

DOI: <https://doi.org/10.36910/6775-2524-0560-2022-47-15>

УДК 004.620

Козак Євген Борисович, магістр в галузі комп'ютерних наук, розробник програмного забезпечення, інженер-програміст GAN Inc.<https://orcid.org/0000-0001-8616-8215>

ПРОГНОЗУВАННЯ ТРАФІКУ КОРПОРАТИВНОЇ МЕРЕЖІ ІЗ ЗАСТОСУВАННЯМ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ

Козак Є.Б. Прогнозування трафіку корпоративної мережі із застосуванням штучних нейронних мереж. У статті досліджено прогнозування трафіку корпоративної мережі із застосуванням штучних нейронних мереж. Наведено модель, яка здатна аналізувати та прогнозувати Інтернет-трафік через IP-мережі шляхом порівняння деяких навчальних алгоритмів із використанням статистичних критеріїв. Визначено історичну складову становлення та розвитку складних систем, та запропоновано поняття мережевого трафіку. Наголошено, що нейронні мережі успішно використовуються для моделювання складних нелінійних систем та прогнозування сигналів для широкого кола інженерних застосувань. Вони є однією з найкращих альтернатив для моделювання та прогнозування параметрів трафіку, можливо тому, що вони можуть апроксимувати майже будь-яку функцію незалежно від ступеня не лінійності та без попереднього знання її функціональної форми. Розроблено модель нейронної мережі із позначенням основних входів та виходу. У статті запропоновано для прогнозування трафіку корпоративної мережі використовувати багатошаровий перцептрон на основі методу зворотного поширення. Наведено опис даного методу, його особливості та основні алгоритми навчання. Підкреслено, що алгоритм зворотного поширення помилки використовує градієнти функцій активації нейронів, щоб повернути похибку, яка вимірюється на виході нейронної мережі, і обчислити градієнти вихідної помилки по кожній вазі в мережі. Запропоновано математичну складову кожного з описаних алгоритмів навчання штучної нейронної мережі з порівнянням у дієвості та продуктивності. Наведено способи обчислення константи, які відрізняє різні версії спряженого градієнта. Пропонується наведену модель з використанням двох алгоритмів Левенберг Марквардт та алгоритму еластичного зворотного поширення застосовувати для ідентифікації та управління Інтернет-трафіком корпоративної мережі та як фундаментальний інструмент для прогнозування Інтернет-трафіку корпоративної мережі на у різних проміжках часу.

Ключові слова: корпоративна мережа, інтернет, трафік, штучна нейронна мережа, передача пакетів.

Kozak Y. Prediction of corporate network traffic using artificial neural networks. The article investigates the forecasting of corporate network traffic with the use of artificial neural networks. A model that is able to analyze and predict Internet traffic over IP networks by comparing some training algorithms using statistical criteria is presented. The historical component of formation and development of complex systems is determined, and the concept of network traffic is offered. It is emphasized that neural networks are successfully used for modeling complex nonlinear systems and signal prediction for a wide range of engineering applications. They are one of the best alternatives for modeling and predicting traffic parameters, possibly because they can approximate almost any function regardless of the degree of nonlinearity and without prior knowledge of its functional form. A neural network model with the designation of the main inputs and outputs has been developed. The article proposes to use a multilayer perceptron based on the backpropagation method to predict corporate network traffic. The description of this method, its features and basic algorithms of training are given. It is emphasized that the inverse error propagation algorithm uses the gradients of the neuron activation functions to return the error measured at the output of the neural network and to calculate the gradients of the original error for each weight in the network. The mathematical component of each of the described algorithms of training of an artificial neural network with comparison in efficiency and productivity is offered. Methods for calculating the constant that distinguish different versions of the conjugate gradient are given. It is proposed to use this model using two Levenberg Marquardt algorithms and the elastic backpropagation algorithm to identify and manage corporate Internet traffic and as a fundamental tool for forecasting corporate Internet traffic at different intervals.

Key words: corporate network, internet, traffic, artificial neural network, packet transmission.

Постановка проблеми. Складні мережі, на сьогодні, є найбільш обговорюваною темою. Складні мережі, це мережі, що характеризують багато природних та штучних систем, таких як Інтернет, авіатранспортні системи, інфраструктура енергетичних мереж та Всесвітня павутина. Дійсно, моделювання трафіку є фундаментальним для оцінки продуктивності мережі та розробки схеми управління мережею, що є вирішальним для успіху високошвидкісних мереж. Останній факт пояснюється тим, що пропускна здатність мережевого трафіку допоможе кожному веб-майстру оптимізувати свій веб-сайт, максимізувати конверсії в Інтернеті та вести відстеження кампаній, що пропускної здатності. Крім того, моніторинг ефективності та продуктивності IP-мереж на основі точних та вдосконалених вимірювань трафіку є важливою темою, в якій дослідження повинні вивчити нову схему моніторингу мережевого трафіку, для підвищення ефективності функціонування. Отже, актуальною є модель руху з простим виразом, яка здатна точно фіксувати статистичні характеристики фактичного мережевого трафіку.

Аналіз останніх досліджень і публікацій. Застосування штучних нейронних мереж, як пріоритетного та актуального напрямку сьогодення на сторінках своїх праць розглядало чимало як зарубіжних так і вітчизняних вчених. А. В. Собчук та Ю. І. Олімпієва [1] розкрили питання

застосування нейромереж для забезпечення функціональної стійкості виробничих процесів. Е. М. Бовда [2] проаналізував існуючі підходи та методи прогнозування стану телекомунікаційної мережі, розглянув завдання системи управління телекомунікаційною мережею. 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 запропонувала О. В. Герасіна [3]. Д. О. Жуковська та В. Я. Воропаєва [4] запропонували метод прогнозування телекомунікаційного трафіку за допомогою нейронних мереж з використанням нелінійної авторегресійної моделі, що дозволяє отримати прогнозне значення періодів істотних змін часткового співвідношення трафіків різних типів для подальшого використання при динамічному розподілі пропускної здатності супутникового каналу зв'язку. У роботі [5] запропоновано використовувати нейронну мережу у інтелектуальному алгоритмі багатокритеріального вертикального хендверу. Після створення програмного або апаратного рішення нейронної мережі необхідно створити математичну модель та виконати навчання мережі. Пропонована у даній роботі нейронна мережа представляє собою багатошаровий перцептрон. Проведено моделювання роботи нейронної мережі у програмі Matlab.

Із зарубіжних авторів варто відзначити такі роботи як: А. S. Mul-la, В. Т. Jadhav [6], В. Tran, S. Picek, В. Хue [7], Keller, J., Liu, D. and Foge, D. [8], Т. Hamed, J. В. Ernst, S. С. Kremer [9], N. Mokari, P. Haji-pour, L. Mohammadi et al. [10], С. Koliias, А. Stavrou, J. Voas, I. Vojanova, R. Kuhn [11] та інші.

Проте, враховуючи описані наукові набутки, за темою, питання прогнозування трафіку корпоративної мережі із застосуванням штучних нейронних мереж залишається відкритим та потребує детального опрацювання.

Постановка завдання. Розкрити принципи прогнозування трафіку корпоративної мережі із застосуванням штучних нейронних мереж на основі багатошарового перцептрона для виявлення та розробки моделі, яка здатна аналізувати та прогнозувати Інтернет-трафік через IP-мережі шляхом порівняння деяких навчальних алгоритмів із використанням статистичних критеріїв.

Викладення основного матеріалу дослідження. З 1950-х років було розроблено багато моделей для вивчення складних явищ мережевого трафіку, які з кожним роком масштабувалися та виходили на новий рівень [12]. Необхідність точного прогнозування параметрів трафіку вже давно визнана у науковій літературі [13].

Основною мотивацією тут є отримання кращого розуміння характеристик мережевого трафіку. Одним із підходів, що використовується для профілактичного контролю, є прогнозування найближчого майбутнього трафіку в мережі, а потім вжиття відповідних дій, таких як контроль розмірів буферів. Кілька робіт, розроблених у літературі, зацікавлені у вирішенні проблеми підвищення ефективності та результативності моніторингу мережевого трафіку шляхом попереднього прогнозування потоку пакетів даних. Тому, точна модель прогнозування мережевого руху повинна мати можливість фіксувати основні параметри руху, наприклад коротко- та далекозалежність, самоподібність у великому масштабі та мультифрактал у малому. На сьогодні, враховуючи наукові здобутки, запропоновано кілька схем прогнозування трафіку корпоративної мережі [14]. Серед запропонованих схем прогнозування найбільш перспективними є схеми, засновані на нейромережах, оскільки нейронні мережі продемонстрували більш ніж прийнятну продуктивність із відносно простою архітектурою в різних областях.

Нейронні мережі успішно використовуються для моделювання складних нелінійних систем та прогнозування сигналів для широкого кола інженерних застосувань. Вони є однією з найкращих альтернатив для моделювання та прогнозування параметрів трафіку, можливо тому, що вони можуть апроксимувати майже будь-яку функцію незалежно від ступеня не лінійності та без попереднього знання її функціональної форми.

Штучні нейронні мережі – це абстрактне представлення реальної нервової системи, що складається з набору нейронних одиниць, з'єднаних між собою за допомогою аксонових зв'язків, які дуже схожі на дендрити та аксони в біологічних нервових системах [15].

Крім того, штучні нейронні мережі – це великий клас архітектури паралельної обробки, яка може імітувати складні та нелінійні процесори, що називаються нейронами. Штучні нейронні мережі, як апроксиматор функції, корисний, оскільки він може наблизити бажану поведінку без необхідності вказувати певну функцію. Це є великою перевагою штучних нейронних мереж порівняно з багатовимірною статистикою. Такі мережі можна навчити досягти, з певного входу,

конкретного цільового результату, використовуючи відповідний метод навчання, поки вихід мережі не відповідає цілі. Крім того, нейронні мережі навчаються досвідом, коли до мережі застосовується невідомий вхід, він може бути узагальнений з минулим досвідом і буде створений новий результат.

Структура штучної нейронної мережі деревоподібна, вона складається з: вхідного шару, вихідного шару та проміжного прихованого шару з відповідними нейронами. Кожен шар з'єднаний з наступним шаром нейроном, що породжує велику кількість зв'язків. Кожне з'єднання має вагу, пов'язану з цим з'єднанням. Прихований рівень навчається забезпечувати подання даних для входів. Вихід нейрона в прихованому або вихідному шарі обчислюється шляхом застосування функції активації до зваженої суми вхідних даних до цього нейрона (рис. 1). Спочатку модель штучної нейронної мережі повинна бути «навчена», використовуючи випадки з відомими результатами, а потім вона буде коригувати зважування різних вхідних змінних з часом для уточнення вихідних даних. Дані перевірки використовуються для оцінки ефективності моделі мережі.

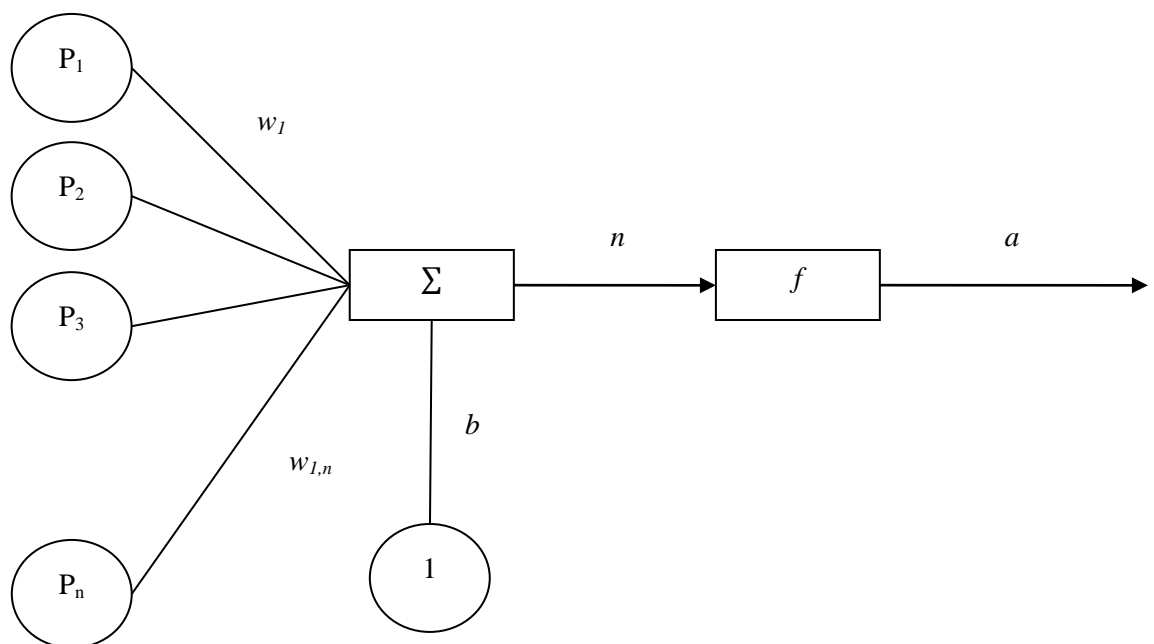


Рисунок 1 – Модель нейронної мережі

Для прогнозування трафіку корпоративної мережі пропонується використовувати багатозаровий перцептрон на основі методу зворотного поширення. Багатозаровий перцептрон є найбільш часто використовуваною технікою нейронних мереж, що дозволяє виконувати найрізноманітніші програми. Ідентифікація нейронних мереж з багатозаровим перцептронном вимагає двох типів етапів. Перший – це визначення структури мережі. Випробувано різні мережі з прихованим одним шаром, і функцією активації, яка використовується в цьому дослідженні, є сигмовидна функція, що описується як:

$$f(x) = \frac{1}{1 + \exp(-x)}$$

Другий етап – ідентифікація параметрів.

Навчання мережі можна розглядати як проблему наближення функції, при якій параметри мережі коригуються під час навчання, намагаючись мінімізувати (оптимізувати) функцію помилок між мережевим виходом та бажаним виходом. Питання алгоритму навчання є дуже важливим для багатозарового перцептронну. Більшість добре відомих алгоритмів навчання нейронної мережі базуються на реальних градієнтних обчисленнях. Серед них найбільш популярним та широко використовуваним алгоритмом навчання є зворотне поширення. Метод зворотного поширення помилки, також відомий як алгоритм розповсюдження помилок, заснований на правилі навчання штучної нейронної мережі.

Алгоритм зворотного поширення помилки використовує градієнти функцій активації нейронів, щоб повернути похибку, яка вимірюється на виході нейронної мережі, і обчислити градієнти вихідної помилки по кожній вазі в мережі. Згодом ці градієнти використовуються для оновлення ваг штучної нейронної мережі.

Стандартний навчальний процес алгоритму розповсюдження помилок може бути реалізований шляхом мінімізації функції помилок E , яка визначається як:

$$E = \sum_{p=1}^p \sum_{j=1}^{N_M} (y_{j,p}^M - t_{j,p})^2 = \sum_{p=1}^p E_p$$

де $y_{j,p}^M - t_{j,p}$ – квадратична різниця між фактичним вихідним значенням на нейроні j -го вихідного шару для шаблону p та цільовим вихідним значенням. Скаляр p є індексом над парами вхід-вихід. Загальною метою навчання є пошук оптимального набору ваг з'єднань таким чином, щоб помилки вихідних даних мережі були мінімізовані.

Для спрощення формулювання рівнянь нехай w є n -мірним ваговим вектором усіх ваг з'єднань та зсувів. Відповідно, рівняння оновлення ваги для будь-якого навчального алгоритму має ітераційну форму. У кожній ітерації синаптичні ваги змінюються у протилежному напрямку до градієнта функції витрат.

Для обчислення градієнта для двох випадків застосовується алгоритм поширення помилок, що підсумовується наступним чином

$$w(k+1) = w(k) + a_k d_k$$

де $w(k) = (w_1(k), \dots, w_n(k))^T$ – вектор ваги в k ітераціях, n – кількість синаптичних з'єднань мережі, k – індекс ітерацій, a_k – це швидкість навчання, яка регулює розмір градієнта кроку, а d_k – напрямок пошуку, який задовольняє умові спуску.

Напрямок спуску заснований на мінімізації функції помилки, а саме $d_k = -g_w$

де $g_w(k) = \left(\frac{\partial E}{\partial w_1(k)}, \dots, \frac{\partial E}{\partial w_n(k)} \right)^T$ – градієнт розрахункової похибки в w .

Протягом усього навчання зі стандартним спуском швидкість навчання залишається незмінною, що робить алгоритм дуже чутливим до належного встановлення темпу навчання. Дійсно, алгоритм може коливатися і ставати нестабільним, якщо швидкість навчання встановлена занадто високою. Але, якщо швидкість навчання занадто мала, алгоритм буде довго збігатися.

Основний алгоритм зворотного розповсюдження регулює вагу в напрямку спуску, в якому функціональна здатність найшвидше зменшується. Хоча функція швидше зменшується вздовж вектора градієнта, це не обов'язково забезпечує найшвидшу конвергенцію. В алгоритмах спряженого градієнта виконується пошук по напрямку спряженого градієнта, щоб визначити розмір кроку, який мінімізує функцію продуктивності вздовж цієї лінії.

Методи спряженого градієнта – це клас дуже важливих методів мінімізації гладких функцій, особливо коли розмірність велика.

Принципова перевага методу спряженого градієнта полягає в тому, що вони не вимагають зберігання будь-яких матриць, як у методі Ньютона, або як у квазіньютонівських методах, і вони розроблені для швидкого зближення, ніж метод спуску.

Існує чотири типи спряжених градієнтних алгоритмів, які можна використовувати для навчання.

Всі алгоритми спряженого градієнта починаються з пошуку в напрямку спуску (мінус градієнта) на першій ітерації:

$$p_0 = -g_w(0)$$

де p_0 – початковий градієнт пошуку, а g_0 – початковий градієнт.

Потім виконується пошук лінії, щоб визначити оптимальну відстань для переміщення вздовж поточного напрямку пошуку:

$$w(k+1) = w(k) + a_k d_k$$

Наступний напрямок пошуку визначається таким чином, щоб він був спряжений до попередніх напрямків пошуку. Загальна процедура визначення нового напрямку пошуку полягає в поєднанні нового напрямку спуску з попереднім напрямком пошуку:

$$d_k = -g_w(k) + \beta_k d_{k-1}$$

β_k – параметр, який слід визначити так, що d_k стає k -спряженим напрямком.

Спосіб обчислення константи k відрізняє різні версії спряженого градієнта, а саме: оновлення Флетчера-Рівза, кон'югований градієнт з оновленнями Полака-Ріб'єра, градієнт з перезапусками Пауелла-Біла та масштабований алгоритм спряженого градієнта.

1) Спряжений градієнт з оновленнями Флетчера-Рівза

Процедура оцінки константи β_k за допомогою оновлення Флетчера-Рівза обчислюється як:

$$\beta_k = \frac{g_w^T(k)g_w(k)}{g_w^T(k-1)g_w(k-1)}$$

являє собою відношення квадрата норми поточного градієнта до квадрата норми попереднього градієнта.

2) Спряжений градієнт з оновленнями Полака-Ріб'єра

Константа β_k обчислюється оновленням Полака-Ріб'єра як:

$$\beta_k = \frac{g_w^T(k)y_k}{g_w^T(k-1)g_w(k-1)}$$

де $y_k = g_w(k) - g_w(k-1)$ – внутрішній добуток попередньої зміни градієнта з поточним градієнтом, поділений на норму в квадраті попереднього градієнта.

3) Кон'югатний градієнт з перезапусками Пауелл-Біла

У спряжених градієнтних алгоритмах напрямок пошуку періодично скидається до від'ємного значення градієнта. Стандартна точка скидання виникає, коли кількість ітерацій дорівнює кількості мережових параметрів, але існують інші методи скидання, які можуть підвищити ефективність процесу навчання. Цей прийом перезапускається, якщо між поточним та попереднім градієнтом залишається дуже мало ортогональності:

$$|g_w^T(k-1)g_w(k)| \geq 0,2 \|g_w(k)\|^2$$

Якщо ця умова виконана, напрямок пошуку скидається до від'ємного значення градієнта.

4) Масштабований спряжений градієнт

Масштабований алгоритм спряженого градієнта вимагає лінійного пошуку на будь-якій ітерації, що викликає труднощі з обчисленнями, оскільки вимагає обчислення мережової реакції для всіх навчальних входів по кілька разів для кожного пошуку. Масштабований алгоритм спряженого градієнта поєднує в собі підхід моделі-довіри та підхід спряженого градієнта. Цей алгоритм був розроблений, щоб уникнути трудомісткого пошуку рядків. Константа обчислюється як:

$$\beta_k = \frac{|g_w(k+1)|^2 g_w^T(k+1)g_w(k)}{|g_w(k)|^2}$$

Алгоритм Левенберга-Марквардта є найбільш широко використовуваним алгоритмом оптимізації. Це ітераційний прийом, який визначає мінімум багатоваріантної функції, який виражається як сума квадратів нелінійних дійсних функцій [16]. Алгоритм Левенберга-Марквардта – це перший алгоритм, який поєднує градієнтний спуск та ітерації Гауса-Ньютона. Як і квазіньютонівські методи, алгоритм Левенберга-Марквардта був розроблений для наближення швидкості навчання другого порядку без необхідності обчислювати матрицю Гессе. Алгоритм Левенберга-Марквардта забезпечує рішення нелінійних задач мінімізації найменших квадратів. Коли функція ефективності має вигляд суми квадратів, тоді матрицю Гессе можна апроксимувати як:

$$H = J^T J$$

де J – матриця Якобі, яка містить перші похідні помилок мережі, а градієнт можна обчислити як:

$$g_w = J^T e$$

де матриця Якобі містить перші похідні помилок мережі щодо ваг та упереджень, а e – вектор помилок мережі.

Алгоритм Левенберга – Марквардта використовує наближення до матриці Гесса в наступному оновленні, подібному до Ньютона:

$$w_{k+1} = w_k - [J^T J + \mu I]^{-1} J^T e$$

де I – матриця тотожності, а μ – константа.

μ зменшується після кожного успішного кроку (зменшення функції продуктивності) і збільшується лише тоді, коли попередній крок збільшить функцію продуктивності. Таким чином, функція продуктивності завжди зменшується на кожній ітерації алгоритму.

Алгоритм еластичного зворотного розповсюдження

Метою алгоритму еластичного зворотного розповсюдження є усунення шкідливого впливу величин часткових похідних. Тому для визначення напрямку оновлення ваги використовується лише знак похідної. Дійсно, алгоритм еластичного зворотного розповсюдження змінює розмір кроку ваги, який приймається адаптивно. Механізм адаптації в алгоритмі еластичного зворотного розповсюдження не враховує величину градієнта, за певною вагою, а лише знак градієнта (позитивний чи негативний).

Алгоритм еластичного зворотного розповсюдження базується на модифікації кожної ваги значенням оновлення (або параметром навчання) таким чином, щоб зменшити загальну помилку. Значення оновлення для кожної ваги та зміщення збільшується, коли похідна функції продуктивності щодо цієї ваги має однаковий знак для двох послідовних ітерацій.

Принцип цього методу такий:

$$w_k - w_{k-1} = -\text{sign}(g_w(k-1))\Delta_k$$
$$\Delta_k = n^+ \Delta_{k-1} \text{ якщо } g_w(k-1) * g_w(k) > 0$$
$$\Delta_k = n^- \Delta_{k-1} \text{ якщо } g_w(k-1) * g_w(k) < 0$$

інакше $\Delta_k = \Delta_{k-1}$ де $0 < n^- < 1 < n^+$

Δ_k – значення оновлення ваги, яке змінюється відповідно до змін знака різниці ($w_k - w_{k-1}$) тієї ж ваги в k ітераціях. Значення оновлення та ваги змінюються після кожної ітерації.

Усі значення оновлення ініціалізуються до значення D_0 . Значення оновлення модифікується таким чином: якщо поточний градієнт ($g_k(k)$), помножений на градієнт попереднього кроку, є позитивним (тобто напрямок градієнта залишився незмінним), тоді значення оновлення множиться на значення n^+ (яке більше ніж один). Подібним чином, якщо добуток градієнта від'ємний, значення оновлення множиться на значення n^- (яке менше одиниці).

Висновки і перспективи подальших досліджень. У роботі досліджено прогнозування трафіку корпоративної мережі із застосуванням штучних нейронних мереж.

Запропоновано модель штучної нейронної мережі, яка заснована на багат шаровому перцептроні для прогнозування інтернет-трафіку через IP-мережі. Запропоновано низку алгоритмів навчання, які використовуються для оцінки ваги нейрона. Порівняння між деякими алгоритмами навчання демонструє ефективність алгоритмів Левенберг Марквардт та алгоритмів еластичного зворотного поширення із використанням статистичних критеріїв. Наведену модель з використанням алгоритму Левенберг Марквардт і алгоритму еластичного зворотного поширення можна успішно використовувати як адекватну модель для ідентифікації та управління Інтернет-трафіком корпоративної мережі. Крім того, модель можна застосовувати як фундаментальний інструмент для прогнозування Інтернет-трафіку у різний час.

Список бібліографічного опису

1. Собчук А. В. Застосування нейромереж для забезпечення функціональної стійкості виробничих процесів / А. В. Собчук, Ю. І. Олімпієва // Телекомунікаційні та інформаційні технології, 2020. № 2. С. 13-28.
2. Бовда, Е. М. Модель моніторингу та прогнозування стану телекомунікаційної мережі з використанням нечітких нейронних мереж / Е. М. Бовда // Збірник наукових праць [Текст] / [редкол.: Романюк В. А. (голов. ред.) та ін.]. Київ: ВІПІ, 2018. Вип. № 1. С.6-16.
3. Герасіна О. В. Методику інтелектуальної ідентифікації та прогнозування трафіку в інформаційних телекомунікаційних мережах / О. В. Герасіна // Державний вищий навчальний заклад «Національний гірничий університет», Дніпро, Системи обробки інформації, 2018, випуск 1 (152). С. 94-99.
4. Жуковська Д.О., Воропаєва В.Я. Метод пріоритетного управління радіо ресурсом супутникового каналу на основі прогнозування вхідного трафіку / Д.О. Жуковська, В.Я. Воропаєва // Наукові праці ДонНТУ. Серія: «Обчислювальна техніка та автоматизація» № 1(32)'2019. С. 79-93.
5. Семенова О. О. Застосування нейронної мережі у процедурі вертикального хендверу / О. О. Семенова, А. О. Семенов, О. О. Войцеховська // Інформаційні технології та комп'ютерна інженерія, 2020. № 3. С. 14-21.
6. Mulla A. S. Queue Management Policies / A. S. Mul-la, B. T. Jadhav // International Journal of Latest Trends in Engineering and Technology (IJLTET). – 2014. Vol. 3. P. 31-34.
7. B. Tran, S. Picek, B. Xue "Automatic feature construction for network intrusion detection," in Asia-Pacific Conference on Simulated Evolution and Learning. Springer, 2017, pp. 569–580.
8. 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.
9. T. Hamed, J. B. Ernst, S. C. Kremer "A survey and taxonomy on data and preprocessing techniques of intrusion detection systems," in Computer and Network Security Essentials. Springer, 2018, pp. 113–134.
10. Resource allocation for non-delay-sensitive satellite services using adaptive coding and modulation–multiple-input and multiple-output–orthogonal frequency division multiplexing / [N. Mokari, P. Haji-pour, L. Mohammadi et al.] // IET Commun. – 2016. – Vol. 10 (3). – P. 309-315.

11. Koliass C., Stavrou A., Voas J., Bojanova I., Kuhn R. "Learning internet-of-things security" hands-on", IEEE Security Privacy, vol. 14, no. 1, pp. 37–46, 2016.
12. Мендічіно, Самуїл. Комп'ютерні мережі. 1972. С. 95-100. <http://rogerdmoore.ca/PS/OCTOA/OCTO.html>
13. Aminanto M. E., Choi R., Tanuwidjaja H. C., Yoo P. D., Kim K. "Deep abstraction and weighted feature selection for Wi-Fi impersonation detection," IEEE Transactions on Information Forensics and Security, vol. 13, no. 3, pp. 621–636, 2018.
14. Романчук В.І. Методи та алгоритми управління ресурсами мультисервісних інформаційних функціонально-орієнтованих корпоративних мереж. – Кваліфікаційна наукова праця на правах рукопису. Дисертація на здобуття наукового ступеня доктора технічних наук за спеціальністю 05.12.02 «Телекомунікаційні системи та мережі» (172 – Телекомунікації та радіотехніка). – Національний університет «Львівська Політехніка» МОН України, Львів, 2018. 346 с.
15. Коротка Л. І. Функціональна підсистема раціонального вибору архітектури нейронної мережі / Л. І. Коротка // Вісник Херсонського національного технічного університету, 2017. № 3(1). С. 55-59. – Режим доступу: [http://nbuv.gov.ua/UJRN/Vkhdtu_2017_3\(1\)_10](http://nbuv.gov.ua/UJRN/Vkhdtu_2017_3(1)_10).
16. Гилл Ф., Мюррей У., Райт М. Практическая оптимизация / Practical optimization. – М.: Мир, 1985. 509 с.

References

1. Sobchuk A.V. Application of neural networks to ensure the functional stability of production processes / A.V. Sobchuk, Yu. I. Olimpieva // Telecommunication and information technologies, 2020. № 2. P. 13-28.
2. Bovda E.M. Model of monitoring and forecasting the state of the telecommunications network using fuzzy neural networks / E.M. Bovda // Collection of scientific works [Text] / [editor: Romanyuk VA (ed.) etc.]. Kyiv: VITI, 2018. Issue. № 1. P.6-16.
3. Gerasina O.V. Methods of intellectual identification and traffic forecasting in information telecommunication networks / O.V. Gerasina // State Higher Educational Institution "National Mining University", Dnipro, Information Processing Systems, 2018, Issue 1 (152). Pp. 94-99.
4. Zhukovskaya D.O., Voropaeva V.Ya. Method of priority management of radio resource of the satellite channel on the basis of forecasting of incoming traffic / D.O. Zhukovska, V.Ya. Voropaeva // Scientific works of DonNTU. Series: "Computing and Automation" № 1 (32) 2019. Pp. 79-93.
5. Semenova O.O. Application of neural network in the procedure of vertical handover / O.O. Semenova, A.A. Semenov, O.O. Wojciechowska // Information technologies and computer engineering, 2020. № 3. P. 14-21.
6. Mulla A. S. Queue Management Policies / A. S. Mul-la, B. T. Jadhav // International Journal of Latest Trends in Engineering and Technology (IJLTET). - 2014. Vol. 3. P. 31-34.
7. B. Tran, S. Picek, B. Xue "Automatic feature construction for network intrusion detection," in Asia-Pacific Conference on Simulated Evolution and Learning. Springer, 2017, pp. 569–580.
8. 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.
9. T. Hamed, J. B. Ernst, S. C. Kremer "A survey and taxonomy on data and preprocessing techniques of intrusion detection systems," in Computer and Network Security Essentials. Springer, 2018, pp. 113–134.
10. Resource allocation for non-delay-sensitive satellite services using adaptive coding and modulation – multiple-input and multiple-output – orthogonal frequency division multiplexing / [H. Mokari, P. Haji-pour, L. Mohammadi et al.] // IET Commun. - 2016. - Vol. 10 (3). - P. 309-315.
11. Koliass C., Stavrou A., Voas J., Bojanova I., Kuhn R. "Learning internet-of-things security" hands-on ", IEEE Security Privacy, vol. 14, no. 1, pp. 37–46, 2016.
12. Mendicino, Samuel. Computer networks. 1972. S. 95-100. <http://rogerdmoore.ca/PS/OCTOA/OCTO.html>
13. Aminanto M. E., Choi R., Tanuwidjaja H. C., Yoo P. D., Kim K. "Deep abstraction and weighted feature selection for Wi-Fi impersonation detection," IEEE Transactions on Information Forensics and Security, vol. 13, no. 3, pp. 621–636, 2018.
14. Romanchuk V.I. Methods and algorithms for resource management of multiservice information functionally-oriented corporate networks. – Qualifying scientific work on the rights of the manuscript. The dissertation on competition of a scientific degree of the doctor of technical sciences on a specialty 05.12.02 "Telecommunication systems and networks" (172 - Telecommunications and radio engineering). - National University "Lviv Polytechnic" MES of Ukraine, Lviv, 2018. 346 p.
15. Korotka L.I. Functional subsystem of rational choice of neural network architecture / L.I. Korotka // Bulletin of the Kherson National Technical University, 2017. № 3 (1). Pp. 55-59. - Access mode: [http://nbuv.gov.ua/UJRN/Vkhdtu_2017_3\(1\)_10](http://nbuv.gov.ua/UJRN/Vkhdtu_2017_3(1)_10).
16. Gill F., Murray W., Wright M. Practical optimization. - M.: Mir, 1985. 509 s.