

9 Učenie v rozpoznávaní obrazcov

- predpokladáme rozhodovacie pravidlo v tvare $\omega = d(\mathbf{x}, \mathbf{q})$, kde \mathbf{q} vystupuje ako parameter, ktorým je možné zlepšovať kvalitu pravidla, teda minimalizovať chybu klasifikácie pri neseparabilných obrazoch. Pri učení predpokladáme informáciu učiteľa Ω , ktorá obvykle informuje klasifikátor o správnej klasifikácii.
- rozlišujeme tri druhy učenia:
 - a) učenie s učiteľom – o tom budeme ďalej uvažovať
 - b) učenie s nedokonalým učiteľom – informácia Ω nemusí byť vždy správna
 - c) učenie bez učiteľa – vedie na metódy zhlukovej analýzy
- trénovacia množina – množina $\{[\mathbf{x}_1, \Omega_1], [\mathbf{x}_2, \Omega_2], \dots, [\mathbf{x}_K, \Omega_K]\}$, okrem nej sa používa aj testovacia množina na experimentálne overenie správnosti nastavenia klasifikátora



- v činnosti učiaceho sa klasifikátora rozlišujeme dve fázy:
 - a) fáza učenia – v ktorej sa mu predkladajú prvky trénujacej množiny a samočinne nastavuje hodnotu parametra \mathbf{q} tak, aby sa postupne blížila k optimálnej hodnote \mathbf{q}^* . Skúsenosť sa ukladá v parametri \mathbf{q} .
 - b) fáza klasifikácie – v tej sa neposkytuje informácia učiteľa
- význam apriórnej informácie – ak by sme poznali apriórne pravdepodobnosti pri štatistickom rozpoznávaní – obvykle ich v tomto rozsahu nepoznáme, ale vieme napr., že obrazy majú normálne rozdelenie apod. Do apriórnej informácie zaraďujeme aj informáciu o separabilite. Trénovacia množina nepatrí do apriórnej znalosti.
- matematická formulácia učenia klasifikátora: ak informácia Ω poskytuje informáciu o triede, do ktorej sa má zaradiť neznámy obraz, potom stratu pre obraz \mathbf{x} vyjadríme funkciou Q argumentu $\Omega - \omega$, t.j.

$$Q(\Omega - \omega) = Q(\omega - d(\mathbf{x}, \mathbf{q})),$$

pričom často sa volí funkcia Q ako norma vektora.

- Učiace klasifikátory musia byť nastavené so zreteľom na všetky možné obrazy, preto pracujú s integrálnymi kritériami *strednej straty* v tvare

$$J(\mathbf{q}) = \int_{\mathbf{x} \in \Omega_1} Q(\Omega - \omega) dF(\mathbf{x}, \Omega),$$

čo sa vzhľadom na že $Q(\Omega - \omega)$ závisí od Ω a cez rozhodovacie pravidlo aj od \mathbf{x} a \mathbf{q} , tak sa dá písať tento integrál ako

$$J(\mathbf{q}) = \int_{\mathbf{x} \in O_I} Q(\Omega, \mathbf{x}, \mathbf{q}) dF(\mathbf{x}, \Omega),$$

kde O_I je množina všetkých informácií Ω o triede, t.j. $O_I = \{\omega_1, \dots, \omega_R\}$ a $F(\mathbf{x}, \Omega)$ je distribučná funkcia združeného rozloženia náhodných veličín \mathbf{x} a Ω .

- Pretože pri konečnom počte R tried je rozloženie veličiny Ω na O_I popísané frekvenčnou funkciou, môžeme strednú stratu upraviť na tvar

$$J(\mathbf{q}) = \sum_{r=1}^R P(\omega_r) \int_{\mathbf{x} \in O_I} Q(\mathbf{x}, \omega_r, \mathbf{q}) dF(\mathbf{x}|\omega_r) =$$

$$\sum_{r=1}^R P(\omega_r) \int_{\mathbf{x} \in O_I} Q(\mathbf{x}, \omega_r, \mathbf{q}) p(\mathbf{x}|\omega_r) d\mathbf{x},$$

čo interpretujeme tak, že v danej úlohe sa obrazy \mathbf{x} a informácie $\Omega \in O_I$, t.j. triedy nevyskytujú rovnako často a preto pri výpočte strednej straty treba rešpektovať pravdepodobnosť ich výskytu.

- cieľom učenia je minimalizovať strednú stratu, t.j. nájsť taký parameter \mathbf{q}^* , pri ktorom stredná chyba nadobúda minimum. Ak $Q(\Omega, \mathbf{x}, \mathbf{q})$ zvolíme ako konvexnú funkciu, potom aj $J(\mathbf{q})$ je konvexná a nutnou a postačujúcou podmienkou na existenciu minima bude

$$\text{grad}_{\mathbf{q}} J(\mathbf{q}^*) = 0.$$
- Takáto algebrická rovnica sa rieši buď analyticky alebo rekurentne. Analyticky je možné riešiť len veľmi jednoduché prípady. Ale obvykle dopredu nepoznáme distribučnú funkciu $F(\mathbf{x}, \Omega)$ a preto nemožno rovnicu bezprostredne riešiť.
- Z toho dôvodu ťažisko jednej skupiny metód učenia spočíva v odhadovaní podmienených hustôt pravdepodobností a apriórnych pravdepodobností na základe informácie z tréningovej množiny.
- Rekurentné riešenie vyžaduje prechod k novej hodnote \mathbf{q} , ktorá sa približuje optimálnej hodnote \mathbf{q}^* . Vo všeobecnosti je možné použiť gradientné metódy, ale opäť narazíme na problém, že nepoznáme $F(\mathbf{x}, \Omega)$. Riešením býva stochastická aproximácia, ktorá nie je viazaná na znalosť distribučnej funkcie, tieto metódy učenia sú potom založené na priamej minimalizácii strát.
- induktívnosť a sekvenčnosť učenia – induktívnosť – z konečnej tréningovej množiny usudzujeme na nekonečnú množinu obrazov – sekvenčnosť – prvky tréningovej množiny sa predkladajú obvykle postupne.


- z konečnej trénovacej množiny nezískame optimálny parameter \mathbf{q}^* , ale parameter $\hat{\mathbf{q}}^*$, ktorý minimalizuje výberovú (empirickú) stratu. Snažíme sa, aby pravdepodobnosť, že rozdiel $J(\mathbf{q}^*)$ a $J(\hat{\mathbf{q}}^*)$ je menší ako epsilon, bola menšia ako $1 - \alpha$.

Metódy učenia založené na odhadovaní hustôt pravdepodobností

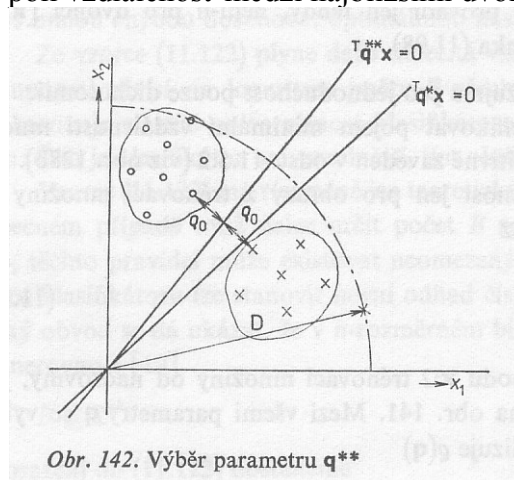
- tieto metódy prevádzajú určenie minima algebrickej rovnice na stanovenie neznámej distribučnej funkcie $F(\mathbf{x}, \Omega)$ z trénovacej množiny.
- ukážeme to na klasifikácii založenej na kritériu minimálnej chyby. Tam potrebujeme určiť neznáme apriórne pravdepodobnosti, ktoré obvykle dopredu nepoznáme. Keďže hustoty pravdepodobnosti $p(\mathbf{x}|\omega_r)$ a $P(\omega_r)$ sú funkcie definované na celom obrazovom priestore, na základe trénovacej množiny určíme ich aproximácie $\hat{p}(\mathbf{x}|\omega_r)$ a $\hat{P}(\omega_r)$.
- požiadavky kladené na odhad hustôt pravdepodobnosti: nestrannosť, konzistentnosť (konverguje k správnej hodnote pri zväčšujúcom sa počte prvkov trénovacej množiny) a efektívnosť.
- dve skupiny odhadu podľa veľkosti apriórnej informácie: s nenulovou apriórnu informáciou a nulovou apriórnu informáciou. Obvykle sa vie, o tvare hustoty rozloženia obrazov triedy ω_r , pričom parameter \mathbf{q} je dopredu neznámy. Najčastejšie sa uvažuje normálne rozdelenie. Metódy s apriórnu informáciou sú podstatne efektívnejšie a vyžadujú aj menšiu trénovaciu množinu.
- Trénovacia množina ako n - rozmerný náhodný výber, ktorý má svoju strednú hodnotu aj smerodajnú odchýlku. Výberový priemer je konzistentným odhadom pre túto strednú hodnotu, pričom výberový priemer sa počíta ako lineárny odhad.
- okrem lineárnych odhadov sa používajú aj ďalšie metódy, založené na pravdepodobnosti.

Metódy učenia založené na priamej minimalizácii strát

- rekurentné riešenie – spočíva v tom, že k optimálnemu parametru \mathbf{q}^* sa dopracujeme postupným vypočítavaním jeho odhadov. Treba určiť funkciu, ako sa zo starého odhadu vypočíta nový odhad. Takýmto rekurentným spôsobom vieme riešiť aj úlohy, ktoré sa analyticky nedajú vyjadriť.
- Príkladom sú gradientné metódy, ktoré tvoria odhady pomocou dotyčníc (derivácií) funkcie, ale prakticky sú pre učenie nepoužiteľné.



- základný tvar algoritmu priamej minimalizácie – použijeme metódu stochastickej aproximácie
- riešenie pre neseperabilné triedy -
- riešenie pre separabilné triedy – Novikoffova veta, že v konečnom počte krokov zostrojíme rozdeľujúce nadroviny – pričom korekcie robíme pri nesprávnej klasifikácii – hľadáme parameter \mathbf{q}^{**} , ktorý je optimálny a zároveň najlepší v tom zmysle, že polí vzdialenosť medzi najbližšími dvoma obrazmi z trénovacej množiny



- dôležitý je výber trénovacej množiny

