

УДК 621.396

В.В. Сальник, С.В. Сальник, Е.М. Бовда

Військовий інститут телекомунікацій та інформатизації, Київ

МЕТОД НАВЧАННЯ НЕЧІТКИХ БАЗ ЗНАТЬ СИСТЕМ ВИЯВЛЕННЯ ТА ЗАПОБІГАННЯ ВТОРГНЕНЬ В МОБІЛЬНИХ РАДІОМЕРЕЖАХ КЛАСУ MANET

В статті запропоновано метод навчання нечітких баз знань інтелектуальних систем виявлення та запобігання вторгнень в мобільних радіомережах класу MANET. Розглянуто особливості побудови вузлових баз знань та методи отримання знань. Розробка методу навчання нечітких баз знань ґрунтувалося на комплексному застосуванні нейронних мереж та нечіткої логіки. Суть розробленого методу полягає в модифікації методу навчання Хебба, якій ґрунтується на навчанні баз знань без учителя при комплексному використанні нечіткої логіки та апарата нейронних мереж. Розробка методу дозволила проводити поповнення бази знань в процесі функціонування системи виявлення та запобігання вторгнень в мобільних радіомережах класу MANET.

Ключові слова: база знань, методи отримання знань, навчання бази знань, мобільна радіомережа, MANET.

Вступ

Актуальність дослідження. Останнім часом спостерігається динамічний розвиток та поширення мобільних радіомереж (МР) класу MANET, які стають більш вживаними у повсякденному житті та у військовій галузі, особливо в тактичній ланці управління військами [1]. Основними особливостями побудови та застосування МР є: мобільність усіх вузлів; динамічна топологія; децентралізоване управління МР; спільний доступ вузлів до середовища передачі даних; масштабованість; необхідність збору значної кількості інформації про стан мережі на різних рівнях мережевої моделі OSI. Основною відмінністю МР від класичних радіомереж є відсутність фіксованої мережевої інфраструктури і, як наслідок, фіксованих маршрутів передачі інформації, що потребує використання нових підходів до управління МР та системами, які забезпечують її функціонування. Однією з основних систем МР є система забезпечення безпеки, до складу якої входить підсистема виявлення та запобігання вторгнень [1].

Досвід застосування МР вказує те, що доцільно використовувати децентралізовані системи управління (СУ) та інтелектуалізацію процесів управління у складі вузлової системи забезпечення безпеки [2; 3]. Аналіз публікацій вказує на те, що при побудові системи забезпечення безпеки головне місце займає обробка знань про стан МР. В свою чергу рішення подібного завдання у [4] покладається на модель зі штучним інтелектом.

Управлінські рішення, що приймаються інтелектуальною системою виявлення та запобігання вторгнень (ІСВЗВ), базуються на аналізі та оцінці множини різнорідних параметрів функціонування МР.

Крім того, через зміну умов функціонування МР, динамічність та наявність нечіткої мережевої активності виникає ситуація з отриманням швидко старіючих, нечітких вхідних даних, які не дозволяють побудувати чітку модель функціонування МР. З вказаного виходить те, що в основі ІСВЗВ в МР повинна бути покладена система знань про об'єкти управління, де в якості об'єктів знаходиться, як окремих вузол так і МР в цілому.

На підставі вказаного, **метою статті** є розробка методу навчання нечітких баз знань ІСВЗВ в МР класу MANET, що є актуальним на даному етапі розвитку МР.

Об'єктом розгляду статті є процес отримання, збирання та обробки знань щодо стану МР.

Предметом дослідження є метод навчання нечітких баз знань ІСВЗВ.

Аналіз предметної області. Через динамічну топологію МР класу MANET, її СУ відносяться до складних розподілених систем, які характеризуються слабкою формалізацією залежності вхідних та вихідних змінних. В даному випадку можуть бути застосовані інтелектуальні методи, які дозволяють відобразити нечіткість в управлінні МР.

Функціонування ІСВЗВ ґрунтується на збиранні та переробці вхідних параметрів в знання, завдяки яким будуть прийматися управлінські рішення. Ці знання являють собою інформацію щодо функціонування інформаційної, програмної та апаратної складової МР на рівнях мережевої моделі OSI та множини правил щодо використання даної інформації. На практиці будь які дії та перетворення з цими знаннями здійснюється базою знань (БЗ).

БЗ являє собою базу даних, яка містить структуровану, подану в певному вигляді інформацію про стан компонентів МР, що використовується ПВЗВ.

Основними особливостями БЗ є здатність: отриманих нових знань та складання висновків; знаходити розбіжності; пристосованість до нечіткої мережевої активності та отримання знань [5; 6; 7].

В цілому, за способом навчання методи отримання знань поділяються на:

1. Методи навчання з учителем, де кожного прецеденту примусово задається пара „ситуація – необхідне рішення”.

2. Методи навчання без вчителя, тобто спосіб машинного навчання, під час якого досліджувана система навчається виконувати завдання, без втручання з боку користувача.

Виходячи з вказаного, для ІСВЗВ в МР доцільно використовувати методи навчання з учителем на етапі побудови мережі, а далі для навчання мережі необхідно використовувати методи навчання БЗ без учителя, основною рисою яких є здатність до самоорганізації.

Таким чином, нечітке моделювання процесу функціонування вузлової ІСВЗВ передбачає опис причинно-наслідкових зв'язків між вхідними та вихідними змінними, які характеризують залежність на кожному з рівнів моделі OSI за допомогою нечітких БЗ. Процес функціонування в даному випадку описується лінгвістичними змінними, які оцінюються якісними термами [8].

Враховуючи нечітку мережеву активність та неповноту знань щодо стану МР, які викликані масштабованістю та динамічною топологією компонентів МР, в [4] запропоновано комплексне використання апарата нечіткої логіки та нейронних мереж (НМ) для побудови БЗ та її функціонування.

Вирішенню питань навчання нечітких БЗ, що побудовані за допомогою нейронних мереж, присвячені роботи Д.О. Хебба, А.К. Джейна, В. МакКаллохом та інших. Однак, більшість робіт не враховують особливостей функціонування в МР. У зв'язку з цим у даній статті пропонується метод навчання нечітких БЗ в ІСВЗВ, який спроможний поповнювати новими знаннями БЗ ІСВЗВ в МР при застосуванні нечіткої логіки та апарату НМ.

Виклад основного матеріалу

В даний час, дослідження НМ вважається одним з найбільш перспективних напрямків в галузі штучного інтелекту. НМ являє собою систему з'єднаних та взаємодіючих між собою штучних нейронів. При з'єднанні нейронів у велику мережу з управляємою взаємодією виникає здатність виконувати складні завдання. НМ можуть проводити навчання, в наслідок якого вона спроможна виявляти складні залежності між вхідними та вихідними даними, а також проводити кластеризацію вхідних образів до навченого переліку параметрів [9].

З формальної точки зору НМ являє собою уні-

версальну модель-апроксиматор у вигляді графа, головною рисою якої є використання зв'язків різної ваги між нейронами. Обробка інформації НМ ведеться одночасно великою кількістю елементів, завдяки чому вони стійкі до несправностей та здатні до швидких обчислень. До інших переваг НМ можна віднести малі об'єми пам'яті, необхідні для зберігання нейронів, високу адаптивність, а також здатність до опрацювання нечіткої та неповної інформації, що дозволяє застосовувати НМ в будь-якій предметній області, в тому числі при вирішенні задач прогнозування складних процесів.

Нечітка логіка (НЛ), серед усіх відомих засобів моделювання базується на нечітких множинах та дозволяє здійснювати математичну формалізацію логіко-лінгвістичної інформації, яка застосовується при описах складних нелінійних об'єктів [10]. Як правило, моделювання таких об'єктів зводиться до побудови нечітких БЗ, які втілюють в собі експертні знання про об'єкт у вигляді лінгвістичних висловлювань ЯКЦО-ТО, що відносять до переваг.

Обмеження та допущення: розглядається процес функціонування вузла в режимі реального часу, в складі якого є ІСВЗВ, в наслідок чого маємо множину вхідних параметрів МР – змінних x_n . В складі ІСВЗВ знаходиться БЗ, що будується на апараті НМ та НЛ. Допускається робота в умовах децентралізованого управління; можливість взаємодії на рівнях моделі OSI: $\{B_q = \{B_1, B_2, B_3, B_4\}$.

Необхідно: розробити метод навчання нечітких баз знань ІСВЗВ в МР класу MANET, якій ґрунтується на застосуванні нечіткої логіки та НМ.

Суть розробки методу полягає в модифікації методу навчання Хебба, якій ґрунтується на навчанні БЗ без учителя при комплексному використанні НЛ та апарату НМ, розподілі процесу навчання нечіткої бази знань ІСВЗВ, впровадженні класифікаційного шару, та можливості проведення навчання БЗ в режимі реального часу.

Метод навчання нечітких баз знань в ІСВЗВ.

Виходячи з особливостей функціонування МР класу MANET та потреби проводити навчання НМ визначимо ряд вимог до методу: навчання без учителя; рішення задач класифікації та кластеризації; проведення адаптації мережі для роботи при нечіткій мережевій активності; наявність в мережі обернених зв'язків; проведення навчання в режимі реального часу, надання управлінських рішень.

Виходячи із висунутих вимог та з урахуванням характеристичних особливостей МР за основу був обраний метод навчання Хебба [11]. В даному методі процес навчання є локальним процесом, що охоплює два сусідні нейрони та синапс, у якому немає потреби в глобальному зворотному зв'язку для розвитку нейронних утворень. При роботі НМ нейрон отримує множину вхідних сигналів одночасно, де

кожен вхід має власну синаптичну вагу. Вага являє собою міру важливості вхідних зв'язків, яка моделює поведінку синапсів. Ваги вагомого входу підсилюються, а ваги несуттєвих входів надмірно зменшуються, що визначає інтенсивність вхідного сигналу. Ваги змінюються у відповідності з правилами БЗ, які навчаються [8; 12].

Метод навчання нечітких баз знань ІСВЗВ полягає в обчислення попередніх вимірів виходів для визначення змін ваг за наступним правилом:

$$\omega_{ij}(t) = \omega_{ij}(t-1) + \eta \cdot y_i^{(n-1)} \cdot y_j^{(n)}, \quad (1)$$

де $y_i^{(n-1)}$ – вихідне значення нейрона i шару $t-1$,

y_j^n – вихідне значення нейрона j шару n ; $\omega_{ij}(t)$ – ваговий коефіцієнт синапсу від нейрону i до нейрону j в момент часу t , $\omega_{ij}(t-1)$ – вагові коефіцієнти синапсу, що з'єднує нейрон, на ітераціях t і $t-1$ відповідно; η – коефіцієнт швидкості навчання. n вважається довільним шаром НМ. При навчанні по даному методу посилюються зв'язки між збудженими нейронами.

Структурна схема запропонованого методу навчання нечітких баз знань ІСВЗВ в МР зазначена на рис. 1, та скрадається з наступних етапів:

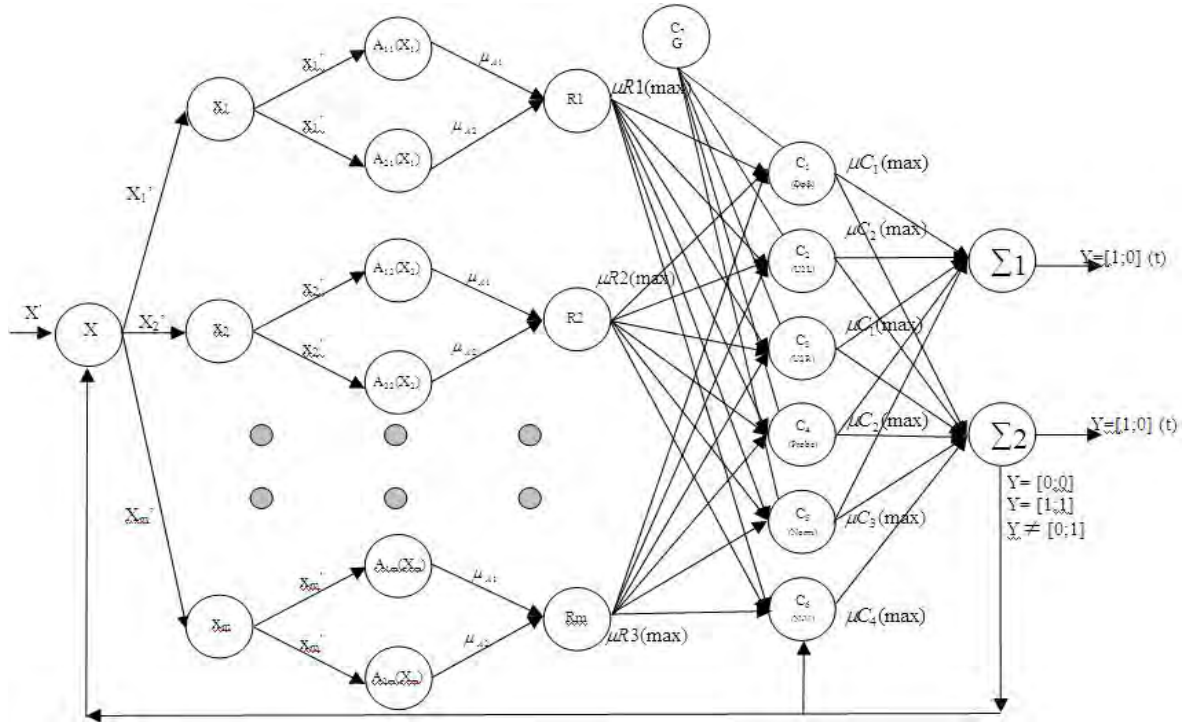


Рис. 1. Структурна схема навчання нечітких баз знань ІСВЗВ

перший шар – представляє собою вхідний шар, який розподіляє трафік на наступний шар рівнозначними потоками;

другий шар представляє собою шар, який отримує вектор вхідних значень, що характеризує параметри трафіка. Тобто з системи контролю надходять вхідні дані $X = (x_1, \dots, x_m)$, де m – кількість параметрів мережі, яка дорівнює 41.

В даному шарі формується база правил (БП) вузлової ІСВЗВ, при виконанні наступних кроків:

- *терм вхідних змінних*, в якому відбувається форматування вхідних даних до нечіткого вигляду, а після цього результати проходять агрегування;

- *формування початкової БП*, який заснований на генерації множини правил, де максимальна кількість правил в базі визначається:

$$X = x_1 \times x_2 \times \dots \times x_m, \quad (2)$$

де x_1, x_2, x_m – кількість функцій належності для

визначення вхідних/вихідних змінних відповідно. Початкові БП ґрунтуються на присвоєнні кожному з прикладів вибірки окремого правила. Кожному прикладу з навчальної вибірки ставляться у відповідність нечіткі множини з максимальними значеннями відповідності змін. Вони побудовані таким чином, щоб множина правил становила початкову БП вузлової ІСВЗВ.

Особливістю підходу є формування початкової БП при невеликій кількості змінних і функцій належності, для завдання цих змінних.

- *визначення рейтингу правил*. БП може містити правила з однаковими передумовами і різними висновками, що призводить до надлишковості та суперечливості. З цього випливає необхідність оптимізації правил на основі емпіричних гіпотез, для уникнення надлишковості правил в БП.

В наслідок чого для кожного правила визначається його рейтинг за виразом:

$$r_i = \text{Agg}_k(r_i^k) (i = \overline{1, I}), \quad (3)$$

$$r_i^k = T(\mu_{a_{i1m}}(\delta_1^k), \dots, \mu_{a_{iNm}}(\delta_n^k), \mu_{d_{ih}}(w^k)) (k = \overline{1, K}),$$

де Agg і T – оператор агрегування або норма [13].

– скорочення кількості правил, скорочення відбувається за групами правил, які мають однакові передумови і різні висновки. Таким чином, вирішується завдання суперечливості правил та зменшення їх кількості. Правила, що лишилися, формують кінцеву базу правил вузлової ІСВЗВ.

Решта правила зберігають своє розміщення. Це пояснюється тим, що множина правил з більшим ступенем гранулярності не завжди дозволяє побудувати кращу модель функціонування того чи іншого об'єкту моделювання, ніж множина правил з меншим ступенем гранулярності [8].

– *Адаптація параметрів правил, у базі.* Повністю сформованою БП можна вважати ту базу, яка пройшла адаптацію правил, які залишилися в ній після скорочення. Адаптація полягає у знаходженні, відповідно до наявних експериментальних даних і прийнятого критерію, оптимальних значень параметрів для правил з БП.

– *Формування груп правил шару* дорівнює сумі потужностей терм-множин усіх вхідних змінних. Виходом вузлів шару є ступінь належності значення вхідної змінної відповідному нечіткому терму:

$$\mu^{a_{nm}}(X_n^*), m = \overline{1, M}, n = \overline{1, N}. \quad (4)$$

Після чого нейронний елемент розподіляє та надсилає вхідне значення на наступний шар.

– **третій шар** – представляє собою розподіл кожного вхідного значення на лінгвістичні вхідні терми. Кожна терма відповідає повноті отриманих значень вхідних параметрів у нечіткій відповідності {висока, низька}, тобто (A_1, A_2) , нейрони шару. Кожен з нейронів отримує вхідні значення та визначає ступінь належності їх нечіткій множині. Вихід (A_1, A_2) , m -го параметру має вигляд:

$$A_{im}(x_m) = \mu_{Ai}(x_m), \quad (5)$$

де x_m – вхідний сигнал m -го елемента, A_i – лінгвістична змінна, яка відповідає нечіткій відповідності, μ_{Ai} – функція належності.

Кожен нейрон відповідає одному нечіткому правилу, а вихідне значення з m елементів являє собою завершення та визначатиметься:

$$R_m = \mu_{A1}(x_1) \times \dots \times \mu_{Am}(x_m). \quad (6)$$

Сумарне значення термів лінгвістичних змінних вузла відповідає вхідному значенню параметра та визначається:

$$M = X_m = \sum_{i=1}^3 A_{im}. \quad (7)$$

Далі етап здійснюється за кроками [14]:

– *фазифікація вхідних змінних*, встановлення відповідності між конкретним значенням окремої вхідної змінної системи нечіткого виводу і значенням S_n^{mk} , яке відображає ступінь істинності підумови правила на основі значення функції належності відповідного їй терма вхідної змінної:

$$S_n^{mk} = \mu_n^m(\overline{x_n}), \quad (8)$$

де $\overline{x_n}$ – вектор значень вхідних змінних системи нечіткого виводу; $\mu_n^m(\overline{x_n})$ – функція належності m -го терма.

– *агрегування підумов в нечітких правилах*, на якому відбувається визначення ступеню істинності умов S^{hk} , $h = \overline{1, H}$ за кожним з правил системи нечіткого виводу на основі відомих значень істинності підумов S_n^{mk} , які входять до нього. Якщо умову правила задано у формі нечіткого лінгвістичного виразу виду $x_1 = a_1^m$, $m = \overline{1, M}$, етап їх агрегування залишає ступінь істинності без зміни. Якщо ж умова правила складається з декількох підумов, ступінь істинності для такого правила визначається [16]:

$$S^{hk} = \min_n S_n^{mk}; \quad (9)$$

$$S^{hk} = \max_n S_n^{mk}, \quad (10)$$

де вираз (10) відображає логічну кон'юнкцію чи логічне „ТА” нечітких підумов правила (6), а вираз (12) – логічну диз'юнкцію чи логічне „АБО” правила (6). Ті правила, ступінь істинності яких не нульова, вважаються активними і використовуються для подальших розрахунків.

У результаті виконання цієї процедури визначаються рівні „відсікання” для умов кожного з правил. Виходи вузлів цього шару позначаються:

$$\eta_h, h = \overline{1, H}. \quad (11)$$

– *активація проміжних висновків в нечітких правилах*, передбачає визначення значень функції належності кожного з підвисновків для вихідних лінгвістичних змінних, які розглядаються.

$$\mu^{hk}(\overline{w_g}) = \min_h \{Z_g^h, \mu_g^h(\overline{w_g})\}, \quad (12)$$

де $\mu_g^h(\overline{w_g})$ – функція належності h -го терма вихідної змінної $\overline{w_g}$; Z_g^h – ступінь істинності кожного з підвисновків, що розраховується:

$$Z_g^h = S^{hk} \cdot F^k, \quad (13)$$

де F^k – ваговий коефіцієнт правила.

– *акумуляція висновків нечітких правил* – передбачає об'єднання і акумуляція з використанням операції \max -диз'юнкції [15; 16] всіх ступенів істинності підвисновків для отримання функції належності кожної із вихідних змінних:

$$\mu_g^*(\overline{w_g}) = \bigcup_{k=1}^{k_M} \bigcup_{h=1}^H \mu^{hk}(\overline{w_g}). \quad (14)$$

– дефазифікація вихідних змінних, полягає в тому, що на основі результатів акумуляції всіх вихідних лінгвістичних змінних отримуються чіткі значення кожної із вихідних змінних, які можуть бути використані підсистемами вузла в процесі функціонування. Відповідно до алгоритму Сугено [18], для дефазифікації використовується модифікований варіант в формі методу центру тяжіння для одноточкових множин:

$$w_g = \frac{\sum_{h=1}^H z_g^h \cdot d_g^h}{\sum_{h=1}^H z_g^h}, \quad (15)$$

де w_g – результат дефазифікації у вигляді чіткого значення змінної; H – загальна кількість активних правил нечітких продукцій, в підвисновках яких є вихідна лінгвістична змінна d_g^h .

четвертий шар – збір ступенів належності вхідних параметрів відповідним нечітким правилам та визначення переможного значення рівня відповідності {висока, низька}. Кількість нейронів шару R_m відповідає кількості вхідних значень параметрів. Заключення нечітких правил з визначенням переможних термів параметрів направляються на кожен нейрон шару. Переможний лінгвістичний терм параметру визначається, як оптимальне значення переможних параметрів або максимальних переможних значень:

$$R_m = \text{opt} \left\{ \max \mu_{A_m}; x_m \right\}. \quad (16)$$

п'ятий шар – складається з C_j нейронів, де j дорівнює 7 та має у своєму складі нейрони:

- C_1, C_2, C_3, C_4 категорій вторгнень (DoS, U2R, R2L, Probe) – f ;
- C_5 нормальних видів поведінки (Norm) – 1;
- C_6 нововиявлених вторгнень (N-V) – v ;
- C_7 порогового рівня поведінки, який висуває поріг контролю та обмеження, що дозволяє визначати бажаний вихідний результат.

Цей шар навчений виявленню вторгнень, він відіграє ключову роль в класифікації даних та здійсненні кластеризації вхідного простору образів. Кількість нейронів шару розраховується:

$$C_K = f + 1 + v + G. \quad (17)$$

Для навчання шару використовується конкурентний метод навчання [19]. Суть методу полягає в тому, що в процесі навчання відбувається конкуренція між нейронними елементами, в результаті чого визначається нейронний елемент-переможець, який

і характеризує параметри вторгнень. З метою пошуку аномальних значень у багатомірних даних та проведення аналізу ступеня подібності об'єктів на основі міри відстаней, а також для визначення „нейрона-переможця” використовується Евклідова відстань (ЕВ) між вхідним і ваговими векторами C_j -го нейронного елемента шару. В основі визначення ЕВ є оцінка відстані між усіма спостереженнями у n -му просторі даних. ЕВ між пошуковими точками є геометричною відстанню та визначається:

$$d_j = |X - \mu_j|, \quad (18)$$

де μ_j – ваговий коефіцієнт параметру, якій відповідає значенню функції належності; $X = (x_1, \dots, x_m)$ – вхідний образ.

При навчанні мережі може виникати проблема так званих „мертвих нейронів”. Одне з обмежень будь якого конкуруючого слою полягає в тому, що деякі нейрони можуть бути не задіяні. Тобто, нейрони, які мають початкові вагові вектори, значно віддалені від векторів входу, ніколи не виграють конкуренції, не залежно від терміну навчання. Як наслідок, такі вектори не використовуються при навчанні та відповідні нейрони ніколи не перемагають (мертві). Тому з метою надання можливості перемогти іншим нейронам, передбачена можливість втрати „нейроном-переможцем” своєї активності. З цією метою проводиться облік активності нейронів на основі підрахунку потенціалу p_i кожного нейрону в процесі виявлення вторгнення та навчання нейрона [20], та нейронам шару надається потенціал

$$p_i(0) = \frac{1}{n}, \quad (19)$$

де n – кількість нейронів (кластерів).

– якщо значення p_i опускається нижче рівня p_{\min} , то нейрон виключається з розгляду;

– якщо $p_{\min} = 0$, то нейрони не виключаються з розгляду;

– якщо $p_{\min} = 1$, то нейрони перемагають по черзі, так як в кожен цикл пошуку тільки один з них готов до розгляду.

В k -му циклі навчання потенціал обчислюється за правилом:

$$p_i(k) = \begin{cases} p_i(k-1) + \frac{1}{n}, i \neq j; \\ p_i(k-1) - p_{\min}, i = j, \end{cases} \quad (20)$$

де j – номер „нейрона-переможця”.

Ваги „нейрона - переможця” та інших нейронів, що знаходяться в межах радіусу навчання, навчаються за правилом:

$$\omega_i^{(k+1)} = \omega_i^{(k)} + \eta_i^{(k)} \left[x - \omega_i^{(k)} \right], \quad (21)$$

де x – вхідний вектор, k – номер циклу навчання, $\eta_i^{(k)}$ – коефіцієнт швидкості навчання i -го нейрона з радіусу навчання в k -му циклі навчання.

Ваги нейронів, що знаходяться за межами радіусу навчання, не змінюються.

$\eta_i^{(k)}$ поділяється: функцію сусідства $\eta_i(d, k)$ та функцію швидкості навчання $a(k)$:

$$\eta_i^{(k)} = \eta_i \cdot (d, k) \cdot a(k). \quad (22)$$

В якості функції сусідства застосовується Гаусова функція:

$$\eta_i(d, k) = e^{-\frac{d_i}{2\sigma(k)}}, \quad (23)$$

де d_i – відстань між i -м нейроном та „нейроном-переможцем”. При цьому $\sigma(k)$ – функція, лінійно збігаюча від номеру циклу навчання, а $a(k)$ являє собою збігаючу від номеру циклу навчання, та використовуються як лінійно або зворотно-пропорційна від номеру циклу навчання виду:

$$a(k) = \frac{A}{k+B}, \quad (24)$$

де A і B – це константи. Використання цієї функції призводить до того, що всі вектори з навчальної вибірки вносять приблизно рівний внесок в результат навчання.

Навчання буде складатись з двох етапів:

1. Обирається *max* швидкості та радіусу навчання, що дозволяє розташувати вектори нейронів згідно з розподілом у виборці.

2. Проводиться точне налаштування ваг, коли значення параметрів швидкості навчання набагато менше початкових.

Навчання продовжуватиметься до тих пір, поки похибка мережі при P вхідних векторах не стане *min* (ω_j – вектор вагів „нейрона-переможця”).

$$E = \frac{1}{P} \sum_{i=1}^P \|x_i - \omega_j\|^2. \quad (25)$$

– **шостий шар** – представлений двома елементами – інтерпретаторами, які обраховують відповідність виявлених значень нейронами категорій атак, нормальної поведінки, нововиявлених вторгнень до нейрона порогового рівня. Вихідна змінна з інтерпретатора буде направлена до підсистеми реалізації рішень у вигляді:

– якщо вихідне значення інтерпретатора, яке отримане з класифікаторів C_1, C_2, C_3, C_4 хоча б одне рівне $Y_n = 1$, та C_5, C_6 хоча б одне дорівнює $Y_n = 0$ або навпаки C_1, C_2, C_3, C_4 хоча б одне рівне $Y_n = 0$, та C_5, C_6 хоча б одне дорівнює $Y_n = 1$, з'єднання оцінюється як „впізнана поведінка”. Після чого на виході інтерпретатора 1 з'являється значення

встановленої поведінки.

– якщо хоча б одне вихідне значення інтерпретатора, яке отримане з класифікаторів C_1, C_2, C_3, C_4 рівне $Y_n = 0$, та хоча б один з C_5, C_6 , теж хоча б одне рівне $Y_n = 0$, або навпаки хоча б одне C_1, C_2, C_3, C_4 рівне $Y_n = 1$, та хоча б один з C_5, C_6 , теж хоча б одне теж рівне $Y_n = 1$, то встановлене з'єднання оцінюється як „не впізнана поведінка”. Внаслідок чого трафік відправляється на нейрон (N-V) на фіксацію та навчання, а також на перший шар мережі. Таким чином відбувається навчання, внаслідок чого на виході нейрона (N-V) буде отримане значення щодо виявлення нового вторгнення $Y_n = 1$. На виході інтерпретатора 2 з'являється значення встановленої поведінки.

Висновок

Таким чином, в статті вперше запропоновано метод навчання нечітких БЗ в ІСВЗВ в МР класу MANET. Суть розробки методу полягає в модифікації методу навчання Хебба, якій ґрунтується на навчанні БЗ без учителя при комплексному використанні НЛ та апарата НМ, розподілі процесу навчання нечіткої бази знань ІСВЗВ, впровадженні класифікаційного шару. Даний метод дозволяє: спростити процес навчання БЗ, поповнювати БЗ в процесі функціонування СВЗВ, в режимі реального часу.

Список літератури

1. Розенблатт Ф. Принципи нейродинамики. Перцептронні та теорія механізмів мозгу / Ф. Розенблатт. – М.: Мир, 1965. – 480 с.
2. Романюк В.А. Архітектура системи оперативного управління тактичними радіомережами / В.А. Романюк // Збірник наукових праць ВІТІ НТУУ „КПІ”. – 2009. – № 3. – С. 70-76.
3. Intellectual Mobile Ad Hoc Networks / [Zhuk P., Romanuk V., Sova O., Bunin S.] // In Proc. of International Conference Modern Problems of Radio Engineering, Telecommunications and Computer Science (TCSET 2012), Lviv, 2012. – P. 238.
4. Романюк В.А. Концепція ієрархічного построения інтелектуальних систем управління тактичними радіосетями класу MANET / В.А. Романюк, О.Я. Сова, П.В. Жук, А.В. Романюк // Сборник тезисов докладов и выступлений участников XXII Международной Крымской конференции [“СВЧ-техника и телекоммуникационные технологии”], (КрыМиКо). – Севастополь, 2012. – С. 265.
5. Романюк В.А. Цільові функції оперативного управління тактичними радіомережами / В.А. Романюк // Збірник наукових праць ВІТІ НТУУ „КПІ”. – 2012. – № 1. – С. 109-117.
6. Сальник С.В. Метод виявлення вторгнень в мобільні радіомережі на основі нейронних мереж / С.В. Сальник, В.В. Сальник, О.А. Симоненко, О.Я. Сова. – СПб.: ВАС, 1998. – 404 с.

7. Гаврилова Т.А. Базы знаний интеллектуальных систем: Учебник для вузов // Т.А. Гаврилова, В.Ф. Хорошевский. – СПб.: Питер, 2000. – 384 с.

8. Ковтун М.В. Определение гранулярности данных таблиц фактов [Электронный ресурс] / М.В. Ковтун // Корпоративные хранилища данных. Интеграция систем. Проектная документация. – 2011. – Наименование с экрана. – Режим доступа к информации: http://prj-exr.ru/dwh/granularity_of_data.php.

9. Машинное обучение [Электронный ресурс] // Матеріал з Вікіпедії. – Останнє оновлення сторінки 14.01.2014. – Режим доступу: https://ru.wikipedia.org/wiki/Машинное_обучение.

10. Комашинский В.И. Нейронные сети и их применение в системах управления и связи // В.И. Комашинский, Д.А. Смирнов. – М.: Горячая линия–Телеком, 2002. – 94 с.

11. Wang L. Machine Learning for Human Motion Analysis / L. Wang, L. Cheng, G. Zhao. – IGI Global, 2009. – 318 p.

12. Стариков А. Нейронные сети – математический аппарат [Электронный ресурс] / А. Стариков. – Base Group Labs. – Режим доступа: <http://www.basegroup.ru/library/analysis/neural/math>.

13. Штовба С.Д. Введение в теорию нечетких множеств и нечеткую логику / С.Д. Штовба. – Винница: Континент-Прим, 2003. – 198 с.

14. Борисов В.В. Нечеткие модели и сети / В.В. Борисов, В.В. Круглов, А.С. Федулов. – М.: Горячая линия – Телеком, 2007. – 284 с.

15. Сальник С.В. Метод выявления вторжений в мобильные радиосети класса MANET на основе гибридного нейро-нечеткого классификатора / С.В. Сальник, В.В. Сальник, Е.М. Бовда, Д.А. Міночкін // Сучасні інформаційні технології у сфері безпеки та оборони. – 2016. – № 1. – С. 104-111.

16. Представление и использование знаний / под ред. Х. Уэно: пер. с япон. – М.: Мир, 1989. – 220 с.

17. Искусственный интеллект и интеллектуальные системы управления / И.М. Макаров, В.М. Лохин, С.В. Манько, М.П. Романов; [отв. ред. И.М. Макарова]; Зайченко Отделение информ. технологий и вычислит. систем РАН. – М.: Наука, 2006. – 333 с.

18. Уоссермен Ф. Нейрокомпьютерная техника: Теория и практика / Ф. Уоссермен. – М.: Мир, 1992. – 184 с.

19. Головкин В.А. Нейронные сети: обучение, организация, применение / В.А. Головкин // Нейрокомпьютеры и их применение: учеб. пособие. – М., 2001. – 256 с.

20. Вежневцев А. Популярныe нейросетевые архитектуры / А. Вежневцев // Компьютерная Графика и Мультимедиа: Сетевой журнал. – 2004. – №2 (1).

Надійшла до редколегії 12.09.2016

Рецензент: д-р техн. наук, проф. О.В. Кувшинов, Військовий інститут телекомунікацій та інформатизації, Київ.

МЕТОД ОБУЧЕНИЯ НЕЧЕТКИХ БАЗ ЗНАНИЙ СИСТЕМ ОБНАРУЖЕНИЯ И ПРЕДОТВРАЩЕНИЯ ВТОРЖЕНИЙ В МОБИЛЬНЫХ РАДИОСЕТЯХ КЛАССА MANET

В.В. Сальник, С.В. Сальник, Е.М. Бовда

В статье предложен метод обучения нечетких баз знаний интеллектуальных систем обнаружения и предотвращения вторжений в мобильных радиосетях класса MANET. Рассмотрены особенности построения узловых баз знаний и методы получения знаний. Разработка метода обучения нечетких баз знаний основывалась на комплексном применении нейронных сетей и нечеткой логики. Суть разработанного метода заключается в модификации метода обучения Хебба, которой основывается на обучении БЗ без учителя при комплексном использовании нечеткой логики и аппарата нейронных сетей. Разработка метода позволила проводить пополнение базы знаний в процессе функционирования системы обнаружения и предотвращения вторжений в мобильных радиосетях класса MANET.

Ключевые слова: база знаний, методы получения знаний, обучение базы знаний, мобильная радиосеть, MANET.

METHOD STUDY OF FUZZY KNOWLEDGE BASES OF INTRUSION DETECTION AND PREVENTION SYSTEMS IN MOBILE RADIO NETWORKS CLASS MANET

S.V. Salnyk, V.V. Salnyk, E.M. Bovda

In the article method study of fuzzy knowledge bases of intelligent systems to detect and prevent intrusions in mobile radio networks class MANET. The features of construction key knowledge bases and methods getting knowledge. Development method learning of fuzzy knowledge bases was based on comprehensive application of neural networks and fuzzy logic. The essence method is a modification method of teaching Hebb, which based on unsupervised learning in knowledge bases integrated use of fuzzy logic and neural networks unit. Development method allowed conduct replenishment base of knowledge in the process functioning system of intrusion detection and prevention in mobile radio networks class MANET.

Keywords: knowledge base, methods getting knowledge, training knowledge base, mobile radio network, MANET.