

8. Грудяева Е. К. Разработка и исследование математических моделей водоочистного комплекса с мембранным биореактором как объекта управления: дис. ... канд. техн. наук. СПб.: Изд-во СПбГЭТУ «ЛЭТИ», 2016. 259 с.

9. Gujer W., Henze M., Mino T. et. al. Activated sludge model № 3 // Water Science and Technology. 1999. Vol. 39, № 1. P. 165–182.

О. I. Brikova, S. E. Dushin
Saint Petersburg Electrotechnical University «LETI»

RESEARCH OF TEMPERATURE EFFECT OF THE ENVIROMENT ON BIOLOGICAL PROCESSES IN ASM1 MODELS

The existing models describing process of biological cleaning do not consider influence of external factors therefore the purpose of work is the research of temperature effect of the environment on biological processes. Non-linear mathematical models of a nitrification and a denitrification taking into account temperature effect of the environment are presented in article. The dependence of growth rate of microorganisms on temperature opisyvtsya by the van't Hoff's equation. On the basis of the developed mathematical models computer models in the environment of MATLAB/Simulink were constructed. Solvable tasks consist in the analysis of temperature effect of the external environment on behavior of models of a nitrification and denitrification. As a result, of researches the best temperature ranges for development of a biocenosis of the fissile ooze which can be the basis for creation of mathematical ASM model taking into account a temperature factor are found.

Biological cleaning; the fissile ooze, nitrification, denitrification, mathematical model operations, temperature of the external environment, ASM models

УДК 004.048

Е. Е. Котова, А. С. Писарев
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина)

Автоматизация прогнозирования результатов обучения студентов

Предлагается метод автоматизированного прогнозирования результатов обучения студентов, отличающийся использованием разнородных факторов: результатов сдачи Единого государственного экзамена по русскому языку, математике, физике и информатике, оценок академической успеваемости и индивидуальных параметров когнитивно-познавательной сферы учащихся. Проанализированы случаи прогнозирования средних баллов обучения студентов на интервале первого года и всего периода обучения в вузе. Разработаны сценарии применения гибридных моделей классификации и регрессии для прогнозирования результатов обучения по различным дисциплинам. Процедуры прогнозирования реализованы в сетевом программном комплексе ОнтоМАСТЕР при помощи интеллектуальных агентов. Метод предназначен для повышения точности прогнозирования результатов обучения студентов и обоснованности применения методов интеллектуального анализа данных к образовательным данным (Educational Data Mining, EDM). Демонстрируется, насколько более точным может быть метод прогнозирования успеваемости обучающихся с включением в множество факторов модели индивидуальных параметров когнитивно-стилевого потенциала учащихся.

Прогнозирование успеваемости обучающихся, процесс обучения, множественная регрессия, когнитивный потенциал, интеллектуальные агенты

Технологии поддержки процессов обучения и образования в интеллектуальных системах обучения (Intelligent Tutoring Systems, ITS) значительно продвинулись благодаря методам искус-

ственного интеллекта. Стали широко использоваться интеллектуальные, интерактивные образовательные технологии, научные симуляции и виртуальные лаборатории, образовательные игры,

онлайн-ресурсы, массовые открытые онлайн-курсы, интерактивные веб-сайты и др. [1].

Внедрение информационных технологий в области образования приводит к накоплению больших объемов данных, что требует применения средств автоматизированного анализа и обработки.

Актуальность методов автоматизированного анализа данных в образовательных системах подтверждается рядом исследований процессов обучения [2]–[8]:

- динамического подхода к процессам развития (Van Geert P., Fisher K. W., Fogel A., Hollenstein T.);

- динамических систем при моделировании образовательных траекторий (Steenbeek H., Van Geert P.);

- планирования процессов обучения в гибридной (смешанной) среде, создания адаптивных систем обучения (Laurillard D.);

- методов и алгоритмов интеллектуального анализа данных в области образования (Baker R. S., Inventado P. S., Romero C., Ventura S.);

- исследований нелинейных методов и статистических инструментов для описания изменений в производительности студентов (Stamovlasis D.);

- применения аналитических инструментов для процессов принятия решений в условиях роста образовательных данных, требующих извлечения знаний из массивов данных (Bala M.);

- управления качеством и содержанием учебных программ, соответствующих требованиям рынка труда (Achcaoucaou F., Wilson R.);

- применения агентного подхода для построения архитектуры системы управления обучением с учетом различных видов учебной деятельности учащихся (Samadyar Z.);

- создания стереотипных моделей групп учащихся (Rafferty A. N., Yudelson M.)

- применения инструментов и стандартов анализа и структурирования управляемого учебного контента (Qamar S.)

Основные подходы методов интеллектуального анализа данных к образовательным данным (Educational Data Mining, EDM) применяются для прогнозирования, кластеризации, анализа отношений, обнаружения и извлечения данных с целью принятия решений человеком [9].

В новых исследованиях применяются методы EPM (Educational process mining) для анализа процессов обучения [10]. Process mining является новой дисциплиной, обеспечивающей основанное на фактах понимание и поддержку процессов, и предоставляет новые средства для улучшения процессов в различных областях применения

[11]. Отмечаются значительные преимущества в сочетании образовательных данных с методами PM для понимания образовательных процессов.

При помощи автоматизированного анализа с применением методов машинного обучения (Machine Learning – ML), в частности методов прогнозирования, возможно прогнозировать индивидуальные результаты обучения студентов в условиях неопределенности внешних воздействий среды обучения, оценивать действия учащихся и различия между ними, факторы, связанные с успехом или неудачей (например, [12]–[16] и др.).

К факторам неопределенности относятся: неполнота экспериментальных данных, методические погрешности обработки, погрешности методов и неопределенность моделей, неполнота знаний о начальных состояниях и различные возмущающие воздействия в процессах обучения. В зависимости от наличия априорной информации для описания факторов неопределенности применяются стохастические, статистические, интервальные и нечеткие методы [17]–[20].

Цель описываемой работы – разработка метода автоматизированного прогнозирования результатов обучения студентов в вузе на основе данных Единого государственного экзамена (ЕГЭ), оценок академической успеваемости и дополнительных параметров когнитивно-стилевого потенциала, характеризующих познавательно-мыслительные стратегии обучающихся в процессе учебной деятельности.

Дальнейшее содержание статьи включает: раздел 1 – общее описание постановки задачи; раздел 2 – описание метода прогнозирования результатов обучения; раздел 3 – примеры и результаты экспериментальных исследований; раздел 4 – архитектура программного комплекса; раздел 5 – завершение обсуждений и результаты.

1. Общее описание постановки задачи. Для достижения поставленной цели решается 2 типа задач: прямая и обратная, что позволяет сравнивать различные методы анализа данных. Подзадачами являются: выбор модели прогнозирования и анализ точности построенного прогноза.

Прогнозирование численных значений оценок результатов обучения студентов относится к постановке прямой задачи, которая формулируется следующим образом: требуется предсказать значение выходной переменной Y (например, средние баллы обучения студентов за семестр или за весь период обучения и др.) в зависимости от значений входных переменных X (например, баллы ЕГЭ, результаты успеваемости в семестре и др.) на основе модели

анализа данных f , представляющей отображение: $f: X \rightarrow Y$. Для решения прямой задачи необходима структура и значения параметров модели анализа данных, входные переменные и факторы.

Поиск модели анализа данных f в виде множественной регрессии формулируется в виде обратной задачи: найти отображение f^* (структуру модели, значимые факторы и значения коэффициентов) при известных априорных значениях независимых переменных (факторов) X и зависимой переменной Y , которое обеспечивает экстремум критерия качества модели при выполнении условий, заданных в виде ограничений.

Определение независимых переменных, соответствующих конкретной предметной области и цели прогнозирования, представляет собой отдельную задачу. В описываемой работе помимо балльных оценок успеваемости студентов в качестве независимых переменных модели предложены параметры когнитивно-стилевого потенциала (КСП) с целью проверки гипотезы, что включение в модель в качестве независимых переменных параметров КСП позволит повысить точность прогноза успеваемости обучающихся.

Для решения задачи автоматизированного прогнозирования результатов обучения студентов разработан метод интервального прогноза с учетом принципа последовательного раскрытия неопределенности [21].

2. Метод автоматизированного прогнозирования результатов обучения. Итоговые результаты академической успеваемости студентов по дисциплинам в конце каждого семестра формируют средние баллы соответствующих участков (сегментов) траекторий обучения. В разработанном методе применяются процедуры последовательного уточнения прогноза результатов обучения с использованием данных ЕГЭ, параметров модели КСП и оценок студентов. На рис. 1 изображен алгоритм последовательного уточнения прогноза результатов обучения.

Формирование модели анализа данных (обратная задача) осуществляется с применением следующих процедур:

- создания обучающих и тестовых выборок с данными ЕГЭ и оценками результатов учебной деятельности студентов на основе априорных данных;
- подготовки данных, характеризующих параметры когнитивно-стилевого потенциала (когнитивной модели) учащихся;
- построения регрессионных моделей с использованием различных структур регрессионных моделей (линейных и нелинейных), значимых факторов X и методов регрессионного анализа;

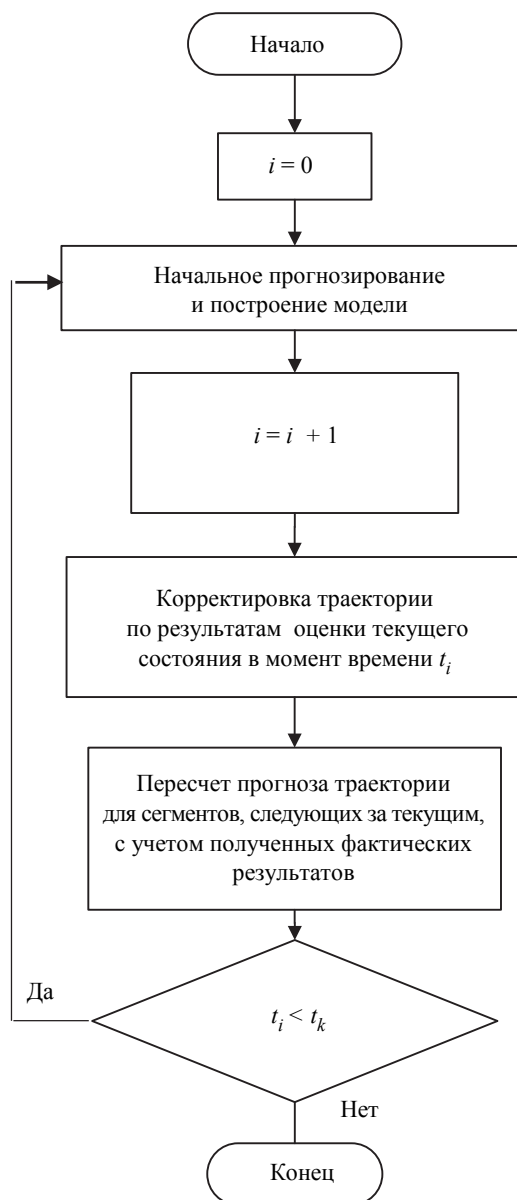


Рис. 1

– оценки качества моделей на тестовых выборках.

Прогнозирование результатов обучения для новых групп студентов на основе разработанных моделей (прямая задача) осуществляется с помощью процедур:

- сбора данных ЕГЭ и результатов (оценок и др.), полученных на определенном этапе прогнозирования;
- диагностики параметров когнитивной модели;
- начального прогноза результатов обучения студентов 1-го курса к окончанию первого года обучения и к окончанию бакалавриата;
- последовательного уточнения результатов индивидуальных прогнозов по каждому студенту с учетом оценок, полученных в процессе обучения, и параметров КСП.

3. Результаты экспериментальных исследований. Разработанные процедуры, реализующие метод, были применены при исследовании задач автоматизированного прогнозирования результатов обучения.

Ввиду того, что в различных исследованиях и системах обучения используются разные системы оценок академического обучения (баллы Болонской системы, в отечественном обучении – балльная система от 2 до 5 (от 0 до 5) и др.), в данной статье для сравнения результатов, полученных в различных исследованиях, производится нормализация данных (баллов) в интервале [0–1].

Данные – баллы ЕГЭ и средние баллы представлены в нормализованной шкале [0, 1]:

$$Y_e = X_e / X_{\max}, Y_a = (X_a - 2) / 3,$$

где X_e – значение балла ЕГЭ; X_a – значение среднего балла по пятибалльной шкале [2, 5]; Y_e, Y_a – нормализованные значения баллов по шкале [0, 1].

Далее приведены примеры исследований: прогнозирования средних баллов за первый год обучения; прогнозирования средних баллов за весь период обучения; прогноза результатов обучения по дисциплинам.

1. Прогнозирование средних баллов за первый год обучения. В качестве экспериментальных данных использовались баллы ЕГЭ и значения средних баллов студентов за первый год обучения. Экспериментальную выборку составили 152 студента по направлениям подготовки «Информационные системы и технологии», «Управление в технических системах», обучающиеся в 2015–17 гг.

На рис. 2 изображена гистограмма распределения средних баллов студентов, полученных за первый год обучения. Получены значения: среднее значение среднего балла $\mu = 0.65$, стандартное отклонение $\sigma = 0.14$ по нормализованной шкале.




Рис. 2

Сравнительный анализ баллов ЕГЭ и средних баллов за первый год обучения проведен с помощью множественного регрессионного анализа с использованием 50 %-х обучающих и тестовых выборок данных. Прогноз среднего балла ($nsr1$) по наиболее значимому фактору ($nege$ – суммарный балл ЕГЭ) осуществляется со среднеквадратической ошибкой $RMSE \sigma = 0.15$:

$$nsr1 = 0.24nege + 0.47.$$

Далее с учетом дополнительных факторов КСП прогноз среднего балла ($nsr1$) осуществляется с меньшим значением среднеквадратической ошибки $RMSE \sigma = 0.12$:

$$\begin{aligned} nsr1 = & 0.238nege + 0.0192pzmes + \\ & + 0.0013errsum3 - 0.003tsum3 + 0.0034T3minusT2 + \\ & + 0.2723T2delT1 + 0.009P1 - 0.0248P2 + \\ & + 0.7916H3 - 1.0162Hsr - 0.1994Hobr2 + 0.9052. \end{aligned}$$

На рис. 3 представлена гистограмма частот среднеквадратических ошибок ($RMSE$).




Рис. 3

2. Прогнозирование средних баллов за весь период обучения. В качестве экспериментальных данных использовались баллы ЕГЭ: средний балл, баллы по русскому языку, математике, профильной дисциплине (физика, информатика) и значения средних баллов за весь период обучения в 2014–18 гг. для студентов СПбГЭТУ «ЛЭТИ» по направлениям подготовки «Информационные системы и технологии», «Управление в технических системах».

Сравнительный анализ баллов ЕГЭ и средних баллов за весь период обучения проведен с помощью множественного регрессионного анализа с использованием 50 %-х обучающих и тестовых

выборок данных. Прогноз среднего балла ($nsr4$) по наиболее значимому фактору ($nmath$ – балл ЕГЭ по математике) осуществляется со среднеквадратической ошибкой $RMSE \sigma = 0.12$:

$$nsr4 = 0.56nmath + 0.3.$$

На рис. 4 изображен график прогноза средних баллов в нормализованной шкале за весь период обучения в вузе.

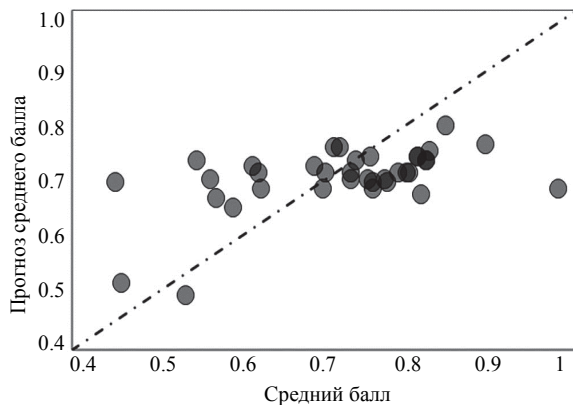


Рис. 4

Из графика можно заключить, что на данной выборке обучающихся лучший прогноз осуществляется в середине шкалы значений средних баллов для наибольшего числа студентов. Для некоторых учащихся точный прогноз осуществить затруднительно ввиду необходимости учета иных факторов когнитивной модели, которые в данной статье не рассматриваются.

3. Прогноз результатов обучения по дисциплинам. Сравнительный анализ баллов ЕГЭ и значений оценок, полученных по дисциплине «Математический анализ» во 2-м семестре, проведен с помощью множественного регрессионного анализа с использованием 50 %-х обучающих и тестовых выборок данных. Прогноз оценок по дисциплине во 2-м семестре ($nmath2$) по наиболее значимому фактору ($nmath1$ – оценка по дисциплине за 1-й семестр) осуществляется со среднеквадратической ошибкой $RMSE \sigma = 0.23$:

$$nmath2 = 0.48nmath1 + 0.31.$$

Прогноз результатов обучения по дисциплине «Интеллектуальные технологии и представление знаний» («ИТиПЗ») осуществлялся с использованием баллов ЕГЭ, оценок по предыдущим дисциплинам и параметров модели КСП [22] для 160 студентов по направлениям подготовки «Информационные системы и технологии», «Управление в технических системах», обучающихся в 2014–17 гг. После предварительной классификации

студентов на 3 условные группы, обозначенные: high (H), average (A) и special (S) по успешности обучения, для каждой группы были построены регрессионные модели. Последовательное применение методов классификации и регрессии на 50 %-й тестовой выборке студентов позволяет прогнозировать оценки успешности обучения по условным группам со среднеквадратической ошибкой $RMSE: \sigma = 0.08$ (рис. 5). На рис. 5 светлыми точками обозначены результаты прогноза успеваемости студентов в баллах по нормализованной шкале условно «сильной» группы (high (H) – группа). Для условно «слабых», менее продуктивных студентов (обозначены темными точками на рисунке) визуально заметно, что прогноз осуществляется практически с минимальной ошибкой, т. е. для данной группы получена наивысшая точность прогнозирования. Этот результат важен, так как в первую очередь необходимо выявить обучающихся группы «риска», нуждающихся в дополнительном внимании со стороны педагогов и образовательной среды.




Рис. 5

Полученные результаты подтверждают гипотезу о том, что включение в модель в качестве независимых переменных параметров КСП позволяет повысить точность прогноза успеваемости обучающихся. Для сравнения, например, в исследовании [23] к данным академической базы данных информационной системы университета применены методы регрессионного анализа (SVR, Random Forest, AdaBoost.R2 и др.). Полученные оценки точности моделирования и прогнозирования результатов обучения характеризуются значениями среднеквадратических ошибок (Root Mean Squared Error, RMSE) в интервале от 0.23 до 0.27 в нормализованной шкале.

4. Реализация метода автоматизированного прогнозирования в структуре программного комплекса. Метод прогнозирования результатов

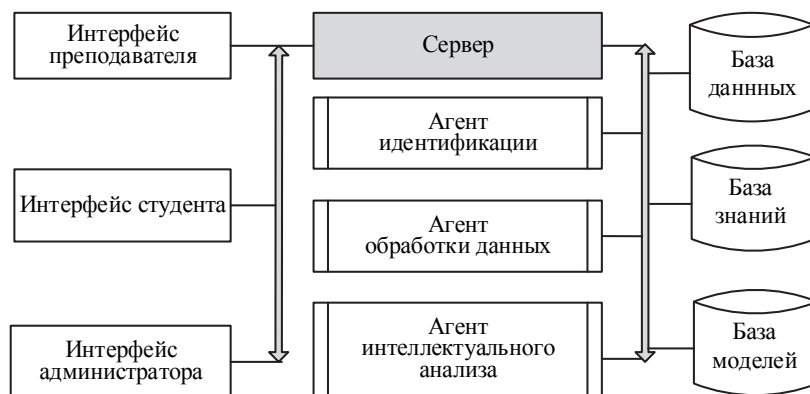


Рис. 6

обучения реализован в автоматизированной системе в сетевом программном комплексе ОнтоМАСТЕР. Архитектура комплекса изображена на рис. 6, содержит следующие компоненты:

- интерфейс преподавателя;
- интерфейс студента;
- интерфейс администратора;
- web-серверы;
- базу данных (БД);
- базу знаний (БЗ) и базу моделей;
- программные агенты интеллектуального анализа данных: диагностики и идентификации параметров модели КСП, обработки данных.

Интерфейс преподавателя обеспечивает взаимодействие преподавателя с системой и студентами.

Интерфейс студента предназначен для взаимодействия с системой, преподавателями и студенческой группой.

Интерфейс администратора позволяет поддерживать базу данных в актуальном состоянии, контролировать функционирование информационно-вычислительных средств.

В базе данных поддерживается актуальное состояние информации о составе групп обучающихся, дисциплинах, результатах обучения, оценках по дисциплинам, средних баллах за семестры, баллах ЕГЭ, архивные и др. данные.

В базе знаний и базе моделей содержится описание моделей прогнозирования и моделей когнитивно-стилевого потенциала студентов.

Программные агенты обеспечивают выполнение процедур обработки результатов экспресс-диагностики параметров моделей КСП студентов, формирование моделей регрессионного анализа и прогнозирование результатов обучения [22].

Диагностирование параметров когнитивной модели студентов осуществляется с использованием web-интерфейса. В программном комплексе ОнтоМАСТЕР (<http://ontomaster.ru/diagnostic/>)

реализованы диагностические методики, на базе которых определяются когнитивные параметры в виде комплексной модели КСП. Компьютерная реализация модифицированной версии методики Струп-М [24]–[26] позволяет фиксировать и получать данные диагностирования в виде параметров КСП: времени и скорости выполнения заданий, числа ошибок и др.

Агенты интеллектуального анализа данных обеспечивают автоматизированное формирование моделей классификации и регрессионного анализа и реализуются с применением методов LinearRegression, AdditiveRegression, Regression-ByDiscretization, M5Rules, M5P и др. [27].

5. Обсуждения и результаты. Целью описываемой работы было изучение возможностей применения методов анализа данных для построения прогноза учебной деятельности студентов. Основная гипотеза исследования заключалась в том, что включение в модель в качестве независимых переменных индивидуальных параметров когнитивно-мыслительной сферы (параметров когнитивно-стилевого потенциала) позволяет повысить точность прогноза успеваемости обучающихся.

В качестве предварительного анализа авторы обнаружили, что прогноз успешности обучения по баллам ЕГЭ не подтверждается. Аналогичные результаты были получены авторами ранее ([28] и др.). В зарубежных исследованиях в качестве независимых переменных собираются различные данные: возраст, пол, статус ученика, речевые особенности, уровень образования, уровень активности (в том числе и демографические данные), которые важны для выявления различий в процессе обучения. Например, предварительно проводится так называемый демографический опрос [29]. В других исследованиях были использованы следующие переменные: возраст, пол, семейное положение, национальность, перемеще-

ние места жительства, стипендия, особые потребности, тип студента (обычный, мобильный, экстраординарный), статус студента (обычный, занятый, спортсмен...), год зачисления, отложенные курсы, тип занятости (полный рабочий день, неполный рабочий день) и даже «долговая ситуация» [23]. Авторы рекомендуют расширить область исследования и влияния разнообразных индивидуальных характеристик на процессы обучения, например, включать в целевые переменные личные интересы, время занятий, навыки управления, занятия спортом, привычки сна и т. д. [23].

Сбор образовательных данных весьма ресурсоемкий процесс. Особенность образовательных данных – сильно контекстно-зависимые и не очень большие наборы данных. Типичные проблемы – данные могут быть распределены по различным источникам. Сбор данных осуществляется из разных источников: из административной информации, учебных классов, онлайн-среды обучения, журналов событий и т. п. Таким образом образовательная среда может создавать сложные модели, которые трудно понять, так называемые spaghetti models [30].

Наиболее частые цели в современных исследованиях сосредоточены на получении лучшего понимания основных образовательных процессов на основе обнаружения трудностей обучения [30]. Трудности могут быть непредсказуемыми и сильно различаться от человека к человеку, и педагоги должны очень оперативно получить данные, чтоб определить их [31], в то время как текущие оценки дают данные слишком поздно для педагогов, чтобы успеть повлиять на обучение студентов [32]. Следующие важные шаги должны способствовать обмену онлайн-сбора данных, которые могут быть проанализированы с разных точек зрения, с различными методами и инструментами [30]. Примеры данных в открытом доступе практически отсутствуют. Доступный для исследователей пример бесплатного набора данных Educational process mining (EPM) приводится в Техни-

ческом университете Эйндховена Eindhoven University of Technology (Eindhoven University of Technology research portal, <https://research.tue.nl/en/>) [33].

Включение авторами статьи КСП в параметры модели относится к показателю «когнитивной готовности», который означает умственную подготовку к будущей профессиональной деятельности.

В статье представлен метод автоматизированного прогнозирования результатов обучения студентов с использованием параметров КСП учащихся, данных ЕГЭ по русскому языку, математике, физике и информатике и оценок академической успеваемости.

Дополнительный учет параметров КСП позволяет снизить среднеквадратическую ошибку (RMSE) прогнозирования средних баллов за 1-й год обучения до 0.12 и прогнозирования результатов обучения студентов по дисциплинам до 0.08. Метод автоматизированного прогнозирования реализован в сетевом программном комплексе ОнтоМАСТЕР [34], зарегистрированном в Государственном Реестре программ.

Исследование авторов демонстрирует потенциал технологии РМ для образовательной сферы. На примере показано, что эта технология полезна не только в исследовании «исторических» данных, но и в содействии принятию решений для педагогов, методистов, советников по образованию, экспертов и студентов, например за счет использования различных сценариев «что..., если...», которые могут быть смоделированы с учетом существующих ограничений с целью представления рекомендаций по изучению учебных курсов (дисциплин) для студентов на основе ожидаемых результатов.

Будущие работы касаются исследований стратегий обучения для оценки и повышения когнитивной готовности с целью принятия решений по персональным рекомендациям студентам в процессе обучения.

СПИСОК ЛИТЕРАТУРЫ

1. Koedinger K. R. New potentials for data-driven intelligent tutoring system development and optimization // AI Magazine. 2013. Vol. 34, № 3. P. 27–41.
2. Bala M., Ojha D. B. Study of applications of data mining techniques in education // Intern. J. of Research in Science and Technology. 2012. Vol. 1, № 4. P. 1–10.

3. Laurillard D. Digital technologies and their role in achieving our ambitions for education. London: University of London, Institute of Education, 2008. 40 p.
4. Stamovlasis D. Bifurcation and hysteresis effects in student performance: the signature of complexity and chaos in educational research // Complicity: An Intern. J. of Complexity and Education. 2014. Vol. 11, № 2. P. 51–64.

5. Steenbeek H., van Geert P. The emergence of learning-teaching trajectories in education: A complex dynamic systems approach // *Nonlinear dynamics, psychology, and life sciences*. 2013. Vol. 17, № 2. P. 233–267.
6. Van Geert P. Dynamic modeling for development and education: from concepts to numbers // *Mind, Brain, and Education*. 2014. Vol. 8, № 2. P. 57–73.
7. Daniel B. Big data and analytics in higher education: Opportunities and challenges // *British j. of educational technology*. 2015. Vol. 46, № 5. P. 904–920.
8. Rafferty A. N., Yudelson M. Applying learning factors analysis to build stereotypic student models // *Frontiers in Artificial Intelligence and Applications*. 2007. Vol. 158, № 697. P. 51.
9. Asif R., Merceron A. Analyzing undergraduate students' performance using educational data mining // *Computers & Education*. 2017. Vol. 113. P. 177–194.
10. Bogarín A., Cerezo R., Romero C. A survey on educational process mining // *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*. 2018. Vol. 8, № 1. P. 1–17.
11. Van Der Aalst W. *Process mining: discovery, conformance and enhancement of business processes*. Heidelberg: Springer, 2011. Vol. 2. 352 p.
12. Romero C., Ventura S. Educational data mining: A survey from 1995 to 2005 // *Expert systems with applications*. 2007. Vol. 33, № 1. P. 135–146.
13. Baker R. Data mining for education // *Intern. encyclopedia of education*. 2010. Vol. 7, № 3. P. 112–118.
14. Strecht P., Cruz L., et al. A Comparative Study of Classification and Regression Algorithms for Modelling Students' Academic Performance // *Intern. Educational Data Mining Society. Proc. of the 8th Intern. Conf. on Educational Data Mining*. 2015. P. 392–395.
15. Wang R., Zaïane O. R. Sequence-based Approaches to Course Recommender Systems // *Intern. Conf. on Database and Expert Systems Applications*. Cham: Springer, 2018. P. 35–50.
16. Romero C. Discovering prediction rules in ANA! courses // *Intern. Conf. on User Modeling*. Berlin, Heidelberg: Springer, 2003. P. 25–34.
17. Беллман Р., Заде Л. Принятие решений в расплывчатых условиях // *Вопросы анализа и процедуры принятия решений*. М.: Мир, 1976. С. 172–215.
18. Куржанский А. Б. *Управление и наблюдение в условиях неопределенности*. М.: Наука, 1977. 392 с.
19. Орловский С. А. Проблемы принятия решений при нечеткой исходной информации. М.: Наука, 1981. 206 с.
20. Самарский А. А., Вабищевич П. Н. Численные методы решения обратных задач математической физики. М.: ЛКИ, 2007. 480 с.
21. Vavilov A. A. *Modellierung Analyse und evolutionaere Synthese komplizierter Steuerungssysteme // Modellierung und Simulation von Produktionsprozessen*. Berlin: VEB Verlag Technik, 1983. P. 14–87.
22. Котова Е. Е., Писарев А. С. Анализ данных в образовательной среде с применением интеллектуальных агентов // *Тр. VII всерос. науч.-практ. конф. (НСМВИТ-2017)*. Т. 2. СПб.: Политехника-сервис, 2017. С. 108–117.
23. Strecht P., Cruz L. A Comparative Study of Classification and Regression Algorithms for Modelling Students' Academic Performance // *Proc. for the 8th Intern. Conf. on Educational Data Mining*, Madrid, Spain, 2015. P. 392–395.
24. Имаев Д. Х., Котова Е. Е. Компьютерная имитация процесса обучения в условиях периодического контроля успеваемости // *Изв. СПбГЭТУ «ЛЭТИ»*. 2014. № 1. С. 74–79.
25. Имаев Д. Х., Котова Е. Е. Оценка параметров динамических моделей обучаемых по результатам экспресс-диагностирования // *Изв. СПбГЭТУ «ЛЭТИ»*. Современные технологии образования. 2015. № 1. С. 70–75.
26. Kotova E. E. Intellectual data analysis in the educational process // *XX IEEE Intern. Conf. St. Petersburg: IEEE*, 2017. P. 757–759.
27. *Data Mining: Practical machine learning tools and techniques* / I. H. Witten, E. Frank, M. A. Hall, C. J. Pal. USA: Morgan Kaufmann. 2016. 629 p.
28. Котова Е. Е. Планирование адаптивных управляющих дидактических стратегий на начальном этапе обучения в вузе // *Изв. СПбГЭТУ «ЛЭТИ»*. Современные технологии образования. 2011. № 8. С. 91–98.
29. Starr E. L., Reilly J. M., Schneider B. Toward Using Multi-Modal Learning Analytics to Support and Measure Collaboration in Co-Located Dyads // *Conf. ICLS*. URL: <https://repository.isls.org/handle/1/888>
30. Bogarín A., Cerezo R., Romero C. A survey on educational process mining // *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*. 2018. Vol. 8, № 1. P. 1–17.
31. Real-Time Scaffolding of Students' Online Data Interpretation During Inquiry with Inq-ITS Using Educational Data Mining / J. D. Gobert, M. Auer, A. Azad, A. Edwards, T. I. de Jong. URL: <https://link.springer.com/book/10.1007%2F978-3-319-76935-6>.
32. Pellegrino J. W., Chudowsky N., Glaser R. *Knowing what students know: The science and design of educational assessment*. Washington: National Academy Press, 2001. 379 p.
33. Educational process mining (EPM): a learning analytics data set, UCI Machine Learning Repository. Educational process mining (EPM): a learning analytics data set / M. Vahdat, L. Oneto, D. Anguita, M. Funk, G. W. M. Rauterberg. URL: <https://research.tue.nl/en/datasets/educational-process-mining-epm-a-learning-analytics-data-set>.
34. Котова Е. Е., Писарев А. С., Писарев И. А. Программный комплекс анализа информационных ресурсов ОнтоМАСТЕР-Ресурс. Свидетельство о государственной регистрации программы для ЭВМ № 2018611107 от 24 января 2018 г.

E. E. Kotova, A. S. Pisarev
Saint Petersburg Electrotechnical University «LETI»

AUTOMATED PREDICTION OF STUDENT LEARNING OUTCOMES

A method and procedures for automated forecasting of students learning outcomes have been developed, distinguished by the use of heterogeneous factors: the results of taking the Unified State Examination in Russian, mathematics, physics and computer science, assessments of academic performance and parameters of students' cognitive-style potential. The application of the developed method and procedures allows to increase the accuracy of forecasting the results of student learning. Analyzed cases predict the average scores in the interval of the first year and the entire period of study in the university. Developed scenarios for the use of hybrid models of classification and regression for predicting learning outcomes in the disciplines. The prediction procedures are implemented in the OntoMASTER network software complex. The method is designed to improve the accuracy of prediction and the validity of controlling didactic effects (resources) based on dynamically changing data obtained in the learning process.

Predicting student performance, learning process, multiple regression, cognitive potential, intellectual agents

УДК 78.21.14

С. А. Багрецов, Н. А. Карпенчук
Военно-космическая академия им. А. Ф. Можайского

В. С. Карпенко
Военная академия связи им. С. М. Буденного

Методика выбора форм и методов проведения занятий с учетом значимости репрезентативных систем обучаемых

Рассматривается задача выбора рациональных форм и методов проведения занятий с учетом доминирующих форм репрезентативных систем обучаемых как важнейшее условие психолого-педагогического обеспечения их эффективной когнитивной адаптации на занятиях. Показано, что наиболее актуальным становится учет этих факторов на старших курсах обучения в вузе, когда начинают изучаться практические дисциплины с использованием на занятиях изучаемых технических объектов или их элементов и определяются особенности управления ими в реальных условиях их функционирования. При выборе форм и методов изложения материала учитывается преобладание групповых форм практического обучения в вузе. Во внимание принимается в целом сложившийся на старших курсах групповой характер восприятия информации, учитывающий неоднородность статусного распределения индивидов в группе. В основу реализуемой методики выбора рациональных форм и методов проведения занятий с учетом доминирующих форм репрезентативных систем обучаемых положен метод анализа иерархий в предположении о нечеткости их выраженности и применяемых средств диагностики репрезентативных систем обучаемых.

Обучаемые, репрезентативные системы, функция принадлежности, статусный потенциал

Важнейшим условием и правилом психолого-педагогического воздействия на обучаемых в целях обеспечения их эффективной когнитивной адаптации на занятиях является их дифференциация по типу ведущей репрезентативной системы (ВРС) и детерминация психолого-педагогического воздействия особенностями их мыслительных процессов, отнесенных к конкретным психогрупп-

пам [1]. Особенно это актуально на старших курсах, когда начинают изучаться практические дисциплины с применением на занятиях изучаемой техники и определяются особенности ее применения в реальной обстановке.

Дифференциация и индивидуализация воздействия на обучаемых, основанная на признаке репрезентаций, объективна и не зависит от со-