

SROVNÁNÍ VYBRANÝCH METOD DIGITÁLNÍ KLASIFIKACE DŘEVINNÉ SKLADBY Z LETECKÝCH SNÍMKŮ

M. Gabzdyl

Došlo: 26. října 2007

Abstract

GABZDYL, M.: *Comparison of the tree species select classification methods from aerial photo*. Acta univ. agric. et silvic. Mendel. Brun., 2008, LVI, No. 5, pp. 279–292

This article describes a comparison of various programs for the automatic supervised classification used for identification of forest tree species representation from the aerial photographs. These programs were represented by American software Erdas Imagine 8.4, Czech products LuciaG 4.0 and TopoL DMT 6.014. The study displays a minor production forest area with proportion of four most frequently occurring tree species – spruce, larch, oak and ash in the research area of the forest region around Bystřice pod Hostýnem, the Czech Republic. For the reason of lower quality of spectrozonal photographs it was necessary to use some corrections; such as highlighting pen techniques, namely Kernel Processor Low-Frequency and High-Frequency filters, belonging to space operations. Photographs, modified in this way, served for a construction of individual training sets, which were consequently used within individual classification methods of directed classification in each comparative software. Self-classification took place at the level of a particular tree species. Classification accuracy was determined by comparison of results and reference data from the terrain research.

The outcome is, that the best classification for oak and ash was in combination with TopoL program, classification according to gravity centre and combination of solation + insolation signature of the treetop parts with an aggressive shade.

On the contrary, for spruce and larch was the best classification in combination with software Erdas Imagine, classification roles of intervals mahalanobis with combination of solation signature of the treetop parts, along these tree edges with an aggressive shade.

aerial photo, supervised classification, species composition, spruce, larch, oak, ash, Erdas, TopoL, LuciaG, geographical information system (GIS), forest management

Interpretace obrazových dat dálkového průzkumu země slouží již desítky let jako cenný pomocný nástroj v hospodářské úpravě lesa. Využití zahrnuje zejména lesní inventarizace, tematické mapování, zjišťování stromových a porostních charakteristik, zdravotního stavu atd. Ale i přes tento značný význam není stále tato metoda plnohodnotná náhrada využitelná při tvorbě lesního hospodářského plánu, vzhledem k vysoké heterogenitě vlastních dat, tzn. leteckých snímků, což může být i do budoucna problematické.

Tato práce sice ještě popisuje tradiční metodu klasifikace založenou pouze na analýze jednotlivých pixelů, které ignorují prostorové vztahy a texturu, přesto však je zajímavá možnost srovnání jednotlivých softwarů, jejich příslušných klasifikačních me-

tod, potažmo vliv velikosti výběru trénovacích ploch pro jednotlivé koruny příslušných dřevin.

V městské části Hyytiälä v jižním Finsku bylo z digitálních leteckých snímků určováno prostorové rozšíření dřevin z digitálních leteckých snímků. Tato studie zkoumá možnosti interpretace při použití digitálního leteckého snímku v určujícím prostorovém rozšíření dřevin ve třech mapovaných porostech (osm zkušných ploch). Používaný letecký snímek byl snímán v červnu 1995 v měřítku 1:5000. Pro určení prostorového modelu ze stromů byly použity dva přístupy. První přístup byl založený na bodovém postupu; jednotlivé stromy v digitálním leteckém snímku byly členěny pomocí silné metody segmentace, založené na poznání modelu koruny

stromu se sub-pixelovou přesností. Druhý přístup spočívá v tom, že pokrytí koruny bylo určeno z regionální rostoucí segmentace složené z prezentace aktivního povrchu (UUTTERA et al., 1998).

Další studií byla předpověď množství zvýšeného přírůstu smrku černého (*Picea mariana* P. (Mill)) v severovýchodním Ontariu z leteckého snímku. V severovýchodním Ontariu, Kanada byly pro každý porost smrku černého vytvořeny černobílé letecké snímky v měřítku 1:20 000. Každý porost byl popsán podle šedého tónu snímku, porostního modelu, velikosti uzavřeného zápoje, velikosti otevřeného zápoje, velikosti a čísla přímočarých odvodňovacích cest, postavení na svahu, svahové komplexnosti, stupně (svahové procento), složení druhů. Porosty tedy byly seskupeny do tří tříd založených na množství zvýšeného šedého tónů snímku. Následně byl klíč stupně šedi ověřován a bylo dosaženo správné identifikace třídy zakmenění pro 78 % porostů (ARNUP, 1996).

V práci „Dvoufázový vzor design zaměstnávající letecké fotografie velkého měřítka“ byla použita pro určení stromů a bylinné struktury společenstva metoda, která nabídla významné zvýšení odhadu přesnosti (>35%) nad samotným pozemním vzorkováním, právě tak jako atraktivní snížení nákladů na vyhodnocení (0 do 40%) (PITT et al., 1996).

Další metodou pro zjišťování typů lesa pomocí leteckých snímků byla v Číně použita „Shannon's information formula“ s doloženou přesností více jak 90% (ZHOU, 1986).

Použití geografického informačního systému (GIS) v hospodářské úpravě lesa při aplikaci oblastní inventarizace lesa v Belgii bylo ověřeno na 200 km² plochy lesa, která zahrnovala různé lesní typy. Mapa byla vytvořena použitím barevných infračervených leteckých snímků v měřítku 1:25 000 a GIS data byla zpracována s použitím softwaru ILWIS Chybovost interpretace druhů dřeviny nebo hospodářských typů porostu byla <6% (LEJEUNE et al., 1993).

V Německu v lesích v Ostholstein byly letecké snímky srovnány s venkovními daty. Hlavní druh dřeviny byl rozpoznán správně v 83% porostů, správný věk a hustota porostu byly určeny v 60% porostů (SCHNOKLAKE a AKCA, 1998). V podobné studii, ale o mnoho let dříve, byla v porostech při zjišťování druhu dřeviny z leteckých snímků zaznamenaná obdobná přesnost ve výši 88% úspěšnosti (SPELLMANN, 1987).

Ve Finsku byla pro smrk ztepilý (*Picea abies* L. (Karst.)) a borovice lesní (*Pinus sylvestris* L.) přesnost digitálních leteckých snímků při hodnocení lesního stanoviště na úrovni ploch v rozmezí 57,7–85% (HOLPAINEN a WANG-GUANGXING, 1998).

Z dosavadního literárního přehledu vyplývá, že při zjišťování druhové skladby dřevin z leteckých snímků byla zaznamenána poměrně vysoká přesnost.

Vzhledem ke skutečnosti, že v současné době odborná literatura neobsahuje několik programů a jejich klasifikačních technik, může být takový pohled na uvedenou problematiku přínosem. V dostupných studiích se můžeme setkat s různými přístupy ke kla-

sifikaci leteckých snímků, ať už pro zjišťování druhové skladby dřevin, či pro další stromové charakteristiky.

MATERIÁL A METODY

Materiál a terénní šetření (Site and field data collection)

Letecké snímky zachycovaly katastrální území Mr. línek, Sovadina, Rychlov v okrese Bystřice pod Hostýnem, Česká republika.

Ke zpracování předložené studie sloužily spektrozónální (infračervené) letecké snímky v měřítku 1:10 500, které byly pořízeny 28. 9. 1999 ve 12.15–12.20 hod firmou Argus Geo system, s. r. o. kamerou LMK 2015 s filtrem 490 nm na materiál Kodak 2443. Snímky byly předány k analýze 5. 11. 1999.

K získání digitální formy vstupů byly spektrozónální snímky naskanovány skanerem PHOTOSCAN TD INTERGRAPH v rozlišení 900 dpi.

Snímek byl pak použit jako základ pro zhotovení snímku ortofoto překresleného (formát Topol, velikost pixelu 0,3 m, bez úprav charakteristik obrazu). Byl vytvořen na základě DMT (digitální model terénu) pomocí vrstevnicového plánu (diference vrstevnic 10 m), bez zaměřování vlčivacích (identických) bodů v terénu. Tento plošně vyrovnaný ortofotosnímek sloužil jako základní vstupní materiál pro veškeré další vyhodnocování dat s využitím SW TopoL DMT v. 6.008, LUCIA G v. 4.00. a Erdas Imagine 8.4. Střední polohová chyba snímku dosahuje 1,4 × 1,4 m.

V letních měsících r. 1999 byly na analyzovaném majetku vylišený kalibrační plochy (trénovací množiny). Jejich umístění je na obrázku 1. Smyslem tvorby těchto kalibračních ploch je popis objektů následně klasifikovaných v procesu zpracování. K danému účelu byly zvoleny dva základní metodické postupy:


1. V téměř pravidelné síti (Obr. 1) označena zeleně v kroužku) – zvolená výrazná místa, snadno identifikovatelná v terénu (sedm ploch).
2. V náhodném uspořádání (Obr. 1 – tady označeny modře) zvoleno cca 40 ploch.

V dané oblasti byly zjišťovány klasifikací tyto dřeviny: smrk ztepilý (*Picea abies* L. (Karst.)), modřín (*Larix decidua* Mill.), dub (*Quercus*) a jasan ztepilý (*Fraxinus excelsior*).

Úprava snímku (Imagery preprocessing)

Pro zvýraznění informačních schopností se na leteckých snímcích se používají postupy, při kterých se zvyšuje jejich vypovídací schopnost, čímž se i zlepšuje možnost jejich interpretace.

Vzhledem k potřebě následné klasifikace bylo pro dané letecké snímky zapotřebí jednotlivé koruny stromu rozostřit a naopak zvýraznit jejich hrany pro lepší oddělení jednotlivých korun. Proto byla zvolena metoda prostorového zvýraznění, a to konkrétně filtrace. Metoda je založena na principu pohybujícího se okna, pohyb zvaný „konvulace“, jakéhosi okolí pixelu, pro který se vypočte jeho nová hodnota v závislosti na hodnotách okolních pixelů



1: Rozmístění kalibračních ploch (trénovacích množin) v zájmovém území. Zeleně jsou značeny pravidelné rozmístěné plochy na výrazných bodech, modře náhodně rozmístěné plochy

v okně. V okně se provádí jednoduchý výpočet s malým množstvím dat, aby nedocházelo ke zpomalení výpočtu, a opakováním operace po posunu okénka se mění hodnoty obrazové funkce v celém zvýrazňovaném obrazu. Nejčastěji se používá okolí 3×3 nebo 5×5 a nová hodnota se počítá pro středový pixel.

K tomu byly použity prostředky Kernel Processoru Erdas Imagine, kde byl použit Low-Frequency Kernels a High-Frequency Kernels o rozměrech rotujícího okna 3×3.

Výpočet filtrovaných hodnot se provádí na základě rovnice JENSENA (1996).

Tyto filtry Low-Frequency Kernels (filtr rozostřovací) a High-Frequency Kernels (filtr úpravy hran) umožnily takovou úpravu snímku, že výsledná koruna konkrétního stromu není rozčleněna do mnoha rozdílných tříd, stává se z ní téměř barevně jednotlý povrch. I když tyto filtry nedosahují maximální účinnosti, mohly by být pro praxi dostačující.

Definice tříd (Class definition)

Cílem této první fáze je určení tzv. trénovacích ploch pro každou klasifikovanou třídu, kterou chceme ze snímku získat. Výběr trénovacích ploch předpokládá shromáždění informací z terénního průzkumu. Data pro trénování musí být především komplexní a reprezentativní.

V této práci se při tvorbě trénovacích ploch vycházelo ze zásad jedinečnosti daných pixelů. Trénovací plochy byly vybrány pro čtyři základní dřeviny (smrk, modřín, jasan, dub) nejčastěji se vyskytující na zkoumaném území. Byly vybrány snímky JS_4 (DB_22-označení snímku), SM_3 (MD_37), JS_6 (JS_18), a SM_2 (SM_25) (Tab. I).

Pro trénovací množiny byly vybrány ty dřeviny, které byly zjištěny šetřením přímo v terénu.

Vzhledem k míře určité subjektivity, která souvisí s výběrem trénovacích množin, byly vybrány možné

I: Základní charakteristiky zkusných ploch, (*) – údaj dle platného LHP

Označení plochy	JS_4	SM_3	JS_6	SM_2
Porostní skupina	1E10/8x	2D11	2A7y/1	2A6
Převládající dřevina	DB	MD	JS	SM
Věk (*)	78	106	69	
LT (*)	3D9	3O7	3D5	
Zakmenění	10	8	10	10

kombinace signatur, to znamená vytvořené charakteristiky popisující jednotlivé kategorie objektů (TUČEK, 1998). U korun stromu od nejsvětlejších částí korun (osluněná část, špička) přes tmavší část (zastíněná) až po celé koruny s mezikorunními prostory. Obdobným způsobem bylo přistoupeno i k výběru signatur pro stín. Od nejtmavšího definovaného jako stín, až po světlejší části stínu, který se vyskytuje převážně na hranici s okraji korun. Těmto stínům byl přiřazen termín stín agresivní (Obr. 2).


Při následné řízené klasifikaci byly pro nalezení vhodné kombinace trénovacích množin vytvářeny jednotlivé kombinace mezi signaturami vlastních korun jednotlivých dřevin a signaturami jednotlivých typů stínů.

Jednotlivé signatury dle dřevin:


JS_18 + DB_22

1. osluněná část koruny – světle zbarvený pixel
2. neosluněná část koruny – tmavě zbarvený pixel
3. mezikorunní prostory – tmavě šedý pixel
4. okraje korun


1.




stín



5.



stín agresivní



7.



2: Tvorba trénovacích množin pro dřevinu smrk


5. kombinace signatur 1 + 2
6. kombinace signatur 1 + 2 + 3
7. kombinace signatur 1 + 2 + 3 + 4

MD_37 + SM_25

1. osluněná část koruny + vrchol – světle zbarvený pixel
2. neosluněná část koruny – tmavě zbarvený pixel
3. (nevstupuje do signatury)

1stin

= osluněná část koruny + vrchol + stín




4. okraje korun

5. kombinace signatur 1 + 2
6. (nevstupuje do signatury)
7. kombinace signatur 1 + 2 + 4

Pozn. červená tučná čísla – vlastní signatury vstupující do klasifikace
černá čísla – signatury vstupující do jiné signatury


5stinag

= kombinace signatur 1 + 2 + stín agresivní




1stinag

= osluněná část koruny + vrchol + stín agresivní




7stin

kombinace signatur 1 + 2 + 4 + stín




5stin

= kombinace signatur 1 + 2 + stín



7stinag

kombinace signatur 1 + 2 + 4 + stín agres.



3: Histogramy pro dřevinu smrk dle kombinací trénovacích množin

Následně byly jednotlivé trénovací plochy a jejich kombinace okulárně ověřeny v histogramech v programu TopoL. Jako nejvhodnější se jevila kombinace signatur osluněné a neosluněné části korun spolu se stínem. Jednotlivé signatury byly jasně odděleny a zároveň zaujímaly co největší spektrum DN hodnot (Obr. 3).

Klasifikace (Classification)

Pro srovnání softwarů bylo použito řízené klasifikace. V systému Erdas Imagine je řízená klasifikace založena na typu rozhodovacího pravidla. Rozhodovací pravidlo je matematický algoritmus, který na základě příslušných signatur přiřazuje pixely do jednotlivých tříd. Používány jsou dva typy (ERDAS Field Guide 1994):

1. Parametrické – založeno na statistických parametrech (např. průměr, kovarianční matice).
Těmito zástupci jsou:
 - a) Maximum likelihood – metoda maximální pravděpodobnosti
 - b) Minimum distance – metoda minimální vzdálenosti
 - c) Mahalanobis distance – metoda je založena na základě výpočtu rovnice s využitím kovarianční matice.
2. Neparametrické – nejsou založeny na statistice, ale na diskrétních objektech (polygony a pravoúhelníků) v zobrazených prostorových snímcích.
Těmito zástupci jsou:
 - a) Feature space – metoda podobná klasifikaci parallelepiped, ale pixely shlukuje do různých útvarů např. obdélník, elipsa, mnohoúhelník
 - b) Parallelepiped – klasifikátor pravoúhelníku ve vícerozměrném prostoru.

Ve vlastní práci byly použity v Erdas Imagine tyto kombinace rozhodovacích pravidel:

1. parallelepiped, parametric rule, maximum likelihood
2. parallelepiped, parametric rule, mahalanobis distance
3. parallelepiped, parametric rule, minimum distance
4. parallelepiped, classify by order
5. parallelepiped, unclassified.

Obdobná rozhodovací pravidla používá i druhý software TopoL. Zde byla pro klasifikaci použita stejná rozhodovací pravidla jako v Erdas Imagine. Těmito rozhodovacími pravidly jsou:

1. Klasifikace dle k-NN – metoda k-nejbližších sousedů.
2. Klasifikace – hyperkvadry – metoda pravoúhelníků. Shoda s funkcí parallelepiped v Erdas Imagine.
3. Klasifikace dle těžišť – metoda minimální vzdálenosti. Ekvivalent funkce minimum distance v Erdas Imagine.


Třetím srovnávaným programem byla LuciaG. Ta na rozdíl od výše zmíněných programů nepracuje s řízenou klasifikací, ale s metodou prahování, neboli tvorbou binárních obrazů korun dřevin. Zde byl barevný obraz interaktivním způsobem segmentován za vzniku jednobarevného obrazu binárního, tj. na základě údajů získaných při kalibraci (venkovním šetřením) byla označena místa na barevném obrazu o velikosti 1 až n pixelů, která odpovídala daným reálným objektům (v tomto případě obrazům korun, identifikovaným při venkovním šetření). Takto byly vylišeny vybrané druhy dřevin.

Při vlastním procesu řízené klasifikace docházelo ke kombinaci jednotlivých signatur a klasifikačních pravidel pro softwaru Erdas Imagine a TopoL. Takovým postupem se hledala optimální kombinace klasifikačního pravidla a signatury (Obr. 4) Tímto vznikl seznam procentického vyjádření zastoupení jednotlivých klasifikačních tříd, který byl porovnán se zastoupením na ploše v terénu. Následně byla vybrána vždy jedna nejvhodnější kombinace pro klasifikační pravidlo, signatury a software a zde pak bylo měřeno pro jednotlivé dřeviny procentické vyjádření úspěšnosti klasifikace, a to tak, že pro každého jedince bylo získáno procento zaujaté plochy ve třídách: dominantní dřevina, ostatní dřeviny a stín. V systému LuciaG, který pracuje na systému prahování, byl nejprve zvolen subjektivní způsob zjištění RGB hodnot, který se v důsledku lišil od RGB hodnot v Erdas Imagine. Tím samozřejmě bylo procentické vyjádření klasifikovaných tříd odlišné. Bohužel toto odporuje metodice, kdy do všech systému vstupují stejné trénovací množiny, aby byla zachována objektivita. Proto byly následně získány RGB hodnoty jednotlivých signatur z Erdasu a ty byly naprahovány. Výsledkem bylo, že LuciaG vykazovala stejné výsledky procentického vyjádření zastoupení dřevin jako Erdas Imagine při použití klasifikačního pravidla parallelepiped, parametric rule. Proto se dále s vyhodnocením úspěšnosti klasifikace u LuciaG nesetkáme.


Vzhledem k dosažení jednotnosti vyhodnocení klasifikací byl zvolen postup, kdy bylo zjištěno nejprve pro všechny signatury a klasifikační pravidla procentické zastoupení za celou zkusnou plochu a následně byly vybrány ty zkusné plochy, které odpovídaly zastoupení dřevin zjištěných na ploše v terénu. S vybranými plochami se dále pracovalo způsobem, kdy pro každý strom bylo určeno procentické zařazení do tří signatur (dominantní dřevina, ostatní dřevina, stín). Ty se získaly poměrem mezi počtem pixelů každé ze tří signatur a velikosti masky celé koruny jednotlivých dřevin.

Pro zjišťování úspěšnosti přesnosti klasifikace byla naměřená data srovnána s referenčními daty naměřenými v terénu a určena pro každou dřevinu správná kombinace signatury, klasifikačního pravidla a softwaru, která se nejvíce blíží procentickému zastoupení dřevin přímo na zkusné ploše. Proto byl pro statistické vyhodnocení vybrán párový T-test (MS Excel 2000). Za doplňující statistický test byl vybrán korelační koeficient (MS Excel 2000).


SM




stin



ost.



stin agresivní



4: Výsledná klasifikace pro dřevinu smrk dle kombinací trénovacích množin

VÝSLEDKY A DISKUSE


Pro dřevinu jasan bylo v softwaru Erdas Imagine jako nejlepší klasifikační pravidlo vyhodnocena minimální vzdálenosti. V oblasti trénovacích množin to byla kombinace signatur osluněné části koruny a neosluněné části včetně mezikorunních prostorů a agresivního stínu ($F = 0,77$; $p < 0,01$) (Obr. 5). V programu TopoL byla jako nejúspěšnější klasifikace vyhodnocena klasifikace dle těžišť ($F = 0,98$; $p < 0,01$) (Obr. 5), ať už pro signaturu stín nebo stín agresivní, která dopadla nejlépe. Jako signatury byly vyhodnoceny stejné signatury, jako u Erdas Imagine. Celkově nejlepší klasifikace pro jasan bez ohledu na klasifikační pravidlo a signatury byl vyhodnocen TopoL, klasifikace dle těžišť, signatury koruny osluněné + neosluněné + mezikorunní prostory a stín agresivní. Index korelace tento výsledek jen potvrdil (Obr. 6).

U dřeviny dubu lze v programu Erdas jako nejlepší pravidlo klasifikace považovat taktéž minimální vzdálenosti ($F = 0,71$; $p < 0,01$) (Obr. 7). Trénovací množiny obsahovaly tyto signatury: osluněná a neosluněná část koruny spolu s okraji koruny a se stínem agresivním. Naopak TopoL se zachoval stejně jako v případě ja-


sanu, kde nejlepší klasifikace bylo dosaženo klasifikací dle těžišť se signaturami osluněná + neosluněná část koruny a mezikorunní prostory se stínem agresivním ($F = 0,93$; $p < 0,01$) (Obr. 7). Taktéž tato kombinace bez ohledu na testovací program, druh klasifikace a typ trénovací množiny byla nejúspěšnější. U korelačního koeficientu pro Erdas byly zaznamenány stejné úspěšnosti. Jen pro TopoL byla za nejúspěšnější klasifikací bez ohledu na její typ považována signatura stejná jako pro Erdas. To znamená kombinace osluněné části koruny spolu s částí neosluněnou a se stínem agresivním ($K = 0,57$; $\alpha = 0,01$) (Obr. 8).

Z toho všeho vyplývá, že pro uvedené listnáče měla nejlepší výsledky klasifikace v kombinaci: program TopoL s klasifikací dle těžišť a kombinací signatury osluněné + neosluněné části korun se stínem agresivním.


Dřevina modřín byla v programu Erdas Imagine nejlépe určena při použití klasifikace minimální vzdálenosti s kombinací signatur osluněná a neosluněná část korun spolu s okraji koruny a se stínem agresivním ($F = 0,28$; $p < 0,01$) (Obr. 9). Tato kombinace signatur byla nejlepší také pro software TopoL, ale




5: Výsledky T-testu pro software, trénovací množiny, klasifikační pravidla a dřevinu JS




6: Výsledky korelace pro software, trénovací množiny, klasifikační pravidla a dřev. JS




7: Výsledky T-testu pro software, trénovací množiny, klasifikační pravidla a dřev. DB




8: Výsledky korelace pro software, trénovací množiny, klasifikační pravidla a dřev. DB




9: Výsledky T-testu pro software, trénovací množiny, klasifikační pravidla a dřev. SM



10: Výsledky korelace pro software, trénovací množiny, klasifikační pravidla a dřev. SM



11: Výsledky T-testu pro software, trénovací množiny, klasifikační pravidla a dřev. MD



12: Výsledky korelace pro software, trénovací množiny, klasifikační pravidla a dřev. MD

na rozdíl od listnáčů se zde jako nejlepší klasifikační pravidlo projevila klasifikace dle k-NN ($F = 0,02$; $p < 0,01$) (Obr. 9). Index korelace, jako doplňující statistický test, tento výsledek jen potvrdil (Obr. 10).

Jako nejlepší trénovací množiny pro smrk byly u Erdas Imagine potvrzeny stejné kombinace jako u modřínu, ale tentokrát byl nejlepším klasifikačním typem vzdálenost mahalanobis ($F = 0,98$; $p < 0,01$) (Obr. 11). Úspěšnost v TopoLu byla stejná jako u modřínu ($F = 0,47$; $p < 0,01$) (Obr. 11). Korelační koeficient vyšel nejlépe pro program Erdas v klasifikaci classify by order ($K = 0,81$; $\alpha = 0,01$) a pro TopoL v kombinaci osluněné spolu s neosluněnou částí korun i s okraji se stínem s klasifikací dle těžišť ($K = 0,41$; $\alpha = 0,01$) (Obr. 12).

Pro jehličnany byla jako nejlepší klasifikace vyhodnocena kombinace softwaru Erdas Imagine s klasifikačním pravidlem vzdálenosti mahalanobis s kombinací signatur osluněná část koruny včetně jeho vrcholu s neosluněnou částí spolu s okraji těchto korun s agresivním stínem.

Vzhledem ke skutečnosti, že „digital numer“ hodnoty listnáčů a jehličnanů jsou různé, nehledě na jiný výběr trénovacích množin, nelze pro listnáče a jehličnany vyhodnotit univerzální metodu klasifikace spolu s programem a příslušnou kombinací signatur.

Předcházející studie z literární rešerše ukázaly (ZHOU, 1986; LEJEUNE et al., 1993), že úspěšnost bodové klasifikace přesahuje padesát procent. Získané výsledky to dokládají bez rozdílu softwaru, klasifikačních pravidel, či druhu dřeviny. Přesto je již v dnešní době znát trend odklonu od klasifikace na úrovni jednotlivých bodů, které ignorují texturu a prostorové vztahy v obraze, ke klasifikaci objektové (HÁJEK, 2006), tzn. přiřazování bodů na základě vztahů (spektrální, geometrické, texturální a kontextuální) s okolními body. I tak dosažené výsledky mají svojí váhu a s určitou přesností je to i v dnešní době nadále schůdná cesta při použití těchto softwaru, pro dosažení kvalitních výsledků klasifikace.

SOUHRN

Principy letecké fotogrammetrie a dálkového průzkumu země slouží již po mnoho let jako účinný nástroj hospodářské úpravy lesa. Využití zahrnuje zejména lesní inventarizace, lesní tematické mapování, zjišťování stromových a porostních charakteristik, zdravotního stavu apod. V minulosti byla v praxi uplatněna především vizuální interpretace leteckých snímků, které sloužily k zakreslování základních jednotek rozdělení lesa do hospodářských map. Aplikací postupů geografických informač-

ních systémů lze dále odečítat mnohé atributy, jako např. druhová skladba, střední porostní výška, atd. V České republice se principy lesnického dálkového průzkumu země začaly prosazovat počátkem 80. let u státního Ústavu pro hospodářskou úpravu lesů v Brandýse nad Labem. Později se však od leteckých snímků upustilo, hlavně z důvodů problematického uplatnění v technologii zpracování LHP.

Přes všechny zmíněné výhody však při tvorbě automatické metody stále vyvstává problém s vysokou různorodostí snímků s velmi vysokým rozlišením. Plochy představující jednu tematickou třídu (např. koruna stromu) jsou ve skutečnosti tvořeny skupinou většího počtu pixelů se značným rozsahem hodnot stupňů šedi. Tradiční metody automatické klasifikace (řízené či neřízené) navíc porovnávají pouze digitální hodnoty obsažené v jednotlivých pixelech snímku. Tyto problémy lze v zásadě řešit vyhlazením obrazu pomocí různých filtrů.

Tato práce popisuje srovnání automatické řízené klasifikace při zjišťování zastoupení lesních dřevin z leteckých snímků mezi jednotlivými programy použitými pro klasifikaci. Tyto programy byly zastoupeny americkým softwarem Erdas Imagine 8.4, a českými produkty LuciaG 4.0 a TopoL DMT 6.014. Studie zobrazuje menší oblast hospodářského lesa s podílem čtyř nečastěji se vyskytujících dřevin – smrk, modřín, dub a jasan, na zkoumaném území lesní oblasti v okolí Bystřice pod Hostýnem, Česká republika. Z důvodu méně kvalitně pořízených spektrozónálních snímků bylo nutné před vlastní klasifikací provést jisté korekce v podobě zvýrazňovacích technik, a to Kernel Procesoru filtru Low-Frequency a High-Frequency, které patří mezi prostorové operace. Takto upravené letecké snímky sloužily pro vytvoření jednotlivých trénovacích množin, které byly následně použity v rámci jednotlivých klasifikačních metod řízené klasifikace u jednotlivých srovnávacích softwarů. Vlastní klasifikace probíhala až na úroveň jedinců stromového druhu. Přesnost klasifikace byla stanovena porovnáním výsledků s referenčními údaji z terénních šetření.

Výsledkem je, že pro dřeviny dub a jasan měla nejlepší výsledky klasifikace v kombinaci s programem TopoL s klasifikací dle těžišť a kombinací signatury osluněné + neosluněné části korun se stínem agresivním.

Naopak pro dřeviny smrk a modřín byla jako nejvhodnější klasifikace zjištěna kombinace softwaru Erdas Imagine s klasifikačním pravidlem vzdálenosti mahalanobis s kombinací signatur osluněná část koruny včetně jeho vrcholu s neosluněnou částí spolu s okraji těchto korun s agresivním stínem.

SUMMARY

Principles of aerial photogrammetry and remote sensing serve as an effective instrument for the forest management planning for many years. Its utilization particularly includes forest inventories, forest thematic cartography, tree and stand characteristics survey, health status estimation etc. In the past was mainly used a visual interpretation of the aerial photographs which served for charting of basic

forest units into the management maps. With geographic-information system applications it is possible to read many attributes as species composition, mean stand height etc. Principles of the forest remote sensing started to be promoted at the state Forest management institute in Brandýs nad Labem, Czech Republic in the early 80's. But the usage of aerial photographs was abandoned later, mainly from the reason of the problematic application to processing technology of the forest management planning.

Despite all mentioned advantages, a problem concerning photograph high variability with a very high resolution still persists. Areas, which shape one thematic class (for example a tree crown), are in fact composed of a higher pixel number with a considerable range of grey scale values. Moreover, traditional methods of the automatic classification (controlled or uncontrolled) compare only digital values contained in each pixel of the photograph. These problems can be basically solved with a picture smoothing by the means of different filters.

This study describes a comparison of various programs for the automatic controlled classification used for identification of tree species representation from the aerial photographs. Following programs were selected for the analysis; american software Erdas Imagine 8.4 and czech products LuciaG 4.0 and TopoL DMT 6.014. The study presents a smaller locality of commercial forest with four, most frequently occurring tree species – spruce, larch, oak and ash in the studied forest region nearby Bystřice pod Hostýnem, Czech Republic. Because the spectrozonal photographs were taken in a lower quality it was necessary to perform certain corrections with highlighting techniques such as Kernel Processor Low-Frequency and High-Frequency filters, belonging to space operations. So corrected aerial photographs served for a creation of separate training sets which were consequently analysed with individual classification methods of the controlled classification in each comparative software. Self classification was proceeded up to the level of tree specimen. Classification accuracy was defined by the comparison of results with reference data from the field surveys.

In conclusion, the best classification results for oak and ash trees showed TopoL software in a combination with classification based on focal points and in a combination with a signature of sun exposed and non-exposed tree crown parts with an aggressive shadow.

On the contrary, as the best classification for spruce and larch trees was identified combination of Erdas Imagine software with a classification rule of the mahalanobis distance and with a signature combination of sun exposed tree crown part including its top with non-exposed part together with crown edges with an aggressive shadow.

SOUHRN

Tento článek popisuje srovnání automatické řízené klasifikace zastoupení lesních dřevin z leteckých snímků mezi jednotlivými programy, použitými pro klasifikaci. Tyto programy byly zastoupeny americkým softwarem Erdas Imagine 8.4, a českými produkty LuciaG 4.0 a TopoL DMT 6.014. Studie zobrazuje menší oblast hospodářského lesa s podílem čtyř nečastěji se vyskytujících dřevin – smrk, modřín, dub a jasan na zkoumaném území lesní oblasti v okolí Bystřice pod Hostýnem, Česká republika. Z důvodu méně kvalitně pořízených spektrozonálních snímků bylo nutné před vlastní klasifikaci provést jisté korekce v podobě zvýrazňovacích technik, a to Kernel Procesoru filtru Low-Frequency a High-Frequency, které patří mezi prostorové operace. Takto upravené letecké snímky sloužily pro vytvoření jednotlivých trénovacích množin, které byly následně použity v rámci jednotlivých klasifikačních metod řízené klasifikace u jednotlivých srovnávacích softwarů. Vlastní klasifikace probíhala až na úroveň jedinců stromového druhu. Přesnost klasifikace byla stanovena porovnáním výsledků s referenčními údaji z terénních šetření.

Výsledkem je, že pro dřeviny dubu a jasanu měla nejlepší výsledky klasifikace v kombinaci s programem TopoL s klasifikací dle těžišť a kombinací signatury osluněné + neosluněné části korun se stínem agresivním.

Naopak pro dřeviny smrku a modřínu byla jako nejvhodnější klasifikace zjištěna kombinace softwaru Erdas Imagine s klasifikačním pravidlem vzdálenosti mahalanobis s kombinací signatur osluněná část koruny včetně jeho vrcholu s neosluněnou částí spolu s okraji těchto korun s agresivním stínem.

letecké snímky, řízená klasifikace, dřevinná skladba, smrk, modřín, dub, jasan, Erdas, TopoL, LuciaG, geografické informační systémy, hospodářská úprava lesa

LITERATURA

ARNUP, R., 1996: Predicting the abundance of advance growth in black spruce forests in north-eastern Ontario: an aerial photograph interpre-

tive key, NODA Notes. No. 23, 4 pp. ERDAS Field Guide. Erdas, Inc., 1994, Atlanta
HÁJEK, F., 2006: Object-oriented classification of Ikonos satellite data for the identification of tree

- species composition, *Journal of Forest Science*, 52, 2006 (4): 181–187, Prag
- HOLOPAINEN, M., WANG-GUANGXING, 1998: Accuracy of digitized aerial photographs for assessing forest habitats at plot level, *Scandinavian Journal-of-Forest-Research.*, 13: 4, 499–508
- JENSEN, J. R., 1996: *Introductory Digital Image Processing. A remote sensing perspective*. Prentice Hall, London, Sydney, Toronto
- LEJEUNE, P., LECOMTE, H., PREVOT, H., 1993: Use of GIS in forest resources management: application to a regional forest inventory. *Bulletin-des-Recherches-Agronomiques-de-Gembloux.*, 28, 2–3, 275–286
- PITT, D. G., GLOVER, G. R., JONES, R. H., 1996: Two-phase sampling of woody and herbaceous plant communities using large-scale aerial photographs, *Canadian Journal of Forest Research*. 26: 4, 509–524
- SCHNOKLAKE, S., AKCA, A., 1998: Possibilities and constraints of a simple analysis of aerial photographs, *AFZ-Der-Wald,-Allgemeine-Forst-Zeitschrift-fur-Waldwirtschaft-und-Umweltvorsorge*. 53: 24, 1452–1453
- SPELLMANN, H., 1987: Forest classification, digital stand mapping and computation of area with the aid of aerial photography. *Plant-Research-and-Development*. 25: 69–84; ORS. Transl. from *Forstarchiv*, 56(5) 186–190
- TUČEK, J., 1998: *GIS Geografické informační systémy, Principy a praxe*, Computer Press, Brno
- UUTTERA, J., HAARA, A., TOKOLA, T., MALTA-MO, M., 1998: Determination of the spatial distribution of trees from digital aerial photographs, *Forest Ecology and Management*. 110: 1–3, 275–282
- ZHOU, H. Z., 1986: Application of information theory to aerial-photograph interpretation. *Journal of North East Forestry University, China*. 14:4, 36–41

Adresa

Ing. Martin Gabzdyl, Ústav pro hospodářskou úpravu lesů Brandýs nad Labem, pobočka Frýdek-Místek, Nádražní 2811, 738 25 Frýdek-Místek, Česká republika, e-mail: martin.gabzdyl@uhul.cz