

В. В. ВІННИЧЕНКО

аспірант

ДВНЗ «Ужгородський національний університет»

ORCID: 0000-0002-8522-7348

ПІДХОДИ МАШИННОГО НАВЧАННЯ ДЛЯ ІНТЕРПРЕТАЦІЇ ВІЗУАЛЬНИХ ДАНИХ В УМОВАХ НЕВИЗНАЧЕНОСТІ

У сфері обчислювального інтелекту інтерпретація візуальних даних лежить в основі безлічі застосувань, від автономних навігаційних систем до медичної діагностики. Однак властива невизначеність, присутня у візуальних даних, що виникає через такі фактори, як шум, оклюзії та мінливість зовнішнього вигляду об'єкта, створює значні проблеми для надійної інтерпретації. Традиційні методи комп'ютерного зору часто борються з неоднозначністю та неточністю даних реального світу, що призводить до пошуку на більш адаптивні та стійкі методи. Машинне навчання з його здатністю вчитися на складних шаблонах даних і адаптуватися до них стає ключовим рішенням цієї головоломки. У цьому документі досліджуються передові підходи машинного навчання, призначені для інтерпретації невизначених візуальних даних, що має вирішальне значення для підвищення точності та надійності автоматизованого візуального розуміння. Поява машинного навчання у сфері інтерпретації візуальних даних започаткував зміну парадигми, перехід від обробки на основі правил до навчання, керованого даними. Серед безлічі проблем невизначена інтерпретація візуальних даних вимагає тонкого підходу, коли система повинна не лише розпізнавати закономірності, але й кількісно оцінювати та керувати невизначеністю, притаманною вхідним даним. Ця невизначеність може проявлятися в різних формах, включаючи, але не обмежуючись цим, шум датчика, часткові оклюзії та неоднозначні межі об'єктів, які разом погіршують продуктивність звичайних систем перекладу. Тому ця наукова стаття спрямована на аналіз різних моделей і алгоритмів машинного навчання, які спеціально розроблені або адаптовані для інтерпретації візуальних даних в умовах невизначеності. Він зосереджений на розумінні того, як ці методи можуть ефективно обробляти та інтерпретувати дані, які є неоднозначними, неповними або спотвореними. Метою дослідження є вибір оптимального підходу до аналізу візуальних даних за допомогою штучного інтелекту в умовах невизначеності. Основною задачею дослідження є аналіз методів класифікації на основі відомих нейронних мереж, які орієнтовані на обробку та розпізнавання образів зображень.

Ключові слова: штучний інтелект, комп'ютерний зір, нейронні мережі, штучні нейронні мережі, згорткові нейронні мережі, рекурентні нейронні мережі, розпізнавання образів.

V. V. VINNYCHENKO

Postgraduate Student

Uzhhorod National University

ORCID: 0000-0002-8522-7348

MACHINE LEARNING APPROACHES FOR INTERPRETING VISUAL DATA UNDER CONDITIONS OF UNCERTAINTY

In the field of computational intelligence, the interpretation of visual data underlies many applications, from autonomous navigation systems to medical diagnostics. However, the inherent uncertainty present in visual data due to factors such as noise, occlusions, and variability in object appearance pose significant challenges to reliable interpretation. Traditional computer vision methods often struggle with the ambiguity and inaccuracy of real-world data, leading to a demand for more adaptive and robust methods. Machine learning, with its ability to learn from and adapt to complex data patterns, becomes a key solution to this puzzle. This paper explores advanced machine learning approaches designed to interpret uncertain visual data, which is critical to improving the accuracy and reliability of automated visual understanding. The emergence of machine learning in the field of visual data interpretation initiated a paradigm shift from rule-based processing to data-driven learning. Among the many challenges, the uncertain interpretation of visual data requires a fine-grained approach where the system must not only recognize patterns, but also quantify and manage the uncertainty inherent in the input data. This uncertainty can take many forms, including but not limited to sensor noise, partial occlusions, and ambiguous object boundaries, which together degrade the performance of conventional translation systems. Therefore, this research paper aims to analyze various machine learning models and algorithms that are specially developed or adapted for the interpretation of visual data under conditions of uncertainty. It focuses on understanding how these techniques can effectively process and interpret data that is ambiguous, incomplete, or distorted. The purpose of the research is to choose the optimal approach to the analysis of visual data using artificial intelligence under conditions of uncertainty. The main task of the research is the analysis of classification methods based on well-known neural networks, which are focused on the processing and recognition of image patterns.

Key words: artificial intelligence, computer vision, neural networks, artificial neural networks, convolutional neural networks, recurrent neural networks, pattern recognition.

Постановка проблеми

Дослідження машинного навчання, особливо у галузі обробки невизначених візуальних даних, виявило кілька серйозних проблем, які суттєво впливають на ефективність існуючих підходів. Однією з важливих проблем є природа самих невизначених візуальних даних; він часто неповний, галасливий та двозначний. Такі характеристики створюють суттєві перешкоди для алгоритмів машинного навчання, які зазвичай покладаються на точні та зрозумілі дані для ефективного навчання. Притаманна невизначеність вимагає розробки моделей, які можуть допускати неточності, а й виводити недостатню інформацію щоб одержати точних прогнозів.

Крім того, висока розмірність візуальних даних ще більше посилює ці проблеми. Моделі машинного навчання важко справляються із завданням ефективного обробки та аналізу цих об'ємних даних без втрати важливої інформації. Це з прокляттям розмірності, коли продуктивність алгоритмів знижується зі збільшенням розмірності даних. Як наслідок, методи вибору ознак та зменшення розмірності набувають вирішального значення, проте визначення найбільш значущих ознак без відкидання інформації, яка може мати життєво важливе значення в контексті невизначеності, стає складним завданням.

Більше того, динамічний характер візуального середовища додає ще одного рівня складності. Зміни освітлення, перспективи та оклюзії можуть суттєво вплинути на зовнішній вигляд візуальних даних, збільшуючи невизначеність. Алгоритми машинного навчання мають бути адаптивними та надійними, щоб справлятися з такими змінами, проте багатьом сучасним моделям не вистачає гнучкості, щоб робити це ефективно. Вони часто не можуть добре узагальнити різні умови, що призводить до зниження точності та надійності.

Ще одним важливим завданням є розробка узагальнених моделей, які можуть добре працювати у різних завданнях та умовах. Багато існуючих алгоритмів машинного навчання призначені для вирішення конкретних завдань і можуть неефективно працювати поза передбачуваним контекстом. Відсутність можливості узагальнення обмежує застосування таких моделей до ширшого кола завдань, що вимагає створення більш універсальних та адаптованих алгоритмів.

Аналіз останніх досліджень і публікацій

Нещодавні досягнення в машинному навчанні, зокрема в архітектурах глибокого навчання, таких як згорткові нейронні мережі (CNN), генеративні змагальні мережі (GAN) і байєсовські нейронні мережі, показали багатообіцяючі можливості для вирішення цих проблем. Ці моделі, завдяки своїй складній архітектурі та алгоритмам навчання, можуть витягувати значущі шаблони з даних, враховувати неоднозначність, притаманну візуальним вхідним даним, і надавати імовірнісні результати, які пропонують кількісно вимірювану міру невизначеності.

Технології автономного водіння в основному покладаються на машинне навчання, щоб зрозуміти складне, динамічне та часто невизначене візуальне середовище. Ці системи об'єднують дані з багатьох датчиків, включаючи камери, LiDAR і радар, щоб створити повне розуміння оточення автомобіля. Проблема полягає в тому, щоб інтерпретувати ці дані в умовах змінних умов, таких як зміна погоди, різне освітлення та непередбачувана поведінка інших учасників дорожнього руху. Алгоритми машинного навчання, особливо глибокі нейронні мережі, навчаються на величезних наборах даних, щоб розпізнавати дорожні знаки, пішоходів, інші транспортні засоби та дорожню розмітку, навіть якщо ці елементи частково затемнені або спотворені. Здатність точно інтерпретувати такі невизначені візуальні дані має вирішальне значення для прийняття рішень у режимі реального часу, забезпечення безпеки та надійності автономних транспортних засобів і підтримки функцій ADAS, таких як автоматичне гальмування, допомога в утриманні смуги руху та виявлення пішоходів [1, с. 5].

У галузі медицини моделі машинного навчання відіграють ключову роль в інтерпретації візуальних даних, отриманих різними методами візуалізації (МРТ, КТ, рентген), щоб допомогти в діагностиці, плануванні лікування та моніторингу прогресування захворювання. Ці моделі стикаються з проблемою розшифровки зображень, які можуть містити неоднозначні або ледве помітні ознаки патології, часто приховані через складність біологічних структур або наявність артефактів. Удосконалені методи машинного навчання, включаючи згорткові нейронні мережі та трансферне навчання, продемонстрували надзвичайні можливості в ідентифікації та класифікації пухлин, прогнозуванні розвитку захворювань і сегментації анатомічних структур. Це не тільки підвищує діагностичну точність, але й полегшує персоналізовану медицину шляхом адаптації планів лікування до стану окремих пацієнтів, що значно впливає на результати пацієнтів та ефективність медичної допомоги [2, с. 3].

Також у контексті російської збройної агресії проти України машинне навчання підвищує точність і швидкість ідентифікації та відстеження цілей, аналізуючи дані з кількох датчиків у режимі реального часу. Ці системи навчені розпізнавати конкретні військові цілі, такі як літаки, кораблі чи бронетехніка, серед безлічі цивільних об'єктів за різних умов навколишнього середовища та рівнів візуальної оклюзії. Завдяки точному визначенню та відстеженню цілей алгоритми машинного навчання підтримують системи наведення ракет, повітряні бойові безпілотні літальні апарати та наземні системи захисту, забезпечуючи високий рівень точності та знижуючи ризик супутнього збитку [3, с. 8].

Хоча машинне навчання не пов'язане безпосередньо з інтерпретацією візуальних даних, воно також відіграє важливу роль у військовій кібербезпеці та зусиллях у сфері інформаційної війни. Алгоритми машинного навчання

аналізують шаблони трафіку даних, щоб виявити аномалії, які можуть вказувати на кібератаки або шпигунську діяльність [4, с. 7]. У контексті інформаційної війни машинне навчання може допомогти в аналізі соціальних медіа та онлайн-вмісту для виявлення дезінформаційних кампаній або психологічних операцій, які часто включають аналіз мультимедійного вмісту, включаючи зображення та відео, для розуміння та протидії цим операціям.

Формулювання мети дослідження

Мета цього дослідження полягає в тому, щоб проаналізувати сучасні підходи машинного навчання для інтерпретації візуальних даних в умовах невизначеності. Дослідження має на меті виявити основні виклики та обмеження існуючих методів, зокрема проблеми з неповними, зашумленими даними та високою розмірністю. Особлива увага приділяється оцінці застосування згорткових нейронних мереж (CNN), байєсовських нейронних мереж (BNN) та інших сучасних архітектур для вирішення проблем візуальних невизначеностей у різних сферах, таких як автономне водіння, медицина та військові технології.

Викладення основного матеріалу дослідження

Підходи до аналізу даних за умов невизначеності за допомогою машинного навчання

При вивченні підходів до аналізу даних в умовах невизначеності з використанням машинного навчання стає обов'язковим враховувати нюанси методологій, які використовуються для керування та інтерпретації неоднозначної чи неповної інформації. Одним з основних підходів є ймовірнісне моделювання, при якому розподіли ймовірностей використовуються для вираження невизначеностей над змінними. Наприклад, байєсовські методи дозволяють інтегрувати попередні знання з даними, що спостерігаються, оновлюючи уявлення про параметри моделі або прогнози в міру появи нових даних. Це особливо ефективно у сценаріях, де даних мало або вони зашумлені, оскільки включення попередніх розподілів може спрямовувати процес навчання, роблячи його стійкішим до невизначеностей.

Байєсівська нейронна мережа (BNN)

Байєсівська нейронна мережа (BNN) – це тип нейронної мережі, яка застосовує принципи байєсівської ймовірності для оцінки невизначеності прогнозів. На відміну від традиційних нейронних мереж, які надають точкові оцінки як прогнози, BNN пропонують ймовірнісну інтерпретацію, розміщуючи розподіли за вагами мережі. Цей підхід дозволяє BNN як прогнозувати результат, а й кількісно оцінювати невизначеність його прогнозу, забезпечуючи повніше уявлення про процес прийняття рішень.

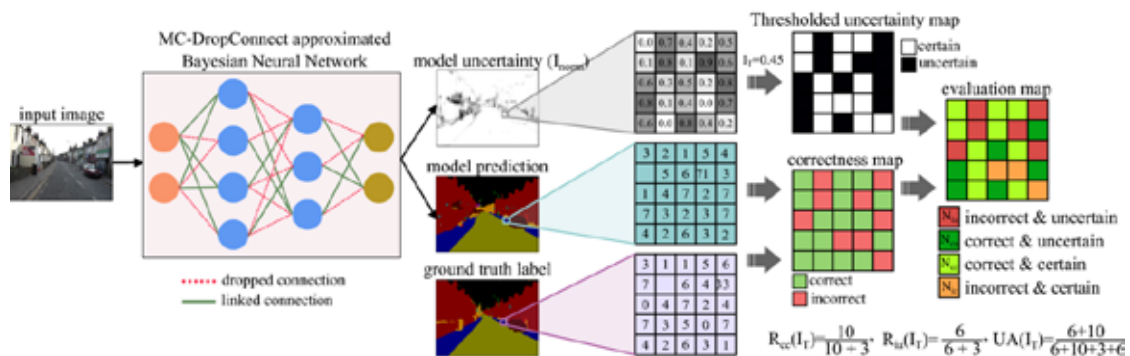


Рис. 1. Загальна архітектура згорткової нейронної мережі BNN

Робота BNN починається з визначення апіорних розподілів по терезах мережі, що представляють наші переконання про терези до спостереження будь-яких даних. Оскільки дані подаються в мережу під час навчання, теорема Байєса застосовується для оновлення цих апіорних значень до апостеріорних, відображаючи наші оновлені уявлення про терези після розгляду доказів, наданих даними. Цей процес включає обчислення ймовірності спостереження даних з урахуванням ваг і об'єднання їх з попередніми даними для отримання апостеріорного розподілу по вагах.

Оскільки обчислення справжнього апостеріорного розподілу часто складно для мереж, що становлять практичний інтерес, використовуються різні методи апроксимації, такі як метод варіаційного виведення або методи Монте-Карло з марковським ланцюгом (MCMC). Після навчання мережі для будь-якого заданого вхідного сигналу BNN використовує ці апостеріорні розподіли по терезах для генерації розподілу за вихідними даними, забезпечуючи тим самим як прогноз, так і міру його невизначеності [5, с. 5].

Переваги:

- BNN природним чином визначають кількісну невизначеність у своїх прогнозах, що є неоціненним для критично важливих програмних засобів, таких як охорона здоров'я або автономне водіння, де прийняття рішень в умовах невизначеності має вирішальне значення.

- Імовірнісна природа BNN пропонує форму регуляризації, що потенційно зменшує перенавчання за рахунок інтеграції ваг замість їх прив'язки до точкових оцінок.
 - Подібно до інших байєсовських моделей, BNN можуть включати попередні знання за допомогою вибору апіорних розподілів ваг, що потенційно підвищує продуктивність при нестачі даних.
 - Завдяки ефективному використанню попередніх знань та зосередженню уваги на розподілах за параметрами, BNN можуть працювати краще, ніж традиційні нейронні мережі у сценаріях з обмеженими даними [6, с. 8].
- Мінуси BNN:
- Процес навчання BNN та апроксимації апостеріорних розподілів за вагами потребує більше обчислювальних зусиль, ніж навчання традиційних нейронних мереж, вимагаючи більше обчислювальних ресурсів та часу [7, с. 10].
 - Реалізація BNN та пов'язаних з ними методів апостеріорної апроксимації може бути складним завданням, що потребує досвіду як у глибокому навчанні, так і у байєсівському висновку.
 - Незважаючи на досягнуті успіхи, масштабування BNN до великих наборів даних або складних моделей залишається проблемою через обчислювальні витрати, пов'язані з обчисленням або апроксимацією апостеріорних даних.
 - Вибір апіорних розподілів може суттєво вплинути на продуктивність BNN, а непридатні апіорні значення можуть призвести до поганої продуктивності моделі, ускладнюючи процес вибору моделі.

Згорткові нейронні мережі (CNN)

Згорткова нейронна мережа (CNN) – це клас глибоких нейронних мереж, які найчастіше застосовуються для аналізу візуальних зображень. Він спеціально розроблений для обробки піксельних даних та використовується в різних додатках, включаючи розпізнавання зображень та відео, класифікацію зображень, аналіз медичних зображень та обробку природної мови.

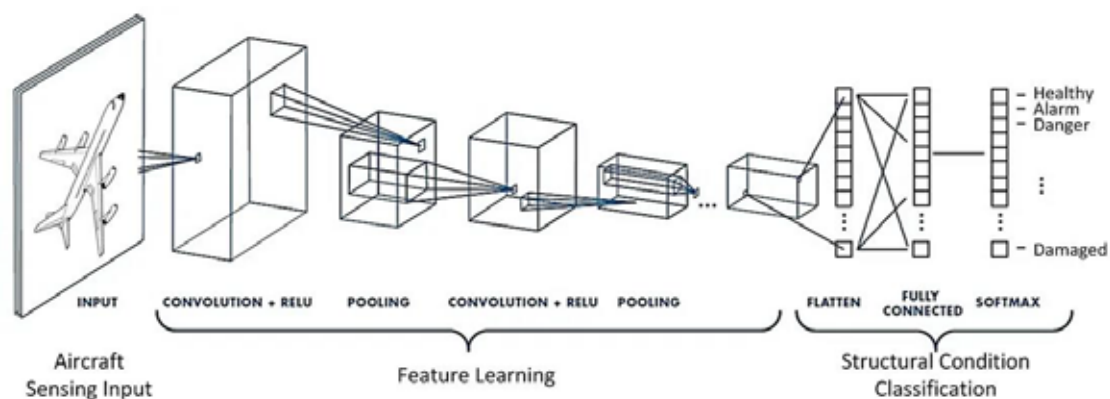


Рис. 2. Загальна архітектура згорткової нейронної мережі CNN

Основний принцип роботи CNN включає кілька рівнів, які обробляють і перетворюють зображення для вилучення ознак і виконання завдань класифікації або виявлення. Спочатку вхідне зображення проходить через серію згорткових шарів, де до зображення застосовуються фільтри (або ядра) для створення карток об'єктів, які ідентифікують певні функції, такі як краї, текстури або форми. Після згортковими шарами шари об'єднання (зниження дозволу) зменшують розмірність карт об'єктів, роблячи виявлення об'єктів інваріантним до масштабу і орієнтації. Після кількох згорткових шарів та шарів об'єднання високорівневі міркування в нейронній мережі виконуються через пов'язані рівні, де мережа класифікує зображення на основі функцій, витягнутих на попередніх шарах. Функція, звана функцією активації, наприклад ReLU, застосовується після кожної операції згортки, щоб внести нелінійність до моделі, дозволяючи їй вивчати складні закономірності [8, с. 7].

Короткий перелік переваг згорткових нейронних мереж:

- Автоматичне вилучення функцій. На відміну від традиційних алгоритмів, CNN автоматично виявляють та вивчають важливі функції без будь-якого втручання людини.
- Інваріантність перетворення зображення: CNN можуть розпізнавати об'єкти незалежно від змін положення, розміру або орієнтації в полі зображення через об'єднання шарів.
- Ефективна обробка зображень. Завдяки загальним вагам у згорткових шарах та об'єднанню в пули CNN вимагають менше параметрів, ніж повністю пов'язані мережі, що робить їх ефективнішими [9, с. 204].
- Універсальність. Їх можна застосовувати для вирішення широкого спектра завдань, крім розпізнавання зображень, включаючи обробку природної мови та прогнозування часових рядів.

Наступний список містить недоліки згорткових нейронних мереж:

- Високі обчислювальні витрати. Навчання CNN може бути трудомістким та трудомістким, що потребує потужного обладнання, зазвичай із високопродуктивними графічними процесорами.
- Ризик перенавчання. Без належної регуляризації та збільшення навчальних даних CNN мають тенденцію до перенавчання, особливо коли мережа дуже глибока або набір даних обмежений.
- Природа «чорної скриньки». Внутрішню роботу CNN іноді буває важко інтерпретувати, що ускладнює розуміння того, чому мережа прийняла те чи інше рішення.
- Для гарної роботи CNN зазвичай потрібні великі обсяги помічених навчальних даних, що може стати серйозною перешкодою в деяких додатках.

Рекурентні нейронні мережі (RNN)

Рекурентна нейронна мережа (RNN) – це клас штучних нейронних мереж, у яких зв'язки між вузлами утворюють орієнтований граф вздовж тимчасової послідовності. Ця архітектура дозволяє їй демонструвати тимчасову динамічну поведінку і обробляти як окремі точки даних, а й цілі послідовності даних, як-от мова, текст чи відео. На відміну від нейронних мереж з прямим зв'язком, RNN можуть використовувати свій внутрішній стан (пам'ять) для обробки послідовностей вхідних даних, що робить їх потужними для вирішення таких завдань, як моделювання мови, розпізнавання мови та прогнозування часових рядів [10, с. 243].

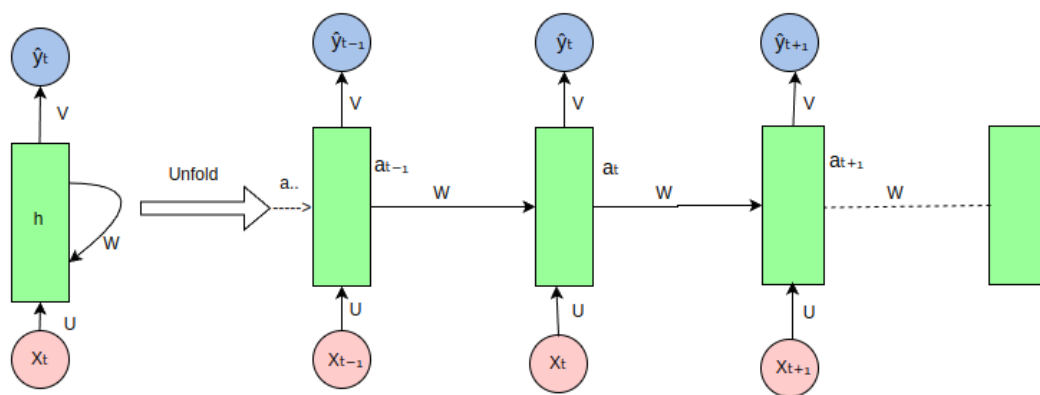


Рис. 3. Рекурентна нейронна мережа (RNN)

Принцип роботи даної моделі полягає в тому, що вона обробляє послідовності, перебираючи елементи та підтримуючи стан, що містить інформацію щодо того, що вона бачила досі. По суті, на кожному етапі послідовності RNN приймає два вхідні сигнали: поточний елемент та попередній стан. Він поєднує ці вхідні дані для генерації вихідних даних та оновлення свого стану, яке потім передається на наступний крок послідовності. Цей процес дозволяє мережі приймати рішення з урахуванням інформації, накопиченої попередніх етапах послідовності.

Головні переваги рекурентних нейронних мереж:

- Пам'ять: їхня здатність пов'язувати попередню інформацію з поточним завданням (наприклад, попередні слова для прогнозування наступного слова у реченні) робить їх ідеальними для послідовних завдань.
- Гнучкість довжини введення/виводу. На відміну від багатьох інших нейронних архітектур, RNN можуть обробляти вхідні та вихідні дані різної довжини, що робить їх універсальними для широкого спектру програмних засобів.
- Застосовність: RNN широко застосовні для вирішення різних завдань, пов'язаних із передбаченням послідовностей, таких як обробка природної мови, розпізнавання мови та прогнозування часових рядів.

Мінуси нейронних мереж рекурентного типу:

- Проблема зникнення/вибухового градієнта: RNN схильні до цих проблем під час навчання, що ускладнює вивчення довгострокових залежностей у даних.
- Інтенсивність обчислень. Поетапна обробка послідовностей та підтримка стану на всіх цих етапах може призвести до високих обчислювальних витрат, особливо для довгих послідовностей [11, с. 6].
- Проблема розпаралелювання. Через свою послідовну природу RNN нелегко розпаралелити, що обмежує швидкість навчання та виведення в порівнянні з іншими архітектурами, що допускають паралельну обробку вхідних даних.

Висновки

В результаті проведеного дослідження слід відзначити, що рекурентні нейронні мережі (RNN), згорткові нейронні мережі (CNN) і байєсівські нейронні мережі (BNN) відіграють ключову роль у розвитку галузі машинного навчання, кожна з яких має свої архітектурні особливості та додатки. RNN чудово справляються з обробкою послідовних даних, що робить їх ідеальними для програмних засобів мовної обробки та аналізу часових

рядів, але їм доводиться боротися з довгостроковими залежностями та інтенсивністю обчислень. CNN, з іншого боку, дуже ефективні для завдань розпізнавання та обробки зображень, отримуючи вигоду зі своєї здатності автоматично вивчати та узагальнювати функції на основі візуальних вхідних даних, хоча і за рахунок необхідності значних обчислювальних ресурсів та великих наборів даних для оптимальної продуктивності. BNN привносять ймовірні міркування в нейронні мережі, пропонуючи засоби кількісної оцінки невизначеності в прогнозах, що має вирішальне значення для прийняття рішень в критично важливих додатках та за умов невизначеності. Однак складність їх реалізації та пов'язані з цим обчислювальні витрати створюють серйозні проблеми. У сукупності розуміння сильних і слабких сторін цих архітектур нейронних мереж має вирішальне значення для використання їх можливостей у різних галузях, вказуючи на майбутнє, в якому гібридні або спеціалізовані моделі зможуть подолати існуючі обмеження, підвищуючи як продуктивність, так і застосування моделей машинного навчання при вирішенні складних задач. Тому враховуючи переваги та недоліки досліджених нейронних мереж в даній роботі, дійшли висновку, що баєсівська нейронна мережа (BNN) найкраще підходить для аналізу візуальних даних за допомогою штучного інтелекту в умовах невизначеності, проте з деякими обмеженнями. Отримані результати потребують проведення додаткового, більш глибокого аналізу роботи баєсівської нейронної мережі для розуміння реальних обмежень у роботі за умов невизначеності.

Список використаної літератури

1. Abhishek G., Alagan A., Ling G., Ahmed S. K. Deep learning for object detection and scene perception in self-driving cars: Survey, challenges, and open issues. *Array*. 2021. Т. 1, № 10. С. 1-10. DOI: <https://doi.org/10.1016/j.array.2021.100057>
2. Arshi P., Muhammad A. K., Rukhsana Z., Huma A., Muhammad A., Muhammad M. F. Vision Transformers in medical computer vision. *Engineering Applications of Artificial Intelligence*. 2023. Т. 1, № 122. С. 1-10. DOI: <https://doi.org/10.1016/j.engappai.2023.106126>
3. Lee M., Valisetty R., Breuer A., Kirk K. Current and Future Applications of Machine Learning for the US Army. URL: <https://apps.dtic.mil/sti/pdfs/AD1050263.pdf> (дата звернення: 20.10.2024).
4. Karaman M., Çatalkaya H., Aybar C. Institutional Cybersecurity from Military Perspective. *International journal of information security science*. 2016. № 5. – С. 1-11. – URL: https://www.researchgate.net/publication/299533127_Institutional_Cybersecurity_from_Military_Perspective
5. Chang D. T. Bayesian Neural Networks: Essentials. URL: https://www.researchgate.net/publication/353067263_Bayesian_Neural_Networks_Essentials (дата звернення: 20.10.2024).
6. Rabaey P., De Boom C., Demeester T. Neural Bayesian Network Understudy. URL: https://www.researchgate.net/publication/365422792_Neural_Bayesian_Network_Understudy (дата звернення: 20.10.2024).
7. Bonnet D., Hirtzlin T., Majumdar A., Dalgaty T. Bringing uncertainty quantification to the extreme-edge with memristor-based Bayesian neural networks. *Nature Communications*. 2023. Т. 1, № 14. С. 3-10. DOI: <http://dx.doi.org/10.1038/s41467-023-43317-9>
8. Khan Tareen S., Khan Tareen F. Convolutional Neural Networks for Beginners. *SSRN Electronic Journal*. 2023. С. 1-10. URL: https://www.researchgate.net/publication/373813288_Convolutional_Neural_Networks_for_Beginners
9. Liu C. Research on image classification leveraging deep convolutional neural networks and visual. *Applied and Computational Engineering*. 2024. Т. 1, № 32. С. 200-209. DOI: <https://doi.org/10.54254/2755-2721/32/20230212>
10. Wang R. (2024). Generalisation of Feed-Forward Neural Networks and Recurrent Neural Networks. *Applied and Computational Engineering*. 2024. Т. 1, № 40. С. 242-246. DOI: <https://doi.org/10.54254/2755-2721/40/20230659>
11. Agrwal P., Kumar S., Shekhar Yadav C. Denoising watermarked images using Bidirectional Recurrent Convolutional Neural Networks. URL: https://www.researchgate.net/publication/371899317_Denoising_watermarked_images_using_Bidirectional_Recurrent_Convolutional_Neural_Networks (дата звернення: 20.10.2024).

References

1. Abhishek G., Alagan A., Ling G., Ahmed S. K. (2021) Deep learning for object detection and scene perception in self-driving cars: Survey, challenges, and open issues. *Array*. Т. 1, № 10. С. 1-10. DOI: <https://doi.org/10.1016/j.array.2021.100057>
2. Arshi P., Muhammad A. K., Rukhsana Z., Huma A., Muhammad A., Muhammad M. F. (2023) Vision Transformers in medical computer vision. *Engineering Applications of Artificial Intelligence*. Т. 1, № 122. С. 1-10. DOI: <https://doi.org/10.1016/j.engappai.2023.106126>
3. Lee M., Valisetty R., Breuer A., Kirk K. Current and Future Applications of Machine Learning for the US Army. URL: <https://apps.dtic.mil/sti/pdfs/AD1050263.pdf> (visited at: 20.10.2024).
4. Karaman M., Çatalkaya H., Aybar C. (2016) Institutional Cybersecurity from Military Perspective. *International journal of information security science*. № 5. – С. 1-11. – URL: https://www.researchgate.net/publication/299533127_Institutional_Cybersecurity_from_Military_Perspective

5. Chang D. T. Bayesian Neural Networks: Essentials. URL: https://www.researchgate.net/publication/353067263_Bayesian_Neural_Networks_Essentials (visited at: 20.10.2024).
6. Rabaey P., De Boom C., Demeester. T. Neural Bayesian Network Understudy. URL: https://www.researchgate.net/publication/365422792_Neural_Bayesian_Network_Understudy (visited at: 20.10.2024).
7. Bonnet D., Hirtzlin T., Majumdar A., Dalgaty T. (2023) Bringing uncertainty quantification to the extreme-edge with memristor-based Bayesian neural networks. *Nature Communications*. T. 1, № 14. C. 3-10. DOI: <http://dx.doi.org/10.1038/s41467-023-43317-9>
8. Khan Tareen S., Khan Tareen F. (2023) Convolutional Neural Networks for Beginners. *SSRN Electronic Journal*. C. 1-10. URL: https://www.researchgate.net/publication/373813288_Convolutional_Neural_Networks_for_Beginners
9. Liu C. (2024) Research on image classification leveraging deep convolutional neural networks and visual. *Applied and Computational Engineering*. T. 1, № 32. C. 200-209. DOI: <https://doi.org/10.54254/2755-2721/32/20230212>
10. Wang R. (2024). Generalisation of Feed-Forward Neural Networks and Recurrent Neural Networks. *Applied and Computational Engineering*. 2024. T. 1, № 40. C. 242-246. DOI: <https://doi.org/10.54254/2755-2721/40/20230659>
11. Agrwal P., Kumar S., Shekhar Yadav C. Denoising watermarked images using Bidirectional Recurrent Convolutional Neural Networks. URL: https://www.researchgate.net/publication/371899317_Denoising_watermarked_images_using_Bidirectional_Recurrent_Convolutional_Neural_Networks (visited at: 20.10.2024).