

СТРУКТУРНО-ПАРАМЕТРИЧЕСКАЯ ИДЕНТИФИКАЦИЯ ТРАФИКА В ИНФОРМАЦИОННЫХ ТЕЛЕКОММУНИКАЦИОННЫХ СЕТЯХ

УДК 621.72:004.724.4

ГЕРАСИНА Александра Владимировна

к.т.н., доцент кафедры безопасности информации и телекоммуникаций ГВУЗ «Национальный горный университет».

Научные интересы: исследование и разработка адаптивных систем управления сложными нелинейными технологическими процессами и системами связи.

e-mail: piv_av@meta.ua

ВВЕДЕНИЕ

Рост информатизации общества усиливает требования к надежности и производительности передачи данных в информационных телекоммуникационных сетях (ИТС). Увеличение потоков данных приводит к возникновению пиковых нагрузок, при которых наблюдаются значительные потери пакетов и существенные временные задержки. В связи с этим актуальным является идентификация трафика в ИТС для предупреждения перегрузок в сети и повышения качества услуг.

ПОСТАНОВКА ЗАДАЧИ

Трафик в современных ИТС является нелинейным стохастическим процессом с хаотической и фрактальной динамикой, обладающий свойством самоподобия [1].

Неравномерность интенсивности поступления пакетов данных приводит к появлению пачечности и пиковых нагрузок. Однако продолжительность пиков небольшая и большую часть времени работы сети наблюдается сравнительно небольшая средняя интенсивность трафика. Поэтому для обеспечения необходимого качества услуг и избежания потери пакетов нецелесообразно увеличивать пропускную способность сети и количество оборудования. Целесообразным решением данной проблемы является построение и использование для управления передачей адекватных моделей сетевого трафика.

Для идентификации и прогнозирования телетрафика наиболее актуальным является использование методов систем искусственного интеллекта: нейронных сетей (НС) и систем с нечеткой логикой, которые являются универсальными эффективными аппроксиматорами.

В работе [2] предложен комплексный метод идентификации трафика в ИТС, позволяющий классифицировать и оценить характеристики порождающей системы, и получить адекватную динамическую модель трафика. Вместе с тем, в работе [2] отсутствует оптимизация структур интеллектуальных моделей сетевого трафика и не исследовано влияние разных методов глобальной (структурной) и локальной (параметрической) оптимизации на точность его идентификации.

Цель статьи. Оптимизация структур интеллектуальных прогнозирующих моделей трафика в ИТС путем использования композиции методов глобальной и локальной оптимизации.

СТРУКТУРНО-ПАРАМЕТРИЧЕСКАЯ ИДЕНТИФИКАЦИЯ

Задача идентификации трафика в ИТС состоит в определении структуры (обобщенной функции Φ) и параметров a его модели. Формирование вектора $\Psi_s = \{\Phi, a\}$ оценки структуры Φ (структурная идентификация) и параметров a (параметрическая идентификация) модели телетрафика осуществляется на

основе векторов сигналов наблюдения путем минимизации принятого функционала [3]:

$$C[\Psi_s] \rightarrow \min_{\Psi_s \in \theta} C \Rightarrow \Psi_{\theta}^{\text{opt}} = \{\Phi_{\text{opt}}, a_{\text{opt}}\}, \quad (1)$$

где θ – ограничения.

Поскольку выражение (1) является полимодальным (комбинацией непрерывного и дискретного программирования), то это требует использования методов глобальной оптимизации, среди которых наиболее эффективными являются поисковые методы. В них алгоритм поиска оптимального решения связывает следующие друг за другом решения $\Psi_s(j+1) = F[\Psi_s(j)]$, где F – алгоритм поиска, который показывает какие операции следует сделать на шаге j при решении $\Psi_s(j)$, чтобы получить новое решение $\Psi_s(j+1) \succ \Psi_s(j)$. Здесь знак преимущества \succ при минимизации функционала имеет смысл:

$$C[\Psi_s(j+1)] < C[\Psi_s(j)]. \quad (2)$$

В алгоритмах прямого случайного поиска (ПСП) задаются направления поиска и определяются значения функционала C в точках $\Psi_s(j) \pm \gamma \zeta$. Решение состоит в выборе шага в направлении уменьшения этого функционала:

$$\Psi_s(j+1) = \Psi_s(j) - \omega \zeta \{ C[\Psi_s(j) + \gamma \zeta] - C[\Psi_s(j) - \gamma \zeta] \}' \quad (3)$$

где ω, ζ, γ – параметры, которые определяют сферы принятия решения (ω), сбора информации (γ) и единичное случайное направление (ζ). В общем случае параметры в (3) могут изменяться (адаптироваться) к процедуре поиска и вида гиперповерхности принятого функционала.

Развитием метода ПСП является метод имитации отжига (МИО), который отражает поведение расплавленного материала при отверждении с применением процедуры управляемого охлаждения (отжига). В процессе отжига кристаллизация расплава сопровождается глобальным уменьшением его энергии, однако допускаются ее возрастание на некоторое время. Благодаря этому возможен выход из ловушек локальных минимумов энергии, которые возникают при реализации процесса.

В алгоритмах МИО задаются направления поиска и определяются значения функционала C в точках $\Psi_s(j) \pm v\tau$. Решение состоит в выборе шага в направлении уменьшения этого функционала:

$$\Psi_s(j+1) = \Psi_s(j) - \omega v \tau \{ C[\Psi_s(j) + v\tau] - C[\Psi_s(j) - v\tau] \}' \quad (4)$$

где ω, v, τ – параметры, которые определяют сферы принятия решения (ω), изменение текущего решения (v) и уменьшение температуры (τ).

Метод порогового принятия (МПП) использует подход, схожий с МИО, но вместо того, чтобы выбрать новые точки, оптимизирующие критерий с некоторой вероятностью, этот метод выбирает все новые точки ниже установленного порога. Таким образом, порог и температура систематически понижаются, что позволяет избежать вероятностных вычислений, и может определить оптимум быстрее, чем в МИО.

Развитием поисковых методов являются эволюционные алгоритмы, среди которых наиболее распространены генетические алгоритмы (ГА), которые моделируют развитие биологической популяции на уровне геномов: мутации структуры и параметров $\delta\Psi_s$, их скрещивание (размножение) [4]:

$$\Psi_s(j+1) = \Psi_s(j) + \delta\Psi_s(j), \quad (5)$$

и правило отбора, что позволяет обнаруживать их благоприятные вариации, с помощью которых строится последовательность улучшенных решений.

Большинство задач, решаемых при помощи ГА, имеют один критерий оптимизации. Многокритериальная оптимизация (МО) основана на отыскании решения, одновременно оптимизирующего более чем одну функцию. В этом случае ищется некоторый компромисс, в роли которого выступает решение, оптимальное в смысле Парето. При МО, использующей ГА выбирается не одна хромосома, представляющая собой оптимальное решение в обычном смысле, а множество хромосом, оптимальных в смысле Парето. Пользователь имеет возможность выбрать оптимальное решение из этого множества [5]:

$$k \cdot \Psi_s(j+1) = k \cdot (\Psi_s(j) + \delta\Psi_s(j)), \quad (6)$$

где $k \geq 2$ – число рассматриваемых критериев.

При решении задачи (2) актуальным является выбор критериев качества модели (функционала C). Для идентификации эффективны внешние критерии, адекватные задаче построения моделей с минимальной дисперсией ошибки прогноза, которые делятся на критерии регулярности и критерии несмещенности [6].

Критерий регулярности основан на разделении данных на обучающую и проверочную выборки:

$$C_{\text{рег}} = \frac{\|Y_B^*[m+n] - \hat{Y}_B[m+n]\|}{\|Y_B^*[m+n]\|}, \quad (7)$$

где m – глубина памяти, n – глубина прогноза. Оптимизация модели осуществляется на обучающей (А), а проверка ее эффективности (величины ошибки) на проверочной (В) выборке. Вся выборка $N = A + B$.

Критерий регулярности ориентирован на выбор модели, которая будет наиболее точной на множестве точек, которых еще нет в таблице, но которые появятся там в ближайшем будущем.

Более стойкие к помехам критерии минимума смещения (несмещенности). Например, критерий несмещенности, основанный на анализе решений:

$$C_{\text{см}} = \frac{\|\hat{Y}_A[m+n] - \hat{Y}_B[m+n]\|}{\|Y^*[m+n]\|}, \quad (8)$$

где $\hat{Y}_A[m+n]$ и $\hat{Y}_B[m+n]$ – выходы моделей, которые обучены на выборках А и В, соответственно. Вычисление критерия $C_{\text{см}}$ осуществляется на всей выборке N .

Критерий минимума смещения позволяет выбрать модель наименее чувствительную к изменению множества точек, по которым она получена. Такая модель должна давать одинаковые результаты на выборках А и В. Поэтому, он рекомендуется для решения задач структурной идентификации.

Выбор метода локальной (параметрической) оптимизации ограничен выбором типа базисных функций. Идентификацию с помощью НС прямого распространения (НСПР) со скрытым слоем предлагается приводить в виде [3]:

$$\hat{Y}[m+n] = \sum_{\tau \in P} F_{\hat{Y}} \left\{ \sum_{l \in Q} w_l[\tau] \cdot F_l \left(\sum_{m \in Q} w_{l,k}[\tau] \cdot y_k[m-\tau] \right) \right\}' \quad (9)$$

где P – множество глубин памяти соответствующих входов; $F_{\hat{Y}}$ – функция активации выходного слоя НС; Q – множество входов нейронов; l – порядковый номер входа выходного слоя НС; w_l – весовые коэффициенты выходного слоя; F_l – функция активации нейронов скрытого слоя; k – порядковый номер входа

НС; $w_{l,k}$ – весовые коэффициенты связи k -го входа и l -го нейрона; y_k – вход НС.

Структурными характеристиками НС (9) являются – $\{T_s, P, P_{\text{пр}}, F_{\hat{Y}}, F_l, r_s, M_{\text{по}}\} \subset \Phi$, где T_s – тип структуры, $r_s \subset Q$ – размер скрытого слоя, $M_{\text{по}}$ – метод параметрической оптимизации (функция обучения НС), $P_{\text{пр}}$ – глубина прогноза. Параметрами НСПР являются $\{w_l, w_{l,k}\} \subset a$. К НСПР относятся перцептроны, каскадные НС, вейвнеты и др.

Идентификация с помощью НС с радиальными базисными функциями (РБФ) выполняется согласно уравнению:

$$\hat{Y}[m+n] = \sum_{\tau \in P} F_{\hat{Y}} \left\{ \sum_{l,k \in Q} w_l \cdot F_l(\vartheta_l, \|y_k[m-\tau] - v_l\|) \right\}, \quad (10)$$

где ϑ_l, v_l – параметры РБФ l -го нейрона скрытого слоя.

При этом, структурными характеристиками НС (10) являются – $\{T_s, P, P_{\text{пр}}, F_{\hat{Y}}, F_l, r_s, M_{\text{по}}\} \subset \Phi$, а ее параметрами – $\{w_l, \vartheta_l, v_l\} \subset a$.

Идентификацию с помощью гибридной НС с нечеткой логикой (Anfis) предлагается приводить в виде:

$$\hat{Y}[m+n] = \sum_{\tau \in P} \sum_{k \in Q} \beta_k[\tau] \cdot \alpha_k[m-\tau], \quad (11)$$

$$\text{где } \beta_k[\tau] = U_k^{-1}(\alpha_k[\tau] / \sum_k \alpha_k[\tau]);$$

$$\alpha_k[m-\tau] = T_{\text{norm}} \{L_{l,k}(y_k[m-\tau])\}; \quad U = U(a_U);$$

$$L = L(a_L).$$

Здесь U_k^{-1} – функция, обратная функции принадлежности промежуточного выхода k сети с параметрами a_U ; α_k – значение промежуточного выхода; T_{norm} – произвольная t -норма моделирования логической операции «f»; $L_{l,k}$ – функция принадлежности нечеткого правила l входа k с параметрами a_L .

Структурные характеристики НС (11) – $\{T_s, P, P_{\text{пр}}, U_k, L_{l,k}, r_p, M_{\text{по}}\} \subset \Phi$, где $r_p \subset Q$ – количество правил разложения по входам, а ее параметры – $\{a_U, a_L\} \subset a$.

Идентификация параметров (обучение) НСПР (9) осуществляется с помощью градиентных алгоритмов обучения: алгоритмов метода сопряженных градиентов, алгоритмов обратного распространения ошибки или квазиньютоновских алгоритмов. При обучении НС с РБФ (10) сначала


определяются центры и отклонения для радиальных элементов, после чего оптимизируются параметры линейного выходного слоя: $\{w_1, \vartheta_1, v_1\} \subset a$. Обучение гибридной НС (11) выполняется с помощью гибридного алгоритма или алгоритма обратного распространения ошибки [7]. Преимуществом этих алгоритмов параметрического обучения НС является их простота и быстродействие, а недостатком – их локальность.

МОДЕЛИРОВАНИЕ

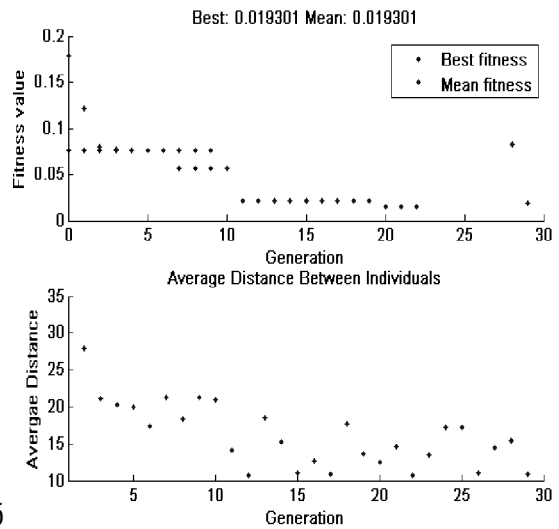
Моделирование решения задачи структурно-параметрической идентификации выполнялось с помощью разработанных программ в среде Matlab на основе экспериментальных данных – трафика, передающегося через сеть Интернет [8]. Данные представляют собой зависимость размера Ethernet кадров в байтах от времени. Для их приведения к эквидистантной шкале по временной оси была проведена процедура агрегации с шагом 5 с.

Глубина прогноза была принята $n = 3$ такта, а глубина памяти по разным входам от 1 до 4. В качестве критерия структурной оптимизации выбран критерий (8). В качестве глобальных методов оптимизации применялись ГА, МО, ПСП, МИО, МПП. При этом использовалась структура моделей Гаммерштейна-Винера с базисными функциями (9), (10) и (11).

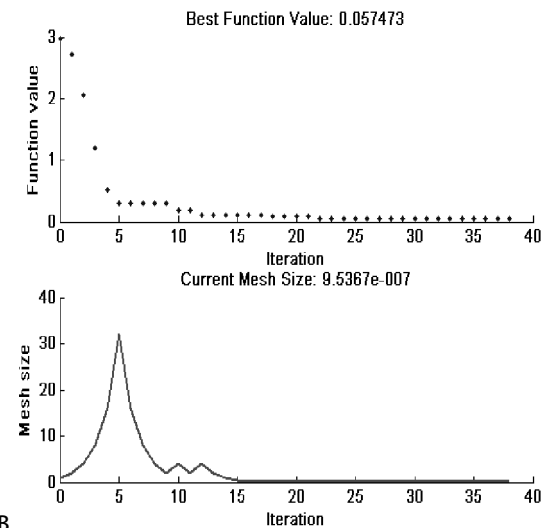
Результаты глобальной оптимизации структуры модели трафика в ИТС приведены на рис. 1.




a



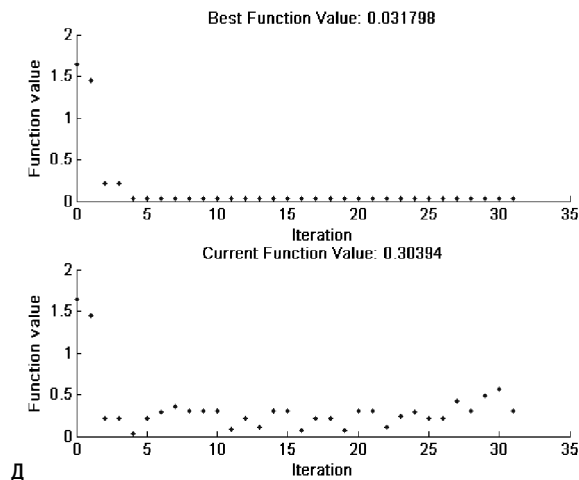
б



B



Г



Д
Рисунок 1 – Результаты глобальной оптимизации структуры модели трафика с помощью ГА (а), МО (б), ПСП (в), МИО (г) и МПП (д)

Метод МО использовал ГА для нахождения множества оптимальных по Парето решений. ПСП имел адаптивный шаг поиска и полный поиск вокруг текущей итерации, МИО и МПП – ограниченную область переотжига, ГА – одноточечное скрещивание, селективный выбор родителей, формирование новой популяции с вытеснением. Количество итераций для ПСП, МПП и МИО (для ГА и МО поколений) ограничивалось на уровне 100, а размер пространства поиска для ПСП (для ГА и МО размер популяции, для МПП и МИО размер области переотжига) – 30.

При глобальной оптимизации варьировались следующие структурные характеристики модели:

- тип базисной функции – (9), (10) и (11);
- количество нейронов в скрытом слое;
- тип функций активации и принадлежности скрытого слоя;
- тип алгоритма параметрической оптимизации.

В результате моделирования (рис. 1) установлено, что ГА имеет самую высокую скорость сходимости (ГА выходит в область оптимальных решений на первых поколениях, МПП – в среднем после 5 итераций, МИО – после 15, а МО и ПСП – после 20 итераций). Алгоритм МПП выявил самое высокое быстродействие (0,6 с на итерацию при 0,7с на итерацию в МИО, 2,2 с на итерацию в ПСП, 19,3 с на поколение в ГА и 27,4 с на поколение в МО). Алгоритм МО выявил наилучшую сходимость (значения критерия (7) при его использовании –

0,019, в отличие от 0,032 при МПП, 0,042 при ГА, 0,057 при ПСП и 0,077 при МИО).

Результат параметрической идентификации трафика в ИТС приведен на рис. 2.

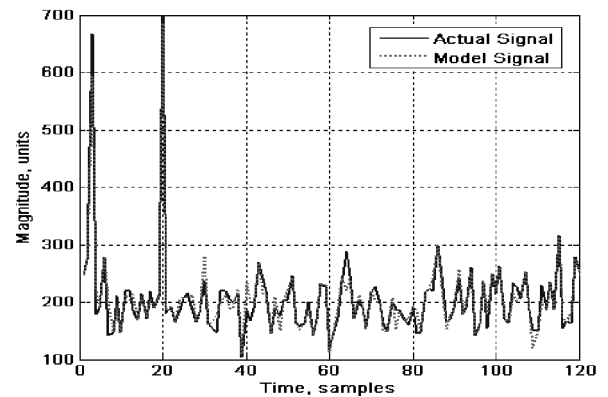


Рисунок 2 – Результат идентификации трафика



Установлено, что минимуму критерия (8) отвечают базисные функции в виде каскадной НСПР. При этом количество нейронов в скрытом слое составляет 73, функция активации скрытого слоя – конкурирующая с мягким максимумом, выходного слоя – линейная, алгоритм обучения НС – градиентного спуска с выбором параметра скорости настройки [7].

За меру точности параметрической идентификации модели оптимальной структуры использовался критерий (7), значение которого составило – 0,0311, что меньше ошибок известных моделей трафика в ИТС.

Адекватность полученной интеллектуальной прогнозирующей модели трафика проверялась по непараметрическому критерию знаков. Было установлено, что для уровня значимости 0,01 разработанная модель с идентифицированными структурой и параметрами адекватна экспериментальным реализациям.

ВЫВОДЫ

Исследование методов структурной и параметрической оптимизации моделей трафика в ИТС показало эффективность применения их композиции. Интеллектуальные прогнозирующие модели оптимальной структуры, построенные таким образом, имеют повышенную точность. Дальнейшие исследования должны быть направлены на разработку математического и программного обеспечения для решения задач идентификации трафика в ИТС.



ЛИТЕРАТУРА:

1. Crovella M.E. Self-Similarity in World Wide Web Traffic: Evidence and Possible Causes /M.E. Crovella, A. Bestavros //IEEE Transactions on Networking. – 1997. – Vol.5. – №6. – pp.835-846.
2. Budkova L.V. Kompleksna ocinka karakteristik ta identifikacija trafiku v informacijnih telekomunikacijnih mrežhah /L.V. Budkova, V.I. Kornienko //Sistemi obrobki informacii. – 2013. – №2 (109). – S.207-211.
3. Kuznecov G.V. Kompozicijna strukturno-parametrična identifikacija nelinejnih dinamičnih ob'ektiv keruvannja /G.V. Kuznecov, V.I. Kornienko, O.V. Gerasina //Naukovi visti NTUU KPI. – 2009. – №5. – S.69-75.
4. Nelles O. Nonlinear System Identification: From Classical Approaches to Neural and Fuzzy Models /O. Nelles. – Berlin: Springer, 2001. – 785 p.
5. Rutkovskaja D. Nejronnye seti, geneticheskie algoritmy i nechetkie sistemy /D. Rutkovskaja, M. Pilin'skij, L. Rutkovskij. – M.: Gorjachaja linija-Telekom, 2006. – 452 c.
6. Ivahnenko A.G. Dolgosrochnoe prognozirovanie i upravlenie slozhnymi sistemami /A.G. Ivahnenko. – K.: Tehnika, 1975. – 312 s.
7. Nejronnye seti. MATLAB 6 /Pod red. V.G. Potemkina. – M.: DIALOG-MIFI, 2002. – 496 s.
8. Arhiv trafika: <http://ita.ee.lbl.gov>

Рецензент: *д.т.н., проф. Алексеев М.О., Национальный горный университет, Днепропетровск.*