

---

# Сети телекоммуникаций

УДК 004.732, 519.876

## Математические модели временных рядов интенсивностей трафика сети при различных подходах к их построению

А. А. Габдрахманов\*, Н. Т. Габдрахманова†

\* ЗАО «Самара-Транстелеком»

† Российский университет дружбы народов  
ул. Миклухо-Маклая, 6, Москва, 117198, Россия

В статье исследуется возможность применения механизмов искусственных нейронных сетей и авторегрессионного анализа для построения прогнозирующих математических моделей загруженности канала пакетной передачи данных. Задача решена на примере временного ряда наблюдений интенсивностей на порту пограничного коммутатора. Приведён алгоритм построения авторегрессионной модели на основе статистического анализа временного ряда наблюдений. Приведён алгоритм построения нейросетевой модели на основе определения фрактальной размерности временного ряда. Построенные модели сравнены по расчётным значениям введённых критериев оценки точности прогноза.

**Ключевые слова:** нелинейная динамика, теорема Такенса, нейронные сети, временные ряды, трафик сети Gigabit Ethernet.

### 1. Введение

В настоящее время существует два качественно различных подхода к исследованию временных рядов: статистические и динамические. В статье приводятся алгоритмы и основные результаты построения математических моделей с использованием этих двух подходов, а также сравнительный анализ способностей моделей к построению прогноза на несколько шагов упреждения.

Целью работы является получение обоснованного вывода по выбору подхода к построению математической модели в рассматриваемой прикладной области.

Актуальность работы определяется следующим. Непрерывно развивающаяся сфера телекоммуникационных услуг и сети Интернет предъявляет новые требования к пропускной способности каналов передачи данных. Существование огромного количества разнородных сервисов в одном физическом канале в часы наивысшей нагрузки могут приводить к перегрузке коммутирующих и маршрутизирующих устройств на магистральных линиях связи и, как следствие, к массовому отказу спектра услуг. Для предотвращения ситуаций, ведущих к отказу магистрального сетевого оборудования, и для оптимизации использования сетевых ресурсов наиболее значимой становится задача грамотного использования ширины полосы пропускания канала передачи данных (за исключением случая увеличения ширины полосы пропускания канала, что заведомо приведёт к увеличению стоимости услуг). Необходимо применять разумные эффективные методы управления трафиком и контроля загруженности, которые бы основывались на данных, предоставляемых, например, инструментом прогнозирования интенсивностей трафика на основе предыдущих значений. Существует множество публикаций по построению математических моделей трафика сети [1, 2]. Однако в настоящее время эти работы пока не нашли широкого практического применения.

В работе в качестве примера взят пограничный коммутатор 2-го уровня организации, ориентированной на предоставление услуг магистральной связи. Трафик, поступающий на каждый порт устройства, представляет собой суммированный трафик от групп клиентов определённого района. Структурная схема проведения измерений приведена на рис. 1. Статистика снята при помощи программы

---

Статья поступила в редакцию 1 ноября 2011 г.

Работа выполнена при финансовой поддержке РФФИ, проект 10-01-00381-а.

Sacti, протокол SNMP-Interface statistic. Для практических целей более полезной является информация о степени загруженности сети. Информация о количестве пакетов в единицу времени может вводить в заблуждение. Поэтому в качестве наблюдаемой переменной выбрано агрегированное значение  $x(t)$  – интенсивность трафика (бит) в момент  $t$ . Длительность данных составляет 10080 точек или 7 суток. График интенсивностей, измеренных на порту GE 0, приведён на рис. 2. Каждая точка на этом графике представляет собой количество бит информации, переданной в магистральном канале за интервал времени в 1 минуту.

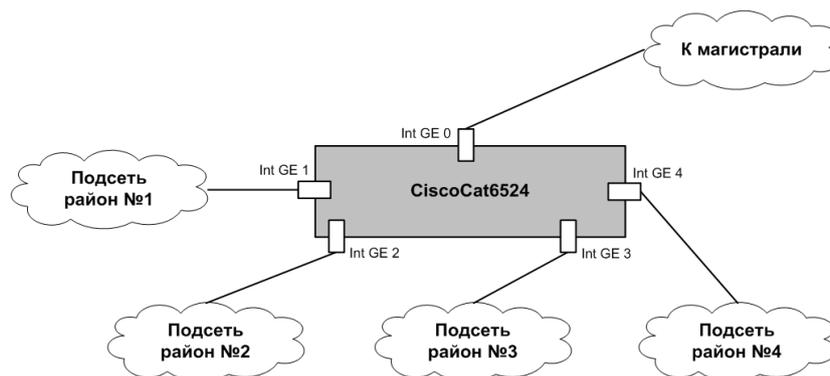


Рис. 1. Схема проведения измерений

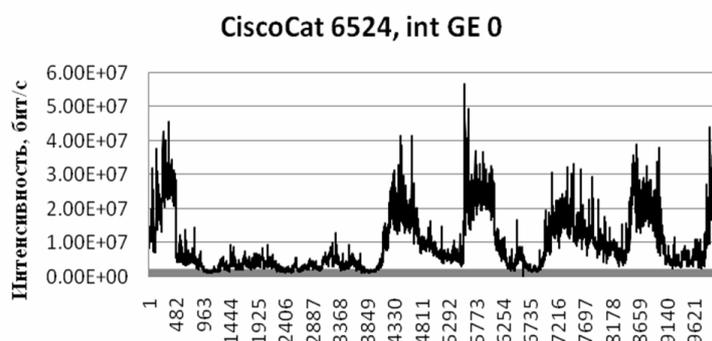


Рис. 2. График интенсивностей трафика на порту GE 0

Необходимо по данным наблюдений  $\{x(t), t = 1, 2, \dots, N\}$ , где  $N$  – число точек наблюдения, решить задачу идентификации временного ряда и построить прогноз на  $m$  шагов упреждения.

## 2. Выбор и обоснование авторегрессионной модели временных рядов интенсивностей трафика сети

Авторегрессионные модели используют статистический подход. В статистических методах обработки используется допущение, что всегда имеется шум. Поэтому априори полагается, что изучаемый ряд – стохастический. Визуальный анализ гистограммы распределения (рис.3) интенсивностей показывает, что в сети преобладают интенсивности от 0 до  $5 \cdot 10^8$  бит в минуту. Предварительный анализ

временного ряда показывает, что он имеет нестационарность в виде тренда и сезонную составляющую. В данных ярко выражена сезонная составляющая, связанная с суточной периодичностью интенсивности (см. рис.2). Исследования графика интенсивности месячного трафика показали, что наблюдается также устойчивая сезонная составляющая с недельным периодом. Однако в целом тренд неоднороден, так как в нем присутствуют участки с разной скоростью роста и даже спада. Нестационарные данные, характеризующие функционирование системы связи, рационально моделировать процессами авторегрессии проинтегрированного скользящего среднего (АРПСС) [3,4] или их модификациями ARCH и GARCH.

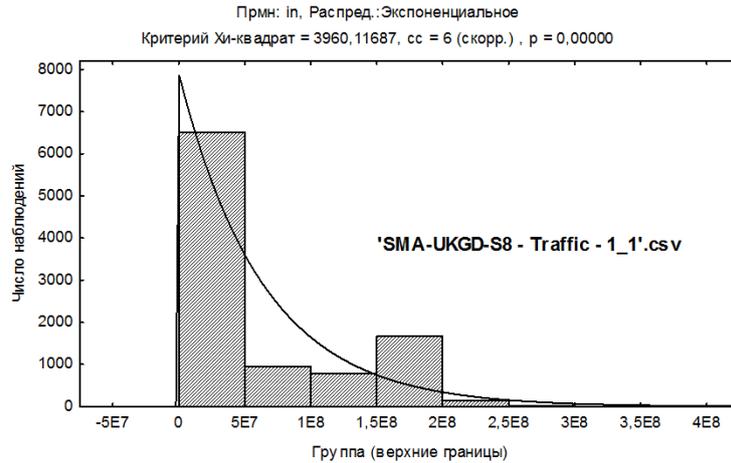


Рис. 3. Гистограмма битовой интенсивности исходного ряда наблюдений

Внутрисуточные колебания интенсивности приводят к тому, что корреляционная функция процесса описывает в основном сезонные колебания и тренд. Для получения модели стационарного процесса необходимо вначале устранить тренд и сезонные колебания.

Введём следующие операторы.

Операторы сдвига по времени:

$$F_-x(t) = x(t - 1); \quad F_+x(t) = x(t + 1);$$

$\Delta$  — оператор последовательной разности:

$$\Delta x(t) = (1 - F_-)x(t) = x(t) - x(t - 1);$$

$\nabla_T$  — упрощающий оператор взятия разности:

$$\nabla_T = 1 - F_-^T; \quad \nabla_T x(t) = (1 - F_-^T)x(t) = x(t) - x(t - T).$$

Для исключения сезонной составляющей применяется упрощающий оператор взятия разности. Так как прогнозируемые данные представляют собой значения интенсивности за каждую минуту, то для исключения внутрисуточных колебаний нужно выбрать  $T = 1440$ , т.е. сдвиг равный количеству отсчётов за одни сутки. После действия оператором  $\nabla_T$  на исходный процесс

$$\omega_1(t) = \nabla_T x(t) = x(t) - x(t - 1440) \quad (1)$$

получается новый случайный процесс  $\omega_1(t)$  без внутрисуточных колебаний. Для устранения тренда используется метод, применяемый для синтеза нестационарных моделей АРПСС [3], основанный на применении к случайным процессам с

трендом оператора взятия разности

$$\omega(t) = \Delta^d x(t), \quad (2)$$

где  $d$  — порядок стационарных приращений процесса.

Для линейного тренда  $d = 1$ , а для квадратичного необходимо брать  $d = 2$ :  $\Delta^2 x(t) = \Delta x(t) - \Delta x(t - 1)$ .

Заметим, что для нестационарных процессов с произвольным законом изменения тренда применение этого метода даёт существенные погрешности прогноза. Для линейных участков тренда из (1) с учётом (2) получаем при  $d = 1$

$$\omega_2(t) = \nabla \omega_1(t) = \omega_1(t) - \omega_1(t - 1). \quad (3)$$

Исключение из нестационарного процесса сезонной составляющей и тренда позволяет синтезировать модели линейного предсказания стационарного процесса. Однако исследования преобразованного ряда по формулам (2), (3) показали, что в ряде малые и большие значения группируются целыми кластерами или сериями. Причём это не приводит к нарушению их стационарности и, в частности, их гомоскедастичности для относительно больших временных интервалов, т.е. гипотеза о том, что дисперсия  $D(x(t)) = \text{const}$  не противоречит экспериментальным данным. Однако в рамках моделей АРПСС удовлетворительно объяснить процесс не удалось. Для увеличения точности прогнозирования предлагается использовать двухуровневый алгоритм построения моделей. На первом уровне разбить всё пространство на подобласти, где временной ряд является стационарным относительно математического ожидания и дисперсии. На втором уровне построить в каждой подобласти локальные АРПСС модели.

При решении задачи построены следующие кластеры: кластер 1 — с 0.00 ч. — до 08.00 ч.; кластер 2 — с 08.00 ч. до 10.00 ч.; кластер 3 — с 10.00 ч. 19.00ч.; кластер 4 — с 19.00 до 24.00ч. По данным каждого кластера построены модели АРПСС (1,1,1). Математические модели в общем виде имеют следующий вид:

$$(1 - \alpha F_-)(1 - F_-)\omega_1(t)(1 - \beta F_-)\delta(t), \quad (4)$$

$(1 - \alpha F_-)\Delta\omega_1(t) = (1 - \beta F_-)\delta(t)$ , где  $\delta(t)$  — элементы нормального белого шума,  $\alpha$  — параметр авторегрессии,  $\beta$  — параметр скользящего среднего.

Для временного исключения из анализируемого ряда  $x(t)$  сезонной составляющей, имеющий период  $T$ , в левую часть АРПСС (1, 1, 1) — модели, представленной уравнением (4), мультипликативно вводится упрощающий оператор  $\nabla_T = 1 - F_-^T$ , а в правую часть — упрощающий оператор вида  $1 - \theta^* F_-^T$ .

Уравнение модели имеет вид

$$(1 - \alpha F_-)\Delta\nabla_T x(t) = (1 - \beta F_-)(1 - \theta^* F_-^T)\delta(t). \quad (5)$$

Такие модели называются мультипликативными.

Для всех четырёх кластеров построены мультипликативные модели. Диагностическая проверка (анализ остатков в описании реального ряда  $x(t)$  с помощью построенной модели) полученных моделей позволяет сделать вывод об адекватности построенных моделей временного ряда.

Для оценки пригодности модели к построению прогноза используются вычисленные на тестовом множестве выборочные оценки математического ожидания ошибки прогноза и дисперсии

$$M(\varepsilon) = \frac{1}{N} \sum_{t=1}^N \varepsilon_t, \quad (6)$$

$$D(\varepsilon) = \frac{1}{N} \sum_{t=1}^N (\varepsilon_t - M(\varepsilon))^2, \quad (7)$$

где  $\varepsilon_t = x(t) - \hat{x}(t)$ ; среднее значение модуля относительной ошибки прогноза

$$MSE = \frac{1}{N} \sum_{t=1}^N \left| \frac{x(t) - \hat{x}(t)}{x(t)} \right|, \quad (8)$$

максимальное и минимальное значения модуля относительной ошибки

$$MaxE = \max_t \left| \frac{x(t) - \hat{x}(t)}{x(t)} \right|, \quad (9)$$

$$MinE = \min_t \left| \frac{x(t) - \hat{x}(t)}{x(t)} \right|. \quad (10)$$

Тестовое множество состоит из  $m = 30$  последних точек временного ряда, не использованных при построении моделей. На рис.4 представлен график сопоставления прогнозируемых (расчётных) данных с данными натуральных наблюдений. На графике отложены по оси абсцисс – номер точки, по оси ординат – значение интенсивности трафика. Результаты верификации моделей для каждого кластера представлены в табл. 1.

Таблица 1

Результаты верификации моделей АРПСС (1, 1, 1)

АРПСС	Кластер 1	Кластер 2	Кластер 3	Кластер 4
Max E	6,66E-01	3,89E-01	1,74E-01	1,70E-01
Min E	1,30E-02	3,28E-03	2,87E-03	5,45E-03
MSE	1,21E-01	1,23E-01	5,55E-02	7,19E-02
D	0,122777	0,120128	0,044071	0,044378
M	0,01	0,004	0,005	0,003

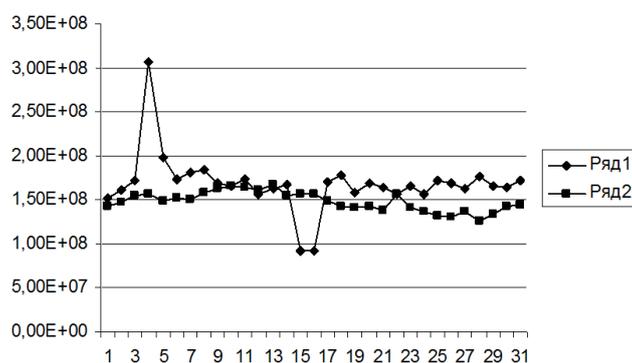


Рис. 4. График сопоставления прогнозируемых (расчётных) данных (ряд 2) с данными натуральных наблюдений (ряд 1). На графике по оси абсцисс – номер точки, по оси ординат – значение интенсивности трафика

### 3. Выбор и обоснование нейросетевой модели временных рядов интенсивностей трафика сети

В качестве параллельной модели для АРПСС построена нейросетевая модель с использованием методов нелинейной динамики. Полагается,  $\{x(t)\}_{t=1}^N$  измерения некоторой наблюдаемой скалярной компоненты  $d_1$  мерной динамической системы  $\bar{y}$ . При этом размерность и поведение динамической системы в целом неизвестны. Для заданного временного ряда необходимо построить некоторую модель, которая вобрала бы в себя рассматриваемую динамику, ответственную за генерацию наблюдений  $x(t)$ . Решаемую задачу принято называть задачей динамического восстановления.

Особенностью размерности динамической системы является то, что это одна из немногих характеристик, которую можно оценить по временному ряду. Согласно теореме Такенса [5], геометрическая структура динамики этой системы, зависящей от многих переменных, может быть восстановлена на основе наблюдений  $\{x(t)\}_{t=1}^N$  в  $D$  мерном пространстве, построенном на основе нового вектора  $\bar{z}(t) = \{x(t), x(t-1), \dots, x(t-(D-1))\}^T$ , где  $D \geq 2d_1 + 1$ . Эволюция точек  $\bar{z}(t) \rightarrow \bar{z}(t+1)$  в реконструированном пространстве соответствует эволюции точек  $\bar{y}(t) \rightarrow \bar{y}(t+1)$  в исходном пространстве. Процедура поиска подходящего  $D$  называется вложением. Минимальное число  $D$ , при котором достигается динамическое восстановление, называется измерением вложения. В работе используется алгоритм, предложенный в 1983 г. П. Грассбергом и И. Прокачиа, который позволяет по временному ряду оценить фрактальную размерность  $d_{fC}$  странного аттрактора динамической системы. Алгоритм поиска коротко описывается следующими шагами. Пусть по временному ряду построена  $m_1$ -мерная реконструкция, и в распоряжении исследователя находится набор векторов  $\bar{z}(t) = (x(t), x(t-1), \dots, x(t-(m_1-1)))$ . Задаётся некоторое число  $\delta$  и разбивается область фазового пространства на кубики со стороной  $\delta$ . Для выбранных  $m_1$  и  $\delta$  вычисляется корреляционный интеграл:

$$C(\delta) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{n=1}^N \left( \frac{1}{N-1} \sum_{k=1, k \neq n}^N \theta(\delta - \|\bar{z}(n) - \bar{z}(k)\|) \right), \quad (11)$$

где

$$\theta(r) = \begin{cases} 1, & r > 0, \\ 0, & r < 0, \end{cases}$$

$\theta(\cdot)$  — функция Хэвисайда,  $\|\cdot\|$  — какая-либо норма (в нашем случае Евклидова),  $N$  — количество точек.

$C(\delta)$  является мерой вероятности того, что две точки  $\bar{z}(n)$  и  $\bar{z}(k)$  на аттракторе находятся на расстоянии  $\delta$ . Количество  $N$  должно быть достаточно большим.

При малых  $\delta$  корреляционный интеграл  $C(\delta) \sim \delta^{d_{fC}}$  [5], поэтому корреляционную размерность  $d_{fC}$  можно определить по наклону зависимости  $\ln C(\delta)$  от  $\ln \delta$ . Другими словами, корреляционную размерность  $d_{fC}$  можно определить как

$$d_{fC} = \lim_{\delta \rightarrow 0} \frac{\ln C(\delta)}{\ln \delta}.$$

С ростом размерности вложения  $m_1$  корреляционная размерность  $d_{fC}(m)$  увеличивается. Если в рассматриваемом временном ряде есть проявление детерминированного хаоса, то, начиная с некоторого  $m_1 = m$ , величина соответствующей  $d_{fC}(m_1)$  перестает расти. Достигнутое при этом значение принимается за размерность аттрактора исходной системы  $d_f = d_{fC}(m_0)$ . Если же рост продолжается без насыщения, то это свидетельствует о том, что наблюдаемый сигнал шумовой. Конечное значение  $d_{fC}$  означает, что рассматриваемый сигнал можно воссоздать с помощью детерминированной системы. На рис.5 приведён график зависимости корреляционной размерности от размерности вложения для ряда. На графике по

оси абсцисс отложены значения вложения  $m$ , по оси ординат — значение корреляционной размерности  $d$ . Полученная кривая показывает, что фрактальная размерность временного ряда измеренных значений равна 4,53, а следовательно, размерность вложения для восстановления динамической системы  $D = 2[d_f] + 1 = 11$ .

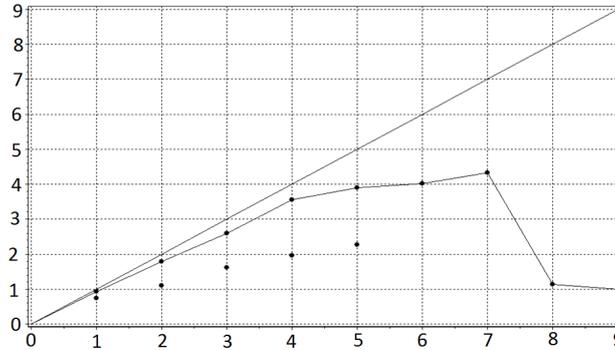


Рис. 5. Зависимость корреляционной размерности от размерности вложения для ряда

Решаемую задачу можно сформулировать следующим образом. Имеется временной ряд  $\{x(t)\}_{t=1}^N$ , заданы параметры реконструкции (в нашем случае  $D = 11$ ). Для  $N_1$  векторов  $\bar{z}(t) = \{x(t), x(t-1), \dots, x(t-(D-1))\}^T$  известны значения искомой функции:  $F(t) = F(\bar{z}(t))$  (потому что известны следующие за  $\bar{z}(t)$  члены временного ряда). Требуется найти значение искомой функции в новой точке  $\bar{z}(t)$ ,  $\hat{x} = F(\bar{z})$ . Иначе, требуется аппроксимировать неизвестную функцию  $F$  по заданным  $N_1$  точкам.

Задача динамического восстановления является плохо обусловленной обратной задачей. Может быть нарушено условие существования, для единственности восстановления нелинейной динамики может оказаться недостаточно информации, наличие шума добавляет в динамическое восстановление неопределённость. Следовательно, на модели прогнозирования должны налагаться некоторые формы ограничений. Это можно сделать использованием теории регуляризации Тихонова. В этом контексте подходящим решением для построения модели прогнозирования будет использование нейронных сетей. В нейронных сетях MLP и RBF теория регуляризации была математически включена как составная часть их конструкции.

При создании многослойного персептрона [6] строится модель физического явления, обеспечивающая обобщение примеров, использованных при обучении сети. Поскольку архитектура сети по своей природе статична, необходимо обеспечить баланс между достоверностью данных обучения и качеством самой модели. При обучении методом обратного распространения весовые коэффициенты нейросети находятся путём минимизации функционала [6]:

$$R(\bar{w}) = E_s(\bar{w}) + \lambda E_c(\bar{w}), \quad (12)$$

где  $E_s(\bar{w})$  — стандартная мера эффективности нейросети (среднеквадратическая ошибка),  $E_c(\bar{w})$  — штраф за сложность,  $\lambda$  — параметр регуляризации.

Например,

$$E_c(\bar{w}, k) = \frac{1}{2} \int \left\| \frac{\partial^k}{\partial x^k} F_{nc}(\bar{x}, \bar{w}) \right\|^2 \mu(\bar{x}) d\bar{x}, \quad (13)$$

$F_{nc}(\bar{x}, \bar{w})$  — выполняемое моделью отображение,  $\mu(\bar{x})$  — некоторая весовая функция, определяющая область входного пространства, на которой  $F_{nc}(\bar{x}, \bar{w})$  должна быть гладкой.

Искусственные НС решают задачу аппроксимации функций нескольких переменных по обучающей выборке путём погружения временного ряда в многомерное пространство. Для увеличения точности прогнозирования НС моделей предлагается использовать двухуровневый алгоритм построения моделей. На первом уровне решается задача построения в реконструированном пространстве подобластей, где возможно построение маломодовой модели. Для этого используется процедура кластеризации множества  $\{\bar{z}(t)\}_{t=1}^{N_1}$ . На втором уровне в каждой подобласти осуществляется построение локальных нейросетевых моделей.

Для рассматриваемого примера построено два кластера. Для каждого кластера построены нейросетевые модели. Тип нейросети — многослойный персептрон. Для построенных моделей на тестовом множестве вычислены по формулам (8)–(10) значения введённых критериев:

$$MSE = 0,011600969, \quad MaxE = 0,573175783, \quad MinE = 0,08769853.$$

На рис.6 представлен график сопоставления прогнозируемых (расчётных) данных с данными натуральных наблюдений. На графике отложены по оси абсцисс — номер точки, по оси ординат — нормированное значение интенсивности трафика.

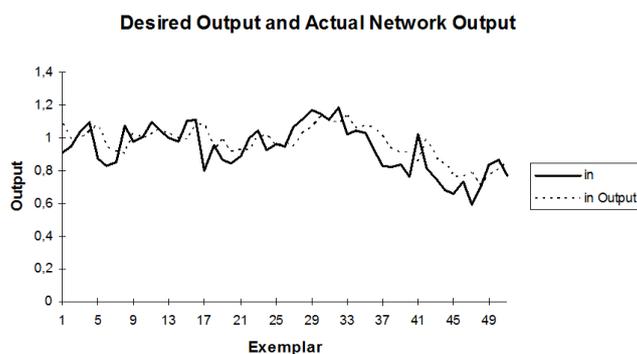


Рис. 6. График прогнозируемых (расчётных) данных (in Output) с данными натуральных наблюдений (in)

Для возможности сравнения авторегрессионных и нейросетевых моделей построение НС моделей осуществлялось также для каждого кластера, полученного разбиением по первому способу. Диагностическая проверка (анализ остатков в описании реального ряда  $x(t)$  с помощью построенной модели) полученных моделей подтвердила правильность моделей. Результаты верификации моделей для каждого кластера представлены в табл. 2. Верификация осуществлена также как и для АРПСС моделей. Результаты вычислений значений введённых критериев для каждого кластера приведены в табл. 2. В табл. 3 приведены реальные значения  $x(t)$ , модельные прогнозные значения  $\hat{x}(t)$ , модули абсолютных  $|\varepsilon_t| = |x(t) - \hat{x}(t)|$  и относительных  $\varepsilon_{\text{отн}}(t) = \left| \frac{x(t) - \hat{x}(t)}{x(t)} \right|$  ошибок прогноза.

Сравнение вычисленных значений введённых критериев для оценки прогностических свойств моделей свидетельствует о том, что НС наиболее пригодны для решения поставленной задачи.

#### 4. Выводы

1. Проведён статистический анализ реальных данных функционирующей сети.
2. На основе результатов статистического анализа данных проведено обоснование и выбор математической модели линейного предсказания для адекватного

Таблица 2

Результаты верификации нейросетевых моделей

НС	Кластер 1	Кластер 2	Кластер 3	Кластер 4
Max E	1,37E-01	3,51E-01	1,58E-01	1,19E-01
Min E	8,19E-04	4,78E-04	1,53E-03	1,89E-03
MSE	4,73E-02	1,26E-01	4,30E-02	4,79E-02
D	0,022777	0,050128	0,0044071	0,0044378
M	0,001	0,004	0,005	0,0003

Таблица 3

Фрагмент вычислений прогнозных значений нейросетевой моделью

$\underline{n}$	$t$	$x(t)$	$\hat{x}(t)$	$ \varepsilon(t) $	$ \varepsilon_{\text{отн}}(t) $	$ \varepsilon_{\text{отн}}(t)  * 100\%$
<u>1</u>	5,01	1,78E+07	1,69E+07	896362,5	5,02E-02	5%
<u>2</u>	5,02	1,82E+07	1,70E+07	1184912	6,51E-02	7%
<u>3</u>	5,03	1,75E+07	1,72E+07	325032,4	1,86E-02	2%
<u>4</u>	5,04	1,69E+07	1,70E+07	177761,2	1,05E-02	1%
<u>5</u>	5,05	1,77E+07	1,69E+07	728532,1	4,13E-02	4%
<u>6</u>	5,06	1,81E+07	1,70E+07	1067601	5,91E-02	6%
<u>7</u>	5,07	1,70E+07	1,71E+07	124981	7,36E-03	1%
<u>8</u>	5,08	1,65E+07	1,70E+07	436779,1	2,64E-02	3%
<u>9</u>	5,09	1,70E+07	1,69E+07	112739,1	6,65E-03	1%
<u>10</u>	5,1	1,72E+07	1,68E+07	427219,7	2,48E-02	2%
<u>11</u>	5,11	1,81E+07	1,69E+07	1248611	6,89E-02	7%
<u>12</u>	5,12	1,66E+07	1,70E+07	391387,7	2,35E-02	2%
<u>13</u>	5,13	1,55E+07	1,69E+07	1329873	8,55E-02	9%
<u>14</u>	5,14	1,60E+07	1,66E+07	559059,7	3,49E-02	3%
<u>15</u>	5,15	1,57E+07	1,65E+07	794942,4	5,07E-02	5%
<u>16</u>	5,16	1,91E+07	1,65E+07	2625073	1,37E-01	10%
<u>17</u>	5,17	1,58E+07	1,70E+07	1161766	7,33E-02	7%
<u>18</u>	5,18	1,56E+07	1,67E+07	1085970	6,96E-02	7%
<u>19</u>	5,19	1,61E+07	1,65E+07	375116,4	2,33E-02	2%
<u>20</u>	5,2	1,60E+07	1,63E+07	316829,6	1,98E-02	2%

описания реальных данных и прогнозирования процессов функционирующей сети.

3. На основе анализа временного ряда как наблюдаемая нелинейной динамической системы проведено обоснование и построение нейросетевой прогнозной модели.

4. Получены положительные результаты по прогнозированию трафика сети с помощью АРПСС и НС моделей, которые могут быть использованы для эффективного управления и оптимизации ресурсов в процессе функционирования сети.

5. Сравнение результатов прогнозирования по моделям с различными подходами свидетельствует о преимуществах динамического подхода к моделированию с использованием нейросетевых технологий. Вывод делается на основе вычислений и сравнений значений введённых критериев.

6. Структура сети очень быстро изменяется, и статистические методы в некоторых случаях могут не справиться. В отличие от них НС способны не только выполнять заранее запрограммированную последовательность действия на заранее

определённом наборе данных, но и анализировать вновь поступающую информацию, находить в ней закономерности, адаптироваться и проводить прогнозирование.

## Литература

1. Исследование возможностей прогнозирования трафика сети мобильной связи / В. М. Безрук, И. В. Корсун, В. А. Тихонов, Н. В. Кудрявцева // Восточно-Европейский журнал передовых технологий. — 2010. — № 4/9 (46). — С. 58–62. [Issledovanie vozmozhnostey prognozirovaniya trafika seti mobilnoy svyazi / V. M. Bezruk, I. V. Korsun, V. A. Tikhonov, N. V. Kudryavceva // Vostochno-Evropeyskiy zhurnal peredovikhk tekhnologiy. — 2010. — No 4/9 (46). — S. 58–62. ]
2. *Zhani M. F., Elbiaze H.* Analysis and Prediction of Real Network Traffic // Journal of Networks. — 2009. — Vol. 4, No 9.
3. Бокс Д., Дженкинс Г. Анализ временных рядов: Пер. с англ. — М.: Мир, 1974. — 406 с. [*Boks D., Dzhenkins G.* Analiz vremennikh ryadov: Per. s angl. — М.: Mir, 1974. — 406 s. ]
4. Боровиков В. П., Ивченко Г. И. Прогнозирование в системе STATISTIKA в среде Windows. — М.: Финансы и статистика, 1999. — 384 с. [*Borovikov V. P., Ivchenko G. I.* Prognozirovanie v sisteme STATISTIKA v srede Windows. — М.: Finansih i statistika, 1999. — 384 s. ]
5. Маллинецкий Г. Г., Потанов А. Б., Подлазов А. В. Нелинейная динамика: Подходы, результаты, надежды. — 3-е издание. — М.: Книжный дом «ЛИБРОКОМ», 2011. — 280 с. [*Malineckiy G. G., Potapov A. B., Podlazov A. V.* Nelineynaya dinamika: Podkhodih, rezuljtatih, nadezhdih. — 3-е издание. — М.: Knizhniy dom «LIBROKOM», 2011. — 280 s. ]
6. Хайкин С. Нейронные сети: полный курс: Пер. с англ. — 2-е издание издание. — М.: Издательский дом «Вильямс», 2006. — 1104 с. [*Khayjkin S.* Neyjronnihe seti: polniy kurs: Per. s angl. — 2-е izdanie издание. — М.: Izdateljskiy dom «Viljams», 2006. — 1104 s. ]

UDC 004.732, 519.876

## Mathematical Models of Time Series of Intensities of Network Traffic with Different Approaches to Their Creating

A. A. Gabdrakhmanov\*, N. T. Gabdrakhmanova†

\* CJSC "Samara-Transtelecom"  
450022, Russia, Ufa, Vladivostokskaya str., 2/1-302

† Peoples' Friendship University of Russia  
6, Miklukho-Maklaya str., Moscow, 117198, Russia

In this article the possibility of application of artificial neural networks and autoregressive analysis to creating prediction models the channel with packet data transfer describes. The problem is solved using example time row measurement intensities on port edge switch. Algorithm of building autoregressive models based on statistical analysis of time row measurements. Algorithm of neural network model on the basis of the definition of fractal dimension of time rows was shown. Built models compared to current values entered criteria for evaluating the accuracy of the prediction.

**Key words and phrases:** nonlinear dynamics, Takens theorem, neural networks, time rows, self-similar traffic of Gigabit Ethernet.