

<https://doi.org/10.31891/2307-5740-2024-328-23>

УДК 005.95/.96

БОЙКО Богдан

Національний університет "Львівська політехніка"

<https://orcid.org/0009-0002-9850-2764>e-mail: bohdan.m.boiko@lpnu.ua

ПРОЦІК Ірина

Національний університет "Львівська політехніка"

<https://orcid.org/0000-0002-6370-1344>e-mail: iryana.s.procyk@ukr.net

ВИКОРИСТАННЯ АЛГОРИТМІВ КЛАСТЕРИЗАЦІЇ ДЛЯ СЕГМЕНТАЦІЇ ПЕРСОНАЛУ КОМПАНІЇ

У цьому дослідженні детально розглянуто важливість та потенціал застосування алгоритмів кластеризації в контексті управління людськими ресурсами. Відзначено, що сегментація персоналу є стратегічною складовою для компаній будь-якого розміру та галузі діяльності, оскільки вона дозволяє ефективніше адаптувати стратегії управління до потреб і характеристик різних груп працівників. Підкреслено, що алгоритми кластеризації можуть автоматизувати процес сегментації, забезпечуючи об'єктивні та консистентні результати. Детально описано різні типи алгоритмів кластеризації, включаючи їх принципи роботи та особливості застосування в контексті управління персоналом. Зокрема, висвітлено, як кластеризація може базуватися на різних критеріях, таких як навички, професійний досвід, мотивація та інші, і як ці кластери можуть бути використані для вдосконалення процесів найму, планування кар'єрного росту, оцінки продуктивності та розвитку персоналу. Також надано приклади успішних випадків впровадження алгоритмів кластеризації в практиці управління людськими ресурсами, що демонструють їхній позитивний вплив на ефективність та стратегічний розвиток компанії. Нарешті, наголошено на необхідності подальших досліджень у цій області з метою вдосконалення методологій сегментації персоналу та розширення їхнього застосування в різних сферах бізнесу. У цьому дослідженні було проведено кластерний аналіз датасету з маркетинговими даними, використовуючи три різні методи кластеризації: *k*-середніх, DBSCAN та агломеративну кластеризацію. Результати оцінки показали, що DBSCAN продемонстрував найкращі результати як з повним, так і зі зменшеним датасетом, що свідчить про його ефективність у виявленні густозаповнених кластерів з нерегулярним розподілом точок. Натомість метод *k*-середніх виявився менш ефективним для даних з нерегулярним розподілом та викидами. Агломеративна кластеризація показала помірні результати, проте виявилася вразливою до викидів та вимагає значних обчислювальних ресурсів. Загалом, проведене дослідження дозволяє зробити висновок про ефективність різних методів кластеризації у виявленні структури даних у маркетингових дослідженнях.

Ключові слова: кластеризація, сегмент, міжквартильний діапазон, мітки, метод головних компонент

BOIKO Bohdan, PROTCYK Iryna

Lviv Polytechnic National University

USING CLUSTERING ALGORITHMS FOR COMPANY PERSONNEL SEGMENTATION

This research thoroughly examines the importance and potential of applying clustering algorithms in the context of human resource management. It is noted that personnel segmentation is a strategic component for companies of any size and industry, as it allows for more effective adaptation of management strategies to the needs and characteristics of different groups of employees. It is emphasized that clustering algorithms can automate the segmentation process, providing objective and consistent results. Various types of clustering algorithms are described in detail, including their principles of operation and application peculiarities in the context of personnel management. In particular, it is highlighted how clustering can be based on different criteria such as skills, professional experience, motivation, and others, and how these clusters can be used to improve hiring processes, career planning, performance evaluation, and personnel development. Successful case examples of implementing clustering algorithms in human resource management practices are also provided, demonstrating their positive impact on company efficiency and strategic development. Finally, the need for further research in this area is emphasized to refine personnel segmentation methodologies and expand their application in various business sectors. This research conducted a cluster analysis of a dataset with marketing data using three different clustering methods: *k*-means, DBSCAN, and agglomerative clustering. The results of the evaluation showed that DBSCAN demonstrated the best performance both with the full and reduced dataset, indicating its effectiveness in identifying densely populated clusters with irregular distributions of points. In contrast, the *k*-means method proved to be less effective for data with irregular distributions and outliers. Agglomerative clustering yielded moderate results but was found to be vulnerable to outliers and demanding in terms of computational resources. Overall, the study allows us to conclude on the effectiveness of different clustering methods in identifying data structures in marketing research.

Keywords: clustering, segment, interquartile range, labels, principal component analysis (PCA).

ПОСТАНОВКА ПРОБЛЕМИ У ЗАГАЛЬНОМУ ВИГЛЯДІ ТА ЇЇ ЗВ'ЯЗОК ІЗ ВАЖЛИВИМИ НАУКОВИМИ ЧИ ПРАКТИЧНИМИ ЗАВДАННЯМИ

Зараз все більше людей працюють з великим обсягом даних, особливо в контексті управління персоналом компаній. При цьому важливо враховувати, що різні групи працівників можуть мати відмінні потреби, навички та характеристики. Саме тому використання технологій машинного навчання і штучного інтелекту, зокрема алгоритмів кластеризації, стає надзвичайно важливим для ефективної сегментації персоналу [2, 5].

Кластеризація дозволяє автоматично групувати працівників за різними критеріями, такими як навички, досвід роботи, професійні цілі, рівень продуктивності тощо. Це дозволяє краще розуміти потреби та інтереси різних груп працівників і відповідно адаптувати стратегії управління та персоналізовані підходи до кожної групи [1, 3].

Такий підхід до сегментації персоналу дозволяє компаніям оптимізувати найм, зберігання талантів, розвиток кар'єрних траєкторій, а також підвищити загальну ефективність та задоволеність працівників. Таким чином, використання алгоритмів кластеризації в контексті сегментації персоналу є надзвичайно перспективним і корисним напрямком для сучасних організацій.

Покупців, крім цього моє дослідження буде доцільне для застосування у інших сферах життя та науки, перерахованих вище.

АНАЛІЗ ДОСЛІДЖЕНЬ ТА ПУБЛІКАЦІЙ

Останні дослідження та публікації підтверджують актуальність проблем, пов'язаних із сегментацією працівників у сучасному світі праці. Деякі з ключових аспектів, які відображають цю актуальність, включають: персоналізований підхід до управління персоналом; управління робочою силою у змінному середовищі; розвиток технологій та аналітики даних; зростання значення роботи з великими даними (Big Data).

Дослідники акцентують увагу на необхідності вирішення комплексних завдань, зокрема розробки інтегрованих підходів до сегментації працівників. Вони вбачають важливість розробки методів, які не лише враховують основні характеристики працівників, такі як вік, стать, освіта, досвід роботи тощо, але і враховують складні взаємозв'язки між цими характеристиками. Також, авторам як Шуйлеру [10], Джексону [4], Касіо [2], Бодро [1], які підкреслюють важливість розробки адаптивних методів сегментації, які можуть адаптуватися до змін в умовах ринку праці та внутрішньої організаційної динаміки. Це включає в себе використання алгоритмів машинного навчання та штучного інтелекту для автоматизації процесу сегментації та аналізу даних про працівників.

Узагальнюючи, дослідники підкреслюють потребу у комплексному підході до розробки методів сегментації працівників, що враховує не лише їхні основні характеристики, але й адаптується до змін у ринкових умовах та забезпечує конфіденційність та захист персональних даних.

ФОРМУЛЮВАННЯ ЦІЛЕЙ СТАТТІ

Метою дослідження є дослідити та визначити ефективні методи застосування алгоритмів кластеризації для сегментації персоналу компаній. Дослідження спрямоване на вивчення можливостей використання цих алгоритмів для автоматизованого групування працівників за різними критеріями, такими як навички, досвід роботи, рівень продуктивності тощо, та на подальше визначення оптимальних підходів до управління персоналом на основі отриманих результатів.

ВИКЛАД ОСНОВНОГО МАТЕРІАЛУ

Один із аспектів, на який звертається увага, - це персоналізований підхід до управління персоналом. Сучасні організації усвідомлюють, що кожен працівник унікальний, і для досягнення оптимальних результатів необхідно враховувати індивідуальні особливості кожного з них. Сегментація дозволяє розподілити працівників на групи зі спільними характеристиками, що дозволяє керівництву легше адаптувати стратегії управління та мотивації для кожної групи [6].

Крім того, сегментація працівників допомагає підвищити ефективність рекрутингу та збереження персоналу. Розуміння потреб та очікувань різних груп працівників дозволяє залучити та утримати найбільш кваліфікованих та мотивованих спеціалістів.

Останні дослідження також вказують на важливість адаптивності методів сегментації до змін у ринкових умовах та внутрішній динаміці організацій. Методи сегментації повинні бути гнучкими та адаптованими до нових викликів та можливостей, які можуть виникнути у майбутньому [6].

Математичний опис алгоритму, де K - кількість кластерів, на які треба розділити дані. $X = \{x_1, x_2, \dots, x_n\}$ - множина n -вимірних точок даних, які треба кластеризувати, у нашому випадку - це працівники.

Наступним кроком слід вибрати K початкових центроїдів $(\mu_1, \mu_2, \dots, \mu_k)$ випадковим чином або на підставі деякої евристики. Призначити кожному точку даних x_i до найближчого центроїда μ_j , використовуючи міру відстані, таку як Евклідова відстань: $d(x_i, \mu_j) = \|x_i - \mu_j\|$. Оновити центроїди, обчисливши середнє значення точок у кожному кластері: $\mu_j = (1/|C_j|) * \sum x_i$, де C_j - кластер, до якого належать точки [7].

Перевіримо умову збіжності. Якщо вона виконується (наприклад, зміна центроїдів мала), то слід зупинити ітерації та відповідно дати вивід результату: кластери C_1, C_2, \dots, C_k , які містять точки, призначені до відповідних центроїдів $\mu_1, \mu_2, \dots, \mu_k$.

Наведемо основні кроки виконання цього методу з використанням обраного набору даних. Один з найважливіших кроків це вибір оптимальної кількості кластерів, оскільки від цього залежить якість кластерного аналізу. Для побудови моделі визначено оптимальну кількість кластерів за допомогою метода силуетів (silhouette method). Ще одним поширеним методом для оцінки якості кластеризації та вибору

кількості кластерів є метод "ліктя". Метод силуетів полягає в тому, що ми застосовуємо алгоритм кластеризації (в цьому випадку k -means) до набору даних для різної кількості кластерів, було обрано діапазон з 2 до 15 кластерів [4].

Обчислимо середній силуетний коефіцієнт для всіх об'єктів вибірки. Силуетний коефіцієнт вимірює, наскільки кожен об'єкт підходить до свого власного кластера порівняно з іншими кластерами. Він може приймати значення від -1 до 1, більші значення вказують на кращу кластеризацію. Відповідно слід вибрати значення k , яке максимізує середній силуетний коефіцієнт. Це і буде оптимальна кількість кластерів для задачі кластеризації. Цей метод дозволяє оцінити якість кластеризації і вибрати оптимальну кількість кластерів, забезпечуючи більш надійні результати. Після виконання цього кроку, оптимальна кількість кластерів була визначена - 13.

Визначаємо початкові центроїди кластерів випадковим чином. Ще одним кроком виконання методу k -середніх після визначення k кластерів є те, що кожен об'єкт вибірки призначається до найближчого центроїда на основі відстані між ними. Проте оскільки набір даних містить багато характеристик, які враховуються для кластерного аналізу, якість кластеризації може бути погана. Тому обираємо значущі ознаки і виконуємо ті самі кроки для порівняння моделей з різною кількістю ознак.

Формула для обчислення коефіцієнта силуету для одного об'єкта має вигляд (Формула 1) [5]:

$$S_i = \frac{b_i - a_i}{\max(a_i, b_i)}, \quad (1)$$

де - s_i - коефіцієнт силуету для об'єкта i ;

a_i - середня відстань між об'єктом i та всіма іншими об'єктами у тому ж кластері;

b_i - середня відстань між об'єктом i та об'єктами з найближчого сусіднього кластера (до якого не належить об'єкт i).

Також для порівняння результатів дослідницької роботи було обрано метод Density-Based Spatial Clustering of Applications with Noise (DBSCAN) [8].

Параметрами алгоритму DBSCAN є: ϵ (epsilon) - радіус околу навколо кожної точки, в якому шукаються сусіди та m (min_samples) - мінімальна кількість сусідів, яку має мати точка, щоб бути визнаною як "ядром" кластера. Далі слід позначити всі точки як "не відвідані".

Отже, для кожної точки P у наборі даних, якщо вона вже була відвідана, перейти до наступної точки.- Позначити точку P як відвідану. Далі знайти всі точки, які знаходяться в межах радіусу ϵ навколо точки P . Ця група точок називається сусідньою групою. Відповідно, якщо кількість точок у сусідній групі менше ніж m , позначити точку P як "шумову", що не належить жодному кластеру. В іншому випадку, створити новий кластер C і додати точку P до цього кластера та додати всі точки з сусідньої групи, які мають не менше ніж m сусідів, до кластера C [9].

Для кожної точки Q з сусідньої групи, яка ще не відвідана слід позначити точку Q як відвідану. Знайти всі точки, які знаходяться в межах радіусу ϵ навколо точки Q . Якщо кількість точок у цій сусідній групі не менше ніж m , додати їх до кластера C [10].

Відстань між двома точками розраховуємо за формулою Евклідової відстані (Формула 2):

$$\rho(P, Q) = \sqrt{\sum_i^n (P - Q)^2}, \quad (2)$$

Наведемо кроки реалізації алгоритму:

1. Якщо у методі k -середніх важливим кроком був вибір оптимальної кількості кластерів, то у DBSCAN слід вибрати оптимальні початкові параметри, такі як радіус околу ϵ , який було обчислено також за допомогою методу силуетів. Визначено значення ϵ , які потрібно перевірити, потім відповідно створення моделі DBSCAN з поточним ϵ , створення кластерів за допомогою `fit_predict()` та обчислення силуетного коефіцієнту для кожного ϵ . Для обраного датасету оптимальне ϵ було рівне 1.0, що і буде значенням для радіусу околу. Також ще одним параметром є вибір мінімальної кількості елементів m , які повинні знаходитись в окрузі, щоб точка вважалась ядром кластера. А ядро кластера в свою чергу означає групу покупців, які мають достатню щільність в околі ϵ . Якщо точки не мають принаймні m сусідів в окрузі, вони є шумовими, а це означає що ці покупці, які не належать до жодного кластера.

2. Для моделі DBSCAN як і для k -means будуть створені моделі для двох наборів даних (повного та з меншою кількістю характеристик), також буде проаналізовано результати виконання при різних ϵ та m , щоб визначити оптимальні значення цих параметрів.

3. Відповідно для оцінки якості кластеризації також буде використовуватись метод силуетів, який описаний у методі k -means:

Формула 3 наводить обчислення коефіцієнта силуету для одного об'єкта [8]:

$$S_p = \frac{b_p - a_p}{\max(a_p, b_p)}, \quad (3)$$

де s_p - коефіцієнт силуету для об'єкта P ;
 a_p - середня відстань між об'єктом P та всіма іншими об'єктами у тому ж кластері;
 b_p - середня відстань між об'єктом P та об'єктами з найближчого сусіднього кластера (до якого не належить об'єкт P).

Наведемо формулу 4 для обчислення силуетного коефіцієнта для кластера:

$$S = \frac{1}{n} \sum S_p, \quad (4)$$

де P точки в кластері;

n - кількість точок у кластері.

Для відображення усіх характеристик, буде застосовано PCA, перевагою цього методу є те, що можна візуалізувати складні дані, зменшивши розмірність даних до двох або трьох головних компонентів і знайти важливі закономірності або кластери. На Рис. 1-2 представлена візуалізація характеристик працівників.




Рис. 1. Візуалізація характеристик покупців за допомогою 2 головних компонент




Рис. 2. Візуалізація характеристик покупців за допомогою 3 головних компонент

Першим кроком методу k-means є визначення оптимальної кількості кластерів, визначимо це за допомогою методу силуетів.

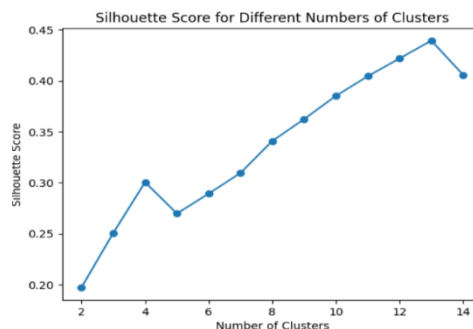


Рис. 4. Графік якості кластеризації відповідно до різної кількості кластерів

На основі Рис. 4 видно, що силуетний коефіцієнт досягає свого найвищого значення при 13 кластерах. Це вказує на те, що при такій кількості кластерів даний алгоритм досягає найкращої оптимальності. Таким чином, можна вважати, що 13 кластерів є оптимальною кількістю кластерів для цього набору даних. Оцінка якості кластерного аналізу - 0.38689147929847423. Тепер виконаємо візуалізацію за допомогою методу PCA (Рис. 5).

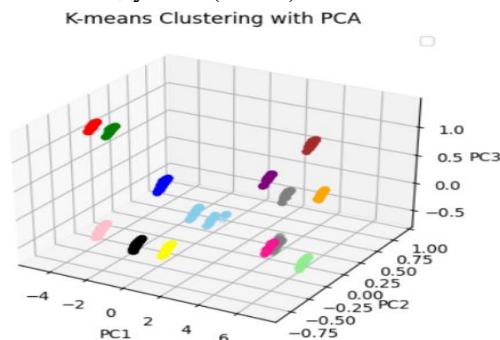


Рис. 5. Візуалізація кластерного аналізу оптимізованого датасету методом k-середніх за допомогою 3 PCA




Рис. 6. Графік якості кластеризації відповідно до різної кількості кластерів

Після аналізу середніх значень виявлено, що через велику кількість характеристик, яка призводить до складної структури даних, та кластерів, якість кластеризації в даному випадку становить близько 0.39. Це вказує на те, що порівняння цих кластерів є складним і не дасть чіткого розуміння по характеристиках працівників. Тому зменшимо кількість характеристик в датасеті, щоб покращити якість кластеризації. Після цього знову знайдемо оптимальну кількість кластерів за допомогою методу силуетів (Рис. 6). Оцінка якості кластерного аналізу - 0.5120383159898028.

Тепер можна зробити висновок, що працівники, які входять до кластеру 1, мають високий дохід, та вищий соціальний статус, ніж у працівників кластера 2. Це доволі логічно, оскільки дохід працівників 2-го кластера удвічі менший. Компанія може запропонувати різні акції, враховуючи поведінку працівників з різними доходами та їхні вподобання щодо витрат. Також хорошим рішенням буде розробка програм лояльності, де працівники отримують бонусні бали або накопичують знижки на основі своїх витрат.

Кластерний аналіз за допомогою методу DBSCAN починається з визначення оптимальних значень для параметрів (радіус околу eps та мінімальної кількості сусідів m). Оптимальний радіус околу було визначено за допомогою силуетів, перевіряючи різні значення eps після виконання кластеризації, параметр $m = 20$. Оцінка якості кластерного аналізу - 0.5459986675777213. Також для візуалізації кластерів буде використано метод PCA (Рис. 7)

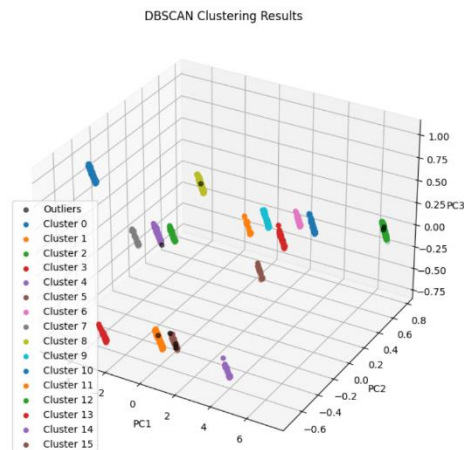


Рис. 7. Візуалізація кластерного аналізу датасету методом DBSCAN за допомогою 3 PCA

У цьому методі не потрібно вказувати кількість кластерів, алгоритм сам групує дані на кластери. При таких оптимальних вхідних параметрах, кількість кластерів - 16.

Як і у методі k -середніх, обчислюємо оптимальну кількість кластерів за допомогою $silhouette_score$ в діапазоні з 2 до 16 кластерів (Рис. 8).

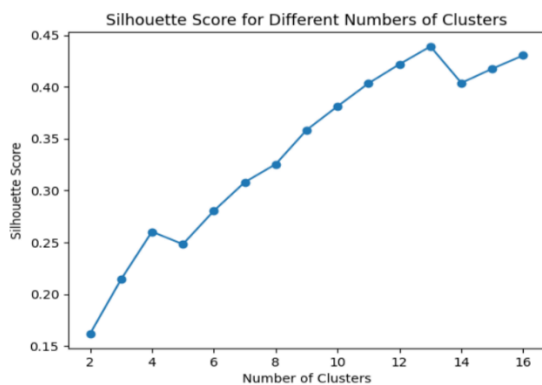


Рис.8. Графік якості кластеризації відповідно до різної кількості кластерів

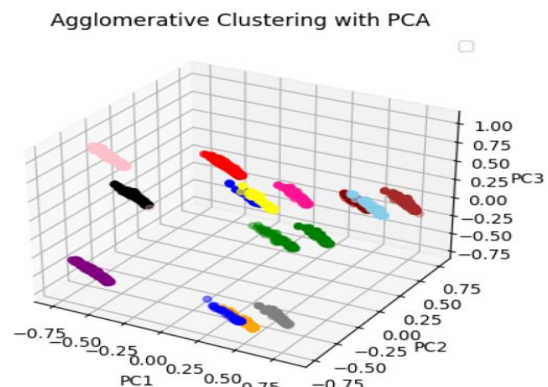


Рис. 9. Візуалізація кластерного аналізу датасету методом Agglomerative Clustering за допомогою 3 PCA

На Рис. 8 можна побачити, що оптимальна кількість кластерів - 13. Оцінка якості кластерного аналізу - 0.4389670667535322. Для візуалізації кластерів використовуємо метод PCA, наведеного на Рис. 9.

Проте для порівняння та можливості покращити якість кластеризації, виконаємо кластерний аналіз на зменшеному датасеті. Відповідно знову знайдемо оптимальну кількість кластерів за допомогою методу силуетів (Рис. 10).




Рис. 10. Графік якості кластеризації оновленого датасету відповідно до різної кількості кластерів




Рис. 11. Візуалізація кластерного аналізу оновленого датасету методом Agglomerative Clustering за допомогою 3 PCA

Оптимальна кількість кластерів для даного оновленого датасету становить 2. Відповідно оцінка якості кластерного аналізу є досить висока - 0.6853116319704362. Візуалізуємо кластери методом PCA (Рис.11).

Для аналізу нижче будуть наведені оцінки якості кластеризації кожного методу для датасету та його зменшеної версії (Таблиця 1).

Таблиця 1.

Оцінки якості кластеризації повного набору даних різними методами

Метод кластеризації	Якість кластеризації для повного набору даних
K- Means	0.38689147929847423
DBSCAN	0.5459986675777213
Agglomerative Clustering	0.4389670667535322

У таблиці 1 наведені оцінки кластеризації кожного методу, тому можна зробити такий аналіз результатів. При проведенні кластерного аналізу на повному наборі даних, були отримані оцінки якості для різних методів. Виявилось, що найкращим методом був DBSCAN з оцінкою якості приблизно 0.55, що є нормальним показником, хоча це не є ідеальним результатом, він все ще вважається прийнятним. У результаті було утворено 16 кластерів. Натомість, найгірший результат був зафіксований при використанні методу *k*-середніх з оцінкою якості приблизно 0.39, де продавці були розділені на 13 груп. Однією з причин чому кластерний аналіз з використанням методу *k*-середніх був неефективним для даного набору даних, є те, що цей метод розділяє усі об'єкти на кластери, враховуючи навіть аномалії. Оцінка методу агломеративної кластеризації була проміжним показником між попередніми методами, становлячи ~ 0.44. Проте, цей метод також не є достатньо ефективним для сегментації продавців набору даних, оскільки він має певні недоліки, такі як вразливість до аномалій та вимоги до великих обчислювальних ресурсів.

ВИСНОВКИ З ДАНОГО ДОСЛІДЖЕННЯ

І ПЕРСПЕКТИВИ ПОДАЛЬШИХ РОЗВІДОК У ДАНОМУ НАПРЯМКУ

У даній дослідницькій роботі було проведено кластерний аналіз датасету з маркетинговими даними, використовуючи методи *k*-середніх, DBSCAN та агломеративну кластеризацію. Після оцінки результатів, можна зробити наступні висновки:

1. DBSCAN показав найкращі результати як з повним, так і зі зменшеним датасетом, що свідчить про його ефективність у виявленні густозаповнених кластерів з нерегулярним розподілом точок.
2. *K*-середніх виявився менш ефективним для даних з нерегулярним розподілом та викидами, що може бути пов'язано з його призначенням для даних з однорідними кластерами.
3. Агломеративна кластеризація показала помірні результати, але виявилася вразливою до викидів та вимагає значних обчислювальних ресурсів.

Всі методи мали оцінку якості кластеризації, що перевищує 0.51, що є прийнятним результатом. На основі створених кластерів можливо провести аналіз витрат та доходу працівників, щоб розробити маркетингові стратегії та акції для кожного сегменту працівників.

У майбутніх дослідженнях можна розглядати наступні аспекти:

1. Оптимізація гіперпараметрів: Подальше дослідження може включати оптимізацію гіперпараметрів для кращої ефективності методів кластеризації.
 2. Вдосконалення даних: Важливо вдосконалити якість та структуру даних для отримання кращих результатів кластеризації.
 3. Використання альтернативних мір схожості і оцінки якості: Дослідження може включати використання інших мір схожості та оцінок якості для порівняння методів кластеризації.
 4. Дослідження впливу кластеризації на маркетингові стратегії: Подальше дослідження може досліджувати, як створені кластери впливають на результативність маркетингових стратегій та акцій.
 5. Розширення області застосування: Методи кластеризації можуть бути використані не лише у маркетингу, але й у інших галузях, таких як медицина, фінанси та соціальні науки.
- Ці напрями досліджень можуть допомогти вдосконалити методи кластеризації та їх вплив на маркетингові стратегії та аналітику.

Література

1. Cascio, W. F., & Boudreau, J. W. The search for global competence: From international HR to talent management. *Journal of World Business*. 2016. 51(1). S. 103-114.
2. Delery, J. E., & Roumpi, D. Strategic human resource management, human capital and competitive advantage: is the field going in circles?. *Human Resource Management Journal*. 2017. 27(1). S. 1-21.
3. Paauwe, J., & Farndale, E. *Strategy, HRM, and performance: A contextual approach*. Oxford University Press. 2017.
4. Schuler, R. S., & Jackson, S. E. *Strategic human resource management: A global perspective*. Cengage Learning. 2019.
5. Ulrich, D., Brockbank, W., Johnson, D., & Younger, J. *HR competencies: Mastery at the intersection of people and business*. SHRM Press. 2017.
6. Wright, P. M., Dunford, B. B., & Snell, S. A. Human resources and the resource-based view of the firm. *Journal of Management*. 2016. 27(6). S. 701-721.
7. Armstrong, M. (2017). *Armstrong's handbook of human resource management practice*. Kogan Page Publishers.
8. Boxall, P., & Purcell, J. *Strategy and human resource management*. Palgrave Macmillan. 2016.
9. Guest, D. E. Human resource management and performance: Still searching for some answers. *Human Resource Management Journal*. 2017. 27(1). S. 3-13.
10. Jackson, S. E., & Schuler, R. S. *Managing human resources*. Cengage Learning. 2019.

References

1. Cascio, W. F., & Boudreau, J. W. The search for global competence: From international HR to talent management. *Journal of World Business*. 2016. 51(1). S. 103-114.
2. Delery, J. E., & Roumpi, D. Strategic human resource management, human capital and competitive advantage: is the field going in circles?. *Human Resource Management Journal*. 2017. 27(1). S. 1-21.
3. Paauwe, J., & Farndale, E. *Strategy, HRM, and performance: A contextual approach*. Oxford University Press. 2017.
4. Schuler, R. S., & Jackson, S. E. *Strategic human resource management: A global perspective*. Cengage Learning. 2019.
5. Ulrich, D., Brockbank, W., Johnson, D., & Younger, J. *HR competencies: Mastery at the intersection of people and business*. SHRM Press. 2017.
6. Wright, P. M., Dunford, B. B., & Snell, S. A. Human resources and the resource-based view of the firm. *Journal of Management*. 2016. 27(6). S. 701-721.
7. Armstrong, M. (2017). *Armstrong's handbook of human resource management practice*. Kogan Page Publishers.
8. Boxall, P., & Purcell, J. *Strategy and human resource management*. Palgrave Macmillan. 2016.
9. Guest, D. E. Human resource management and performance: Still searching for some answers. *Human Resource Management Journal*. 2017. 27(1). S. 3-13.
10. Jackson, S. E., & Schuler, R. S. *Managing human resources*. Cengage Learning. 2019.