

## ВИКОРИСТАННЯ МОДЕЛЕЙ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ ПЕРЕВІРКИ ВИМОГ ДО ФУНКЦІОНАЛЬНОЇ СТІЙКОСТІ ІНФОРМАЦІЙНИХ СИСТЕМ

Активна інформатизація суспільства вимагає все більш активного використання інформаційних систем. З ростом необхідності їх застосування для вирішення тих чи інших задач зростають й вимоги до інформаційних систем з однієї сторони та їхні розміри з другої. Очевидно, що функціональна стійкість займає все більш значиме місце в експлуатації інформаційних систем. Внаслідок цього розробляються найрізноманітніші способи її охарактеризувати та забезпечити фізично. Як наслідок, вже розроблено ряд показників та критеріїв функціональної стійкості систем, а також і вимоги до організації самої системи. Метою цього всього є зробити використовувані інформаційні системи максимально функціонально стійкими. Попри розробку нових показників та критеріїв функціональної стійкості та вимог, виконання яких функціональну стійкість забезпечує, на даний момент у них всіх є дуже суттєвий недолік: їх досить складно реалізувати технічно. Як наслідок, при збільшенні розмірів інформаційних систем або їх деградації стає все важче оцінити, чи є вони функціонально стійкими, чи ні. В результаті, виникає необхідність в оптимізації вже розроблених методів оцінки та забезпеченні функціональної стійкості. Останнім часом досить підвищився інтерес до використання моделей машинного навчання, в тому числі, і для оптимізації обчислень. Останні дослідження показують, що моделі машинного навчання в ряді випадків справляються з даною задачею досить успішно. А тому логічним постає питання про їх застосування і в дослідження функціональної стійкості інформаційних систем. В даній роботі досліджується застосування кількох моделей машинного навчання для оптимізації перевірки виконання умови, виконання якої забезпечує функціональну стійкість розглядуваної інформаційної системи.

**Ключові слова:** інформаційні системи, машинне навчання, штучний інтелект, нейронні сітки, дерева рішень, мережеві технології.

### Вступ

Все більш активне використання інформаційних систем передбачає й збільшення вимог до них. Однією з вимог, зокрема, в роботі інформаційних систем в автономному режимі є те, щоб ці системи були функціонально стійкими. Другими словами, інформаційна система, що введена в експлуатацію повинна виконувати поставлені задачі на протязі заданого часу на фоні власної деградації та різноманітних негативних впливів на неї. Відповідно, виникає необхідність в тому, щоб формально охарактеризувати функціональну стійкість систем.

На даний момент розроблено ряд показників функціональної стійкості, які умовно можна поділити на ймовірнісні та структурні. Так, наприклад, в [2] введено такі ймовірнісні показники як ймовірність зв'язності  $R_{ij}$ , що характеризує ймовірність передачі інформації між машинами  $v_i$  та  $v_j$ , і матриця зв'язності  $W$ , кожен елемент  $w_{ij}$  рівний відповідному значенню  $R_{ij}$ . До структурних же показників функціональної стійкості можна віднести степінь вершинної зв'язності  $\chi(G)$  та степінь реберної зв'язності  $\lambda(G)$ , де  $G$  – граф, що описує структуру розглядуваної системи. На основі вище згаданих показників рядом авторів запропоновано свої критерії функціональної стійкості. Так, наприклад, в [4] наведено структурний критерій локальної функціональної стійкості. Також в деяких роботах на основі згаданих показників були сформульовані й вимоги до структури інформаційної системи, виконання яких забезпечує функціональну стійкість. Так, в [2] була сформульована наступна вимога: якщо виконується умова

$$\chi(G) \geq 2 \wedge \lambda(G) \geq 2. \quad (1)$$

То структура розглядуваної інформаційної системи вважається функціонально стійкою, інакше – функціонально нестійкою. Дана вимога хороша тим, що є інтуїтивно зрозумілою, а тому її використання має певний практичний інтерес. Однак, вона має й один важливий

недолік: перевірка умови (1) в масштабах сучасних інформаційних систем може бути досить трудомістким процесом. Тому виникає необхідність в оптимізації цієї перевірки.

Відомо, що останнім часом як один зі способів оптимізації необхідних обчислень досліджують моделі машинного навчання [10–12]. Тому метою даної роботи є дослідження застосування моделей класифікації для перевірки виконання вимоги (1) на основі ряду параметрів структури інформаційної системи.

### Огляд останніх досліджень та публікацій

Дослідження функціональної стійкості як характеристики інформаційних систем останніми десятиліттями все більш поширеними. Так, наприклад, вже в [1–3] вже сформульовано поняття функціональної стійкості та розглянуто ряд показників та критеріїв, які б дозволили її оцінити чисельно. В роботах [3] проводиться огляд ряду структурних і ймовірнісних показників та критеріїв функціональної стійкості як от ймовірність зв'язності  $R_{ij}$ , степені реберної та вершинної зв'язності  $\chi(G)$  і  $\lambda(G)$  та ряд інших. В [3] більший акцент робиться на структурних показниках типу останніх двох. В [4] розглядаються структурні критерії та алгоритми, заточені під локальну функціональну стійкість. В [5] описані дещо подібні підходи вже для дослідження запасу функціональної стійкості. В ряді робіт, як от [6–7], більший акцент робиться вже на прикладні спекти застосування показників функціональної стійкості та поняття функціональної стійкості загалом, а в [8] розглядаються особливості такого застосування. В деяких роботах можна зустріти й більш конкретні дослідження. Так, наприклад, в [9] автори досліджують вплив функціональної стійкості в кібербезпеці. Однак, попри такі широкі дослідження головною проблемою методів оцінки та подальшого дослідження функціональної стійкості, описаних, наприклад, у вище згаданих роботах, є їх висока обчислювальна складність. Із-за цього аспекту встановлення того, чи є розглядувана інформаційна система функціонально стійкою, чи ні, зможе стати дуже проблематичним, особливо, якщо ця система дуже велика.

На даний момент досить сильно зростає інтерес до застосування різних моделей машинного навчання. Однією з головних причин цього є спрощення різного роду обчислень. Так, наприклад, в [10] автори використовують нейронні сітки для наближеного розв'язування полігармонійних рівнянь, що, в загальному випадку, є досить трудомістким процесом. Автори [11], в свою чергу, розглядають конкретну архітектуру нейронних сіток з ціллю дослідження динаміки системи, описаної складною моделлю. В [12] для вирішення такого роду задач пропонується модель машинного навчання, яка, в певному сенсі, імітує процес інтерполяції.

Однак, попри все вище сказане, використання моделей машинного навчання для дослідження структурних ознак функціональної стійкості інформаційних систем досліджено досить поверхнево. Так, наприклад, в [13] розглянуто загальні концепції використання нейронних мереж. В силу цього постає питання про те, які особливості можуть мати інші моделі машинного навчання та які із них краще використовувати при вирішенні тієї чи іншої задачі, пов'язаної з функціональною стійкістю?

### Вибір параметрів

Оскільки функціональна стійкість інформаційної системи тісно пов'язана з її структурою, то логічно подавати на вхід моделі машинного навчання певні показники структури. Так, сюди можна віднести певні параметри, які великою мірою впливають на зв'язність графа, що моделює систему, а саме, мінімальний, максимальний та середній степені вершин, що представляють машини, кількість самих машин та кількість ліній зв'язку між ними. Також до параметрів, що подаватимуться на вхід моделі машинного навчання можна подати характеристики самої матриці суміжності графа, такі як її норма  $L_{2,2}$ . Тепер виникає питання про те, що очікувати на виході моделі? Враховуючи вище сказане, доцільно буде покласти виходом логічне значення, яке показуватиме, виконується для розглядуваної системи умова (1) чи ні.

### Аналіз вибірки для навчання

Перед дослідженням ефективності ідентифікації виконання умови (1) по згаданим вище параметрам за допомогою моделей машинного навчання слід попередньо дослідити вибірку, на якій ці моделі будуть навчатися.

В межах дослідження було згенеровано випадковим чином 13380 інформаційних систем, у яких кількість машин коливається від 5 до 10. Сама вибірка містить в собі дев'ять параметрів: мінімальна, середня та максимальна кількість ліній зв'язку, прокладена до машини, безпосередньо кількість машин та ліній зв'язку, норма матриці суміжності графа, що моделює структуру розглядуваної інформаційної системи, степені реберної та вершинної зв'язності та виконання умови (1), де 1 означає, що умова виконується, а 0, – що не виконується. Відповідно, маючи на меті оцінити розподіл значень кожного з указаних параметрів, побудуємо гістограми розподілу значень параметрів у вибірці, що використовуватиметься далі. Вони матимуть наступний вигляд (рис. 1).

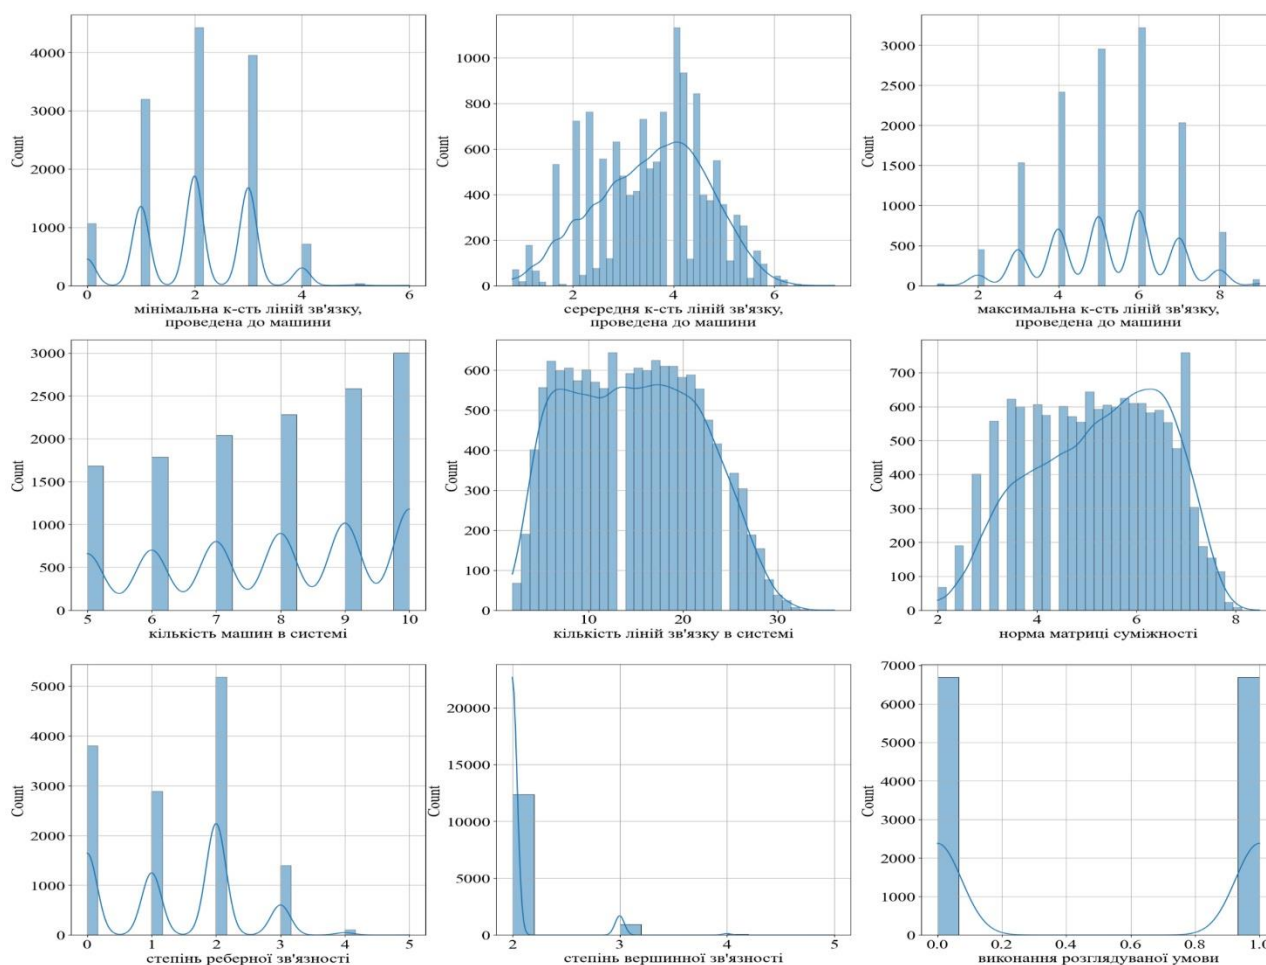


Рис. 1. Гістограми розподілів кожного з параметрів у вибірці

На рис. 1 добре видно кілька особливостей вибірки, яка використовується в дослідженні. В першу чергу, видно, що ця вибірка збалансована відносно виконання умови (1). Це означає, що при тестуванні в подальшому вибраних моделей машинного навчання можна очікувати приблизно однакову ймовірність похибки першого та другого роду або, другими словами, ймовірність неправильної ідентифікації виконання та невиконання вимоги (1). Можливі невеликі відхилення в цих ймовірностях можуть бути спричинені певною незбалансованістю розподілу таких параметрів, як кількість машин в системі, у використовуваній вибірці. Також неважко побачити, що частина з вибраних для оцінки

виконання умови (1) параметрів може бути попарно корельованими. Отже, необхідно перевірити, чи дійсно це так, і у випадку позитивної відповіді дослідити, вилучення яких із цих параметрів суттєво не вплине на точність в подальшому вибраних моделей машинного навчання. Для цього варто побудувати матрицю кореляції (рис. 2).

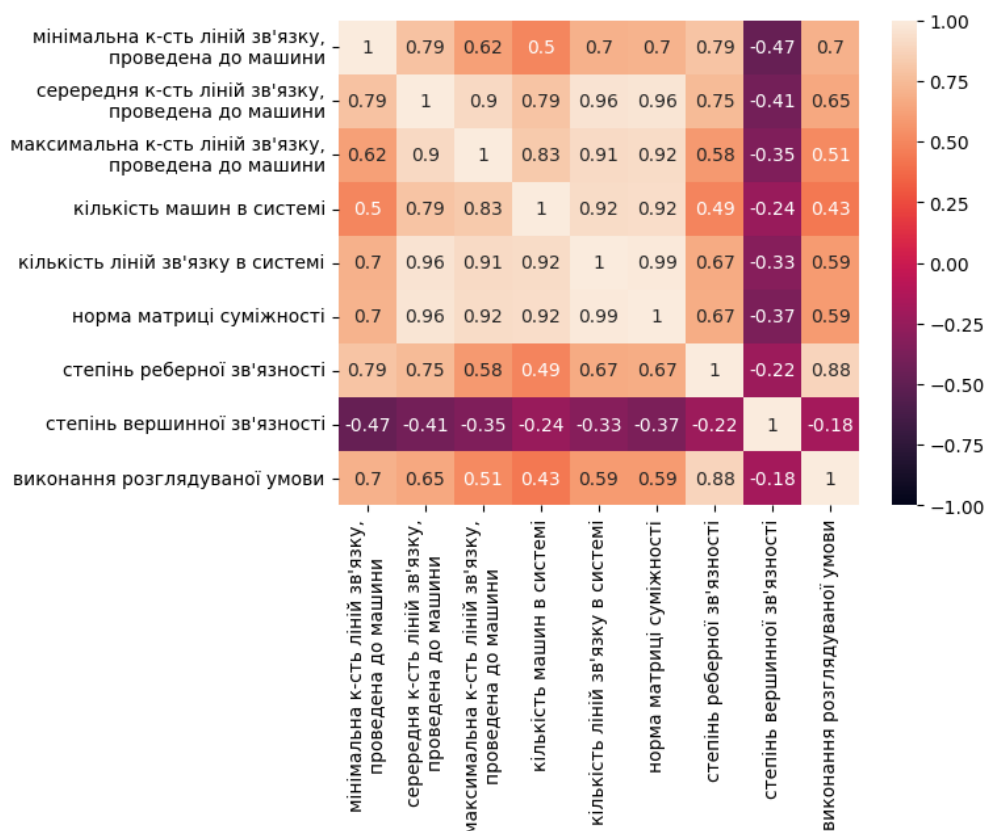


Рис. 2. Матриця кореляції для параметрів у вибірці

З рис. 2 видно, що деякі з відібраних параметрів, дійсно між собою корелюють. Зокрема, варто відмітити наступні пари параметрів:

- середня та максимальна кількість ліній зв'язку, проведених до машини;
- середня ліній зв'язку, проведених до машини, та їх загальна кількість;
- середня ліній зв'язку, проведених до машини, та норма матриці суміжності;
- максимальна з ліній зв'язку, проведених до машини, та їх загальна кількість;
- максимальна з ліній зв'язку, проведених до машини, та норма матриці суміжності;
- кількість машин та кількість ліній зв'язку в системі;
- кількість машин та норма матриці суміжності.

Це зразу ж наштовхує на думку, що для прогнозу виконання умови (1) слід використовувати моделі машинного навчання, основані на нелінійних залежностях між параметрами, або варто виключити зі списку параметрів кількість машин в системі, а також середню і максимальну кількість ліній зв'язку, проведених між ними (чи певну їх частину). Однак, кожен із 6 вибраних для передбачення виконання умови (1) параметрів є статистично значимим з достовірністю 0,001. Відповідно, це наштовхує на думку, що необхідно дослідити обидва наведені вище варіанти та порівняти між собою.

### Передбачення виконання умови (1) на всіх відібраних параметрах

В межах дослідження було розглянуто три моделі машинного навчання: дерево рішень, випадковий ліс та нейронна мережа прямого розповсюдження. При навчанні на вибраному наборі даних кожної з моделей та оцінці точності було отримано результати (табл. 1).

Таблиця 1

## Точність отриманих моделей

| Модель                                 | Відсоток правильних відповідей | Достовірність правильної ідентифікації виконання умови (1) | Достовірність правильної ідентифікації невиконання умови (1) |
|--|--------------------------------|--|--|
| Дерево рішень                          | 86,2                           | 0,88   | 0,847  |
| Випадковий ліс                         | 86,84                          | 0,882  | 0,856  |
| Нейронна мережа прямого розповсюдження | 85,5                           | 0,868  | 0,843  |

Спираючись на таблицю 1, логічним питанням є питання про архітектуру кожної з моделей. Точність, представлена в даній таблиці можна досягнути, якщо відповідні моделі мають задовольняють наступні умови щодо параметрів:

- Дерево рішень:
  - мінімальна кількість об'єктів у листі рівна 18;
  - мінімальна кількість об'єктів, достатня для розбиття, рівна 92.
- Випадковий ліс:
  - мінімальна кількість у листі рівна 1;
  - мінімальна кількість об'єктів, достатня для розбиття, рівна 4;
  - кількість дерев рішень рівна 16.
- Багатошарова нейронна мережа прямого розповсюдження:
  - активаційна функція у всіх нейронах: гіперболічний тангенс;
  - 4 прихованих шари по 20 нейронів у кожному.

Виходячи із вище сказаного, при правильному підборі гіперпараметрів модель машинного навчання, основана на випадковому лісі, найбільш адекватно передбачає виконання умови (1) на основі. Однак, різниця в точності вибраних моделей несуттєва.

#### Передбачення виконання умови (1) на частині відібраних параметрів

Як зазначалося вище, для передбачення виконання умови (1) за допомогою моделей машинного навчання вибрано наступні шість параметрів:

- 1) мінімальна кількість ліній зв'язку, що проведена до машини;
- 2) середня кількість ліній зв'язку, що проведена до машини;
- 3) максимальна кількість ліній зв'язку, що проведена до машини;
- 4) кількість машин у розглядуваній системі;
- 5) кількість ліній зв'язку у розглядуваній системі;
- 6) норма матриці суміжності графа, що описує структуру системи, яка розглядається.

Однак, як видно із рис. 2, другий, третій та четвертий параметри добре корелюють між собою або з іншими параметрами. Відомо, що така ситуація може спричинити певні незручності як от збільшення розмірності моделі без явного покращення її точності. Одним із можливих способів вирішення цієї проблеми є виключення всіх цих параметрів або певної їх підмножини. Відповідно, логічним є питання про те, як змінюватиметься точність кожної із вище розглянутих моделей машинного при такому підході.

Досліджуючи таким чином зміну точності дерева рішень, виявлено, що при відповідних змінах в архітектурі моделі можна отримати такі результати (табл. 2). Як можна бачити із таблиці 2, у випадку використання дерев рішень при одночасному вилученні зі списку параметрів середню кількість ліній зв'язку, проведених до машини, та кількість самих машин спостерігається незначне покращення точності моделі. В інших же ситуаціях спостерігається одночасне зменшення ймовірності першого роду та збільшення помилки другого роду.

Таблиця 2

Зміна точності дерева рішень при видаленні зазначених параметрів

| Вилучені параметри   | Загальний відсоток правильних відповідей | Достовірність правильної ідентифікації виконання умови (1) | Достовірність правильної ідентифікації невиконання умови (1) |
|--|--|--|--|
| Середня кількість ліній зв'язку, що проведена до машини  | 86,4                                     | 0,888  | 0,843  |
| Максимальна кількість ліній зв'язку, що проведена до машини  | 86,7                                     | 0,888  | 0,85   |
| Кількість машин у розглядуваній системі  | 86,8                                     | 0,874  | 0,863  |
| - середня кількість ліній зв'язку, що проведена до машини<br>- максимальна кількість ліній зв'язку, що проведена до машини | 85,9                                     | 0,89   | 0,83   |
| - середня кількість ліній зв'язку, що проведена до машини<br>- кількість машин у розглядуваній системі                     | 85,3                                     | 0,927  | 0,8  |
| - максимальна кількість ліній зв'язку, що проведена до машини<br>- кількість машин у розглядуваній системі                 | 86,9                                     | 0,889  | 0,85   |
| Всі три вище зазначені   | 85                                       | 0,93   | 0,793  |

Аналогічну динаміку можна спостерігати й у випадку використання випадкового лісу як моделі машинного навчання в контексті поставленої задачі (табл. 3).

Таблиця 3

Зміна точності випадкового лісу при видаленні зазначених параметрів

| Вилучені параметри   | Загальний відсоток правильних відповідей | Достовірність правильної ідентифікації виконання умови (1) | Достовірність правильної ідентифікації невиконання умови (1) |
|--|--|--|--|
| Середня кількість ліній зв'язку, що проведена до машини  | 86                                       | 0,876  | 0,845  |
| Максимальна кількість ліній зв'язку, що проведена до машини  | 85,8                                     | 0,886  | 0,834  |
| Кількість машин у розглядуваній системі  | 86,4                                     | 0,879  | 0,85   |
| - середня кількість ліній зв'язку, що проведена до машини<br>- максимальна кількість ліній зв'язку, що проведена до машини | 86,7                                     | 0,881  | 0,852  |

| Вилучені параметри   | Загальний відсоток правильних відповідей | Достовірність правильної ідентифікації виконання умови (1) | Достовірність правильної ідентифікації невиконання умови (1) |
|--|--|--|--|
| - середня кількість ліній зв'язку, що проведена до машини<br>- кількість машин у розглядуваній системі     | 85,5                                     | 0,918  | 0,808  |
| - максимальна кількість ліній зв'язку, що проведена до машини<br>- кількість машин у розглядуваній системі | 86,6                                     | 0,895  | 0,841  |
| Всі три вище зазначені   | 85,7                                     | 0,9165   | 0,815  |

Аналізуючи таблицю 3, неважко побачити, що, як і у випадку з деревами рішень, вилучення середньої кількості ліній зв'язку, проведених до машини. Однак, це лише у випадку, коли заодно вилучено й максимальну кількість ліній зв'язку.

Якщо ж для ідентифікації виконання умови (1) використовувати модель машинного навчання, основу на багатошаровій нейронній мережі прямого розповсюдження, то можна помітити подібну ситуацію (табл. 4).

Таблиця 4

Зміна точності багатошарових нейронних мереж прямого розповсюдження при видаленні зазначених параметрів

| Вилучені параметри   | Загальний відсоток правильних відповідей | Достовірність правильної ідентифікації виконання умови (1) | Достовірність правильної ідентифікації невиконання умови (1) |
|--|--|--|--|
| Середня кількість ліній зв'язку, що проведена до машини  | 86,7                                     | 0,967  | 0,805  |
| Максимальна кількість ліній зв'язку, що проведена до машини  | 86                                       | 0,967  | 0,805  |
| Кількість машин у розглядуваній системі  | 87,2                                     | 0,918  | 0,837  |
| - середня кількість ліній зв'язку, що проведена до машини<br>- максимальна кількість ліній зв'язку, що проведена до машини | 86,5                                     | 0,886  | 0,847  |
| - середня кількість ліній зв'язку, що проведена до машини<br>- кількість машин у розглядуваній системі                     | 84,9                                     | 0,988  | 0,773  |
| - максимальна кількість ліній зв'язку, що проведена до машини<br>- кількість машин у розглядуваній системі                 | 86,5                                     | 0,83   | 0,91   |
| Всі три вище зазначені   | 86                                       | 0,993  | 0,786  |

Досліджуючи таблицю 4, можна також побачити, що, як і у випадку з випадковим лісом, вилучення зі списку параметрів середньої та максимальної кількості ліній зв'язку, проведених між машинами, фактично, не призведе до значимої зміни точності моделі. При видаленні ж інших параметрів чи їх комбінацій спостерігається зріст ймовірності помилки другого роді разом зі спадом ймовірності помилки першого роду або навпаки.

Отже, виходячи з вище сказаного, можна заключити, що при використанні однієї з трьох вище зазначених моделей для передбачення виконання умови (1) з точністю вище 80% достатньо в ролі параметрів використовувати мінімальну кількість ліній зв'язку, що проведені до машини, кількість машин і ліній зв'язку у розглядуваній системі, а також норму матриці суміжності графа, що описує структуру системи, яка розглядається.

Вище було сказано що можна очікувати приблизно однакову ймовірність похибки першого та другого роду. Дійсно, якщо навчати кожен із розглянутих вище моделей машинного навчання, то ми будемо спостерігати таку тенденцію (табл. 1). Однак, як тільки ми поспробуємо видалити бодай якийсь параметр із вибірки, то ймовірності похибки першого та другого роду можуть бути суттєво відрізнятися (табл. 2-4). Зокрема, важно прогнозованою ця різниця може бути у випадку використання нейронних мереж прямого розповсюдження, яка, як показано вище (табл. 2), найгіршу точність прогнозу. Однак, навіть, з урахуванням цього, прямий перебір підмножин параметрів, підозрілих на можливість виключення, все ж, дозволяє знайти підмножину початкових параметрів, при використанні яких результуюча модель в плані точності майже не поміняється.

## Висновки

В даній роботі досліджено особливості використання моделей машинного навчання для ідентифікації виконання вимог, виконання яких указує на функціональну стійкість розглядуваної інформаційної системи. Так, в межах даного дослідження було розглянуто точність передбачення виконання умови (1) на основі шести параметрів: мінімальної, середньої та максимальної кількості ліній зв'язку, проведених до машини, кількості самих машин та ліній зв'язку, а також норми матриці суміжності графа.

В першу чергу, показано при аналізі використовуваної вибірки встановлено, що серед вище згаданих параметрів середню та максимальну кількість ліній зв'язку, проведених до машини, в межах поставленої задачі можна ігнорувати. Це пов'язано з тим, що ці два виміри добре корелюють з деякими іншими параметрами із вище згаданих. Даний фактор говорить часто означає, що вилучення таких параметрів суттєво не впливає на точність моделі. В межах вирішення поставленої задачі показано, що стосовно саме двох зазначених вище параметрів це дійсно так, незалежно від того, яку модель машинного навчання використовувати.

В дослідженні розглядається три моделі машинного навчання: дерева рішень, випадкові ліси та нейронні мережі прямого розповсюдження. Встановлено, що за допомогою кожної з цих трьох моделей машинного навчання можна передбачити виконання чи невиконання вимоги (1) з точністю вище 80 відсотків. Зокрема, таку точність можна досягнути без обов'язкової попередньої оптимізації гіперпараметрів кожної з моделей.

Як показано а таблиці 1, для передбачення виконання вимоги на основі мінімальної кількості ліній зв'язку, проведених до машини, кількості самих машин та ліній зв'язку та норма матриці суміжності графа структури системи найкраще використовувати випадковий ліс. Однак, використання дерева рішень дає майже таку ж точність передбачення. Це пов'язано, в першу чергу, з тим, що дерево рішень можна розглядати як спеціальний випадок випадкового лісу. З іншої сторони, нейронні мережі прямого розповсюдження показали дещо гіршу точність прогнозу, яку, причому, набагато важче спрогнозувати при зміні набору параметрів або архітектури моделі машинного навчання. В цьому можна переконатися, дослідивши таблиці 2-4.



**Перелік посилань**

1. Машков, О. А., Барабаш, О. В. Оцінка функціональної стійкості розподілених інформаційно-керуючих систем. Фізико-математичне моделювання та інформаційні технології. 2005. № 1. С. 159–165.
2. Барабаш, О. В. Побудова функціонально стійких розподілених інформаційних систем. Київ: НАОУ, 2004. 226 с.
3. Машков, О. А., Барабаш, О. В. Топологічні критерії та показники функціональної стійкості складних ієрархічних систем. Моделювання та інформаційні технології: Збірник наукових праць, 2003. № 25: С. 29-35.
4. Саланда, І. П., Барабаш, О. В., Мусієнко, А. П. Система показників та критеріїв формалізації процесів забезпечення локальної функціональної стійкості розгалужених інформаційних мереж. Системи управління, навігації та зв'язку, 2017. Т. 41, № 1. С. 122–126.
5. Калашник, Г. А., Калашник-Рибалко, М. А. Ознаки та критерії функціональної стійкості інтегрованого комплексу бортового обладнання сучасного повітряного судна та перспективні напрямки його розвитку. Збірник наукових праць Харківського національного університету Повітряних Сил, 2021. Т. 68, № 2. С. 7–15.
6. Кравченко, Ю. В., Нікіфоров, С. В. Визначення проблематики теорії функціональної стійкості щодо застосування в комп'ютерних системах. Телекомунікаційні та інформаційні технології. 2014. № 1. С. 12–18.
7. Барабаш, О. В., Кіреєнко, В. В. Поняття та визначення властивості функціональної стійкості системи розвідки повітряного противника. Збірник наукових праць ВІКНУ. 2013. Т. 44. С. 12–17.
8. Kravchenko, Y., Vialkova, V. The problem of providing functional stability properties of information security systems. 13th international conference on modern problems of radio engineering, telecommunications and computer science (TCSET). 2016. P. 526–530.
9. Барабаш, О., Лукова-Чуйко, Н., Мусієнко, А., Собчук, В. Забезпечення функціональної стійкості інформаційних мереж на основі розробки методу протидії DDoS-атакам / О. Varabash та ін. Сучасні інформаційні системи. 2018. Т. 2, № 1. С. 55–63.
10. Cen, J., Chen, X., Xu, M., Zou, Q. Deep finite volume method for high-dimensional partial differential equations. Guangzhou. 16 p. (Preprint)
11. Zhang, X., Helwig, J., Lin, Y., Xie, Y., Fu, C., Wojtowysch, S., Ji, Sh. SineNet: Learning temporal dynamics in time-dependent partial differential equations. Texas. 42 p. (Preprint)
12. Dulny, A., Heinisch, P., Hotho, A., Krause, A. GrINd: Grid Interpolation Network for Scattered Observations. Würzburg. 19 p. (Preprint. University Würzburg).
13. Sobchuk, V., Olimpiyeva, Yu., Musienko, A., Sobchuk, A. Ensuring the properties of functional stability of manufacturing processes based on the application of neural networks. IT&I workshops. 2020. P. 106–116.

Надійшла 28.06.2024