

Сегментація текстурних зображень на основі методу векторної підтримки

Довженко Оксана Володимирівна

Дніпропетровський національний університет, Радіофізичний факультет, вул. Наукова 13,
корпус 12, м. Дніпропетровськ 49050. тел. 056-7769092. e-mail: dovzhenko@mail.dsu.dp.ua

Мета даної роботи – дослідження інформаційних характеристик методу векторної підтримки стосовно до задачі сегментації текстур. Метод сегментації включає два етапи: на першому реалізується розпізнавання і локалізація текстурних об'єктів зображення на основі модуля векторної підтримки з учителем, на другому - додаткова обробка результатів з використанням медіанної фільтрації і морфологічної обробки для виявлення невірно класифікованих блоків і більш зручного візуального аналізу результатів. Експериментальні дослідження проводилися для різних типів текстурних зображень.

1. Вступ

Сегментація текстурних зображень відноситься до високоактуальних задач в області комп'ютерного бачення, що приваблює увагу багатьох дослідників довгий час, оскільки і на даний момент є проблемою, далекою від кінцевого розв'язку. Вирішення задачі сегментації текстур провадиться за двома основними напрямками, до першого з котрих відноситься відшукування текстурної моделі, в рамках якої кожен піксел вихідного зображення представляється вектором характеристик (точка багатомірного простору ознак), причому віднайдена модель повинна задовольняти вимогам чутливого аналізу і локалізації подібних регіонів зображення, другий напрямок включає безпосередньо розробку методів сегментації. На даний момент для вирішення першого типу задач найбільш активно використовуються підходи, основані на моделюванні випадкових полів (Марківські, Гаусівські випадкові поля) [1], а також багаторівневої декомпозиції зображення за допомогою банків фільтрів Лапласа, Габора [2], вейвлет-перетворення і популярного останнім часом апарату орієнтованих пірамід [3]. Сегментація текстур, в залежності від наявності апріорної інформації про характер і тип вихідного зображення, може бути реалізована на основі методів навчання з учителем, куди можна віднести нейронні мережі підходи [4], метод векторної підтримки або на основі адаптивних методів без учителя [5], однак, єдиного підходу, котрий би задовольняв вимогам високої чутливості аналізу, точності і низьких витрат ресурсів і машинного часу на даний момент не існує.

В даній роботі демонструється можливість застосування нового методу розпізнавання образів, названого як метод векторної підтримки (МВП) для вирі-

шення задачі сегментації текстур, причому обґрунтуванням до використання саме цього методу є задовільні в розумінні точності і витрат машинного часу результати застосування МВП для вирішення задач класифікації [6].

Головна ідея методу – це побудова на основі модуля векторної підтримки оператора, що на основі апріорної інформації про характер ділянок, які треба локалізувати, здійснює аналіз зображення. Питання вибору розміру оператора досліджується в експериментальній частині.

2. Метод векторної підтримки

Алгоритм векторної підтримки являє собою нелінійний варіант узагальненого портретного алгоритму, що був запропонований Вапніком на початку 60-х років. У зв'язку зі складною програмною реалізацією практично метод векторної підтримки не використовувався, і тільки в 1998 році Платтом [7] був розроблений алгоритм послідовної мінімальної оптимізації, що дозволив усунути обмеження прямого варіанта МВП, пов'язані з високими витратами машинного часу при вирішенні задачі квадратичного програмування.

В рамках спрощеного опису, МВП являє собою задачу побудови гіперплощини, що розділяє вхідні дані $\{x_i, y_i\}, i=1, \dots, m; y_i \in \{-1, +1\}, x_i \in R_n$ таким чином, що забезпечується максимальна відстань між найближчими точками "позитивного" і "негативного" піднаборів.

Нехай існує набір вхідних даних x_1, x_2, \dots, x_m де $x_i \in R_n$. Кожному вхідному значенню відповідає мітка з набору y_1, y_2, \dots, y_m , де $y_i \in \{-1, +1\}$, що показує, до якого з двох класів належить те чи інше вхідне значення. Будемо говорити, що гіперплощина $(w \cdot x) + b$, що розділяє дані, існує тоді і тільки тоді, коли виконуються наступні умови:

$$(w \cdot x_i) + b \geq 0, \text{ для } y_i = 1, \quad (1)$$

$$(w \cdot x_i) + b \leq 0, \text{ для } y_i = -1, \quad (2)$$

або

$$y_i((w \cdot x_i) + b) \geq 1, \text{ для } \forall i. \quad (3)$$

Оптимальною гіперплощиною буде така, для котрої відстань між найближчими точками з піднаборів, що помічені позитивними і негативними мітками та самою гіперплощиною була б максимальною.

Відстань між двома найближчими точками з різних піднаборів може бути визначена як:

$$d(w,b) = \min_{\{x_i|y_i=1\}} \frac{w \cdot x_i + b}{|w|} - \max_{\{x_i|y_i=-1\}} \frac{w \cdot x_i + b}{|w|},$$

З виразів (1) та (2) можна бачити, що значення максимуму та мінімуму відповідно дорівнюють 1 та -1. Тоді необхідно максимізувати відстань:

$$d(w,b) = \frac{1}{|w|} - \frac{-1}{|w|} = \frac{2}{|w|},$$

Задача відшукування максимальної відстані еквівалентна задачі мінімізації $|w|^2/2$ за умови, що виконуються обмеження (3).

Для вирішення цієї задачі використаємо перехід до форми Лагранжа, в результаті чого задача в двоїтій формі може бути записана як:

$$\min(\sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i \cdot x_j)$$

За обмежень

$$\begin{aligned} \alpha_i &\geq 0 \\ \sum_i \alpha_i y_i &= 0 \end{aligned}$$

Де α_i – множники Лагранжа. Кожному вхідному значенню може відповідати лише один такий множник. Ті значення вхідного набору, для котрих множники Лагранжа приймають ненульові значення, називаються векторами підтримки і використовуються для відшукування розділюючої гіперповерхні.

Розглянута вище задача оптимізації не має розв'язків, якщо вхідні дані не є такими, що можуть бути розділені лінійно. В даному випадку обмеження (1) та (2) модифікуються наступним чином:

$$\begin{aligned} (w \cdot x_i) + b &\geq 1 - \xi_i, \text{ для } y_i = 1, \\ (w \cdot x_i) + b &\geq \xi_i - 1 \text{ для } y_i = -1, \\ \xi_i &\geq 0, \text{ для } y_i = 1, \end{aligned}$$

де ξ_i – це “послаблююча” змінна, що задає верхню межу похибки навчання. Схематичне зображення цього випадку задачі класифікації представлено на Рис. 1. Тоді задача мінімізації $|w|^2/2$ може бути сформульована як

$$\min(\frac{|w|^2}{2} + C(\sum_i \xi_i)),$$

Параметр C – параметр, що задається, і він визначає припустиму похибку класифікації. Якщо перейти до запису задачі в формі Лагранжа, то в двоїтій

тому формулюванні вона буде виглядати наступним чином:

$$\min(\sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i \cdot x_j),$$

за обмежень

$$\begin{aligned} 0 &\leq \alpha_i \leq C, \\ \sum_i \alpha_i y_i &= 0. \end{aligned}$$




Рис. 1 Схематичне зображення розділюючої гіперплощини для лінійно-нероздільного випадку.

Наступний крок полягає в приведенні розглянутого алгоритма до більш узагальненого, тобто нелінійного варіанту, що досягається відображенням вхідних ознак x_i в деякий багатовимірний простір, причому його розмірність вище, ніж розмірність простору вхідних значень R^d . Це відображення може бути представленим як $\Phi: X \rightarrow F$; після здійснення попередньої обробки вхідних даних використовується стандартний алгоритм МВП. Як було розглянуто раніше, для лінійного варіанту методу вхідні дані представляються в формі точкового добутку між вхідними ознаками x_i, x_j , причому $i \neq j$, що для нелінійного випадку: $k(x, x') = \langle \Phi(x), \Phi(x') \rangle$, причому k називають функцією ядра.

Тепер виникає наступне питання: яким умовам мають задовільняти функції, що можуть бути вибрані в якості функцій ядер? Розглянемо теорему, що характеризує такі функції.

Теорема: нехай існує $k \in L_\infty(X^2)$, таке, що інтегральний оператор $T_k: L_2(X) \rightarrow L_2(X)$,

$$T_k f(\cdot) = \int_X k(\cdot, x) f(x) d\mu(x)$$

є додатнім.

Тоді, якщо

$$\int_{X \times X} k(x, x') f(x) f(x') dx dx' \geq 0$$

для всіх $f \in L_2(X)$, то ми можемо представити $k(x, x')$ як векторний добуток в деякому просторі відображення. Такі функції k будемо називати припустимими ядрами векторної підтримки.

Аналіз пулікацій показує, що наступні функції, котрі задовільняють умовам припустимості ядер векторної підтримки, найчастіше використовуються для вирішення практичних задач.

1) Поліноміальні ядра k з $p \in \mathbb{N}$:

$$k(x, x') = \langle x, x' \rangle^p.$$

2) Поліноміальні ядра k з $p \in \mathbb{N}$ і $c > 0$:

$$k(x, x') = (\langle x, x' \rangle + c)^p.$$

3) Ядра на основі радіальних базисних функцій

$$k(x, x') = e^{-\frac{\|x-x'\|^2}{2\sigma^2}}.$$

В описі теоретичних основ методу векторної підтримки був розглянутий випадок розділення даних на два класи, однак, в реальних задачах зазвичай постає питання класифікації вхідних ознак на значно більшу кількість класів, у зв'язку з чим виникає необхідність розширення апарату класифікації до т. з. мультикласифікатора або N -класифікатора, що дозволяє вирішувати задачу для випадку $N > 2$, де N – кількість класів. Стандартний метод для конструювання N -класифікатора полягає в послідовному створенні N класифікаторів, кожен з котрих визначає розділяючу гіперповерхню для i -го класу, позначеного міткою “1” та всіх тестових входів, позначених “-1”. Цей підхід скорочено називається “1-vs-r” (1-versus-rest) або “один проти багатьох”.

Інший підхід, котрий вигідно відрізняється від попереднього більшою точністю класифікації, вимагає побудови $K = N(N-1)/2$ класифікаторів і скорочено позначається “1-vs-1” або “один проти одного”. Метод 1-vs-1 базується на комбінації бінарних класифікаторів на основі архітектури орієнтованого ациклічного графу.

Кінцевий N -класифікатор представляє собою деревоподібну структуру з $N(N-1)/2$ вузлами, кожен з котрих – елемент множини булевих функцій $F = \{f: X \rightarrow \{0, 1\}\}$, де X – простір вхідних даних, при чому будь-який i -й вузол у шарі $j < N$ зв'язаний з i -тим $(i+1)$ -м вузлом $(j+1)$ -го шару. Таким чином, вузли дерева повністю описують всі можливі двокласові комбінації на множині з N класів і кожна вхідна точка для віднесення її до якогось з класів повинна пройти шлях від кореневого вузла до найнижчого шару дерева з N виходами, котрий визначається як шлях оцінки. Недолік описаного підходу – це надлінійне зростання кількості операторів із зростанням значення N . З іншого боку, кожен операційний вузол

преставляє собою окремих класифікатор, що дозволяє регулювання параметрів і похибки класифікації, завдяки чому забезпечується вища точність класифікації.

3. Вибір функції ядра

Важливим питанням при реалізації методу для вирішення практичних задач є правильний вибір функції ядра, від котрого, в більшості випадків, залежить точність отримуваних результатів. Однак, єдиного підходу для визначення необхідної функції ядра, а також її параметрів, на даний момент немає, тому ця задача вирішується емпірично в кожному окремому випадку.

Для вирішення задачі сегментації текстур з учителем найліпші результати були отримані з використанням радіальних базисних функцій з вар'юванням коефіцієнту σ від 0.001 до 2.5 в залежності від розміру вікна оператора сегментації.

4. Експериментальна частина

Експериментальні дослідження було проведено з використанням різних типів текстурних зображень з відомої бази текстур Brodatz Collection [8]. Реалізація методу сегментації здійснювалася на основі алгоритму послідовної мінімальної оптимізації з використанням методу ациклічних графів для побудови мультикласифікатора.

Для кожного аналізованого зображення було досліджено можливість використання вікон операторів (window) різних розмірів: 4×4 , 8×8 , 16×16 , 32×32 . Необхідно зазначити, що розмір блока навчання визначає кількість операцій i , відповідно, обсяг витрат машинного часу. Ця обставина пов'язана з тим, що обчислення векторів підтримки відбувається для кожного кроку вікна оператора. Розмір вікна вибирався в залежності від характеру вихідного зображення, що сегментується.

5. Висновки

Як показують отримані результати (Рис. 2), метод векторної підтримки представляє собою чутливий апарат для вирішення задачі сегментації текстурних зображень, котрий вигідно відрізняється від стандартних підходів високою точністю і низькими витратами машинного часу при реалізації його на основі алгоритму послідовної мінімальної оптимізації.

Однак, виникає цілий ряд додаткових питань, пов'язаних з розвитком методу сегментації, котрі в цілому визначають успішність результатів – а саме розробка автоматичного (адаптивного) методу вибору параметрів ядер, оскільки, як видно з Рис. 2е-л, точність сегментації (котра визначається кількістю невірних класифікованих блоків) суттєво змінюється при невеликому вар'юванні параметру σ ядра радіальної базисної функції.




Рис. 2 Результати сегментації текстурних зображень на основі МВП:

а-г – вихідні зображення; е – результат сегментації зображення а: $window = 8, \sigma = 1.5$; ж – результат додаткової фільтрації і морфологічної обробки сегментованого зображення; з – $window = 16, \sigma = 0.1$; к – $window = 32, \sigma = 0.05$; л – $window = 32, \sigma = 0.07$; м - результат сегментації зображення б: $window = 8, \sigma = 1.5$; н – додаткова обробка результатів; п - результат сегментації зображення в: $window = 16, \sigma = 0.05$; р - результат сегментації зображення г: $window = 8, \sigma = 1.0$; с – додаткова обробка результатів.

Література

1. Geman S, Graffigne C., *Markov random fields and their application to computer vision*. In Gleason, A. (Ed.), *Proceedings of the International Congress of Mathematicians*, pp. 1496-1517 Berkeley, California, 1989.
2. Jan Puzicha and Joachim M. Buhmann, *Multiscale Annealing for Real-Time Unsupervised Texture Segmentation*. Technical Report IAI-TR-97-4, Institut für Informatik III, University of Bonn. April 1997.
3. Simoncelli E. P. and Portilla J. *Texture Characterization via Joint Statistics of Wavelet Coefficient Magnitudes*. // 5th IEEE Int'l Conf on Image Processing. - Chicago, IL. Oct 4-7, 1998.
4. Mario Koppen, Javier Ruiz-del-Solar, Pierre Soille, *Texture Segmentation by biologically-inspired use of*

Neural Networks and Mathematical Morphology, Pattern recognition, v. 30, pp. 183-196, 1997.

5. Tanachit Tangsukson, Joseph P. Havlicek, *AM-FM image segmentation*, *Image Processing, 2000. Proceedings. 2000 International Conference on*, Vol. 2, pp. 104 – 107, Jan. 2001.

6. Ахметшин О. М. , Довженко О. В., *Підвищення ефективності класифікації в багатовимірному просторі ознак великої розмірності на основі методу векторної підтримки*, Збірка праць МКІМ-2002, т. 4, сс. 36-41, 2002.

7. J. Platt, *Fast training of support vector machines using sequential minimal optimization*. In *advances in kernel methods—support vector learning*, pp.185-208, Cambridge, 1999.

8. <http://www.ux.his.no/~tranden/brodatz.html>.