

ПРОГНОЗИРОВАНИЕ ЗНАЧЕНИЙ ТРАФИКА ДАННЫХ С ИСПОЛЬЗОВАНИЕМ МОДЕЛЕЙ ВРЕМЕННЫХ РЯДОВ

Гребенников Александр Витальевич¹, Крюков Юрий Алексеевич²,
Чернягин Денис Викторович³

¹Ассистент;

ГОУ ВПО «Международный Университет природы, общества и человека «Дубна»,

Институт системного анализа и управления;

141980, Московская обл., г. Дубна, ул. Университетская, 19;

e-mail: grebennikovav@mail.ru.

²Кандидат технических наук, доцент;

ГОУ ВПО «Международный Университет природы, общества и человека «Дубна»,

Институт системного анализа и управления;

141980, Московская обл., г. Дубна, ул. Университетская, 19;

e-mail: kua@uni-dubna.ru.

³Ассистент;

ГОУ ВПО «Международный Университет природы, общества и человека «Дубна»,

Институт системного анализа и управления;

141980, Московская обл., г. Дубна, ул. Университетская, 19;

e-mail: dancher2000@mail.ru.

Прогнозирование сетевого трафика представляет значимый интерес в таких областях как отслеживание перегрузок в сети, контроль потоков данных и сетевое управление. Тщательно подобранная модель трафика способна выявить и предугадать важнейшие характеристики сетевого трафика, такие как кратковременно и долговременно зависимые процессы, самоподобность на больших временных масштабах. В данной работе рассматривается ряд простых моделей временных рядов для осуществления прогноза.

Ключевые слова: прогнозирование сетевого трафика, модель трафика, модель скользящих средних, модель экспоненциального сглаживания.

A PREDICTION METHOD OF NETWORK TRAFFIC USING TIME SERIES MODELS

Grebennikov Alexandr¹, Krukov Yury²
Chernyagin Denis³

¹Assistant;

Dubna International University of Nature, Society, and Man,

Institute of system analysis and management;

141980, Dubna, Moscow reg., Universitetskaya str., 19;

e-mail: grebennikovav@mail.ru.

²Candidate of Science in Engineering, associate professor of Institute of system analysis and management;

Dubna International University of Nature, Society, and Man,

Institute of system analysis and management;

141980, Dubna, Moscow reg., Universitetskaya str., 19;

e-mail: kua@uni-dubna.ru.

³Assistant;

Dubna International University of Nature, Society, and Man,

Institute of system analysis and management;

141980, Dubna, Moscow reg., Universitetskaya str., 19;

e-mail: grebennikovav@mail.ru.

The predictability of network traffic is a significant interest in many domains such as congestion control, admission control, and network management. An accurate traffic prediction model should have the ability to capture prominent traffic characteristics, such as long-range dependence and self-similarity in the large time scale. In this paper the simple models of time series have been considered to accurate traffic prediction.

Keywords: traffic prediction, traffic modeling, moving average model, exponential smoothing model.

Введение

Современные компьютерные сети стали основной средой для передачи информации, а перманентный рост пользователей Интернета приводит к нелинейному росту объемов передаваемого информационного трафика. В свою очередь рост объемов трафика оказывает огромное влияние на производительность сети в целом, в частности, на времязависимые приложения. Таким образом, управление трафиком является основной задачей сетевого управления, а анализ трафика данных позволяет своевременно отреагировать на изменение в поведении потока данных и устранить неисправности связанные с перегрузкой транзитных узлов. Избыток трафика, который ввёл сеть в состояние перегрузки, можно:

- заблокировать, т.е. удалить соответствующие пакеты из передачи (как правило, данное действие приводит к повторной передачи заблокированных пакетов, что только усугубляет ситуацию перегрузки);
- временно запретить источнику генерировать пакеты определенного типа (большинство существующих сервисов не предусматривают внешнего динамического управления);
- доставить адресату с худшими показателями качества, например, за большее время или с большей долей потерянных пакетов.

Последнее из упомянутых действий выглядит предпочтительней, если процесс управления доминирующим трафиком будет осуществляться в динамическом режиме и ограничивать поток данных лишь в кратковременные периоды, минимизируя эффект «снежного кома». Учитывая временные интервалы, необходимые для осуществления управляющего воздействия, решения о необходимости такого воздействия должны приниматься с упреждением. Таким образом, технологии прогнозирования играют значительную роль в сетевом управлении.

В основном алгоритмы прогнозирования можно классифицировать на долгосрочный и краткосрочный в зависимости от периода прогнозирования или в зависимости от количества прогнозируемых интервалов. Долгосрочные алгоритмы прогнозирования имеют недостатки, они чувствительны к объему анализируемых данных, показывают низкую прогнозную точность и имеют достаточно сложные модели. С другой стороны, краткосрочные алгоритмы прогнозирования могут быть более предпочтительными из-за их удовлетворительной точности, а также использования более простых моделей. Таким образом, намного проще использовать краткосрочные алгоритмы прогнозирования для операций реального времени. В этой статье рассматриваются краткосрочные алгоритмы прогнозирования значений высокоскоростного трафика с помощью простых моделей: скользящих средних и ряда моделей экспоненциального сглаживания.

Рассматриваемые модели

Модели скользящих средних

Простые скользящие средние

В этой модели n предшествующих значений участвуют в прогнозировании. Этот метод позволяет сгладить, как случайные, так и периодические колебания, выявить имеющуюся тенденцию в развитии процесса. Прогнозное значение задается выражением:

$$\hat{Y}_{n+1} = \frac{\sum_{i=n-d+1}^n X_i}{d}, \quad (1)$$

где \hat{Y}_{n+1} – прогнозное значение, d – активный участок сглаживания.

Взвешенные скользящие средние

В этой модели используется взвешенное среднее предшествующих значений для построения прогнозного значения.

$$\hat{Y}_{n+1} = \frac{\sum_{i=n-d+1}^n Y_i \cdot \omega_i}{\sum_{i=n-d+1}^n \omega_i}, \quad (2)$$

где ω_i – весовые коэффициенты, сумма которых не превышает 1.

Адаптивные методы прогнозирования

Простое экспоненциальное сглаживание

В этой модели прогнозное значение основано на предшествующем значении временного ряда и предшествующем значении экспоненциальной средней:

$$\hat{Y}_{n+1} = \alpha Y_n + (1 - \alpha) \hat{Y}_n, \quad (3)$$

где \hat{Y}_n – значение экспоненциальной средней, α – параметр сглаживания, $0 < \alpha < 1$.

Модель Хольта

В этой модели учитывается линейная тенденция:

$$\hat{Y}_{n+1} = \hat{a}_{1,n+1} + \hat{a}_{2,n+1} \tau, \quad (4)$$

где $\hat{a}_{1,n+1} = \alpha_1 Y_n + (1 - \alpha_1)(\hat{a}_{1,n} + \hat{a}_{2,n})$, $\hat{a}_{2,n+1} = \alpha_2 (\hat{a}_{1,n+1} - \hat{a}_{2,n}) + (1 - \alpha_2) \hat{a}_{2,n}$, τ – время упреждения прогноза.

Полиномиальная модель второго порядка

В этой модели предполагается, что тренд некоторого процесса может быть описан полиномом второй степени.

$$\hat{Y}_{n+1} = \hat{a}_{1,n+1} + \tau \cdot \hat{a}_{2,n+1} + \frac{1}{2} \tau^2 + \hat{a}_{3,n+1}, \quad (5)$$

где $\hat{a}_{1,n+1} = 3(S_{n+1}^{(1)} - S_{n+1}^{(2)}) + S_{n+1}^{(3)}$,

$$\hat{a}_{2,n+1} = \frac{\alpha}{2(1-\alpha)^2} \left[(6-5\alpha)S_{n+1}^{(1)} - 2(5-4\alpha)S_{n+1}^{(2)} + (4-3\alpha)S_{n+1}^{(3)} \right],$$

$$\hat{a}_{3,n+1} = \frac{\alpha^2}{\beta^2} (S_{n+1}^{(1)} - 2S_{n+1}^{(2)} + S_{n+1}^{(3)}),$$

$$S_{n+1}^{(1)} = \alpha Y_n + (1 - \alpha)S_n^{(1)},$$

$$S_{n+1}^{(2)} = \alpha S_{n+1}^{(1)} + (1 - \alpha)S_n^{(2)},$$

$$S_{n+1}^{(3)} = \alpha S_{n+1}^{(2)} + (1 - \alpha)S_n^{(3)},$$

$$S_0^{(1)} = \hat{a}_{1,0} - \frac{(1-\alpha)}{\alpha} \hat{a}_{2,0} + \frac{(1-\alpha)(2-\alpha)}{2\alpha^2} \hat{a}_{3,0},$$

$$S_0^{(2)} = \hat{a}_{1,0} - \frac{2(1-\alpha)}{\alpha} \hat{a}_{2,0} + \frac{(1-\alpha)(3-2\alpha)}{\alpha^2} \hat{a}_{3,0},$$

$$S_0^{(3)} = \hat{a}_{1,0} - \frac{3(1-\alpha)}{\alpha} \hat{a}_{2,0} + \frac{3(1-\alpha)(4-3\alpha)}{2\alpha^2} \hat{a}_{3,0},$$

$\hat{a}_{1,0}, \hat{a}_{2,0}, \hat{a}_{3,0} = Y_0$ - начальные значения,

τ – время упреждения прогноза.

Адекватность подобранной модели оценивается по критерию минимизации метода наименьших квадратов (МНК), т.е.

$$Q = \sum_{i=1}^n (Y_i - \hat{Y}_{i-1})^2 \Rightarrow \min. \quad (6)$$

Таким образом, поиск наиболее подходящей модели для совершения прогноза сводится к нахождению оптимальных параметров модели на тренировочном участке, а задача выбора прогнозной модели состоит в нахождении минимума функции $f(Q, p_1, p_2, \dots, p_n) \Rightarrow \min$, где p_1, p_2, \dots, p_n – искомые параметры. В частности для описанных выше моделей необходимо найти минимум на графиках.

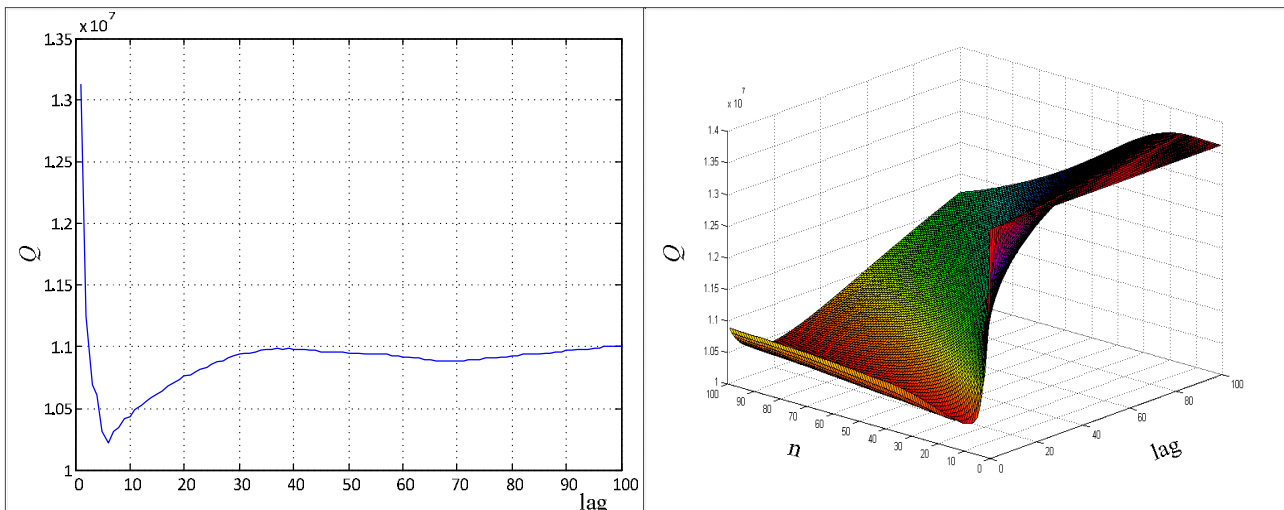


Рис. 1: а) Зависимость критерия качества модели (1) от лаговой составляющей;
б) Зависимость критерия качества модели (2) от лаговой составляющей и от степени полинома, описывающий весовые коэффициенты

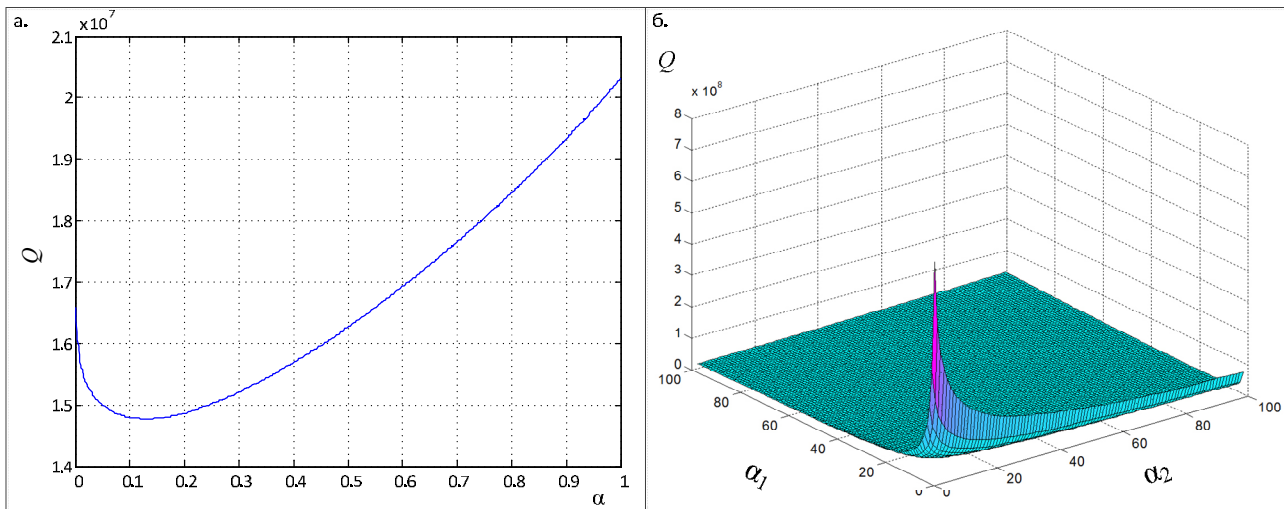


Рис. 2: а) Зависимость критерия качества модели (3) от параметра сглаживания α ;
 б) Зависимость критерия качества модели (4) от параметров сглаживания α_1, α_2

Для оценки точности прогноза используется ряд стандартных показателей.

1. Средняя абсолютная процентная ошибка (MAPE):

$$MAPE = \frac{100\%}{L} \sum_{t=1}^L \left| \frac{X_t - \hat{X}_t}{X_t} \right|, \quad (7)$$

где X_t – реальное значение, \hat{X}_t – прогнозное значение, L – интервал прогноза. Если $MAPE < 10\%$ то прогноз сделан с высокой точностью, $10\% < MAPE < 20\%$ – прогноз хороший, $20\% < MAPE < 50\%$ – прогноз удовлетворительный, $MAPE > 50\%$ – прогноз плохой.

2. Отношение сигнала к шуму (SER):

$$SER = 10 \lg \left(\frac{\sum_{t=1}^L X_t^2}{\sum_{t=1}^L (X_t - \hat{X}_t)^2} \right). \quad (8)$$

Методика эксперимента

В соответствии с методикой, описанной в [3] были получены дампы трафика соответствующие временному промежутку с 17 до 00 часов нескольких суток. Далее дампы приводились в эквидистантный вид с временем агрегации 10 мкс. Эксперимент по выявлению значений параметров модели для адекватного прогнозирования был поставлен по следующему алгоритму:

- в исходном дискретном временном ряде X_t , соответствующем трафику выделялся так называемый тренировочный участок с фиксированной длиной равной 5000 значениям;
- на данном тренировочном участке оценивались параметры упреждающей модели в соответствии с критерием качества модели (6);
- полученные результаты значений параметров упреждающей модели на каждом тренировочном участке сводились в таблицу, отражающую частоту появления модели с определенным количеством параметров на всем рассматриваемом временном ряде X_t ;
- из полученной таблицы выбиралась наиболее часто встречающиеся параметры модели;
- на основе полученной модели, на случайно выбранном тренировочном участке исходного ряда оценивались параметры прогностической модели по алгоритму из пункта 2, причем формировался прогноз X_{t+10} (на 10 шагов вперед) $t+10$ значения ряда X_t , следующего за концом тренировочного участка;

- фиксировалась абсолютная ошибка прогноза вплоть до ε_{t+10} ;
- сдвигался тренировочный участок на один шаг вперед, считая, что к наступившему моменту времени уже стало известно действительное значение только что спрогнозированного отсчета $t+1$ и т.д.

С помощью вышеуказанной методики были проведены исследования с целью определения наиболее адекватной модели для выполнения прогноза. Исследования проводились с использованием программы Matlab 7.9. Всего было найдено 10124 прогнозных моделей с соответствующими параметрами. Частоты появления моделей с соответствующими параметрами представлены на рисунках ниже в виде функций плотности распределения вероятности.




Рис. 3. Функция плотности распределения вероятности значений параметра модели:
а) для модели (1); б) для модели (3)




Рис. 4. Функция плотности распределения вероятности значений параметров модели (2)

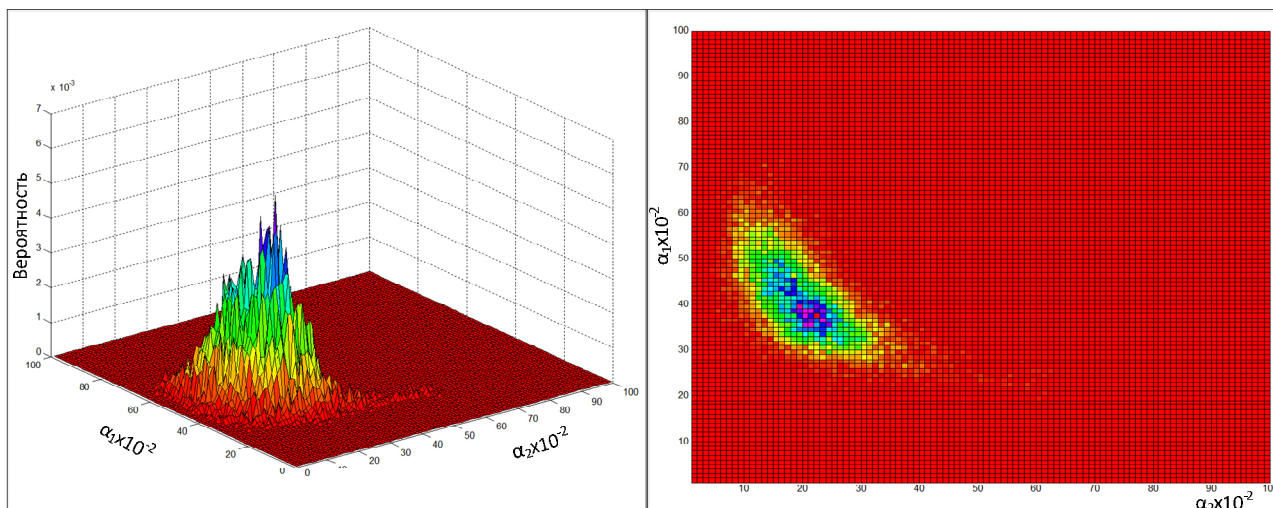


Рис. 5. Функция плотности распределения вероятности значений параметров модели (4)

Таким образом, наиболее удачный параметр прогнозной модели будет соответствовать математическому ожиданию на графике функции плотности распределения вероятности. Для модели (1) $d = 11$, касательно модели (2), в силу сложной функции плотности распределения вероятности, имеет смысл выбрать в качестве параметра моду, т.е., в данном случае, длина активного участка равна 10 лагам, а степень полинома 1, для модели (3) коэффициент сглаживания $\alpha = 0,21$, для модели (4) коэффициенты сглаживания $\alpha_1 = 0,2$ $\alpha_2 = 0,41$, для модели (5) коэффициент сглаживания $\alpha = 0,1028$.

В соответствие с вышеуказанными показателями (5) и (6) осуществлялась оценка точности прогноза. В прогнозном сценарии для прогноза полученных моделей сравнивался прогноз на 10 шагов вперед. Следует отметить, что для чистоты эксперимента случайным образом выбирались тренировочные участки, производился прогноз на 10 шагов вперед, а затем для вышеуказанных моделей с найденными параметрами высчитывались значения MAPE и SER по формулам (7) и (8). Всего было выбрано 230 случайных участков временного ряда, на каждом были получены значения MAPE и SER. Затем вычислялось среднее значение данных показателей.

На рис. 6 показан пример прогноза значений трафика на 10 шагов вперед для одного из участка временного ряда.




Рис. 6. Прогноз значений трафика для одного из случайных участков временного ряда

Анализ полученных данных

Далее приведены результаты усредненных оценок, характеризующие качество прогнозных оценок MAPE и SER.




Рис. 7. Среднее значение коэффициентов MAPE и SER для прогноза на 10 шагов вперед

Из Рис. 7 видно, что оценка MAPE модели (7) не намного меньше и находится между 10% и 20%, что соответствует хорошему прогнозу, но эта модель сложнее модели (3), чей показатель SER чуть больше. Поэтому модель (3) лучше подходит для прогнозирования значений трафика. В работе [2] показано, что для осуществления прогноза на 10 шагов подходит модель ARIMA(1,1,0), при этом показатель MAPE = 21,84%, а SER = 12,94%, сравнивая эти результаты с полученными результатами MAPE и SER можно сделать вывод, что модель (3) показывает наиболее точный прогноз.

Заключение

Построение систем on-line мониторинга с возможностью динамического управления выделенной пропускной способностью линии связи для определенных видов сервиса — важная перспективная задача. Широкое распространение сервисов распределенного хранения данных P2P, отсутствие «узкого горла» как элемента системы, ограничивающего общий объем транслирующихся данных, позволяют рассматривать дальнейшее развитие сетей P2P как фактор, вносящий дисбаланс в существующую сетевую инфраструктуру. Внедрение систем динамического управления сетевым трафиком способно сбалансировать нагрузку, возникающую в различные временные периоды, и исключить возникновение перегрузок в сегментах сети без существенного влияния на качество работы распределенных файлообменных сервисов.

В данной работе рассмотрены простые модели прогнозирования трафика в высокоскоростном магистральном канале и найдены подходящие параметры для осуществления наиболее адекватного прогноза, который позволит своевременно предупреждать о последующих выбросах сетевого трафика. Таким образом, экспериментальным путем было установлено, что из предлагаемых моделей наиболее хорошим прогнозом обладает модель экспоненциального сглаживания с параметром сглаживания 0,21. Использование прогнозных моделей с шагом 10 мс хорошо согласуется с временем управляющего воздействия системы на коммутационное оборудование, что наряду с высокой вероятностью прогноза на коротких временных периодах обеспечивает адекватное управление мгновенной пропускной способностью сегмента сети.

Список литературы

1. Дуброва Т.А. Статистические методы прогнозирования. – М.: ЮНИТИ-ДАНА, 2003. – С. 206.
2. Гребенников А. В., Крюков Ю. А., Чернягин Д. В. Моделирование сетевого трафика и прогнозирование с помощью модели ARIMA // Системный анализ в науке и образовании: электрон. науч. журнал. – 2011. – №1. – [Электронный ресурс]. URL: <http://www.sanse.ru/archive/19>. – 0421100111\0002.