

ИНФОРМАТИКА, ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА И УПРАВЛЕНИЕ

УДК 004.942

DOI: 10.22213/2410-9304-2020-1-26-35

Нейросетевая модель прогнозирования человеческого капитала

Д. Д. Вавилова, аспирант, ИжГТУ имени М. Т. Калашникова, Ижевск, Россия

К. В. Кетова, доктор физико-математических наук, профессор,

ИжГТУ имени М. Т. Калашникова, Ижевск, Россия

Целью данной работы является применение нейросетевого моделирования и адаптация его алгоритмов для прогнозирования величины, структуры и динамики человеческого капитала региона. Статистической базой служат данные по демографии, объемам инвестирования в человеческий капитал региональной системы, а также индикаторы направлений социально-экономического развития региона. Суммарные объемы инвестиций в человеческий капитал определяют расходы бюджета и частные инвестиции граждан в капитал образования, здравоохранения и культуры. Прогноз величины, структуры и динамики человеческого капитала построен с помощью нейросетевой модели, которая представляет собой многослойную сеть с последовательными связями, обученную методом обратного распространения ошибок. Нейросетевая модель прогнозирования объемов частных и бюджетных инвестиций в составляющие человеческого капитала региона показала свою эффективность. Оценка человеческого капитала за период 2000–2018 гг. и его прогноз на период 2019–2023 гг. выполнен на примере региональной экономической системы Удмуртской Республики. Полученные результаты качественно коррелируют с динамикой индекса человеческого развития России, определяемого специалистами ООН. Предложенная методика расчета и прогноза человеческого капитала может быть использована для оценки и сравнительного анализа состояния социально-экономического развития регионов РФ.

Ключевые слова: нейросетевая модель, алгоритм прогноза, социально-экономическая система, человеческий капитал, инвестиции.

Введение

Прогноз развития производственной и социальной сфер социально-экономической системы строится с использованием методов экономико-математического моделирования. Производственная сфера характеризуется структурой и величиной производственного капитала (ПК), методология расчета которого хорошо известна. Для оценки социальной сферы в последнее время все чаще используется такой показатель, как человеческий капитал (ЧК).

Построение общей методики расчета ЧК является трудной задачей, поскольку существует доля субъективных оценок при моделировании. Различаются и позиции, на основе которых формулируется понятие ЧК. Он может быть изучен, в частности, как качество жизни, как способность к высокопроизводительной деятельности, как объем доходов, которые способен получить человек, или как объем инвестиций в социальную сферу. Какой бы подход ни был выбран исследователем для оценки ЧК, важно, что в настоящее время он выступает в качестве одного из наиболее важных факторов развития социально-экономической системы.

В данной работе используется интегральная экономико-математическая модель ЧК, включающая в себя количественные и качественные характеристики [1]. На основе модели производится расчет величины ЧК. Прогноз ЧК осуществляется с использованием нейросетевого алгоритма.

Нейросетевое моделирование является одним из математических методов исследования различного рода процессов и явлений. Оно применяется для решения задач интеллектуального анализа и прогнозирования данных [2–5].

Изначально искусственные нейронные сети (ИНС) были сконструированы в результате изучения нервной системы живого организма. Нейронная сеть является в определенном смысле аналогом мозга по качественной структуре и по количеству нейронов, содержащихся в ней. Применение нейронных сетей обладает преимуществами при построении прогнозов социально-экономических явлений: результативность при решении плохо формализованных задач; устойчивость к частым изменениям среды; эффективность при работе с большим объемом противоречивой или неполной информации [6].

Впервые об ИНС заговорили в 40-х годах прошлого века. Считается, что как научное направление теория ИНС была позиционирована в работе У. Мак-Каллока и В. Питтса [7]. Было показано, что любую логическую функцию можно реализовать с помощью простой нейронной сети. Также следует выделить и модель Д. Хэбба (1949 г.) [8]. В 1958 г. Ф. Розенблатт конструирует перцептрон, содержащий один слой [9]. После некоторого охлаждения к ИНС в 70-х годах возникает новая волна интереса. Благодаря исследованиям Т. Кохонена, С. Гроссберга и Д. Андерсона был построен фундамент, на основе которого стало возможно построение и использование

многослойных ИНС [10, 11]. В 1974 г. П. Вербосом для обучения многослойных ИНС разработан алгоритм, который нашел широкое применение на практике [12]. Среди исследователей, работающих в этой области, можно отметить М. Минского [13], Дж. Хопфилда [14], С. Хайкина [15], Р. Хехт-Нильсена [16] и др. Исследования последних лет представлены, например, в работах [17–19].

В данной статье рассмотрена задача прогнозирования ЧК социально-экономической системы на основе нейросетевого алгоритма. Структура исследования представлена на рис. 1.



Рис. 1. Структура исследования

Экономико-математическая модель человеческого капитала

Носителями ЧК являются демографические элементы, каждый из которых в момент времени t характеризуется возрастом τ . Численность элементов определяет количественную характеристику ЧК. Распределение демографических элементов по возрастам, описывающее демографическую структуру населения, обозначим $\rho(t, \tau)$. Функция $\varepsilon(t, \tau)$ задает долю населения возраста τ , участвующую в общественном производстве в год t . Задача моделирования и прогнозирования демографической динамики подробно представлена в работе [20].

Для расчета ЧК $H(t)$ экономической системы используется модель:

$$H(t) = \int_0^{\infty} \sum_{i=1}^3 \alpha_i h_i(t, \tau) \varepsilon(t, \tau) \rho(t, \tau) d\tau. \quad (1)$$

Функции $h_i(t, \tau)$ есть качественные составляющие ЧК: здоровье $i=1$, образование $i=2$, культура $i=3$. Удельное (на одну демографическую единицу) среднестатистическое значение ЧК определяется линейной комбинацией:

$$h(t, \tau) = \alpha_1 h_1(t, \tau) + \alpha_2 h_2(t, \tau) + \alpha_3 h_3(t, \tau), \quad (2)$$

$$\alpha_i \in (0, 1); \quad \sum_{i=1}^3 \alpha_i = 1,$$

α_i – веса составляющих ЧК; значения $h_i(t, \tau)$ измеряются в денежных единицах.

Эволюция каждой из составляющих ЧК описывается уравнением:

$$\frac{\partial h_i(t, \tau)}{\partial t} + \frac{\partial h_i(t, \tau)}{\partial \tau} = -v_i h_i(t, \tau) + s_i(t, \tau) + p_i(t, \tau). \quad (3)$$

В формуле (3) $s_i = s_i(t, \tau)$ – удельные расходы государства; $p_i = p_i(t, \tau)$ – удельные частные инвестиции; $v_i = v_i(t, \tau)$ – коэффициент выбытия [21].

Алгоритм нейросетевого прогнозирования человеческого капитала

Построим нейронную сеть для решения задачи прогнозирования ЧК. На рис. 2 представлен элемент нейронной сети – нейрон, у которого имеется m входов и выход. Такая конструкция называется перцептрон. Искусственная нейросеть – это способ компоновки нейронов для решения определенных задач. Обученный искусст-

венный нейрон работает так: каждый вход умножается на веса; далее все суммируется и прогоняется через активационную функцию, результат подается на выход. Нейроны собираются по слоям, где выполняются основные вычислительные операции. Обучение заключается в том, чтобы найти правильную весовую информацию, которая корректируется на основе анализа разности между вычисленными и идеальными выходными значениями. Для этого используется алгоритм обратного распространения ошибки.

Входные данные суммируются с весовыми коэффициентами w_j : $D = \sum_{j=1}^m w_j x_j$. На выходе нейрона присутствует логистическая активационная функция $f(D)$ (рис. 2), которая преобразует взвешенную сумму D входящего сигнала (рис. 3).

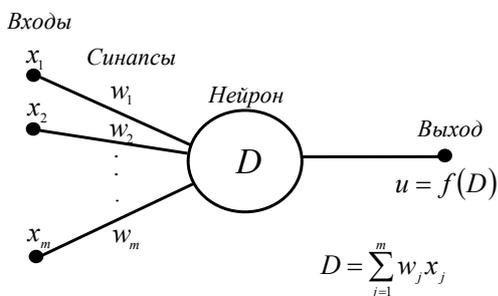


Рис. 2. Искусственный нейрон

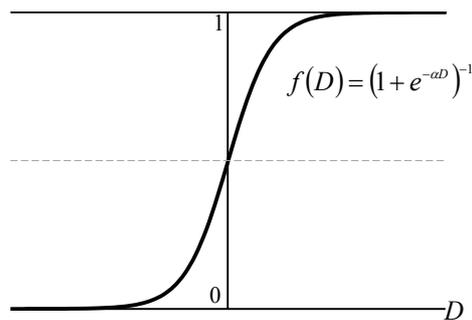


Рис. 3. Активационная функция

Для прогноза объемов инвестиций в социальную сферу сконструируем сложную k -слойную нейронную сеть с m входами и l выходами (рис. 4). Входными данными в нейросетевой модели являются объемы бюджетных $\{S_i\}_{i=1}^{n=3}$ и частных инвестиций $\{P_i\}_{i=1}^{n=3}$ в ЧК, индикаторы направлений социально-экономического развития $\{I_i\}_{i=1}^{n=8}$. Для учета инфляционных процессов используется индекс-дефлятор K . Выходные данные сети – прогнозные ежемесячные объемы бюджетных и частных инвестиций в ЧК: $\{\tilde{S}_i\}_{i=1}^{n=3}$ и $\{\tilde{P}_i\}_{i=1}^{n=3}$.

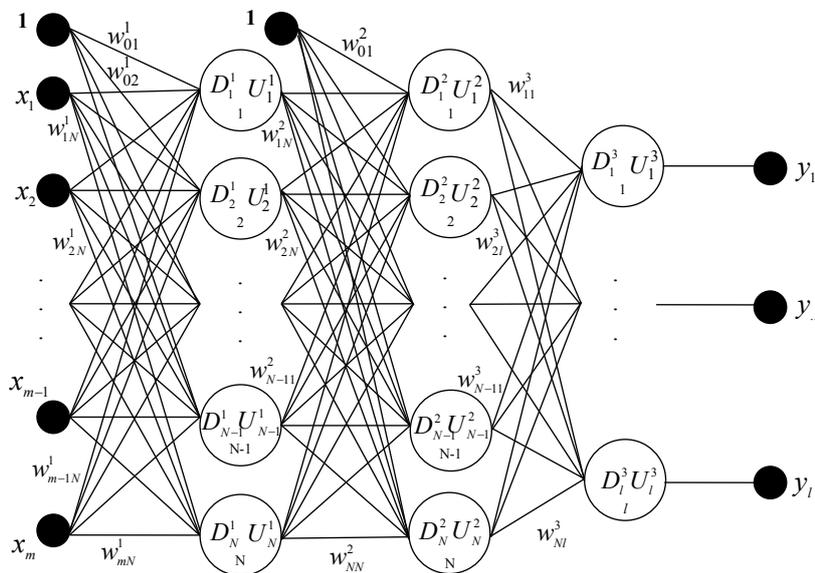


Рис. 4. Нейросетевая модель, используемая для прогнозирования инвестиций в ЧК

Для нашей задачи на входе будем рассматривать бюджетные инвестиции в здравоохранение (x_1), в образование (x_2), в культуру (x_3), а также частные инвестиции в здравоохранение (x_4),

в образование (x_5) и в культуру (x_6). Объемы инвестирования в социальную сферу зависят от множества факторов и окружающих условий. В работе С. А. Айвазяна [22] были выявлены

показатели, наиболее сильно влияющие на качество социальной сферы, а именно: валовой региональный продукт (x_7), среднедушевые денежные доходы (x_8), производство товаров и услуг на душу населения (x_9), площадь введенного жилья (x_{10}), количество зарегистрированных преступлений (x_{11}), естественный прирост населения (x_{12}), смертность в трудоспособном возрасте (x_{13}), минимально необходимый месячный доход (x_{14}). Таким образом, $\{S_i\}_{i=1}^{n=3} = \{x_1, x_2, x_3\}$, $\{P_i\}_{i=1}^{n=3} = \{x_4, x_5, x_6\}$, $\{I_i\}_{i=1}^{n=8} = \{x_7, x_8, x_9, x_{10}, x_{11}, x_{12}, x_{13}, x_{14}\}$, $K = x_{15}$. Алгоритм нейросетевого прогнозирования построим для произвольного случая с любым количеством входных переменных. На рис. 4 представлена нейросетевая модель, положенная в основу алгоритма. В каждом слое ИНС содержится N_p нейронов, $p = 1, \dots, k$.

Обозначения: w_{ij}^p – весовой коэффициент связи, соединяющий сигнал, выходящий из $(p-1)$ -го слоя i -го нейрона и входящий в j -й нейрон p -го слоя. Коэффициенты для каждого слоя представим в виде матрицы:

$$\vec{W} = (w_{ij}^p), p = 1, \dots, k; i = 0, \dots, N_{p-1}; j = 1, \dots, N_p. \quad (4)$$

С алгоритмической точки зрения выходные значения нулевого слоя u_j^0 следует приравнять к входящим в нейронную сеть сигналам x_j , $x_0 \equiv 1$:

$$u_j^0 = x_j, j = 0, \dots, m. \quad (5)$$

В остальных слоях выходные значения нейронов вычисляются:

$$u_j^p = 1, u_j^p = f(d_j^p), p = 1, \dots, k, j = 1, \dots, N_p, \quad (6)$$

$f(d_j^p)$ – активационная функция вида $f(t) = (1 + e^{-\alpha t})^{-1}$, α – коэффициент обучения.

Обозначим через d_j^p входящий сигнал в j -й нейрон p -го слоя, который определяется взвешенной суммой входящих в него сигналов:

$$d_j^p = \sum_{i=0}^{N_{p-1}} w_{ij}^p u_i^{p-1}, j = 1, \dots, N_p. \quad (7)$$

Выходные значения последнего k -го слоя должны соответствовать y_j :

$$y_j = u_j^k, j = 1, \dots, l. \quad (8)$$

Процесс обучения состоит в подстройке весовых коэффициентов w_{ij}^p . На основе информации о значениях переменных в известные моменты времени сеть определяет их наиболее вероятные значения на будущее. Статистическая информация делится на обучающее и тестовое множество.

Для обучения сети на входы подаются данные $\mathbf{x}_q = (x_{q1}, x_{q2}, \dots, x_{qm})$, далее сравнивают выходные значения с реально заданными $\mathbf{r}_q = (r_{q1}, r_{q2}, \dots, r_{ql})$, $q = 1, \dots, n$. На обучающем множестве реализуется алгоритм обратного распространения ошибок [23]. Для определения весовых коэффициентов $\vec{W} = (w_{ij}^p)$ сети используется погрешность

$$E_q(\vec{W}) = \frac{1}{2} \sum_{j=1}^l (y_{qj} - r_{qj})^2, q = 1, \dots, n, \quad (9)$$

где y_{qj} – соответствует j -му выходу при подаче на вход q -го образа.

При подаче q -го наблюдения коэффициенты будут изменяться так:

$$\vec{W}(q) = \vec{W}(q-1) + (-\lambda \cdot \nabla E_q), \quad (10)$$

где $\vec{W}(q)$ – состояние вектора \vec{W} после обучения сети по q -му наблюдению; $\lambda \in (0; 1]$ – скорость обучения сети; ∇E_q – градиент функции

$E_q(\vec{W})$, когда на вход подается q -й образ:

$$\nabla E_q = \left(\frac{\partial E_q}{\partial w_{ij}^p} \right), p = 1, \dots, k; i = 0, \dots, N_{p-1}; j = 1, \dots, N_p. \quad (11)$$

В компонентной форме выражение (11) представим в виде

$$w_{ij}^p(q) = w_{ij}^p(q-1) + \Delta w_{ij}^p, \Delta w_{ij}^p = -\lambda \frac{\partial E_q}{\partial w_{ij}^p}. \quad (12)$$

Компоненты вектора (12) распишем следующим образом:

$$\frac{\partial E_q}{\partial w_{ij}^p} = \frac{\partial E_q}{\partial u_j^p} \frac{\partial u_j^p}{\partial d_j^p} \frac{\partial d_j^p}{\partial w_{ij}^p}, \quad (13)$$

где частную производную $\frac{\partial u_j^p}{\partial d_j^p}$ в соответствии с производной логистической функцией $\frac{\partial f(t)}{\partial d} = \alpha f(t)(1-f(t))$ представим в виде

$$\frac{\partial u_j^p}{\partial d_j^p} = \alpha \cdot u_j^p \cdot (1 - u_j^p). \quad (14)$$

Введем новую переменную δ_j^p следующим образом:

$$\delta_j^p = \frac{\partial E_q}{\partial u_j^p} \frac{\partial u_j^p}{\partial d_j^p}, \quad (15)$$

$$\begin{aligned} \frac{\partial E_q}{\partial u_j^p} &= \sum_{i=1}^{N_{p+1}} \frac{\partial E_q}{\partial u_i^{p+1}} \frac{\partial u_i^{p+1}}{\partial d_i^{p+1}} \frac{\partial d_i^{p+1}}{\partial u_j^p} = \\ &= \sum_{i=1}^{N_{p+1}} \frac{\partial E_q}{\partial u_i^{p+1}} \frac{\partial u_i^{p+1}}{\partial d_i^{p+1}} w_{ji}^{p+1}. \end{aligned} \quad (16)$$

Тогда δ_j^p можно рекурсивно вычислять через данные $(p+1)$ -го слоя δ_j^{p+1} :

$$\delta_j^p = \left[\sum_{i=1}^{N_{p+1}} \delta_j^{p+1} w_{ji}^{p+1} \right] \cdot \alpha \cdot u_j^p \cdot (1 - u_j^p). \quad (17)$$

При $p=k$ из (7), (14) и (15), приравнявая $u_j^k = y_{qj}$, находим:

$$\delta_j^k = [u_j^k - r_{qj}] \cdot \alpha \cdot u_j^k \cdot (1 - u_j^k). \quad (18)$$

Последний множитель в формуле (13), согласно (7), равен: $\frac{\partial d_j^p}{\partial w_{ij}^p} = u_i^{p-1}$.

В результате на основании формул (12), (13), (15) получаем разностную схему:

$$w_{ij}^p(q) = w_{ij}^p(q-1) - \lambda \delta_j^p u_j^{p-1}. \quad (19)$$

Для того чтобы обучить сеть, необходимо нормировать входные и выходные данные в области их определения. Если известно, что $x_j \in [a_j - h_j; b_j + h_j]$, то нормированные входные данные имеют вид

$$\bar{x}_{qj} = \frac{x_{qj} - (b_j + a_j) / 2}{(b_j - a_j) / 2 + h_j}, q = 1, \dots, n. \quad (20)$$

Если известно, что изменение i -й выходной функции находится в пределах $[\varphi_i^{\min}, \varphi_i^{\max}]$, то нормированные выходные данные имеют вид:

$$\bar{r}_{qi} = \frac{r_{qi} - \varphi_i^{\min}}{\varphi_i^{\max} - \varphi_i^{\min}}, q = 1, \dots, n. \quad (21)$$

Чтобы получить реальные значения выходных данных, необходимо сделать обратное преобразование:

$$y_{qi} = \varphi_i^{\min} + \bar{y}_{qi} (\varphi_i^{\max} - \varphi_i^{\min}), q = 1, \dots, n, \quad (22)$$

где y_{qi} – реальное значение функции; \bar{y}_{qi} – i -е выходное нормированное значение функции при поданном на вход сети q -м образе.

Качество обучения сети определяется погрешностью обучения по формуле

$$\tilde{E}(\vec{W}) = 100 \sqrt{\frac{2}{l \cdot n} \sum_{q=1}^n E_q(\vec{W})}. \quad (23)$$

Погрешность расчетов определяется по формуле

$$\tilde{\varepsilon} = \frac{1}{M_y} \sum_{y \in [2000, 2018]} \frac{|y^* - y|}{y}, \quad (24)$$

где M_y – заданные точки показателя y ; y^* – значения, полученные по модели; y – реальные данные.

Результаты нейросетевого прогнозирования человеческого капитала

Проведем расчеты ЧК на примере Удмуртской Республики (УР). В построенной нейросетевой модели количество входных нейронов $N = 16$ ($1, \{S_i\}_{i=1}^{n=3}, \{P_i\}_{i=1}^{n=3}, \{I_i\}_{i=1}^{n=8}, K$), количество скрытых слоев равно двум (см. рис. 4).

В таблице представлены годовые бюджетные $\{S_i\}_{i=1}^{n=3}$ и частные инвестиции $\{P_i\}_{i=1}^{n=3}$, направленные на развитие ЧК УР, по данным [24, 25]. Динамика базовых индикаторов направлений социально-экономического развития УР $\{I_i\}_{i=1}^{n=8}$ взята с официальных сайтов статистической информации России [26, 27].

Бюджетные и частные инвестиции, направленные в ЧК, в УР в текущих ценах

Показатель	Временной интервал, год	Год, млн руб.				
		2000	2005	2010	2015	2018
Расходы консолидированного бюджета УР и территориальных государственных внебюджетных фондов						
Бюджетные инвестиции в здравоохранение и спорт		1459,3	4790,4	11966,7	26477,7	24996,2
Здравоохранение	$1 \leq \tau \leq \tau_m$	1382,3	4537,7	10500,7	25107,9	23224,9
Спорт и физическая культура	$3 \leq \tau \leq \tau_m$	42,0	137,9	680,9	1369,8	1741,3
Прочие расходы	$1 \leq \tau \leq \tau_m$	35,0	114,8	–	–	–
Бюджетные инвестиции в образование		2125,3	5425,5	13419,9	26349,0	31207,0
Дошкольное образование	$3 \leq \tau \leq 6$	528,7	1349,6	3306,2	7900,5	9596,1
Общее образование	$7 \leq \tau \leq 17$	1333,1	3403,2	7152,0	14471,7	14867,6
Начальное профессиональное образование	$14 \leq \tau \leq 17$	2,7	6,9	666,6	–	2003,3
Среднее профессиональное образование	$18 \leq \tau \leq 21$	60,4	154,2	455,0	1820,1	2261,7
Переподготовка и повышение квалификации	$25 \leq \tau \leq 59$	16,6	42,3	55,2	84,9	89,9
Высшее профессиональное образование	$18 \leq \tau \leq 22$	5,3	13,4	–	–	–
Молодежная политика и оздоровление детей	$3 \leq \tau \leq 59$	178,6	455,9	1787,5	2071,8	2388,4
Другие вопросы в области образования	$3 \leq \tau \leq \tau_m$	–	–	785,1	–	–
Бюджетные инвестиции в культуру		307,7	2433,0	1916,9	3634,4	4623,0
Культура	$3 \leq \tau \leq \tau_m$	235,7	1874,7	1642,3	2965,5	3444,7
Кинематография	$3 \leq \tau \leq \tau_m$	16,2	13,5	107,9	443,0	905,7
Телевидение и радиовещание	$3 \leq \tau \leq \tau_m$	28,3	298,8	83,6	84,5	80,3
Периодическая печать и издательства	$7 \leq \tau \leq \tau_m$	27,5	217,7	78,9	120,5	175,9
Прочие расходы в области культуры и СМИ	$3 \leq \tau \leq \tau_m$	–	28,4	4,2	20,9	16,4
Итого		3892,3	12648,9	27303,5	56461,1	60826,2
Расходы из федерального бюджета РФ и государственных внебюджетных фондов в УР						
Бюджетные инвестиции в здравоохранение	$1 \leq \tau \leq \tau_m$	*	*	*	987,3	1065,1
Бюджетные инвестиции в образование	$1 \leq \tau \leq \tau_m$	*	*	*	505,3	1440,7
Бюджетные инвестиции в культуру	$1 \leq \tau \leq \tau_m$	*	*	*	10,2	50,9
Итого		*	*	*	1502,8	2556,7
Частные инвестиции населения УР						
Частные инвестиции в здравоохранение	$1 \leq \tau \leq \tau_m$	412,2	2355,7	5996,2	9826,9	11952,0
Частные инвестиции в образование	$1 \leq \tau \leq \tau_m$	250,2	674,4	2410,2	2680,2	2553,5
Частные инвестиции в культуру и отдых	$1 \leq \tau \leq \tau_m$	423,2	4601,2	12525,5	19091,4	24724,8
Итого		1085,6	7631,3	20931,9	31598,5	39230,4

* отсутствуют статистические данные

На рис. 5–7 представлены результаты прогнозирования инвестиций в социальную сферу УР на период 2019–2023 гг. На рис. 8 приведен график сходимости к 1%-му уровню погрешности. Отклонение модельных значений инвестиций от фактических данных по УР за период 2000–2018 гг. в здравоохранение составляет 1,4 %, в образование – 1,2 %, в культуру – 1,1 %.

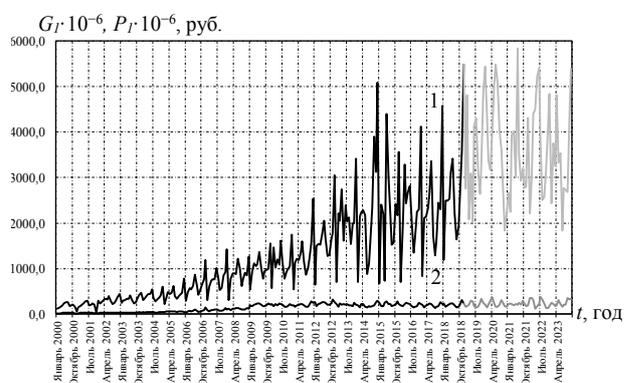


Рис. 5. Динамика инвестиций в образование УР за 2000–2018 гг. и их прогноз на 2019–2023 гг.: бюджетные (1), частные (2)

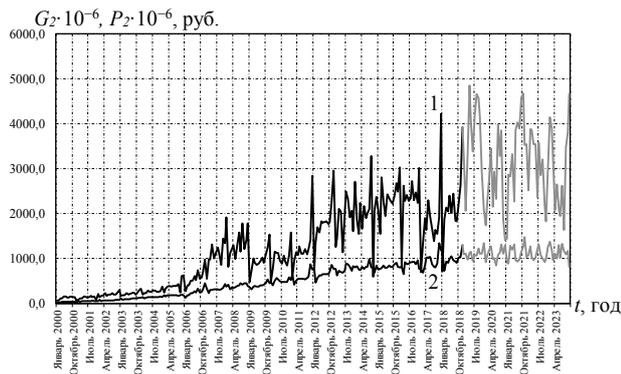


Рис. 6. Динамика инвестиций в здравоохранение УР за 2000–2018 гг. и их прогноз на 2019–2023 гг.: бюджетные (1), частные (2)

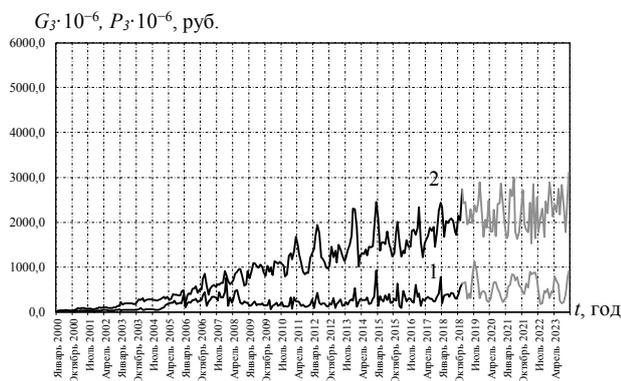


Рис. 7. Динамика инвестиций в культуру УР за 2000–2018 гг. и их прогноз на 2019–2023 гг.: бюджетные (1), частные (2)

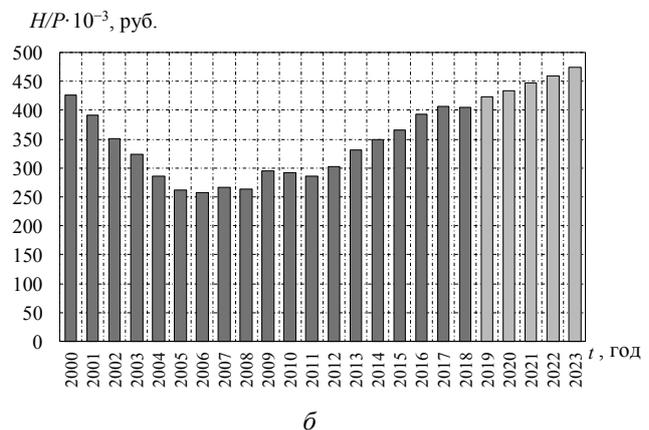
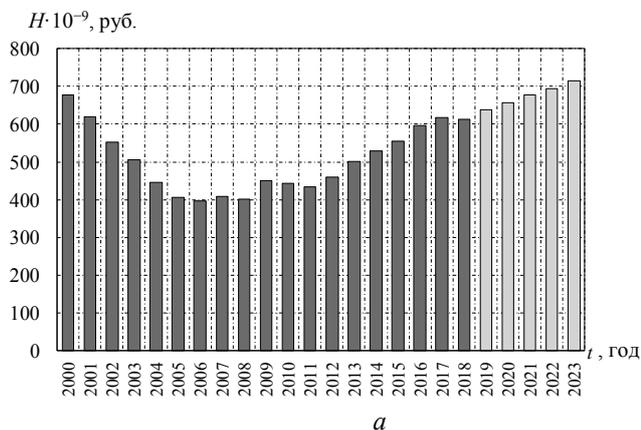


Рис. 9. Динамика человеческого капитала (а) и удельной величины ЧК (б) УР за 2000–2018 гг. и его прогноз в сопоставимых ценах

Заключение

Построен нейросетевой алгоритм, на основе которого решена задача прогнозирования человеческого капитала социально-экономической системы Удмуртской Республики. Нейросетевое моделирование прогнозных объемов инвестиций в человеческий капитал показало свою эффективность. Так, отклонение модельных зна-

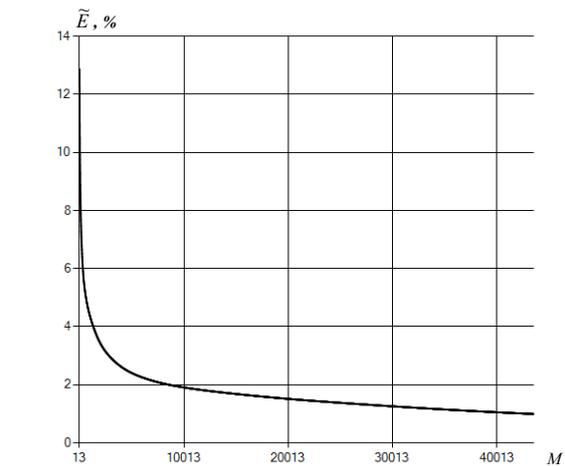


Рис. 8. Зависимость показателя качества обучения нейронной сети от числа итераций

На основе формулы (1) рассчитана величина ЧК УР за период 2000–2018 гг. Результаты расчета величины ЧК УР за период 2000–2018 гг. и результаты решения задачи прогнозирования величины и динамики ЧК с использованием результатов решения задачи прогнозирования объемов инвестиций в ЧК на основе нейросетевого моделирования на 2019–2023 гг. представлены на рис. 9.

Алгоритм нейросетевого прогнозирования социально-экономических процессов реализован авторами в программно-вычислительном комплексе [28].

чений инвестиций в составляющие ЧК УР от фактических данных за период 2000–2018 гг. составило 1,4 %.

Расчеты показали, что величина человеческого капитала Удмуртии снижалась в 2000–2006 гг., в дальнейшем наблюдался рост этого показателя. Наибольшие темпы роста изучаемый показатель демонстрирует с 2013 г. В 2018 г.

величина ЧК на одного жителя УР составила порядка 400 тыс. руб. Полученные результаты качественно коррелируют с динамикой индекса человеческого развития России, определяемого специалистами ООН, который в период с 2000 по 2012 г. возростал от значения 0,71 до 0,79 и в дальнейшем, вплоть до 2017 г., оставался практически постоянным, близким к значению 0,80.

Удмуртская Республика по многим социально-экономическим показателям является типичным регионом РФ [29] и характеризуется среднероссийскими значениями этих показателей. Поэтому результаты и выводы, полученные в ходе исследования, можно экстраполировать на РФ в целом. Предложенная методика расчета и прогноза человеческого капитала может быть использована для оценки и сравнения социально-экономического положения регионов России.

Библиографические ссылки

1. *Кетова К. В.* Математические модели экономической динамики: монография. Ижевск : Изд-во ИжГТУ, 2013. 284 с.
2. *Schmidhuber J.* Deep learning in neural networks: An overview. *Neural Networks*, 2015, vol. 61, pp. 85–117. DOI:10.1016/j.neunet.2014.09.003.
3. *Nguyen G., Dlugolinsky S., Bobk M.* Machine Learning and Deep Learning frameworks and libraries for large-scale data mining: a survey. *Artificial Intelligence Review*. 2019. Vol. 52. Pp. 77–124. DOI:10.1007/s10462-018-09679-z.
4. *Тененёв В. А., Тененёва А. В.* Обучение нечетких нейронных сетей генетическим алгоритмом // Интеллектуальные системы в производстве. 2010. № 1 (15). С. 76–85.
5. *Vavilova D.D., Ketova K.V., Kasatkina E.V.* Application of Genetic Algorithm for Adjusting the Structure of Multilayered Neural Network for Prediction of Investment Processes // Материалы VIII Международной конференции «Технические университеты: интеграция с европейскими и мировыми системами образования». 2019. Т. 1. С. 223–233.
6. *Ghanbarzadeh M., Aminghafari M.* A novel wavelet artificial neural networks method to predict non-stationary time series. *Communications in statistics-theory and methods*. 2018. Vol. 49. No. 4. Pp. 864–878. DOI:10.1080/03610926.2018.1549259.
7. *McCulloch W.S., Pitts W.* A logical calculus of the ideas immanent in nervous activity. *Bull. Math. Biophys.* 1943. Vol. 5. Pp. 115–133.
8. *Hebb D. O.* The Organization of Behavior: A Neuropsychological Theory. Wiley, 1949. 335 p.
9. *Rosenblatt F.* Principles of Neurodynamics: perceptrons and the theory of brain mechanisms. Washington, D.C. Spartan books, 1962. 480 p.
10. *Kohonen T.* Self-Organizing Maps(Third Ext. Edition). New York, 2001. 501 p.
11. *Grossberg S.* Competitive learning: From interactive activation to adaptive resonance. *Cognitive Science*. 1987. Vol. 11. No. 1. Pp. 23–63.
12. *Werbos P.J.* Beyond regression: New tools for prediction and analysis in the behavioral sciences. Harvard University, Cambridge, 1974.
13. *Minsky M.L., Papert S.* Perceptrons: an introduction to computational geometry. Cambridge, Mass., 1969. 112 p.
14. *Hopfield J.J., Tank D. W.* Neural computation of decisions in optimization problems. *Biological Cybernetics*. 1985. Vol. 52. No. 3. Pp. 141–152.
15. *Haykin S.* Neural Networks: A Comprehensive Foundation. United States, 1998. 842 p.
16. *Hecht-Nielsen R.* Confabulation Theory. Springer-Verlag Berlin Heidelberg, 2007. 116 p.
17. *Мутинская А. Н., Матыч М. А.* Исследование проблемы прогнозирования с использованием нейронных сетей // Актуальные направления научных исследований XXI века: теория и практика. 2015. Т. 3. № 7-2 (18-2). С. 30–31. DOI: 10.12737/15021.
18. *Cavarretta F., Naldi G.* Mathematical study of a nonlinear neuron model with active dendrites. *Aims Mathematics*. 2019. Vol. 4. No. 3. Pp. 831–846. DOI:10.3934/math.2019.3.831.
19. *Тененев В. А., Паклин Н. Б.* Гибридный генетический алгоритм с дополнительным обучением лидера // Интеллектуальные системы в производстве. 2003. № 2. С. 181.
20. Математическое моделирование человеческого капитала / К. В. Кетова, И. Г. Русяк и др. // Компьютерные исследования и моделирование. 2019. Т. 11. № 2. С. 329–342. DOI: 10.20537/2076-7633-2019-11-2-329-342.
21. *Русяк И. Г., Кетова К. В.* Идентификация и прогнозирование обобщающих показателей развития региональной экономической системы // Прикладная эконометрика. 2009. № 3 (15). С. 56–71.
22. *Айвазян С. А., Афанасьев М. Ю., Кудров А. В.* Индикаторы основных направлений социально-экономического развития // Прикладная эконометрика. 2019. № 2 (54). С. 51–62. DOI:10.24411/1993-7601-2019-10003.
23. *Рутковская Д., Пилинский М.* Нейронные сети. Генетические алгоритмы и нечеткие системы. М. : Горячая линия – Телеком, 2006. 452 с.
24. Исполнение бюджетов «Консолидированные бюджеты субъектов РФ и бюджетов территориальных государственных внебюджетных фондов». URL: <http://www.roskazna.ru/ispolnenie-byudzhetrov/konsolidirovannye-byudzhety-subektov/> (дата обращения: 10.12.2019).
25. Доходы, расходы и потребление домашних хозяйств. URL: <https://www.gks.ru/compendium/document/13271> (дата обращения: 10.12.2019).
26. Регионы России. Основные характеристики субъектов РФ. URL: <https://www.gks.ru/folder/210/document/13205> (дата обращения: 11.12.2019).
27. Итоги федеральных статистических наблюдений по социально-демографическим проблемам.

URL: https://www.gks.ru/free_doc/new_site/inspection/itog_inspect1.htm (дата обращения: 12.12.2019).

28. Кетова К. В., Касаткина Е. В., Насридинова Д. Д. Программа структурной оптимизации прогнозных нейросетевых моделей. Свидетельство о регистрации программы для ЭВМ 2014618038. Заявка № 2014615568 от 10.06.2014.

29. Рейтинг социально-экономического положения регионов РФ – 2019. URL: rating.ru/info-grafika/20190604/630126280.html (дата обращения: 20.01.2020).

References

1. Ketova K.V. *Matematicheskie modeli ekonomicheskoi dinamiki* [Mathematical Models of Economic Dynamics]. Izhevsk, Izd-vo IzhGTU Publ., 2013. 284 p. (in Russ.).

2. Schmidhuber J. Deep learning in neural networks: An overview. *Neural Networks*, 2015, vol. 61, pp. 85-117. DOI:10.1016/j.neunet.2014.09.003.

3. Nguyen G., Dlugolinsky S., Bobk M. (2019). Machine Learning and Deep Learning frameworks and libraries for large-scale data mining: a survey. *Artificial Intelligence Review*, vol. 52, pp. 77-124. DOI:10.1007/s10462-018-09679-z.

4. Tenenev V.A., Teneneva A.V. [Training fuzzy neural networks with a genetic algorithm]. *Intellektual'nye sistemy v proizvodstve*, 2010. No. 1, pp. 76-85. (in Russ.).

5. Vavilova D.D., Ketova K.V., Kasatkina E.V. Application of Genetic Algorithm for Adjusting the Structure of Multilayered Neural Network for Prediction of Investment Processes. *Materialy VIII Mezhdunarodnoi konferentsii «Tekhnicheskie universitety: integratsiya s evropeiskimi i mirovymi sistemami obrazovaniya»*, 2019, vol. 1, pp. 223-233.

6. Ghanbarzadeh M., Aminghafari M. A novel wavelet artificial neural networks method to predict non-stationary time series. *Communications in statistics-theory and methods*, 2018, vol. 49, no.4, pp.864–878. DOI:10.1080/03610926.2018.1549259.

7. McCulloch W.S., Pitts W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bull. Math. Biophys.*, vol. 5, pp.115–133.

8. Hebb D.O. *The Organization of Behavior: A Neuropsychological Theory*. 1949. Wiley, 335 p.

9. Rosenblatt F. *Principles of Neurodynamics: perceptrons and the theory of brain mechanisms*. Washington, D.C. Spartan books, 1962. 480 p.

10. Kohonen T. *Self-Organizing Maps (Third Ext. Edition)*. New York, 2001. 501 p.

11. Grossberg S. Competitive learning: From interactive activation to adaptive resonance. *Cognitive Science*, 1987, vol. 11, no. 1, pp. 23-63.

12. Werbos P.J. *Beyond regression: New tools for prediction and analysis in the behavioral sciences*. 1974. Harvard University, Cambridge.

13. Minsky M.L., Papert S. *Perceptrons: an introduction to computational geometry*. 1969. Cambridge, Mass. 112 p.

14. Hopfield J.J., Tank D.W. Neural computation of decisions in optimization problems. *Biological Cybernetics*, 1985, vol. 52, no. 3, pp. 141–152.

15. Haykin S. *Neural Networks: A Comprehensive Foundation*. United States. 1988. 842 p.

16. Hecht-Nielsen R. *Confabulation Theory*. Springer-Verlag Berlin Heidelberg. 2007. 116 p.

17. Mitinskaya A.N., Matych M.A. [Investigation of the problem of forecasting using neural networks]. *Aktual'nye napravleniya nauchnykh issledovaniy XXI veka: teoriya i praktika*, 2015, vol. 3, no. 7-2, pp. 30-31. DOI: 10.12737/15021 (in Russ.).

18. Cavarretta F., Naldi G. Mathematical study of a nonlinear neuron model with active dendrites. *Aims Mathematics*, 2019, vol. 4, no. 3, pp. 831-846. doi:10.3934/math.2019.3.831.

19. Tenenev V.A., Paklin N.B. (2003). [Hybrid genetic algorithm with additional leader training]. *Intellektual'nye sistemy v proizvodstve*, no. 2, pp. 181 (in Russ.).

20. Ketova K.V., Rusyak I.G. [Mathematical modeling of human capital]. *Komp'yuternye issledovaniya i modelirovanie*, 2019, vol. 11, no.2, pp. 329-342. DOI: 10.20537/2076-7633-2019-11-2-329-342 (in Russ.).

21. Rusyak I.G., Ketova K.V. [Identification and forecasting of general indicators of development of a regional economic system]. *Prikladnaya ekonometrika*, 2009, no. 3 (15), pp. 56-71 (in Russ.).

22. Aivazyan S.A., Afanas'ev M.Yu., Kudrov A.V. [Indicators of the main directions of socio-economic development]. *Prikladnaya ekonometrika*, 2019, no. 2 (54), pp. 51-62. DOI: 10.24411/1993-7601-2019-10003 (in Russ.).

23. Rutkovskaya D., Pilin'skii M. *Neironnye seti. geneticheskie algoritmy i nechetkie sistemy* [Neural networks. Genetic Algorithms and Fuzzy Systems]. Moscow, 2006, Goryachaya liniya–Telekom Publ., 452 p. (in Russ.).

24. *Ispolnenie byudzhetrov «Konsolidirovannye byudzhety sub"ektov RF i byudzhetrov territorial'nykh gosudarstvennykh vnebyudzhethnykh fondov»*, [Budget execution "Consolidated budgets of the constituent entities of the Russian Federation and budgets of territorial state extra-budgetary funds."], available at: <http://www.roskazna.ru/ispolnenie-byudzhetrov/konsolidirovannye-byudzhety-subektov/> (accessed 10.12.2019) (in Russ.).

25. *Dokhody, raskhody i potreblenie domashnikh khozyaistv* [Household income, expenses and consumption], available at: <https://www.gks.ru/compendium/document/13271> (accessed 10.12.2019) (in Russ.).

26. *Regiony Rossii. Osnovnye kharakteristiki sub"ektov RF* [Regions of Russia. The main characteristics of the constituent entities of the Russian Federation], available at: <https://www.gks.ru/folder/210/document/13205> (accessed 11.12.2019) (in Russ.).

27. *Itogi federal'nykh statisticheskikh nablyudenii po sotsial'no-demograficheskim problemam* [The results of federal statistical observations on socio-demographic problems], available at: https://www.gks.ru/free_doc/new_site/inspection/itog_inspect1.htm (accessed 12.12.2019) (in Russ.).

28. Ketova K.V., Kasatkina E.V., Nasridinova D.D. *Programma strukturnoi optimizatsii prognoznnykh neirosetevykh modelei. Svidetel'stvo o registratsii programmy dlya EVM 2014618038*. 2014. (in Russ.).
29. *Reiting sotsial'no-ekonomicheskogo polozheniya regionov RF – 2019* [Rating of the socio-economic situation of the regions of the Russian Federation – 2019], available at: riarating.ru/infografika/20190604/630126280.html (accessed 20.01.2020) (in Russ.).

Neural Network Model for Forecasting Human Capital

D. D. Vavilova, Post-graduate, Kalashnikov ISTU, Izhevsk, Russia

K. V. Ketova, DSc (Physics and Mathematics), Professor, Kalashnikov ISTU, Izhevsk, Russia

The aim of this research is the using of neural network modeling and the adaptation of its algorithm to build a forecast of the value, structure and dynamics of human capital. The statistical base is data on demographics, the volume of investment in human capital of the regional economic system, as well as indicators of the directions of socio-economic development. The total investment in human capital determines budget expenditures and private expenses of citizens. To forecast the dynamics of human capital, the values of volumes of investments in them are used, the forecast of which, in turn, is built using the neural network model. The neural network model used in this study is a multi-layer fully connected perceptron. Neural network modeling of forecast values of investment volumes has shown its effectiveness. The assessment of human capital for 2000-2018 and its forecast for 2019-2023 are carried out on the example of the regional economic system of the Udmurt Republic. The results obtained are qualitatively correlated with the dynamics of changes in the human development index of Russia, determined by UN specialists. The proposed methodology for calculating and forecasting human capital can be used to assess and compare the socio-economic situation of the regions of Russia.

Keywords: neural network model, forecast algorithm, socio-economic system, human capital, investments.

Получено: 19.02.2020