

УДК 681.51.015

А.Ф. Лановой

Харьковский национальный университет внутренних дел, Харьков

ОБ ОДНОМ ПОДХОДЕ К ПОСТРОЕНИЮ ПРОГНОЗИРУЮЩИХ МОДЕЛЕЙ ВРЕМЕННЫХ РЯДОВ ПОКАЗАТЕЛЕЙ ПРЕСТУПНОСТИ

В статье рассматриваются методологические вопросы процессов моделирования и прогнозирования с использованием нейросетевого подхода к прогнозированию преступности.

Ключевые слова: нейросетевой подход, моделирование и прогнозирование уровня преступности

Введение

Постановка проблемы. Процесс прогнозирования является ключевым моментом при принятии решений в управлении деятельностью правоохранительных органов. Для построения такого прогноза необходимо осуществить детальный анализ временных рядов соответствующих показателей преступности с целью выявления сложившихся тенденций и построения моделей изучаемых процессов. Простейшими средствами такого анализа являются статистические методы кластерного и регрессионного анализа. Однако математические модели, построенные с использованием данных методов, являются линейными, что существенно сужает их применение в реальных системах.

В связи с этим, на первое место выходит новое поколение методов, включающих нейросетевые и генетические алгоритмы, которые позволяют анализировать и прогнозировать нелинейные временные ряды.

Актуальность исследований. Применение нейронных сетей (НС) для прогнозирования временных рядов основано на способности НС аппроксимировать нелинейные функции. При этом обработка нейронной сетью входных данных может осуществляться как для отдельных данных, так и для набора данных, описывающих предысторию процесса. Обозначая входную информацию в момент времени k через $y[k]$ (при этом y может быть вектором), функционирование выделенных видов НС может быть описано соотношениями

$$y[k+1] = NN(y[k]) \text{ и}$$

$$y[k+1] = NN(y[k], y[k-1], \dots, y[k-l]), \quad (1)$$

где функция $NN()$ характеризует структуру нейросетевого предиктора, а l – объем предыстории наблюдений.

Такой подход позволяет использовать авторегрессионные модели для прогнозирования нелинейных временных рядов, что позволяет эффективно использовать существующий аппарат нейронных сетей.

Целью работы является разработка методики построения комплекса прогнозирующих математических моделей временных рядов с использованием нейронных сетей.

Основной материал

1. Схема прогнозирования временных рядов с использованием нейронных сетей. Представим нейронную сеть как многослойную структуру, в которой входной слой нейронов связан с выходным через один или более промежуточных слоев. Процесс обучения нейронных сетей заключается в настройке весовых коэффициентов обеспечивающих реализацию связи между входом и выходом. Большинство адаптивных обучающих алгоритмов основано на процедуре обратного распространения.

Нейросетевая прогнозирующая модель может быть представлена в следующем виде

$$\begin{aligned} y[k+1] = NN(y[k], y[k-1], \dots, \\ y[k-i], e[k], e[k-1], \dots, e[k-d]), \end{aligned} \quad (2)$$

где y является соответствующим наблюдением, а $e[k], \dots, e[k-d]$ – набором остатков.

Процесс построения прогнозирующей модели невозможен без определения количества используемых элементов временного ряда y и ошибок прогнозирования e .

Рассмотрим схему прогнозирования временных рядов с использованием нейронных сетей обратного распространения. Такая схема включает три этапа: определение объема предыстории для входных последовательностей; определение количества нейронов в скрытом слое (слоях); построение нейросетевой прогнозирующей модели.

Рассмотрим предлагаемую схему подробнее.

2. Выделение входных последовательностей.

Выделение входных последовательностей (обучающих выборок) осуществляется с использованием автокорреляционного анализа и осуществляется в два этапа:

Этап 1. Для заданных временных рядов показателей преступности вычисляются автокорреляционные функции. Если ряд содержит тренд, то последний должен быть исключен путем взятия последовательных разностей. Дифференцирование уменьшает коррелированность: если автокорреляции исходного ряда строго положительны, то (несезонное дискретное) дифференцирование уменьшает их или даже делает отрицательными. Повторное дифференцирование еще уменьшает автокорреляции.

Для временного ряда, записанного в виде $y_i, i = 1, 2, \dots$, коэффициент автокорреляции для оцениваемых значений выборки вычисляется как

$$r_k = \frac{\sum_{i=1}^{n-k} (y_{i+k} - \bar{y}_{i+k})(y_i - \bar{y}_i)}{[\sum_{i=1}^n (y_i - \bar{y}_i)^2]^{1/2} [\sum_{i=1}^{n-k} (y_{i+k} - \bar{y}_{i+k})^2]^{1/2}}, \quad (3)$$

где r_k описывает автокорреляцию между наблюдениями y_i и y_{i+k} . Автокорреляции для различных выборок следуют закону распределения значений вокруг k , такой закон называется выборочным распределением автокорреляций. Выборочное распределение коэффициентов автокорреляции подчинено нормальному закону распределения с математическим ожиданием и дисперсией (соответственно):

$$\mu_{r_k} = 0; \quad (4)$$

$$\sigma_{r_k} = 1/n^{1/2}. \quad (5)$$

Вычисленные на этом этапе значения автокорреляционных коэффициентов определяют лаги остатков, которые используются при краткосрочном прогнозировании.

Этап 2. Вычисляются частные автокорреляционные коэффициенты, которые показывают как $u[i]$ автокоррелирует с $y[i+k]$.

Автокорреляционная функция, АКФ, вычисляется как последовательность корреляций между рядом и им же, сдвинутым на 1, 2, ... временных точек *лагов*. Автокорреляция при лаге 1 есть коэффициент корреляции между $y[i]$ и $y[i-1]$, который равняется коэффициенту корреляции между $y[i-1]$ и $y[i-2]$. (Собственно, это свойство и позволяет говорить об автокорреляционной функции и вычислять ее значения описанным образом.) Однако, если коррелированы $y[i]$ и $y[i-1]$, а также $y[i-1]$ и $y[i-2]$, то естественно думать, что $y[i]$ и $y[i-2]$ также коррелированы. Таким образом, автокорреляция при лаге 1 «вызывает» автокорреляцию при лаге 2, а, соответственно, и при больших лагах. Потому-то и оказывается полезной частная автокорреляционная функция, ЧАКФ. Ее значение при лаге 1 совпадает с обычной автокорреляцией, отличия начинаются с лага 2. Значение ЧАКФ при лаге 2 равняется корреляции рядов $y[i]$ и $y[i-2]$, причем считается исключенной их корреляция с рядом $y[i-1]$. Аналогично, ЧАКФ при лаге 3 равняется корреляции рядов $y[i]$ и $y[i-3]$, причем считается исключенной их корреляция с рядами $y[i-1]$ и $y[i-2]$.

Обозначим оценки коэффициентов частных автокорреляционных функций для авторегрессионной модели порядка m как $\rho_1, \rho_2, \dots, \rho_m$. Данные оценки могут быть получены путем решения системы уравнений:

$$y[k] = \rho_1 y[k-1] + e[k]; \quad (6)$$

$$y[k] = \rho_1 y[k-1] + \rho_2 y[k-2] + e[k]; \quad (7)$$

$$y[k] = \rho_1 y[k-1] + \dots + \rho_{m-1} y[k-m+1] + \rho_m y[k-m] + e[k]. \quad (8)$$

При рассматриваемом подходе частная автокорреляционная функция должна обрываться после l значений. Критерием обрыва функции является выполнение нестрогого равенства $\rho_{ll} \cong 1/\sqrt{n}$, $l \geq p+1$.

3. Определение количества нейронов в скрытом слое (слоях). Количество нейронов в скрытом слое вычисляется по формуле

$$N_{\text{нейронов}} \leq \frac{N_{\text{обуч}} E_{\text{толер}}}{N_{\text{выборки}} + N_{\text{выход}}}, \quad (9)$$

где $N_{\text{нейронов}}$ – количество нейронов в скрытом слое (слоях); $N_{\text{обуч}}$ – число обучающих выборок; $E_{\text{толер}}$ – ошибка толерантности; $N_{\text{выборки}}$ – количество элементов обучающей выборки; $N_{\text{выход}}$ – количество выходных нейронов.

4. Построение нейросетевой прогнозирующей модели. На основе рассчитанного входного образа (процедура определения входных образов рассмотрена в п. 2.1) и определенного количества нейронов в скрытом слое (процедура определения количества нейронов рассмотрена в п. 2.2) мы можем построить нейросетевую прогнозирующую модель. В зависимости от величины интервала упреждения различают краткосрочное и долгосрочное прогнозирование.

Под краткосрочным понимается такой процесс прогнозирования, при котором нейросетевая модель позволяет получить прогноз только на один шаг вперед. Для построения прогнозирующих моделей данного вида могут быть использованы ряды конечных разностей, задаваемые оператором сдвига назад z^{-1} ($z^{-1}y[k] = y[k-1]$). Нейросетевой предиктор, использующий определенные на предыдущих этапах входные образы и количество нейронов в скрытом слое(ях) и реализующий задачу краткосрочного прогнозирования представлен на рис. 1.

Данная структура отличается от других нейросетевых структур тем, что в качестве входных значений использует также и остатки. Структура использует статистические прогнозирующие модели авторегрессии проинтегрированного скользящего среднего (ARIMA), которые используют для нахождения прогнозируемого значения предысторию наблюдаемых значений и разности между этими значениями и соответствующими им прогнозами.

Долгосрочное прогнозирование предназначено для определения основного тренда и главных точек изменения тренда для некоторого промежутка времени в будущем. При этом прогнозирующая система использует полученные (выходные) данные для моментов времени $k+1$, $k+2$ и т.д. в качестве входных данных для прогнозирования на моменты времени $k+2$, $k+3$ и т.д. Обучение предиктора для долгосрочного прогнозирования не использует разности между реальными и прогнозируемыми значениями (ввиду отсутствия ре-




Рис. 1. Нейросетевая прогнозирующая модель для краткосрочного прогнозирования

альных значений), что является существенным отличием данного вида прогнозирующих моделей от моделей краткосрочного прогнозирования.

Выводы

Существующие в настоящее время методы проверки качества прогноза достаточно формальны и в большинстве своем могут использоваться только тогда, когда ныне прогнозируемый период становится прошедшим. Поэтому желательно использовать методы, которые позволяют определить качество прогноза в текущих условиях или хотя бы сопоставляют качество отдельных прогнозов. Именно эти задачи можно решить с использованием нейросетевых и генетических алгоритмов, которые позволяют анализи-

ровать и прогнозировать нелинейные временные ряды. И все-таки, конкретный процесс прогнозирования вступает в действие только после проведенного всестороннего анализа собранной информации и обработки экспертных оценок. Естественно, это итеративный процесс, включающий в себя формальные и интеллектуальные методы, постоянно подвергаемый коррекции в связи с появлением новой информации. Только таким достаточно сложным путем можно решить проблемы, связанные с прогнозированием и мониторингом такого комплексного явления, как прогнозирование преступности.

Список литературы

1. Бокс Дж., Дженкинс Г. Анализ временных рядов. Прогноз и управление. – М.: Мир, 1971. – Вып. 1. – 406 с.
2. Теория прогнозирования и принятия решений / Под ред. С.А. Саркисяна. – М.: Высшая школа, 1977. – 352 с.
3. Яковлев С.В., Гнусов Ю.В. Математические методы оценки состояния и прогнозирования преступности. – Х.: Ун-т внутр. дел, 1998. – 158 с.
4. Лановой А.Ф. Некоторые аспекты построения имитационных моделей сложных систем // Системи обробки інформації. – Х.: ХУ ПС, 2006. – Вып. 1 (50). – С. 99-106.

Поступила в редколлегию 15.07.2008

Рецензент: д-р физ.-мат. наук, проф. С.В. Смеляков, Харьковский университет Воздушных Сил им. И. Кожедуба, Харьков.

ПРО ОДИН ПІДХІД ДО ПОБУДОВИ ПРОГНОЗУЮЧИХ МОДЕЛЕЙ ЧАСОВИХ РЯДІВ ПОКАЗНИКІВ ЗЛОЧИННОСТІ

О.Ф. Лановий

У статті розглядаються методологічні питання процесів моделювання та прогнозування з використанням нейромережевого підходу до прогнозування злочинності.

Ключові слова: нейромережевий похід, моделювання і прогнозування рівня злочинності

ABOUT ONE APPROACH TO BUILD-UP OF FORECASTING MODELS OF TIME SERIES OF INDEXES OF CRIMINALITY

O.F. Lanovoj

In paper the methodological problems of processes of simulation and prediction with usage neural network for prediction of criminality are considered.

Keywords: neural network campaign, modelling and prediction of a crime rate.