

байєсівського класифікатора. Переваги даного методу у можливості виконувати класифікацію навіть за умов відсутності частини вхідних даних [1].

Байєсівський класифікатор заснований на принципі максимуму апостеріорної ймовірності. Для об'єкта, що класифікується, обчислюються функції правдоподібності кожного з класів, потім апостеріорні ймовірності класів. Об'єкт відноситься до того класу, ймовірність якого максимальна. Алгоритм передбачає, що наявність якої-небудь ознаки в класі не пов'язано з наявністю будь-якої іншої ознаки. Спрощено формулу для даного алгоритму можна представити таким чином:

$$P(H_k|A) = \frac{P(H_k) * P(A|H_k)}{P(A)},$$

де $P(H_k)$ – апіорна ймовірність події H_k , $P(H_k|A)$ – ймовірність події H_k при настанні A , $P(A|H_k)$ – ймовірність події A при настанні H_k , $P(A)$ – повна ймовірність події A .

Вирахувані за формулою числові значення являють собою ступінь прояву хвороб у клінічній практиці.

ВИСНОВКИ

Точна класифікація діагнозів дозволяє покращити якість надання медичних послуг і може бути отримана за допомогою впровадження моделі Байєса.

ЛІТЕРАТУРА

1. Розыходжаева Д. А., Розыходжаева Г. А. Методы интеллектуального анализа данных в диагностировании сердечно-сосудистых заболеваний // Техника. Технологии. Инженерия. — 2017. — №3

Маценко Р. В.,

Криворізький національний університет

Купін А.І.,

д.т.н., професор, Криворізький національний університет

АПАРАТНЕ ПРИСКОРЕННЯ НАВЧАННЯ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ

Особливості глибокого навчання нейронних мереж та вплив апаратної частини на швидкість формування значень вагів.

Глибоке навчання – це поле з інтенсивними обчислювальними вимогами, і вибір GPU принципово визначить ефективність навчання. При відсутності графічного прискорювача процес навчання виглядає як очікування завершення експерименту терміном до місяця, або проведення експерименту протягом дня чи більше, лише щоб виключити вибрані параметри. З потужним графічним процесором можна швидко перейти до глибоких навчальних мереж і запускати експерименти за дні замість місяців, годин замість днів, хвилин замість годин, тому головним є покупка графічного процесора.

При наявності потужного графічного процесора – це дуже важливий аспект коли при проведенні розробки глибокого вивчення, оскільки це дозволяє швидко отримати практичний досвід, щоб застосовувати глибоке навчання для вирішення нових проблем. Без швидкого зворотного зв'язку навчання займає надто багато часу, щоб вчитися на своїх помилках, і це може сповільнити процес розробки.

Розпаралелити нейронні мережі на кількох графічних процесорах дуже важко, і спостерігається прискорення посереднє для щільних нейронних мереж. Малі нейронні мережі можуть бути досить ефективно паралізовані за допомогою паралелізму даних, але більша кількість нейронних мереж майже не отримує прискорення.

Розробка нейронних мереж з нуля є неоправданим складним завданням. Якщо взяти до уваги велику кількість платформ, то API створених для розробки та навчання нейронних мереж.

З боку програмного забезпечення були розроблені потужні готові рішення компаніями Microsoft та Nvidia, такі як Azure ML, бібліотеки Cuda [1]. Головний принцип розробки платформ та бібліотек було поширення використання машинного навчання, спрощення вхідного порогу створення нових рішень. Розглядаючи ML Studio яка автоматично обробляє розгортання, підготовку пропускової здатності, балансування навантаження, автоматичне масштабування і моніторинг працездатності, радикально спрощує створення систем прогнозування. Використання серверного механізму, що надає можливість створювати та публікувати веб-сервіси завдяки простому інтерфейсу.

Важливим фактором для навчання та тестування моделей нейронних мереж – є підтримка на апаратному рівні GPU, як наприклад використання cuDNN 2.0 – GPU. Прискорена бібліотека для задач глибокого навчання від NVIDIA для масштабних проєктів, яка дозволяє задіяти потужність графічного прискорювача[2].

Апаратна частина надзвичайно важлива і правильно обрати її вибрати нелегко. Згідно з даних практичних заміряннь, вигрaш швидкості не дає поєднання багатьох дешевших відеокарт проти меншої кількості дорожчих, за умови складності реалізації програмного розпаралелення. Таке твердження справедливе для великих проєктів. Найефективнішим апаратним забезпеченням для розробки ШНМ може стати GPU 900 і 1000 серії GTX компанії Nvidia.




Рис. 1 - Відносне порівняння продуктивності між GPU при великих обчисленнях

ВИСНОВКИ

Порівняння виводяться з порівнянь специфікацій карт разом з обчислювальними критеріями (деякі випадки видобутку криптовалют – завдання, які в обчисленні порівняні з глибоким вивченням) (Рисунок 1). Отже, це приблизні оцінки. Реальні числа можуть дещо

відрізнятися, але зазвичай помилка повинна бути мінімальною і порядком карт відносно правильним.

ЛІТЕРАТУРА

1. Офіційний сайт Nvidia [Електронний ресурс] – Режим доступу до ресурсу: <https://www.nvidia.ru/object/blog-nvidia-digits-devbox-ru.html>
2. Заміри швидкості апаратного забезпечення для глибокого навчання [Електронний ресурс] – Режим доступу: <http://timdettmers.com/2017/04/09/which-gpu-for-deep-learning>

Сіряк Р.В.

Східноукраїнський національний університет ім. В. Даля

Скарга-Бандурова І.С.

д.т.н., доцент,

Східноукраїнський національний університет ім. В. Даля

СИСТЕМА РОЗПІЗНАВАННЯ ДИНАМІЧНИХ ЖЕСТІВ ЗА ДОПОМОГОЮ МЕРЕЖІ CNN-LSTM

Представлено технологічні підходи до розробки системи розпізнавання динамічних жестів рук у відеопотоці за допомогою багатосарової нейронної мережі. Розробка проводилась на мові програмування Python у фреймворках Keras та TensorFlow.

Завдяки розвитку інформаційних технологій, а також нових підходів до розробки згорткових нейронних мереж, що були реалізовані протягом останнього десятиліття, в області комп'ютерного зору були досягнуті значні успіхи. Однак, щодо динамічного розпізнавання жестів рук, це проблема й досі залишається актуальною з широким простором для досліджень. Розроблена система поєднує в собі архітектури згорткової нейронної мережі (CNN) та мережі довгої короткочасної пам'яті (LSTM) й складається з двох модулів (рис. 1). Перший модуль з CNN-шарів та послідовними maxpooling-шарами використовується для виявлення просторових ознак на кожному кадрі відеопослідовності, другий з двома шарами LSTM виявляє часові закономірності у відеопослідовності.