прихованим каналом. Після знаходження кількох різних методів існує можливість вибору та використання їх залежно від умов у конкретній мережі. Проте, не слід використовувати гібридну комбінацію з декількох полів заголовка, щоб створити канал більшої місткості - навіть якщо не всі, то частина може бути скинута за певних обставин, що призводить до повної неможливості використовувати такий канал.

1. *Кирик М. І., Плесканка Н. М., Тимченко О. В.* Методи та моделі управління трафіком в розподілених інфокомунікаційних системах: моногр. — Львів : Укр. акад. друкарства, 2017. — 264 с. (ISBN 978-966-322-473-2)
2. *Jon Postel*. Internet Protocol – DARPA Internet Program Protocol Specification. RFC 791, september 1981. // http://www.rfc-editor.org/ rfc/rfc791.txt.
3. *Jon Postel.* Transmission Control Protocol – DARPA Internet Program Protocol Specification. RFC 793, september 1981. // http://www.rfc-editor.org/rfc/rfc793.txt.
4. *Steven M. Bellovin*. Defending Against Sequence Number Attacks. RFC 1948, may 1996. // http://www.rfc-editor.org/rfc/rfc1948.txt.
5. *Jeffrey S. Havrilla*. CERT/CC Vulnerability Note VU#498440. Multiple TCP/IP implementations may use statistically predictable initial sequence numbers, marzec 2001. // http://www.kb.cert.org/vuls/id/498440.
6. *K. K. Ramakrishnan*. The Addition of Explicit Congestion Notification (ECN) to IP. RFC 3168, september 2001. // http://www.rfc-editor.org/rfc/rfc3168.txt.
7. *Ємець В., Мельник А., Попович Р.* Сучасна криптографія. Основні поняття. - Львів: БаК, 2003. - 144 с.

Поступила 24.09.2018р.

УДК 004.62

В.Р. Сподарик, НУ «Львівська політехніка»

ВИКОРИСТАННЯ МЕТОДУ ГЛИБИННОГО НАВЧАННЯ ПРИ РОЗРОБЦІ НАЙПРОСТІШИХ СИМУЛЬОВАНИХ ОРГАНІЗМІВ

Розглянуто проблему складності побудови штучних нейронних мереж. Описано з чого складаються, як вони функціонують та для чого можуть використовуватись. Розроблено і описано систему, яка моделює штучні нейрони, які можуть керувати мікроорганізмами у симульованому мікро-світі.

Ключові слова: штучні нейронні мережі, персептрон, функція активації, сигмоїд, глибинне навчання, нейрон.

I. Постановка проблеми

За останні кілька років, частота обговорень на тему алгоритмів машинного навчання, штучного інтелекту, штучних нейромереж та інших

 © В.Р. Сподарик

колись футуристичних термінів, суттєво збільшилась. Це пов’язано з багатьма факторами, але найбільш ймовірні це те, що в світі назбиралось чимало різноманітних даних у практично кожній сфері промисловості та вартість обчислювальних потужностей сильно впала, а їх доступність виросла.

Чимало нових компаній починають з того, що намагаються зробити те саме, що і їх конкуренти тільки з використанням великої кількості даних (big data) та інноваційних алгоритмів. Проте дуже часто використовують саме штучні нейромережі, зокрема мережі з глибинним навчанням (deep learning). Це можна пояснити тим, що вони можуть дати хороші і неочікувані результати на неструктурованих даних, які досягти за допомогою аналітичного способу дуже складно.

Проте чимало розробників та науковців не до кінця розуміють як же ж працюють штучні нейромережі з глибинним навчанням, не говорячи про людей, які трохи віддаленіші від цієї галузі.

II. Мета роботи

Продемонструвати на прикладах, як працює нейромережа з глибинним навчанням, з чого складається та що вона може досягнути на прикладі найпростіших симульованих організмів.

III. Опис алгоритму

Глибинне навчання (також відоме як глибинне структурне навчання, ієрархічне навчання, глибинне машинне навчання, англ. deep learning, deep structured learning, hierarchical learning, deep machine learning) — це галузь машинного навчання, що ґрунтується на наборі алгоритмів, які намагаються моделювати високорівневі абстракції в даних, застосовуючи глибинний граф із декількома обробними шарами, що побудовано з кількох лінійних або нелінійних перетворень.

Глибинне навчання є частиною ширшого сімейства методів машинного навчання, що ґрунтуються на навчанні ознак даних. Спостереження (наприклад, зображення) може бути представлено багатьма способами, такими як вектор значень яскравості для пікселів, або абстрактнішим способом, як множина кромок, областей певної форми тощо. Деякі представлення є кращими за інші у спрощенні задачі навчання (наприклад, розпізнаванню облич, або виразів облич). Однією з обіцянок глибинного навчання є заміна ознак ручної роботи дієвими алгоритмами автоматичного або напівавтоматичного навчання ознак та ієрархічного виділяння ознак.

Дослідження в цій області намагаються зробити кращі представлення та створити моделі для навчання цих представлень з великомасштабних немічених даних. Деякі з цих представлень було зроблено під натхненням досягнень в нейронауці та з мотивів схем обробки та передавання інформації в нервовій системі, таких як нервове кодування, що намагається визначити зв'язок між різноманітними стимулами та пов'язаними нейронними реакціями в мозку.

Різні архітектури глибинного навчання, такі як глибинні нейронні мережі, згорткові глибинні нейронні мережі, глибинні мережі переконань та рекурентні нейронні мережі застосовувалися в таких областях, як комп'ютерне бачення, автоматичне розпізнавання мовлення, обробка природної мови, розпізнавання звуків та біоінформатика, де вони, як було показано, представляють передові результати в різноманітних задачах. [1]

Найпоширенішим видом глибинного і машинного навчання загалом є навчання з учителем, так зване supervised learning. Уявіть собі, що ми хочемо побудувати систему, яка зможе розпізнати на зображенні кота чи собаку. Спочатку нам потрібно зібрати data set, тобто набір даних, який буде складатись з зображень котів, та собак, кожна з яких буде позначена відповідно до своєї категорії.

Протягом самого процесу навчання, машині показується зображення, і в результаті ми отримуємо вектор балів, по одному для кожної категорії, який показує ймовірність, що на цій картинці зображений саме кіт, а не собака.

Наша ціль—щоб “правильна” категорія отримала найвищий бал. Далі ми визначаємо функцію, яка рахує різницю між отриманими оцінками та бажаним шаблоном. Після цього машина модифікує свої параметри так, щоб зменшити похибку. У звичайній машині глибинного навчання може бути сотні мільйонів таких параметрів, як і позначених для тренування прикладів. [2]

Інший спосіб - навчання без вчителя, коли при вирішенні яких випробовувана система спонтанно навчається виконувати поставлене завдання, без втручання з боку експериментатора. З точки зору кібернетики, є одним з видів кібернетичного експерименту. Як правило, це підходить тільки для задач, в яких відомий опис множини об'єктів (навчальна вибірка), і необхідно виявити внутрішні взаємозв'язки, залежності, закономірності, що існують між об'єктами.

Навчання без вчителя часто протиставляється навчанню з учителем, коли для кожного об'єкта, що навчається, примусово задається «правильна відповідь», і потрібно знайти залежність між стимулами та реакціями системи.

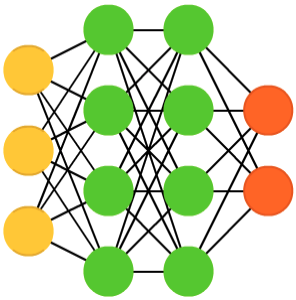

Рис. 1. Структура типової моделі найпростішої штучної нейромережі з глибинним навчанням [3]

На рис. 1 можна зображена загальна структура моделі нейромережі, де в першому стовпчику знаходиться вхідний шар з трьома нейронами, куди подаються дані для аналізу, 2 наступних стовпчики – приховані шари, останні 2 нейрони – вихідний результуючий шар.

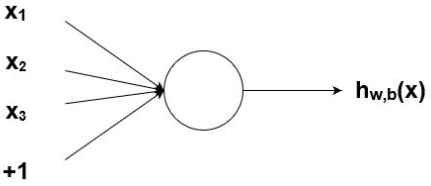

Рис.2. Персептрон – базовий елемент штучної нейронної мережі

Коло на картинці зображує вузол. Вузол є "місцерозташуванням" активаційної функції, він приймає зважені входи, сумує їх, а потім вводить їх в активаційну функцію. Вивід активаційної функції представлений через h. Примітка: у деякій літературі вузол також називають персептроном.

За вагу беруться числа, які потім множаться на вході і сумуються у вузлі. Іншими словами, зважений вхід у вузол має вигляд:

$$x_1w_1+x_2w_2+x_3w_3+b$$

де w_i - числові значення ваги. Ваги нам потрібні, вони є значеннями, які будуть змінюватись протягом процесу навчання. b є вагою елемента зміщення на +1, включення ваги b робить вузол гнучкішим, так як ми можемо змінювати час запуску вузла. Зміщення дуже важливе у випадках, коли потрібно імітувати умовні відносини. [4]

Нейрон імітується у ШНМ через активаційну функцію. Іншими словами, якщо вхід більше, ніж деяке значення, то вихід повинен змінювати стан, наприклад з 0 на 1 або -1 на 1. Це імітує "включення" біологічного нейрону. У якості активаційної функції зазвичай використовують сигмоїдну функцію:, зокрема функція гіперболічного тангенсу, але може бути лінійна функція, бінарна чи будь-яка інша.

$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

IV. Аналіз отриманих результатів

В результаті було розроблено систему, яка складається з поля, певної кількості мікроорганізмів, ресурсів, які можна поїдати та “бомб”. Коли організм стає суттєво більший за сусіда, сусід теж стає ресурсом, який можна «з’їсти».

На початку створювалось 20 організмів, 100 ресурсів та 10 бомб. Кожен організм на вхідні нейрони отримував інформацію про розташування всіх предметів на полі, мав 2 шари прихованих нейронів, та 2 вихідних нейрони (які відповідали за швидкість та напрямок руху). Перше покоління має зовсім довільні ваги. Для кожного покоління вирішено давати можливість зробити 500 кроків, які вирішить зробити штучна нейромережа.

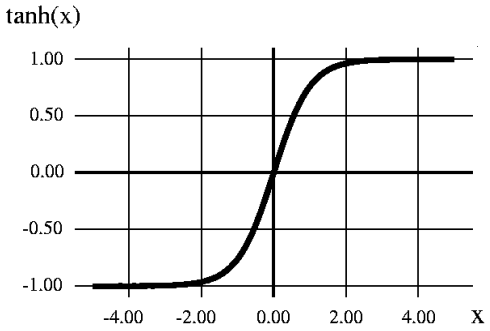

Рис.3. Графік функції гіперболічного тангенсу

Потім проводиться оцінка кількості енергії, яку організм встиг назбирати. На основі цієї інформації обираються кілька кандидатів, які показали себе найкраще і вони переходять до наступного покоління без змін. Дві третіх від решти генеруються на їх основі з довільним збільшенням/зменшенням ваг (частина на 1%, інша частина на 10%). А для решти генерувались просто довільні ваги аби привносити нові потенційно кращі «гени».

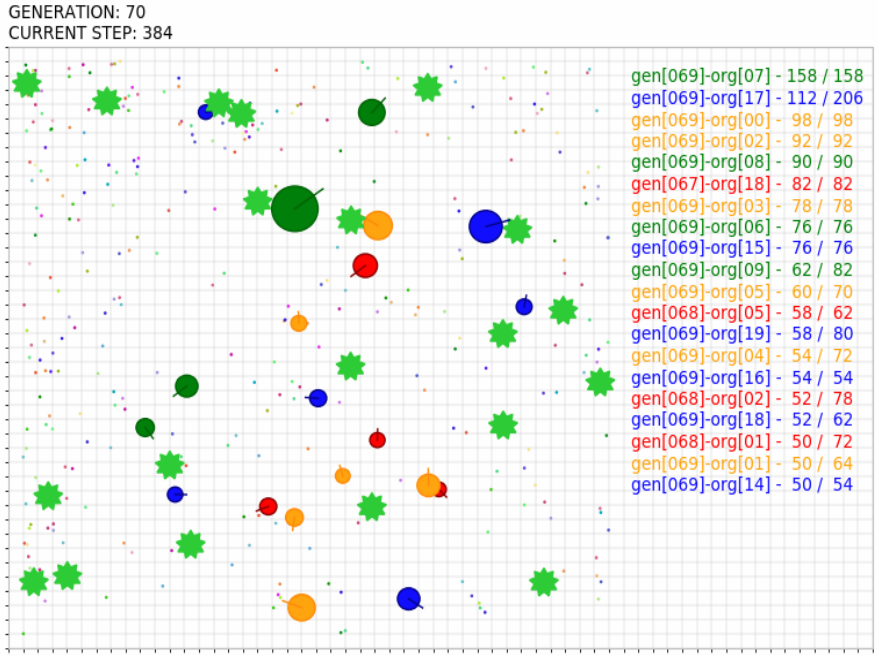

Рис.4. Демонстрація роботи системи

V. Висновки

У даній статті було розглянуто, що таке штучна нейромережа з глибинним навчанням, з чого вона складається, як її тренувати та який результат можна отримати. Продемонстровано на реальному прикладі створення симулятора поля заселеного найпростішими організмами, які можуть поїдати ресурси та один одного. Також описано процес їх еволюції (навчання та розмноження).

Для того щоб ці організми щось навчились, потрібно якомога більше поколінь. Вже десь після 1000-го експерименту, вони рухаються не так хаотично. Проте це потребує великої кількості часу та обчислювальних ресурсів. Також важливо зазначити, що ефективність тренування такої штучної нейронної мережі сильно залежить від обраної функції активації, кількості прихованих шарів та кількості нейронів на кожному з них. Хоча найголовніше, це вхідні дані, на основі яких, нейромережа власне буде намагатись робити прогнози.

1. «Глибинне навчання,» [З мережі]. Available: https://uk.wikipedia.org/wiki/Глибинне_навчання.
2. *С. Холод*, «Коротко про глибинне навчання,» [З мережі]. Available: https://medium.com/@sophiekholod/коротко-про-глибинне-навчання-4c441d556f7c.
3. *S. Kojouharov*, «Cheat Sheets for AI, Neural Networks, Machine Learning, Deep Learning & Big Data,» [З мережі]. Available: https://becominghuman.ai/cheat-sheets-for-ai-neural-networks-machine-learning-deep-learning-big-data-678c51b4b463.
4. «Нейронні мережі - шлях до глибинного навчання,» [З мережі]. Available: https://codeguida.com/post/739.
5. «Штучна нейронна мережа,» [З мережі]. Available: https://uk.wikipedia.org/wiki/Штучна_нейронна_мережа.

Поступила 3.09.2018р.

УДК 528.852

О.В. Зайцев, к.т.н., доцент
Воєнно-дипломатична академія імені Євгенія Березняка, м.Київ

МОДЕЛЬ ОЦІНЮВАННЯ НЕЧІТКОСТІ ГІПОТЕЗ ЩОДО СТАНУ ОБ'ЄКТА НА ОСНОВІ ІНТЕГРОВАНОЇ РІЗНОРІДНОЇ ІНФОРМАЦІЇ

Розроблено модель інтеграції інформації від різних джерел на основі байєсовського підходу. Результати інтегрування інформації з різних джерел оцінюються функцією U-нечіткості гіпотез щодо стану об'єкта інтересу. Апробовано запропоновану модель та наведено результати.

Ключові слова: різнорідна інформація, оцінювання нечіткості гіпотез, інтеграція даних, байєсовський підхід.

© О.В. Зайцев