

УДК 3784:331.7

## ИСПОЛЬЗОВАНИЕ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ ЗАВИСИМОСТЕЙ ПРИ КОМПЛЕКСНОМ АНАЛИЗЕ СОСТОЯНИЯ ЗДОРОВЬЯ СТУДЕНТОВ ВЫСШИХ УЧЕБНЫХ ЗАВЕДЕНИЙ

<sup>1</sup>Горбатов С.А., <sup>2</sup>Горбаткова Е.Ю.<sup>1</sup>Уфимский филиал Финансового университета при Правительстве Российской Федерации, Уфа, e-mail: gorbatkovaeu@mail.ru;<sup>2</sup>ФГБОУ ВПО «Башкирский государственный педагогический университет им. М. Акмуллы», Уфа

Работа проблемно ориентирована на исследование состояния здоровья обучающихся в различных высших учебных заведениях. Рассматриваются на модельной задаче восстановления многомерных нелинейных зависимостей, скрытых в данных, влияния уровня зашумленности данных на устойчивость нейросетевой модели. Данные, получаемые путем анкетного опроса студентов и анализа показателей заболеваемости, содержат как количественные, так и качественные показатели, и характеризуются высоким уровнем зашумленности. Поэтому актуален исследуемый в статье вопрос о допустимом уровне шума в данных, при котором нейросетевая модель еще сохраняет свою прогностическую способность. В статье на модельном примере показана эффективность и состоятельность процедур удаления противоречивых и аномальных наблюдений при оценке заболеваемости студентов по данным обращаемости, с временной утратой трудоспособности в случаях и в днях и госпитализированной заболеваемости. Особое значение имеет то, что процесс поиска и удаления аномальных наблюдений проводится итерационно, взаимосвязанно с обучением нейросети.

**Ключевые слова:** здоровье обучающейся молодежи, условия жизни студентов, здоровый образ жизни, ценностные ориентации, нейросетевая модель, восстановление зависимости, модельная задача, влияние уровня зашумленности на устойчивость модели

## USING NEURAL NETWORK MODELING DEPENDENCIES IN COMPLEX ANALYSIS OF THE STATE UNIVERSITY STUDENTS HEALTH

<sup>1</sup>Gorbatkov S.A., <sup>2</sup>Gorbatkova E.Y.<sup>1</sup>Federal State-Funded Educational Institution of Higher Professional Education «Financial University under the Government of the Russian Federation», Ufa, e-mail: gorbatkovaeu@mail.ru;<sup>2</sup>Bashkir state pedagogical university n.a. M. Akmulla», Ufa

The work focused on the study of problematic health status of students in various universities. We consider the effect of the level of noise in the data on the stability of neural network model to model the problem of reconstructing multidimensional nonlinear dependencies, hidden in the data. The data is obtained by questionnaire survey and analysis of students morbidity contain both quantitative and qualitative indicators and is characterized by a high level of noise. Therefore, the article analyzed the question of an acceptable level of noise in the data is relevant, in which the neural network model still retains its predictive ability. Therefore, the article analyzed the question of the permissible noise level at which the neural network model still retains its predictive power is relevant. In this paper a model example shows the effectiveness and consistency of procedures remove controversial and anomalous observations in assessing the incidence of students according to negotiability, with temporary disability in the cases and in the days and hospital morbidity. The particular importance is the fact that the process of finding and removing abnormal observations carried out iteratively, correlated with neural network learning.

**Keywords:** health of pupils, students living conditions, healthy lifestyles, social values, neural network model, the restoration of dependence, model problem, the impact of noise pollution on the stability of the model

Ухудшение социально-экономических условий жизни населения страны, нарастание экологического неблагополучия приводят к изменению качества жизни студенческой молодежи [1, 2]. К сожалению, далеко не всегда образ жизни современного молодого человека можно назвать здоровым. Негативные тенденции в состоянии здоровья студенческой молодежи возникают также за счет воздействия неблагоприятных факторов обучения. Интенсификация учебных программ приводит к значительному увеличению учебной нагрузки, и, соответственно, избыточной напряженности умственной деятельности [4, 5]. Все эти неблагоприятные факторы, в конечном итоге, отрицательно воздействуют на состояние здоровья

молодого человека и приводят к функциональным отклонениям и хроническим заболеваниям [10].

В связи с актуальностью вышеизложенного в нашем исследовании большое внимание уделяется комплексной оценке состояния здоровья и образа жизни студенческой молодежи.

В настоящее время нами проводится анализ данных заболеваемости студентов по обращаемости, с временной утратой трудоспособности в случаях и днях, а также госпитализированной заболеваемости. Исследуемый контингент насчитывает более 2 тысяч человек, обучающихся в 4 высших учебных заведениях г. Уфы. Данные по заболеваемости берутся из учетной до-

кументации студенческой поликлиники. Выкопировка нозологических форм осуществляется в соответствии с международной классификацией болезней десятого пересмотра. Сведения собираются в порядке текущей регистрации, на основе сплошного учета всех заболеваний.

Для оценки полученных данных нами используются нейросетевые инструментари [3, 7]. Нейросетевые информационные технологии проявили себя весьма успешно как универсальные средства в задачах аппроксимации, распознавания образов, прогнозирования, ранжирования, способных работать в условиях неопределенности (так называемой триады «НЕ-факторов»: не точности, неполноты, неопределенности в данных). Однако, как показали наши исследования, существуют предельные уровни и объемы зашумленности данных по заболеваемости студентов, когда нейросеть теряет свои прогностические способности и начинает аппроксимировать в большей степени шум, чем восстанавливаемые зависимости. При этих условиях нейросетевая модель теряет устойчивость. Данный вопрос в литературе практически не исследован. Ему посвящается данная статья.

Целями вычислительных экспериментов были:

1. Обнаружение неустойчивости НСМ типа многослойного персептрона при росте шумовой составляющей в данных по анализу заболеваемости студентов высших учебных заведений.

2. Анализ условий возникновения неустойчивости НСМ при оценке результативности данных по заболеваемости.

Идея постановки модельного вычислительного эксперимента была предложена Д.В. Полупановым [6].

Исследуем вопрос о влиянии возмущений на качество обучения НСМ. Вышеописанные характеристики искажения делают невозможным варьирование параметров возмущения по отдельности на реальных данных. Поэтому сконструируем модельный пример, задающий базу данных, т.е. обучающее и тестовое множество НСМ, следующим образом. Введем величины  $p_i \in [p_0; p_N]$ , где  $p_0 = 1$ ,  $p_N = 7,8$ ,  $p_i = p_0 + i(p_N - p_0)/N$  и  $q_i \in [q_0; q_N]$ , где  $q_0 = 4,6$ ,  $q_N = 1$ ,  $q_i = q_0 + i(q_N - q_0)/N$ ,  $i = 1, N$ ,  $N = 200$ . Сконструируем 10 факторов:

$$X_1 = p + q; X_2 = pq; X_3 = 1/p - 1/q;$$

$$X_4 = p/q; X_5 = p - q;$$

$$X_6 = (\sqrt{p} - \sqrt{q})^2; X_7 = \sqrt{p^2 + q^2}; \quad (1)$$

$$X_8 = (p^2 + q) / (p + q^2);$$

$$X_9 = (p^3 + q^3) / (p^2 - pq + q^2); \quad (2)$$

Зададим моделируемую детерминированную зависимость:

$$Y = \sum_{j=1}^n th(X_j), n=10. \quad (3)$$

Вычислительный эксперимент проводился на модельных данных для того, чтобы знать неискаженные значения входных факторов (1) – (2) и выходной величины (3). Составим матрицу наблюдений  $A = \{a_{ij}\}$ . Здесь  $a_{ij} = x_{ij}$ ,  $i = 1, N$ ,  $j = 1, n$ ,  $a_{i, n+1} = y_i$ . В получившейся матрице строки перемешаем случайным образом. Первые 100 строк будут обучающим множеством, другие 100 – тестовым. Тестовое множество обозначим  $T = \{t_{ij}\}$ . Здесь  $i = 1, N_{test}$ ,  $j = 1, n+1$ ,  $N_{test} = 100$ . Детерминированная зависимость (3) аппроксимировалась при помощи нейросети типа многослойный персептрон с двумя скрытыми слоями и активационной функцией гиперболического тангенса [9].

Качество обучения сети на каждой итерации оценивалось по обобщенному критерию  $J$ , представляющему собой произведение двух частных критериев:

$$J = E \cdot S; \quad (4)$$

$$E = \|\hat{Y}_i - Y_i\| / \|Y_i\|; S = \frac{1}{N_{(k)}^{\Omega_{test}}} \sum_{i=1}^{N_{(k)}^{\Omega_{test}}} \frac{|\hat{y}_i - \hat{y}_{i+1}|}{\|\bar{x}_i - \bar{x}_{i+1}\|},$$

$$i = \overline{1, N}; N \in \Omega_{test}, \quad (5)$$

где  $y_i$  – точное значение функции  $Y$  по (3) в  $i$ -ой строке модельных данных;  $\hat{y}_i$  – рассчитанное обученной и протестированной нейросетью значение моделируемой величины  $Y$ .

Величина  $E$  в (4), (5) является ошибкой обобщения, рассчитанной на тестовом множестве  $\Omega_{test}$  наблюдений, не участвовавших в обучении НСМ, и характеризует точность и прогностические свойства сети. Величина  $S$  также вычисляется на тестовом множестве  $\Omega_{test}$ . Критерий  $S$  характеризует устойчивость НСМ к вариации переменных: чем меньше  $S$ , тем меньше разброс значений  $\hat{y}(\bar{x})$  на новых наблюдениях после обучения нейросети.

#### Результаты исследования и их обсуждение

Сначала сеть была обучена на незашумленных данных, показатели качества обучения, вычисленные по (4)–(5) следующие:

щие:  $E = 0,0013$ ,  $S = 0,01078$ ,  $J = 0,000014$ . Далее обученной на «эталонных» данных сети предъявлялись зашумленные данные, для того чтобы определить, как будут меняться показатели качества при разном уровне шума. Зашумлению было подвергнуто тестовое множество исходной базы данных, состоящее из 100 вектор-строк. Зашумлению подвергнуты не все столбцы (факторы), а только  $X_1$ ,  $X_3$ ,  $X_5$ ,  $X_7$ ,  $X_9$ ,  $Y$ . Столбцы  $X_2$ ,  $X_4$ ,  $X_6$ ,  $X_8$ ,  $X_{10}$  оставались незашумленными. Выбор зашумленных и незашумленных факторов случаен. При этом для факторов  $X_1$ ,  $X_5$ ,  $X_9$  и моделируемой величины  $Y$  был выбран нормальный закон распределения шумов, а для факторов  $X_3$ ,  $X_7$  – равномерный, т.е. использовался смешанный шум. Рассмотрим случайные величины  $\xi_j^{(k)}$ ,  $h_j^{(k)}$ , распределенные по нормальному закону:

$$\xi_j^{(k)} \sim N(k_{X_j} \cdot \bar{X}_j; k_{X_j} \cdot S_{X_j}^2), \quad (6)$$

$$\eta_j^{(k)} \sim N(k_Y \cdot \bar{Y}; k_Y \cdot S_Y^2), \quad (7)$$

где  $\bar{X}_j$ ,  $\bar{Y}$  – средние арифметические вдоль столбцов;  $S_{X_j}^2$ ,  $S_Y^2$  – дисперсии величин  $X_j$ ,  $Y$ ;  $k_{X_j}$ ,  $k_Y$  – параметры, характеризующие задаваемый уровень шума в столбцах  $X_j$  и  $Y$  соответственно. Рассмотрим также случайные величины  $\lambda_j^{(k)}$  и  $\tau_j^{(k)}$ , равномерно распределенные на интервалах:

$$k_{X_j} \cdot \bar{X}_j - k_{X_j} \cdot S_{X_j}; k_{X_j} \cdot \bar{X}_j + k_{X_j} \cdot S_{X_j};$$

и

$$k_Y \cdot \bar{Y} - k_Y \cdot S_Y; k_Y \cdot \bar{Y} + k_Y \cdot S_Y. \quad (8)$$

Сгенерируем по 100 значений случайных величин  $\xi_j^{(k)}$ ,  $h_j^{(k)}$ ,  $\lambda_j^{(k)}$  и  $\tau_j^{(k)}$ . Добавив шумовую составляющую к исходным данным, получим возмущенное тестовое множество

$$\tilde{T} = \{\tilde{t}_{ij}\},$$

где

$$\tilde{t}_{ij}^{(k)} = t_{ij} + \xi_{ij}^{(k)}, \quad \tilde{t}_{i,n+1}^{(k)} = t_{i,n+1}^{(k)} + \eta_j,$$

$$i = \overline{1, N_{test}}; j = 1, 5, 9, n+1; \quad (9)$$

$$\tilde{t}_{ij}^{(k)} = t_{ij} + \lambda_j^{(k)}, \quad \tilde{t}_{i,n+1}^{(k)} = t_{i,n+1}^{(k)} + \tau_j,$$

$$i = \overline{1, N_{test}}; j = 3, 7. \quad (10)$$

Параметр  $k$ , характеризующий интенсивность шума, выбирался произвольным образом для каждого фактора  $X_j$  и моделируемой величины  $Y$ . Рассмотрим евклидовы нормы исходной и зашумленной матриц, составляющих тестовое множество:

$$\|T\| = \sqrt{\sum_{i=1}^{N_{test}} \sum_{j=1}^{n+1} t_{ij}^2}, \quad \|\tilde{T}\| = \sqrt{\sum_{i=1}^{N_{test}} \sum_{j=1}^{n+1} \tilde{t}_{ij}^2}. \quad (11)$$

Величину, характеризующую меру интенсивности возмущения тестового множества, определим как

$$\mu = \|\tilde{T} - T\| / \|T\|. \quad (12)$$


Рассмотрим зависимость показателей качества обучения сети (4)–(5) от интенсивности возмущения данных  $m$ . Для этого будем последовательно увеличивать количество зашумленных строк и предъявлять зашумленные данные нейросети, обученной на «эталонных» данных. Долю зашумленных строк матрицы  $\tilde{T} = \{\tilde{t}_{ij}\}$  обозначим  $w$ . В табл. 1 и на рисунке отражены результаты тестирования нейросети.

При появлении шума в данных все показатели качества сети резко ухудшаются [8]. Например, уже при  $w = 0,1$  (зашумлено 10% строк тестового множества) ошибка обобщения составляет 33,9%, что делает сеть непригодной для ответственных практических расчетов оценки заболеваемости студентов. Следует отметить, что при работе с реальными (не модельными) данными, доля зашумленных данных может быть значительно больше 10%.

Таблица 1

Показатели качества обучения при разном уровне шума

| $w$ | 0        | 0,1   | 0,2   | 0,3   | 0,4   | 0,5   | 0,6   | 0,7   | 0,8   | 0,9   | 1     |
|-----|----------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| $m$ | 1,000    | 1,098 | 1,179 | 1,241 | 1,307 | 1,395 | 1,477 | 1,535 | 1,586 | 1,660 | 1,685 |
| $E$ | 0,00130  | 0,339 | 0,435 | 0,477 | 0,496 | 0,515 | 0,528 | 0,536 | 0,545 | 0,550 | 0,553 |
| $S$ | 0,01078  | 0,098 | 0,266 | 0,417 | 0,506 | 0,654 | 0,906 | 1,068 | 1,091 | 1,267 | 1,473 |
| $J$ | 0,000014 | 0,033 | 0,115 | 0,199 | 0,251 | 0,337 | 0,479 | 0,572 | 0,593 | 0,697 | 0,814 |



*Зависимость  $E$ ,  $S$ ,  $J$  от интенсивности шума  $\mu$*

При уровне шума  $\mu = 1,535$  и доле зашумленных строк данных  $w = 0,7$  критерий устойчивости  $S > 1$ , нейросетевое отображение становится «растягивающим»: кривые  $E$ ,  $S$ ,  $J$  начинают расти экспоненциально при увеличении  $\mu$ . Можно сделать вывод, что при некотором критическом уровне зашумленности данных  $\mu_{кр}$  нейросетевая модель становится неустойчивой. При проведении вычислительных экспериментов на реальных данных выяснилось, что сеть становится неустойчивой при гораздо меньшем значении  $w$ . Объясняется это более сложной и недетерминированной зависимостью факторов и моделируемой величины. Относительно небольшие возмущения входных данных могут приводить к значительному искажению нейросетевого отклика  $\hat{y}$ .

Полученные на модельном примере результаты подтверждают идею о необходимости и полезности регуляризации НСМ, т.е. обеспечения ее устойчивости. Можно сделать следующий вывод: для построения качественной нейросетевой модели необходима предварительная подготовка (предобработка) данных, направленная на повышение их однородности. Предложенные авторами процедуры удаления противоречивых и аномальных наблюдений позволяют ослабить нежелательные последствия шума и добиться нужных прогностических свойств и точности модели. Интересно, что зависимость ошибки обобщения от интенсивности шума носит экспоненциальный характер.

Для того чтобы подтвердить эффективность предлагаемых процедур удаления противоречивых и аномальных наблюдений, проведем еще один вычислительный

эксперимент. Суть его в следующем: к исходной базе данных  $A = \{a_{ij}\}$ , состоящей из 200 вектор-строк, добавляется шумовая составляющая согласно правилам (9)–(10), формируется зашумленная база данных  $\tilde{A} = \{\tilde{a}_{ij}\}$  для обучения нейросети. Пусть  $\omega = 0,2$ , это значит, что 40 из 200 строк базы данных зашумлены. Зашумленные данные были промаркированы, для того чтобы оценить эффективность предлагаемых процедур регуляризации.

К полученной базе данных  $\tilde{A} = \{\tilde{a}_{ij}\}$  применим процедуру удаления противоречивых наблюдений и итерационную процедуру удаления аномальных наблюдений. После добавления шума в базе данных  $\tilde{A} = \{\tilde{a}_{ij}\}$  появилось 19 противоречивых пар вектор-строк. После их удаления в базе данных осталось 188 строк, 28 из которых содержат шум. Отметим, что в результате выполнения этой процедуры не все зашумленные строки были выявлены и удалены из базы данных. Можно дать следующее объяснение: процедуру удаления противоречивых наблюдений можно отнести к процедурам предрегуляризации модели, т.е. на этом этапе из зашумленной базы данных удаляются самые грубые неоднородности, дальнейшая чистка базы данных происходит на этапе обучения сети. После этого была проведена итерационная процедура обучения сети с удалением на каждой итерации аномальных наблюдений. На каждой  $k$ -й итерации фиксировались показатели качества обучения (4)–(5), число аномальных наблюдений  $A$  и уровень отбраковки  $\xi^{(k)}$  (табл. 2).



Таблица 2

Показатели качества обучения сети на каждой итерации при очистке базы данных от аномальных наблюдений

| (k)         | 1      | 2      | 3      | 4      | 5       | Обучение без шума |
|-------------|--------|--------|--------|--------|---------|-------------------|
| N           | 188    | 180    | 172    | 163    | 158     | 200               |
| A           | 8      | 8      | 9      | 5      | —       | —                 |
| $\xi^{(k)}$ | 10 %   | 4 %    | 3 %    | 2 %    | —       | —                 |
| E           | 0,5280 | 0,0741 | 0,0509 | 0,0325 | 0,0079  | 0,00130           |
| S           | 0,9064 | 0,0913 | 0,0939 | 0,0675 | 0,0978  | 0,01078           |
| J           | 0,4786 | 0,0067 | 0,0047 | 0,0021 | 0,00077 | 0,000014          |

В табл. 2 обозначено (k) – верхний индекс – это номер итерации по удалению аномальных наблюдений из данных; A – число удаленных аномальных точек;  $\xi^{(k)}$  – процент удаленных точек.

Как видно из табл. 2, после 4-й итерации в базе данных осталось 158 наблюдений. После обучения и тестирования сети на оставшихся данных, показатели качества обучения достигли желаемых значений, и процесс удаления аномальных наблюдений был остановлен. Из 158 наблюдений оставшихся в базе данных, только 3 строки содержат шум (они были промаркированы и отслеживались). Таким образом, 37 из 40 зашумленных строк были обнаружены и удалены из данных. При этом показатели качества обучения приблизились к значениям, наблюдавшимся при обучении сети на эталонных (незашумленных) данных (для удобства сравнения они приведены в последнем столбце табл. 2).

### Выводы

1. Проведенные вычислительные эксперименты подтвердили гипотезу о необходимости предобработки данных в целях повышения однородности, информативности и повышения качества обучения нейросетей в задачах, для которых характерны зашумление или сознательное искажение первичных данных.

2. На модельном примере показана эффективность и состоятельность процедур удаления противоречивых и аномальных наблюдений. Особое значение имеет то, что процесс поиска и удаления аномальных наблюдений проводится итерационно, взаимосвязанно с обучением нейросети при оценке данных по заболеваемости студентов высших учебных заведений.

3. Общая предлагаемая концепция исследований в статье: если имеют место сложные условия моделирования, то есть большая числовая мера интенсивности возмущения  $m^{(k)}$ , которые устранить нельзя, то нужно парировать эти условия (вырабатывать у НСМ «иммунитет» к указанным возмущениям):

- осуществить предобработку данных в направлении повышения их однородности и информативности; при этом предобработка интерпретируется как предрегуляризация нейросетевой модели, оценивающей показатели заболеваемости студентов;

- осуществить регуляризацию нейросетевой модели здоровьесбережения студентов на основе байесовского подхода.

Вопрос о реализации предложенной концепции является предметом отдельной публикации. Отметим лишь, что она оказалась успешной («зачатки» такой реализации уже видны из табл. 2).

Направления дальнейших исследований:

1. Необходимо детально проработать процедуры предобработки реальных данных опросных анкет, посвященных изучению условий жизни студентов различных высших учебных заведений.

2. Необходимо разработать метод байесовской регуляризации нейросетевых моделей применительно к сложным условиям моделирования (триады «НЕ-факторов»), близким к реальным, где закон распределения плотности вероятности шумов в данных не может быть априори заданным. Применить данный метод для оценки образа жизни студентов с дальнейшим прогнозированием заболеваемости в зависимости от образа и условий жизни.

3. Апробировать разработанные подходы в образовательных организациях.

### Список литературы

1. Бахтин Ю.К., Соломин В.П., Макарова Л.П., Сыромятникова Л.И. Значение медико-валеологического образования студентов и опыт его реализации в педагогическом университете. – Молодой ученый, 2012. – № 6. – С. 372–375.
2. Борисов А.А., Сыромятникова Л.И., Борисова Л.П. Реализация здоровьесформирующих образовательных технологий в области педагогического образования / Молодой ученый, 2012. – № 6. – С. 375–377.
3. Галушкин А.И. Нейрокомпьютеры и их применение на рубеже тысячелетий в Китае: Монография. В 2-х томах – М.: Горячая линия – Телеком, 2004. – Том I. – 367 с., том II. – 464 с.
4. Горбаткова Е.Ю., Шурыгина В.В., Шайдулина Ж.В. Основы медицинских знаний и здорового образа жизни. Ру-

ководство к самостоятельной работе студентов. – Уфа: Изд-во БГПУ, 2014. – 211 с.

5. Горбаткова Е.Ю., Мануйлова Г.Р. О некоторых вопросах профилактики девиантных форм поведения школьников / Перспективы развития науки и образования // Международная науч.-практ. конф. – Тамбов, 2014. – С. 27–29.

6. Горбатков С.А., Полупанов Д.В. Методы нейроматематики в налоговом контроле: Монография/Под ред. д-ра техн. наук, проф. С.А. Горбаткова. – Уфа: РИЦ БашГУ, 2008. – 136 с.

7. Горбаткова Е.Ю., Мануйлова Г.Р., Ланговой В.Е. Некоторые подходы к оценке результативности профилактической деятельности, направленной на сохранение и укрепление здоровья обучающихся // Современные проблемы науки и образования. – 2015. – № 1.

8. Нейросетевое математическое моделирование в задачах ранжирования и кластеризации бюджетно-налоговой системе регионального и муниципального уровней: Монография / С.А. Горбатков, Д.В. Полупанов, А.М. Солнцев, И.И. Белолипец, М.В. Коротнева, С.А. Фархьева, О.Б. Рашитова. – Уфа: Изд-во Башгосуниверситета, 2011. – 244 с.

9. Хайкин С. Нейронные сети: полный курс: Монография/Пер. с англ., 2-е издание. – М.: Издательский дом «Вильямс», 2006. – 1104 с.

10. Хуснутдинова З.А., Мануйлова Г.Р., Горбаткова Е.Ю., Титова Т.А. Основные вопросы реализации магистерской программы «Профилактика социальных отклонений (превентология)» / Молодой ученый. – № 3 (62). – СПб, 2014. – С. 1053–1056.

### References

1. Bahtin Ju.K., Solomin V.P., Makarova L.P., Syromjatnikova L.I. Znachenie mediko-valeologicheskogo obrazovaniya studentov i opyt ego realizacii v pedagogicheskom uni-versitete. Molodoj uchenyj, 2012. no. 6. pp. 372–375.

2. Borisov A.A., Syromjatnikova L.I., Borisova L.P. Realizacija zdoroveformirujushhih obrazovatelnyh tehnologij v oblasti pedagogicheskogo obrazovaniya / Molodoj uchenyj, 2012. no. 6. pp. 375–377.

3. Galushkin A.I. Nejrokompjutery i ih primenenie na rubezhe tysjacheletij v Kitae: Mo-nografija. V 2-h tomah M.: Gorjachaja linija Telekom, 2004. Tom I. 367 p., tom II. 464 p.

4. Gorbatkova E.Ju., Shurygina V.V., Shajdulina Zh.V. Osnovy medicinskih znanij i zdorovogo obraza zhizni. Rukovodstvo k samostojatelnoj rabote studentov. Ufa: Izd-vo BGPU, 2014. 211 p.

5. Gorbatkova E.Ju., Manujlova G.R. O nekotoryh voprosah profilaktiki deviantnyh form povedeniya shkolnikov / Perspektivy razvitiya nauki i obrazovaniya // Mezhdunarodnaja nauch.-prakt. konf. Tambov, 2014. pp. 27–29.

6. Gorbatkov S.A., Polupanov D.V. Metody nejromatematiki v nalogovom kontrole: Mono-grafija/ Pod red. d-ra tehn. nauk, prof. S.A. Gorbatkova. Ufa: RIC BashGU, 2008. 136 p.

7. Gorbatkova E.Ju., Manujlova G.R., Langovoj V.E. Ne-kotorye podhody k ocenke rezulta-tivnosti profilakticheskoy dejatel'nosti, napravlennoj na sohranenie i ukreplenie zdorov'ja obuchajushhihsja // Sovremennye problemy nauki i obrazovani-ja. 2015. no. 1.

8. Nejrosetevoe matematicheskoe modelirovanie v zadachah ranzhirovaniya i klasterizacii bjudzhetno-nalоговой sisteme regionalnogo i municipalnogo urovnej: Monografija / S.A. Gorbatkov, D.V. Polupanov, A.M. Solncev, I.I. Belolipcev, M.V. Korotneva, S.A. Farhieva, O.B. Rashitova. Ufa: Izd-vo Bashgosuniversiteta, 2011. 244 p.

9. Hajkin S. Nejronnye seti: polnyj kurs: Monografija / Per. s angl., 2-e izdanie. M.: Izdatelskij dom «Viljams», 2006. 1104 p.

10. Husnutdinova Z.A., Manujlova G.R., Gorbatkova E.Ju., Titova T.A. Osnovnye voprosy realizacii masterskoj programmy «Profilaktika socialnyh otklonenij (preventologija)» / Molodoj uchenyj. no. 3 (62). SPb, 2014. pp. 1053–1056.

### Рецензенты:

Лобанов С.А., д.м.н., профессор кафедры охраны здоровья и безопасности жизнедеятельности, ФГБОУ ВПО «Башкирский государственный педагогический университет им. М. Акмуллы», г. Уфа;

Горбушина С.Н., д.п.н., профессор кафедры стандартизации и сертификации Уфимского государственного авиационного технического университета, г. Уфа.