

О.В. Герасіна

Державний вищий навчальний заклад «Національний гірничий університет», Дніпро

МЕТОДИКА ІНТЕЛЕКТУАЛЬНОЇ ІДЕНТИФІКАЦІЇ ТА ПРОГНОЗУВАННЯ ТРАФІКУ В ІНФОРМАЦІЙНИХ ТЕЛЕКОМУНІКАЦІЙНИХ МЕРЕЖАХ

Запропоновано методику інтелектуальної ідентифікації та прогнозування трафіку в інформаційних телекомунікаційних мережах, яка складається з визначення розмірностей моделей трафіку, а також його ідентифікації та прогнозування з використанням систем штучного інтелекту, обґрунтування структури моделей та композиції методів глобальної і локальної оптимізації. Шляхом моделювання оцінено ефективність використання запропонованої методики на прикладі ідентифікації та прогнозування експериментальних даних – трафіку, що передається через мережу Інтернет.

Ключові слова: ідентифікація, прогнозування, трафік, нейронні мережі, нечітка логіка, структури моделей, глобальна оптимізація.

Вступ

Постановка проблеми. Зростання інформатизації суспільства посилює вимоги до надійності та продуктивності передачі даних в інформаційних телекомунікаційних мережах (ІТМ). До актуальних завдань оптимізації сучасних ІТМ відносять дослідження складних процесів, що виникають у системах передачі, їх ідентифікація, оцінка й формування (на основі отриманих адекватних математичних описів цих процесів) моделей керування мережевим трафіком.

Дослідження трафіку в сучасних ІТМ показали, що він є нелінійним стохастичним процесом з хаотичною і фрактальною динамікою [1]. Крім того, агрегований трафік від різних джерел на малих часових масштабах проявляє мультифрактальний характер. При цьому, на основі моделювання властивостей трафіку можливо розробити засоби забезпечення якості обслуговування в ІТМ.

Аналіз останніх досліджень і публікацій. Для ідентифікації і прогнозування трафіку в ІТМ найбільш актуальним є використання інтелектуальних методів: нейронних мереж (НМ) і систем з нечіткою логікою, що є універсальними ефективними апроксиматорами [2–3].

В роботах [2–3] запропоновано методи ідентифікації та прогнозування трафіку в ІТС, що дозволяє класифікувати і оцінити характеристики породжуючої системи, і отримати адекватну динамічну модель трафіку. Разом з тим, в роботах [2–3] відсутня оптимізація структур інтелектуальних моделей трафіку і не досліджено вплив різних методів глобальної і локальної оптимізації на точність його ідентифікації та прогнозування.

Формулювання мети статті. Розробка методики інтелектуальної ідентифікації та прогнозування трафіку в ІТМ, а також оцінка її ефективності.

Виклад основного матеріалу

Схему методики інтелектуальної ідентифікації та прогнозування трафіку в ІТМ наведено на рис. 1.

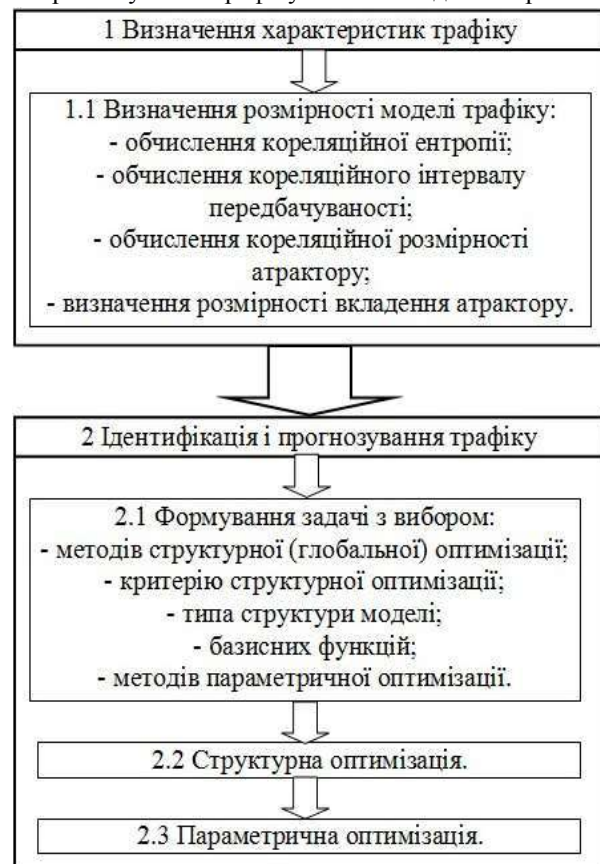


Рис. 1. Схеми інтелектуальної ідентифікації та прогнозування трафіку в ІТМ

Згідно теореми Такенса за часовою реалізацією спостережуваного сигналу $x = x(t)$ задаючи затримку τ і розмірність d фазового простору, можна отримати його дискретне відображення:

$$x[k] = \{x[k], x[k - m], x[k - 2m], \dots, x[k - (d - 1)m]\}, \quad (1)$$

де $m = \tau/T$; T – інтервал дискретизації за часом.

При переборі за тактом часу k маємо дискретний набір точок в d -мірному просторі, який при сталому режимі системи є фазовим портретом атрактора. Аналіз фазового портрета може виявити напрями рухів за різних початкових умов, а також визначити якісні властивості динамічної системи, що породжує процес (1).

Для визначення режиму породжуючого процесу оцінюють його ентропію Колмогорова K , яка дорівнює сумі старших показників Ляпунова і характеризує швидкість втрати інформації про стан динамічної системи в часі. K -ентропія дорівнює нулю при регулярному русі, нескінченна для випадкових систем, позитивна і обмежена для систем з динамічним хаосом [4].

Значення кореляційної ентропії [5]:

$$K_{ng} = \lim_{\sigma \rightarrow 0} \lim_{m \rightarrow \infty} \ln \left[\frac{J_m(\sigma)}{J_{m+1}(\sigma)} \right] \leq K, \quad (2)$$

де $J(\sigma)$ – кореляційний інтеграл; σ – розмір осередку покриття даної множини; ϵ нижньою межею K -ентропії і дозволяє оцінити інтервал передбачуваності процесу (глибини точного прогнозу):

$$T_{vg} \sim \frac{1}{K_{ng}} \ln \left(\frac{1}{\sigma} \right) \geq T_{pr}. \quad (3)$$

Розмірність фазового простору d , починаючи з якої кореляційна розмірність атрактору

$$D_{ng} = \lim_{\sigma \rightarrow 0} \frac{\log J(\sigma)}{\log \sigma} \quad (4)$$

перестає змінюватися, є мінімальною розмірністю вкладення атрактора (найменшою цілою розмірністю фазового простору, що вміщує весь атрактор).

Таким чином, розмірність вкладення атрактору d визначає порядок породжуючої системи (глибини пам'яті вхідних і вихідних змінних моделі трафіку):

$$d \geq 2D_{ng} + 1. \quad (5)$$

Задача ідентифікації та прогнозування трафіку полягає у визначенні структури (узагальненої функції Φ) і параметрів a його моделі. Формування вектора $\Psi_s = \{\Phi, a\}$ оцінки структури (структурна оптимізація) і параметрів (параметрична оптимізація) моделі телетрафіку здійснюється на основі векторів сигналів спостереження шляхом мінімізації прийнятого функціонала:

$$C[\Psi_s] \rightarrow \min_{\Psi_s \in \theta} C \Rightarrow \Psi_s^{opt} = \{\Phi_{opt}, a_{opt}\}, \quad (6)$$

де θ – обмеження.

Оскільки вираз (6) є полімодальним (комбінацією безперервного та дискретного програмування), то це вимагає використання методів глобальної оптимізації, серед яких найбільш ефективними є пошукові методи. У них алгоритм пошуку оптимального рішення пов'язує наступні один за одним рішення $\Psi_s(j+1) = F[\Psi_s(j)]$, де F – алгоритм пошуку, який показує які операції слід зробити на кроці j при рішенні $\Psi_s(j)$, щоб отримати нове рішення $\Psi_s(j+1) > \Psi_s(j)$. Тут знак переваги $>$ при мінімізації функціоналу має сенс:

$$C[\Psi_s(j+1)] < C[\Psi_s(j)]. \quad (7)$$

В алгоритмах прямого випадкового пошуку (ПВП) задаються напрямки пошуку і визначаються значення функціоналу C в точках $\Psi_s(j) \pm \gamma\zeta$. Рішення полягає у виборі кроку в напрямку зменшення цього функціоналу:

$$\Psi_s(j+1) = \Psi_s(j) - \omega\zeta \{C[\Psi_s(j) + \gamma\zeta] - C[\Psi_s(j) - \gamma\zeta]\}, \quad (8)$$

де ω, ζ, γ – параметри, що визначають сфери прийняття рішення (ω), збору інформації (γ) та одиничний випадковий напрям (ζ). У загальному випадку параметри в (8) можуть змінюватися (адаптуватися) до процедури пошуку і виду гіперповерхні прийнятого функціоналу.

Розвитком методу ПВП є метод імітації відпалу (МІВ), який відображає поведінку розплавленого матеріалу при затвердінні із застосуванням процедури керованого охолодження (відпалу). У процесі відпалу кристалізація розплаву супроводжується глобальним зменшенням його енергії, однак допускається її зростання на деякий час. Завдяки цьому можливий вихід з пасток локальних мінімумів енергії, що виникають при реалізації процесу.

В алгоритмах МІВ задаються напрямки пошуку і визначаються значення функціоналу C в точках $\Psi_s(j) \pm \nu\tau$. Рішення полягає у виборі кроку в напрямку зменшення цього функціоналу:

$$\Psi_s(j+1) = \Psi_s(j) - \omega\nu \{C[\Psi_s(j) + \nu\tau] - C[\Psi_s(j) - \nu\tau]\}, \quad (9)$$

де ω, ν, τ – параметри, що визначають сфери прийняття рішення (ω), зміну поточного рішення (ν) і зменшення температури (τ).

Метод порогового прийняття (МПП) використовує підхід, схожий з МІВ, але замість того, щоб вибрати нові точки, які оптимізують критерій з певною ймовірністю, цей метод обирає все нові точки нижче встановленого порогу. Таким чином, поріг і температура систематично знижені, що дозволяє уникнути ймовірнісних обчислень, і може визначити оптимум швидше, ніж в МІВ.

Розвитком пошукових методів є еволюційні алгоритми, серед яких найбільш поширені генетичні алгоритми (ГА), які моделюють розвиток біологіч-

ної популяції на рівні геномів: мутації структури і параметрів, їх схрещування (розмноження) [6]:

$$\Psi_s(j+1) = \Psi_s(j) + \delta\Psi_s(j), \quad (10)$$

і правило відбору, що дозволяє виявляти їх сприятливі варіації, за допомогою яких будується послідовність поліпшених рішень.

Більшість задач, що вирішуються за допомогою ГА, мають один критерій оптимізації. Багатокритеріальна оптимізація (БО) заснована на знаходженні рішення, одночасно оптимізуючого більш ніж одну функцію. У цьому випадку шукається певний компроміс, в ролі якого виступає рішення, оптимальне в сенсі Парето. При БО, що використовує ГА, вибирається не одна хромосома, що представляє собою оптимальне рішення в звичайному сенсі, а безліч хромосом, оптимальних в сенсі Парето. Користувач має можливість вибрати оптимальне рішення з цієї безлічі [7]:

$$k \cdot \Psi_s(j+1) = k \cdot (\Psi_s(j) + \delta\Psi_s(j)), \quad (11)$$

де $k \geq 2$ – число розглянутих критеріїв.

Як критерій параметричної оптимізації використовують критерій регулярності, що заснований на поділі даних на навчальну А і перевірочну (В) вибірки [8]:

$$C_{\text{рег}} = \frac{\|Y_B^*[m+n] - \hat{Y}_B[m+n]\|}{\|Y_B^*[m+n]\|}, \quad (12)$$

де m – глибина пам'яті; n – глибина прогнозу.

Як критерій структурної оптимізації використовують критерій незміщеності (мінімуму зсуву), який не чутливий до рівня шуму у вхідних даних і при збільшенні завад їх мінімум не зміщується в область простіших моделей [8]:

$$C_{\text{см}} = \frac{\|\hat{Y}_A[m+n] - \hat{Y}_B[m+n]\|}{\|Y^*[m+n]\|}, \quad (13)$$

де $\hat{Y}_A[m+n]$ і $\hat{Y}_B[m+n]$ – виходи моделей, які навчені на вибірках А і В, відповідно.

При визначенні структур моделей складних систем найбільш продуктивним є спостереження їх вхідних і вихідних змінних з використанням апроксимацій у вигляді функціональних рядів Вольтера, поліномів Колмогорова-Габора, блочно-орієнтованих моделей тощо [9].

У блочно-орієнтованих моделях мережевий трафік представляється шляхом композиції лінійного динамічного (ЛДБ) і нелінійного статичного (НСБ) блоків, наприклад, у вигляді моделей Вінера, Гамерштейна або їх комбінацій [10].

Модель Вінера містить послідовно з'єднані нелінійний статичний і лінійний динамічний блоки (рис. 2). На рис. 2 ЛДБ – лінії затримки Т, величини яких (глибини пам'яті) визначаються розмірністю вхідних d_i і вихідних $d_{\hat{Y}}$ змінних, а у якості НСБ

використовуються традиційні засоби: поліноми, та інтелектуальні – НМ, системи з нечіткою логікою. Входом моделей є вектори спостережень $\{z_i[k]\} \in \tilde{Z}[k]$ для моментів часу k , а виходом – його прогноз на n тактів ($\hat{Y}[k+n]$).

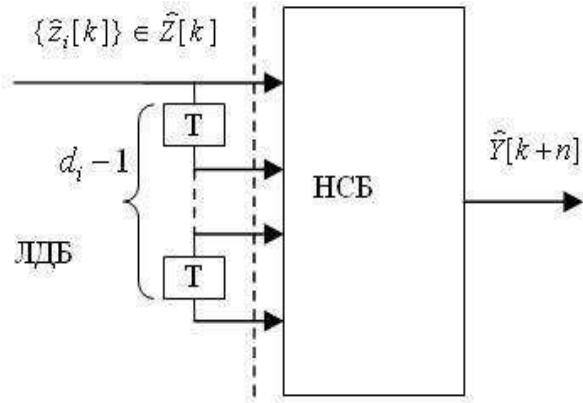


Рис. 2. Структура моделі Вінера

Вибір методу параметричної оптимізації обмежений вибором типу базисних функцій. Рівняння (6) на основі НМ прямого поширення (НМПП) із прихованим шаром пропонується наводити у вигляді:

$$\hat{Y}[m+n] = \sum_{\tau \in P} F_{\hat{Y}} \left\{ \sum_{l \in Q} w_l[\tau] \cdot F_l \left(\sum_{m \in Q} w_{l,k}[\tau] \cdot y_k[m-\tau] \right) \right\}, \quad (14)$$

де P – множина глибини пам'яті відповідних входів; $F_{\hat{Y}}$ – активаційна функція вихідного шару НМ; Q – множина входів нейронів; l – порядковий номер входу вихідного шару НМ; w_l – вагові коефіцієнти вихідного шару; F_l – активаційна функція нейронів прихованого шару; k – порядковий номер входу НМ; $w_{l,k}$ – вагові коефіцієнти зв'язку k -го входу і l -го нейрона; y_k – вхід НМ.

Структурними характеристиками НМ (14) є – $\{T_s, P, P_{\text{пр}}, F_{\hat{Y}}, F_l, r_s, M_{\text{по}}\} \subset \Phi$, де T_s – тип структури, $r_s \subset Q$ – розмір прихованого шару, $M_{\text{по}}$ – метод параметричної оптимізації (функція навчання НМ), $P_{\text{пр}}$ – глибина прогнозу. При цьому параметрами НМ є $\{w_l, w_{l,k}\} \subset a$. ДО НМПП відносяться перцептрони, каскадні НМ, вейвнети тощо [11].

Прогнозування за допомогою НМ із радіальними базисними функціями (РБФ [12]) виконується згідно рівняння:

$$\hat{Y}[m+n] = \sum_{\tau \in P} F_{\hat{Y}} \left\{ \sum_{l,k \in Q} w_l \cdot F_l(\theta_l, \|y_k[m-\tau] - v_l\|) \right\}, \quad (15)$$

де θ_l, v_l – параметри РБФ l -го нейрона прихованого шару.

Структурні характеристики НМ (15) – $\{T_s, P, P_{pr}, F_{\hat{Y}}, F_L, r_s, M_{po}\} \subset \Phi$, а її параметри – $\{w_l, \theta_l, v_l\} \subset a$.

Гібридну НМ із нечіткою логікою (Anfis [13]) пропонується наводити у вигляді:

$$\hat{Y}[m+n] = \sum_{\tau \in P} \sum_{k \in Q} \beta_k[\tau] \cdot \alpha_k[m-\tau], \quad (16)$$

де $\beta_k[\tau] = U_k^{-1}(\alpha_k[\tau] / \sum_k \alpha_k[\tau])$, $U = U(a_U)$,

$\alpha_k[m-\tau] = T_{norm} \{L_{l,k}(y_k[m-\tau])\}$, $L = L(a_L)$.

Тут U_k^{-1} – функція, зворотна функції належності проміжного виходу k мережі з параметрами a_U ; α_k – значення проміжного виходу; T_{norm} – довільна t -норма моделювання логічної операції «І»; $L_{l,k}$ – функція належності нечіткого правила l входу k із параметрами a_L .

Структурні характеристики НМ (16) – $\{T_s, P, P_{pr}, U_k, L_{l,k}, r_p, M_{po}\} \subset \Phi$, де $r_p \subset Q$ – кількість правил розкладання за входами, а параметри – $\{a_U, a_L\} \subset a$.

Структурна оптимізація здійснюється за допомогою методів глобальної оптимізації, при цьому генеруються структури моделей-претендентів (базисних функцій зі своїми структурними характеристиками), а потім виконується відбір кращих з них за критерієм структурної оптимізації. Результатом є модель оптимальної структури, знайдена за допомогою алгоритму глобальної оптимізації.

Параметрична оптимізація, полягає у визначенні параметрів цієї моделі шляхом її навчання за критеріями параметричної оптимізації на всій вибірці вихідних даних.

Моделювання розв'язання задачі ідентифікації та прогнозування трафіку згідно запропонованої методики виконувалося за допомогою розроблених програм в середовищі Matlab на основі експериментальних даних – трафіку, що передається через мережу Інтернет [14]. Дані являють собою залежність розміру Ethernet кадрів в байтах від часу. Для їх приведення до еквідистантної шкали за часовою віссю було проведено процедуру агрегації з кроком 5 с.

Глибина прогнозу була прийнята $n = 3$ такти, а глибина пам'яті – 4. Як критерій параметричної оптимізації використовувався критерій (12), а структурної – критерій (13). Як глобальні методи оптимізації застосовувались ГА, БО, ПВП, МІВ, МПП. При цьому використовувалась структура моделей Гаммерштейна-Вінера [10].

При структурній оптимізації варіювалися наступні характеристики моделі:

- тип базисної функції – (14), (15) і (16);
- кількість нейронів в прихованому шарі;
- тип функції активації прихованого шару;
- тип алгоритму навчання НМ.

В результаті моделювання встановлено, що ГА має найвищу швидкість збіжності (ГА виходить в область оптимальних рішень на перших поколіннях, МПП – в середньому після 5 ітерацій, МІВ – після 15, а БО і ПВП – після 20 ітерацій). Алгоритм МПП виявив найвищу швидкість (0,6 с на ітерацію при 0,7 с на ітерацію в МІВ, 2,2 с на ітерацію в ПВП, 19,3 с на покоління в ГА і 27,4 с на покоління в БО). Алгоритм БО виявив найкращу збіжність (значення критерію (13) при його використанні – 0,019, на відміну від 0,032 при МПП, 0,042 при ГА, 0,057 при ПВП і 0,077 при МІВ).

Результат параметричної оптимізації трафіку в ІТС наведено на рис. 3.




Рис. 3. Результат параметричної оптимізації мережевого трафіку

Встановлено, що мінімуму критерію (12) відповідають базисні функції у вигляді каскадної НСПР. При цьому кількість нейронів в прихованому шарі – 73, функція активації прихованого шару – конкуруюча з м'яким максимумом, вихідного шару – лінійна, алгоритм навчання НМ – градієнтного спуску з вибором параметра швидкості налаштування [11]. При цьому значення критерію (12) склало – 0,0361, що менше похибок відомих моделей трафіку в ІТМ.

Статистична перевірка за непараметричним критерієм знаків дозволила встановити адекватність експериментальних сигналів з рівнем значущості 0,01.

Висновки

Розроблено методику інтелектуальної ідентифікації та прогнозування трафіку в ІТМ, що полягає у визначенні глибини пам'яті і прогнозу моделі, а

також використання композиції методів структурної і параметричної оптимізації.

Шляхом моделювання трафіку в ІТМ показано ефективність застосування цієї методики – інтелектуальні прогнозуючі моделі, побудовані таким чином, мають підвищену точність (відносна похибка апроксимації експериментальних сигналів не пере-

вищує 3,6%), а статистична перевірка підтвердила адекватність отриманих результатів.

Подальші дослідження мають бути спрямовані на розробку алгоритмів керування передачею в інформаційних телекомунікаційних мережах на основі ідентифікації їх трафіку.

Список літератури

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. – P. 835-846.
2. Будкова Л.В. Комплексна оцінка характеристик та ідентифікація трафіку в інформаційних телекомунікаційних мережах / Л.В. Будкова, В.І. Корнієнко // *Системи обробки інформації*. – Х.: ХУ ПС, 2013. – № 2 (109). – С. 207-211.
3. Корнієнко В.І. Комплексна оцінка, ідентифікація та прогнозування складних нелінійних процесів / В.І. Корнієнко, І.Г. Гуліна, Л.В. Будкова // *Науковий вісник Національного гірничого університету*. – 2013. – № 6. – С. 124-131. – ISSN 2071-2227.
4. Schuster S.G. *Deterministic Chaos: An Introduction* / S.G. Schuster, W. Just. – Weinheim: WILEY-VCH Verlag GmbH & Co, 2005. – 312 с.
5. Cencini M. *Chaos: From Simple Models to Complex Systems* / M. Cencini, F. Cecconi, A. Vulpiani. – Hackensack, NJ: World Scientific, 2010. – 460 p.
6. Nelles O. *Nonlinear System Identification: From Classical Approaches to Neural and Fuzzy Models* / O. Nelles. – Berlin: Springer, 2001. – 785 p.
7. Zitzler E. *Evolutionary Multiobjective Optimization* / E. Zitzler // *Handbook of Natural Computing*. – Springer-Verlag Berlin Heidelberg, 2012. – P. 871-904.
8. Ivakhnenko A.G. *Inductive learning algorithms for complex systems modeling* / A.G. Ivakhnenko, H.R. Madala. – London, Tokyo: CRC Press, 1994. – 384 p.
9. Ljung L. *Perspectives on system identification* / L. Ljung // *Annual Reviews in Control*. – 2010. – № 34. – P. 1-12.
10. Герасіна О.В. Обґрунтування блочно-орієнтованих структур моделей трафіку в інформаційних телекомунікаційних мережах / О.В. Герасіна // *Проблеми інформаційних технологій*. – 2013. – № 2(014). – С. 26-29.
11. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский; пер. с польск. И.Д. Рудинского. – М.: Горячая линия-Телеком, 2006. – 452 с.
12. Keller J. *Fundamentals of Computational Intelligence: Neural Networks, Fuzzy Systems, and Evolutionary Computation* / J. Keller, D. Liu, D. Foge. – Hoboken, NJ: John Wiley & Sons Inc., 2016. – 378 p.
13. Штовба С.Д. Проектирование нечетких систем средствами Matlab / С.Д. Штовба. – М.: Горячая линия-Телеком, 2007. – 288 с.
14. Архів трафіку: <http://ita.ee.lbl.gov>.

References

1. Crovella, M.E. and Bestavros, A. (1997), "Self-Similarity in World Wide Web Traffic: Evidence and Possible Causes", *IEEE Transactions on Networking*, Vol. 5, No. 6, pp. 835-836.
2. Budkova, L.V. and Korniyenko, V.I. (2013), "Kompleksna otsinka kharakterystyk ta identyfikatsiya trafiku v informat-siynykh telekomunikatsiynykh merezhakh" [Complex estimation of characteristics and traffic identification in information telecommunication networks], *Information processing systems*, No. 2(109), pp. 207-211.
3. Korniyenko, V.I., Hulina, I.H. and Budkova, L.V. (2013), "Kompleksna otsinka, identyfikatsiya ta prohozuvannya skladnykh nelineynykh protsesiv" [Complex estimation, identification and prediction of complicated nonlinear processes], *Scientific Bulletin of National Mining University*, No. 6, pp. 124-131.
4. Schuster, S.G. and Just, W. (2005), *Deterministic Chaos: An Introduction*, WILEY-VCH Verlag GmbH & Co, Weinheim, 312 p.
5. Cencini, M., Cecconi, F. and Vulpiani, A. (2010), *Chaos: From Simple Models to Complex Systems*, World Scientific, Hackensack, NJ, 460 p.
6. Nelles, O. (2001), *Nonlinear System Identification: From Classical Approaches to Neural and Fuzzy Models*, Springer, Berlin, 785 p.
7. Zitzler, E. (2012), *Evolutionary Multiobjective Optimization*, *Handbook of Natural Computing*, Springer-Verlag, Berlin, Heidelberg, pp. 871-904.
8. Ivakhnenko, A.G. and Madala, H.R. (1994), *Inductive learning algorithms for complex systems modeling*, CRC Press, London, Tokyo, 384 p.
9. Ljung, L. (2010), *Perspectives on system identification*, *Annual Reviews in Control*, No. 34, pp. 1-12.
10. Gerasina, O.V. (2013), "Obgruntuvannya blochno-oriyentovanykh struktur modeley trafiku v informat-siynykh telekomunikatsiynykh merezhakh" [Justification block-oriented structures of models of traffic in information telecommunication networks], *Problems of Information Technologies*, No. 2(014), pp. 26-29.

11. Rutkovskaya, D., Pylyn'skyu, M. and Rutkovskyy, L. (2006), “*Nejronnye seti, geneticheskie algoritmy i nechetkie sistemy*” [Neural networks, genetic algorithms and fuzzy systems], Hotline–Telecom, Moscow, 452 p.
12. Keller, J., Liu, D. and Foge, D. (2016), *Fundamentals of Computational Intelligence: Neural Networks, Fuzzy Systems, and Evolutionary Computation*, John Wiley & Sons Inc., Hoboken, NJ, 378 p.
13. Shtovba, S.D. (2007), “*Proektyrovanye nechetkykh system sredstvamy Matlab*” [Design of fuzzy systems by means of Matlab], Hotline–Telecom, Moscow, 288 p.
14. Traffic archive, www.ita.ee.lbl.gov.

Надійшла до редколегії 13.02.2018

Схвалена до друку 20.03.2018

Відомості про автора:

Герасіна Олександра Володимирівна
кандидат технічних наук доцент
доцент Державного вищого навчального закладу
«Національний гірничий університет»,
Дніпро, Україна
<https://orcid.org/0000-0002-8196-0657>
e-mail: gerasina.alexandra@gmail.com

Information about the author:

Aleksandra Gerasina
Candidate of Technical Sciences Associate Professor
Senior Lecturer of State Higher Education Institution
«National Mining University»,
Dnipro, Ukraine
<https://orcid.org/0000-0002-8196-0657>
e-mail: gerasina.alexandra@gmail.com

**МЕТОДИКА ИНТЕЛЛЕКТУАЛЬНОЙ ИДЕНТИФИКАЦИИ И ПРОГНОЗИРОВАНИЯ ТРАФИКА
В ИНФОРМАЦИОННЫХ ТЕЛЕКОММУНИКАЦИОННЫХ СЕТЯХ**

А.В. Герасина

Предложена методика интеллектуальной идентификации и прогнозирования трафика в информационных телекоммуникационных сетях, которая состоит из определения размерностей моделей трафика, а также его идентификации и прогнозирования с использованием систем искусственного интеллекта, обоснования структур моделей и композиции методов глобальной и локальной оптимизации. Путем моделирования оценена эффективность использования предложенной методики на примере идентификации и прогнозирования экспериментальных данных – трафика, передаваемого через сеть Интернет.

Ключевые слова: идентификация, прогнозирование, трафик, нейронные сети, нечеткая логика, структуры моделей, глобальная оптимизация.

**METHOD OF INTELLECTUAL IDENTIFICATION AND PREDICTION OF TRAFFIC
IN INFORMATION TELECOMMUNICATION NETWORKS**

O. Gerasina

The method of intellectual identification and prediction of traffic in information telecommunication networks is proposed. It consists of the definition of dimensions of traffic models, its identification and prediction using artificial intelligence systems, choice of block-oriented structures of models and the composition of global and local optimization methods. Determination of dimensions of models is done by calculation of correlation entropy, correlation interval of predictability, correlation dimension of the attractor, the dimension of attachment to the attractor. For global optimization methods applied genetic algorithms, multiobjective optimization, direct search, simulated annealing and threshold acceptance. Models of Wiener, Hammerstein, and their compositions are used as block-oriented models. As the basis functions are used cascaded feedforward neural network, neural network with radial basis functions and hybrid network with fuzzy logic. For parametric optimization was used the criterion of regularity, calculated on the test sample, and for the global – the criterion of minimum bias, based on the analysis of solutions. By modeling, the efficiency of using the proposed method is estimated using the example of identification and prediction of experimental data - traffic transmitted via the Internet.

Keywords: identification, prediction, traffic, neural networks, fuzzy logic, model structures, global optimization.