

DOI: 10.32517/0234-0453-2025-40-3-57-68



МОНИТОРИНГ СДВИГА ДАННЫХ В МОДЕЛИ ПРОГНОЗИРОВАНИЯ УСПЕШНОСТИ ОБУЧЕНИЯ С ИСПОЛЬЗОВАНИЕМ ЗНАЧЕНИЙ ШЕПЛИ

Т. А. Кустицкая¹ ✉, Р. В. Есин¹¹ Сибирский федеральный университет, г. Красноярск, Россия

✉ tkustitskaya@sfu-kras.ru

Аннотация

Прогнозирование успешности обучения — одна из важнейших задач учебной аналитики, решение которой позволяет образовательным учреждениям своевременно выявлять студентов, испытывающих затруднения в обучении, и применять к ним средства педагогической поддержки и содействия. Для эффективной работы моделей прогнозирования в долгосрочной перспективе после внедрения их в учебный процесс необходимо регулярно проводить мониторинг сдвига данных в используемых моделях. Это позволит выявлять изменения в распределении образовательных данных, которые могут стать причиной падения точности прогнозирования, а также влиять на интерпретацию полученных прогнозов.

В статье предлагается методика анализа моделей прогнозирования успешности обучения на сдвиг данных с помощью значений Шепли, предполагающая двухэтапный мониторинг. На первом этапе (непосредственно в ходе образовательного процесса) с помощью исследуемой модели проводится прогнозирование успешности обучения и выявляются изменения вклада предикторов модели в итоговый прогноз. На втором этапе (после проведения промежуточной аттестации), когда уже возможна оценка точности прогнозирования, определяются изменения вклада предикторов в функцию потерь модели. Такой подход позволяет обнаруживать разные типы сдвига данных. На основании результатов анализа образовательное учреждение может принимать своевременные решения о коррекции, переобучении или замене используемой модели.

Предложенная методика была апробирована на моделях из сервиса прогнозирования успеваемости «Пифия», разработанного в Сибирском федеральном университете. После внедрения сервиса в образовательный процесс прогнозирования на новых данных было проведено для четырех учебных семестров, и было отмечено падение точности прогнозирования. В результате проведенного мониторинга для каждой из моделей ансамбля были выявлены отдельные предикторы, ставшие источниками ковариационного сдвига или сдвига концепции. Были предложены варианты коррекции используемых моделей.

Ключевые слова: учебная аналитика, анализ образовательных данных, прогнозирование успешности обучения, сдвиг данных, значение Шепли, SHAP, сервис прогнозирования успеваемости «Пифия», объяснимый искусственный интеллект, цифровой след.

Для цитирования:

Кустицкая Т. А., Есин Р. В. Мониторинг сдвига данных в модели прогнозирования успешности обучения с использованием значений Шепли. *Информатика и образование*. 2025;40(3):57–68. DOI: 10.32517/0234-0453-2025-40-3-57-68.

MONITORING DATA SHIFT IN THE LEARNING SUCCESS FORECASTING MODEL USING SHAPLEY VALUES

Т. А. Kustitskaya¹ ✉, R. V. Esin¹¹ Siberian Federal University, Krasnoyarsk, Russia

✉ tkustitskaya@sfu-kras.ru

Abstract

Predicting academic success is one of the most critical tasks in learning analytics. Solving this problem enables educational institutions to identify students struggling with their studies in a timely manner and apply appropriate pedagogical support and interventions. For predictive models to remain effective in the long term after being integrated into the educational process, it is essential to regularly monitor data shift within these models. This helps detect changes in the distribution of educational data that could lead to decreased forecasting accuracy and affect the interpretation of predictions.

The article presents a methodology for analyzing data shift in academic performance forecasting models using Shapley values, incorporating a two-stage monitoring approach. In the first stage (during the educational process), while the forecasting model is predicting academic success, changes in predictor contributions to the final forecast are identified. In the second stage (after exams), when prediction accuracy can be evaluated, shifts in predictor contributions to the model's loss function are analyzed. This approach enables the detection of different types of data shifts. Based on the analysis results, an educational institution can make timely decisions regarding model adjustments, retraining, or replacement.

The proposed methodology was tested on models from the academic performance forecasting service Pythia, developed at Siberian Federal University. After the service was integrated into the educational process, forecasting on new data was already conducted over four academic semesters, revealing a decline in prediction accuracy. Through monitoring, several predictors responsible for covariate or concept shifts within the ensemble models were identified. As a result, recommendations for model adjustments were proposed.

Keywords: learning analytics, education data mining, learning success prediction, data shift, Shapley value, SHAP, academic performance forecasting service Pythia, explainable artificial intelligence, digital footprint.

For citation:

Kustitskaya T. A., Esin R. V. Monitoring data shift in the learning success forecasting model using Shapley values. *Informatics and Education*. 2025;40(3):57–68. DOI: 10.32517/0234-0453-2025-40-3-57-68.

1. Введение

Прогнозирование успешности обучения является одним из актуальных трендов в области аналитики образовательных данных [1, 2]. С учетом растущей конкуренции и изменяющихся технологических условий университетам необходимо внедрять современные сервисы и модели для предсказания результатов обучения. Модели прогнозирования академической успеваемости предоставляют стейкхолдерам высшего образования актуальные данные, которые могут быть использованы для оценивания и корректировки учебного процесса, что, в свою очередь, позволяет обеспечить более персонализированный и эффективный образовательный опыт.

Цикл разработки модели машинного обучения включает несколько ключевых этапов, в том числе мониторинг и техническое обслуживание модели. На этом этапе контролируется производительность модели и проводится коррекция, дообучение или замена модели. Важно отметить, что принятие решения о необходимости таких действий зависит от множества факторов. Один из критически значимых — процесс устаревания модели из-за **эффекта сдвига (дрейфа) данных** (англ. data shift, data drift), который может происходить в результате изменений образовательных условий, демографических изменений контингента обучающихся и других внутренних и внешних факторов, влияющих на учебный процесс, например, таких как пандемия COVID-19 [3].

Сдвиг данных можно определить как изменение распределения входных данных или целевой переменной между обучением и эксплуатацией модели. Пусть X — вектор признаков модели, Y — значение целевой переменной, t — данные используемые для обучения модели, $t + 1$ — данные после внедрения модели. Под **сдвигом данных** принято понимать ситуацию, когда $P_t(X, Y) \neq P_{t+1}(X, Y)$, а так как $P(X, Y) = P(X) \cdot P(Y|X)$, то можно выделить следующие типы сдвига [4–6]:

- **ковариационный сдвиг** — изменения в распределении признаков: $P_t(X) \neq P_{t+1}(X)$;
- **сдвиг меток** — изменения в распределении целевой переменной: $P_t(Y) \neq P_{t+1}(Y)$;
- **сдвиг концепции** — изменения зависимостей между признаками и целевой переменной: $P_t(Y|X) \neq P_{t+1}(Y|X)$.

Эффект сдвига данных возникает в различных прикладных областях, однако в сферах, где результат работы модели машинного обучения непосредственно влияет на человека, он особенно критичен. Сдвиг

данных может значительно снижать точность предсказаний и вызывать нежелательные последствия, такие как ошибки диагностики заболеваний в медицине [7, 8], неточные прогнозы успеваемости студентов, приводящие к недостаточной поддержке тех, кто нуждается в помощи [9, 10]. При этом в области анализа образовательных данных исследований на тему сдвига данных относительно мало. В литературе можно встретить единичные исследования, например, в работе [3] оценивается устойчивость линейных моделей к дрейфу, в работе [11] авторы определяют принципы построения ансамблей, наиболее устойчивых к сдвигу данных

Для выявления сдвига данных часто используются такие методы, как индекс стабильности популяции (англ. Population Stability Index — PSI), дивергенция Кульбака—Лейблера (KL), расстояние Дженсона—Шеннона (JSD) и тест Колмогорова—Смирнова [4, 6, 7, 12, 13]. Эти методы позволяют сравнить распределения обучающих и новых данных и выявить значимые различия между ними. Например, PSI используется для оценки изменений в распределении признаков, а KL и JSD помогают количественно измерить степень различий между распределениями. Такие методы особенно полезны на начальных этапах анализа, когда требуется быстрая оценка наличия сдвига данных без необходимости сложных вычислений. Однако они имеют ограничения в случае многомерных данных и могут быть слабо чувствительны к небольшим изменениям [14].

Для более глубокого анализа сдвига данных существуют **продвинутое методы**, которые учитывают специфику конкретных задач и данных. При работе с потоковыми данными применяют методы последовательного анализа, например, Drift Detection Method (DDM) и Early Drift Detection Method (EDDM), которые основаны на мониторинге частоты ошибок классификации [15, 16]. Некоторые методы используют пользовательские модели для обнаружения сдвига, например, метод выделения области пространства признаков, где модель совершает наибольшее количество ошибок, что позволяет сосредоточиться на проблемных зонах [17]. Результаты исследования [18] показывают, что предложенный метод обнаружения сдвига эффективен для обнаружения изменений в распределениях или увеличения количества ошибок модели. В работе [19] авторы предлагают не просто выявлять наличие сдвига в данных, но и определять его вредоносность для модели и принимать обоснованное решение о необходимости переобучения. Разработанный ими подход основан на применении деревьев

решений к выявлению частей распределений данных с низкой точностью, где сдвиг может быть потенциально вредным для производительности модели.

Несмотря на успех существующих методов, сохраняется потребность в более интерпретируемых подходах к обнаружению сдвига данных. Одним из перспективных направлений является использование значений Шепли. Значения Шепли позволяют учитывать как индивидуальный, так и совместный вклад переменных в предсказание целевой переменной, что делает их идеально подходящими для анализа влияния каждого признака на сдвиг данных [20].

Методы на основе значений Шепли эффективны для объяснения предсказаний моделей и ранжирования важности признаков [21]. Более того, они могут быть использованы для выявления изменений во взаимосвязях между признаками, что особенно важно при анализе сдвига концепции. Например, фреймворк L-CODE в [21] использует значения Шепли для обнаружения и объяснения сдвига без использования истинных меток целевой переменной. Этот подход может быть особенно полезен в образовательных системах, где данные об итоговой успеваемости могут быть получены, например, только в конце семестра. Еще одно применение значений Шепли возможно в концепции объяснимого искусственного интеллекта eXplainable AI (XAI) [10] — они могут стать ключевым компонентом такого подхода, позволяя стейкхолдерам образовательного процесса понять причины успеха или неудачи студентов и принимать соответствующие решения.

Целью представленной в данной статье работы является разработка и реализация комплексного подхода к мониторингу модели прогнозирования успеваемости студентов с использованием значений Шепли для обнаружения и анализа сдвига данных. Исследование направлено на решение трех взаимосвязанных задач:

- во-первых, разработку методик обнаружения сдвига в образовательных данных как в динамике семестра (при отсутствии истинных меток), так и по его завершении (с учетом уже известных результатов обучения);
- во-вторых, проведение и анализ результатов мониторинга сдвига данных для модели прогнозирования, разработанной в Сибирском федеральном университете (СФУ);
- в-третьих, оценку необходимости коррекции, дообучения или замены действующей модели для обеспечения ее стабильности и точности предсказаний в условиях изменяющихся данных.

2. Материалы и методы

2.1. Сервис прогнозирования успеваемости «Пифия»

В 2023 году в Сибирском федеральном университете в рамках программы стратегического академического лидерства «Приоритет 2030» был внедрен

цифровой сервис прогнозирования академической успеваемости «Пифия»¹ (<https://services-sfu.ru/pifiya>). Его целью является раннее прогнозирование результатов сессии на основе динамики искусственного интеллекта и визуализация динамики успеваемости обучающегося по принципу «светофора». Сервис рассчитан на использование преподавателями и сотрудниками институтов и позволяет на ранних этапах выявить обучающихся, у которых только формируются трудности в обучении, чтобы спланировать работу по своевременному оказанию им мер педагогического содействия и помощи [22].

Работа сервиса основана на комплексе моделей прогнозирования успешности обучения, представленных на рисунке 1 [23].

Модель LSSp разработана для прогнозирования успешности обучения в текущем семестре на основе данных цифровой образовательной истории предыдущих семестров и цифрового личного портрета студента. Она решает задачу бинарной классификации, где целевая переменная равна 1, если студент не справляется хотя бы с одной дисциплиной текущего семестра, и 0, если студент успешно аттестован по всем дисциплинам. Точность выявления класса 1 наиболее важна в рамках данной задачи, поскольку студенты с потенциальными академическими задолженностями нуждаются в своевременной помощи и поддержке в учебном процессе.

Модель LSSp представляет собой ансамбль из четырех алгоритмов: Random Forest, XGBoost, CatBoost, LightGBM.

$$Prob_{LSSp} = k_1 \cdot Prob_{Random\ Forest} + k_2 \cdot Prob_{XGBoost} + k_3 \cdot Prob_{CatBoost} + k_4 \cdot Prob_{LightGBM}$$

Для каждого алгоритма был произведен подбор гиперпараметров. Взвешенное предсказание всех четырех алгоритмов используется в качестве мета-модели. Оптимизация коэффициентов k_i производилась путем максимизации метрики F1-score на валидационной выборке.

Модель LSC разработана для прогнозирования вероятности получения определенной оценки по дисциплине по данным цифрового следа с платформы электронного обучения «Е-Курсы» (<https://e.sfu.kras.ru>). Лежащий в основе модели алгоритм описан в статьях [24, 25].

Модель LSSc построена по текущей образовательной истории и предназначена для уточнения прогноза успешности обучения в семестре. Она представляет собой мета-модель, работающую на основе алгорит-

¹ Свидетельство о государственной регистрации программы для ЭВМ № 2019610914 Российская Федерация. Система прогнозирования академической успеваемости «Пифия»: № RU 2023683411: заявлено 03.11.2023: опубликовано 07.11.2023 / Сантьев Е. А., Захарьин К. Н., Шниперов А. Н., Курченко Р. А., Шефер И. А., Вайнштейн Ю. В., Сомова М. В., Федотова И. М., Носков М. В., Куститская Т. А., Есин Р. В., Киселевич В. В., Андреев Д. С., Белолипецкая Н. А., Бурмистрова Е. А.; правообладатель ФГБОУ ВО «Сибирский федеральный университет». EDN: ZCMDLJ.

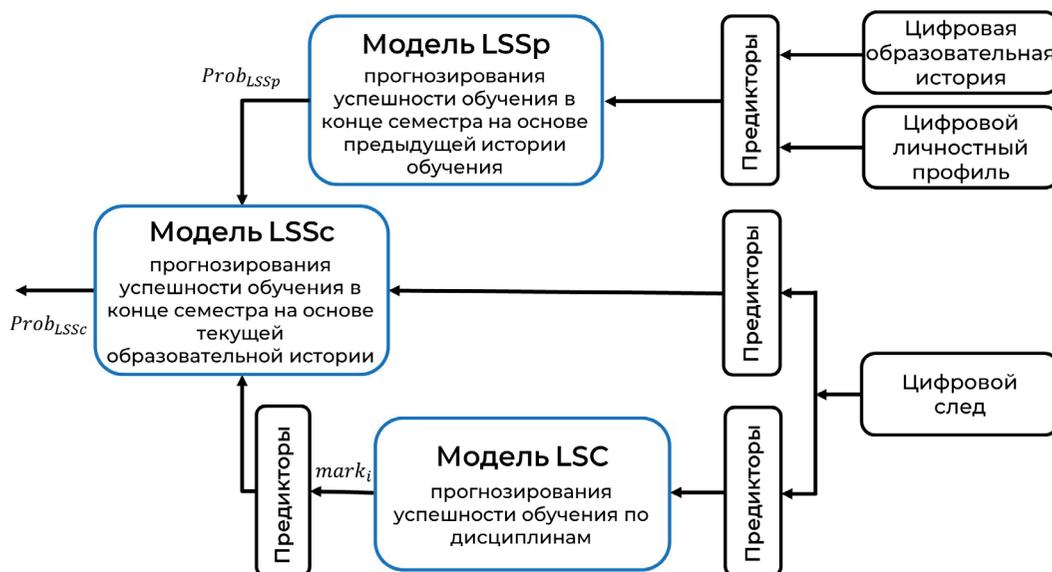


Рис. 1. Прогнозирование успешности обучения в сервисе «Пифия»

Fig. 1. Academic success prediction in the Pythia service

мов LSSp и LSC, а также показателей активности студентов на платформе «Е-Курсы».

Для обучения и мониторинга моделей LSSp и LSSc использован набор данных, содержащий 197 624 записи для 57 369 обучающихся 20 институтов СФУ всех уровней образования и форм обучения. Этот датасет включал признаки, созданные на основе базы данных образовательного профиля, базы данных зачетных книжек, базы данных приказов о движении контингента и базы данных цифрового следа платформы «Е-Курсы» [26]. Датасет объединил данные с 2018 по 2024 год, т. е. за шесть учебных лет, которые были поделены на три последовательных временных периода:

- выборка 2018/2019–2021/2022 учебных годов, на которой обучена и протестирована модель LSSp;
- выборка 2022/2023 учебного года, по которой построен прогноз модели LSSp, используемый далее в качестве предиктора в модели LSSc;
- выборка 2023/2024 учебного года, которая получена в ходе текущей работы сервиса «Пифия».

2.2. Методы мониторинга сдвига данных на основе значений Шепли

Значения Шепли (*англ.* Shapley values) — инструмент из теории игр, позволяющий оценить вклад каждого игрока в результат кооперативной игры (достижение общей цели). В машинном обучении значения Шепли применяются для локального объяснения ответа модели. При этом игроками считаются признаки, используемые в модели, а с помощью значений Шепли оценивается вклад каждого признака в предсказание модели на конкретном объекте x .

Пусть $val(S)$ — некоторая характеристическая функция, которая каждому множеству признаков S

сопоставляет число — вклад этого множества признаков в прогноз модели. Значение Шепли для признака j из множества всех признаков модели $\{1, \dots, p\}$ вычисляется по формуле:

$$\varphi(j) = \sum_{S \subseteq \{1, \dots, p\} \setminus \{j\}} \frac{|S|!(p-|S|-1)!}{p!} (val(S \cup \{j\}) - val(S)).$$

Зафиксируем некоторый объект x и обучающую выборку X . С помощью значений Шепли можно представить прогноз модели на объекте x следующим образом:

$$f(x) = E_X(f(X)) + \sum_{j=1}^p \varphi(j),$$

где $E_X(f(X))$ — средний прогноз модели по выборке X . Таким образом, значения Шепли позволяют получить конструктивное объяснение сделанного моделью прогноза.

Для вычисления значений Шепли нужно многократно переобучать модель на разных подмножествах признаков S , что является существенным недостатком метода ввиду больших вычислительных затрат. Предложенная в работе [27] аппроксимация значений Шепли, названная авторами SHAP, позволяет оценить вклад отдельных признаков в прогноз, обучая только одну модель на всех признаках. Существуют разные варианты вычисления SHAP, которые применяются для разного типа моделей. Например, KernelSHAP может использоваться для моделей, не позволяющих работать с пропущенными данными. Для моделей на основе деревьев решений разработан алгоритм TreeSHAP [28], имеющий полиномиальную сложность низкого порядка. Различные модификации SHAP реализованы в пакете shap для Python [27].

Значения Шепли можно использовать для диагностики сдвига данных. Идея заключается в том,

что если новые данные распределены так же, как и обучающая выборка, то зафиксированное значение некоторого признака модели для объекта новой выборки должно вносить такой же вклад в результат, что и соответствующее значение признака для объектов обучающей выборки. При этом под результатом кооперативной игры может пониматься как прогноз модели, так и функция потерь.

2.2.1. Применение SHAP-loss для анализа сдвига данных в моделях прогнозирования после завершения семестра

В работе [28] для оценки дрейфа данных в уже внедренных моделях, основанных на деревьях решений, предлагается вычислять *SHAP-loss* — значения *SHAP* для признаков модели относительно функции потерь. Мониторинг моделей с помощью *SHAP-loss* имеет несколько преимуществ перед стандартным мониторингом значений самой функции потерь. При мониторинге общих потерь проблемы по отдельным предикторам могут быть скомпенсированы другими предикторами. Могут остаться незамеченными проблемы с кодировкой категориальных переменных (например, если между собой перепутаны категории, одинаково часто встречающиеся в данных). Отслеживая же вклад каждого предиктора в функцию потерь, мы можем более эффективно обнаруживать как истинный сдвиг в данных, так и проблемы, возникающие при изменении словарей значений категориальных переменных или процедуры их кодирования.

Для моделей прогнозирования успешности обучения в семестре истинные значения отклика становятся известны по завершении экзаменационной сессии. Тогда же появляется возможность вычислить значения *SHAP-loss*. В целях выявления сдвига данных для каждого предиктора модели i следует проверить гипотезу о значимости отличий в значениях *SHAP-loss* между обучающей выборкой ($SHAP-loss_{train}(i)$) и новой ($SHAP-loss_{new}(i)$)

Если объемы исследуемых выборок велики (например, если модель внедрена на уровне всего университета), то при использовании критерия Стьюдента велика вероятность обнаружить статистически значимые отличия, которые тем не менее не приведут к заметному изменению качества прогнозирования. Поэтому стоит делать вывод о наличии сдвига данных, принимая во внимание как результаты проверки гипотезы о статистически значимой разнице в значениях *SHAP-loss*, так и размер обнаруженного эффекта. Также весьма вероятно, что при стандартных уровнях значимости ($\alpha = 0,1; 0,5; 0,01$) мощность критерия Стьюдента будет несоразмерно велика. Поэтому желательно перед проверкой гипотезы провести анализ мощности критерия и, возможно, уменьшить уровень значимости, чтобы сбалансировать вероятности ошибок 1-го и 2-го рода.

Мы предлагаем следующую схему исследования:

1. Зафиксировать размер эффекта, значимый с практической точки зрения (*prac_effect*).

2. Для каждого предиктора i по выборкам $SHAP-loss_{train}(i)$ и $SHAP-loss_{new}(i)$:

- а) провести процедуру анализа мощности теста и определить α для проверки гипотезы о значимости отличий;
- б) проверить гипотезу о значимости отличий *SHAP-loss*;
- в) вычислить наблюдаемый размер эффекта *Cohen's d*;
- г) сделать вывод о наличии сдвига данных по предиктору i , если отличия в *SHAP-loss* признаны статистически значимыми и при этом $Cohen's d \geq prac_effect$.

Для определения эффекта, значимого с практической точки зрения, можно применить подход с использованием стандартной градации значений *Cohen's d* [29]. Однако предпочтительно установить минимально значимый эффект с точки зрения возможных значений прогноза модели.

Пусть прогноз модели $p(x)$ — это вероятность принадлежности к одному из двух классов и классификатор относит объект x к положительному классу, если $p(x) \geq p_0$. Тогда объект, который по прогнозу p_0 ранее правильно определялся алгоритмом как объект положительного класса, после сдвига прогноза в меньшую сторону на некоторое δ будет неверно отнесен к отрицательному классу. Аналогично объект отрицательного класса с близким к p_0 значением прогноза может в результате сдвига данных быть неверно отнесен алгоритмом к положительному классу. При этом функция потерь изменится с $loss(p_0)$ на $loss(p_0 - \delta)$ (или на $loss(p_0 + \delta)$ для объекта отрицательного класса). Мы предлагаем устанавливать δ , ориентируясь на конкретную решаемую задачу, свойства функции потерь и число предикторов в модели (чем их больше, тем меньшим стоит выбирать δ).

В нашей работе $p_0 = 0,5$, используемая в моделях функция потерь — это $logloss()$. Будем считать существенным изменение прогнозируемой вероятности на 0,005. Поэтому для каждого из предикторов мы будем вычислять эффект, значимый с практической точки зрения, по формуле:

$$prac_effect = \frac{|\logloss(0,5) - \logloss(0,495)|}{S_{corrected}(i)},$$

где $S_{corrected}(i)$ — скорректированное среднеквадратическое отклонение.

2.2.2. Анализ SHAP в процессе работы модели в течение семестра

Если изучаемая модель выдает прогнозы несколько раз в течение семестра и эти прогнозы используются для педагогического воздействия на студентов, то возникает необходимость обнаружения сдвига данных еще до появления истинных значений отклика после экзаменационной сессии. Не зная истинного отклика, невозможно вычислить *SHAP-loss*, но можно вычислить значения Шепли (или какую-либо из их аппроксимаций SHAP) относительно прогноза модели.

В [21] предложен фреймворк L-CODE анализа сдвига данных по предикторам модели, предназначенный для случая последовательного поступления отдельных прогнозов. После небольшой адаптации этого фреймворка для случая одномоментного поступления большого числа прогнозов получилась следующая схема исследования:

Пусть X^{train} и f^{train} — обучающая выборка из n объектов и прогнозы модели на этой выборке, а X^{new} и f^{new} — новая выборка из m объектов и прогнозы на ней. Для числового признака модели i определяем значимость различий в значениях Шепли между обучающей и новой выборкой:

1. Разбиваем область выборочных данных для X_i^{train} на $s = \lfloor \sqrt{N} \rfloor + 1$ интервалов группировки (в каждый интервал должно попасть не менее 30 значений). Обозначим их $\Delta_1, \dots, \Delta_s$.

2. Для каждого интервала группировки Δ_k находим значения $SHAP(i)$ для всех значений X_i^{train} , попавших в этот интервал группировки, и формируем из них выборку. Для этой выборки вычисляем среднее выборочное μ_k^{train} и выборочное стандартное отклонение σ_k^{train} .

3. Вычисляем среднее выборочное μ^{train} и выборочное стандартное отклонение σ^{train} для объединенной выборки значений $SHAP(i)$ по всем интервалам $\Delta_1, \dots, \Delta_s$.

4. Область выборочных данных для X_i^{new} разбиваем на те же интервалы $\Delta_1, \dots, \Delta_s$. Для каждого Δ_k определяем частоты попаданий элементов X_i^{new} в этот интервал группировки n_k^{new} .

5. Вычисляем μ^{exp} и σ^{exp} — ожидаемые значения для среднего и стандартного отклонения значений $SHAP(i)$ при условии, что не происходит сдвига данных:

$$\mu^{exp} = \frac{\sum_{k=1}^m \mu_k^{train} \cdot n_k^{new}}{\sum_{k=1}^m n_k^{new}},$$

$$\sigma^{exp} = \sqrt{\frac{\sum_{k=1}^m (\sigma_k^{train})^2 \cdot n_k^{new} + \sum_{k=1}^m (\mu_k^{train} - \mu^{exp})^2 \cdot n_k^{new}}{\sum_{k=1}^m n_k^{new}}}.$$

6. Вычисляем фактические значения $SHAP(i)$ для выборки X_i^{new} , их среднее выборочное μ^{new} и стандартное отклонение σ^{new} .

7. Проверяем гипотезу о равенстве μ^{exp} и μ^{new} с помощью критерия Стьюдента, вычисляя выборочное значение статистики критерия по формуле:

$$t = \frac{\mu^{exp} - \mu^{new}}{\sqrt{\frac{(\sigma^{exp})^2 + (\sigma^{new})^2}{m}}}.$$

8. Если гипотеза отвергнута, делаем вывод о наличии сдвига данных по предиктору i .

Для категориального признака i вместо интервалов группировки необходимо рассмотреть все уникальные значения X_i^{train} . Каждое значение должно встретиться не менее 30 раз.

3. Результаты

Базовые модели ансамбля LSSp, используемого в сервисе «Пифия», были исследованы на сдвиг данных. Так как каждая из них содержит более 70 предикторов, то было решено на данном этапе проанализировать на сдвиг данных только те признаки, которые вносят наибольший вклад в прогноз модели и в значение функции потерь модели. Для нахождения наиболее значимых признаков для каждой из моделей ансамбля были вычислены значения метрики *feature importance* (FI): относительно прогноза модели (FI_{SHAP}) и относительно функции потерь ($FI_{SHAP-loss}$). Для каждой из базовых моделей были созданы списки из 10 наиболее значимых предикторов по FI_{SHAP} и 10 наиболее значимых предикторов по $FI_{SHAP-loss}$. Получившиеся в результате наборы пересекаются по девяти предикторам для XGBoost, Random Forest и CatBoost и полностью совпадают для LighGBM.

Мониторинг базовых моделей на сдвиг данных в течение семестра был проведен с помощью фреймворка L-CODE. Для обучающей выборки, созданной на основе данных за 2018/2019–2021/2022 учебные годы, по каждой из моделей были вычислены значения Шепли ($SHAP^{train}$). Для новых данных, соответствующих осенним и весенним семестрам 2022/2023 и 2023/2024 учебных годов, были получены выборки $SHAP^{2022-1sem}$, $SHAP^{2022-2sem}$, $SHAP^{2023-1sem}$ и $SHAP^{2023-2sem}$. Для вычисления значений Шепли был использован метод TreeSHAP, так как в основе всех базовых моделей лежат деревья решений. Далее по выборкам, соответствующим осенним и весенним семестрам обучения, на уровне значимости 0,05 были проверены гипотезы о значимости отличий между значениями Шепли.

Для всех базовых моделей хотя бы в нескольких парах выборок были обнаружены статистически значимые отличия в значениях Шепли по отдельным предикторам. При этом модель Random Forest оказалась сильнее всего подвержена сдвигу данных — значимые отличия в значениях Шепли были обнаружены для всех рассмотренных предикторов модели.

Далее с помощью предложенной выше в разделе 2.2.1 схемы был проведен мониторинг моделей на сдвиг данных после завершения семестра (т. е. после того, как истинные значения целевой переменной стали известны). По тем же образовательным данным для каждой из базовых моделей были вычислены значения $SHAP-loss$ и получены следующие выборки: $SHAP-loss^{train}$, $SHAP-loss^{test}$, $SHAP-loss^{2022-1sem}$, $SHAP-loss^{2022-2sem}$, $SHAP-loss^{2023-1sem}$ и $SHAP-loss^{2023-2sem}$.

Для всех базовых моделей хотя бы по нескольким предикторам были найдены статистически значимые отличия в значениях $SHAP-loss$ между новыми данными и обучающей выборкой. Однако практически значимых отличий было существенно меньше, причем для модели Random Forest не было найдено ни одного практически значимого отличия, а для моде-

ли CatBoost — только по одному из 10 предикторов (при сравнении $SHAP-loss^{train}$ и $SHAP-loss^{2023-2sem}$).

Все базовые алгоритмы продемонстрировали заметное ухудшение качества прогнозирования для осенних семестров обучения. Так, значение F-меры для тестовой выборки 2018/2019–2021/2022 учебных годов находилось в интервале от 0,723 (Random Forest) до 0,774 (CatBoost), для осеннего семестра 2022/2023 учебного года — в интервале от 0,678 (XGBoost) до 0,687 (CatBoost), а для осеннего семестра 2023/2024 учебного года — в интервале от 0,686 (XGBoost) до 0,695 (LightGBM и CatBoost). Такое снижение точности для всех моделей, кроме CatBoost, сопровождалось статистически значимыми изменениями значений SHAP по части предикторов, и для всех моделей, кроме Random Forest, — значимыми изменениями значений SHAP-loss по отдельным предикторам.

Для одной из базовых моделей, XGBoost, опишем процесс мониторинга и анализа его результатов более подробно. Наборы из наиболее значимых предикторов XGBoost с соответствующими значениями метрик FI_{SHAP} и $FI_{SHAP-loss}$ представлены в таблице 1. Для этих предикторов с помощью L-CODE проведен мониторинг сдвига данных в течение семестра.

Смещений не выявлено по предикторам *Доля долгов после передачи сессии прошлого семестра*, *Доля долгов после сессии прошлого семестра*, *Средний балл зачетки после сессии прошлого семестра*.

В таблице 2 приведены предикторы, показавшие значимые отличия в значениях Шепли. По переменной *Осенний семестр* значимый сдвиг наблюдается в каждой паре выборок. По предикторам *Курс*, *Средний балл зачетки после передачи сессии прошлого семестра*, *Число несданных экзаменов в сессию прошлого семестра* сдвиг имеется между обучающей выборкой и выборкой 2022/2023 учебного года, а между

2022/2023 учебным годом и 2023/2024 учебным годом значимого сдвига не происходит, что говорит о более медленном устаревании модели по этим предикторам.

На рисунке 2 представлены диаграммы распределений значений Шепли для предиктора *Курс* в модели XGBoost для осенних семестров обучения ($SHAP^{train}$, $SHAP^{2022-1sem}$, $SHAP^{2023-1sem}$). Цвет точек на диаграммах отражает значение числовой переменной *Курс* и изменяется по шкале от синего (для первокурсников) до красного (для пятикурсников).

Из рисунка видно, что обучение студента на младших курсах увеличивает вероятность быть не аттестованным хотя бы по одному предмету по завершении семестра (положительным значениям Шепли соответствуют в основном точки синего и фиолетового цветов), обучение на старших курсах, напротив, снижает прогноз вероятности неуспешности обучения. При этом форма распределения для $SHAP^{train}$ заметно отличается от $SHAP^{2022-1sem}$ и $SHAP^{2023-1sem}$, прежде всего, для положительных значений Шепли, что демонстрирует наличие сдвига данных по переменной *Курс*.

Также был проведен мониторинг сдвига данных после завершения семестра. По каждому из десяти предикторов хотя бы на одном из сравнений наблюдаются статистически значимые отличия между $SHAP-loss$ текущей выборки и $SHAP-loss$ тренировочной выборки. При этом наблюдаются значимые с практической точки зрения отличия по трем предикторам:

- *Курс* — для $SHAP-loss^{2022-1sem}$, $SHAP-loss^{2023-1sem}$ и $SHAP-loss^{2023-2sem}$;
- *Доля долгов после сессии прошлого семестра* — для $SHAP-loss^{2022-1sem}$, $SHAP-loss^{2022-2sem}$ и $SHAP-loss^{2023-1sem}$;
- *Доля долгов после передачи сессии прошлого семестра* — для $SHAP-loss^{2022-2sem}$ и $SHAP-loss^{2023-1sem}$.

Таблица 1 / Table 1

Наиболее значимые предикторы модели XGBoost

The most important features for XGBoost

№ п/п	Предиктор	FI_{SHAP}	Ранг	$FI_{SHAP-loss}$	Ранг
1	Курс	0,475	1	0,205	1
2	Доля долгов после передачи сессии прошлого семестра	0,374	2	0,122	3
3	Доля долгов после сессии прошлого семестра	0,318	3	0,13	2
4	Средний балл зачетки после передачи сессии прошлого семестра	0,24	4	0,087	5
5	Осенний семестр	0,221	5	0,097	4
6	Доля долгов после сессии позапрошлого семестра	0,146	6	0,063	7
7	Число дисциплин в сессии прошлого семестра	0,143	7	0,075	6
8	Средний балл зачетки после сессии прошлого семестра	0,116	8	0,044	10
9	Пол женский	0,113	9	—	—
10	Число несданных экзаменов в сессию прошлого семестра	0,098	10	0,044	9
11	Число несданных зачетов после передачи прошлой сессии	—	—	0,047	8

Результаты исследования предикторов XGBoost на сдвиг данных по значениям Шепли
Results of the study on the features of XGBoost regarding data shift using Shapley values

№ п/п	Предиктор	Осенний семестр				Весенний семестр			
		SHAP ^{train} и SHAP ^{2022-1sem}	SHAP ^{train} и SHAP ^{2023-1sem}	SHAP ^{2022-1sem} и SHAP ^{2023-1sem}	SHAP ^{train} и SHAP ^{2022-2sem}	SHAP ^{train} и SHAP ^{2023-2sem}	SHAP ^{2022-2sem} и SHAP ^{2023-2sem}		
1	Курс	0,041 / 0,064 / да / 4,62	0,067 / 0,091 / да / 5,34	0,089 / 0,091 / нет / 0,34	0,067 / 0,089 / да / 3,41	0,104 / 0,127 / да / 3,82	0,125 / 0,127 / нет / 0,27		
2	Доля долгов после передачи сессии прошлого семестра	0,081 / 0,078 / нет / 0,7	0,059 / 0,064 / нет / 1,38	0,056 / 0,064 / да / 2,17	0,054 / 0,060 / нет / 1,16	0,098 / 0,107 / нет / 1,8	0,106 / 0,107 / нет / 0,1		
3	Средний балл зачетки после передачи сессии прошлого семестра	-0,023 / -0,004 / да / 6,72	-0,02 / -0,003 / да / 6,39	-0,001 / -0,003 / нет / 1,04	-0,092 / -0,09 / нет / 0,56	0,072 / 0,067 / нет / 1,89	-0,067 / -0,067 / нет / 0,04		
4	Осенний семестр	0,223 / 0,211 / да / 11,96	0,223 / 0,202 / да / 22,2	0,211 / 0,202 / да / 10,0	-0,214 / -0,201 / да / 10,41	-0,214 / -0,201 / да / 10,23	-0,201 / -0,201 / нет / 0,68		
5	Доля долгов после сессии позапро- шлого семестра	0,021 / 0,022 / нет / 0,58	0,019 / 0,016 / нет / 1,57	0,020 / 0,016 / да / 2,05	-0,004 / -0,007 / нет / 1,48	0,003 / -0,001 / нет / 1,79	-0,001 / -0,001 / нет / 0,12		
6	Число дисциплин в сессии прошлого семестра	-0,116 / -0,008 / да / 3,65	-0,113 / -0,105 / да / 3,49	-0,101 / -0,105 / нет / 1,76	-0,003 / -0,012 / да / 4,54	-0,019 / -0,039 / да / 8,01	-0,036 / -0,039 / да / 2,14		
7	Число несданных экзаменов в сессию прошлого семестра	0,008 / 0,011 / да / 2,43	0,013 / 0,016 / да / 2,3	0,016 / 0,016 / нет / 0,93	0,012 / 0,011 / нет / 0,93	0,024 / 0,025 / нет / 0,79	0,008 / 0,008 / нет / 0,01		
Критическое значение статистики: 1,96									

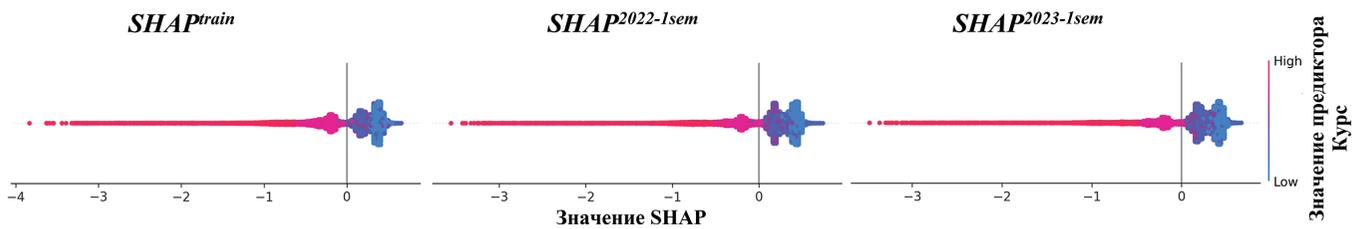


Рис. 2. Диаграммы распределений значений Шепли для предиктора **Курс** в модели XGBoost

Fig. 2. Plot of Shapley values for predictor **Year of Study** in the XGBoost model

На рисунке 3 представлены значения $SHAP-loss$, вычисленные для предиктора *Доля долгов после сессии прошлого семестра* по шести последовательно поступающим в модель XGBoost наборам данных:

- обучающему;
- тестовому;
- за осенний семестр 2022/2023 учебного года;
- за весенний семестр 2022/2023 учебного года;
- за осенний семестр 2023/2024 учебного года;
- за весенний семестр 2023/2024 учебного года.

Среднее значение $SHAP-loss$ для обучающей выборки равно $-0,083$, оно представлено на рисунке черной горизонтальной линией. Получается, что для обучающей выборки знание предиктора *Доля долгов после сессии прошлого семестра* улучшает качество прогноза модели (функция потерь в среднем уменьшается на $0,083$). Средние значения $SHAP-loss$ для всех последующих выборок представлены красными линиями. В ситуации, когда на рисунке красная линия не совпадает с черной, можно предположить, что влияние предиктора на качество прогноза изменилось. Стоит внимательно отнестись к ситуации, когда красная линия проходит выше, чем черная, так как это может говорить об ухудшении предиктивных свойств переменной — в нашем случае опасение вызывают выборки за

осенние семестры 2022/2023 и 2023/2024 учебных годов.

По предложенной в разделе 2.2.1 схеме анализа для предиктора *Доля долгов после сессии прошлого семестра* были проверены гипотезы о значимости отличий между $SHAP-loss^{train}$ и последующими выборками. В результате анализа мощности был установлен уровень значимости 10^{-7} , мощность теста при этом оказалась более, чем $1 - 10^{-7}$. Обнаружено, что для выборок $SHAP-loss^{2022-1sem}$, $SHAP-loss^{2022-2sem}$, $SHAP-loss^{2023-1sem}$ отличия от $SHAP-loss^{train}$ являются статистически значимыми. Более того, обнаруженные эффекты ($Cohen's d_{2022-1sem} = 0,13$, $Cohen's d_{2022-2sem} = 0,09$ и $Cohen's d_{2023-1sem} = 0,09$) значимы с практической точки зрения ($prac_effect_{2022-1sem} = 0,083$, $prac_effect_{2022-2sem} = 0,075$, $prac_effect_{2023-1sem} = 0,081$). При этом для выборок 2022/2023 и 2023/2024 учебных годов за осенний семестр включение в модель предиктора *Доля долгов после сессии прошлого семестра* ухудшает качество прогноза (среднее значение $SHAP-loss^{2022-1sem}$ равно $-0,068$, а среднее значение $SHAP-loss^{2023-1sem}$ равно $-0,073$). Для весеннего семестра 2022/2023 учебного года значение этого предиктора, наоборот, улучшает точность прогнозирования (среднее значение $SHAP-loss^{2022-2sem}$ равно $-0,095$).

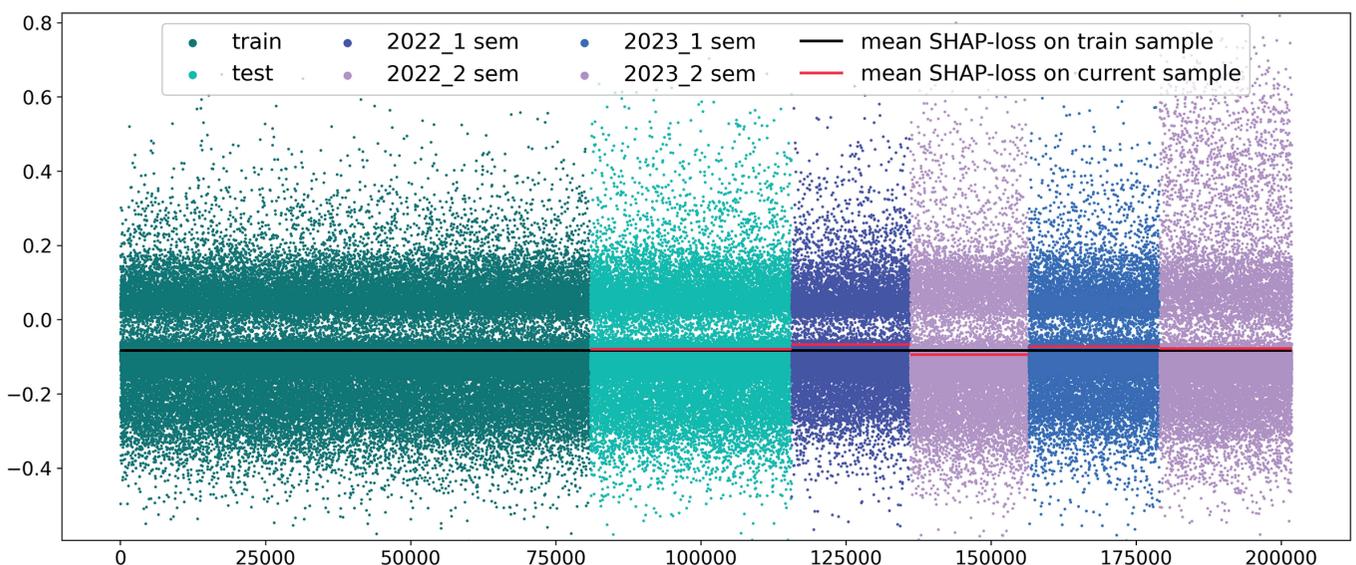


Рис. 3. $Shap-loss$ для предиктора *Доля долгов после сессии прошлого семестра* в модели XGBoost

Fig. 3. $Shap-loss$ values for **Learning Failure Ratio after the last semester session** in the XGBoost model

Таблица 3 / Table 3

Результаты сопоставления точности модели XGBoost и наличия сдвига данных

Performance of the XGBoost model in reference to data shift

№ п/п	Выборка	F-мера / recall / precision	Предикторы, по которым наблюдается сдвиг данных относительно тренировочной выборки 2018/2019–2021/2022 учебных годов	
			По SHAP	По SHAP-loss
1	2022/2023 учебный год, осенний семестр	0,678 / 0,665 / 0,681	Курс, Осенний семестр, Средний балл зачетки после передачи сессии прошлого семестра, Число дисциплин в сессии прошлого семестра, Число несданных зачетов после передачи прошлой сессии, Число несданных экзаменов в сессию прошлого семестра	Курс, Доля долгов после сессии прошлого семестра
2	2022/2023 учебный год, весенний семестр	0,771 / 0,680 / 0,798	Курс, Осенний семестр, Число дисциплин в сессии прошлого семестра, Число несданных зачетов после передачи прошлой сессии	Доля долгов после сессии прошлого семестра, Доля долгов после передачи сессии прошлого семестра
3	2023/2024 учебный год, осенний семестр	0,687 / 0,659 / 0,694	Курс, Осенний семестр, Средний балл зачетки после передачи сессии прошлого семестра, Число дисциплин в сессии прошлого семестра, Число несданных зачетов после передачи прошлой сессии, Число несданных экзаменов в сессию прошлого семестра	Курс, Доля долгов после сессии прошлого семестра, Доля долгов после передачи сессии прошлого семестра
4	2023/2024 учебный год, весенний семестр	0,711 / 0,697 / 0,715	Курс, Осенний семестр, Число дисциплин в сессии прошлого семестра, Число несданных зачетов после передачи прошлой сессии	Курс
Качество на тестовой выборке 2018/2019–2021/2022 учебных годов: 0,770 / 0,704 / 0,789				

Сопоставим выявленные сдвиги данных с изменениями качества прогноза модели XGBoost. В таблице 3 для каждой из исследованных выборок приведены значения метрик качества прогнозирования модели XGBoost, а также списки предикторов, по которым происходят значимые изменения средних значений SHAP и SHAP-loss. Видно, что по сравнению с тестовой выборкой 2018/2019–2021/2022 учебных годов качество прогнозирования заметно ухудшилось в осенних семестрах 2022/2023 и 2023/2024 учебных годов, а также умеренно снизилось в весеннем семестре 2023/2024 учебного года. При этом в весеннем семестре 2022/2023 учебного года точность прогнозирования оказалась приблизительно равной точности прогнозирования на тестовой выборке. Таким образом, модель XGBoost особенно нуждается в корректировке для прогнозирования успешности обучения в осенних семестрах.

Проведенный анализ выявил сдвиг данных по некоторым предикторам, который отражается в изменениях как SHAP, так и SHAP-loss. Отметим, что списки проблемных с точки зрения изменения SHAP и SHAP-loss предикторов пересекаются, но не совпадают.

4. Обсуждение

Проведенные расчеты SHAP и SHAP-loss для базовых моделей прогнозирования показали, что наличие значимых отличий между выборками по SHAP часто не означает существования для этих же предикторов значимых отличий по SHAP-loss, и наоборот. Например, в модели XGBoost для предиктора Доля долгов после сессии прошлого семестра статистически значимых отличий в SHAP не было обнаружено ни в одной паре выборок, однако SHAP-loss для этого предиктора значимо отличается по трем выборкам. Обратная ситуация — для предиктора Число несданных зачетов после передачи прошлой сессии были найдены статистически значимые отличия в SHAP между тренировочной и всеми остальными выборками, однако по SHAP-loss значимых отличий не обнаружено. Это, вероятно, связано с тем, что SHAP и SHAP-loss выявляют сдвиги данных разного типа — если SHAP-loss свидетельствует о наличии сдвига концепции, то SHAP — о наличии ковариационного сдвига, который не всегда сопровождается сдвигом концепции.

При обнаружении значимых различий у предикторов по значениям SHAP в течение семестра

необходимо менять интерпретации прогнозов, если они сообщаются стейкхолдерам системы прогнозирования в терминах вклада переменных модели в прогноз. Это позволит более корректно применять меры педагогического воздействия к студентам из группы риска. Для сервиса «Пифия» при обнаружении большого числа значимых сдвигов по *SHAP* по одной из четырех рассмотренных моделей, возможно, следует уменьшить вес k_i соответствующего ей прогноза в ансамбле, чтобы итоговый прогноз строился по более стабильным моделям. Необходимо провести эксперимент по оценке эффективности такой меры для получения более точных прогнозов.

Принимать решения о дообучении или переобучении моделей прогнозирования по завершении учебного семестра стоит, опираясь как на результаты мониторинга изменений значений *SHAP-loss*, так и на изменения качества прогнозирования на новых данных. Если качество прогнозирования заметно не ухудшилось, то не имеет смысла как-либо изменять модель, даже при обнаружении значимых отличий в *SHAP-loss*.

Если качество прогнозирования на новых данных заметно ухудшилось, то стоит рассмотреть два сценария изменения модели.

Если падение точности сопровождается значимыми изменениями в *SHAP-loss* по каким-то предикторам, то модель необходимо переобучить. При этом, возможно, стоит вообще исключить предикторы, которые в нескольких последовательных выборках новых данных демонстрировали значимые изменения по *SHAP-loss*, и заново провести отбор признаков модели. В нашей ситуации стоит рассмотреть вариант исключения из модели XGBoost предикторов *Курс* и *Доля долгов после сессии прошлого семестра*.

В случае потери точности модели, не сопровождаемой значимыми изменениями по *SHAP-loss*, возможно, достаточно ограничиться дообучением модели по новым данным без изменения состава предикторов. Для нашего случая такую меру стоит попробовать применить к модели Random Forest, продемонстрировавшей заметное ухудшение качества для осенних семестров 2022/2023 и 2023/2024 учебных годов, не сопровождаемое значимыми изменениями по *SHAP-loss*.

В целом отметим, что сдвиг данных — это явление весьма характерное для образовательных данных, однако принимать решения об изменениях моделей по результатам мониторинга их работы следует, принимая во внимание не только необходимость получения точных прогнозов, но и затраты на такие изменения и готовность сотрудников, проводящих воспитательную работу со студентами, работать с динамически изменяющейся системой прогнозирования.

5. Выводы

В исследовании была разработана методика для мониторинга сдвига данных в моделях прогнозирования успешности обучения на основе значений

Шепли. Она позволяет обнаруживать разные типы сдвига данных как до появления значений целевой переменной в результате проведения промежуточной аттестации студентов, так и по завершении учебного семестра, когда истинное значение отклика становится известным. Следует подчеркнуть, что данная методика может быть эффективно применена к любым моделям машинного обучения, используемым для прогнозирования успешности обучения на основе образовательных данных. Предложенный комплексный подход позволит своевременно принимать обоснованные решения о необходимости коррекции, дообучения или замены модели прогнозирования, что обеспечит стабильность модели и предотвратит значимое снижение точности прогнозирования при эксплуатации модели в образовательном процессе.

Методика доказала свою эффективность в обнаружении сдвига данных для ансамбля моделей сервиса прогнозирования успеваемости «Пифия». По отдельным предикторам моделей выявлены значимые изменения в значениях Шепли на новых данных, что свидетельствует о наличии в выборках как ковариационного сдвига, так и сдвига концепции. Предложены варианты коррекции действующей модели.

Список источников / References

1. Дюличева Ю. Ю. Применение учебной аналитики в высшем образовании: датасеты, методы и инструменты. *Высшее образование в России*. 2024;33(5):86–111. EDN: EIDBZY. DOI: 10.31992/0869-3617-2024-33-5-86-111.
2. [Dyulichева Yu. Yu. Application of learning analytics in higher education: Datasets, methods and tools. *Higher Education in Russia*. 2024;33(5):86–111. (In Russian.) EDN: EIDBZY. DOI: 10.31992/0869-3617-2024-33-5-86-111.]
3. Kustitskaya T. A., Noskov M. V. Learning analytics in Russia and abroad: Level of development, trends and prospects. *RUDN Journal of Informatization in Education*. 2023;20(2):150–158. EDN: KEROFN. DOI: 10.22363/2312-8631-2023-20-2-150-158.
4. Sonnleitner B., Madou T., Deceuninck M., Theodosiou F., Sagaert Y. R. Evaluation of early student performance prediction given concept drift. *Computers and Education: Artificial Intelligence*. 2025;8:100369. DOI: 10.1016/j.caeai.2025.100369.
5. Maia Polo F., Izbicki R., Lacerda E. G., Ibieta-Jimenez J. P., Vicente R. A unified framework for dataset shift diagnostics. *Information Sciences*. 2023;649:119612. DOI: 10.1016/j.ins.2023.119612.
6. Hinder F., Vaquet V., Hammer B. One or two things we know about concept drift—a survey on monitoring in evolving environments. Part A: Detecting concept drift. *Frontiers in Artificial Intelligence*. 2024;7:1330257. DOI: 10.3389/frai.2024.1330257.
7. Deho O. B., Liu L., Li J., Liu J., Zhan C., Joksimovic S. When the past != the future: Assessing the impact of dataset drift on the fairness of learning analytics models. *IEEE Transactions on Learning Technologies*. 2024;17:1007–1020. DOI: 10.1109/TLT.2024.3351352.
8. Guo L. L., Pfohl S. R., Fries J., Posada J., Fleming S. L., Aftandilian C., Shah N., Sung L. Systematic review of approaches to preserve machine learning performance in the presence of temporal dataset shift in clinical medicine. *Applied Clinical Informatics*. 2021;12(04):808–815. DOI: 10.1055/s-0041-1735184.
9. Sahiner B., Chen W., Samala R. K., Petrick N. Data drift in medical machine learning: implications and

potential remedies. *The British Journal of Radiology*. 2023;96(1150):20220878. DOI: 10.1259/bjr.20220878.

9. Allogmany B., Josyula D. An approach to dealing with incremental concept drift in personalized learning systems. *IEEE 4th Int. Conf. on Cognitive Machine Intelligence (CogMI)*. 2022:139–147. DOI: 10.1109/CogMI56440.2022.00029.

10. Tiukhova E., Vemuri P., Flores N. L., Islind A. S., Óskarsdóttir M., Poelmans S., Baesens B., Snoeck M. Explainable Learning Analytics: Assessing the stability of student success prediction models by means of explainable AI. *Decision Support Systems*. 2024;182:114229. DOI: 10.1016/j.dss.2024.114229.

11. Ovadia Y., Fertig E., Ren J., Nado Z., Sculley D., Nowozin S., Dillon J., Lakshminarayanan B., Snoek J. Can you trust your model's uncertainty? Evaluating predictive uncertainty under dataset shift. *Advances in Neural Information Processing Systems*. 2019;32.

12. Намиот Д. Е., Ильюшин Е. А. Мониторинг сдвига данных в моделях машинного обучения. *International Journal of Open Information Technologies*. 2022;10(12):84–93. EDN: NDOMRK.

[Namiot D., Ilyushin E. Data shift monitoring in machine learning models. *International Journal of Open Information Technologies*. 2022;10(12):84–93. (In Russian.) EDN: NDOMRK.]

13. Wan J. S.-W., Wang S.-D. Concept drift detection based on pre-clustering and statistical testing. *Journal of Internet Technology*. 2021;22(2):465–472. DOI: 10.3966/160792642021032202020.

14. Gama J., Žliobaite I., Bifet A., Pechenizkiy M., Bouchachia A. A survey on concept drift adaptation. *ACM Computing Surveys (CSUR)*. 2014;46(4):1–37. DOI: 10.1145/2523813.

15. Gama J., Medas P., Castillo G., Rodrigues P. Learning with drift detection. *Advances in Artificial Intelligence – SBIA 2004*. 2004;3171:286–295. DOI: 10.1007/978-3-540-28645-5_29.

16. Baena-Garcia M., del Campo-Ávila J., Fidalgo R., Bifet A., Gavalda R., Morales-Bueno R. Early drift detection method. *Fourth Int. Workshop on Knowledge Discovery from Data Streams*. 2006;6:77–86.

17. Liu A., Lu J., Liu F., Zhang G. Accumulating regional density dissimilarity for concept drift detection in data streams. *Pattern Recognition*. 2018;76:256–272. DOI: 10.1016/j.patcog.2017.11.009.

18. Ackerman S., Dube P., Farchi E., Raz O., Zalmanovici M. Machine learning model drift detection via weak data slices. *2021 IEEE/ACM Third Int. Workshop on Deep Learning for Testing and Testing for Deep Learning (DeepTest)*. 2021:1–8. DOI:10.1109/DeepTest52559.2021.00007.

19. Dong S., Wang Q., Sahri S., Palpanas T., Srivastava D. Efficiently mitigating the impact of data drift on machine learning pipelines. *Proc. VLDB Endowment*. 2024;17(11):3072–3081. DOI:10.14778/3681954.3681984.

20. Ma S., Tourani R. Predictive and causal implications of using shapley value for model interpretation. *Proc. 2020 KDD workshop on causal discovery*. 2020:23–38.

21. Zheng S., van der Zon S. B., Pechenizkiy M., de Campos C. P., van Ipenburg W., de Harder H., Nederland R. Label-less concept drift detection and explanation. *NeurIPS 2019 Workshop on Robust AI in Financial Services: Data, Fairness, Explainability, Trustworthiness, and Privacy*. 2019:1–10.

22. Сомова М. В. Методическая модель персонализированного образовательного процесса на основе прогнозирования успешности предметного обучения. *Современные наукоемкие технологии*. 2023;(12-1):165–170. EDN: IARKPS. DOI: 10.17513/snt.39877.

[Somova M. V. Methodological model of personalized educational process based on prediction of success in subject training. *Modern High Technologies*. 2023;(12-1):165–170. (In Russian.) EDN: IARKPS. DOI: 10.17513/snt.39877.]

23. Kustitskaya T. A., Esin R. V., Vainshtein Y. V., Noskov M. V. Hybrid approach to predicting learning success

based on digital educational history for timely identification of at-risk students. *Education Sciences*. 2024;14(6):657. DOI: 10.3390/educsci14060657.

24. Носков М. В., Сомова М. В., Федотова И. М. Управление успешностью обучения студента на основе марковской модели. *Информатика и образование*. 2018;(10(299)):4–11. EDN: SMQFKX. DOI: 10.32517/0234-0453-2018-33-10-4-11.

[Noskov M. V., Somova M. V., Fedotova I. M. Management of the success of student's learning based on the Markov model. *Informatics and Education*. 2018;(10(299)):4–11. (In Russian.) EDN: SMQFKX. DOI: 10.32517/0234-0453-2018-33-10-4-11.]

25. Носков М. В., Вайнштейн Ю. В., Сомова М. В., Федотова И. М. Прогностическая модель оценки успешности предметного обучения в условиях цифровизации образования. *Вестник Российского университета дружбы народов. Серия: Информатизация образования*. 2023;20(1):7–19. EDN: BDFDRI. DOI: 10.22363/2312-8631-2023-20-1-7-19.

[Noskov M. V., Vaynshteyn Yu. V., Somova M. V., Fedotova I. M. Prognostic model for assessing the success of subject learning in conditions of digitalization of education. *RUDN Journal of Informatization in Education*. 2023;20(1):7–19. (In Russian.) EDN: BDFDRI. DOI: 10.22363/2312-8631-2023-20-1-7-19.]

26. Kustitskaya T. A., Esin R. V., Kytmanov A. A., Zyкова T. V. Designing an education database in a higher education institution for the data-driven management of the educational process. *Education Sciences*. 2023;13(9):947. DOI: 10.3390/educsci13090947.

27. Lundberg S. M., Lee S.-I. A unified approach to interpreting model predictions. *Neural Information Processing Systems*. 2017;30:4768–4777. DOI: 10.48550/arXiv.1705.07874.

28. Lundberg S. M., Erion G., Chen H., DeGrave A., Prutkin J. M., Nair B., Katz R., Himmelfarb J., Bansal N., Lee S. I. From local explanations to global understanding with explainable AI for trees. *Nature Machine Intelligence*. 2020;2(1):56–67. DOI: 10.1038/s42256-019-0138-9.

29. Cohen J. *Statistical power analysis for the behavioral sciences* (2nd ed.). New Jersey, Routledge; 1988. 567 p. DOI: 10.4324/9780203771587.

Информация об авторах

Кустицкая Татьяна Алексеевна, канд. физ.-мат. наук, доцент, доцент кафедры прикладной математики и анализа данных, Институт космических и информационных технологий, Сибирский федеральный университет, г. Красноярск, Россия; *ORCID*: <https://orcid.org/0000-0001-9854-1259>; *e-mail*: tkustitskaya@sfu-kras.ru

Есин Роман Витальевич, канд. пед. наук, доцент, доцент кафедры прикладной математики и анализа данных, Институт космических и информационных технологий, Сибирский федеральный университет, г. Красноярск, Россия; *ORCID*: <https://orcid.org/0000-0002-9682-4690>; *e-mail*: resin@sfu-kras.ru

Information about the authors

Tatiana A. Kustitskaya, Candidate of Sciences (Physics and Mathematics), Docent, Associate Professor at the Department of Applied Mathematics and Data Analysis, School of Space and Information Technology, Siberian Federal University, Krasnoyarsk, Russia; *ORCID*: <https://orcid.org/0000-0001-9854-1259>; *e-mail*: tkustitskaya@sfu-kras.ru

Roman V. Esin, Candidate of Sciences (Education), Docent, Associate Professor at the Department of Applied Mathematics and Data Analysis, School of Space and Information Technology, Siberian Federal University, Krasnoyarsk, Russia; *ORCID*: <https://orcid.org/0000-0002-9682-4690>; *e-mail*: resin@sfu-kras.ru

Поступила в редакцию / Received: 19.02.2025.

Поступила после рецензирования / Revised: 05.05.2025.

Принята к печати / Accepted: 06.05.2025.