

Прогнозирование временных рядов на основе нейросетевых и нечетких моделей

О.И. Федяев, С.А. Гладунов, А.В. Прокофьев

Кафедра ПМИ, ДонГТУ

E-mail: fedyaev@r5.dgtu.donetsk.ua

Abstract

Fedyayev O., Gladunov S., Prokof'ev A. Prediction of time series using neural networks and fuzzy logic. It was considered a task of predicting a time series with methods, which uses neural networks and fuzzy computing. There were compared these two ways with an example of real data.

Введение

При прогнозировании или управлении сложными процессами, такими как обеспечение безопасности на производстве, техническая диагностика, предсказание чрезвычайных ситуаций и т. п., не всегда априори известна их структура. Это обусловлено неоднозначностью, неполнотой и противоречивостью знаний о поведении процессов подобного типа. С математической точки зрения речь идёт о трудно формализуемой задаче. При её решении изначально трудно выделить и учесть даже основные факторы, кардинально влияющие на развитие ситуации, на которых по сути и должен основываться научный прогноз. Отсутствие по этим причинам детерминированного правдоподобного алгоритма развития ситуации, её изначально нечёткая логика - основной отличительный признак такого рода процессов. Поэтому организация качественного прогнозирования или управления на основе стандартных и традиционных методов математического моделирования затруднительна и может рассматриваться как предварительный прогноз.

Для повышения качества прогноза требуется принципиально другой подход, основывающийся на других посылах и принципах и опирающийся на методы искусственного интеллекта, которые включают нейросетевые и нечёткие вычисления. Такой подход позволяет осуществлять конкретный прогноз развития ситуации даже в отсутствие заранее известных функциональных связей и зависимостей между различными факторами (без изначального знания модели поведения сложной системы).

Задача анализа (прогнозирования) временных рядов

Временной ряд - это упорядоченная последовательность вещественных чисел

$$X_t, \quad t = 1, 2, \dots, T,$$

представляющих собой результаты наблюдений некоторой величины. Если требуется найти зависимость между текущими и прошлыми значениями, то нужно рассматривать вектор задержки ($X_{t-1}, X_{t-2}, \dots, X_{t-n}$) в n -мерном пространстве сдвинутых во времени значений (пространстве задержки).

Цель анализа временных рядов состоит в том, чтобы извлечь из данного ряда полезную информацию. Для этого необходимо построить математическую модель явления. Такая модель должна отражать существо процесса, в частности - описывать

характер данных (случайные, имеющие тренд, периодические, стационарные и т.п.). После этого можно применять различные методы фильтрации данных (сглаживание, удаление выбросов и т.д.) с конкретной целью - предсказать будущие значения.

В работе рассматривается два подхода к решению задачи анализа временного ряда – нейросетевой и нечёткий.

Нейронные сети можно рассматривать как обобщение традиционных подходов к анализу временных рядов, основанных на статистических методах. Они дают дополнительные возможности в моделировании нелинейных явлений и описании хаотического поведения.

Нечёткий групповой метод оценки данных основан на принципах эвристической самоорганизации по данным ввода-вывода.

Метод группировки данных в обучающее множество

Для идентификации закономерностей во временной последовательности данных применялся универсальный метод, называемый методом окон - "Windowing". Основная идея его заключается в использовании двух окон W^i и W^o , имеющих фиксированные размеры n и m соответственно, для наблюдения за множеством данных, попадающих в эти окна (рис. 1).




Рисунок 1 – Метод "Windowing".

Оба окна сдвигаются вдоль оси времени с постоянным шагом Δt . Для выбранных размеров окон предполагается, что последовательность значений $W_0^i, W_1^i, \dots, W_n^i$ однозначно отображается в последовательность $W_0^o, W_1^o, \dots, W_m^o$ и эта связь (оприори неизвестная) определена на всем множестве данных. Для корреляции двух множеств значений могут быть использованы различные методы. В случае применения нейросетевых или нечетких моделей отображение $W^i \rightarrow W^o$ удобно использовать в качестве обучающего множества.

Нейросетевая модель

При построении нейросетевой модели, описывающей динамику процесса, была использована нейросеть обратного распространения (рис. 2). Этот выбор обусловлен высокими представляющими свойствами данной сети за счёт нелинейности и непрерывности функции активации у образующих её нейронов [1].




Рисунок 2 – Схема прогнозирующая с помощью трёхслойной нейросети.

При построении модели использовался следующий нейроалгоритм:

- входной сигнал сети - вектор X , представляющий собой содержимое входного окна W^1 ;
- выходной сигнал - значение Y , формируемое сетью как результат прогнозирования;
- желаемый выходной сигнал - значение временного ряда, взятое из выходного окна W^0 ;
- структура нейросети - многослойная с полными последовательными связями; модель нейрона использует сигмоидальную функцию активации:

$$f(g) = \frac{1}{1 + e^{-g}};$$

- функция ошибки нейросети - отклонение реального выходного сигнала от желаемого;
- критерий качества обучения - минимум ошибки прогнозирования на всем обучающем множестве;
- весовые коэффициенты - матрицы и вектор вещественных чисел в скрытых и выходном слоях соответственно.

Настройка нейросети осуществлялась по стратегии "обучение с учителем" с применением процедуры обратного распространения ошибки (Back propagation).

Нечеткая модель

Построение другой эффективной модели, способной адаптироваться к процессу, возможно на основе нечётких вычислений. В работе для этого был использован групповой метод оценки данных (ГМОД) [2].

Суть ГМОД заключается в построении модели, ставящей в соответствие входному вектору информации о процессе интервал, характеризующий наиболее вероятную область значения прогнозируемой величины. В общем виде групповую модель можно описать формулой:

$$Y = \sum_{i=0}^k A_i * \prod_{j=1}^n X_j^{n_j} \quad (1),$$

где Y - выходной интервал;

A_i - набор интервальных коэффициентов;

X_j - вектор входных параметров;

p_{ij} - степень, с которой X_j входит в i -е слагаемое.

Как видно из формулы (1), задача построения такой модели сводится к нахождению коэффициентов A_i и степеней p_{ij} . Для этого использовался следующий алгоритм:

Шаг 1. Все данные о прогнозируемом процессе представляются в виде совокупности обучающих пар (x_i, y_i) , $i = 1, 2, \dots, n$, где $x_i = \{x_{ij}\}$, $j = 1, 2, \dots, m$ - набор данных о состоянии процесса в i -й момент времени, y_i - соответствующее значение прогнозируемой величины.

Шаг 2. Разбиение множества данных на подготовительные данные (ПД) и контрольные данные (КД) следующим образом: каждая третья пара (x_i, y_i) , а также последняя относятся к КД, остальные - к ПД.

Шаг 3. Построение частичных представлений для каждой пары столбцов ПД x_p, x_q , $p=1, 2, \dots, m, q=1, 2, \dots, m, p \neq q$. Частное представление строится по формуле

$$Y_k = A_{0k} + A_{1k}x_p + A_{2k}x_q + A_{3k}x_p^2 + A_{4k}x_q^2 + A_{5k}x_px_q \quad (2),$$

$$k=1, 2, \dots, \frac{m(m-1)}{2}.$$

Здесь Y_k - набор интервалов попадания прогнозируемой величины. При этом коэффициенты A_{ik} находятся симплексным методом из следующих условий:

- ширина выходных интервалов должна быть минимальна;
- y_i из ПД должны принадлежать интервалам Y_k .

Шаг 4. Вычисляется матрица промежуточных переменных:

$$z_k = a_{0k} + a_{1k}x_p + a_{2k}x_q + a_{3k}x_p^2 + a_{4k}x_q^2 + a_{5k}x_px_q, \quad (3)$$

где a_{ik} - середины соответствующих интервальных коэффициентов k -го частичного представления.

Шаг 5. Для каждого частного представления с использованием КД вычисляется критерий

$$J_k = \frac{\sum_{i=1}^{N_1} J_{ik}^{(2)}}{\sum_{i=1}^{N_2} J_{ik}^{(1)}} \quad (4),$$

$$J_{ik}^{(1)} = \mu_{Y_k}(y_i) \quad (5),$$

$$J_{ik}^{(2)} = c_{0k} + c_{1k}|x_p| + c_{2k}|x_q| + c_{3k}|x_p^2| + c_{4k}|x_q^2| + c_{5k}|x_px_q| \quad (6),$$

где N_2 - количество пар контрольных данных;

μ_{Y_k} - функция принадлежности Y_{ik} , определяемая как равнобедренный треугольник с основанием, совпадающим с интервалом, и высотой, равной 1;

Y_{ik} - выходной интервал k -го частичного представления, вычисленный по i -й строке КД;

y_i - значение прогнозной переменной из КД;

x_p, x_q - p -й и q -й столбцы КД;

c_{ij} - половина ширины i -го интервала k -го частичного представления.

После вычисления J_k нужно найти пороговое значение

$$\theta = \min_k J_k.$$

Вычисленный порог сравнивается с порогом предыдущего цикла алгоритма. Если он перестал уменьшаться - переходим на шаг 7, иначе - на шаг 6.

Шаг 6. Среди промежуточных переменных выбирают m векторов z (формула (3)) с минимальными значениями критерия. Полученная матрица заменяет матрицу информации о процессе из ПД, после чего переходим на шаг 3.

Шаг 7. В наилучшее частное представление с минимальным значением критерия производится обратная подстановка переменных по формуле (3) с возвратом до самого первого цикла алгоритма, получая таким образом модель в виде формулы (1).

Анализ результатов

Анализ эффективности прогнозирования производился на примере предсказания концентрации метана в 20-й лаве шахты № 8 “Великомостовская-Комсомольская” [3]. Для моделирования были использованы реальные данные об изменении концентрации метана в течение двух суток (рис. 3). Значения концентрации метана в первые 36 часов (72 измерения) использовались для обучения, а оставшиеся реальные значения (12 измерений) – для оценки достоверности прогноза.




Рисунок 3 - Изменение концентрации метана в 20-й лаве шахты № 8 “Великомостовская-Комсомольская”.

Результаты нейросетевого прогнозирования представлены на рис. 4. Показано влияние размера входного окна W^1 на качество многошагового прогноза. С этой целью проведено 5 экспериментов на нейросетевой модели, обученной при следующих




Рисунок 4 - Результаты нейросетевого прогнозирования концентрации метана при различных размерах входного окна: — реальный процесс; — прогноза; а) окно из 10 значений; б) окно из 20 значений в) окно из 30 значений.

размерах входного окна: 5, 10, 20, 30 и 40 измерений. Наилучший прогноз получен на обучающем множестве, сформированном окном из 10 значений. В проведенных экспериментах применялась трёхслойная нейросеть.

Важными показателями нейросетевого моделирования служат представляемость и обучаемость нейросети. Для оценки обучаемости определялась зависимость количества итераций, необходимого для наилучшего обучения сети, от размеров входного окна. Результаты приведены в таблице 1:

Таблица 1. Сравнение различных размеров входного окна.

Размер окна	Количество итераций	Достигнутая ошибка обучения
10	2000	0,06
20	1800	0,07
30	1600	0,16
40	1200	0,09

Ошибка обучения представляет собой максимальное отклонение модельного значения концентрации метана от реального на всем обучающем множестве. При обучении сети по данным входного окна из 5 значений стабильность не была достигнута. Результаты экспериментов показали, что наилучший результат как при обучении, так и при прогнозировании даёт моделирование с использованием входного окна, содержащего 10 значений. Эти параметры входного окна были использованы при определении оптимального количества слоёв сети. Рассматривались двух, трёх и четырёхслойная сети. В первом случае ошибка обучения составила 0,08%, во втором - 0,06% и в третьем - 0,09% концентрации метана. Полученные при этом прогнозы отличались друг от друга незначительно, но наиболее близок к реальному процессу прогноз, полученный на трёхслойной сети.

Заключение

Результаты работы показали, что нейросетевой подход может быть эффективно использован для прогнозирования сложных временных зависимостей. Фактически, обученная нейросеть представляет собой адаптируемую модель сложного процесса, пригодную для управления его поведением.

Разработанные программные модели нейросетей и алгоритмы их обучения в дальнейшем будут использованы для построения систем управления сложными процессами, не имеющими формального описания.

Литература

1. Уоссермен Ф. Нейрокомпьютерная техника. Теория и практика. -М.: Мир, 1992. – 240 с.
2. Ивахненко А.Г. Самообучающиеся системы распознавания и автоматического управления.- Киев: Техника, 1969. – 392 с.
3. Тянь Р.Б., Потёмкин В.Я. Управление проветриванием шахт. – Киев: Наукова думка, 1977. – 204 с.