

УДК 517.5+519.95

ПРОГНОЗИРОВАНИЕ ПЕРИОДИЧЕСКИХ ВРЕМЕННЫХ РЯДОВ С ПОМОЩЬЮ АППАРАТА ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

© А.А. Арзамасцев, М.Н. Толмачёва, С.Н. Толмачёва, П.А. Азарова, А.В. Неудахин

Arzamastsev A.A., Tolmacheva M.N., Tolmacheva S.N., Azarova P.A., Neudakhin A.V. Forecasting periodic time rows with the aid of artificial neural networks. The article looks at the possibility to forecast periodic time rows using artificial neural networks. 3-, 4- and 5-pixel schemes are studied.

В настоящее время аппарат искусственных нейронных сетей (ИНС) используется для моделирования и прогнозов в различных областях естественных наук. К его достоинствам следует отнести: высокую адаптивную способность к экспериментальным данным (предыстории), встроенные алгоритмы минимизации функции невязки, возможность быстрого переучивания ИНС по мере поступления новых данных и удаления несущественных связей.

Многие естественнонаучные, экономические, социальные и другие процессы описываются эмпирическими функциями многих переменных вида $Y = f(x)$, где Y представляет собой базовую переменную, а x – вектор независимых переменных. Для многих процессов Y и x могут быть представлены в виде временных рядов, представляющих собой результат наблюдений за ними на протяжении некоторого периода времени. Часто ситуация усложняется еще и тем, что измерения самого базового фактора производятся с определенной погрешностью, которая накладывает шум на временной ряд. На практике бывает важно восстанавливать вид функции $Y = f(x)$ по результатам наблюдений, и делать прогноз Y по известным значениям для x .

Целью данной работы является исследование возможности прогнозирования периодических детерминированных и частично зашумленных временных рядов с помощью аппарата искусственных нейронных сетей. При этом необходимо определить целесообразность использования трех-, четырех- и пятиточечных схем.

При прогнозировании периодических временных рядов мы предлагаем поступать следующим образом. Пусть имеется временной ряд X_i , $i = 1, \dots, n$. Время в этом случае может быть выражено через число шагов.

Создадим матрицу для обучения ИНС (табл. 1), где k – дальность прогноза (число шагов, на которые делается прогноз); m – число входов для прогноза. В данной работе будем исследовать 3-х, 4-х и 5-ти точечные схемы, т. е. варьировать $m = 3, 4, 5$.

Таблица 1

Входы				Выход
X_1	X_2	..	X_m	X_k
X_2	X_3	..	X_{m+1}	X_{k+1}
X_3	X_4	..	X_{m+2}	X_{k+2}
:	:	..	:	:
X_{n-m+1}	X_{n-m+2}	..	X_n	$X_{k+n-m+1}$

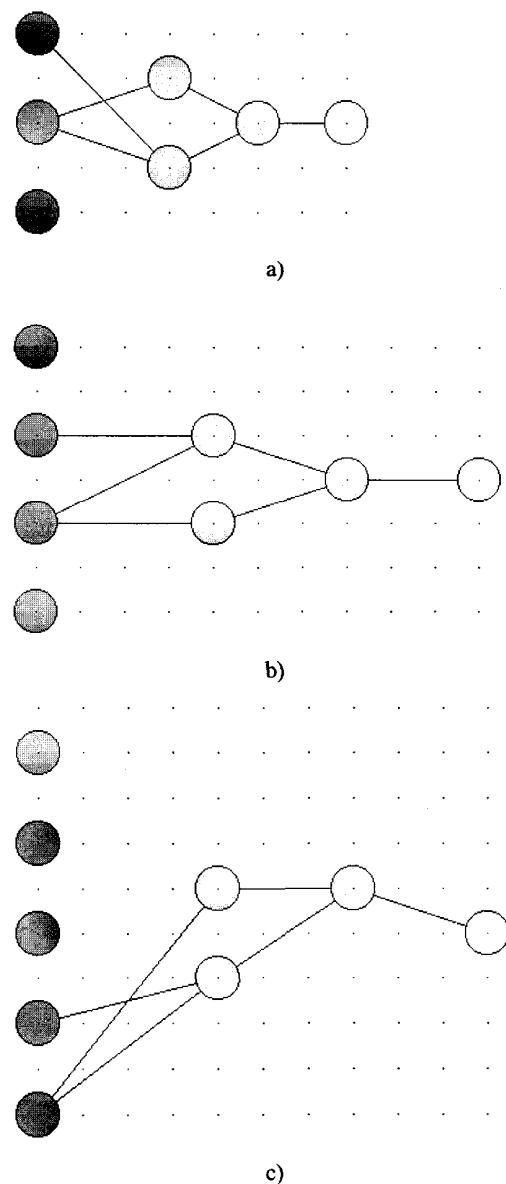


Рис. 1. Оптимальная структура ИНС для детерминированного случая: а) $-m = 3$; б) $-m = 4$; в) $-m = 5$

Выбор структуры ИНС и ее обучение производим стандартным образом. В ходе работы сравним точность прогнозов для $m = 3, 4, 5$.

Для проверки данного подхода была использована:
а) детерминированная периодическая функция $y = 10\sin x$; б) такая же функция, зашумленная случайным образом (уровень шума составил 10 % от амплитуды); $y = 10\sin x + \delta$, где δ – случайное число от -1 до 1.

Для каждого из этих случаев было испытано различное количество входных данных – $m = 3; 4; 5$ при дальности прогноза $k = 20$.

Выбор структуры и обучение ИНС проводились в программе NNC 3.01 (Neural Network Constructor copyright by Vladimir V. Krepets).

Получены следующие результаты.

Для детерминированного случая были подобраны структуры ИНС, представленные на рис. 1.

Результаты обучения ИНС и прогноза по ИНС для этих случаев представлены в табл. 2.

Из рис. 1 и табл. 2 следует, что для хорошего прогноза в случае детерминированной функции при дальности прогноза $k = 20$ достаточно информации только о двух точках. Интересным результатом является то, что в процессе своего обучения ИНС сама определила, что во всех случаях использование более двух входов нецелесообразно, и удалила лишние синаптические связи как несущественные.

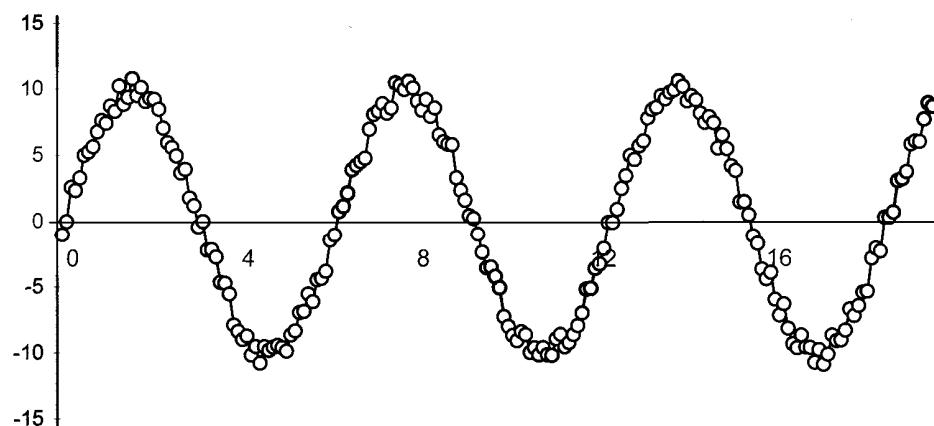


Рис. 2. Периодическая функция с наложенным шумом

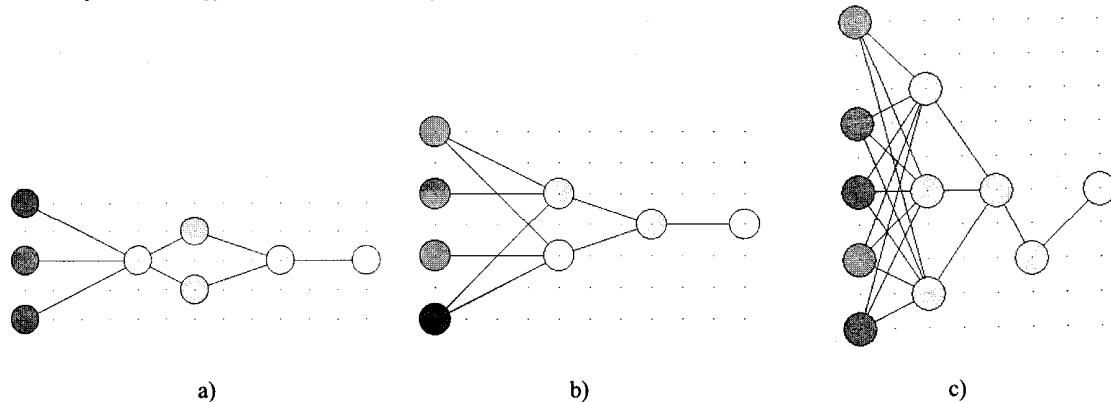


Рис. 3. Оптимальная структура ИНС для случая функции с наложенным шумом: а) – $m = 3$; б) – $m = 4$; в) – $m = 5$

Для случая периодической функции (рис. 2) с наложенным шумом были подобраны следующие структуры ИНС (рис. 3).

Результаты обучения ИНС и прогноза по ИНС для этих случаев представлены в табл. 3.

Соотношения спрогнозированных значений функции и экспериментальных данных представлены на графиках а–с (рис. 4).

Таблица 2

	Погрешность обучения ИНС, %	Погрешность прогноза по ИНС, %
$m = 3$	$2,87 \cdot 10^{-5}$	$9,79 \cdot 10^{-5}$
$m = 4$	$1,7 \cdot 10^{-5}$	$7,09 \cdot 10^{-5}$
$m = 5$	$1 \cdot 10^{-5}$	$2,14 \cdot 10^{-4}$

Таблица 3

	Погрешность обучения ИНС, %	Погрешность прогноза по ИНС, %
$m = 3$	27,34	41
$m = 4$	19,45	32,11
$m = 5$	14,65	15,81

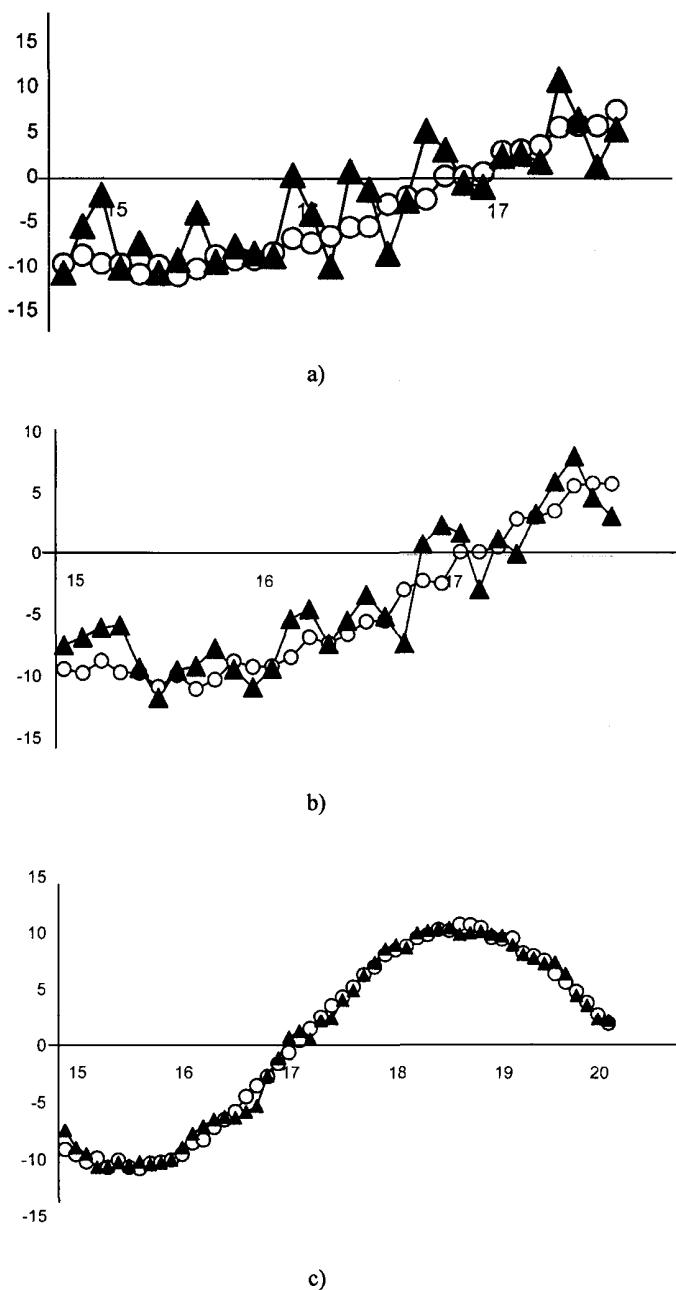


Рис. 4. Соотношения спрогнозированных значений функции и экспериментальных данных: а) – $m = 3$; б) – $m = 4$; в) – $m = 5$

Очевидно, что с увеличением количества входных точек уменьшается погрешность прогноза, хотя нужно учитывать, что структуры сетей в трех случаях неодинаковы.

Таким образом, применение искусственных нейронных сетей позволяет делать довольно удачные про-

гнозы поведения каких-либо реальных факторов, во внутренней структуре которых есть периодические составляющие.

Поступила в редакцию 15 июня 2005 г.