в 0,843 показывает высокий шанс в списке первых 5 программ найти нужную.

Таблица 2. Детализация метрик $NDCG$ и MAP по уровню ранжирования k

Модель	$NDCG@5$	$NDCG@10$	$NDCG@15$	$MAP@5$	$MAP@10$
M_A	0,756	0,723	0,712	0,703	0,684
M_M	0,687	0,649	0,638	0,632	0,607
$R(u, i)$	0,843	0,816	0,798	0,781	0,758

Примечание – составлено авторами

Некоторые данные обучающихся на первых двух курсах по образовательным программам ИТ плохо связаны с $Minop$ -программами, так как на этих курсах большая часть дисциплин - это общеобразовательные дисциплины (например, «Физическая культура»). Из-за таких дисциплин модель SVD в сценарии «холодного старта» показывает скромную

точность в 0,590. В отличие от академического ядра, мотивационное тем не менее сохраняет прежний уровень точности. Именно за счет этого рекомендательная система показывает точность прогнозного значения 0,776. Такой результат говорит о том, что точность построенной рекомендательной системы на 31,53% лучше, чем просто прогноз базовой модели. Это позволяет давать вполне надежные рекомендации по выбору программ до того, как обучающиеся освоят базовые дисциплины, связанные с программированием (например, такие как «Технология программирования», «Алгоритмы, структуры данных и программирование»). График на рисунке 3 демонстрирует устойчивость рекомендательной системы.

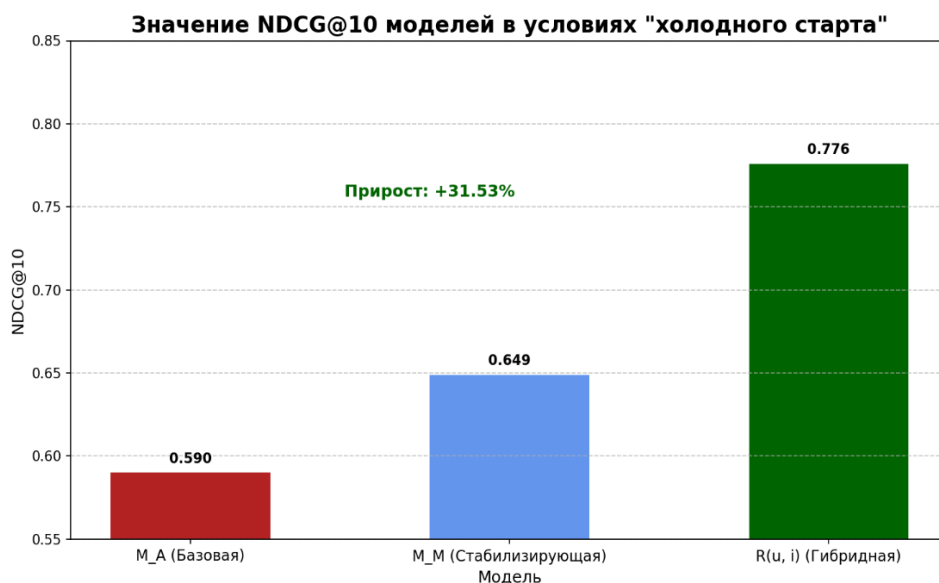


Рисунок 3. График значений точности прогноза моделей в условиях «холодного старта»
Примечание – составлено авторами

Рассчитанные в результате анализа значения показывают связь между $RMSE$ и $RIASEC$. Из вычислений следует, что если высокая ($>0,85$) мотивация по $RIASEC$, то снижается до 0,63 ошибка прогноза $RMSE$. И наоборот, низкий ($<0,40$) интерес к сфере приводит к увеличению ошибки до 0,93. Таким образом, мотивация – это не просто учет индивидуальных интересов обучающихся, а реальный фактор снижения рисков. Мотивация, таким образом, показывает и здесь, что она является значимым фактором, который способствует гарантированному успешному окончанию Minog-программы при длительном использовании.

На последнем этапе исследования проведена проверка устойчивости с использованием тестирования модели пятикратной кросс-валидацией. Вариация всего в 2,27 % построенной рекомендательной системы 5,35% почти в два раза меньше, чем у базовой модели SVD (табл. 3).

Таблица 3. Результаты тестирования по пятикратной кросс-валидации

Модель	Средний $NDCG@10$	Доверительный интервал (95%)	Коэффициент вариации (%)
M_A	0,723	$\pm 0,048$	5,35
$R(u, i)$	0,816	$\pm 0,023$	2,27

Примечание – составлено авторами

Значения в таблице говорят о предсказуемости и стабильности нашей системы. Лучшие результаты прогноза в плане ошибки система демонстрирует на близких к ИТ узкопрофильных технических дисциплинах (например, Minor-программа 11 «Горная квалиметрия», «Беспилотники в горнодобывающем секторе», «Геотехнология» $RMSE$ около 0,61). В свою очередь, для гуманитарных программ (Minor-программы 1 «Академическое письмо», «Английский для специальных целей», «Базовый иностранный на выбор») ошибка чуть выше, около 0,77. В целом для найденного значения весового коэффициента $\alpha = 0,58$ построенная модель дает низкую ошибку и хорошую точность прогноза рекомендательной системой.

Полученные результаты говорят о высоком качестве построенной модели. Но, тем не менее, есть вероятность, что со временем могут измениться предпочтения у конкретного обучающегося. А это в свою очередь со временем влияет на достоверность рекомендаций.

ЗАКЛЮЧЕНИЕ

Проведенное исследование показало решение поставленной задачи построения рекомендательной системы, объединяющей мотивационный и академические профили на примере обучающихся по образовательным программам ИТ. Такая система, как показал анализ, оказалась более надежной и точной в плане рекомендаций для изучения Minor-программ как мини специализаций. На наш взгляд, основным результатом исследования является успешная апробация построенной рекомендательной системы $R(u, i)$. Причем система учитывает как полученные оценки по всем дисциплинам, изучаемым на первых двух курсах, так и личные предпочтения при выборе из представленного списка Minor-программ.

Эксперименты в рамках данного исследования аналитически показали важность учета и личного интереса и прошлых оценок, полученных в процессе учебы. Об этом говорит соотношение 0,58 к 0,42 (академической модели к мотивационной), полученное при поиске оптимального весового коэффициента. На основании этого соотношения можно сделать вполне аргументированный вывод, что мотивация вносит в прогнозный результат ненамного меньше, чем академическая составляющая. Анализ метрик $NDCC@10$ и $RMSE$ также подтверждает это положение. Значения этих метрик оказались гораздо лучше в построенной в рамках исследования модели, чем в моделях, которые игнорируют интересы обучающихся.

Особенность предложенного подхода - это использование дополнительно профиля мотивированности обучающихся $RIASEC$, в отличие от распространенных гибридных систем, основанных на анализе ключевых слов и демографических характеристик (Burke, R., 2002.; Dierks P.O. et al, 2016). Такое использование сделало модель $R(u, i)$ более стабильной. Об этом говорит коэффициент вариации, принимающий низкое значение 2,27% для нашей модели. Еще одним плюсом в пользу предложенного решения стало то, что модель решила проблему «холодного старта». Такая проблема для простых алгоритмов обычно неразрешима.

Полученные рекомендации построенной нами системы следует понимать как вспомогательную информацию для принятия решения в выборе, а не как обязательный к выполнению план.

В дальнейших исследованиях одним из актуальных направлений будет настройка мотивационного ядра P_M . Такая настройка на соответствующих данных может позволить улучшить прогностическую способность модели для, например, гуманитарных образовательных программ. Можно также изучить динамическое изменение весового коэффициента α в зависимости от курса обучающегося.

Подводя итог, можно с уверенностью говорить о том, что предложенная модель $R(u, i)$ показала себя как прозрачный, надежный и очень эффективный инструмент. Полученное нами решение практически значимо. Оно помогает обеспечить обучающихся персонализированными рекомендациями. Для консультантов решение будет полезно в плане обоснования рекомендаций. Администрация университета получает пользу от такого решения в плане более осмысленного управления образовательным процессом.

КОНФЛИКТ ИНТЕРЕСОВ: Авторы заявляют об отсутствии конфликта интересов.

СПИСОК ЛИТЕРАТУРЫ

- Al-Ajmi, S. et al. (2024). Hybrid attribute-based recommender system for personalized e-learning with emphasis on cold start problem. *Frontiers in Computer Science*, Vol. 6. <https://doi.org/10.3389/fcomp.2024.1404391>.
- Burke, R. (2002). Hybrid Recommender Systems: Survey and Experiments. *User Modeling and User-Adapted Interaction*, 12, 331-370. <https://doi.org/10.1023/A:1021240730564>.
- Bujang S. D., Selamat A., Ibrahim R., Krejcar O., Herrera-Viedma E. Fujita, H., Ghani, N. A. Multiclass prediction model for student grade prediction using machine learning, *IEEE Access*, vol. 9, pp. 95608-95621, 2021, <https://doi.org/10.1109/ACCESS.2021.3093563>.
- Bonfield, D., Hassan, M.G., Palmieri, J.M. (2025). Integration of Professional Skills (Communications, Teamwork, Etc.), Ethics, Empathy Lifelong Learning into the Student's Educational Experiences. In: Kandakatla, R., Kulkarni, S., Auer, M.E. (eds) *Academic Leadership in Engineering Education. Lecture Notes in Networks and Systems*, vol 1097. Springer, Cham. <https://doi.org/10.1007/978-3-031-68282-7>.
- Dierks P.O., Höffler T.N., Blankenburg J.S., Peters H., & Parchmann I. (2016). Interest in science: A RIASECbased analysis of students' interests. *International Journal of Science Education*, 38, 238–258, <https://doi.org/10.1080/09500693.2016.1138337>.
- Cao Thi, T.-X. (2023). Singular value decomposition and applications in data processing and artificial intelligence. *HPU2 Journal of Science: Natural Sciences and Technology*, 2(3), 34–41. <https://doi.org/10.56764/hpu2.jos.2023.2.3.34-41>.
- Jawed Liu, Chuan Shi, Cheng Yang, Zhiyuan Lu, Philip S. Yu, (2022) A survey on heterogeneous information network based recommender systems: Concepts, methods, applications and resources, *AI Open*, 3, 40–57. <https://doi.org/10.1016/j.aiopen.2022.03.002>.
- Lee H., Cho S., Jiang Y., Kim J. Woo, H. (2021). Differentiable ranking metrics using relaxed sorting for top-k recommendation. *IEEE Access*, 9, pp.114649-114658. <https://doi.org/10.1109/access.2021.3105389>.
- Choi, S.-M., Lee, D., Jang, K., Park, C., & Lee, S. (2023). Improving Data Sparsity in Recommender Systems Using Matrix Regeneration with Item Features. *Mathematics*, 11(2), 292. <https://doi.org/10.3390/math11020292>.
- Man Li, Luosheng Wen, Feiyu Chen, (2020) A novel Collaborative Filtering recommendation approach based on Soft Co-Clustering. *Physica A: Statistical Mechanics and its Applications*, 561. 125140 pp. <https://doi.org/10.1016/j.physa.2020.125140>.
- MA Thanh Trung Pham , Thi Thanh Do , Thi Thanh Hai Dinh , Thi Thanh Van Nguyen , Kim Nguu (2025), *International Journal of Research and Innovation in Social Science (IJRISS)*, Vol. 9, Issue 05, Pages 4162-4175, <https://doi.org/10.47772/IJRISS.2025.905000317>.
- Rocek M., Juva V., Jakubcova K. Development of a Questionnaire Focused on Sports Coaches Learning (2023) *Studia Sportiva*, 17 (1), pp. 87 – 98. <https://doi.org/10.5817/STS2023-1-8>.
- Yang, Z. et al. (2023). Deep Learning and Embedding Based Latent Factor Model for Collaborative Recommender Systems. *Applied Sciences*, Vol. 13, No. 2. (MDPI). Open, Volume 3, 2022, Pages 40-57, ISSN 2666-6510, <https://doi.org/10.1016/j.aiopen.2022.03.002>.

Tursyn M.S. Role of artificial intelligence in sign language recognition. Herald of the Kazakh-British Technical University. 2025;22(1):94-102. <https://doi.org/10.55452/1998-6688-2025-22-1-94-102>.

Пилявская И.М. Разработка архитектуры гибридной рекомендательной системы для финансового ассистента // Universum: технические науки. – 2022. – № 5-2 (98). – С. 41–44. // Piliavskaia I.M. Razrabotka arkhitektury gibridnoi rekomendatel'noi sistemy dlia finansovogo assistenta [Development of the architecture of a hybrid recommender system for a financial assistant] // Universum: tekhnicheskie nauki. – 2022. – No. 5-2 (98). – P. 41–44. (In Russ.)

Авторлар туралы мәліметтер Информация об авторах Information about authors



Попова Галина Владимировна – физика-математика ғылымдарының кандидаты, «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ «Цифрлық технологиялар және жасанды интеллект мектебі» қауымдастырылған профессоры, Өскемен қ., Қазақстан,

Попова Галина Владимировна – кандидат физико-математических наук, Восточно-Казakhstanский технический университет имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан,
Popova Galina Vladimirovna – Candidate of Physical and Mathematical Sciences, D.Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan,
e-mail: assadenova@edu.ektu.kz,
ORCID: <https://orcid.org/0000-0002-6935-1066>



Вайс Юрий Андреевич – техника ғылымдарының кандидаты, «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ «Цифрлық технологиялар және жасанды интеллект мектебі» қауымдастырылған профессоры, Өскемен қ., Қазақстан,

Вайс Юрий Андреевич – кандидат технических наук, Восточно-Казakhstanский технический университет имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан ,
Vais Yuriy Andreevich – Candidate of Technical Sciences, D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan,
e-mail: yuvais@edu.ektu.kz,
ORCID: <https://orcid.org/0000-0002-2964-8260>,



Котлярова Ирина Александровна – техника және технология магистрі, «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ «Цифрлық технологиялар және жасанды интеллект мектебі» аға оқытушы, Өскемен қ., Қазақстан,

Котлярова Ирина Александровна – магистр техники и технологии, Восточно-Казахстанский технический университет имени Д. Серикбаева, г. Усть-Каменогорск, Казахстан,

Kotlyarova Irina Aleksandrovna – Master of Engineering and Technology, D.Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan, IKotlyarova@edu.ektu.kz,

e-mail: IKotlyarova@edu.ektu.kz,

ORCID: <https://orcid.org/0009-0006-5372-4207>



Гүлназ Жомартқызы – PhD докторы, «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ-нің «Цифрлық технологиялар және жасанды интеллект мектебі» қауымдастырылған профессоры, Өскемен қ., Қазақстан,

Гүлназ Жомартқызы – доктор PhD, ассоциированный профессор «Школа цифровых технологий и искусственного интеллекта», НАО «Восточно-Казахстанский технический университет им. Д. Серикбаева», г. Усть-Каменогорск, Казахстан,

Gulnaz Zhomartkyzy – PhD, Associate Professor, School of Digital Technology and Artificial Intelligence, NCJSC «D. Serikbayev East Kazakhstan Technical University», Ust-Kamenogorsk, Kazakhstan e-mail: gzhomartkyzy@edu.ektu.kz,

ORCID: <https://orcid.org/0000-0003-1465-3451>,



Рохас-Криулько Наталья Педровна – «Д. Серікбаев атындағы Шығыс Қазақстан техникалық университеті» КеАҚ «Цифрлық технологиялар және жасанды интеллект мектебі» оқытушы, Өскемен қ., Қазақстан,

Рохас Криулько Наталья Педровна – Восточно-Казахстанский технический университет имени Д. Серикбаева, г. Усть-Каменогорск,

Rokhas Kriulko Natalia Pedrovna – D. Serikbayev East Kazakhstan Technical University, Ust-Kamenogorsk, Kazakhstan,

e-mail: nrohas@edu.ektu.kz,

ORCID: <https://orcid.org/0009-0006-6841-0593>