

ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ КЛАСИФІКАЦІЇ УПОРЯДКОВАНИХ МАСИВІВ ДАНИХ З ФРАКТАЛЬНИМИ ВЛАСТИВОСТЯМИ

БУЛАХ В.А.

Пропонується інформаційна технологія класифікації фрактальних упорядкованих масивів даних, яка застосовує методи машинного навчання. Показується, що вибір методу класифікації та ознак повинен ґрунтуватися на дослідженні мультифрактальних властивостей упорядкованих масивів даних. Розробляється інформаційна технологія, що застосовується для виявлення атак на основі класифікації реалізацій нормальних та атаківаних інфокомунікаційних трафіків.

Ключові слова: інформаційна технологія, машинне навчання, класифікація, фрактальні упорядковані масиви даних.

Вступ і мета

Під упорядкованим масивом даних (УМД) кваліфікується множина статистичних даних будь-якої природи, на якій задана функція упорядкування елементів. Найвідомішим представником УМД є часові ряди, які можна тлумачити як реалізації випадкових процесів з дискретним часом. Властивості часових рядів нескладно узагальнити на УМД, якщо замість змінної упорядкування часу взяти іншу фізичну величину.

За останні два десятиліття запропоновано та розроблено незліченну кількість методів інтелектуального аналізу для часових рядів, в тому числі методи машинного навчання [1,2]. Машинне навчання використовується для реалізації завдань різного типу, що стосуються аналізу часових рядів, зокрема для класифікації.

Фрактальна структура властива для багатьох складних систем, їхня динаміка представлена часовими рядами, для яких, в свою чергу, характерні фрактальні (самоподібні) властивості. Різні області знань широко використовують аналіз фрактальних властивостей УМД. Проблема розпізнавання і класифікації є найпоширенішою, тому зростає практичний інтерес до застосування методів машинного навчання в цій галузі досліджень [3-6].

Однак досі не знайдено єдиного підходу до класифікації УМД на основі їх фрактальних властивостей. *Мета* даної роботи – запропонувати інформаційну технологію класифікації упорядкованих масивів даних, які мають фрактальні властивості, на основі методів машинного навчання.

Запропонована інформаційна технологія (ІТ) повинна задовольняти таким вимогам:

- ІТ має збирати вхідні дані для аналізу та в on-line режимі, обробляти їх і зберігати в базі даних (БД);
- в умовах недостатньої кількості даних ІТ повинна використовувати методи моделювання для генерації даних з подібними фрактальними властивостями;
- використовуючи методи машинного навчання, а також згенеровані та отримані реальні дані, ІТ має навчитися оптимально виявляти (класифікувати) різні стани досліджуваного об'єкта;
- використовуючи навчену модель, ІТ повинна класифікувати вхідні дані та інформувати зовнішню систему і оператора ІТ про виявлені особливості у вхідних даних;
- зберігати в базі даних всі результати роботи;
- зі збільшенням обсягів реальних даних проводити перенавчання моделей класифікації.

Самоподібні та мультифрактальні властивості випадкових процесів

Самоподібність випадкових процесів полягає в збереженні кінцевомірних законів розподілу ймовірностей при зміні масштабу часу. Стохастичний процес $X(t)$ є самоподібним, у вузькому сенсі, з параметром H , $0 < H < 1$, якщо процес $a^{-H}X(at)$ описується тими ж законами розподілів, що і $X(t)$. Параметр H називається показником Херста, являє собою ступінь самоподібності процесу, а також характеризує міру довгострокової залежності. Якщо $H > 0.5$, процес $X(t)$ має персистентні властивості, тобто володіє трендостійкістю. Якщо $H < 0.5$ процес є антиперсистентним, а при $H = 0.5$ значення процесу є незалежним.

Мультифрактальні об'єкти є статистично неоднорідними самоподібними об'єктами та виявляють більш складну скейлінгову поведінку. У такому випадку скейлінговою характеристикою є нелінійна функція $h(q)$ – узагальнений показник Херста. Значення $h(q)$ при $q = 2$ збігаються зі значеннями ступеня самоподібності. Для монофрактальних процесів узагальнений показник Херста є константа $h(q) = H$. Діапазон значень узагальненого показника Херста $\Delta h(q) = h(q_1) - h(q_2)$ визначає ступінь мультифрактальності: чим більше значення $\Delta h(q)$, тим більше виражені мультифрактальні властивості процесу. У разі монофрактальності $\Delta h(q) = 0$. Для визначення діапазону $\Delta h(q)$ вибирають позитивні значення параметра $q_1 = 0.1$, $q_2 = 5$. [7].

Задача класифікації упорядкованих масивів даних

Сформулюємо задачу класифікації УМД так: є множина УМД, які розділені на непересічні класи; визначена скінченна множина УМД, для яких відомо, до яких класів вони належать і ця множина є навчальною та тестовою вибіркою. Класова належність інших УМД невідома. Необхідно побудувати алгоритм, що здатний класифікувати довільний УМД з вихідної множини. У машинному навчанні існує ряд основних методів класифікації: дерева прийняття рішень, метод опорних векторів, нейронні мережі та інші. Найчастіше на вхід класифікатора надходить набір деяких ознак, притаманних даному об'єкту, у нашому випадку – УМД. На виході ми отримуємо значення класу досліджуваного УМД.

Одним з найважливіших питань класифікації є вибір ознак, за якими проводиться поділ на класи. Зміна фрактальних властивостей УМД тягне за собою зміну статистичних та кореляційних характеристик. Тому як ознаки були обрані фрактальні, статистичні та рекурентні характеристики, розраховані за значеннями УМД.

Дослідження показали, що статистичними характеристиками, які відображають зміну фрактальних властивостей, є дисперсія, коефіцієнт варіації, медіана, коефіцієнт асиметрії. Як фрактальні ознаки, зручно використовувати значення показника Херста та узагальненого його показника.

Новим підходом до використання ознак УМД в машинному навчанні є обчислення рекурентних характеристик. Рекурентна діаграма УМД є масивом точок, де елемент з координатами (i, j) характеризує близькість точок i та j в фазовому просторі. Чисельний аналіз рекурентних діаграм дозволяє обчислювати кількісні міри складності структур рекурентних діаграм, такі як міра рекурентності, міра детермінізму, міра ентропії і ін. Ці характеристики доцільно застосовувати як ознаки в машинному навчанні.

Методи класифікації

Метод дерев рішень є найбільш простим та ефективним методом для вирішення задач класифікації, що виникають в різних областях. Він полягає в тому, щоб здійснювати процес розподілу вихідних даних на групи, поки не будуть отримані однорідні їх підмножини. Сукупність правил, які дають таке розбиття, дозволяє потім зробити висновок для нових даних. Простота методу дерев рішень впливає на його

стійкість, навіть невелика зміна в навчальній множині може призвести до істотних змін у структурі дерева. У цьому випадку доцільно використовувати ансамблі моделей.

Бегінг (Bagging) – це мета алгоритму класифікації або регресії, де всі елементарні класифікатори/регресори навчаються й працюють незалежно один від одного. Ідея полягає в тому, що базові методи не виправляють помилки один одного, а компенсують їх при усередненні. Якщо ансамбль будується на основі моделей різних типів, то для кожного типу буде свій алгоритм навчання. Ефективність бегінга досягається завдяки тому, що базові алгоритми, які пройшли навчання за різними підвбірками, виходять досить різними, та їхні помилки взаємно компенсуються при усередненні. [8].

Випадковий ліс (Random Forest) також є методом Бегінга, але, на відміну від його основної версії, має кілька особливостей: використовує всередині себе ансамбль тільки регресійних або класифікуючих дерев прийняття рішень; в алгоритмі семпліювання, крім випадкового вибору навчальних об'єктів, також проводиться випадковий вибір ознак; для кожної підвбірки дерево рішень будується до повного вичерпання навчальних прикладів і не піддається процедурі відсікання гілок [9].

Нейронна мережа. У роботі [10] для проведення класифікації як класифікатор використовувався повнозв'язний багат шаровий персептрон. Для запобігання ефекту перенавчання в мережу були включені шари регуляризації – по одному шару після кожного повнозв'язного шару. Як метод регуляризації, була використана пакетна нормалізація. Він дозволяє підвищити продуктивність і стабілізувати роботу нейронних мереж. Як метод навчання обраний метод стохастичної оптимізації Adam (Adaptive Moment Estimation). Алгоритм оптимізації Adam є розширенням методу стохастичного градієнтного спуску з ітеративним оновленням ваг мережі на основі навчальних даних.

Інформаційна технологія класифікації фрактальних упорядкованих масивів даних

У статті [17] нами була розглянута інформаційна технологія класифікації фрактальних часових рядів. Вона мала певні недоліки: не враховувала збір даних і їхнього збереження, взаємодію із зовнішньою системою, котра використовує результати класифікації. Був також відсутній модуль аналізу результатів роботи інформаційної

технології. У даній статті запропонована ІТ, котра вирішує ці недоліки.

На рис. 1, 2 представлена UML – модель запропонованої ІТ класифікації фрактальних упорядкованих масивів даних. Вона складається з 8 основних функціональних частин, а саме:

- збір інформації;
- збереження вхідної інформації в БД для її повторного використання;
- обробка вхідної інформації запропонованим алгоритмом для підготовки даних, котрі будуть використовуватися для навчання моделі та генерації управління на основі навченої моделі;
- навчання моделі та збереження її структури в базі даних;
- класифікація вхідної інформації та генерація управління;
- використання результатів роботи моделі;
- аналіз ефекту від використання результатів роботи моделі;
- представлення результатів функціонування інформаційної технології, усереднених за деякий час її використання.

Розглянемо короткий опис ІТ:

1. *Збереження даних в БД.* Цей модуль ІТ забезпечує збереження вхідного потоку інформації до бази даних для можливості повторного використання.

2. *Обробка інформації.* Представляє собою цілий комплекс математичного апарату для перетворення та генерації даних:

2.1. *Попередня обробка даних.* Містить в собі досить великий спектр алгоритмів, які спрямовані на виявлення апріорно відомої інформації про природу УМД та їх фрактальних і статистичних характеристик.

2.2. *Оцінювання самоподібних і мультифрактальних властивостей УМД для різних класів.* Даний крок є найбільш важливим під час вибору методу класифікації.

2.3. *Визначення факту, що різні класи УМД мають досить урізноманітнені фрактальні властивості:* якщо фрактальні властивості для різних класів практично однакові, то даний підхід не має сенсу використовувати.

2.4. *Аналіз самоподібних властивостей ЧР* дозволяє виділити три умовних діапазони для показника Херста H : антиперсистентність при $H < 0.45$, персистентність при значеннях $H > 0.55$ і фактичну відсутність довгострокової залежності $0.45 \leq H \leq 0.55$. У даному випадку, враховуючи похибки оцінювання показника Херста, ми приймаємо, що діапазон значень $[0.45, 0.55]$ відповідає дуже малій автокореляційній залежності.

2.5. *Аналіз мультифрактальних властивостей УМД*, тобто оцінювання узагальненого показника Херста, дозволяє виділити три умовних діапазони мультифрактальності для функції $h(q)$: слабкі мультифрактальні властивості $\Delta h(q) < 0.4$, середні мультифрактальні властивості $0.4 \leq \Delta h(q) \leq 1$ і сильну мультифрактальність $\Delta h(q) > 1$. Дослідження показали, що діапазон мультифрактальних і самоподібних властивостей УМД має важливе значення для вибору класифікатора і, відповідно, точності класифікації, а також що якнайкраще піддаються класифікації УМД з сильними мультифрактальними властивостями. У цьому випадку і персистентні, і антиперсистентні УМД найбільш точно класифікуються за допомогою методу випадкового лісу на основі дерев регресії (ВЛ[ДР]).




Рис. 1. Схема інформаційної технології класифікації упорядкованих масивів даних




Рис. 2. Декомпозиція блоку «Обробка інформації» на рис. 1

Як ознаки достатньо використовувати статистичні (С) та фрактальні (Ф) характеристики УМД. Якщо УМД мають трендостійкість (показник Херста $H > 0.5$), то як ознаки можна використовувати самі значення УМД. Це займає набагато більше часу, але не потребує ніякого оцінювання фрактальних характеристик.

2.6. У разі, коли УМД явно має мультифрактальні властивості, але діапазон узагальненого показника Херста має невелике значення $0.4 \leq \Delta h(q) \leq 1$, то як ознаки також можна застосовувати статистичні та фрактальні характеристики. При цьому в персистентному випадку краще працює метод бегінг з деревами регресії (Б[ДР]), а в антиперсистентному – метод випадкового лісу із деревами регресії (ВЛ[ДР]).

2.7. Якщо мультифрактальні властивості УМД слабо виражені, тобто УМД можна вважати умовно монофрактальним, то, як додаткові ознаки, треба використовувати рекурентні (Р) характеристики. Дослідження показали, що у випадку монофрактальності кращі результати класифікації дає застосування нейронних мереж (НМ).

2.8. Найбільш складним випадком класифікації є варіанти з класифікацією УМД, які мають слабку і середню мультифрактальність та у яких практично відсутня автокореляційна залежність $0.45 \leq H \leq 0.55$. У цьому випадку пропонується застосувати ансамбль (бегінг) з декількох операторів, а саме $B\{НМ, ВЛ[ДР], Б[ДР]\}$.

2.9. Блок генерації модельних даних необхідний для використання інформаційної технології в умовах недостатньої кількості інформації.

3. *Навчання/перенавчання моделі.* Цей блок інформаційної технології відповідає за навчання та періодичне перенавчання моделі для класифікації УМД.

4. Обчислення кількісних характеристик якості навченої моделі відповідає за обчислення статистичних оцінок якості отриманої моделі; цей модуль необхідний для розуміння ступеня точності моделі.

5. *Збереження моделі та її характеристик в БД.* Відповідає за збереження нової версії моделі в базі даних.

6. *Класифікація, видача керування.* Цей модуль відповідає за використання актуальної версії моделі для класифікації вхідного потоку даних та генерації керуючого сигналу на основі результатів класифікації. Якщо модель ще не навчена, то цей модуль та ті, що йдуть за ним, свої функції не виконують до моменту завершення збору необхідного об'єму інформації та навчання моделі.

7. *Використання результатів класифікації.* Використання сигналу управління та отримання відповіді зовнішньої системи на управління.

8. *Аналіз результатів роботи моделі.* Цей модуль відповідає за порівняння запропонованого управління та очікуваного результату його використання з фактичним відгуком зовнішньої системи.

9. *Збір та генерація статистичних оцінок результатів використання ІТ.* Цей блок відповідає за усереднення результатів роботи інформаційної технології та генерації звітів.

Застосування запропонованої ІТ на прикладі детектування DDoS-атак

DDoS-атака – хакерська атака на обчислювальну систему з метою створення таких умов, через які користувачі системи не можуть отримати доступ до системних ресурсів. У даний час DDoS-атаки можуть довести до відмови практично будь-яку систему, не залишаючи юридично значущих доказів.

Одним із рішень задачі своєчасного виявлення атаки є розробка класифікатора для визначення ймовірності, що трафік, який приходить, є атакованим. Останні дослідження показують, що однією з характерних ознак атаки є зміна показника Херста у трафіка, який містить атакуючі файли.

Для проведення експериментів були взяті дані трафіків з двох наборів реальних даних. З першого набору взяли реалізації DDoS-атак, а з другого – дані трафіка реальної мережі Internet Service Provider на каналному рівні. Реалізація трафіка під дією DDoS-атаки є сумою трафіка і реалізації одного з видів атаки. У ході роботи проведені експерименти по обчисленню зміни узагальненого показника Херста під дією DDoS-атак. Проведено також виявлення DDoS-атаки методами машинного навчання. Об'єктами були модельні реалізації трафіків, у яких присутня ділянка з DDoS-атакою, та реалізації трафіків без атаки. Реалізація трафіка під дією DDoS-атаки представляє собою суму трафіка та реалізації одного із видів атаки, що описані раніше. Оскільки особливо важливе раннє виявлення атаки, відношення середнього значення реалізації трафіка до середнього значення атаки було взято в діапазоні приблизно 6:3.

Проведено бінарну класифікацію персистентних УМД з сильно вираженими мультифрактальними властивостями. З урахуванням запропонованої ІТ методом класифікації був обраний випадковий ліс на основі регресійних дерев рішень. Як ознаки були використані статистичні та фрактальні характеристики реалізацій трафіка, отримані по значенням УМД: середньоквадратичне відхилення, максимальне значення, та медіана реалізації трафіка, середнє значення, середньоквадратичне

відхилення та діапазон узагальненого показника Херста, значення показника Херста H . Результатом роботи моделі була ймовірність відповідності реалізації трафіка заданому класу (є атака чи немає атаки).

В таблиці представлені результати класифікації для трафіків з різним ступенем самоподібності і атаками, для яких показник Херста був у діапазоні $[0.8, 0.9]$. Значення True Positive (істинопозитивне) відповідає ймовірності правильного визначення атаки, значення False negative (хибнегативне) відповідає помилковому визначенню нормального трафіка як атакованого, значення F міри відповідає агрегованому критерію виявлення атак. Значення показника Херста представлені в діапазоні $H = [0.65, \dots, 0.9]$, що відповідає більшості реалізацій реального трафіка.

Значення істинопозитивні, хибнегативні і F-міра для випадкового лісу залежно від показника Херста

Ймовірності	Значення показника Херста					
	0.65	0.7	0.75	0.8	0.85	0.9
True positive	0.8	0.8	0.72	0.92	0.72	0.68
False negative	0.08	0.16	0.24	0.28	0.44	0.32
F-міра	0.87	0.82	0.75	0.8	0.61	0.68

Висновки. Запропоновано інформаційну технологію, призначену для класифікації упорядкованих масивів даних з фрактальними властивостями на основі методів машинного навчання. Як методи класифікації було застосовано методи Бегінг, Випадковий ліс, Нейронні мережі. За ознаки класифікаторів було обрано статистичні, фрактальні та рекурентні характеристики упорядкованих масивів. Вибір класифікатора і набору ознак ґрунтувався на мультифрактальних і самоподібних властивостях досліджуваних масивів. Показано, що найбільша точність класифікації досягається для персистентних даних із сильно вираженими мультифрактальними властивостями. Розглянуто приклад застосування запропонованої інформаційної технології для виявлення атак в реалізаціях інфокомунікаційних трафіків.

Література: 1. *Esling P., Agon C.* Time series data mining // ACM Computing Surveys. 2012. Vol.46, no.1. 2. *Krisztian Buza.* Time Series Classification and its Applications <https://doi.org/10.1145/3227609.3227690> 3. *André L., Coelho V., Clodoaldo A., Lima M.* Assessing fractal dimension methods as feature extractors for EMG signal classification // Engineering Applications of Artificial Intelligence. 2014. N36. P. 81–98. 4. *Symeonidis S.* Sentiment analysis via fractal dimension // Proceedings of the 6th Symposium on Future Directions in Information Access. 2015. P. 48-50. 5. *Arjunan S.P., Kumar D.K., Naik G.R.* A machine learning based method for classification of fractal features of forearm sEMG using Twin Support

Vector Machines // Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. 2010. P. 4821-4. 6. *Ledesma-Orozco, S.E., Ruiz, J., García G., Aviña, G., Hernández, D.* Analysis of self-similar data by artificial neural networks // Proceedings of the 2011 International Conference on Networking, Sensing and Control, Delft. 2011. P. 480-485. doi: 10.1109/IC-NSC.2011.5874873. 7. *Кіріченко Л.О., Радівилова Т.А.* Фрактальний аналіз самоподібних і мультифрактальних часових рядів. Харків, ФОП Панов А.Н., 2019. 106 с. <https://search.crossref.org/?q=10.30837%2F978-617-77-22-82-2> ISBN 978-617-77-22-82-2. 8. *Breiman L.* Bagging predictors // Machine Learning. 1996. N 24 (2). P.123–140. 9. *Breiman L.* Random Forests // Machine Learning. 2001. N45 (1). P.5–32. 10. *Kirichenko L., Radivilova T., Bulakh V.* Binary Classification of Fractal Time Series by Machine Learning Methods // Lecture Notes in Computational Intelligence and Decision Making. ISDMCI 2019. Advances in Intelligent Systems and Computing. Springer, Cham, 2018. Vol 1020. P. 701–711. doi: https://doi.org/10.1007/978-3-030-26474-1_49. 11. *Кириченко Л.О.* Классификация мультифрактальных стохастических временных рядов с использованием мета-алгоритмов на основе деревьев решений / Л.О. Кириченко, В.А. Булах, Т.А. Радивилова // Системні технології. Регіональний міжвузівський збірник наукових праць. Дніпро, 2018. Вип. 3 (116). С. 22-27. 12. *Kirichenko L., Radivilova T., Bulakh V.* Classification of Fractal Time Series Using Recurrence Plots // Proceedings of IEEE International Science-Practical Conference on Problems of Infocommunications. Science and Technology (PIC S&T). Kharkiv, Ukraine. 2018. P. 719–724. doi: 10.1109/INFOCOMMST.2018.8632010. 13. *Bulakh V., Kirichenko L., Radivilova T.* Classification of Multifractal Time Series by Decision Tree Methods // Proceedings of the 14th International Conference “ICT in Education, Research and Industrial Applications. Integration, Harmonization and Knowledge Transfer”. May 14–17 2018. Kyiv, Ukraine. 2018. Vol. I: Main Conference, Vol. 2105. P. 457-460. 14. *Bulakh V., Kirichenko L., Radivilova T.* Time Series Classification Based on Fractal Properties // 2018 IEEE Second International Conference on Data Stream Mining & Processing (DSMP). Lviv, Ukraine. 2018. P. 198–201. doi: 10.1109/DSMP.2018.8478532. 15. *Kirichenko L., Radivilova T., Bulakh V.* Machine Learning in Classification Time Series with Fractal Properties // Data. 2019. Vol. 4, Issue 1, 5. P. 1–13. doi:10.3390/data40100058632010. 16. *Радивилова Т., Кириченко Л., Булах В.* Обнаружение DDoS-атак методами машинного обучения на основе фрактальных свойств // Security In Cervatury, The Social Internet Space In Context Values And Hazards. 2019. С. 299–315. 17. *Кириченко Л.О.* Інформаційна технологія класифікації фрактальних часових рядів / Л.О. Кіріченко, В.А. Булах, М.Ф. Тавалбех, П.П. Зінченко // Системні технології. 2020. № 3 (128). С. 115.

Transliterated bibliography:

1. *Esling P., Agon C.* Time series data mining // ACM Computing Surveys. 2012. Vol. 46, no. 1.
2. *Krisztian Buza.* Time Series Classification and its Applications <https://doi.org/10.1145/3227609.3227690>
3. *André L., Coelho V., Clodoaldo A., Lima M.* Assessing fractal dimension methods as feature extractors for EMG signal classification // Engineering Applications of Artificial Intelligence. 2014. N36. P. 81–98.
4. *Symeonidis S.* Sentiment analysis via fractal dimension // Proceedings of the 6th Symposium on Future Directions in Information Access. 2015. P. 48–50.
5. *Arjunan S.P., Kumar D.K., Naik G.R.* A machine learning based method for classification of fractal features of forearm sEMG using Twin Support Vector Machines // Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. 2010. P. 4821–4.
6. *Ledesma-Orozco, S.E., Ruiz, J., García G., Aviña, G., Hernández, D.* Analysis of self-similar data by artificial neural networks // Proceedings of the 2011 International Conference on Networking, Sensing and Control, Delft. 2011. P. 480–485. doi: 10.1109/ICNSC.2011.5874873.
7. *Kirichenko L.O., Radivilova T.A.* Fraktalnyy analiz samopodibnykh i multyfraktalnykh chasovykh riadiv. Kharkiv, FOP Panov A.N., 2019. 106 s. <https://search.crossref.org/?q=10.30837%2F978-617-77-22-82-2> ISBN 978-617-77-22-82-2.
8. *Breiman L.* Bagging predictors // Machine Learning. 1996. N 24 (2). P. 123–140.
9. *Breiman L.* Random Forests // Machine Learning. 2001. N45 (1). P. 5–32.
10. *Kirichenko L., Radivilova T., Bulakh V.* Binary Classification of Fractal Time Series by Machine Learning Methods // Lecture Notes in Computational Intelligence and Decision Making. ISDMCI 2019. Advances in Intelligent Systems and Computing. Springer, Cham, 2018. Vol 1020. P. 701–711. doi: https://doi.org/10.1007/978-3-030-26474-1_49.
11. *Kirichenko L.O.* Klassifikacija mul'tifraktal'nyh stohasticheskikh vremennyh rjadov s ispol'zovaniem meta-algoritmov na osnove derev'ev reshenij / L.O. Kirichenko, V.A. Bulakh, T.A. Radivilova // Systemni tekhnologii. Regionalnyi mizhvuzivskyi zbirnyk naukovykh prats. Dnipro, 2018. Vyp. 3 (116). C. 22–27.
12. *Kirichenko L., Radivilova T., Bulakh V.* Classification of Fractal Time Series Using Recurrence Plots // Proceedings of IEEE International Science-Practical Conference on Problems of Infocommunications. Science and Technology (PIC S&T). Kharkiv, Ukraine. 2018. P. 719–724. doi: 10.1109/INFOCOMMST.2018.8632010.
13. *Bulakh V., Kirichenko L., Radivilova T.* Classification of Multifractal Time Series by Decision Tree Methods // Proceedings of the 14th International Conference “ICT in Education, Research and Industrial Applications. Integration, Harmonization and Knowledge Transfer”. May 14–17 2018. Kyiv, Ukraine. 2018. Vol. I: Main Conference, Vol. 2105. P. 457–460.
14. *Bulakh V., Kirichenko L., Radivilova T.* Time Series Classification Based on Fractal Properties // 2018 IEEE Second International Conference on Data Stream Mining & Processing (DSMP). Lviv, Ukraine. 2018. P. 198–201. doi: 10.1109/DSMP.2018.8478532.
15. *Kirichenko L., Radivilova T., Bulakh V.* Machine Learning in Classification Time Series with Fractal Properties // Data. 2019. Vol. 4, Issue 1, 5. P. 1–13. doi: 10.3390/data4010005 8632010.
16. *Radivilova T., Kirichenko L., Bulakh V.* Obnaruzhenie DDoS-atak metodami mashinnogo obuchenija na osnove fraktal'nykh svoystv // Security In Cervatury, The Social Internet Space In Context Values And Hazards. 2019. C. 299–315.
17. *Kyrychenko L.O.* Informatsiina tekhnologhiia klasyfikatsii fraktal'nykh chasovykh riadiv / L.O. Kirichenko, V.A. Bulakh, M.F. Tavalbekh, P.P. Zinchenko // Systemni tekhnologii. 2020. № 3 (128). S. 115.

Надійшла до редколегії 02.06.2020

Рецензент: д-р техн. наук, проф. Кириченко Л.О.

Булakh Віталій Анатолійович, асистент кафедри системотехніки ХНУРЕ. Наукові інтереси: машинне навчання, фрактальні процеси, випадкові процеси. Адреса: Україна, 61166, Харків, пр. Науки, 14, e-mail: vitalii.bulakh@nure.ua

Bulakh Vitaliy Anatoliyovych, Assistant, Department of Systems Engineering, KNURE. Scientific interests: machine learning, fractal processes, random processes. Address: Ukraine, 61166, Kharkiv, 14 Nauki Ave., e-mail: vitalii.bulakh@nure.ua