

2 МЕТОДИ КЛАСИФІКАЦІЇ ЦИФРОВИХ ЗОБРАЖЕНЬ

2.1 Параметричні та непараметричні методи класифікації цифрових зображень

План

1. Роль нормального розподілу в задачах класифікації.
2. Метод максимальної правдоподібності.
3. Метод мінімальних відстаней.
4. Метод паралелепіпедів.
5. Особливості непараметричних методів класифікації.
6. Робастні алгоритми.
7. Рангова статистика.
8. Двовибірний алгоритм Вілкоксона.
9. Декореляції фону.

Роль нормального розподілу в задачах класифікації

Під час дистанційного зондування яскравість кожного пікселя складається з яскравостей природних об'єктів, що потрапили під миттєве поле зору сканера. Об'єкти випадковим чином відображають і розсіюють сонячне випромінювання, так що яскравість пікселя є сумою випадкових величин.

З теорії ймовірностей відомо, що сума незалежних, однаково розподілених випадкових величин має нормальний (гаусівський) закон розподілу (центральна гранична теорема).

Таким чином, є підстави вважати, що для природних об'єктів яскравість пікселів може підпорядковуватися нормальному закону розподілу.

Названа вище причина не єдина, за якою у задачах параметричного розпізнавання зображень широко використовується гіпотеза про нормальний закон розподілу яскравості пікселів.

Під час розпізнавання монохроматичних зображень для розподілу яскравості майже завжди вдається підібрати один з відомих одновимірних законів (нормальний, біноміальний, експонентний, пуасонівський).

Інша справа – зображення, одержані за допомогою сканерів, що мають n -спектральних каналів, $n > 1$. У цьому випадку для опису статистичних характеристик потрібно n -мірний спільний розподіл величин яскравості в каналах.

n -мірна нормальна функція щільності ймовірностей яскравості має вигляд

$$w_n(f_{ij}) = (2\pi)^{-\frac{n}{2}} |R|^{-\frac{1}{2}} \cdot \exp \left[-\frac{1}{2} (f_{ij} - \mu)^T \cdot R^{-1} (f_{ij} - \mu) \right]. \quad (2.1)$$

У (2.1) вектор даних, що характеризує яскравість (i, j) -го пікселя у всіх n -спектральних каналах, позначений через f_{ij} , вектор математичного очікування – через μ , кореляційна матриця – через R , $|R|$ – визначник кореляційної матриці, R^{-1} – матриця, обернена до R , символ $(f_{ij} - \mu)^T$ означає транспонування вектора [8].

$$f_{ij} = \begin{pmatrix} f_{1ij} \\ f_{2ij} \\ \dots \\ \dots \\ f_{nij} \end{pmatrix}, \quad \mu = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \dots \\ \dots \\ \mu_m \end{pmatrix}, \quad R = \begin{pmatrix} R_{11} & R_{12} & \dots & \dots & R_{1n} \\ R_{21} & R_{22} & \dots & \dots & R_{2n} \\ \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots \\ R_{n1} & R_{n2} & \dots & \dots & R_{nn} \end{pmatrix}. \quad (2.2)$$

Компоненти вектора $f_{ij} : f_{1ij}, f_{2ij}, \dots, f_{nij}$ – яскравість пікселя у першому, другому та інших каналах. Компоненти вектора $\mu : \mu_1, \mu_2, \dots, \mu_n$ – математичне очікування яскравості пікселя для першого, другого та інших каналів.

На головній діагоналі кореляційної матриці (2.2) на перетині n -го рядка та n -го стовпця стоїть величина $R_{nn} = \sigma_p^2$, що показує значення дисперсії яскравості пікселів у n -му каналі (характеристика контрасту).

$R_{ns} = R_{sn}$ – це коефіцієнт кореляції значень яскравості пікселів у n -му та s -му каналах.

Методи класифікації, засновані на нормальному законі розподілу, задовільно працюють навіть при помітних відхиленнях від нормальності.

Нехай супутникове сканерне зображення земної поверхні, що отримане в n -спектральних каналах, є сукупністю пікселів, яскравість (i, j) -го пікселя описується вектором f_{ij} з n компонентів. Потрібно віднести цей піксель до одного з M класів. Попередньо створюється *навчальна вибірка* – супутникове зображення, на якому по наземним даним визначені ділянки, що відповідають різним класам. Користувач вказує межі цих класів, відбувається процес навчання, тобто комп'ютер оцінює вектор математичного очікування і кореляційну матрицю для кожного із класів.

Далі проводиться обробка даного супутникового зображення. Комп'ютер для кожного класифікованого пікселя визначає вектор вимірювань f_{ij} і в кожному k класі формує умовні щільності ймовірностей $w\left(\frac{f_{ij}}{C_k}\right)$.

Для цього у багатовимірний нормальний закон розподілу (2.1) підставляються μ_k і R_k – задані умови, тобто у даному випадку оцінки вектора математичного очікування і кореляційної матриці еталонного об'єкта « k ».

Таким чином, для кожного пікселя формується M умовних щільностей ймовірностей, які порівнюються з деяким порогом Q_{kl} . Порівняння дозволяє визначити, яка з гіпотез найбільш правдоподібна.

Відношення правдоподібності L_{kl} для класів k та l має вигляд [8]:

$$L_{kl} = \frac{w\left(\frac{f_{ij}}{C_k}\right)}{w\left(\frac{f_{ij}}{C_l}\right)} = \frac{|R_k|^{-\frac{1}{2}} \exp\left[-\frac{1}{2}(f_{ij} - \mu_k)^T R_k^{-1}(f_{ij} - \mu_k)\right]}{|R_l|^{-\frac{1}{2}} \exp\left[-\frac{1}{2}(f_{ij} - \mu_l)^T R_l^{-1}(f_{ij} - \mu_l)\right]}. \quad (2.3)$$

Замість відношення правдоподібності L_{kl} можна використати будь-яку монотонну функцію від нього, наприклад, натуральний логарифм $\ln L_{kl}$:

$$\ln L_{kl} = \frac{1}{2} \ln \frac{|R_l|}{|R_k|} + \frac{1}{2} \left[(f_{ij} - \mu_k)^T R_k^{-1}(f_{ij} - \mu_k) \right] - \frac{1}{2} \left[(f_{ij} - \mu_l)^T R_l^{-1}(f_{ij} - \mu_l) \right]. \quad (2.4)$$

У цьому випадку величина $\ln L_{kl}$ порівнюється з порогом $q_{kl} = \ln Q_{kl}$. Перший член $\frac{1}{2} \ln \frac{|R_l|}{|R_k|}$ і множник $\frac{1}{2}$ у виразі для $\ln L_{kl}$ можуть бути включені до порогу q_{kl} . Таким чином, завдання з'ясування, до k -го або l -го класу відноситься (i, j) -й піксель, зводиться до порівняння квадратичних форм:

$$A = \left[(f_{ij} - \mu_k)^T R_k^{-1}(f_{ij} - \mu_k) \right], \quad B = \left[(f_{ij} - \mu_l)^T R_l^{-1}(f_{ij} - \mu_l) \right]. \quad (2.5)$$

Нерідко вважають, що $q_{kl} = 0$. У цьому випадку вважається, що (i, j) -й піксель відноситься до k -го класу, якщо квадратична форма $A < B$, тобто коли компоненти вектора f_{ij} тісніше групуються навколо μ_k .

Квадратична форма $\left[(f_{ij} - \mu_k)^T R_k^{-1} (f_{ij} - \mu_k) \right]$ характеризує відстань класифікованого пікселя з вектором яскравості f_{ij} , вона часто застосовується у задачах розпізнавання зображень. У випадку, коли вектор яскравості пікселя f_{ij} складається з двох компонент, тобто для двох спектральних каналів, квадратична форма має вигляд (2.6).

$$P_k = \frac{1}{(1 - \rho_{12k}^2)} \left[\frac{(f_{1ij} - \mu_{1k})^2}{\sigma_{1k}^2} + \frac{(f_{2ij} - \mu_{2k})^2}{\sigma_{2k}^2} - 2\rho_{12k} \frac{(f_{1ij} - \mu_{1k})(f_{2ij} - \mu_{2k})}{\sigma_{1k}\sigma_{2k}} \right], \quad (2.6)$$

де $\rho_{12k} = \frac{R_{12k}}{\sigma_{1k}\sigma_{2k}}$ – нормований коефіцієнт кореляції двох спектральних каналів для об'єкта « k » еталонного зображення.

Метод максимальної правдоподібності

Розпізнавання за методом *максимальної правдоподібності* використовує значний обсяг статистичних даних та успішно справляється із складними завданнями. Метод максимальної правдоподібності забезпечує оптимальне розпізнавання. Однак, цей метод вимагає досить великої кількості операцій і є порівняно повільним. Бажано, щоб під час його використання враховувалися не тільки яскравості в спектральних каналах для кожного одиночного пікселя, але і його оточення. У деяких випадках розглянутий варіант методу максимальної правдоподібності за якістю програє більш простим методам, які беруть до уваги взаємні зв'язки сусідніх пікселів.

Квадратичну форму $\left[(f_{ij} - \mu_k)^T R_k^{-1} (f_{ij} - \mu_k) \right]$ можна спростити, якщо покласти $R_{mnk} = 0$, $m \neq n$, тобто не враховувати кореляцію яскравостей пікселя у спектральних каналах. У (2.6) залишаться тільки два члени, множник перед квадратними дужками стане рівним 1.

У разі двох класів k та s отримуємо такі вирази [8]:

$$r_k^2 = \sum_{m=1}^n \frac{(f_{mij} - \mu_{mk})^2}{\sigma_{mk}^2}, \quad r_s^2 = \sum_{m=1}^n \frac{(f_{mij} - \mu_{ms})^2}{\sigma_{ms}^2}, \quad (2.7)$$

де m – номер спектрального каналу;

n – загальне число каналів;

r_k^2 – квадрат відстані в просторі яскравості по евклідовій метриці між класифікованим пікселем з вектором f_{ij} і вектором середнього значення μ_k еталонного об'єкта « k ».

Під час використання (2.7) вважається, що піксель відноситься до того класу, де менший один із двох r_k^2 чи r_s^2 .

Точність r_k^2 істотним чином залежить від точності оцінювання σ_{mk}^2 , як і в методі максимальної правдоподібності.

Метод мінімальних відстаней

Подальше спрощення призводить до методу *мінімальних відстаней*, коли вирішення про те, до якого класу належить піксель, приймається на підставі порівняння відстаней між пікселями і середніми значеннями в просторі яскравості без урахування вектора дисперсії яскравості еталонного об'єкта:

$$r_k^2 = \sum_{m=1}^n (f_{mij} - \mu_{mk})^2. \quad (2.8)$$

Це самий простий і швидкий метод класифікації, він вимагає мінімальних відомостей про класи, але нерідко поступається методу максимальної правдоподібності у точності класифікації. Порівняння з результатами класифікації по методу максимальної правдоподібності показує, що у даному випадку краще всього виділилися згарища та інші елементи ландшафту, позбавлені рослинності, гірше виділилися листяні дерева.

Метод мінімальних відстаней не враховує оточення пікселя, тому іноді може поступатися методам кластерного аналізу, методам сегментації по нарощуванню областей та по виділенню кордонів.

Метод мінімальних відстаней заснований на евклідовій метриці та не пов'язаний з нормальним законом розподілу.

Метод паралелепіпедів

На практиці знаходить застосування ще один простий метод класифікації, пов'язаний з нормальним законом, – метод паралелепіпедів (метод прямокутників). Він використовує відомості про класи у вигляді векторів середніх значень яскравості μ_k і векторів дисперсій σ_{mk}^2 , що отримані у процесі навчання. Відомо, що для нормально-розподіленої випадкової величини 95,4% її значень лежать у межах відхилень від середнього значення, менших 2σ .

Розглянемо випадок двох спектральних компонент.

На рисунку 2.1 по вертикальній осі відкладені значення яскравості f_1 у першому каналі, по горизонтальній осі – значення яскравості f_2 у другому каналі.

Зазначені середні значення яскравості μ_{11} і μ_{12} для першого і другого класів у першому каналі, μ_{21} і μ_{22} для першого і другого класів у другому каналі. Від значення середньої яскравості в обидві сторони відкладені значення середньоквадратичного відхилення σ_{11} , σ_{12} , σ_{21} , σ_{22} для першого і другого класу в кожному із двох каналів.




Рисунок 2.1 – Дві спектральні компоненти

У двовимірному випадку отримано прямокутники, у три- і більше мірному випадку маємо паралелепіпеди у відповідному просторі.

Якщо компоненти вектора яскравості f_{1ij} та f_{2ij} такі, що потрапляють в лівий прямокутник, приймається рішення про належність пікселя до першого класу, якщо вони потрапляють у правий прямокутник, то до другого.

Прямокутники можуть частково перекриватися, особливо це характерно для областей, що примикають до кутів. У цьому випадку точки виявляються нерозпізнаними.

Метод паралелепіпедів відноситься до числа швидких методів класифікації, однак, за якістю розпізнавання він поступається більшості з розглянутих методів, як видно із зображення.

Метод паралелепіпедів найдоцільніше використовувати для попередньої класифікації, він найбільш ефективний при нормальному законі, так як для нього виконується «правило двох сигма».

Особливості непараметричних методів класифікації

Параметричні методи статистичної класифікації зображень є потужним засобом тематичної обробки. Специфіка дистанційного зондування в оптичному діапазоні полягає у тому, що зображення подане у вигляді декількох шарів, кожен з яких отримано в одному із спектральних каналів [10].

Для використання параметричних методів необхідно знати багатовимірні функції розподілу ймовірностей, пов'язані з класами образів. Часто ці функції не відомі і повинні оцінюватися по множині навчальних образів. Використовується багатовимірний нормальний закон, хоча не відомі докази, що багатовимірні функції розподілу ймовірностей яскравостей багатоспектральних зображень мають саме такий вигляд.

В одновимірному випадку нормальний закон розподілу несправедливий хоча б через те, що яскравість – величина невід'ємна. У разі прийняття гіпотези про нормальність розподілу по навчальним образам необхідно оцінити тільки окремі параметри, пов'язані з цими функціями (такі як математичні сподівання, дисперсії, функції кореляції). Параметричні методи, зазвичай, легше реалізуються, але вимагають більшого обсягу апіорної інформації або фундаментальних припущень щодо природи образів. Якщо форма функцій розподілу ймовірностей не відома заздалегідь, метод є *непараметричним*.

Непараметричні методи мають великі потенційні можливості для точної оцінки функцій розподілу ймовірностей і для точного розпізнавання, але ця перевага, зазвичай, вимагає складних систем, що розпізнають, великого числа навчальних образів і, головне, великих часових витрат. Непараметричні алгоритми, зазвичай, синтезують евристично, часто використовуються локальні оцінки ймовірності за емпіричною частотою.

Робастні алгоритми

Серед непараметричних алгоритмів слід виділити робастні (стійкі) алгоритми, справедливі з тією чи іншою ефективністю при різних законах розподілу. Прикладом непараметричного алгоритму є метод мінімальних відстаней, метод використовує середні значення яскравості і дисперсії або тільки середні значення яскравості об'єктів, знайдені з навчальної вибірки.

При цьому припущення про функції розподілу не використовуються. Головне, щоб середні значення яскравості і дисперсії існували.

Прикладом непараметричного алгоритму, що використовується під час придушення шуму у вигляді крапок і ліній на зображенні, є алгоритм *медіанної фільтрації*.

Рангова статистика

Розглянемо типовий робастний алгоритм, так званий ранговий, який враховує відхилення елементів даної вибірки від елементів випадкової вибірки. Наприклад, є зображення лісу з дозволом 30 м, на якому видні крони дерев та просіка. Потрібно виявити і виділити зображення просіки (рис. 2.2) [10].



Рисунок 2.2 – Зображення лісу з просікою

Можна використати градієнтний фільтр, наприклад, фільтр Лапласа. Просіка стає більш помітною, але пікселі, що відносяться до неї, оточені іншими пікселями, які можна інтерпретувати як шум (рис. 2.3) [10].




Рисунок 2.3 – Результат застосування фільтру Лапласа

Розглянемо один рядок зображення, який показано на рисунку 2.4.



Рисунок 2.4 – Рядок зображення, що містить пікселі об’єкта та шуму

Прийmemo, що A – пікселі об’єкта (просіки), x_i – вибіркoві значення яскравості пікселів (табл. 2.1).

Таблиця 2.1 – Вибіркові значення яскравості пікселів

x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}
4	3	13	8	5	18	9	6	11	15

Рангом R_i елемента вибірки x_i називається число елементів n цієї вибірки, менших або рівних x_i . Якщо елементи вибірки розташувати у порядку зростання від меншого до більшого (сформувати варіаційний ряд за зростанням), то отримаємо таблицю 2.2.

Таблиця 2.2 – Вибіркові значення яскравості пікселів

R_i	1	2	3	4	5	6	7	8	9	10
	3	4	5	6	8	9	11	13	15	18
x_i	x_2	x_1	x_5	x_8	x_4	x_7	x_9	x_3	x_{10}	x_6

Ранг R_9 елемента x_9 дорівнює 7, ранг R_2 елемента x_2 дорівнює 1, ранг R_6 елемента x_6 дорівнює 10.

Коли спостерігається тільки шум, враховуючи незалежність та однорідність значення яскравості пікселів, то величини рангів рівноймовірні при будь-яких функціях розподілу.

Якщо ж у вибірці є суміш шуму і деякого не випадкового зображення, то величини рангу не будуть рівноймовірними.

Двовибірний алгоритм Вілкоксона

Для виявлення локальних контурних ознак можна використати двовибірний алгоритм Вілкоксона. Формуються дві вибірки, одна з яких $X = x_1, x_2, \dots, x_n$ є опорною і належить області фону, інша $Y = y_1, y_2, \dots, y_m$ – робоча. Вхідні в Y елементи можуть бути як пікселями фону, так і пікселями шуканого зображення, тобто до складу вектора Y включені ті пікселі, які відповідають очікуваному положенню об'єкта, що цікавить (табл. 2.3).

Таблиця 2.3 – Двовибірний алгоритм Вілкоксона

Без локальних контурних ознак										
R_i	1	2	3	4	5	6	7	8	9	10
x_i	3	4	5	6	8	9	11	13	15	18
З локальними контурними ознаками										
R_i	1	2	3	7	8	9	10	11	12	13
y_i	3	4	5	11	13	15	18	24	24	24

Складаються два варіаційних ряди – один для елементів опорної X вибірки, а другий для робочої Y вибірки. Ранги елементів робочої вибірки визначаються з урахуванням рангів елементів опорної вибірки, тобто для тих елементів робочої вибірки y_i , які збігаються (або близькі) до елементів опорної вибірки x_i , зберігаються ті ж самі ранги. Значення яскравості y_i пікселів, що відносяться до області A , перевищують x_i , тому вони потраплять у кінець варіаційного ряду з новими (більшими) номерами (рангами), а у загальній послідовності номерів відбудеться стрибок, зникнуть ранги 4, 5, 6.

Далі визначається рангова статистика $R = \sum R_i$, порівняння якої з порогом R_0 призводить до вирішення про наявність чи відсутності локальних контурних ознак згідно правила:

$$R \geq R_0 - \text{локальні контурні ознаки є,} \quad (2.9)$$

$$R < R_0 - \text{локальні контурні ознаки відсутні.} \quad (2.10)$$

У розглянутому прикладі $R = 55$, якщо локальні контурні ознаки відсутні і $R = 76$, якщо локальні контурні ознаки є. При відсутності локальних контурних ознак елементи обох векторів X та Y утворюють однорідну множину випадкових величин, що підкоряються одному і тому ж закону розподілу $w(x)$.

У цьому випадку елемент робочої вибірки з рівними шансами займає будь-яке положення у варіаційному ряді, а це означає, що випадкова величина R_i підпорядковується рівноймовірному закону розподілу:

$$w(R_i) = \frac{1}{(n+1)}, \quad R_i = 0, 1, 2, \dots, n. \quad (2.11)$$

На даний розподіл не робить впливу конкретний вид розподілу некорельованого фону $w(x)$.

Закон розподілу $w(R)$ вирішальної статистики R при фактичній відсутності в Y яскравісного перепаду не залежить від розподілу фону $w(x)$.

Отже, від $w(x)$ не залежить і ймовірність помилкового виявлення локальних контурних ознак, яким відповідає верхня умова у процедурі $R \geq R_0$.

Для практичного застосування особливо важливо, що і вибір порогу рангової процедури R_0 , який підпорядковують вимозі отримання бажаної величини ймовірності помилкового виявлення, також не пов'язаний із розподілом фону $w(x)$.

Таким чином, застосування рангового алгоритму автоматично стабілізує ймовірність помилкового виявлення, роблячи її незалежною від виду та параметрів закону розподілу фону. Ця властивість досягається тільки за умови, що всі випадкові величини, що утворюють вибірки X та Y , незалежні. В іншому випадку в закон розподілу $w(R)$ будуть входити параметри, що описують залежність елементів.

При наявності об'єкта A елементи вектора Y статистично перевищують елементи X , тому закон розподілу рангу $w(R_i)$ перестає бути рівномірним: ймовірності великих значень R_i збільшуються за рахунок зменшення ймовірностей малих значень. Ця тенденція проявляється тим сильніше, чим більша величина яскравісного перепаду.

Декореляції фону

На зображенні ділянки лісу з просікою яскравості пікселів фону залежні статистично, це типово для багатьох зображень випадкового фону.

Тому для коректного використання рангового алгоритму необхідно перетворити зображення. Будемо вважати, що яскравості пікселів фону на рисунку 2.2 підкоряються нормальному закону розподілу, для якого незалежність і некорельованість елементів зображення еквівалентні один одному, тому перетворення зображення зводиться до декореляції фону.

Нехай фон є однорідним та ізотропним випадковим полем, у якого статистичні характеристики однакові по рядках і стовпцях.

Як модель фону (крона дерев) використовуємо чотириточкову модель:

$$f(i, j) = \alpha [f(i-1, j) + f(i, j-1) + f(i+1, j) + f(i, j+1)] + z(i, j), \quad (2.12)$$

де i та j – номери рядків і стовпців;

α – параметр, що характеризує ступінь впливу сусідніх відліків на даний відлік поля $f(i, j)$;

$z(i, j)$ – випадкове поле з нормальним законом розподілу та некорельованими відрахунками.

Для декореляції фону використовуємо таку процедуру [11]:

$$g(i, j) = f(i, j) - \alpha [f(i-1, j) + f(i, j-1) + f(i+1, j) + f(i, j+1)] = z(i, j), \quad (2.13)$$

$$\begin{vmatrix} 0 & -\alpha & 0 \\ -\alpha & 1 & -\alpha \\ 0 & -\alpha & 0 \end{vmatrix}.$$

Декореляція здійснюється шляхом обробки зображення ковзаючим вікном та враховує конфігурацію сусідніх підрахунків.

Результат цієї обробки при відсутності локальних контурних ознак збігається з породжуючим процесом $z(i, j)$, який за властивостями своєї кореляційної функції близький до білого шуму. Для того, щоб при виявленні локальних контурних ознак використовувати незалежну вибірку, її відліки слід розташовувати так, щоб їх взаємна кореляція дорівнювала нулю.

Вид сигналу, що пройшов через процедуру декореляції, залежить від значень параметра α , тому зупинимося на їх визначенні. Прийнемо умову однаковості характеристик зображення по рядках і стовпцях. Параметр α бере участь у процедурі декореляції, тому його вибір необхідно підпорядкувати мінімізації помилок декореляції [12].

$$\langle [g(i, j) - z(i, j)]^2 \rangle, \quad (2.14)$$

враховуючи, що

$$\langle z(i, j) \rangle = 0, \quad \langle [z(i, j)]^2 \rangle = \sigma_z^2, \quad \langle [f(i, j) - \langle f(i, j) \rangle]^2 \rangle = \sigma_f^2,$$

причому коефіцієнт кореляції між сусідніми відліками дорівнює (2.15).