

ТРИВИМІРНІ НЕЙРОНІ МЕРЕЖІ У ЗАВДАННЯХ КЛАСТЕРИЗАЦІЇ

Анотація: У даній роботі досліджуються можливості та ефективність застосування тривимірних нейронних мереж у задачах кластеризації. Автори розробили архітектуру тривимірної нейронної мережі та оцінили її здатність до кластеризації за допомогою індексу Данна. Результати дослідження показують високу ефективність запропонованої моделі порівняно з традиційними методами кластеризації.

Ключові слова: Тривимірні нейронні мережі, кластеризація, індекс Данна, глибинне навчання, просторові дані.

Вступ

Кластеризація - це процес групування об'єктів або даних таким чином, що об'єкти в одному кластері є більш схожими один на одного порівняно з об'єктами в інших кластерах. Вона важлива у багатьох областях, включаючи машинне навчання, обробку даних та аналіз. Методи кластеризації можуть варіюватися від простих, таких як логічна кластеризація, до складніших, які використовують нейромережі або алгоритми на основі аналізу пошукових видач. Кластеризація допомагає виявити структуру в даних та може бути використана для зниження розмірності, сегментації ринку, виявлення аномалій та інших завдань.

Вибір тривимірних нейронних мереж для розв'язання завдань кластеризації обґрунтований їх здатністю ефективно обробляти великі обсяги даних з високою розмірністю. Тривимірні мережі можуть виявляти складні просторові залежності та патерни в даних, що робить їх особливо корисними для аналізу зображень, 3D-моделей та інших видів даних, які мають просторову структуру. Крім того, вони можуть бути ефективно навчені за допомогою сучасних алгоритмів глибинного навчання, що дозволяє досягти високої точності в задачах кластеризації.

Постановка мети та задач

Мета дослідження - Дослідити можливості та ефективність застосування тривимірних нейронних мереж у задачах кластеризації, зокрема в аналізі просторових даних та виявленні складних залежностей між об'єктами.

Завдання дослідження включають наступне:

1. Огляд та аналіз існуючих підходів до кластеризації з використанням нейронних мереж.

2. Розробка архітектури тривимірної нейронної мережі, адаптованої для розв'язання задач кластеризації.

© О. Паладієв, О. Лісовиченко

3. Навчання та тестування розробленої мережі на різних наборах даних для оцінки її здатності до кластеризації.
4. Аналіз результатів та порівняння ефективності тривимірних нейронних мереж з традиційними методами кластеризації.
5. Висвітлення перспектив застосування тривимірних нейронних мереж у різних областях, де потрібна ефективна кластеризація.

Огляд існуючих підходів та літератури

Аналіз існуючих підходів до кластеризації з використанням нейронних мереж включає вивчення різних архітектур та методик. Самоорганізовувальні карти Кохонена є одним із класичних інструментів, які ефективно впорядковують високорозмірні дані в двовимірному просторі, сприяючи інтуїтивному розумінню кластерної структури. З іншого боку, глибинні нейронні мережі, зокрема автокодувальники, здатні виявляти складні структури в даних і зменшувати розмірність, що є важливим для ефективної кластеризації. Крім того, використовуються спеціалізовані мережі, такі як згорткові нейронні мережі для обробки зображень та послідовні мережі для аналізу часових рядів, які можуть бути адаптовані для задач кластеризації. На додаток, розвиваються гібридні підходи, що поєднують кілька типів мереж або інтегрують нейронні мережі з традиційними алгоритмами кластеризації для підвищення точності та ефективності розподілу даних на кластери.

Тривимірні нейронні мережі, особливо 3D згорткові нейронні мережі (3D CNN), є важливим інструментом у різних галузях науки та техніки. У медицині вони використовуються не лише для аналізу МРТ та КТ знімків, але й для діагностики хвороб, таких як рак або деменція, шляхом виявлення аномалій у 3D структурах органів. У робототехніці 3D CNN допомагають роботам розпізнавати об'єкти в просторі, що є критично важливим для автономної навігації. У комп'ютерному зорі вони застосовуються не лише для аналізу відеопотоків, але й для розробки систем віртуальної та доповненої реальності, де важливо розуміння просторових відносин між об'єктами. В геологічних дослідженнях 3D CNN використовуються для аналізу 3D моделей надр землі, дозволяючи виявляти родовища корисних копалин або оцінювати ризики природних катастроф, таких як землетруси або зсуви.

Теоретичні основи

Розробка архітектури нейронної мережі передбачає створення кількох шарів, де кожен шар має свою унікальну функцію і може бути інтегрований у мережу декілька разів для підсилення обчислювальних здібностей. Початковий шар, званий шаром "розсіювання", відіграє ключову роль у збільшенні кількості нейронів і зміцненні їх зв'язків у наступних шарах, що підсилює здатність мережі до обробки і аналізу великих

обсягів даних. Цей шар також сприяє розподілу інформації про просторові ознаки серед сусідніх нейронів, забезпечуючи більш глибоке розуміння структури даних.

Коли інформація з окремого пікселя надходить на шар розсіювання, вона розподіляється між кількома нейронами, а також передається сусіднім нейронам у структурі шару, створюючи багатовимірне представлення даних, що збагачує аналітичні можливості мережі.

Наступним етапом є інтеграція шару повнозв'язних нейронів, де кожен нейрон пов'язаний з усіма нейронами попереднього шару. Це забезпечує мережі здатність виявляти складні залежності між різноманітними ознаками вхідних даних. Шар повнозв'язних нейронів є критичним для визначення високорівневих абстракцій та патернів у даних, що значно підвищує точність кластеризації та класифікації.

Далі йде шар конденсації, де відбувається зменшення кількості нейронів та виділення найбільш інформативних ознак з великої кількості вхідних даних. Цей процес дозволяє зменшити розмірність даних, зберігаючи при цьому критично важливу інформацію, необхідну для ефективного кластеризації. На виході шару конденсації формується матриця векторів, що представляє собою згорнуте представлення даних, готове до подальшого аналізу.

Завершальним етапом є визначення кластеризатора через пошук максимального екстремуму серед набору векторів, отриманих з шару конденсації. Це дозволяє точно визначити місцеположення кластерів у просторі ознак, забезпечуючи ефективне розділення даних на групи за схожістю. Цей підхід до кластеризації з використанням тривимірних нейронних мереж відкриває нові можливості для аналізу складних даних у різних областях досліджень та застосувань, від медичної діагностики до розпізнавання образів.

Архітектура тривимірних нейронних мереж для задач кластеризації може включати такі особливості:

1. Тривимірні згорткові шари (3D Convolutional Layers): Ці шари дозволяють ефективно обробляти тривимірні дані, зберігаючи просторову інформацію. Вони застосовуються для виявлення просторових ознак у 3D об'єктах або зображеннях.

2. Шари підвибірки (Pooling Layers): Використовуються для зменшення розмірності просторових даних, що сприяє зменшенню обчислювальної складності та запобіганню перенаванчання.

3. Повнозв'язні шари (Fully Connected Layers): Ці шари інтегрують інформацію з різних частин даних і використовуються для класифікації або кластеризації на основі виявлених ознак.

4. Функції активації: Наприклад, ReLU (Rectified Linear Unit) або Leaky ReLU використовуються для додання нелінійності у модель, що дозволяє нейронній мережі вчитися складнішим залежностям у даних.

5. Механізми регуляризації: Такі як Dropout або Batch Normalization, використовуються для запобігання перенавчанню та підвищення стабільності тренування мережі.

6. Функції втрат: Для задач кластеризації можуть використовуватися спеціалізовані функції втрат, такі як функція втрат кластеризації або функція втрат на основі відстані між кластерами.

Ці особливості архітектури сприяють ефективній кластеризації об'єктів у тривимірному просторі, дозволяючи моделі виявляти складні просторові залежності та групувати дані за схожими ознаками.

Методологія

Навчання без учителя є ключовим підходом до кластеризації тривимірних нейронних мереж, де мережа самостійно виявляє структуру даних без попередньо визначених міток кластерів. Основною метою такого навчання є здатність мережі групувати дані на основі схожості ознак без зовнішнього керівництва.

Одним із популярних методів навчання без учителя є використання автокодувальників. Автокодувальники складаються з двох частин: енодера, який зменшує розмірність вхідних даних, та декодера, який відновлює дані зі зменшеної репрезентації. Під час навчання автокодувальник намагається мінімізувати втрати між вхідними даними та їх відновленням, що сприяє виділенню ключових ознак та структур у даних.

Іншим методом є використання алгоритмів на основі щільності, таких як DBSCAN або OPTICS. Ці алгоритми групують точки даних на основі їхньої щільності, дозволяючи виявляти кластери різної форми та розміру, а також визначати викиди.

Оптимізація гіперпараметрів є важливою частиною процесу навчання, оскільки вона впливає на здатність мережі ефективно групувати дані. Це може включати налаштування швидкості навчання, кількості епох, розміру пакету, а також вибір алгоритму оптимізації.

Розробка архітектури мережі також відіграє ключову роль у навчанні без учителя. Вибір кількості та типу шарів, розміру фільтрів у згорткових шарах та інших архітектурних параметрів може значно вплинути на якість кластеризації.

Загалом, навчання без учителя для тривимірних нейронних мереж є потужним інструментом для кластеризації, яке дозволяє мережі самостійно виявляти структуру даних та групувати схожі об'єкти.

Використання індексу Данна для оцінювання роботи кластеризатора

Індекс Данна є однією з метрик для оцінки якості кластеризації. Він визначається як відношення мінімальної відстані між кластерами до максимального діаметра кластера:

$$D = \frac{\min_{1 \leq i < j \leq n} d(c_i, c_j)}{\max_{1 \leq k \leq n} d'(c_k)},$$

де $d(c_i, c_j)$ - відстань між кластерами c_i та c_j , а $d'(c_k)$ - діаметр кластера c_k .

Вищі значення індексу Данна вказують на кращу кластеризацію, де кластери добре відокремлені та щільні.

Результати

Показники індексу Данна для досліджуваної моделі виявилися в діапазоні від 0.7 до 0.8, що є досить високими значеннями. Це свідчить про те, що кластери, сформовані мережею, добре відокремлені один від одного та мають відносно малі діаметри. Таким чином, можна зробити висновок, що дана модель ефективно розділяє дані на схожі групи, що є важливим для багатьох застосувань кластеризації.

Ці результати підкреслюють високу якість кластеризації, досягнуту за допомогою тривимірної нейронної мережі, і демонструють її потенціал для вирішення складних задач кластеризації в різних областях, таких як обробка зображень, аналіз даних та багато інших.

Висновок

На основі аналізу результатів дослідження можна зробити висновок, що тривимірні нейронні мережі є ефективним інструментом для кластеризації даних. Показники індексу Данна для розглянутої моделі, які виявилися в діапазоні від 0.7 до 0.8, свідчать про високу якість кластеризації, де кластери добре відокремлені один від одного та мають відносно малі діаметри. Це підкреслює здатність моделі ефективно розділяти дані на схожі групи, що є важливим для багатьох застосувань кластеризації, включаючи обробку зображень, аналіз даних та інші області. Високі показники індексу Данна також демонструють потенціал тривимірної нейронної мережі для вирішення складних задач кластеризації, що відкриває перспективи для подальшого використання цього підходу в різноманітних дослідницьких та практичних застосуваннях. В цілому, результати дослідження підтверджують ефективність тривимірних нейронних мереж у задачах кластеризації та їхній великий потенціал для подальших досліджень та розробок у цій галузі.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Paladiiev, O., & Lisovychenko, O. (2022). The influence of the opponent's color model on the general capabilities of neural networks. *Interdepartmental Scientific-Technical Journal «Adaptive Systems of Automatic Control»*, 2(41), 22-27.
2. Paladiiev, O., & Lisovychenko, O. (2023). Influence of Reducing the Size of a Neural Network on Its Generalization Ability. *Interdepartmental Scientific-Technical Journal «Adaptive Systems of Automatic Control»*, 2(43), 124-130.

3. *Xu, R., & Wunsch, D.* (2005). Survey of clustering algorithms. *IEEE Transactions on Neural Networks*, 16(3), 645-678.
4. *LeCun, Y., Bengio, Y., & Hinton, G.* (2015). Deep learning. *Nature*, 521(7553), 436-444.
5. *Goodfellow, I., Bengio, Y., & Courville, A.* (2016). *Deep Learning*. MIT Press.
6. *Hinton, G. E., Osindero, S., & Teh, Y. W.* (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
7. *Dunn, J. C.* (1974). Well-separated clusters and optimal fuzzy partitions. *Journal of Cybernetics*, 4(1), 95-104.
8. *Jain, A. K., Murty, M. N., & Flynn, P. J.* (1999). Data clustering: a review. *ACM computing surveys (CSUR)*, 31(3), 264-323.
9. *Krizhevsky, A., Sutskever, I., & Hinton, G. E.* (2012). ImageNet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105.