

Využití metod strojového učení pro klasifikaci družicových snímků

Autoři: Petr Dobrovolný, Petr Kuba, Luboš Popelínský

Zdrojová data

Zpracovány byly družicové snímky obsahující hodnoty v šesti pásmech z viditelné, blízké a střední infračervené části spektra. Původní velikost pixelu na snímcích je 30 x 30 metrů. Snímky byly klasifikovány do 6 tříd: voda, listnatý a jehličnatý les, zástavba a pole s vegetací a bez vegetace. Byly použity snímky dvou oblastí - snímek Žďáru nad Sázavou s okolím a snímek Brněnské přehrady s okolím.

Cílem je klasifikace všech pixelů snímku, to znamená určení jaký povrch pixely zobrazují. Výsledná informace o klasifikaci se používá k sestavování tematických map - většinou map základních druhů povrchů.

V současné době se pro datové dolování obrazu používají statistické "per-pixel" klasifikátory, které ovšem mají mnohá omezení. Například tzv. parametrické klasifikátory předpokládají při zpracování obrazu apriorní znalost pravděpodobnostního rozdělení souboru klasifikovaných dat, což může být velmi problematické. Tyto metody také neumožňují využití jiných informací než multispektrální obrazová data (např. model terénu). Stále tak přetrvávají některé výhody "klasické" analogové interpretace snímků, která využívá tzv. interpretační znaky jako barva či tón objektu, ale také informace o vzájemné poloze objektů, textuře či struktuře. Toto jsou informace, které je velmi obtížné využít při automatické klasifikaci tradičními klasifikátory.

Z těchto důvodů se testují nové metody klasifikace rastrových snímků, které by překonaly omezení tradičních přístupů. Jednou z možností, která se nabízí pro řešení této úlohy, je využití metod strojového učení. V tomto textu se zaměříme především na jednu z metod strojového učení, rozhodovací stromy, a ukážeme její možnosti při zpracování obrazových dat. Výhodou této metody je to, že výsledný rozhodovací strom je srozumitelný a snadno interpretovatelný, případně i modifikovatelný, stejně jako rozhodovací pravidla, která lze z rozhodovacího stromu generovat. V druhé části textu jsou popsány experimenty s dalšími algoritmy strojového učení.

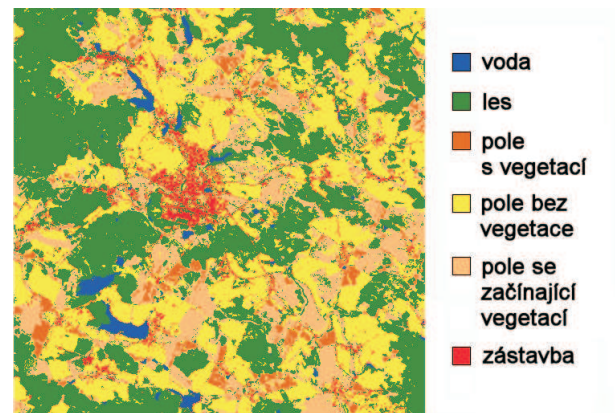
Žďár nad Sázavou

Rozhodovací stromy

Vstupem metody rozhodovacích stromů je tabulka objektů, kde jeden sloupec obsahuje klasifikaci daného řádku do jedné z konečného počtu tříd. Výsledný strom vytvořený na základě učící množiny obsahuje v každém uzlu jeden atribut objektu a větve jsou označeny relačním výrazem obsahujícím tento atribut. V listech je uvedena cílová třída. Při klasifikaci objektu se zpracování v každém uzlu vydá po té větvy, která je pro daný objekt splněna. Po průchodu celým stromem až k listu je objektu přiřazena třída odpovídající tomuto listu.

Klasifikace pomocí rozhodovacích stromů

Satelitní snímek Žďáru nad Sázavou byl klasifikován metodou rozhodovacích stromů pomocí programu C4.5. Pro 8051 pixelů tohoto snímku byl typ povrchu předem určen místním průzkumem terénu a studiemi map. Množina těchto pixelů byla použita pro zjištění přesnosti klasifikace. Tato množina byla rozdělena na učící a testovací množinu. Rozhodovací strom byl vytvořen na základě učící množiny a jeho přesnost poté ověřena na množině testovací. V Tabulce 1 je uvedena přesnost výsledného rozhodovacího stromu v závislosti na velikosti učící množiny. V prvním řádku je navíc přesnost dosažená metodou 10-křížové validace. V dálkovém průzkumu země (DPZ) se pro tento typ úloh standardně používá 10% učících a 90% testovacích dat. Z tabulky je vidět, že i při takto nízkém objemu učících dat je dosažená chyba klasifikace na testovacích datech nízká. Na závěr bylo 8051 pixelů, pro které byla klasifikace známa (tj. 3.1% ze všech dat), použito k vytvoření rozhodovacího stromu, kterým byl klasifikován celý satelitní snímek. Výsledky klasifikace jsou na obrázku.



Učící	Testovací	Chyba
Křížová validace		1.7%
50%	50%	2.1%
10%	90%	3.5%
5%	95%	4.0%
3%	97%	7.0%
1%	99%	13.0%

Tabulka 1

Brněnská přehrada

Testované algoritmy

- c50tree - algoritmus C5.0 se standardním nastavením parametrů
- c50boost - C5.0 s boostingem
- c50rules - pravidla naučená pomocí C5.0
- lindiscr - diskriminace jednotlivých tříd pomocí lineární kombinace atributů
- ltree - rozhodovací strom mající v uzlech lineární kombinace atributů
- mlcib1 - učení z instancí
- mlcnb - naivní bayesovský klasifikátor

Provedené experimenty

Snímek Brněnské přehrady byl použit pro testování algoritmů strojového učení uvedených v tabulce vlevo. Učení probíhalo na výsledcích analogové interpretace družicového snímku a byla použita metoda křížové validace. S každým z těchto algoritmů jsem provedli dva experimenty, jejichž výsledky jsou v Tabulce 2. V prvním experimentu (sloupec central) jsme pro klasifikaci použili pouze hodnoty spektru pro daný pixel. V druhé metodě (sloupec +okolí) jsme učící data rozšířili o hodnoty spektrálních charakteristik sousedních pixelů. Na základě předchozích experimentů bylo nejlepší rozšíření o kříž (severní, jižní, východní a západní pixel). V posledním sloupci tabulky je rozdíl chyb obou experimentů. V Tabulce 3 je srovnání výsledků metody rozhodovacích stromů s dalšími metodami používanými v DPZ. Uvedené přesnosti klasifikaci byly dosaženy na učících datech. Celková přesnost klasifikace rozhodovacími stromy je tedy srovnatelná s nejčastěji používaným klasifikátorem maximální věrohodnosti a lepší než přesnost dosažená ostatními klasickými klasifikátory.

Algoritmus	central	+okolí	Δ
c50tree	9.15%	8.70%	0.45%
c50boost	8.74%	5.76%	2.98%
c50rules	9.09%	7.81%	1.28%
lindiscr	9.59%	7.69%	1.90%
ltree	8.74%	7.05%	1.69%
mlcib1	11.21%	5.36%	5.85%
mlcnb	12.31%	11.05%	1.26%

Tabulka 2

Metoda	Počet příkladů	Chyba
Minimum distance	410	3.9%
Maximum Likelihood	410	1.2%
Parallelepiped	410	22.7%
Decision Tree	410	2.2%

Tabulka 3