

DOI: <https://doi.org/10.36910/6775-2524-0560-2023-51-10>

УДК 004.89

Проніна Ольга Ігорівна, к.т.н., доцент,

<https://orcid.org/0000-0001-7085-8027>

Решетников Антон Олександрович, студент

<https://orcid.org/0000-0002-8081-8835>

Державний вищий навчальний заклад «Приазовський державний технічний університет», м. Маріуполь, Україна

ФОРМУВАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ВИРІШЕННЯ ЗАДАЧІ ЛІНІЙНОЇ КЛАСИФІКАЦІЇ

Проніна О.І., Решетников А.О. Формування нейронних мереж для вирішення задачі лінійної класифікації.

Методів вирішення задачі лінійної класифікації існує велика кількість, проте одним із класичних методів вирішення цієї задачі можна назвати використання багатошарових нейронних мереж та баз знань. Тому наявність зручного та інтуїтивно зрозумілого середовища для створення баз знань, а також створення та навчання багатошарових нейронних мереж для аналітика має велике значення. У даній роботі розглядається модель багатошарової нейронної мережі. Проведено аналіз стану проблеми формування нейронних мереж для вирішення задачі класифікації. Розглянуто основні методи та підходи до формування багатошарових нейронних мереж для вирішення задачі класифікації, що застосовуються в дослідницьких цілях. Розроблена модель лягла в основу системи, яка дозволяє формувати та навчати моделі багатошарових нейронних мереж для вирішення задач лінійної класифікації. Усе це разом допоможе полегшити роботу дослідникам, які використовують нейронні мережі для визначення класу певного об'єкту.

Ключові слова: нейронні мережі, багатошаровий перцептрон, лінійна класифікація, навчальна вибірка.

Pronina O., Reshetnykov A. Formation of neural networks for solving the problem of linear classification. There are a large number of methods for solving the linear classification problem, but one of the classic methods for solving this problem is the use of multilayer neural networks and knowledge bases. Therefore, the availability of a convenient and intuitive environment for creating knowledge bases, as well as the creation and training of multilayer neural networks for the analyst is of great importance. In this paper, we consider a model of a multilayer neural network. The analysis of the state of the problem of formation of neural networks for solving the problem of classification is carried out. The main methods and approaches to the formation of multilayer neural networks for solving the problem of classification used for research purposes are considered. The developed model formed the basis of a system that allows you to form and train models of multilayer neural networks for solving problems of linear classification. All this together will help facilitate the work of researchers using neural networks to determine the class of a particular object.

Keywords: neural networks, multilayer perceptron, linear classification, training set.

Постановка наукової проблеми. Задача класифікації у штучному інтелекті це задача розділення множини спостережень та об'єктів на групи, но заснуванні аналізу їх формального опису. У класифікації важливе значення має вибір властивостей (критеріїв), вони можуть бути суттєвими та несуттєвими, відповідно, класифікацію виконану за допомогою суттєвого критерію називають природною, а ту, що виконана на заснуванні несуттєвого критерію – штучною або допоміжною. При класифікації кожна одиниця спостереження буде віднесена до конкретної визначеної групи або категорії на заснуванні деякої якості властивості.

Задача лінійної класифікації полягає в тому, щоб розділити простір властивостей абстрактними багатовимірними площинами на підпростори таким чином, щоб в кожному із цих підпросторів були згруповані об'єкти одного класу або передбачити вірогідність належності об'єкту до кожного із класів, таким чином створюючи скоркарту об'єктів.

У математичній статистиці задачі класифікації називають також задачами дискримінантного аналізу [1].

У машинному навчанні задача класифікації вирішується зазвичай за допомогою навчання з учителем або одним із різновидів такого методу навчання [2].

Задача класифікації представляє собою одну із базових задач прикладної статистики та машинного навчання, а також штучного інтелекту в цілому. Це пов'язано із тим, що класифікація являє собою одну із найбільш зрозумілих та простих для інтерпретації технологій аналізу даних, а правила класифікації можуть бути сформульовані експертом на природній мові.

Сама по собі задача класифікації знайшла своє застосування в таких областях як: торгівля; телекомунікації; медицина; банківська сфера.

У торгівлі класифікація вирішує задачу розділення клієнтів та товарів на групи, що дозволяє оптимізувати маркетингові стратегії, а також стимулювати продажі та значно скорочувати непотрібні витрати.

У сфері телекомунікацій класифікація дозволяє розділити клієнтів за рівнями лояльності, щоб надати за цими рівнями бонуси клієнтам та розробити нові програми лояльності для майбутнього використання.

Для медицини та охорони здоров'я класифікація грає суттєву роль у методах діагностики захворювань, надає можливість виконувати аналіз знімків мозку, рентгену та симптомів, розділюючи захворювання за етапами протікання хвороби або діагностувати тип захворювання за симптомами. Також за допомогою такого підходу можна розділювати населення на групи ризику за схильністю до захворювання.

У банківській сфері класифікація використовується для розділення клієнтів за їхньою кредитною історією для визначення рівня довіри до клієнта, визначення кредитоздатності клієнтів та підтримки прийняття рішень про видачу кредиту клієнтам або відмові у видачі кредиту.

Найрозповсюдженішими методами вирішення задачі класифікації можна назвати нейронні мережі, логістичну регресію, дерева рішень, метод найближчого сусіда, машини опорних векторів та дискримінантний аналіз.

Нейронна мережа представляє собою математичну модель, а також її програмне та апаратне втілення, що реалізується за принципом організації та функціонування природних (біологічних) нейронних мереж, тобто за принципом роботи нервових клітин біологічного організму.

Багат шаровими нейронними мережами ж називають такий підхід до реалізації нейронних мереж, при якому мережа будується таким чином, щоб нейрони в ній були згруповані у шари, при цьому побудова відбувається за принципом поєднання усіх нейронів попереднього шару із усіма нейронами наступного. Важливо зазначити, що в середині одного шару нейрони незалежні та зв'язками не поєднуються. Шари у багат шарових мережах нумеруються зліва направо [3].

Мета дослідження. Метою даної роботи є створення та навчання інтелектуальної системи для формування багат шарових нейронних мереж та баз знань для вирішення завдання лінійної класифікації.

Аналіз останніх досліджень і публікацій.

У наш час можна знайти велику кількість робіт, що присвячені моделям нейронних мереж, побудованих для вирішення задачі класифікації. У цих роботах описані моделі використовуються як для класифікації зображень, так і для вирішення задачі класифікації на заснуванні вибірки даних. Далі наведено огляд статей із метою пошуку оптимального рішення для створення власної інтелектуальної системи для формування нейронних мереж призначених для вирішення завдання лінійної класифікації.

У статті [4] для вирішення завдання класифікації троянд, автор порівнює класифікацію на основі штучної нейронної мережі (ANN), згорткової нейронної мережі (CNN) і алгоритму вилучення ознак (FE). Таким чином, автор статті показує, що третій алгоритм значно прискорює швидкість роботи і значно покращує середню швидкість розпізнавання в порівнянні з першими двома алгоритмами.

У роботі [5] автори застосовують нейромережеві моделі (CNN, BiLSTM і BERT) для отримання корисної інформації з оглядів вин і класифікації вин за різними рейтинговими класами. Використовуючи велику колекцію відгуків про вино від Wine Spectator, дослідження показує, що BERT, нейромережевий фреймворк, нещодавно розроблений Google, має найкращі показники. У двокласовій класифікації (90-100 і 80-89) BERT досягає точності 89.12%, за нею йдуть BiLSTM (88.69%) і CNN (88.02%). У чотирикласній класифікації (95-100, 90-94, 85-89 і 80-84) BERT дає точність 81.57%, тоді як два інших дають точність 80%.

Згорткові нейронні мережі використовуються також у статті [6]. Автори використовують такий підхід для класифікації якості мармуру, розроблена архітектура згорткової нейронної мережі (CNN) та збільшення даних для зразків мармуру значно підвищили точність моделі в діапазоні від 0.922 до 0.961.

У дослідженні [7] впроваджені найсучасніші моделі глибокого навчання, засновані на підході трансферного навчання, для класифікації різних симптомів хвороби на зображеннях рисових рослин. Ефективність провідних попередньо навчених моделей згорткової нейронної мережі VGG-16 і GoogleNet (CNN) на утримуваному наборі даних оцінюється за допомогою методу триразової перехресної валідації. Навчені моделі VGG-16 і GoogleNet CNN досягли середньої точності класифікації 92.24% і 91.28% відповідно.

Проте в роботі [8] для вирішення задачі класифікації сигналів ЕКГ була висунута модель глибокої динамічної нейронної мережі (DDNN). Запропонована модель DDNN є динамічною гібридною моделлю глибокого навчання, що включає вейвлет-блок, згортковий блок, рекурентний блок і блок класифікації характеристик сигналу ЕКГ, але дана модель є дуже складною, тому її реалізацію у даній роботі не можна назвати виправданою.

Ще один варіант підходу до вирішення задачі класифікації представлений у статті [9]. Автори використовують багатошаровий перцептрон (MLP) для класифікації типів ландшафту, варто зазначити, що автори також наголошують на швидкості роботи та малі затрати ресурсів для даного підходу, що грає велику роль при роботі із системою на слабких персональних комп'ютерах.

Наступний приклад використання моделі перцептрону для класифікації наведено у роботі [10], автори використовують комбінацію багатошарового перцептрону та багатоатласного перцептрона для визначення стадії хвороби Альцгеймера. Основною перевагою перцептронів у цій статті автори вважають швидкість роботи та стабільність даної моделі нейронної мережі.

У роботі [11] автори провели масштабне дослідження алгоритмів для класифікації оливкових олій, згідно із результатами дослідження, найякіснішими алгоритмами виявилися алгоритми Random Forest, BayesNet, and LogitBoost зі результатами 93.88%, 91.84% та 93.88% відповідно, тому ці алгоритми було прийнято до уваги при виборі моделі нейронної мережі, що буде формуватися інтелектуальною системою.

Ще один варіант використання перцептрону для класифікації наведено у статті [12]. Автори використовують комбінацію багатошарового перцептрону та агентної моделі для класифікації землекористування та передбачення варіантів землекористування в майбутньому, при цьому багатошаровий перцептрон показав точність передбачення від 0.81 до 0.84, що для цієї моделі є дуже хорошим результатом.

У статті [13] той самий багатошаровий перцептрон використовується авторами для класифікацій та передбачення захворювань, що можуть бути супутниками діабету в людей на заснуванні вибірки даних про їх фізичний стан та даних аналізів. Запропонований алгоритм класифікації точно передбачив дані з вибором підмножини ознак і без неї, що ще раз вказує на універсальність перцептрону.

В останній розглянутій статті [14] автори аналізують життєво важливу інформацію про пацієнта, включаючи історію захворювання, вік, стать та рівень натрію в сироватці крові до та після госпіталізації за допомогою логістичної регресії, k-найближчого сусіда, багатошарового перцептрона та алгоритму класифікації ансамблю екстрадерев. Результати алгоритму класифікації показують, що запропонований MLP алгоритм дає більш високі результати прогнозування в порівнянні з іншими алгоритмами машинного навчання. Також матриця плутанини, оцінка Каппа, квадратне значення R і показники похибки. Результати показують, що класифікація MLP є більш підходящим прогностичним аналізом гіпонатріємії для хворих пацієнтів.

Після докладного аналізу літератури, наукових статей і публікацій, можна зробити висновок, що для кожного конкретного завдання класифікації потрібно підшукувати індивідуальний алгоритм навчання нейронної мережі та її будову, щоб досягнути максимального результату, проте існують методи формування мереж, що є більш розповсюдженими, це багатошаровий перцептрон та згорткові нейронні мережі. Однак багатошаровий перцептрон виступає більш універсальним та надійним рішенням, коли мова йде про задачу класифікації, а також швидшим у роботі, про що свідчать дослідження експертів.

Виклад основного матеріалу й обґрунтування отриманих результатів дослідження. Як відомо, перцептрон представляє собою математичну модель процесу сприйняття, тому через відносну простоту реалізації та надійність передбачення добре підходить для вирішення завдання лінійної класифікації.

Перцептрон дозволяє задовільню основні умови вирішення задач передбачення та класифікації: висока обчислювальна ефективність; відсутність обмежень на функцію розподілення даних; надає можливість обробки різнотипних експериментальних даних. (без перетворення усіх ознак до єдиної шкали) та інваріативність до допустимих шкал перетворення ознак; простота отримання результату та прив'язки до конкретної предметної області; робота при наявності пропусків в таблиці; робота у випадку коли кількість вимірюваних ознак перевищує кількість об'єктів та кількість об'єктів достатньо мала.

Для побудови багатошарового перцептрону було розроблено наступну математичну модель:

$$Z = \{X, Y, W, S, F, K, L, E\}, \quad (1)$$

де Z – множина ознак багатошарового перцептрона, що описується рядом ознак; X – таблиця значень, що поступає на вхід перцептрона, синапси нейрона; Y – дані вихідного шару перцептрона, тобто передбачені їм значення; W – ваги синапсів, які можуть бути як гальмуючими так і посилюючими; S –

взважена сума вхідних сигналів; F – функція активації нейрона, перетворююча взважену суму у вхідний сигнал; K – кількість шарів перцептрону; L – коефіцієнт швидкості навчання; E – кількість епох навчання.

Таблиця значень (позначено як X в моделі) представляє собою вектор вхідних даних, що буде використовуватися спочатку для навчання перцептрону, а після навчання використовуватиметься для передбачення, зазвичай представляє собою вектор, що складається з ознак об'єкту, класифікація якого відбуватиметься в подальшому. Хоча перцептрон може працювати і з текстовими значеннями, хорошою практикою виступає перетворення вектору таким чином, щоб він складався виключно з числових значень.

Ваги синапсів (позначено в моделі як W) – це матриця, ваг переходу до кожного наступного нейрону в наступному шарі із шару попереднього нейрона.

Зважена сума вхідних сигналів або як їх ще називають синапсів (позначено в моделі як S) представляє собою суму ваг синапсів домножених на значення вхідних синапсів плюс зміщення шару.

Функція активації нейрона (позначена як F в моделі) у штучних нейронних мережах визначає вихідний сигнал, що визначається вхідним сигналом чи набором вхідних сигналів.

Кількість шарів перцептрону (в моделі зазначено буквою K) представляє собою кількість прихованих шарів багатошарового перцептрону, що використовується для навчання побудованою моделі. Кількість шарів перцептрону для кожної конкретної вибірки даних підбирається під час аналітичного процесу навчання, тобто буде використовуватися не статична кількість прихованих шарів, а кількість, що користувач інтелектуальної системи самостійно має обрати для навчання моделі для своєї конкретної задачі класифікації.

Коефіцієнт швидкості навчання (в моделі позначено як L) представляє собою параметр градієнтних алгоритмів навчання нейронних мереж, що дозволяє керувати величиною корекції ваг на кожній ітерації навчання, цей коефіцієнт обирається також для кожного конкретного випадку навчання моделі, єдиною умовою для цієї величини є обмеження від 0 до 1. Обрання значення коефіцієнту швидкості навчання є відповідальною справою, тому що занадто велике або мале значення корекції може завадити досягти великої точності моделі.

Кількість епох навчання (в моделі представлено як E) представляє собою кількість проходів для навчання моделі на вхідній вибірці даних та корекції ваг. Одна епоха означає, що кожна вибірка в наборі навчальних даних мала можливість оновити внутрішні параметри моделі. У цій роботі було вирішено використовувати батч (batch), це передбачає, що епоха складається з однієї чи кількох пакетів-партиї та на кожній із епох проходить обробка цього пакету.

Після розробки математичної моделі та з'ясування основних компонентів моделі, а також їх сутності були встановлені наступні характеристики багатошарового перцептрону, що підлягають впливу зі сторони користувача інтелектуальної системи, що розробляється для формування багатошарових нейронних мереж: кількість шарів нейронної мережі; функція активації; коефіцієнт швидкості навчання; кількість епох. А також ті, на які користувач не може здійснювати прямого впливу: вхідна послідовність; вихідна послідовність; ваги синапсів; зважена вага синапсів.

Виходячи з отриманої інформації та математичної моделі, відбувалося подальше проектування та розробка інтелектуальної системи, а також алгоритмів навчання багатошарового перцептрону.

Функція активації нейронної мережі виконує перетворення зваженої суми вхідних сигналів у вихідний сигнал. Стандартна комп'ютерна мікросхема може розглядатися як цифрова мережа функцій активації, які можуть приймати значення «правда» або «брехня» в залежності від входу. Це схоже на поведінку лінійного перцептрону у нейронних мережах. Однак лише нелінійні функції активації дозволяють таким мережам вирішувати нетривіальні завдання з використанням малої кількості вузлів. У штучних нейронних мережах ця функція називається передавальною функцією [3].

Найрозповсюдженішими функціями активації для багатошарового перцептрону можна назвати ReLU, сигмоїдальну та функцію гіперболічного тангенсу, тому їх було вирішено використовувати при реалізації інтелектуальної системи для формування багатошарових нейронних мереж.

Після первинного формування нейронної мережі та вибору функції активації для навчання необхідно підготувати навчальну вибірку та провести оптимізацію значень для покращення якості навчання сформованої моделі.

Обрана модель побудови нейронної мережі, а саме багатошаровий перцептрон, може працювати як і з текстовими даними, так і з навчальними даними де наявні порожні значення, проте це сильно

загальмовує процес навчання моделі. Для позбавлення від цього негативного ефекту існує декілька підходів, які було вирішено реалізувати в інтелектуальній системі для попередньої підготовки вибірки.

В першу чергу потрібно позбавитися від строкових даних, для цього для кожного унікального значення рядку генерується числове значення та усі входження цього рядку у навчальній вибірці замінюються на це число. Для цього зручно використовувати словники, де ключем виступає строкове значення, а значенням виступає числовий еквівалент. Таким чином можна також замінити логічні значення, що задані у вибірці в текстовому форматі, наприклад, якщо логічне значення задане як «true» та «false», то вони будуть замінені на 1 та 0 відповідно.

Наступним кроком у підготовці навчальної вибірки виступає позбавлення від порожніх значень у стовпцях. Для вирішення цієї задачі існує декілька підходів:

- 1) заміна на середнє арифметичне стовпця;
- 2) заміна на випадкове значення від мінімального до максимального значення стовбця за законом нормального розподілення;
- 3) заміна на випадкове значення від мінімального до максимального значення стовбця за іншими законами розподілення.

Кожний із підходів має як свої плюси так і мінуси, наприклад заміна порожнього значення на середнє значення по стовпцю є найшвидшим варіантом обробки вибірки, проте дає однакові значення на усіх пробілах, що може негативно сказатися на кінцевій точності передбачення, через неточність даних. Заміна ж на випадкове значення від мінімального до максимального значення по стовпцю за будь-яким законом розподілення надасть більш природну корекцію навчальної вибірки, тому не так сильно вплине на якість передбачення, проте вимагають набагато більше ресурсів ніж розрахунок середнього арифметичного.

Інтелектуальна система для формування та навчання багат шарових нейронних мереж для вирішення задачі лінійної класифікації, яка була розроблена представляє собою десктопне програмне забезпечення для операційної системи Windows. Сам модуль формування та навчання нейронної мережі також був написаний на високорівневій мові програмування C#.

Для перевірки працездатності системи було вирішено використати класичну задачу лінійної класифікації, а саме задачу класифікації ірисів. Ця задача надасть можливість виявити якість розробленої інтелектуальної системи формування багат шарових нейронних мереж в умовах приближених до максимально сприятливих, тому що іриси мають досить чітку мережу розділення на три основних класи: Setosa, Versicolor та Virginica [15].

В експерименті було досліджено оптимальну структуру нейронної мережі для виконання задачі класифікації ірисів. В таблиці 1 наведено результати експериментів із різною кількістю шарів та кількістю нейронів у прихованих шарах, графік зміни якості навчання моделі під час експерименту можна побачити на рисунку 1, коефіцієнт швидкості навчання та кількість епох під час експерименту не змінювалися, навчання проведено за методом пакетного градієнтного спуску із перемішуванням датасету.

Таблиця 1 – Результати навчання моделі зі зміною кількості шарів та кількості нейронів у прихованих шарах

№ експерименту	Кількість прихованих шарів	Кількість нейронів у шарі	Відсоток розпізнавання, %
1	1	3	60,0
2	1	4	63,1
3	1	5	65,3
4	1	8	68,2
5	2	5	70,8
6	2	8	71,6
7	3	5	74,4
8	3	8	76,7

З аналізу таблиці 1 можна зробити висновок, що оптимальним варіантом для навчання можна вважати 3 прихованих шари та 8 нейронів у прихованих шарах, такий висновок можна зробити з якості передбачення та виходячи із міркувань економії ресурсів. Подальше збільшення кількості не є ліквідним, тому що існує великий ризик перенавчити модель.



Рис. 1 – Графік змін якості навчання мережі протягом експерименту

Дані стосовно кращої будови моделі нейронної мережі, отримані під час цього експерименту, були відібрані для використання у наступному експерименті, в якому проводиться аналіз кількості епох навчання та їх впливу на якість моделі.

Для проведення цього експерименту використовується модель із кількістю шарів та нейронів у прихованих шарах, які були отримані під час попереднього експерименту та той самий датасет для вирішення задачі з лінійної класифікації ірисів, а також ті самі значення коефіцієнту швидкості навчання. Основна мета експерименту – визначення оптимальної кількості епох для навчання моделі багатошарової нейронної мережі. Результати експерименту у вигляді графічного представлення залежності якості навчання моделі від кількості епох можна побачити на рисунку 2.



Рис. 2 – Динаміка змін розпізнавання залежно від кількості епох

Можна помітити, що найкращий результат по співвідношенню якості навчання моделі до затрачених ресурсів спостерігається на кількості епох 100, якість навчання моделі становить 81,01%, при цьому затрати часу для навчання моделі не високі, а сама модель не перенавчена [16].

Навчену модель розробленої нейронної мережі із оптимальною кількістю шарів, нейронів у прихованих шарах та навчена на оптимальній кількості епох було збережено для проведення експерименту із тестування розробленого програмного забезпечення та порівняння із результатами передбачення бази знань, що була заповнена експертом.

Цей експеримент проводився із використанням розробленої інтелектуальної системи для формування багатошарових нейронних мереж для вирішення задачі лінійної класифікації. За допомогою розробленого програмного забезпечення було створено і навчено нейронну мережу для класифікації ірисів. Після цього було відібрано 30 наборів даних ірисів, по 10 варіантів кожного із трьох видів і на цій тестовій вибірці було проведено експеримент. На заснуванні даних, отриманих під

час експерименту було сформовано таблицю 2, в якій наведено підсумок точності розпізнавання по кожному класу.

Таблиця 2 – Підсумок точності розпізнавання по класах

Вихідний клас	Кількість вихідних зображень класу	Кількість вірно розпізнаних зображень	Кількість невірно розпізнаних зображень	Відсоток розпізнавання, %
Setosa	10	10	0	100
Verginica	10	10	0	100
Versicolor	10	10	0	100

Проаналізувавши таблицю 2 можна побачити, що модель справилася з усіма наборами вхідних даних відмінно та змогла розпізнати усі іриси за їх ознаками вірно.

Висновки та перспективи подальшого дослідження. В результаті виконання роботи було розглянуто проблему формування та навчання нейронних мереж для вирішення задачі лінійної класифікації, особливостей процесу навчання, фактори що впливають на навчання мережі, розглянуті традиційні методи та підходи до побудови нейронних мереж, варіанти вирішення задачі лінійної класифікації за допомогою нейронних мереж та архітектури цих мереж.

Було проведено дослідження наукових статей для виявлення оптимального варіанту вирішення задачі лінійної класифікації за допомогою багатошарових нейронних мереж, розглянуто класичну модель перцептронів та алгоритм його навчання, розроблено алгоритм навчання багатошарового перцептронів на мові програмування C# із використанням методу пакетного градієнтного спуску та методу зворотнього розповсюдження помилки, розглянуто та виявлено найрозповсюдженіші функції активації нейронів для перцептронів, розроблено алгоритм підготовки навчальної вибірки для навчання моделі.

Так як система має бути універсальною, було розроблено алгоритм формування багатошарового перцептронів, що надає користувачу можливість налаштувати кількість шарів, кількість нейронів у прихованих шарах, коефіцієнт швидкості навчання, функцію активації та вхідні параметри зі вхідної вибірки.

Список бібліографічного опису

1. Z. Vujovic. Classification Model Evaluation Metrics. International Journal of Advanced Computer Science and Applications. - 2021. Volume 12. 599-606. 10.14569/IJACSA.2021.0120670.
2. P. Breiding, F. Sottile, J. Woodcock. Euclidean Distance Degree and Mixed Volume. Foundations of Computational Mathematics. – 2021. 10.1007/s10208-021-09534-8.
3. A. Rössig, M. Petkovic. Advances in verification of ReLU neural networks. Journal of Global Optimization. – 2021. 81. 1-44. 10.1007/s10898-020-00949-1.
4. Jiaojiao Hui. Research on Rose Classification Based on Neural Network Model. – 2022. 10.21203/rs.3.rs-1689613/v1.
5. Duwani Katumullage, Chenyu Yang, Jackson Barth, Jing Cao. Using Neural Network Models for Wine Review Classification. – 2022. 10.1017/jwe.2022.2.
6. İdris Karaali, Mete Eminağaoğlu. A convolutional neural network model for marble quality classification. – 2020. 10.1007/s42452-020-03520-5.
7. Rajesh Yakkundimath, Girish Saunshi, Basavaraj Anami, Surendra Palaiiah. Classification of Rice Diseases using Convolutional Neural Network Models. – 2022. 10.1007/s40031-021-00704-4.
8. Tsu-Yang Wu, Naidan Feng, Yongquan Liang. A deep dynamic neural network model and its application for ECG classification. – 2022. 10.3233/JIFS-219314.
9. Chengchao Bai, Jifeng Guo, Linli Guo, Junlin Song. Deep Multi-Layer Perception Based Terrain Classification for Planetary Exploration Rovers. – 2020. 10.3390/s19143102.
10. Xin Hong, Kaifeng Huang, Jie Lin, Xiaoyan Ye, Guoxiang Wu, Longfei Chen, E Chen, Siyu Zhao. Combined Multi-Atlas and Multi-Layer Perception for Alzheimer's Disease Classification. – 2022. 10.3389/fnagi.2022.891433.
11. Ozgur Gumus, Erkan Yasar, Z Pinar Gumus, Hasan Ertas. Comparison of different classification algorithms to identify geographic origins of olive oils. – 2019. 10.1007/s13197-019-04189-4.
12. Zohreh Hashemi Aslani, Babak Omidvar, Abdolreza Karbassi. Integrated model for land-use transformation analysis based on multi-layer perception neural network and agent-based model. – 2022. 10.1007/s11356-022-19392-8.
13. Shahebaz Ahmed Khan, Seemakurthi, Akhil Jabbar. Co-Disease Prediction using Multilayer Perceptron and Classification from Diabetic Medical Data Sets. – 2019. 10.14419/ijet.v7i4.6.20450.
14. P. Theerthagiri, C. Krishnan, H. NishanA. Prognostic Analysis of Hyponatremia for Diseased Patients Using Multilayer Perceptron Classification Technique. – 2018. 10.4108/eai.17-3-2021.169032
15. Ke-Lin Du, M.N.s. Swamy. Perceptrons. – 2014. 10.1007/978-1-4471-5571-3_3.
16. Marius-Constantin Popescu, Valentina E. Balasliana Perescu-Popescu, Nikos Mastorakis. Multilayer perceptron and neural networks. – 2019. 1109-2734.

References

1. Z. Vujovic. Classification Model Evaluation Metrics. International Journal of Advanced Computer Science and Applications. - 2021. Volume 12. 599-606. 10.14569/IJACSA.2021.0120670.
2. P. Breiding, F. Sottile, J. Woodcock. Euclidean Distance Degree and Mixed Volume. Foundations of Computational Mathematics. – 2021. 10.1007/s10208-021-09534-8.
3. A. Rössig, M. Petkovic. Advances in verification of ReLU neural networks. Journal of Global Optimization. – 2021. 81. 1-44. 10.1007/s10898-020-00949-1.
4. Jiaojiao Hui. Research on Rose Classification Based on Neural Network Model. – 2022. 10.21203/rs.3.rs-1689613/v1.
5. Duwani Katumullage, Chenyu Yang, Jackson Barth, Jing Cao. Using Neural Network Models for Wine Review Classification. – 2022. 10.1017/jwe.2022.2.
6. İdris Karaali, Mete Eminagaoglu. A convolutional neural network model for marble quality classification. – 2020. 10.1007/s42452-020-03520-5.
7. Rajesh Yakkundimath, Girish Saunshi, Basavaraj Anami, Surendra Palaiah. Classification of Rice Diseases using Convolutional Neural Network Models. – 2022. 10.1007/s40031-021-00704-4.
8. Tsu-Yang Wu, Naidan Feng, Yongquan Liang. A deep dynamic neural network model and its application for ECG classification. – 2022. 10.3233/JIFS-219314.
9. Chengchao Bai, Jifeng Guo, Linli Guo, Junlin Song. Deep Multi-Layer Perception Based Terrain Classification for Planetary Exploration Rovers. – 2020. 10.3390/s19143102.
10. Xin Hong, Kaifeng Huang, Jie Lin, Xiaoyan Ye, Guoxiang Wu, Longfei Chen, E Chen, Siyu Zhao. Combined Multi-Atlas and Multi-Layer Perception for Alzheimer's Disease Classification. – 2022. 10.3389/fnagi.2022.891433.
11. Ozgur Gumus, Erkan Yasar, Z Pinar Gumus, Hasan Ertas. Comparison of different classification algorithms to identify geographic origins of olive oils. – 2019. 10.1007/s13197-019-04189-4.
12. Zohreh Hashemi Aslani, Babak Omidvar, Abdolreza Karbassi. Integrated model for land-use transformation analysis based on multi-layer perception neural network and agent-based model. – 2022. 10.1007/s11356-022-19392-8.
13. Shahebaz Ahmed Khan, Seemakurthi, Akhil Jabbar. Co-Disease Prediction using Multilayer Perceptron and Classification from Diabetic Medical Data Sets. – 2019. 10.14419/ijet.v7i4.6.20450.
14. P. Theerthagiri, C. Krishnan, H. NishanA. Prognostic Analysis of Hyponatremia for Diseased Patients Using Multilayer Perceptron Classification Technique. – 2018. 10.4108/eai.17-3-2021.169032
15. Ke-Lin Du, M.N.s. Swamy. Perceptrons. – 2014. 10.1007/978-1-4471-5571-3_3.
16. Marius-Constantin Popescu, Valentina E. Balasliliana Perescu-Popescu, Nikos Mastorakis. Multilayer perceptron and neural networks. – 2019. 1109-2734.