

region methods, ” Proc. Int. Joint Conf. Neural Networks 2003, vol. 1. – pp. 260-265.

4. Castiglione F. Forecasting price increments using an artificial Neural Network // Adv. Complex Systems, vol. 1, 2002. – pp. 1-12.

5. Weigend and N. Gerschenfeld, Eds., Time Series Prediction: Forecasting the Future and Understanding the Past. Reading, MA: Addison-Wesley, 1994. – 184 p.

6. Гаскаров Д.В., Голинкевич Т.А., Мозгалеvский А.В. Прогнозирование технического состояния и надежности радиоэлектронной аппаратуры. – М.: Сов. Радио, 1974. – 224 с.

7. Медзатий Д.М. Прогнозування технічного стану мікропроцесорних пристроїв та систем // Вісник національного технічного університету «Львівська політехніка». – 2005. № 555. – С. 158-165.

8. Локазюк В.М., Поморова О.В., Медзатий Д.М. Метод прогнозування технічного стану комп'ютерних систем // Вісник Хмельницького національного університету – 2005. – № 4. – Ч.1. – Т.1. – С.81-85.

9. Victor Lokazyuk, Dmitro Medzatiy. Neural Network Approach to Forecast Working Capacity of Microprocessor and Digital Devices. – Збірник праць за результатами роботи МНПК "ACSN-2007", 1, № 1, 2007. – С.94-99.

10. Медзатий Д. М. Мікропроцесорні пристрої та системи як об'єкти прогнозування // Оптико-електронні інформаційно-енергетичні технології. – № 2 (10). – 2005. – С.119-123.

Надійшла 28.9.2009 р.

УДК 004

В.М ДЖУЛІЙ, К.В. ІВАНОВ  
Хмельницький національний університет

## МЕТОД КЛАСТЕРИЗАЦІЇ СТИСНЕННЯ ВЕКТОРА ХАРАКТЕРНИХ ОЗНАК

*У даній статті представлений метод кластеризації стиснення вектора характерних ознак. Базуючись на запропонованій методиці, розроблено алгоритм рандомізованої кластеризації з метою безпечного хешування, пропонується нова функція затрат для стиснення вектора характерних ознак при застосуванні перцептивного хешування.*

*In this article the presented method clusterisation compression vector of characteristic signs. Based on the offered method the algorithm of random clusterisation developed with the purpose of safe hashing, the new function of expenses is offered for the compression vector characteristic signs at application of perception hashing.*

Ключові слова: алгоритм рандомізованої кластеризації.

**Вступ.** Проблему отримання хеш зображення розділено на два кроки [1]. Завдання першого кроку полягає в отриманні вектора характерних ознак зображення, тоді як на другому кроці необхідно стиснути цей вектор до остаточної хеш величини.

На першому кроці отримання характерних ознак, двомірне зображення відображається як одномірний вектор характерних ознак. Даний вектор повинен вловити перцептивні якості зображення. Тобто, два зображення, що є однаковими для людської зорової системи, повинні мати близькі на певній метричній відстані вектори характерних ознак. Два зображення, що є точно різними у своєму вигляді, повинні мати вектори характерних ознак, які відрізняються великою відстанню. На другому кроці необхідно стиснути перехідний хеш вектор до остаточної хеш величини. Це включатиме кластеризацію між перехідним хеш вектором введеного джерела (зображення) та перехідним хеш вектором перцептивно ідентичних версій. Вектор характерних ознак зображення формується сумуванням величин хвильових коефіцієнтів в обраних точках характерних ознак [1, 2].

**Визначення проблеми.** Представимо нотацію, що використовуватиметься у даній статті. Нехай  $V$  позначає метричний простір векторів перехідного хешу, отриманих на стадії хеш алгоритму [1, 2]. Нехай  $L \in V$  позначає кінцевий ряд векторів  $\{l_i\}_{i=1}^n$ , до яких застосовується метод кластеризації/стиснення. Нехай  $D: V \times V \rightarrow R_+$  буде метричною відстанню, визначеною на області перетину. І нарешті, нехай  $C: L \rightarrow \{1, 2, \dots, k\}$  визначає область кластеризації. Необхідно знайти всі зображення, що візуально не можливо відрізнити, із однаковою хеш величиною та із високою вірогідністю. В даному разі хеш функція зображення подібна до квантування вектора ( $VQ$ ) або до схеми кластеризації. Необхідно згрупувати зображення, вектори перехідного хешу яких метрично близькі, і з високою вірогідністю:

$$\text{if } D(l_i, l_j) < \varepsilon \text{ then } C(l_i) = C(l_j), \quad (1)$$

$$\text{if } D(l_i, l_j) > \delta \text{ then } C(l_i) \neq C(l_j), \quad (2)$$

де  $0 < \varepsilon < \delta$ . Нехай  $l_i, l_j$  позначають довільні вектори на  $l$  (відповідно розподілу перехідного хешу) і

нехай  $C(l_i)$  та  $C(l_j)$  позначають групи, до яких ці вектори відносяться після застосування методу кластеризації.

**Підходи стиснення, ґрунтовані на звичайному VQ.** Мета кроку стиснення полягає в тому, щоб досягти кластеризації векторів перехідного хешу зображення  $I$  та векторів перехідного хешу зображення, що є однаковими за своїм виглядом до  $I$  із високою вірогідністю. Можливо стиснути вектори перехідного хешу, допускаючи певне викривлення. Проблема квантування вектора або схеми стиснення, що мінімізує середнє викривлення, полягає в отриманні  $K$  розбиття простору  $V$ , створюючи вектори кодів  $\{C_k\}_{k=0}^{k-1}$  у  $V$  так як

$$\sum_{k=0}^{k-1} \sum_{l \in S_k} P(l) D(l, C_k) < \varepsilon, \quad (3)$$

де  $P(l)$  позначає вірогідність місцезнаходження вектора  $l$ , а  $S_k$  позначає  $k^{th}$  групу. Середня мінімізація відстані – загальновідома проблема в літературі VQ і було запропоновано багато алгоритмів для її вирішення.

Проте, середня відстань визначає функцію затрат, яка по суті не зовсім підходить для застосування хешування [2]. По перше, так як модель шифрувальної книги [4] стверджує, що середнє викривлення менше за  $\varepsilon$ , то немає гарантії, що перцептивно чіткі вектори, тобто вектори перехідного хешу, які розділяються більше ніж на  $\delta$ , насправді потрапляють до різних груп. У певних застосуваннях, таких як ідентифікація зображення, мета якого полягає у знаходженні змін змісту, такі гарантії можуть бути обов'язковими, тому що відображення перцептивно чітких векторів у однаковій остаточній хеш величині було б надзвичайно небажаним. Природа функції затрат (3) не дозволяє баланс між бажаними властивостями (1) та (2) хеш алгоритму.

По друге, затрати в (3) зростають лінійно, як і функція відстані між вектором перехідного хешу та вектором шифрувальної книги. Необхідно звертати більше уваги на такі моменти як, наприклад, якщо вектори, які насправді близькі, не згруповані разом, або вектори, які дуже далекі, стиснені до однакової остаточної хеш величини. Лінійна функція затрат не відображає такої поведінки.

Основоючись на таких зауваженнях, запропоновано нову функцію затрат для застосування перцептивного хешування, на яку не впливають обмеження вимірів середньої відстані.

**Формулювання та оптимізація функції затрат.** Сформулюємо функцію затрат, що мінімізується запропонованим методом кластеризації. По-перше, проаналізуємо кілька фундаментальних властивостей (1), (2) та перехідного хешу.

Помилка виникає, коли (1), або/та (2) не задовольняється жодною парою векторів  $(l_i, l_j)$ . Вимогу (1), насправді, неможливо гарантувати для кожної введеної пари. Тоді помилки виникають для векторів, які менш вірогідні, або кластеризація обов'язково має бути продиктована вірогідністю багаточисельної функції векторів в  $L$ .

Опишемо створення функції затрат кластеризації. Нехай  $P: L \times L \rightarrow [0,1]$  є спільним розповсюдженням матриці пар перехідного хешу:

$$P = \begin{bmatrix} p(1,1) & p(1,2) & \cdot & \cdot & \cdot & p(1,n) \\ p(2,1) & p(2,2) & \cdot & \cdot & \cdot & p(2,n) \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ p(n,1) & p(n,2) & \cdot & \cdot & \cdot & p(n,n) \end{bmatrix}, \quad (4)$$

де  $p(i, j) = p(i)p(j)$ . Тут  $p(i), p(j)$  відповідно позначають вірогідність місця розташування векторів  $l_i, l_j$  та  $n$  є кількістю векторів на  $L$ .

Щоб визначити вірогідності, що представлені вище, застосуємо статистичну модель до векторів перехідного хешу  $l$  характерних ознак. Фундаментальний принцип, що лежить в основі, полягає у визначенні прямокутних зон (або підзображень) на зображенні, як реальне двомірне однорідне довільне поле Маркова (MRF)  $X(m_1, m_2)$  на кінцевій решітці  $(m_1, m_2) \in L \subset Z^2$ . Основою для поєднання такого статистичного визначення до перцепції є гіпотеза, яку вперше озвучив Жулез [4], і яка була сформульована по новому кількома іншими науковцями: існує ряд функцій  $\phi_k(X)$ ,  $k = 1, 2, \dots, N$ , таких, що приклади, отримані з будь-яких двох MRF, що є однаковими в очікуванні щодо цього ряду, абсолютно не можливо відрізнити.

Застосуємо універсальну параметричну статистичну модель для природних зображень, розроблену Портілою та Сімонкелі [4], що працює із складними надзавершеними хвильовими представленнями

зображення. Характерні ознаки, які отримані в [1, 2], базуються на такому представленні. Статистичні дескриптори Маркова, тобто  $\phi_k$ , основані на парі хвильових коефіцієнтів у суміжних просторових положеннях, орієнтаціях та масштабах. Особливо, необхідно виміряти очікуваний результат необроблених пар коефіцієнтів (тобто кореляцію) та очікуваний результат їх величин.

Не існує жодної невід'ємної структури для вірогідності багаточисельної хеш функції, що асоціюється із цими довільними полями (за винятком властивості Маркова через просторову кореляцію в зображенні).

Математично привабливий вибір – максимальна ентропічна щільність форми

$$P(\bar{x}) \propto \prod_k e^{-\lambda_k \phi_k(\bar{x})}, \quad (5)$$

де  $\bar{x} \in R^{|L|}$  відповідає векторизованому підзображенню, а  $\lambda_k$  – множники Лагранжа. Максимальна ентропічна щільність – оптимальна в тому змісті, що вона не вводить жодного нового обмеження для MRF, окрім перцептивної еквівалентності за очікуваних величин  $\phi_k$ . Щільність в (5) визначається для MRF, що є частинами справжнього зображення. Так як характерні ознаки є функціями MRF, вірогідна щільність таким чином вводиться на векторах характерних ознак.

Вибір статистичної моделі, а не використання емпіричного розподілу щодо отриманих характерних ознак зображення, базується на стійкості параметрів моделі із додаванням все більшої кількості зразків (зображень). За законом великих чисел, відомо, що параметри моделі стають майже інваріантними, як тільки розглядається достатньо великий ряд зразків.

Далі визначаємо  $C_1$  як матрицю загальних затрат для порушення (1), тобто оплачена ціна, якщо  $D(l_i, l_j) < \epsilon$ , все ще  $C(l_i) \neq C(l_j)$ . В особливості  $\forall i, j = 1, 2, \dots, n$

$$C_1(i, j) = \begin{cases} \Gamma^{-\alpha D(l_i, l_j)} & \text{if } D(l_i, l_j) < \epsilon, C(l_i) \neq C(l_j), \\ 0 & \text{інакше} \end{cases}, \quad (6)$$

де  $\alpha > 0$  та  $\Gamma > 1$  – параметри алгоритму. Ціна порушення (1) має бути більшою для менших відстаней, тобто, якщо вектори насправді близькі і не згруповані разом.

По аналогії і  $C_2$  визначається як матриця загальних затрат для порушення (2)

$$C_2(i, j) = \begin{cases} \Gamma^{\alpha D(l_i, l_j)} & \text{if } D(l_i, l_j) > \delta, C(l_i) = C(l_j), \\ 0 & \text{інакше} \end{cases}. \quad (7)$$

Проте, в цьому випадку, ціна – зростаюча функція відстані між  $(l_i, l_j)$ . Це також досить природно, так як нам би хотілось збільшити ціну, якщо віддалені вектори (і таким чином перцептивно чіткі) об'єднані разом. Визначаємо ті ж параметри, тобто  $\Gamma$  та  $\alpha$  як в (6) та (7). Проте, це не обмеження. В загальному, дані параметри можна обрати окремо (оптимізувати емпірично) як для (6), так і для (7).

Далі, нехай матриці  $S_1$  та  $S_2$  визначаються як

$$S_1(i, j) = \begin{cases} \Gamma^{-\alpha D(l_i, l_j)} & \text{if } D(l_i, l_j) < \epsilon, \\ 0 & \text{інакше} \end{cases}, \quad (8)$$

$$S_2(i, j) = \begin{cases} \Gamma^{\alpha D(l_i, l_j)} & \text{if } D(l_i, l_j) > \delta, \\ 0 & \text{інакше} \end{cases}. \quad (9)$$

Зауважимо, що  $S_1$  відрізняється від  $C_1$  в тому змісті, що список  $S_1$  включає ціну за всі можливі помилки, в той час як  $C_1$  – це матриця затрат для помилок, що створюються алгоритмом кластеризації. Теж саме буде вірно і для  $S_2$  та  $C_2$ . Далі нормалізуємо списки в  $C_1$  та  $C_2$  для визначення нормалізованої матриці затрат  $\tilde{C}_1$  та  $\tilde{C}_2$  наступним чином

$$\tilde{C}_1 = \frac{C_1(i, j)}{\sum_i \sum_j S_1(i, j)}, \quad (10)$$

$$\tilde{C}_2 = \frac{C_2(i, j)}{\sum_i \sum_j S_2(i, j)}. \quad (11)$$

Дана нормалізація стверджує, що  $\tilde{C}_1(i, j), \tilde{C}_2(i, j) \in [0, 1]$ .

Таким чином, загальна функція затрат визначається як

$$P_{err} = E[\tilde{C}_1 + \tilde{C}_2]. \quad (12)$$

Очікування щодо загального розподілу  $(l_i, l_j)$ , тобто (12) можна переписати як

$$P_{err} = \sum_i \sum_j p(i) p(j) (\tilde{C}_1(i, j) + \tilde{C}_2(i, j)). \quad (13)$$

На даному етапі важливо відмітити, що функція відстані  $D(l_i, l_j)$  може бути будь-якою функцією  $l_i$  та  $l_j$ , що задовольняє метричні властивості – симетрію та аксіому трикутника. Функція відстані  $D(\cdot, \cdot)$  не обмежується до будь-якого класу функцій, окрім вимоги щоб вона була метрична. На практиці вибір  $D(\cdot, \cdot)$  мотивується природою характерних ознак, отриманих на стадії хеш алгоритму.

Два додаткових члени в (12)  $E[C_1]$  та  $E[C_2]$  визначають кількість помилок, що є результатом порушення (1) та (2) відповідно. В особливості,  $E[C_1]$  можна інтерпретувати як очікувану ціну порушення (1), так само і  $E[C_2]$  визначає очікувану ціну, що є результатом порушення (2). Це саме та структура функції затрат (12), якою запропонований нами алгоритм кластеризації користується для полегшення балансу між цілями (1) та (2) хеш алгоритму. У випадку, якщо  $\alpha = 0$ ,  $E[C_1]$  та  $E[C_2]$  представляють загальну вірогідність порушення (1) та (2) відповідно.

Наша мета – розвинути алгоритм кластеризації чи створити таблиці кодування, щоб мінімізувати функцію затрат в (12), що найбільш підходить для застосування перцептивного хешування зображення (або медіа).

**Запропонований метод кластеризації.** Знаходження оптимальної кластеризації, яка б досягла загального мінімуму для функції затрат в (12) є складною проблемою.

Детермінована кластеризація. Для подальшого викладення матеріалу вектори в  $L$  будемо називати «точками даних». Алгоритм 1 описує базовий алгоритм кластеризації, точки даних у введеному просторі покриваються у значній мірі гіперсферами (кластерами) радіусом  $\varepsilon/2$  (рис. 1). Для кожної пари точок  $(l_i, l_j) \in S_k$  та центру кластеру  $l_k$ , отримаємо

$$D(l_i, l_j) \leq D(l_i, l^k) + D(l^k, l_j). \quad (14)$$

Дана нерівність справедлива, тому що  $D(\cdot, \cdot)$  – метрична. На основі кроків 3 та 5 базового алгоритму 1 кластеризації  $D(l_i, l^k) < \frac{\varepsilon}{2}$ ,  $D(l^k, l_j) < \frac{\varepsilon}{2}$ , і таким чином  $D(l_i, l_j) < \varepsilon$ . Таким чином, алгоритм намагається згрупувати точки даних в  $\varepsilon$  і, крім того, центри кластерів обираються на основі функції їх вірогідної маси. Це гарантує, що «перцептивно близькі» точки даних з великою вірогідністю будуть згруповані разом.




Рис. 1. Візуалізація базового алгоритму кластеризації

Базовий алгоритм кластеризації складається з наступних кроків:

Алгоритм 1.

1. Отримати визначені користувачем параметри  $\varepsilon$  та  $\delta$ . Встановити число кластерів  $k=1$ .
2. Обрати точку даних, пов'язану із найбільш вірогідною масою, та позначити її як  $l^1$ .
3. Створити перший кластер, включаючи всі точки даних  $l_j$  такі як  $D(l^1, l_j) < \frac{\varepsilon}{2}$ .

4.  $k = k+1$ . Вибрати найбільш вірогідну точку даних  $l^k$  серед не згрупованих точок так, щоб  $\min_{S \in C} D(l^k, S) \geq \frac{3}{2} \varepsilon$ , де  $S$  – будь-який кластер,  $C$  – позначає ряд кластерів, сформований для цього кроку алгоритму.  $D(l^k, S)$  – вираховується із використанням поняття відстані ряду отриманого  $D(x, S) = \min_{y \in C} D(x, y)$ .

5. Сформувати  $k^{\text{th}}$  кластер  $S_k$  включаючи всі не згруповані точки даних  $l_j$  так, щоб  $D(l^k, l_j) < \frac{\varepsilon}{2}$ .

6. Повторити кроки 4 та 5 доти, поки всі кластери не будуть сформовані.

7. Кінець алгоритму.

На даному етапі можливо зробити наступні висновки щодо базового алгоритму кластеризації:

- Мінімальна відстань між будь-якими двома членами двох різних кластерів має нижній кордон  $\varepsilon$  і таким чином немає помилок від порушення (1), що гарантується кроком 4 базового алгоритму кластеризації.

- В середині кожного кластеру максимальна відстань між будь-якими двома точками є найбільшою  $\varepsilon$ , і тому що  $\theta < \varepsilon < \delta$  немає порушення (2).

- Точки даних, що залишились не згрупованими, менші за  $\frac{3}{2} \varepsilon$  будь-якого члену кожного кластеру.

Для перцептивної стійкості, тобто досягнення (1), бажано мінімізувати  $E[C_1]$ . Так само для того, щоб підтримати слабкість до візуально чітких вставок, бажано, щоб  $E[C_2]$  було настільки малим, наскільки це можливо (в ідеалі 0). Повна мінімізація одного піддала б небезпеці іншого.

**Висновки.** Запропонований алгоритм кластеризації використовується для стиснення векторів характерних ознак, так як вимір відстані визначений на просторі результату  $V \times V$  задовольняє метричні властивості. Розроблена нова функція затрат, що складається із двох додаткових експоненціальних членів. Такі затрати краще реагують на цілі перцептивного хешування, на відміну від традиційного типу вимірювання викривлень на основі середньої відстані.

Запропоноване рішення проблеми кластеризації досягається визначенням «більш ймовірних» та близьких векторів характерних ознак до однієї групи.

Вперше було розроблено базову кластеризацію, що дає можливість кластерам не зазнавати жодних затрат. Запропонована кластеризація перевершує відомі техніки стиснення традиційного VQ та декодування із виправленням помилок для перцептивного хеш стиснення.

Запропоновані алгоритми мають дві математичні властивості:

1) число кластерів (або еквівалентно довжина хешу) визначається автоматично;

2) кластеризацію можна застосувати до векторів в будь-якому метричному просторі, тобто не потрібно робити жодних припущень щодо топології простору.

Ці дві властивості зроблять запропоновані алгоритми цінними у застосуванні для інших медіа, та в загальному, у стисненні даних та / або зменшенні розмірів.

### Література

1. Джулій В.М., Іванов К.В. Методика виявлення характерних ознак графічних зображень. // Вимірювальна та обчислювальна техніка в технологічних процесах. – № 2. – 2007. – С.115 – 119.
2. Джулій В.М., Іванов К.В. Методика формування перехідного хешу графічного зображення. // Вимірювальна та обчислювальна техніка в технологічних процесах. – № 2. – 2008. – С.136 – 140.
3. Нетравалі, Арун Н. та Хаскель, Баррі Г. "Цифрові зображення: Представлення і компресія". – Нью-Йорк. 2002. – 430 с.
4. Лин та Чанг. Створення надійного цифрового підпису для ідентифікації медіа. – М.: "Лори". 2000. – 270с.
5. Галицкий А. В., Рябко С. Д., Шаньган В. Ф. Защита информации в сети – анализ технологий и синтез решений. – М.: ДМК Пресс, 2004. – 616 с.: ил.
6. Демидович Б. П., Марон И. А. Основы вычислительной математики. – М.: "Наука". 1970. – 664 с.

Надійшла 6.9.2009 р.