

ИНТЕЛЛЕКТУАЛЬНЫЕ СРЕДСТВА ПРОГНОЗИРОВАНИЯ УСПЕВАЕМОСТИ СТУДЕНТОВ НА ОСНОВЕ ДАННЫХ ТЕКУЩЕГО КОНТРОЛЯ

Жигалов О.С., Ильин Д.Ю., Никульчев Е.В.

МИРЭА – Российский технологический университет, Москва, Россия

jigalov@mirea.ru@mirea.ru, ilin_dyu@mirea.ru, nikulchev@mirea.ru

Аннотация. Исследованы возможности применения искусственного интеллекта для прогнозирования итоговой успеваемости студентов вуза по дисциплине на основе текущих данных о посещаемости, выполнении практических и контрольных работ. Рассмотрены интеллектуальные методы классификации, получены достоверные оценки прогноза, позволяющие использовать полученные результаты в цифровой образовательной среде.

Ключевые слова: искусственный интеллект, прогнозирование успеваемости, цифровая образовательная среда.

Введение

Высокий уровень цифровой автоматизации образовательных информационных систем характеризуется использованием моделей искусственного интеллекта (ИИ) [1], часто сохраняя при этом высокий уровень персонального контроля (например, со стороны преподавателей, методистов). В образовательной среде на ИИ возлагаются задачи по прогнозированию различных показателей на основе данных учащихся, что обычно достигается с использованием ансамблями алгоритмов и таких методов, как машинное обучение или интеллектуальные агенты [2]. Несмотря на достижения по прогнозированию успеваемости требуется более целостная обработка данных по выявлению взаимосвязей между персональными психофизиологическими индивидуальными возможностями (например, рабочая память, пространственные способности, скорость реакций) и стратегиями и траекториями обучения [3]. Выявление сложных структурных взаимосвязей между данными об успеваемости со способностями к концентрации и скоростью усваивания информации можно обнаружить на основе данных, имеющихся в образовательных системах [4, 5], например, балльно-рейтинговый учет по дисциплинам, учет посещаемости, оценки за практические занятия и контрольные работы. Существует значительное количество исследований, формирующих с помощью методов ИИ прогнозы академической успеваемости: на основе данных первого года обучения [6]; на основе исторических оценок по конкретному направлению (компьютерная инженерия [7]); на основе использования моделей глубокого обучения на данных цифровой образовательной среды [8] и мн. др. Применение ИИ для анализа контрольных точек [9], позволяет оценивать общую результативность различных проектов. Таким образом, актуальной задачей является формирования ансамбля методов ИИ для прогнозирования академической успеваемости по данным текущего контроля, обеспечивающих масштабируемость используемых источников данных.

Цель исследования – рассмотреть возможность применения ИИ для прогнозирования итоговой успеваемости по дисциплине по текущим данным о посещаемости и выполнении текущих работ, используя исторические данные по дисциплине. Для проведения экспериментов рассмотрено несколько групп по одной дисциплине, для которых необходимо сформировать прогноз итоговой оценки по состоянию на заданный момент освоения дисциплины.

1. Материалы и методы исследования

Рассмотрены исторические данные девяти групп по дисциплине «Вычислительные системы, сети и телекоммуникации», направление подготовки Бизнес-информатика РТУ МИРЭА. Данные по летнему семестру 2 курса обучения 23/24 уч. года. Сведения об анализируемых группах студентов. Исходный объем данных состоял из 292 записей по состоянию на конец семестра.

Признаковое пространство сформировано на основе исходных данных (табл. 1) и включает как исходные нормализованные признаки, так и дополнительные сгенерированные признаки (табл. 2). После расстановки данных по 23 состояниям (после 1-го занятия, 2-го занятия, и т. д.) объем данных был увеличен до 6716 записей.

Итоговой оценкой является «зачтено», полученной в результате первой попытки успешного выполнения итоговой аттестации, последующие пересдачи в данном случае считаются «не зачтено». Модель ИИ должна определять «зачтено»/«не зачтено» на основании результатов текущего контроля.

Таблица 1. Исходные признаки

Признак (группа признаков)	Тип	Допустимые значения	Пояснение
steps_passed	Целое число	23	Количество прошедших учебных мероприятий
s*_type	Категориальный	Практика Лекция Контроль	Тип мероприятия. Группа из 23 признаков, где * заменяется на номер учебного мероприятия
s*_date	Дата	*	Календарная дата мероприятия. Группа из 23 признаков, где * заменяется на номер учебного мероприятия
s*_max_points	Числа с запятой	1.0 – 15.0	Максимальный балл за мероприятие. Группа из 23 признаков, где * заменяется на номер учебного мероприятия
s*_points	Числа с запятой	0.0 – 15.0	Набранный балл за мероприятие. Группа из 23 признаков, где * заменяется на номер учебного мероприятия

Таблица 2. Признаки после предобработки и нормализации

Признак (группа признаков)	Тип	Допустимые значения	Пояснение
steps_passed	Число с запятой	0.0 – 1.0	Доля прошедших учебных мероприятий
s*_type	Категориальный	Кодируется OneHotEncoder с отбрасыванием 1 категории	Тип мероприятия. Группа из 23 признаков, где * заменяется на номер учебного мероприятия
s*_date	Число с запятой	0.0 – 1.0	Дата мероприятия относительно начала и конца семестра. Группа из 23 признаков, где * заменяется на номер учебного мероприятия
s*_max_points	Числа с запятой	0.0 – 1.0	Максимальный балл за мероприятие. Группа из 23 признаков, где * заменяется на номер учебного мероприятия
s*_points	Числа с запятой	0.0 – 1.0	Набранный балл за мероприятие. Группа из 23 признаков, где * заменяется на номер учебного мероприятия
max_semester_points	Числа с запятой	1.0	Максимальный балл в семестре
required_semester_points	Числа с запятой	0.75	Необходимый балл в семестре
total_points	Числа с запятой	0.0 – 1.0	Набранная сумма баллов за мероприятия в семестре

Таким образом, необходимо решить задачу бинарной классификации на основе ансамбля моделей. В ансамбль включены классификаторы:

- RandomForest,
- AdaBoost,
- SVC (с ядром linear).

объединенные классификатором Voting с мягким голосованием.

Выполняется кроссвалидация: 8 из 9 групп используются в качестве обучающей выборки, 1 группа используется как проверочная выборка.

Для всех вариантов использовалась библиотека Scikit-learn для Python: AdaBoostClassifier с из модуля sklearn.ensemble; RandomForestClassifier из модуля sklearn.ensemble; SVC с ядром linear (остальные параметры – по умолчанию) из модуля sklearn.svm. VotingClassifier с мягким голосованием, в который вошли три предыдущих классификатора.

2. Результаты

На рисунках 1-4 показаны усредненные показатели классификации при кроссвалидации в зависимости от количества пройденных в течение семестра учебных мероприятий (лекций, практик, контрольных работ).

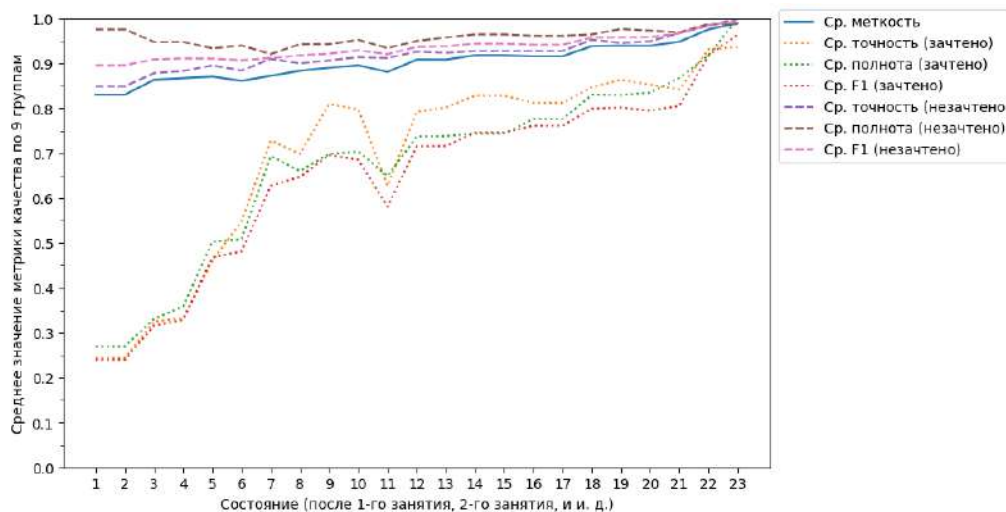


Рис. 1. Оценки для AdaBoost




Рис. 2. Оценки для RandomForest




Рис. 3. Оценки для SVC




Рис. 4. Оценки для ансамбля из 3 классификаторов с мягким голосованием

Анализ результатов показывает, что основной метрикой, на которую целесообразно ориентироваться, является средняя меткость (ассигару). В табл. 3 показана меткость (ассигару) классификатора для каждой из групп на нескольких этапах: в начале, середине и в конце семестра.

Обученный на данных 8-и групп классификатор, применялся к данным проверочной группы с результатами, формируемыми после каждого учебного мероприятия. То есть, на 1 шаге классификатор использовал данные о студентах, посетивших первую лекцию в семестре, а на 2 шаге – 1 лекцию и 1 практику. В зависимости от расписания групп порядок занятий мог отличаться. 23-й шаг фактически является моментом, когда все учебные мероприятия в семестре завершены.

Метрики F1 показывают то, насколько хорошо классификатор выделяет конкретные классы («зачтено»/«не зачтено»). Можно видеть, что классификатор в целом склоняется к большему классу и, в условиях нехватки данных в самом начале семестра, с большей вероятностью отмечает результаты студентов как «не зачтено» в итоге. Это может быть связано с дисбалансом классов в использованной выборке.

Таблица 3. Меткость для групп при классификации с использованием AdaBoost

Номер группы	Начало семестра (после 3 занятий)	Середина семестра (после 12 занятий)	Конец семестра (после 20 занятий)
1	1.00	1.00	1.00
2	0.84	0.84	0.94
3	0.78	0.81	0.86
4	0.81	0.91	0.94
5	0.85	0.94	0.97
6	0.87	0.90	0.90
7	0.94	0.91	0.91
8	0.77	0.90	0.97
9	0.91	0.97	0.97
Средняя меткость	0.86	0.91	0.94

Анализ данных и метрик показал, что лучший результат показал AdaBoost, однако ансамбль трех моделей Voting дает устойчиво достоверный прогноз успеваемости.

3. Заключение

В работе исследованы методы ИИ для формирования прогноза академической успеваемости по дисциплине на основе исторических данных, показано, что данные о текущей успеваемости дают возможность достоверно оценивать итоговую бинарную оценку («зачтено»/«не зачтено»). Используемый подход дает возможности по расширению использования методов ИИ для текущего контроля, расширяя объемы анализируемых данных, как имеющихся в цифровых образовательных средах, так и результатами специализированного тестирования.

Литература

1. *Alfredo R., Echeverria V., Jin Y., Yan L., Swiecki Z., Gašević D., Martinez-Maldonado, R.* Human-centred learning analytics and AI in education: A systematic literature review // *Computers and Education: Artificial Intelligence.* – 2024. – Vol. 6. – P. 100215.
2. *Dogan M.E., Goru Dogan T., Bozkurt A.* The use of artificial intelligence (AI) in online learning and distance education processes: A systematic review of empirical studies // *Applied sciences.* – 2023. – Vol. 13, № 5. – P. 3056.
3. *Bressane A. et al.* Understanding the role of study strategies and learning disabilities on student academic performance to enhance educational approaches: A proposal using artificial intelligence // *Computers and Education: Artificial Intelligence.* – 2024. – Vol. 6. – P. 100196.
4. *Родионов О.В., Тамп Н.В.* Технологии искусственного интеллекта в образовании // *Воздушно-космические силы. Теория и практика.* – 2022. – № 22. – С. 64–74.
5. *Сысоев П.В.* Искусственный интеллект в образовании: осведомлённость, готовность и практика применения преподавателями высшей школы технологий искусственного интеллекта в профессиональной деятельности // *Высшее образование в России.* – 2023. – Т. 32, № 10. – С. 9–33.
6. *Miguéis V.L., Freitas A., Garcia P.J., Silva A.* Early segmentation of students according to their academic performance: A predictive modelling approach // *Decision Support Systems.* – 2018. – Vol. 11. – P. 36–51.
7. *Buenaño-Fernández D., Gil D., Luján-Mora S.* Application of machine learning in predicting performance for computer engineering students: A case study // *Sustainability.* – 2019. Vol. 11, № 10. – P. 2833.
8. *Waheed H., Hassan S.U., Aljohani N.R., Hardman J., Nawaz R.* Predicting academic performance of students from VLE big data using deep learning models // *Computers in Human behavior.* – 2020. – Vol. 104. – P. 106189–106189.
9. *Албычев А.С., Червяков А.А., Никульчев Е.В., Ильин Д.Ю., Газанова Н.Ш.* Разработка интеллектуальных инструментов управления организационными системами для контроля сроков выполнения Национальных и Федеральных проектов // *Теория активных систем – 55 лет (ТАС-55): труды юбилейной научно-практической конференции, 18 ноября 2024, г. Москва / под общ. ред. Д.А. Новикова, В.Н. Буркова.* – М.: ИПУ РАН, 2024. С.11–15.