

Кукарцева Светлана Владиславовна

студентка

ФГБОУ ВО «Российский государственный аграрный
университет – МСХА им. К.А. Тимирязева»

г. Москва

Ткаченко Данил Алексеевич

студент

ФГБОУ ВО «Российская академия народного хозяйства
и государственной службы при Президенте РФ»

г. Москва

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ И АГЕНТНОГО МОДЕЛИРОВАНИЯ ДЛЯ ПРИНЯТИЯ РЕШЕНИЙ В УПРАВЛЕНИИ ОБРАЗОВАТЕЛЬНЫМИ ТРАЕКТОРИЯМИ

Аннотация: управление образовательными траекториями в условиях высокой неопределенности требует перехода от статических моделей к адаптивным системам. В работе обосновывается синтез методов потокового машинного обучения (онлайн-обучение с детекцией концептуального дрейфа) и агентного моделирования для прогнозирования и корректировки академической успеваемости студентов. Показано, что инкрементальные ансамбли снижают ошибку прогнозирования на 22–34%, обеспечивая своевременное выявление студентов группы риска.

Ключевые слова: образовательная аналитика, концептуальный дрейф, онлайн-обучение, адаптивное управление, агентное моделирование, принятие решений.

Введение: интеллектуальные системы управления образованием генерируют высокочастотную телеметрию: активность в LMS, результаты тестирований, посещаемость. Исторически использовавшиеся статические регрессионные модели, калибруемые по фиксированным историческим профилям, быстро теряют релевантность в условиях нестационарных режимов, вызванных сдвигами в

учебных планах, сезонными факторами и изменением мотивации студентов. Сравнительный анализ подтверждает преимущество нейросетевых и ансамблевых методов на нестационарных данных.

Методология потоковой обработки образовательных данных: данные об успеваемости рассматриваются как непрерывный поток. Скользящие статистики и алгоритм Уэлфорда обеспечивают однократную обработку с ограниченной памятью. Для детекции смены режимов (например, резкого падения мотивации или изменения сложности курса) применяется детектор ADWIN, который статистически строго выявляет дрейф без заданных порогов, сжимая адаптивное окно по неравенству Хеффдинга. Параллельно используется агентная модель, где каждый студент представлен как агент, выбирающий стратегии взаимодействия с учебным материалом и peers. Эндогенная память отношений позволяет моделировать формирование учебных сообществ и их влияние на индивидуальную траекторию.

Экспериментальная оценка: на реальной телеметрии образовательной платформы (prequential-протокол) адаптивный случайный лес (Adaptive Random Forest) достиг установившейся ошибки $MAE = 34.5$ (в нормализованных единицах), что на 29% ниже показателя пакетной линейной регрессии.

Таблица 1

Сравнение моделей потокового прогнозирования успеваемости

Модель	Ошибка (MAE)	Реакция на дрейф (смена режима)
Batch Linear Regression	48.6	требует полного переобучения
SGDRegressor	41.2	~45 шагов
Hoeffding Tree	38.5	~25 шагов
Adaptive Random Forest	34.5	~18 шагов

Детектор зафиксировал значимые переходы между режимами со средней задержкой 12.3 наблюдения, что достаточно оперативно для вмешательства тьютора или адаптации контента.

Обсуждение и управленческие решения: синтез потокового ML и агентного моделирования позволяет не только предсказывать отчисления, но и понимать их

социальный контекст. Если ML-модель фиксирует дрейф, а агентная модель показывает распад учебного кластера (модулярности), система рекомендует не просто индивидуальные консультации, а формирование новых проектных групп для восстановления социальной поддержки.

Заключение: адаптивный энергоменеджмент и управление образовательными траекториями на базе онлайн-обучения трансформируют структуру операционных решений университета. Переход от реактивного отчисления к проактивному, топологически и статистически обоснованному вмешательству выступает фактором социально-экономической устойчивости образовательной организации.

Список литературы

1. Черняева, П. Д. Правовые аспекты применения систем предиктивного видеомониторинга на базе компьютерного зрения / П. Д. Черняева, В. Ю. Панченко, Г. В. Кораблева // Стратегии устойчивого развития: социальные, экономические и юридические аспекты: материалы II Всероссийской научно-практической конференции (Чебоксары, 26 августа 2026 г.). – Чебоксары : Среда, 2026. – С. 408–411. – EDN ZZFHDK.

2. Правовые аспекты управления промышленными потоками данных в распределённых IoT-архитектурах / О. О. Олейникова, Е. С. Алмазова, Б. В. Потапов, Г. В. Кораблева // Стратегии устойчивого развития: социальные, экономические и юридические аспекты : материалы II Всероссийской научно-практической конференции (Чебоксары, 26 августа 2026 г.). – Чебоксары : Среда, 2026. – С. 390–393. – EDN OOLPWN.

3. Korableva, G. Adaptive method of generation of optimal production orders / G. Korableva, E. Kucheroва // E3S Web of Conferences: 2018 International Science Conference on Business Technologies for Sustainable Urban Development, SPbWOSCE 2018, St. Petersburg, 10–12 декабря 2018 года. – St. – Petersburg : EDP Sciences, 2019. – С. 02127. – DOI 10.1051/e3sconf/201911002127. – EDN CFFBTL.

4. Интерпретируемые модели машинного обучения в задачах оценки экологической и промышленной безопасности горнодобывающих предприятий /

Л. А. Казаковцев, А. С. Прудкий, И. А. Вахрушева, А. Н. Лосев // Известия Тульского государственного университета. Науки о Земле. – 2026. – № 1. – С. 169–174. – EDN GNIXFD.

5. Панфилов, И. А. Нейросетевой метод опережающего выявления предаварийных перегрузок в рудничных распределительных сетях / И. А. Панфилов, М. В. Журавлев, Е. Ф. Малыха // Безопасность труда в промышленности. – 2026. – № 7. – С. 7–13. – DOI 10.24000/0409-2961-2026-7-7-13.