

ISSN 2310-273X

ПЕДАГОГИЧЕСКАЯ
НАУКА и ОБРАЗОВАНИЕ

ИЗДАЁТСЯ С ОКТЯБРЯ 2012 ГОДА

ЕЖЕКВАРТАЛЬНЫЙ НАУЧНЫЙ ЖУРНАЛ

2020 2 (31)

INFORMATION. EVENTS. FACTS	
	Information on awarding the academic degrees of Doctor and Candidate of Sciences (September 2019 — March 2020) 3
EDUCATIONAL PHILOSOPHY	
A. D. Korol, I. V. Tayanovskaya	The conceptual circle of multilateral organization of the discussion: the heuristic aspect (Ending. Beginning at No. 4/2019.) 11
PSYCHOLOGICAL AND PEDAGOGICAL RESEARCH	
V. F. Rusetsky	Educational orientation of scientific and methodological support in academic subjects of general secondary education institutions 16
A. N. Astashova	Psychological and pedagogical features of the implementation of the differentiated approach to teaching at the first stage of general secondary education 22
V. L. Lozitsky	Functions of the teacher of the STEM-education center in the aspect of the subject-subject interaction of participants in the complete pedagogical process. 31
METHODS OF TRAINING AND EDUCATION	
N. A. Moiseeva	Methods for predicting learning outcomes based on neural networks 38
PROFESSIONAL TRAINING	
G. M. Buldyk	Mathematics as one of the factors in the formation of professional competencies of Bachelor students 49
B. A. Drobyshevsky	The role of psychological support in the process of training future teachers 58
PRESCHOOL EDUCATION	
N. S. Starzhinskaya, V. P. Tukach	The formation and development of innovative preschool education in the Republic of Belarus (the second half of the 80s of the XX century — the beginning of the XXI century) 63
INCLUSIVE EDUCATION	
V. A. Shinkarenko	Possibilities for mastering the content of general secondary education by pupils with mental development disorders (learning difficulties) 73
O. F. Valkovich	Interpersonal aspects of school adaptation of children with severe speech disorders 83
E. A. Obukhovskaya	The formation of perception of information of different modality in children with autistic disorders 91
REVIEWS	
V. P. Tarantei	Ethical and pedagogical thought of Belarus in the X—XVIII centuries: ontogenesis and continuity of development 99

Editorial Office Address:
16, Korolya str., Minsk,
220004, Belarus
Tel: (017) 200 54 09
Fax: (017) 200 56 35
E-mail: red.pednauka@gmail.com

Signed for printing 18.06.2020.
Format 60 × 84¹/₈
Cov. sheets 11,63
Publ. sheets 10,24
Circulation 101 copies
Order No. 0455

The issue was prepared by:
Cover and layout design L. Zaluzhnaya
Computer layout E. Shatilo
Editors O. Panina, M. Shpilevskaya
Proof-readers O. Panina, M. Shpilevskaya
Computer typing I. Mazurenko

Scientific and Methodological Institution «The National Institute of Education» of the Ministry of Education of the Republic of Belarus

The state registration certificate of the publisher, manufacturer and publication distributor: No. 1/263 of 02.04.2014
Address: 16, Korolya str., Minsk, 220004, Belarus

Printed at the JSC «Prompechat»
The state registration certificate of the publisher, manufacturer and publication distributor: No. 2/21 of 29.11.2013
Address: 3, Chernyakhovsky str., Minsk, 220049, Belarus

The opinions expressed in the journal do not always coincide with the editorial point of view. The responsibility for the information and views set out in the articles lies entirely with the authors. Hyphenation of some words is not accomplished according to the rules of grammar, but capabilities of the computer.

УДК 37.013, 51.37

Методика прогнозирования результатов обучения на основе нейронных сетей

Моисеева Наталья Александровна, старший преподаватель кафедры общей математики и информатики механико-математического факультета Белорусского государственного университета; *VoronkinaNA@bsu.by*

Разработана и исследована нейросетевая модель интегрированного обучения студентов по дисциплине «Высшая математика с основами информатики». Предложен новый подход к нейросетевому описанию трудно формализуемого процесса обучения студентов, основанный на моделировании процесса передачи знаний в зависимости от личностных характеристик студента и факторов среды обучения. Данный подход включает разработку алгоритма конструирования нейросетевой модели, прогнозирующей знания, умения и навыки у студентов по дисциплине.

Ключевые слова: моделирование процесса обучения; прогнозирование полученных знаний; нейросетевые технологии.

В настоящее время способность предвидеть и прогнозировать будущее педагогических явлений, процессов, а также влиять на них, установив основные факторы воздействия, становится одним из главных условий организации эффективного учебного процесса. По мере совершенствования системы образования проблема нахождения достоверных прогнозов всё больше актуализируется, так как принятие обоснованных дидактических и воспитательных решений требует более глубоких методов анализа и более совершенных прогностических моделей [1].

На эффективность обучения влияет совокупность различных факторов. Тестирование по дисциплине с использованием информационных технологий позволяет быстро и достоверно получить данные об уровне первоначальных (входных) знаний обучающихся. Важным фактором является также множество различных индивидуальных особенностей обучаемых. В частности, в работе [2] акцентируется внимание на том факте, что формально процесс обучения студентов, в простейшем случае, можно представить

в виде совокупности нескольких векторов: двумерного вектора интеллекта обучаемого ($F; C$), вектора состояния ($X; Y$) и вектора управления ($H; U$). Данная модель позволяет спрогнозировать уровень усвоения учебного материала каждым студентом.

Разработанная нами интегрированная система обучения «Высшей математике с основами информатики» состоит из четырёх блоков:

1. Теоретико-практический (включает теоретические и практические сведения о дисциплине).
2. Технологический (предписывает учёт природных задатков, а именно построение модели индивидуальных характеристик с помощью диагностики личностных характеристик).
3. Аналитико-прогностический (ориентирует на анализ обучения, планирование и прогноз, а также коррекцию деятельности педагога).
4. Управленческий (позволяет осуществить своевременный контроль, регуляцию и коррекцию образовательного процесса).

Эффективным инструментом прогнозирования будущих результатов являются нейросетевые технологии, благодаря которым можно построить достаточно точный прогноз уровня усвоения студентом теоретико-практического блока интегрированной системы обучения. Нейросетевые технологии призваны решать трудно формализуемые задачи, к которым, в частности, сводятся многие проблемы обучения и преподавания. В первую очередь это связано с тем, что преподавателю часто предоставлен недостаточный объём информации об обучающихся, для которых ещё не созданы математические модели.

Основная цель нейросетевой реализации процесса обучения студентов — воспроизведение управляющего воздействия обучаемой в реальном времени нейронной сети, на основании которой возможен выбор управляющего воздействия индивидуально на каждого студента [2].

Нами построена и исследована трёхслойная полносвязная нейронная сеть, на основе которой можно получить прогнозируемое значение оценки знаний и умений для каждого конкретного обучаемого.

В частности:

- 1) разработана математическая модель обучаемого, описывающая зависимость получаемых студентом знаний от таких факторов, как интеллектуальные способности, социально-психологические способности, уровень мотивации;
- 2) разработана нейросетевая модель, способная функционально описать зависимость получаемых студентом знаний и умений от факторов, влияющих на полноту этих знаний;
- 3) спроектирована нейронная сеть для прогнозирования траектории обучения каждого студента;
- 4) проверена корректность построенной нейросетевой модели на экспериментальных данных.

Отличительное свойство нейронных сетей состоит в их способности обучаться на основе экспериментальных данных. Применительно к анализу обучения студентов экспериментальные данные представляются в виде множества исходных признаков или параметров и определённой на их основе модели обучаемого. Обучение

нейронной сети представляет собой интерактивный процесс, в ходе которого находятся скрытые нелинейные зависимости между исходными параметрами и конечной моделью [3].

1. МОДЕЛЬ ОБУЧАЕМОГО

С точки зрения организации процесса обучения и прогнозирования в явном виде знаний и умений обучаемого, полученных им после изучения дисциплины, необходимо иметь модель знаний обучаемого о предметной области (входные знания по математике и информатике) и модель его индивидуальных характеристик (знаний об обучаемом как об индивидууме). Для этого нужно рассмотреть соответствующую диагностику индивидуальных особенностей студентов.

Анализируя различные подходы к построению модели обучаемого, большинство учёных выделяют его индивидуальные характеристики: основные свойства внимания, особенности памяти и мышления, уровень интеллектуальных способностей. Указанные характеристики образуют многомерные векторы психологического портрета обучающегося, которые далее разделяются на кластеры для проведения обучения нейронной сети на начальном этапе [4].

В работе В. Н. Агеева [5] выделяются модель знаний обучаемого о предметной области и модель предметно-независимых (индивидуальных) характеристик. Модель знаний обучаемого о предметной области в начальном состоянии отражает уровень его знаний и умений к началу учебного процесса. В данной статье модель знаний обучаемого включает в себя отметки по двум профильным предметам (математике и информатике), выставленные в аттестате об общем среднем образовании. К модели индивидуальных характеристик относятся такие характеристики, как пол, возраст, образование, а также характеристики, отражающие его внутреннее состояние: эмоциональная настроенность на обучение, тип эмоциональной возбудимости, скорость реакции на выполнение задания и т. д.:

$$M_o = F(MZ_o; M_{ix}), \quad (1)$$

где M_o — модель обучаемого; MZ_o — модель знаний обучаемого; M_{ix} — модель индивидуальных характеристик.

Мы определяем модель обучаемого как функционал F , зависящий от векторов $MЗо$ и $Мих$: $F: R^n \times R^m \rightarrow R$. Далее в статье векторы $MЗо$ и $Мих$ имеют разную размерность, в частности $n = 2$, поскольку модель знаний обучаемого включает в себя отметки по двум профильным предметам (математике и информатике), выставленные в аттестате об общем среднем образовании.

В работе О. И. Федяева [6] проанализированы факторы, влияющие на ментальный портрет студента. В результате для всестороннего анализа личности были выделены следующие типы факторов: мотивация студента к учёбе; интеллектуальные способности студента; психологические особенности студента; физические факторы, влияющие на обучение. Каждый из этих типов разбивается на несколько показателей, которые можно определить по результатам тестов, опросов и т. д. Анализ этих показателей позволил изучить личность обучаемого с разных сторон, выявить наиболее важные ментальные особенности, влияющие на успешность обучения, и дал возможность построить модель индивидуальных характеристик студентов.

На основании обобщения результатов О. И. Федяева нами построена модель индивидуальных характеристик для тестирования обучаемых по следующей модифицированной схеме (таблица 1):

1. Для определения уровня мотивации проводилось два вида тестирования:
 - тест А. И. Божович, И. К. Марковой «Лесенка побуждений» позволил определить уровень учебной деятельности, а именно подсчитать количество познавательных мотивов, занимающих четыре первых места в иерархии мотивов (x_1);
 - тест определения основных мотивов выбора профессии по Е. М. Павлютенкову позволил выявить, какая группа мотивов (1 — социальные; 2 — моральные; 3 — эстетические; 4 — познавательные; 5 — творческие; 6 — связанные с содержанием труда; 7 — материальные; 8 — престижные; 9 — утилитарные) являлась для студента значимой при выборе специальности (x_2).

2. Для определения интеллектуальных способностей каждого студента проводилось три вида тестирования:
 - тест на IQ Айзенка (40 вопросов в тесте на 30 минут) выполнялся в компьютерном классе с использованием тренажёра <https://brainapps.ru/iqtest-eysenck> (x_3);
 - тест Гилфорда также выполнялся в компьютерном классе с использованием платформы <https://psytests.org/iq/guilford/guilford.html> (x_4);
 - вводный тест, содержащий 20 заданий на вычисления, каждое из которых оценивалось по 0,5 балла, проводился для определения уровня вычислительных способностей по десятибалльной шкале (x_5).
3. Для определения социально-психологических особенностей каждого студента проводилось два вида тестирования:
 - тест Айзенка на определение типа темперамента состоял из 57 вопросов и выполнялся в компьютерном классе с использованием платформы http://test.msk.ru/psy2_test/test_ayzenka.htm, на основании результатов теста каждому студенту был присвоен код: 1 — сангвиник, 2 — холерик, 3 — флегматик и 4 — меланхолик (x_6);
 - тест Торренса определял уровень креативности и выполнялся на базе платформы <http://www.test-torrensa.ru/> (x_7).
4. Для определения физических факторов, таких как жилищные условия (x_8) и состояние здоровья (x_9), проводился опрос, где каждый студент самостоятельно выставлял количество процентов от 0 % до 100 %.

Для каждого студента после прохождения всех опросов и тестов в начале семестра была определена модель индивидуальных характеристик $Мих$. Модель знаний обучаемого $MЗо$ была построена на основании двух отметок по математике (x_{10}) и информатике (x_{11}), выставленных в аттестате об общем среднем образовании.

Для определения значения модели конкретного обучаемого Mo , как значения функционала, было проведено анкетирование сотрудников университета, ведущих

занятия на данном потоке и не знающих результатов анкетирования студентов: для каждого студента было выставлено конкретное число y_i , характеризующее обобщённые данные модели обучаемого, где y_i ($i = 1, 2, \dots, 9$) может принимать значения от 0,2 до 1 с шагом 0,1. И модель конкретного обучаемого определялась как среднее арифметическое:

$$Mo = \frac{\sum_{i=1}^k y_i}{k}, \quad (2)$$

где y_i — модель обучаемого, определённая i -м преподавателем, k — количество преподавателей. Значение Mo округлялось с точностью до десятых.

Таким образом, в начале семестра была построена математическая модель каждого обучаемого Mo как функционал F , зависящий от векторов MZo и Mix :

$$F : R^2 \times R^9 \rightarrow R.$$

Мы будем формализовать модель обучаемого математически, используя трёхслойную полносвязную нейронную сеть — перцептрон Розенблатта [7]. Данная нейронная сеть будет обучаться на основании модели индивидуальных характеристик (девять нейронов) и модели знаний обучающегося (два нейрона). Поэтому входными сигналами этой (первой) нейросети являются ментальные характеристики студентов, полученные в процессе их тестирования и отметки по двум предметам (таблица 1).

Таблица 1. — Факторы, влияющие на усвоение материала студентом

Факторы, влияющие на усвоение материала студентом	Характеристика	Способ определения	Оригинальная градация	Входной сигнал нейронной сети
Мотивация	Уровень мотивации_1	Тест «Лесенка побуждений» определения уровня учебной деятельности (А. И. Божович, И. К. Марковой)	5 групп мотивации	x_1
	Уровень мотивации_2	Тест определения основных мотивов выбора профессии (Е. М. Павлютенков)	9 групп мотивов	x_2
Интеллектуальные способности	Уровень интеллекта	Тест на IQ Айзенка	от 0 до 160 баллов	x_3
	Социальный интеллект	Тест Гилфорда	от 0 до 55 баллов	x_4
	Уровень вычислительных способностей	Вычислительный вводный тест	от 0 до 10 баллов	x_5
Социально-психологические особенности	Тип темперамента	Тест Айзенка «Тип темперамента»	4 вида темперамента	x_6
	Уровень креативности	Тест Торренса	от 0 до 70 и более баллов	x_7
Физические факторы	Жилищные условия	Самостоятельное определение	от 0 % до 100 %	x_8
	Состояние здоровья	Самостоятельное определение	от 0 % до 100 %	x_9
Модель знаний обучаемого о предметной области	Отметка по математике	Аттестат об общем среднем образовании	от 0 до 10	x_{10}
	Отметка по информатике		от 0 до 10	x_{11}

Входные сигналы образует вектор $X = (x_1; x_2; \dots; x_q)$, компоненты которого перечислены в последнем столбце таблицы 1 при $q = 11$.

Для решения поставленной задачи экспериментально была выбрана модель трёхслойной нейронной сети прямого распространения с нелинейной логистической (сигмовидной) функцией активации. Входной слой нейронной сети, выполняющий задачу передачи входных значений на скрытый слой, состоял из 11 нейронов, что соответствовало количеству рассматриваемых исходных параметров для определения модели обучаемого.

Для определения количества нейронов в скрытом (втором) слое использовалась теорема Колмогорова, которая служит математической основой для нейронных сетей и заключается в следующем: любая непрерывная функция, определённая на l -мерном единичном кубе, может быть представлена в виде суммы $2l + 1$ суперпозиций непрерывных и монотонных отображений единичных отрезков. То есть верхняя граница числа нейронов в скрытом слое должна быть не более $2l + 1$, где l — количество входов. Как правило, количество нейронов скрытого слоя подбирается экспериментально. В результате экспериментов был выбран скрытый слой, состоящий из $l = 16$ нейронов, который обеспечивает минимизацию функции

ошибки. Экспериментально было установлено, что дальнейшее увеличение нейронов на скрытом слое не приводит к минимизации функции ошибки.

В данной нейросети выходной слой состоял из одного нейрона, который соответствовал модели обучаемого (2).

Обучающую выборку составили 70 студентов географического факультета БГУ, получающие знания по дисциплине «Высшая математика с основами информатики» в 2017/2018 учебном году. Они были протестированы согласно описанной методике. Результаты анкетирования и тестирования одной подгруппы, состоящей из 10 человек, представлены в таблице 2.

На выходе нейросеть должна формировать сигналы Mo^l , определяющие модель обучаемого, соответствующую студенту с конкретной ментальностью. Была протестирована нейронная сеть заданной архитектуры. Тестирование проводилось на выборке, составленной из студентов, не участвующих при обучении нейронной сети, а именно 45 студентов I курса географического факультета (второй поток). Погрешность определения модели обучаемого Mo^l на тестирующих данных составила $p = \frac{5}{45} \cdot 100\% \approx 11,11\%$, так как для пяти студентов прогнозная модель обучаемого Mo^l была определена неверно.

Таблица 2. — Результаты анкетирования и тестирования студентов

Характеристика	Студенты									
	1	2	3	4	5	6	7	8	9	10
Уровень мотивации_1	0	1	4	4	2	3	1	1	3	2
Уровень мотивации_2	3	2	4	4	5	2	1	2	4	3
Уровень интеллекта	50	100	120	150	80	70	40	60	75	100
Социальный интеллект	57	50	27	0	30	57	56	50	30	50
Уровень вычислительных способностей	5	6	10	9	8	5	4	3	7	8
Тип темперамента	1	1	2	4	3	4	4	2	1	4
Уровень креативности	35	30	65	70	65	25	20	35	30	40
Жилищные условия	100	90	50	75	90	100	90	100	90	100
Состояние здоровья	90	70	50	90	80	100	100	100	80	100
Отметка по математике	5	6	10	10	9	5	4	4	7	8
Отметка по информатике	4	6	9	9	9	5	4	3	8	6
Значение модели обучаемого Mo	0,4	0,4	1,0	1,0	0,8	0,4	0,2	0,2	0,6	0,6

Предварительно все входные сигналы были нормализованы, то есть приведены к диапазону $[0; 1]$. Оценивая весовые коэффициенты (синоптические веса) факторов, мы пришли к заключению о незначительном влиянии некоторых из них на определение модели обучаемого. Было выявлено, что к наиболее существенным факторам относятся: уровень мотивации выбора профессии, уровень интеллекта, уровень вычислительных способностей, отметки по профильным предметам (математике и информатике).

Задачу уменьшения размерности входных сигналов мы решили следующим образом. Была обучена вторая нейронная сеть, состоящая из 5 входных нейронов, соответствующих факторам $x_2, x_3, x_5, x_{10}, x_{11}$ из таблицы 1, которые оказывают наибольшее влияние на выходной параметр. Обучение нейронной сети проводилось на основании тех же 70 студентов. Тестирование проводилось на выборке, составленной из тех же 45 студентов, не участвующих при обучении первой нейронной сети. В данном случае погрешность определения модели обучаемого Mo^T на тестирующих данных составила $\varphi = \frac{6}{45} \cdot 100\% \approx 13,33\%$, так как для шести студентов прогнозные модели обучаемых Mo^T были определены неверно.

Для данных, измеренных в дихотомической шкале, целесообразно использование критерия Фишера [8] для определения достоверности совпадения характеристик работы двух нейронных сетей.

Для определения достоверности совпадений и различий для экспериментальных данных, измеренных в дихотомической шкале, вычисляем эмпирическое значение $\Phi_{эмп}$ по следующей формуле:

$$\Phi_{эмп} = \left| 2 \arcsin \sqrt{p} - 2 \arcsin \sqrt{q} \right| \sqrt{\frac{M \cdot N}{M + N}}. \quad (3)$$

В нашем случае $M = 45, N = 45$, вычисленное $\Phi_{эмп} \approx 0,322$. Критическое значение $\Phi_{крит}$ критерия Фишера для уровня значимости $\alpha = 0,05$ равно 1,64. Эмпирическое значение критерия $\Phi_{эмп}$ меньше критического значения $\Phi_{крит}$. Поскольку погрешности моделей обучаемого Mo^T для двух рассмотренных нейронных сетей совпадают с уровнем значимости $\alpha = 0,05$

по статистическому критерию Фишера, то выявленные основные факторы влияния на модель обучаемого Mo^T положены в основу интегрированной методики прогнозирования процесса обучения.

Таким образом, нами построена математическая модель обучаемого $Mo = F(MZo; Mix)$, учитывающая личностные характеристики и отметки по двум предметам. Настроены и обучены две нейронные сети с различным количеством входных сигналов, определяющие модель обучаемого. Поскольку некоторые факторы из первой нейросети оказывают незначительное влияние на определение модели обучаемого, то они не будут учитываться в интегрированной методике прогнозирования.

2. СРЕДА ОБУЧЕНИЯ

Качество образования определяется многообразием различных факторов: квалификацией профессорско-преподавательского состава, его заинтересованностью педагогической деятельностью, базовой подготовкой обучаемых и их отношением к приобретению знаний и умений по дисциплине, уровнем образовательных технологий, состоянием учебно-материальной базы, применением современных методов контроля качества учебных достижений студентов.

Определим среду обучения как комплекс организационно-технических, педагогических и программно-информационных сервисов, направленных на предоставление студентам широкого спектра образовательных услуг. Для построения модели среды обучения необходимо учесть все факторы, влияющие на качество обучения студента в той или иной степени, а также определить степень их влияния.

Разработанная нами нейросетевая модель способна функционально описать зависимость получаемых студентом знаний и умений от среды обучения.

В результате проведенного анкетирования сотрудников университета были определены основные компоненты среды обучения: обеспеченность дисциплины учебно-методическим комплексом, информационно-техническое обеспечение дисциплины, наличие средств контроля знаний. Среда обучения характеризуется не

только состоянием учебно-методического и технического обеспечения учебного процесса (обеспеченность дисциплины учебно-методическими пособиями и разнообразными диагностическими средствами), но и уровнем организации обучения студентов (количеством посещённых занятий).

Современные преподаватели оперируют большим количеством информации о студентах, которая могла бы быть полезна в педагогических исследованиях. Одним из разновидностей такой информации, необходимой для прогнозирования, являются оценки промежуточного уровня знаний студентов в течение семестра, а именно оценки по лабораторным работам, лекционным и практическим занятиям.

Все вышеперечисленные составляющие среды обучения положены в основу предлагаемой нейросети. Входным сигналом третьей нейросети является среда обучения, состоящая из девяти нейронов. Входные сигналы образует вектор $X = (x_1; x_2; \dots; x_9)$, компоненты которого описаны в таблице 3.

Структура у этой нейронной сети также относится к классу однородных многослойных перцептронов с полными последовательными связями и сигмоидальной функцией активации. При построении обучающего множества для данной нейросети

были выбраны те же 70 студентов. Прогнозируемый балл по дисциплине был взят из экзаменационных ведомостей после сдачи всеми студентами летней сессии 2017/2018 учебного года.

Входной слой нейронной сети состоял из девяти нейронов, что соответствовало количеству рассматриваемых исходных параметров для определения прогнозируемого балла. Был выбран скрытый слой, состоящий из 16 нейронов, при этом выходной слой состоял из одного нейрона y , принимающего значения от 0 до 1.

Прогнозируемый балл по дисциплине вычислялся как увеличенное в 10 раз значение выходного нейрона, округлённое до целых. При построении данной нейронной сети модель обучаемого не учитывалась.

Относительная погрешность определения экзаменационной отметки на тестируемых данных составила $\frac{4}{45} \cdot 100\% \approx 8,89\%$ (не совпали отметки у четырёх студентов из 45 тестируемых).

3. ИНТЕГРИРОВАННАЯ МЕТОДИКА ПРОГНОЗИРОВАНИЯ

Для прогнозирования процесса обучения, определения знаний и умений обучаемого, полученных им после изучения дисциплины, необходимо иметь информацию о модели знаний обучаемого о

Таблица 3. — Входные параметры третьей нейросети

Факторы, влияющие на усвоение материала студентом	Характеристика	Входной сигнал
Среда обучения	обеспеченность дисциплины УМК	x_1
	информационно-техническое обеспечение дисциплины	x_2
	текущий контроль качества учебных достижений студентов (тесты в системе e-University)	x_3
	количество посещённых лекций студентом	x_4
	количество посещённых практических занятий студентом	x_5
	количество посещённых лабораторных занятий студентом	x_6
	средний балл по лекциям	x_7
	средний балл по практическим занятиям	x_8
	средний балл по лабораторным занятиям	x_9

предметной области (входные знания по математике и информатике), о модели его индивидуальных характеристик (знаний об обучаемом как об индивидууме) и о среде обучения.

Нами разработана нейросетевая модель, обобщающая две вышеперечисленные модели и способная функционально описать зависимость получаемых студентом знаний и умений от среды обучения и от факторов модели обучаемого.

В первом разделе статьи нами строилась модель обучаемого и исследовалось влияние личностных характеристик на данную модель. Были выявлены основные факторы из первой нейросети, которые оказывают значительное влияние на определение модели обучаемого. Именно эти факторы, а также факторы среды обучения, рассмотренные во втором разделе, положены в основу интегрированной методики прогнозирования. С этой целью была построена нейронная сеть, одновременно учитывающая все эти факторы. Она содержала входные нейроны, представленные в таблице 4.

Для текущего контроля знаний студентов проводились промежуточные

тестирования в системе e-University по каждой теме. Для качественного и достоверного измерения уровня знаний студентов по дисциплине «Высшая математика с основами информатики» (входной сигнал x_3) соблюдались этапы разработки системы адаптивного тестирования, представленные в работе Е. И. Горюшкина [9].

Входной слой нейронной сети, выполняющий задачу передачи входных значений на скрытый слой, состоял из 14 нейронов, что соответствовало количеству рассматриваемых исходных параметров для определения прогнозируемого балла. Был выбран скрытый слой, состоящий из 16 нейронов, при этом выходной слой состоял из одного нейрона y , принимающего значения от 0 до 1. Как и в третьей нейросети, результат выходного нейрона увеличивался в 10 раз и округлялся до целых, что соответствовало прогнозируемой отметке.

Относительная погрешность определения экзаменационной отметки на тестирующих данных составила $\frac{1}{45} \cdot 100 \% \approx 2,22 \%$ (не совпали отметки у одного студента из 45 тестируемых).

Таблица 4. — Входные параметры интегрированной нейросети

Факторы, влияющие на усвоение материала студентом	Характеристика	Входной сигнал
Модель обучаемого	Уровень мотивации выбора профессии	x_1
	Уровень интеллекта	x_2
	Уровень специальных способностей (в данном случае — вычислительных)	x_3
	Отметка по математике	x_4
	Отметка по информатике	x_5
Среда обучения	обеспеченность дисциплины УМК	x_6
	информационно-техническое обеспечение дисциплины	x_7
	текущий контроль качества учебных достижений студентов (тесты в системе e-University)	x_8
	количество посещённых лекций студентом	x_9
	количество посещённых практических занятий студентом	x_{10}
	количество посещённых лабораторных занятий студентом	x_{11}
	средний балл по лекциям	x_{12}
	средний балл по практическим занятиям	x_{13}
средний балл по лабораторным занятиям	x_{14}	

4. ПРОВЕРКА ЭФФЕКТИВНОСТИ РАБОТЫ НЕЙРОННЫХ СЕТЕЙ

Для проверки эффективности применения модели прогнозирования полученных знаний и приобретённых умений и навыков студентов на основе нейронной сети был проведён эксперимент со студентами четырёх групп (всего 73 студента) I курса географического факультета БГУ, изучающими дисциплину «Высшая математика с основами информатики» в двух семестрах 2018/2019 учебного года и не участвующими в обучении ни одной нейронной сети. Исходные данные каждого студента подавались на вход нейронных сетей, в результате чего был составлен прогноз успеваемости для каждого студента по дисциплине «Высшая математика с основами информатики» по двум методикам.

По окончании изучения дисциплины прогнозируемые баллы студентов сравнили с баллами, которые они получили на экзамене по дисциплине.

Для ответа на вопрос «Какая методика прогнозирования (интегрированная методика прогнозирования; методика прогнозирования, учитывающая только среду обучения; методика прогнозирования, учитывающая только личностные характеристики) является эффективнее, то есть прогнозирует отметки с меньшей ошибкой?» использовался статистический критерий Фишера [8]. Сравним три методики между собой, определив количество ошибочных прогнозов в каждой методике.

Относительная погрешность определения экзаменационной отметки по методике прогнозирования, учитывающей только личностные характеристики, составила

$$q = \frac{m_2}{M} = \frac{9}{73} = 0,1232 \approx 12,32 \% \text{ (семь студентов из 73 экзаменуемых получили более высокий балл, а два студента из 73 тестируемых получили более низкий экзаменационный балл, чем прогнозировалось).}$$

Относительная погрешность определения экзаменационной отметки по методике прогнозирования, учитывающей только среду обучения, составила

$$q = \frac{m_2}{M} = \frac{7}{73} = 0,0959 \approx 9,59 \% \text{ (шесть студентов из 73 экзаменуемых получили более}$$

высокий балл, а один студент из 73 тестируемых получил более низкий экзаменационный балл, чем прогнозировалось).

Относительная погрешность определения экзаменационной отметки по интегрированной методике составила

$$p = \frac{n_2}{N} = \frac{2}{73} = 0,0274 \approx 2,74 \% \text{ (один студент из 73 экзаменуемых получил более высокий балл, а один студент из 73 тестируемых получил более низкий экзаменационный балл, чем прогнозировалось).}$$

Для определения достоверности совпадений и различий для экспериментальных данных, измеренных в дихотомической шкале, вычисляем по формуле (3) $\Phi_{эмт}$.

Сравнивая первую и третью методики между собой, получаем $\Phi_{эмт} \approx 2,326$. Сравнивая вторую и третью методики между собой, получаем $\Phi_{эмт} \approx 1,79$.

Критическое значение $\Phi_{крит}$ критерия Фишера для уровня значимости $\alpha = 0,05$ равно 1,64. Эмпирическое значение критерия $\Phi_{эмт}$ больше критического значения $\Phi_{крит}$. Следовательно, достоверность различий методик составляет 95 % по статистическому критерию Фишера.

Значит, интегрированная методика прогнозирует экзаменационные отметки студентов по статистическому критерию Фишера с уровнем значимости 0,05, в то время как достоверность различий между отметками, полученными с помощью методик прогнозирования, учитывающей личностные характеристики студентов и учитывающей только среду обучения, и экзаменационными отметками составляет 95 %.

Таким образом, разработанная математическая модель может применяться для прогнозирования отметок студентов и использоваться в аналитико-прогностическом блоке интегрированной системы обучения. Благодаря анализу полученных данных о промежуточной успеваемости студентов можно выявлять слабые места существующего образовательного процесса, что даёт возможность своевременно модернизировать его.

Результаты проведённого исследования позволяют сделать вывод, что представленная интегрированная методика прогнозирования, учитывающая модель обучаемого и среду обучения, может быть

использована не только для получения достоверных результатов экзаменационных отметок студентов, но и для промежуточного измерения уровня знаний обучающихся, тем самым предоставляя возможность повысить качество обучения путём промежуточной корректировки процесса обучения.

В данной работе был рассмотрен способ применения искусственных нейронных сетей, где нейронная сеть в первом случае работала с исходными параметрами для определения модели обучаемого, которые представлялись в виде набора чисел, а во втором случае — с исходными данными для прогнозирования итоговой отметки по дисциплине. В обоих случаях были построены нейронные сети одинаковой топологии, но различающиеся количеством нейронов, задействованных на входном слое нейронной сети.

Исходя из вышесказанного следует отметить, что нейросетевая технология является помощником в автоматизации процесса обучения и удобстве его анализа, выводя педагогические исследования на принципиально новый уровень, поскольку такие модели не только выявляют закономерности педагогических процессов и явлений, но и строят объективные прогнозы на будущее.

Результаты обучения и проверки работоспособности спроектированных нейронных сетей показывают их успешное применение для прогнозирования отметок студентов и способность находить сложные закономерности и взаимосвязи между различными объектами, относящимися к одному классу данных. После того как нейронная сеть обучена, она становится надёжным и недорогим инструментом анализа.

Литература

1. Коляда, М. Г. Педагогическое прогнозирование в компьютерных интеллектуальных системах / М. Г. Коляда, Т. И. Бугаева. — М. : ООО «Русайнс», 2015. — 432 с.
2. Казаченок, В. В. Тенденции и модели развития образования XXI века / В. В. Казаченок // Матзматика. — 2018. — № 5. — С. 3–8.
3. Калан, Р. Основные концепции нейронных сетей : пер. с англ. / Р. Калан. — М. : Вильямс, 2003. — 288 с.
4. Добровольская, Н. Ю. Компьютерные нейросетевые технологии как средство индивидуализированного обучения студентов физико-математических специальностей : дис. ... канд. пед. наук : 13.00.08 / Н. Ю. Добровольская. — Краснодар, 2009. — 263 с.
5. Агеев, В. Н. Совершенствование управления в социальных коммуникативных системах на основе электронных изданий : дис. ... д-ра техн. наук : 05.13.10 / В. Н. Агеев. — М., 1999. — 313 с.
6. Федяев, О. И. Прогнозирование остаточных знаний студентов по отдельным дисциплинам с помощью нейронных сетей / О. И. Федяев // Известия ЮФУ. Технические науки. — 2016. — № 7. — С. 122–136.
7. Яхьяева, Г. Э. Нечёткие множества и нейронные сети / Г. Э. Яхьяева. — М. : Национальный Открытый Университет «ИНТУИТ», 2016. — 187 с.
8. Новиков, Д. А. Статистические методы в педагогических исследованиях (типовые случаи) / Д. А. Новиков. — М. : МЗ-Пресс, 2004. — 67 с.
9. Горюшкин, Е. И. Использование нейросетевых технологий в адаптивном тестировании по информатике в вузе : дис. ... канд. пед. наук : 13.00.02 / Е. И. Горюшкин. — Курск, 2009. — 176 с.

Материал поступил в редакцию 08.08.2019.

Methods for predicting learning outcomes based on neural networks

Natalya A. Moiseeva, Senior Lecturer of the General Mathematics and Computer Science Department of the Mechanics and Mathematics Faculty of the Belarusian State University; VoronkinaNA@bsu.by

A neural network model of integrated training of students in the academic discipline of Higher Mathematics with Basics of Computer Science has been developed and investigated. The author suggests a new approach to the neural network description of the difficult to formalize process of training students, based on modelling the process of knowledge transfer depending on student's personal characteristics and factors of the learning environment. It includes the development of an algorithm for constructing a neural network model that predicts knowledge and skills of students in the academic discipline.

Keywords: modeling of the training process; knowledge prediction; neural network technologies.

References

1. Kolyada, M. G. Pedagogicheskoe prognozirovanie v komp'yuternykh intellektual'nykh sistemakh / M. G. Kolyada, T. I. Bugayeva. — M. : OOO «Rusajns», 2015. — 432 s.
2. Kazachenok, V. V. Tendencii i modeli razvitiya obrazovaniya XXI veka / V. V. Kazachenok // Matematika. — 2018. — № 5. — S. 3—8.
3. Kalan, R. Osnovnye koncepcii nejronnykh setej : per. s angl. / R. Kalan. — M. : Vil'yams, 2003. — 288 s.
4. Dobrovol'skaya, N. YU. Komp'yuternye nejrosetevye tekhnologii kak sredstvo individualizirovannogo obucheniya studentov fiziko-matematicheskikh special'nostej : dis. ... kand. ped. nauk : 13.00.08 / N. YU. Dobrovol'skaya. — Krasnodar, 2009. — 263 s.
5. Ageev, V. N. Sovershenstvovanie upravleniya v social'nykh kommunikativnykh sistemakh na osnove elektronnykh izdaniy : dis. ... d-ra tekhn. nauk : 05.13.10 / V. N. Ageev. — M., 1999. — 313 s.
6. Fedyaev, O. I. Prognozirovanie ostatochnykh znanij studentov po otдельnym disciplinam s pomoshch'yu nejronnykh setej / O. I. Fedyaev // Izvestiya YUFU. Tekhnicheskie nauki. — 2016. — № 7. — S. 122—136.
7. Yakh'yaeva, G. E. Nechotkie mnozhestva i nejronnye seti / G. E. Yakh'yaeva. — M. : Nacional'nyj Otkrytyj Universitet «INTUIT», 2016. — 187 s.
8. Novikov, D. A. Statisticheskie metody v pedagogicheskikh issledovaniyakh (tipovye sluchai) / D. A. Novikov. — M. : MZ-Press, 2004. — 67 s.
9. Goryushkin, Ye. I. Ispol'zovanie nejrosetevykh tekhnologij v adaptivnom testirovanii po informatike v vuze : dis. ... kand. ped. nauk : 13.00.02 / Ye. I. Goryushkin. — Kursk, 2009. — 176 s.

Submitted 08.08.2019.