
Obrazová klasifikácia 2

Pokročilé metódy klasifikácie

Lekcia 5



Obsah lekcie

1. Tvrdá a mäkká klasifikácia
 2. Bayesiánska pravdepodobnostná klasifikácia
 3. Rozhodovacie stromy
 4. Umelé neurónové siete
-

Delenie klasifikácie

Podľa spôsobu priradovania príslušnosti pixlov/objektov do tried:

1. **tvrdá klasifikácia** – hard classification
2. **mäkká klasifikácia** – soft classification



Delenie klasifikácie

1. **„tvrdé“ klasifikátory** – vyjadrujú príslušnosť pixlov do tried binárnym spôsobom
(1 – úplná príslušnosť, 0 – žiadna príslušnosť)
 2. **„mäkké“ klasifikátory** – vyjadrujú neurčitost' príslušnosti pixla do určitej triedy
 - Bayesiánska klasifikácia* - pravdepodobnosť (probability)
 - Dempster-Shaferova teória* - dôvera (belief)
 - fuzzy klasifikácia* - fuzzy príslušnosť (membership)
 - lineárne zmiešavacie modely* - frakcie (fractions)
-

Neurčitost' v údajoch DPZ


Zdroje neurčitosti v údajoch DPZ:

- limitované geometrické rozlíšenie - zmiešané pixle
 - limitované spektrálne a rádiometrické rozlíšenie
 - kompresia obrazu - stratová/bezstratová
 - vágnosť (neurčitost') v koncepcii klasifikácie tried krajinnej pokrývky
 - mäkké prechody medzi areálmi s rôznou krajinnou pokrývkou v prírode (prechodné pásma)
-

Problém zmiešaných pixlov

Okamžitý obrazový uhol snímača (IFOV – Instantaneous Field Of View)

- snímač sníma energiu odrazenú z daného kruhového výseku zemského povrchu
- priemer kruhu vypočítame ako $D = H' \cdot \beta$, pričom H' je výška letu a β je IFOV (v rad)
- sub-pixlová klasifikácia - napr. lineárne zmiešavacie modely (Linear Mixing Models)



Bayesiánska klasifikácia

- založená na Baeysiánskej inferencii, ktorá využíva **Bayesov teorém (Bayesovo pravidlo)**
 - Bayesov teorém vyjadruje tzv. posteriori pravdepodobnosť ako dôsledok dvoch predpokladov:
 - a priori pravdepodobnosť,
 - pravdepodobnostná funkcia odvodená zo štatistického modelu pozorovaných údajov
-

Bayesiánska klasifikácia

- Bayesov teorém:

$$P(H|E) = \frac{P(E|H) \cdot P(H)}{P(E)}$$

- $P(H|E)$ - posteriori pravdepodobnosť - pravdepodobnosť hypotézy H danej dôkazom E (evidence), ktorý zodpovedá porozovaným dátam
- $P(H)$ - a priori pravdepodobnosť - odhad pravdepodobnosti hypotézy H bez ohľadu na dôkaz
- $P(E|H)$ - pravdepodobnosť nájdenia dôkazu, že daná hypotéza je pravdivá - počíta sa z variančno-kovariančnej matice na základe trénovacích množín
- $P(E)$ - okrajová pravdepodobnosť - rovnaká pre všetky hypotézy

Bayesiánska klasifikácia

- Bayesiánska klasifikácia:

$$P(H|E) = \frac{P(E|H) \cdot P(H)}{\sum_{i=1}^n P(E|H_i) \cdot P(H_i)}$$

- pravdepodobnosť sa normalizuje sumou hypotéz pre všetky triedy (n - počet tried)
 - a priori pravdepodobnosť zadáva užívateľ
 - Bayesiánsky klasifikátor predpokladá kompletne definície tried, nepripúšťa neznalosť (neklasifikované pixle)
-

Neurčitost' klasifikácie

- **neurčitost' klasifikácie (classification uncertainty)** – stupeň, s ktorým žiadna trieda nemá prevahu nad inými triedami vzhľadom na príslušnosť pixla p

$$CU = 1 - \frac{p_{max} - \frac{\sum_{i=1}^n p_i}{n}}{1 - \frac{1}{n}}$$

- rovnaký princíp ako meranie entropie v informačnej teórii
-

Neurčitost' klasifikácie

(0.0 0.0 0.0)	Classification Uncertainty = 1.00
(0.0 0.0 0.1)	Classification Uncertainty = 0.90
(0.1 0.1 0.1)	Classification Uncertainty = 1.00
(0.3 0.3 0.3)	Classification Uncertainty = 1.00
(0.6 0.3 0.0)	Classification Uncertainty = 0.55
(0.6 0.3 0.1)	Classification Uncertainty = 0.60
(0.9 0.1 0.0)	Classification Uncertainty = 0.15
(0.9 0.05 0.05)	Classification Uncertainty = 0.15
(1.0 0.0 0.0)	Classification Uncertainty = 0.00

Výhody a nevýhody

Výhody mäkkých klasifikátorov:

- lepšie vystihujú podmienky reálneho sveta


Nevýhody mäkkých klasifikátorov:

- väčšina GIS aplikácií nevie ich výstupy spracovávať, preto sa často musia previesť na tvrdo klasifikované (napr. na základe najvyššieho stupňa príslušnosti) - strata informácií
-

Rozhodovacie stromy

Rozhodovacie stromy (Decision Trees)

- skladajú sa z koreňového uzla (root), medziuzlov (internode) a listových uzlov (leaf)
- koreňový uzol a medziuzly sú rozhodovacie (vyhodnocuje sa otázka alebo test)
- uzly sú spojené vetvami




Rozhodovacie stromy

Klasifikačné stromy (Classification Trees)

- predpovedanie kategorických premenných

Regresné stromy (Regression Trees)


- predpovedanie spojitých premenných



Rozhodovacie stromy

Classification and Regression Trees (CART)


- klasifikácia údajov DPZ (spojité premenné) do tried (kategorické premenné)



Umelé neurónové siete


Artificial Neural Networks (ANN)

- od 80-tych rokov - odozva na modely biologických neurónových sietí
- umelé systémy schopné sofistikovaných operácií, aké prebiehajú v ľudskom mozgu
- samoadaptácia, samoorganizácia, tolerancia voči poruchám
- husté prepojenie jednoduchých elementov
- neparametrické klasifikátory



Umelé neurónové siete

- typická ANN obsahuje:
 1. vstupnú vrstvu (input layer)
 2. výstupnú vrstvu (output layer)
 3. jednu alebo viac skrytých vrstiev (hidden layer)
- každá vrstva obsahuje uzly (neuróny),
pospájané spojeniami s nerovnakou váhou
(váhová matica)
- váhy sa v procese trénovania (učenia) siete
menia



Umelé neurónové siete

- klasifikácia údajov DPZ:
 - vstupné neuróny - multispektrálne pásma
 - výstupné neuróny - cieľové klasifikačné triedy
 - aktivačná funkcia - konvertuje vážené vstupy na výstupy
 - delenie ANN podľa šírenia signálov:
 - **priamoväzbové (feedforward) ANN** - orientovaný necyklický graf, šírenie signálov len jedným smerom
 - **rekurentné (recurrent) ANN** - orientovaný cyklický graf, šírenie signálov dvomi smermi (dopredu aj späť)
-


Umelé neurónové siete

- typy učenia:
 - **kontrolované učenie (supervised learning)**
 - **nekontrolované učenie (unsupervised learning)**
 - **spätnoväzobné (reinforcement learning)**
 - cieľom učenia je minimalizácia chýb (obyčajne RMSE)
 - kontrolované učenie - časť pixlov trénovacích množín sa použije na trénovanie a časť na výpočet chýb
-

MLP

Multi-Layer Perceptron (MLP)


- najčastejšie využívaná v DPZ
- priamoväzbová sieť s kontrolovaním učením pomocou **spätného šírenia chýb (backpropagation)**
- mnohorozmerná nelineárna funkcia



SOM


Self-Organizing Map (SOM) - Kohonenova mapa

- využíva nekontrolované učenie na tvorbu málorozmernej príznakovej mapy (feature map) - diskretná reprezentácia priestoru trénovacích množín so zachovaním topologických vzťahov v tomto priestore
- analógia mapovania kôry ľudského mozgu
- umožňuje 2D (3D) vizualizáciu mnohorozmerných dát



SOM

- **hrubé ladenie (coarse tuning)** - nekontrolovaná klasifikácia
- **jemné ladenie (fine tuning)** - kontrolovaná klasifikácia
- trénovanie a mapovanie (labelling)




Zdroj:
wikipedia

SOM


Feature map

- vysoká variabilita - veľa neurónov (a naopak)



SOM

- nelineárna generalizácia metódy hlavných komponentov (PCA) - jednorozmerná SOM vs. PCA:



Zdroj: wikipedia