

В.И. Скурихин, Л.С. Житецкий, С.А. Николаенко

Прогнозирование стоимости объектов недвижимости с использованием нейросетевых систем

Приведены результаты экспериментальных исследований аппроксимационных свойств нейронных сетей с одним скрытым слоем для прогнозирования стоимости объектов недвижимости.

The results of the experimental investigations of neural networks' approximating properties with one hidden layer for the prediction of the real estate costs evaluation are given.

Наведено результати експериментальних досліджень апроксимаційних властивостей нейронних мереж з одним прихованим шаром для прогнозування вартості об'єктів нерухомості.

Введение. Рынок недвижимости есть одним из ключевых факторов финансовой активности в экономике государства. Его поведение, подобно другим рынкам (рынок акций, рынок нефти и пр.) можно охарактеризовать как нелинейное. Оно выражается постоянными изменениями, т.е. ростом или падением стоимости квадратного метра недвижимости. Стоимость одного и того же объекта недвижимости, например квартиры, может заметно изменяться в зависимости от значений многих факторов. Однако такая зависимость априори неизвестна. Поэтому прогнозирование стоимости объектов недвижимости – нелегкая задача.

Существуют различные достаточно эффективные методы и алгоритмы восстановления неизвестных функциональных зависимостей по экспериментальным данным, включая знаменитый метод группового учета аргументов (МГУА), который был предложен А.Г. Ивахненко в конце 60-х годов прошлого столетия для построения математических моделей сложных систем и изложен во многих периодических изданиях и монографиях [1–5]. В последнее десятилетие внимание ряда отечественных и зарубежных исследователей стали привлекать методы построения таких моделей на базе искусственных нейронных сетей [6–13]. Эти модели начали активно эксплуатироваться в дальнем зарубежье для решения ряда важных экономических задач, например, прогнозирования состояния фондовой биржи.

Нейронные сети – хорошие аппроксиматоры неизвестных нелинейных функций [8]. В частности, так называемая трехслойная нейронная сеть прямого распространения с одним скрытым слоем может сколь угодно точно аппроксимировать произвольное многомерное отображение [9]. На возможность применения нейронной сети прямого распространения для прогнозирования стоимости квадратного метра объектов недвижимости указано в работе [11]. Других публикаций, использующих подобный подход для конкретных случаев, ранее не встречалось.

Цель работы – исследование возможности прогнозирования стоимости квадратного метра объектов недвижимости на вторичном рынке (т.е. без учета новостроек), в частности, одно-, двух- и трехкомнатных квартир на основе трехслойной нейронной сети прямого распространения.

Характеристика исходных данных

Известно, что существует зависимость между стоимостью C квадратного метра объекта недвижимости и такими переменными: расположение объекта x_1 ; количество комнат x_2 ; этажность дома x_3 ; общая площадь x_4 ; жилая площадь x_5 ; площадь кухни x_6 ; состояние объекта x_7 ; материал стен x_8 ; наличие подземного транспорта в непосредственной близости от объекта x_9 .

Рассмотрим более подробно переменные, которые используются при оценке рыночной стоимости квартир.

Район города (x_1). Чем ближе район расположен к центру города, тем выше будет и стоимость квартиры в сравнении с точно такой же, но расположенной в более отдаленном районе.

Количество комнат (x_2). Наиболее высокая стоимость квадратного метра однокомнатных квартир, так как, учитывая дороговизну недвижимости в целом, однокомнатные квартиры раскупаются в первую очередь. За ними следуют с небольшой разницей в сторону уменьшения стоимости двухкомнатные квартиры. Самым малым спросом пользуются трехкомнатные квартиры, соответственно и стоимость квадратного метра в такой квартире будет заметно отличаться от стоимости одно- и двухкомнатных квартир.

Этажность (x_3). Количество этажей в доме имеет как субъективное, так и объективное влияние на цену квадратного метра. К субъективным факторам можно отнести боязнь высоты, квартирному взлому и пр. Соответственно желание покупателя жить на нижних или верхних этажах при доступном выборе будет также влиять на конечную цену. К объективным факторам относится взаимозависимость между количеством этажей в доме и периодом его постройки. Общеизвестно, что пятиэтажные дома, называемые «хрущевками», массово строились в 50-х – 60-х годах, девятиэтажные массово строились в 70-х – 80-х годах, двенадцати-, пятнадцати- и шестнадцатиэтажные строились и продолжают строиться примерно с 90-х годов. Соответственно, чем новее жилой дом, тем стоимость квадратного метра в нем будет выше.

Общая площадь (x_4). Стоимость квадратного метра жилья будет выше в просторной однокомнатной квартире, чем в тесной. Однако данная тенденция не всегда сохраняется для двух- и трехкомнатных квартир, так как за большую общую площадь взимается большая квартплата, что в случае двух- и трехкомнатных квартир более ощутимо для будущего собственника недвижимости.

Жилая площадь (x_5). Стоимость квадратного метра жилья будет выше в одно-, двух- и трехкомнатной квартире с более просторными спальней и залом.

Площадь кухни (x_6). Стоимость квадратного метра жилья будет выше в одно-, двух- и трехкомнатной квартире с более просторной кухней.

Состояние (x_7). Очевидно, что стоимость квадратного метра жилья будет ниже в квартире, требующей ремонта.

Стены (x_8). Стоимость квадратного метра жилья будет выше в кирпичном доме в сравнении, например, с панельным.

Метро (x_9). Наличие станции метро рядом с жильем (на расстоянии менее десяти минут ходьбы) существенно удорожает стоимость квадратного метра жилья.

Итак, существует функциональная зависимость $C = F(x_1, \dots, x_9)$ между стоимостью C объекта недвижимости и девятью приведенными переменными, упорядоченный набор которых образует девятимерный вектор $\mathbf{x} = [x_1, \dots, x_9]^T$ (T – знак транспонирования). Эту зависимость в компактной форме удобно записывать так:

$$C = F(\mathbf{x}). \quad (1)$$

Функция (1) в явном виде *априори неизвестна* (неизвестен оператор $F: \mathbf{R}^9 \rightarrow \mathbf{R}$, формально отображающий девятимерное евклидово пространство векторов \mathbf{x} на одномерном евклидовом пространстве переменной C). В то же время имеется множество некоторого числа $L \gg 1$ пар

$$\{\mathbf{x}^{(1)}, C^{(1)}\}, \dots, \{\mathbf{x}^{(L)}, C^{(L)}\}, \quad (2)$$

каждая из которых определяется набором значений $\mathbf{x}^{(v)} = [x_{(1)}^{(v)}, \dots, x_{(9)}^{(v)}]^T$ указанных переменных вместе с соответствующей ему известной стоимостью объекта: $\mathbf{x}^{(v)} \rightarrow C^{(v)}, (v = 1, \dots, L)$.

Задача исследования

Аппроксимируем неизвестную функцию (1) функцией

$$\hat{C} = F_0(\mathbf{x}, \mathbf{w}), \quad (3)$$

возложив ее реализацию на нейросетевую систему. Здесь \mathbf{w} – некоторый пока неизвестный вектор, составленный из так называемых весовых коэффициентов и смещений нейронной сети [9]; \hat{C} – прогнозируемая стоимость объекта; $F_0(\cdot, \cdot)$ – скалярная функция, зависящая уже не только от \mathbf{x} , но и от \mathbf{w} . Конкретный вид этой

зависимости в конечном счете определяется выбранной структурой сети.

Качество прогнозирования будем оценивать среднеквадратичной ошибкой

$$\bar{\varepsilon} = \sqrt{\frac{1}{N} \sum_{v=1}^N (C^{(v)} - \hat{C}^{(v)})^2}, \quad (4)$$

которая согласно (1) и (3) зависит от \mathbf{w} и определяется выражением

$$\bar{\varepsilon}(\mathbf{w}) = \sqrt{\frac{1}{N} \sum_{v=1}^N [F(\mathbf{x}^{(v)}) - F_0(\mathbf{x}^{(v)}, \mathbf{w})]^2}. \quad (5)$$

В этом выражении N – некоторое фиксированное натуральное число, удовлетворяющее условиям

$$1 < N \leq L. \quad (6)$$

Процесс обучения нейросетевой системы сводится, как известно [9], к использованию набора (2), позволяющему итерационным способом найти такой вектор $\mathbf{w} = \mathbf{w}^*$, при котором в условиях ограничений (6) на число N средний квадрат $E(\mathbf{w}) := \bar{\varepsilon}^2$ ошибки прогнозирования, записанной на основании (5), достигнет минимума:

$$\bar{E}(\mathbf{w}) = \frac{1}{N} \sum_{v=1}^N [F(\mathbf{x}^{(v)}) - F_0(\mathbf{x}^{(v)}, \mathbf{w})]^2 \rightarrow \min.$$

Задача исследования состояла в том, чтобы на реальных данных, содержащих $L = 4125$ пар (2), проверить возможность применения стандартных методов (алгоритмов) обучения нейросетевой системы, способных обеспечить заданную среднеквадратическую ошибку прогнозирования $\bar{\varepsilon}^0$ в форме целевого требования

$$\bar{\varepsilon} \leq \bar{\varepsilon}^0. \quad (7)$$

Структура нейросетевой системы и ее функционирование в режиме прогнозирования

В качестве прогнозирующей системы была выбрана трехслойная нейронная сеть прямого распространения. Поскольку в рассматриваемой задаче $x \in \mathbf{R}^9$, то входной слой такой нейронной сети должен содержать девять входов.

Сегодня еще нет строго обоснованного метода определения количества нейронов в скрытом слое; впрочем некоторые соображения ма-

тематического характера относительно выбора числа нейронов в скрытом слое можно найти в [13]. Между тем в большинстве работ по нейронным сетям рекомендуются различные интуитивные приемы определения количества этих нейронов. В частности, в работе [10] подбор количества нейронов скрытого слоя предлагается начинать с числа, вдвое большего числа нейронов во входном слое. При неудовлетворительном результате работы нейронной сети рекомендуют добавлять или сокращать число нейронов и сравнивать результаты работы сети до и после изменения количества нейронов. Исходя из этого, было принято число нейронов в скрытом слое, равное 18.

Результатом работы нейронной сети должна быть единственная величина, а именно прогнозируемая стоимость \hat{C} квадратного метра квартиры. Следовательно, выходной слой сети должен содержать всего лишь один нейрон.

Общая схема нейросетевой системы показана на рис. 1. В такой системе распространение информации от входного (первого) слоя нейронов ко второму (скрытому) слою осуществляется в соответствии с соотношением

$$y_i^{(2)} = \sigma(s_i), \quad (i=1, \dots, 18). \quad (8)$$

В этом соотношении $y_i^{(2)}$ – сигнал на выходе i -го нейрона скрытого слоя, а $\sigma(\cdot)$ – активационная функция, которая представляет собой нелинейную функцию от скалярного аргумента

$$s_i = \sum_{j=1}^9 w_{ij}^{(1)} x_j + b_i^{(1)}. \quad (9)$$

Здесь x_j – выходной сигнал j -го нейрона первого слоя (j -я компонента вектора x), $w_{ij}^{(1)}$ – весовой коэффициент синаптической связи j -го нейрона первого слоя с i -м нейроном скрытого слоя, $b_i^{(1)}$ – соответствующее смещение (см. рис. 1). Чаще всего активационной функцией служит функция

$$\sigma(s) = \frac{1}{1 + \exp(-s)} \quad (s \in (-\infty, \infty)) \quad (10)$$

со значениями в интервале $(0, 1)$, именуемая в теории нейросетей сигмоидной [8].

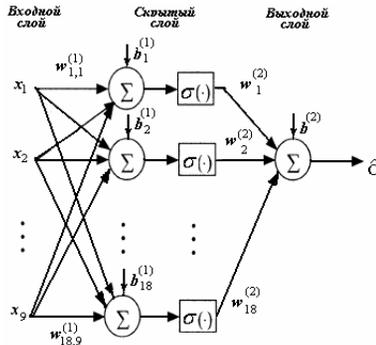


Рис. 1. Трехслойная нейронная сеть, используемая для прогнозирования стоимости квадратного метра недвижимости

Связь между нейронами скрытого слоя и единственным нейроном выходного слоя, как изображено на рис. 1, обычно строится в линейной форме

$$\hat{C} = \sum_{i=1}^{18} w_{i1}^{(2)} y_i^{(2)} + b^{(2)}, \quad (11)$$

где $w_{i1}^{(2)}$ – весовой коэффициент синаптической связи i -го нейрона скрытого слоя с нейроном выходного слоя, $b^{(2)}$ – смещение.

Уравнения (8) – (11) полностью описывают нейросетевую систему (3) в режиме прогнозирования, где вектором \mathbf{w} служит составной вектор $\mathbf{w} = [\mathbf{w}^{(1)T} ; \mathbf{w}^{(2)T}]^T \in \mathbf{R}^{199}$, где

$$\mathbf{w}^{(1)} = \underbrace{[w_{1,1}^{(1)}, \dots, w_{1,9}^{(1)}, b_1^{(1)}, \dots, w_{18,1}^{(1)}, \dots, w_{18,9}^{(1)}, b_{18}^{(1)}]^T}_{180 \text{ компонентов}},$$

$$\text{а } \mathbf{w}^{(2)} = [w_1^{(2)}, \dots, w_{18}^{(2)}, b^{(2)}]^T.$$

Известно [9], что надлежащим выбором числа нейронов в скрытом слое, весовых коэффициентов и смещений в (9) и (11) можно аппроксимировать произвольную непрерывную нелинейную функцию $F(\mathbf{x})$ функцией вида (3) с точностью до любого наперед заданного $\varepsilon > 0$ в том смысле, что $\max_{\mathbf{x} \in X} |F(\mathbf{x}) - F_0(\mathbf{x}, \mathbf{w})| \leq \varepsilon$, где $X \subset \mathbf{R}^9$ есть ограниченное множество. Отсюда следует, что если величина C практически не зависит от других переменных, то задача получения ее оценки \hat{C} с заданной точностью, выраженной в форме требования (7) вместе с (1), (3) и (4) в принципе может быть решена.

Методы обучения нейросетевой системы

Дадим краткую сравнительную характеристику использованных стандартных методов обучения, известных из теории нейронных сетей [9].

Метод градиентного спуска. При реализации этого метода корректировка векторов весов происходит в направлении, противоположном градиенту $\text{grad } E(\mathbf{w}(n))$ среднего квадрата ошибки прогнозирования

$$E(\mathbf{w}(n)) = \frac{1}{N} \sum_{v=1}^N [C^{(v)} - \hat{C}^{(v)}(n)]^2 \text{ на каждом } n\text{-м}$$

шаге алгоритма обучения. Сам же алгоритм градиентного спуска можно записать в виде

$$\mathbf{w}(n+1) = \mathbf{w}(n) - \eta \text{grad}_{\mathbf{w}} E(\mathbf{w}(n)), \quad (12)$$

где η – положительная константа, называемая параметром скорости обучения. Алгоритм (12) обеспечивает коррекцию всех 180 весовых коэффициентов и 19 смещений нейросети (8) – (11).

Методы сопряженного градиента. В алгоритмах, реализующих метод сопряженного градиента, поиск осуществляется вдоль сопряженных направлений, которые дают более быструю сходимость, чем направление наискорейшего спуска. Кроме того, на каждой итерации параметр η изменяет свое значение так, что $\eta = \eta(n) \neq \text{const}$. Такой поиск позволяет найти величину скорости обучения, минимизирующую среднестатистическую ошибку $E(\mathbf{w}(n))$ вдоль этого направления.

Из всех существующих методов сопряженного градиента использовался метод Флэтчера–Ривза [11]. Согласно этому методу на первой итерации осуществляется поиск направления наискорейшего спуска (отрицательного градиента), определяемого вектором

$$\mathbf{p}(0) = -\text{grad } E(\mathbf{w}(0)). \quad (13)$$

Затем осуществляется линейный поиск для определения оптимального расстояния с тем, чтобы двигаться вдоль текущего направления поиска:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \alpha(n)\mathbf{p}(n). \quad (14)$$

Здесь $\alpha(n) > 0$ – некоторая скалярная величина. При этом каждое очередное направление поиска определяется так, чтобы оно было сопряжено с предыдущим направлением поиска.

Общая процедура определения нового направления поиска заключается в объединении нового направления наискорейшего спуска с предыдущим направлением:

$$\mathbf{p}(n) = -\text{grad}_{\mathbf{w}} E(\mathbf{w}(n)) + \beta(n)\mathbf{p}(n-1), \quad (15)$$

$$n = 1, 2, \dots$$

Коэффициент $\beta(n)$ в (15), как и $\alpha(n)$, представляет собой некоторую скалярную величину.

Различные версии алгоритмов сопряженного градиента отличаются одна от другой способом вычисления коэффициента $\beta(n)$. В рассматриваемом методе Флэтчера–Ривза эта величина определяется так:

$$\beta(n) = \frac{\text{grad}_{\mathbf{w}}^T E(\mathbf{w}(n)) \text{grad}_{\mathbf{w}} E(\mathbf{w}(n))}{\text{grad}_{\mathbf{w}}^T E(\mathbf{w}(n-1)) \text{grad}_{\mathbf{w}} E(\mathbf{w}(n-1))}.$$

Ньютоновы методы. Альтернативой методам сопряженного градиента выступают ньютоновы методы. Основной шаг метода Ньютона определяется по формуле

$$\mathbf{w}(n+1) = \mathbf{w}(n) - \mathbf{H}^{-1}(n) \text{grad}_{\mathbf{w}} E(\mathbf{w}(n)), \quad (16)$$

в которой $\mathbf{H}(n)$ матрица вторых частных производных текущей ошибки $E(\mathbf{w}(n))$ по составляющим векторов \mathbf{w} при $\mathbf{w} = \mathbf{w}(n)$ (гессиан). Ньютоновы методы сходятся, как известно, быстрее алгоритмов (13) – (15) сопряженного градиента, однако требуют при этом больше ресурсов нейронной сети для вычисления обратного гессиана $\mathbf{H}^{-1}(n)$.

Квазиньютоновы алгоритмы в отличие от (16) не требуют вычисления обратного гессиана. В этих алгоритмах приближенные значения обратного гессиана обновляются на каждом шаге работы алгоритма.

Метод Левенберга–Марквардта. Алгоритм, реализующий этот метод, подобен квазиньютоновым алгоритмам в том смысле, что он также не предусматривает вычисление напрямую обратного гессиана $\mathbf{H}^{-1}(n)$. Однако приближенные его значения вычисляются несколько по-другому. Именно, гессиан \mathbf{H} аппроксимируется как

$$\mathbf{H} = \mathbf{J}^T \mathbf{J}, \quad (17)$$

а градиент среднего квадрата ошибки определяется как

$$\text{grad}_{\mathbf{w}} E = \mathbf{J}^T \mathbf{e}. \quad (18)$$

Здесь \mathbf{J} – якобиан, содержащий упорядоченный набор первых частных производных ошибок сети e_1, \dots, e_N по весам и смещениям, а

$\mathbf{e} = [e_1, \dots, e_N]^T$ обозначает N -мерный вектор этих ошибок. Якобиан \mathbf{J} в выражениях (17) и (18) может быть вычислен посредством стандартной техники обратного распространения, что значительно менее затратно, чем вычисление обратного гессиана \mathbf{H}^{-1} . Алгоритм Левенберга–Марквардта использует аппроксимированную матрицу \mathbf{H} для обновления параметров сети согласно соотношению

$$\mathbf{w}(n+1) = \mathbf{w}(n) - [\mathbf{J}^T(n)\mathbf{J}(n) + \mu\mathbf{I}]^{-1} \mathbf{J}^T(n)\mathbf{e}(n), \quad (19)$$

в котором $\mu \geq 0$ – некоторое фиксированное число. Заметим, что при $\mu = 0$ алгоритм (19) ничем не отличается от ньютонова алгоритма, использующего аппроксимированную матрицу \mathbf{H} вида (17), тогда как при большом $\mu > 0$ он ничем не отличается от стандартного алгоритма (12) градиентного спуска. Метод Ньютона более быстрый и точный вблизи точки минимума среднеквадратичной ошибки E . Таким образом, главная задача алгоритма Левенберга–Марквардта – как можно более быстрое смещение в направлении использования метода Ньютона. Число μ уменьшается после каждой успешной итерации и увеличивается в противном случае. Тем самым гарантируется уменьшение среднеквадратичной ошибки $E(n)$ на каждом последующем шаге работы алгоритма.

Результаты экспериментов

Чтобы исследовать возможности обучения нейросетей и оценку эффективности прогнозирования стоимости объектов недвижимости, в среде *MATLAB* была разработана прикладная программа, позволившая моделировать функциональные преобразования вида (8) – (11) после завершения процессов обучения, реализующие все описанные методы.

Исходная информация об объектах недвижимости была представлена набором $L = 4125$ пар (2). Заданная точность прогнозирования принята равной $\bar{\varepsilon}^0 = 0,5$ тыс. у.е.

Подобно тому, как это делают при реализации алгоритма МГУА [2, с. 124], имеющееся множество L пар (2) было разделено на две группы, а именно на обучающее множество, содержащее $L_{об}$ таких пар, и проверочное множество $L_{пров}$ пар, так, что

$$L = L_{об} + L_{пров} \quad (20)$$

В соответствии с (20) при $L = 4125$ было взято $L_{об} = 4000$, $L_{пров} = 125$.

Процесс обучения нейросети прекращался на той итерации с номером $n = n_{об}$, когда впервые выполнялось условие

$$\bar{\varepsilon}(\mathbf{w}(n)) \leq \bar{\varepsilon}^0, \quad (21)$$

где $\bar{\varepsilon}(\mathbf{w}(n))$ – среднеквадратичная ошибка прогнозирования, найденная по формуле (5) при $N=L_{об}$ и $\mathbf{w} = \mathbf{w}(n)$ после каждой очередной n -й итерации.

Характер изменения величины $\bar{\varepsilon}$ при различных методах обучения иллюстрируют графики на рис. 2 – 5. Как видно, во всех случаях среднеквадратичная ошибка $E(\mathbf{w}(n))$ на обучающемся множестве монотонно уменьшалась; при этом условие (21) остановка алгоритма рано или поздно выполнялось.

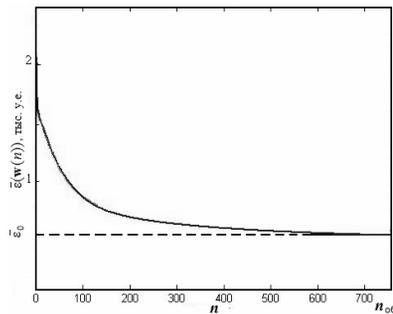


Рис. 2. Процесс обучения нейросети по методу градиентного спуска

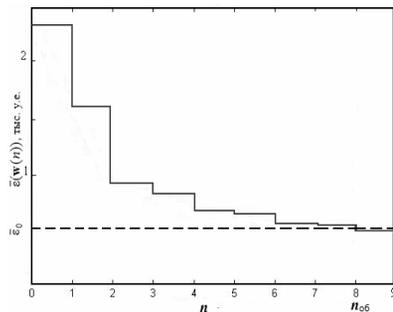


Рис. 3. Процесс обучения нейросети по методу сопряженного градиента

Результаты обучения, содержащие информацию о продолжительности $n_{об}$ процесса обучения и среднеквадратичной ошибке $\bar{\varepsilon}(\mathbf{w}(n_{пров}))$, найденной по формуле (5) при $N=L_{пров}$, представлены в табл. 1.

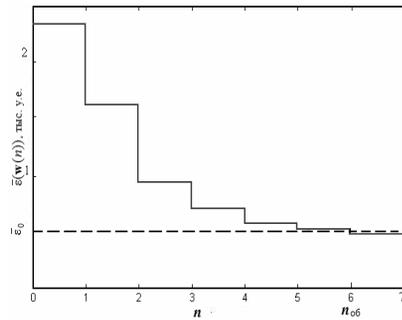


Рис. 4. Процесс обучения нейросети по квазиньютоновскому методу

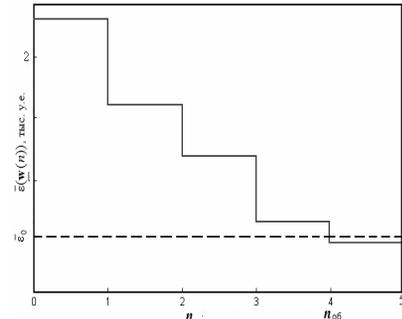


Рис. 5. Процесс обучения нейросети по методу Левенберга-Марквардта

Таблица 1. Результаты обучения нейросети

	Метод			
	градиентного спуска	сопряженного градиента	квазиньютоновский	Левенберга-Марквардта
Продолжительность процесса обучения (в числе итераций $n_{об}$), определяемая условием (21) остановка алгоритма	754	8	6	4
Среднеквадратичная ошибка прогнозирования на проверочном множестве	0,4091	0,3882	0,3778	0,3649

Для проверки точности аппроксимации после завершения обучения на вход нейронной сети подавались примеры, не участвующие при ее обучении, и оценивалась правдоподобность аппроксимации во всех четырех случаях.

Пример 1. Пусть требуется спрогнозировать стоимость квадратного метра однокомнатной квартиры пятиэтажного кирпичного дома в хорошем состоянии общей площадью 27 м^2 , жилой площадью 16 м^2 , площадью кухни 4 м^2 .

Результаты прогнозирования приведены в табл. 2.

Таблица 2. Оценка стоимости квадратного метра недвижимости нейронной сетью в примере 1

Реальная стоимость квадратного метра жилья C тыс. у.е.	Прогнозируемая стоимость \hat{C} , тыс. у.е., найденная после обучения сети по методу:			
	Градиентного спуска	Сопряженного градиента	Квазиньютоновскому	Левенберга – Марквардта
3,482	3,288	3,505	3,286	3,465

Пример 2. Предположим теперь, что требуется спрогнозировать стоимость квадратного метра двухкомнатной квартиры девятиэтажного панельного дома в удовлетворительном состоянии общей площадью $46,4 \text{ м}^2$, жилой площадью $28,4 \text{ м}^2$, площадью кухни 8 м^2 . Результаты работы сети после ее обучения по разным методам (алгоритмам) приведены в табл. 3.

Приведенные в табл. 2 и 3 результаты прогнозирования стоимости объектов недвижимости при двух разных исходных условиях, случайным образом взятых из проверочного множества, показывают, что после обучения трехслойная нейронная система позволяет обеспечить приемлемую точность аппроксимации неизвестной функциональной зависимости (1) в форме (3).

Таблица 3. Оценка стоимости квадратного метра недвижимости нейронной сетью в примере 2

Реальная стоимость квадратного метра жилья, C , тыс. у.е.	Прогнозируемая стоимость \hat{C} , тыс. у.е., найденная после обучения сети по методу:			
	градиентного спуска	сопряженного градиента	квазиньютоновскому	Левенберга–Марквардта
3,089	2,934	3,002	2,915	3,065

Заключение. Установлена возможность прогнозирования стоимости объектов недвижимости на основе нейронной сети прямого распространения, обученной одним из четырех описанных методов: методом градиентного спуска, методом сопряженного градиента, квазиньютоновским методом и методом Левенберга–Марквардта. Оказалось, что наименьшее количество итераций на этапе обучения, необходимых для достижения заданной точности аппроксимации, требуется при использовании метода Левенберга–Марквардта (четыре итерации). Наибольшее количество итераций, равное 754,

требуется при использовании метода градиентного спуска.

Приведенные реальные примеры показывают эффективность использования трехслойной нейросетевой системы для прогнозирования стоимости объектов недвижимости в практической деятельности: аппроксимационные свойства обученной нейронной сети вполне удовлетворительны.

1. *Ивахненко А.Г.* Метод группового учета аргументов – конкурент метода стохастической аппроксимации // Автоматика. – 1968. – №3. – С. 57–73.
2. *Ивахненко А.Г., Зайченко Ю.П., Димитров В.Д.* Принятие решений на основе самоорганизации. – М.: Сов. радио, 1976. – 280 с.
3. *Ивахненко А.Г., Степашко В.С.* Помехоустойчивое моделирование. – К.: Наук. думка, 1985. – 300 с.
4. *Ивахненко А.Г., Юрачковский Ю.П.* Моделирование сложных систем по экспериментальным данным. – М.: Радио и связь, 1987. – 120 с.
5. *Степашко В.С.* Комбинаторный алгоритм МГУА с оптимальной схемой перебора моделей // Автоматика. – 1981. – № 3. – С. 31–36.
6. *Куссуль Н.Н.* Обучение нейронных сетей с использованием метода нечетких эллипсоидальных оценок // Проблемы управления и информатики. – 2001. – № 1. – С. 72–78.
7. *Зайченко Ю.П.* Основы проектирования интеллектуальных систем. – К.: Дім Слово, 2004. – 352 с.
8. *Уоссермен Ф.* Нейрокомпьютерная техника. – М.: Мир, 1992. – 184 с.
9. *Haykin S.* Neural networks: a comprehensive foundation (second edition). – NY: Prentice Hall, 1999. – 1121 p.
10. *Круглов В., Борисов В.* Искусственные нейронные сети. Теория и практика. – М.: Горячая линия – Телеком, 2002. – 377 с.
11. *Hagan M., Demuth H., Beale M.* Neural network design. – NY: PWS Publish. Comp., 2008. – 734 p.
12. *Rumelhart D.E., Hinton G.E., Williams R.J.* Learning internal representations by error propagation // Parallel distributed processing: explorations in the microstructure of cognition. – Cambridge: MIT Press, 1986. – 1. – P. 318–362.
13. *Widrow B., Lehr M.A.* 30 years of adaptive neural networks: perceptron, madaline and backpropagation // Proc. IEEE. – 1990. – 78, N 9. – P. 1415–1442.

Поступила 29.03.2011

Тел. для справок: (044) 526-1154 (Киев)

© В.И. Скурихин, Л.С. Житецкий, С.А. Николаенко, 2011