

**ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ
ПРОГНОЗИРОВАНИЯ ДИНАМИКИ ЭКОНОМИЧЕСКИХ ПОКАЗАТЕЛЕЙ**

**APPLICATION OF ARTIFICIAL NEURAL NETWORKS FOR PREDICTION OF
DYNAMIC ECONOMIC INDICATORS**

Аннотация: в статье рассматривается прогнозирование динамики экономических показателей на основе нейросетевых технологий. Проводится сравнительный анализ использования линейной сети, многослойной сети прямого распространения и радиальной базисной нейронной сети для решения данной задачи.

Abstract: the article deals with predicting the dynamics of economic indicators based on neural network technology. Comparative analysis of linear network, multilayer feed-forward network and radial basis network for solving this problem.

Ключевые слова: нейронная сеть, временной ряд, аппроксимация, функция активации, матрица весов, смещение нейрона, скрытый слой, линия задержки.

Keywords: neural network, time series, approximation, the activation function, the matrix of weights, the offset of the neuron, hidden layer, the delay line.

Предметной областью, в которой уже получили признание нейросетевые методы, является сфера экономики и финансов. В этой области нейросетевые алгоритмы нашли свое применение в форме математического ядра интеллектуальных систем принятия решений, экспертных систем, оболочек для имитационного моделирования, нейросетевых баз знаний и др. В данной работе внимание акцентируется на одном из направлений использования нейросетей – это применение нейросетевых технологий для прогнозирования динамики экономических показателей.

При решении задач прогнозирования роль нейронной сети состоит в предсказании будущей реакции системы по ее предшествующему поведению. Обладая информацией о значениях переменной x в моменты, предшествующие прогнозированию

$x(k-1), x(k-2), \dots, x(k-N)$, сеть вырабатывает решение, каким будет наиболее вероятное значение последовательности $x(k)$ в текущий момент k . При этом нейронная сеть играет роль универсального аппроксиматора функции от нескольких переменных, реализуя нелинейную функцию:

$$y = f(x), (1)$$

где x – это входной вектор, а y – реализация векторной функции нескольких переменных.

Во многих работах по теории и применению нейронных сетей имеет место утверждение, что нейронные сети являются наилучшим аппроксиматором функций [1, 2], что объясняется следующим образом. Согласно классической теории аппроксимации, аппроксимируемая функция представляется в следующем виде:

$$y(x) = \sum_i \alpha_i \psi_i(x). (2)$$

Здесь набор функций $\psi_i(x)$, как правило, выбирается априори, исходя из интересов автора конкретного метода аппроксимации и некоторых свойств данных функций, доказываемых и используемых в процессе аппроксимации.

Для нейронных сетей базовое выражение для аппроксимируемой функции выглядит несколько иначе, например, для трехслойной нейронной сети с последовательными связями:

$$y(x) = \psi \left(\sum_i \alpha_i \psi \left(\sum_j \alpha_{ij} \psi \left(\sum_k \alpha_{kj} x_k \right) \right) \right). (3)$$

В последнем выражении структура эквивалентных базовых функций ψ_i представлена в нейросетевом логическом базисе с множеством коэффициентов, которые являются настраиваемыми в процессе поиска наилучшей аппроксимации.

Задача прогнозирования динамики экономических показателей представляет собой, по существу, задачу прогнозирования временных рядов, которая в свою очередь сводится к задаче аппроксимации одномерных функций [3]. При этом можно использовать либо одно предыдущее значение целевой переменной x_{t-1} , либо несколько предыдущих: x_{t-1}, x_{t-2}, \dots . В этом случае увеличивается количество входов нейронной сети. В задаче прогнозирования временного ряда необходимо определить, сколько предыду-

щих значений одной переменной взять и как далеко вперед прогнозировать значение выходной переменной. Наблюдения должны быть упорядочены во времени, поскольку их порядок имеет значение.

Обычно формирование пары обучающих примеров осуществляется по принципу «скользящего окна»: т.е. берется некоторый отрезок временного ряда и из него выделяется несколько наблюдений, которые и будут представлять собой входной вектор. Значением желаемого выхода в обучающем примере будет следующее по порядку наблюдение. Затем «скользящее окно» сдвигается на одну позицию в направлении возрастания времени, и процесс формирования следующей пары обучающей выборки повторяется. Размер используемого временного ряда для обучения нейронной сети должен быть равен объему обучающей выборки (количеству примеров). При выборе числа входов нейронной сети, работающей в режиме предсказания временного ряда, следует выбирать разумный компромисс между глубиной предсказания и качеством обучения, поскольку увеличение числа входов нейронной сети соответственно уменьшает количество обучающих примеров.

Для прогнозирования временных рядов имеется опыт использования нейронных сетей различных типов. Рассмотрим применение нейронных сетей прямого распространения. В сетях прямого распространения сигнал распространяется только в одном направлении – от входов к выходам.

Согласно общепринятому принципу, если более сложная модель не дает результат лучше, чем более простая, то из этих двух моделей следует предпочесть последнюю. Самой простой архитектурой из нейронных сетей прямого распространения обладают линейные нейронные сети. Любая многослойная нейронная сеть с линейной функцией активации нейронных элементов эквивалентна однослойной линейной нейронной сети, поэтому линейные нейронные сети, как правило, не имеют скрытых слоев. Во время своей работы линейная нейронная сеть фактически умножает вектор входов на матрицу весов, а затем к полученному вектору прибавляет вектор смещения. Выходное значение такой сети определяется выражением:

$$y = Wp + b, (4)$$

где y – выход сети; W – матрица весов; p – вектор входов; b – вектор смещения.

Для организации «скользящего окна» можно предложить использовать на входе нейронной сети линию задержки. Последовательность значений входного сигнала

$p(k)$ поступает на линию задержки, состоящую из $N - 1$ блока запаздывания (по длине «скользящего окна»). Выход линии задержки – N -мерный вектор pd , составленный из значений входа в моменты времени $k, k-1, \dots, k-N-1$.

Результат работы линейной нейронной сети, состоящей из одного линейного нейрона и линии задержки из десяти блоков запаздывания представлен на рисунке 1. Обучение данной нейронной сети производилось по правилу Видроу-Хоффа, предполагающему минимизацию среднеквадратичной ошибки нейронной сети.

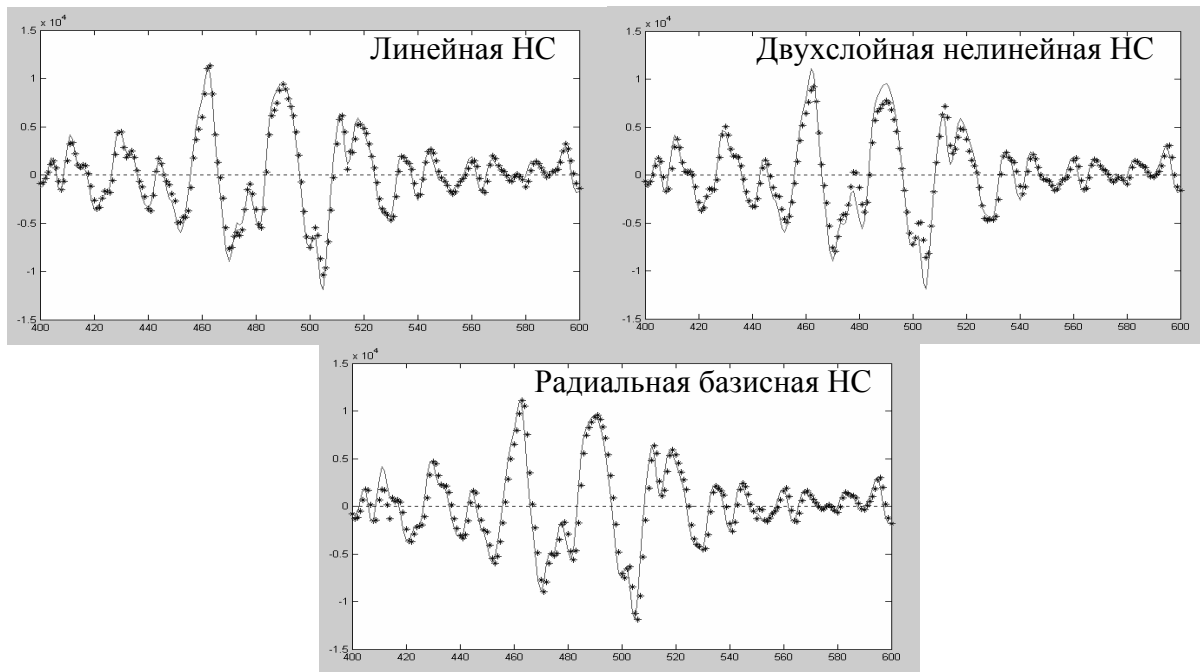


Рис.1. Результат предсказания нейронной сети: — исходные данные; * прогноз.

Многослойные нелинейные нейронные сети позволяют формировать более сложные связи между входами и выходами, чем однослойные линейные. Доказано, что двухслойная нейронная сеть с одним скрытым слоем может быть обучена аппроксимировать с произвольной точностью любую непрерывную функцию [2]. Данное утверждение является основой для аппроксимации и экстраполяции функций при помощи многослойных нейронных сетей.

Основываясь на вышесказанном, можно предложить для предсказания динамики экономических показателей нейронную сеть, структура которой включает входной слой и два слоя нейронных элементов. Входной слой нейронной сети выполняет распределительные функции. Скрытый нейронный слой производит обработку информа-

ции. Выходной нейронный слой служит как для обработки информации от предыдущих слоев, так и для выдачи результатов. Входной слой сети состоит из одного нейрона и линии задержки. Размерность «скользящего окна» определяет количество элементов вектора входа и максимальное значение задержки на входе. Скрытый слой является нелинейным. Чем больше число нейронных элементов в скрытом слое, тем выше точность предсказания. Однако при слишком большой размерности скрытого слоя может наступить явление, называемое перетренировкой сети, т.е. слишком большое число нейронов в скрытом слое ухудшает обобщающие способности нейронных сетей.

Обязательным условием выработки хороших способностей к обобщению считается грамотное определение меры Вапника-Червоненкиса для сети заданной структуры:

$$2 \left\lceil \frac{K}{2} \right\rceil N \leq VC \dim \leq 2N_w (1 + \lg N_n), \quad (5)$$

где $\lceil \cdot \rceil$ обозначена целая часть числа; K – количество нейронов скрытого слоя; N – размерность входного вектора; N_w – общее количество весов сети; N_n – общее количество нейронов сети.

Из выражения (5) следует, что нижняя граница диапазона приблизительно равна количеству весов, связывающих входной и скрытый слои, тогда как верхняя граница превышает двухкратное суммарное количество всех весов сети. В связи с невозможностью точного определения меры $VCdim$ в качестве ее приближенного значения используется общее количество весов нейронной сети. По результатам разнообразных численных экспериментов установлено, что высокие показатели обобщения достигаются в случае, когда количество обучающих выборок в несколько раз превышает меру Вапника-Червоненкиса $VCdim$ [4]. С учетом всего вышесказанного для размера «скользящего окна» десять элементов, скрытый слой был принят состоящим из одиннадцати нейронов. В качестве функции активации скрытого слоя использована логистическая сигмоидная функция:

$$y = \frac{1}{1 + e^{-x}}. \quad (6)$$

Использование нелинейной функции активации позволяет настроить нейронную сеть на реализацию нелинейных связей между входом и выходом. Однако если выходной слой многослойной сети будет использовать нелинейные сигмоидные функции ак-

тивации, то выходы сети будут ограничены. Если же в выходном слое используются линейные нейроны, то выходы сети могут принимать произвольные значения. Количество нейронов в выходном слое определяется целью производимых нейронной сетью вычислений. Таким образом, выходной слой нейронной сети для решения задачи предсказания динамики экономических показателей был принят содержащим один линейный нейрон. Поскольку функция активации нейронных элементов скрытого слоя имеет область чувствительности для входов в диапазоне немногим шире интервала от -1 до $+1$, входные данные были подвергнуты пре-процессированию приведением к диапазону $[-1 1]$ по формуле:

$$PN = 2 * (P - \min P) / (\max P - \min P) - 1, \quad (7)$$

где PN – матрица нормированных векторов входа; P – матрица векторов входа; $\min P$ – минимальный элемент входа; $\max P$ – максимальный элемент входа.

Выходное значение нейронной сети:

$$y = \sum_{i=1}^s v_i a_i + b, \quad (8)$$

где v_i – i -й весовой коэффициент выходного нейрона; b – смещение выходного нейрона; s – количество нейронов в скрытом слое; a_i – выход i -го нейрона скрытого слоя.

Выходные значения нейронных элементов скрытого слоя:

$$a_i = F\left(\sum_{j=1}^n w_{ij} p_j + b\right), \quad (9)$$

где F – сигмоидная функция активации скрытого слоя (6); w_{ij} – весовой коэффициент от j -го входа к i -му нейрону; p_j – j -й элемент входа; b – смещение нейрона скрытого слоя.

Обучение сети производилось методом обратного распространения ошибки с использованием алгоритма градиентного спуска с возмущением. Результат работы многослойной нейронной сети прямого распространения представлен на рисунке 1.

Радиальные базисные нейронные сети [4] выполняют те же функции, что и сигмоидные сети, однако реализуют иные методы обработки данных. В сигмоидной нейронной сети преобразование значения функции в произвольной точке пространства вы-

полняется объединенными усилиями многих нейронов (глобальная аппроксимация). Радиальные базисные нейронные сети осуществляют преобразование путем адаптации нескольких одиночных аппроксимирующих функций к ожидаемым значениям, причем эта адаптация проводится только в ограниченной области многомерного пространства. При таком подходе отображение всего множества данных представляет собой сумму локальных преобразований. Благодаря этой особенности обеспечивается значительное упрощение и, следовательно, ускорение процесса обучения.

Структура типичной радиальной базисной сети включает входной слой, на который подаются сигналы, описываемые входным вектором, скрытый слой с нейронами радиального типа и выходной слой, состоящий, как правило, из одного или нескольких линейных нейронов. Функция выходного нейрона сводится исключительно к взвешенному суммированию сигналов, генерируемых скрытыми нейронами. Скрытые нейроны реализуют функции, радиально изменяющиеся вокруг выбранного центра и принимающие ненулевые значения только в окрестности этого центра. Если сигмоидный нейрон представляется в многомерном пространстве гиперплоскостью, которая разделяет это пространство на две категории, в которых выполняется одно из двух условий: либо $\sum_j w_{ij}x_j > 0$, либо $\sum_j w_{ij}x_j < 0$, то радиальный нейрон представляет собой гиперсферу, которая осуществляет шаровое разделение пространства вокруг центральной точки.

Для предсказания динамики экономических показателей была использована итеративная процедура формирования радиальной базисной сети. Нейроны добавлялись к скрытому слою до тех пор, пока не была достигнута допустимая средняя квадратичная ошибка обучения.

Первый слой сети – это радиальный базисный слой. Вход радиальной базисной функции активации определяется как модуль разности вектора весов и вектора входа, умноженный на смещение. Тогда выход радиального базисного слоя:

$$a_i = F\left(\|IW_i^{11} - P\| b_i^1\right), \quad (10)$$

где P – вектор входа; IW_i^{11} – вектор весов i -го нейрона; b_i^1 – смещение i -го нейрона; F – радиальная базисная функция активации:

$$F(x) = e^{-x^2}. \quad (11)$$

Выход линейного слоя является выходом всей сети:

$$y = LW^{2l} a^l + b^2 \quad (12)$$

где LW^{2l} – матрица весов от первого ко второму слою сети; b^2 – смещение линейного нейрона; y – выход радиального базисного слоя.

При предсказании динамики экономических показателей на основе радиальной базисной нейронной сети в качестве обучающей выборки использовалась информация, содержащаяся в «скользящем окне». Обучающими выходными значениями являлись элементы предсказываемого временного ряда. Число нейронов в скрытом радиальном слое подбиралось сетью автоматически для каждого нового предсказания. Результаты предсказания радиальной базисной сетью представлены на рисунке 1.

По результатам проведенной работы можно сделать вывод, что нейросетевые методы являются эффективным средством решения задачи предсказания динамики экономических показателей. Все рассмотренные нейронные сети показали достаточно хорошие возможности. Однако более детальный анализ ошибки предсказания показал, что наилучшие результаты работы продемонстрировала радиальная базисная нейронная сеть.

Литература:

1. Галушкин А.И. Нейрокомпьютеры: Учеб. пособие для вузов / Общая ред. А.И. Галушкина. – М.: ИПРЖР, 2000. – 528 с.
2. Галушкин А.И. Нейронные сети: основы теории. – М.: Горячая линия-Телеком, 2010. – 496с.
3. Нейроматематика: Учебное пособие для вузов / Агеев А.Д., Балухто А.Н., Бычков А.В. и др.; Общая ред. А.И. Галушкина. – М.: ИПЖР, 2002. – 448 с.
4. Осовский С. Нейронные сети для обработки информации / Пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 344 с.