

**Metsandusteaduskonna
magistrantide ja doktorantide
teaduslikud tööd**

TARTU 2003

Virnatäiuse koefitsiendi hindamine digitaalkaamera piltidelt klassifitseerimistehnika abil

Mait Lang, Jüri Jänes

Lang M., Jänes J. 2003. Estimation of the wood solid volume coefficient from CCD camera images by the maximum likelihood classification. – Transactions of the Faculty of Forestry, Estonian Agricultural University, 36, 107–115.

Abstract. The maximum likelihood classification of regular CCD camera images was used to estimate solid volume coefficients for woodpiles. Additionally, the line sampling technique was tested on the images to provide a simple tool to replace field work. The results showed that the most complicated issue in image classification is shaded log tops. Distinguishing the brown bark from the coloured wood is sometimes problematic. Based on ten images, the R^2 between the maxlike classification and line sampling was 91.2%.

Key words: CCD camera images, solid volume coefficient, line sampling.

Authors' address: Faculty of Forestry, Estonian Agricultural University, Kreutzwaldi 5, 51014 Tartu, Estonia.

Sissejuhatus

Paberi- ja küttepuitu hinnatakse tavaliselt virna kõrguse, pikkuse, nottide pikkuse ning virnatäiuse koefitsiendi abil. Virna mõõtmeid on lihtne suhteliselt väikese veaga hinnata mõõdulati või -lindi abil. Virnatäiuse koefitsiendina kasutatakse tavaliselt mingeid keskmisi puuliigist ning nottide pikkusest sõltuvaid väärtusi. Suurte puidukoguste korral mõjutab süstemaatiliselt tegelikust väärtusest erineva tabuleeritud virnatäiuse koefitsiendi kasutamine ka puidu eest saadavat rahasummat. Näiteks kui müüakse 1000 m^3 paberi- puitu hinnaga 250 kr m^{-3} , siis 10%-line virnatäiuse koefitsiendi viga tähendab rahaliselt $\pm 25\,000 \text{ kr}$. Seetõttu on oluline, et virnatäiuse koefitsient oleks korrektselt hinnatud.

Virnatäiuse koefitsienti on võimalik hinnata näiteks joonproovi abil (Jänes, Lang, 2003). Siiski on vaja suhteliselt pikka vaatlusjoont, et saada usaldusväärset keskmist. Virnatäiuse koefitsiendi hindamiseks on pakutud välja raamil liikuv fotodetektor (Marjomaa, 1991) ning Soome paberivabrikutes saadakse hinnanguid kolmemõõtmelise laserskanneriga tehtud koormapiltide analüüsimisel (Sairanen, 1993). Siiski ei sobi sellised tehnilised lahendused välitingimustes kasutamiseks.

Ränimaatriksil põhinevad digitaalkaamerad võimaldavad saada üsna hea ruumilise lahutusvõimega värvilist pilti. Pilditöötlust on võimalik suhteli-

selt lihtsalt teha näiteks IDRISI32 (IDRISI32 ...) või mõne vabavara paketi, näiteks MultiSpec (MultiSpec ...), abil. Digitaalkaamera on sülearvutiga lihtsalt ühendatav ning seega peaks olema võimalik saada sobivate pilditöötlusprotseduuride kasutamisel piisavalt head hinnangud virnatäiuse koefitsiendile.

Töö eesmärgiks oli uurida võimalusi tavalise digitaalkaameraga tehtud piltidelt virnatäiuse koefitsiendi hindamiseks. Selleks kasutati programmis IDRISI32 olevat õpetava valimi alusel töötavat suurima tõepära järgi klassifitseerimise meetodit MAXLIKE. Klassifitseerimise headuse hindamiseks digiteeriti seitsmel pildil kontrollalad. Lisaks analüüsiti kümmet pilti, mille jaoks oli olemas joonproovide abil saadud virnatäiuse koefitsiendi hinnang (Jänes, Lang, 2003).

Materjal ja metoodika

Kaamera

Piltide tegemiseks kasutati digitaalkaameraid Nikon Coolpix 885 (Nikon ..., 2000) ja Olympos (Olympos ..., 2000). Mõlemal kaameral on CCD maatriksi suuruseks 3,21 miljonit efektiivset pikslit. Kasutaja saab valida erinevate ruumiliste lahutusvõimete vahel. Kõnealuse töö jaoks kasutati suurimat võimalikku lahutusvõimet 2048×1536 pikslit (Nikon ..., 2000). Pildid salvestati JPEG formaadis. Kuigi JPEG puhul on võrreldes TIFF vorminguga teatav kvaliteedi kadu, peeti olulisemaks väiksemat pildifaili mahtu (u 1,5 Mb) kaamerasiseseks salvestamiseks.

Pildistamine, valgustustingimused ja puuliigid

Et töö eesmärgiks oli hinnata metoodika põhimõttelist kasutuskõllikkust, siis prooviti valida erineva puuliigi materjale ning erinevaid valgustustingimusi. Põhilisteks valgustatuse kategooriateks olid: otsene pealelangev päikesekiirgus, hajusa valgustatusega virna varjus olev külg päikesepaistega ja hajus valgustatus pilves ilmaga. Pildistamisel kasutati alati kaamerasse sisseehitatud välklampi. Piltide kirjeldused on tabelis 1.

Virnale kinnitati ka pikkuse etalon (1×0,02×0,02 m), mille otspunktide koordinaatide järgi sai arvutada pildi ruumilise lahutusvõime valemi (1) abil. Piksli suurus ulatus piltidel 1,8–3,6 millimeetrini sõltuvalt kasutatud avast ning pildistamise kaugusest.

$$R = \frac{L_{etalon} \cos \left(\text{ATAN} \left(\frac{y_2 - y_1}{x_2 - x_1} \right) \right)}{x_2 - x_1}, \quad (1)$$

kus/where L_{etalon} on etaloni pikkus / reference length (m); x_1, y_1 – etaloni vasakpoolse otsa koordinaadid / reference left end coordinates; x_2, y_2 – etaloni parempoolse otsa koordinaadid / reference right end coordinates.

Tabel 1. Piltide kirjeldused

Table 1. Description of images

Pilt <i>Image</i>	Kirjeldus <i>Description</i>	Ilm <i>Weather</i>	Valgustatus <i>Illumination</i>
1236	Kvaliteetne kuusepaberipuit <i>Spruce pulpwood</i>	selge/clear	hajus/diffuse
1238	Kvaliteetne männipaberipuit <i>Pine pulpwood</i>	selge/clear	hajus/diffuse
1246	Seismajäänud männipaberipuu. Notiotsad tumenenud / <i>Old pine pulpwood. Logtops darkened</i>	selge/clear	otsene/direct
1256	Värske metsamädanikuga kuusepabe- ripuu / <i>Fresh spruce pulpwood with rot</i>	selge/clear	otsene/direct
1257	Kvaliteetne kuusepaberipuu <i>Spruce pulpwood</i>	selge/clear	otsene/direct
1260	Kvaliteetne halvasti laotud kasepa- beripuu / <i>Incorrectly stacked birch pulpwood</i>	selge/clear	otsene/direct
KsVirn	Kvaliteetne kasepaberipuu metsas <i>Birch pulpwood in forest</i>	pilves õhtul <i>overcast in the evening</i>	hajus/diffuse
1	Kvaliteetne kasepaberipuu vagunis <i>Birch pulpwood in railway carriage</i>	vahelduv <i>intermittent</i>	otsene/direct
2	Kvaliteetne kasepaberipuu vagunis <i>Birch pulpwood in railway carriage</i>	selge/clear	otsene/direct
3	Kvaliteetne kasepaberipuu autokoormas <i>Birch pulpwood on truck</i>	vahelduv <i>intermittent</i>	poolvarjud <i>half-shadows</i>
4	Kvaliteetsed haavapakud <i>Aspen logs</i>	selge/clear	hajus /diffuse
5	Lehtpuu segavirn / <i>Mixed deciduous pulpwood stack</i>	selge/clear	hajus/diffuse
6	Kvaliteetne okaspuupaberipuu <i>Coniferous pulpwood</i>	vahelduv <i>intermittent</i>	otsene/direct
7	Kvaliteetne kasepaberipuu <i>Birch pulpwood</i>	selge/clear	hajus/diffuse
8	Kvaliteetne kasepaberipuu <i>Birch pulpwood</i>	selge/clear	otsene/direct
9	Kvaliteetne kasepaberipuu <i>Birch pulpwood</i>	selge/clear	otsene/direct
10	Värske ja seismajäänud okaspuupaberi- puu virn / <i>Fresh and old coniferous pulpwood stack</i>	pilves <i>overcast</i>	hajus/diffuse

Pilditöötlus ja klassifitseerimine

Digitaalsed värvipildid võeti programmis GIMP lahti kolmeks värvisignaali: siniseks, rohelineks ja punaseks. Saadud failid imporditi IDRISI32-te moodulite TIFIdris ja BIPIdris abil. Pildi suurimateks X- ja Y-koordinaatideks sai veergude ja ridade arv. Mooduli WINDOW abil lõigati piltidest välja virna-alad.

Iga pildi infosisaldust uuriti esmalt kõige lihtsamat klassifitseerimis-meetodit CLUSTER kasutades. CLUSTERi abil klassifitseeriti kõik pildid esmalt kaheksaks kuni kümneks spektraalselt homogeenseks alaks, et hinnata objektide eristatavust. Originaalpiltidega võrdlemisel leiti, millised peaks olema vajalikud ja eristatavad spektraalsed klassid (tabel 2).

Tabel 2. Virnades eristatavad objektid

Table 2. Distinguishable objects in wood piles

Element <i>Object</i>	Eristuvad spektraalsed klassid <i>Distinguishable spectral classes</i>
Notiotsad <i>Log tops</i>	hele kollakasvalge; punakaspruun; mäda; varjutatud <i>bright yellowish-white; bright red-brown; rotten; shady</i>
Koor/ <i>Bark</i>	pruun; hall; hallikasroheline; valge, must <i>brown; grey; greyish-green, white, black</i>
Tühi ruum <i>Empty space</i>	must; valge (ülelööb) <i>black; bright white (flashover)</i>
Lumi/ <i>Snow</i>	valge/ <i>white</i>
Etalon/ <i>Reference</i>	helesinine / <i>bright blue</i>
Okkad/ <i>Needles</i>	roheline/ <i>green</i>
Märkevärvi <i>Marker paint</i>	punane; must <i>red; black</i>

Notiotste ja muude objektide eristamiseks kasutati moodulit MAXLIKE. MAXLIKE on õpetava valimi alusel töötav klassifitseerimis-algoritm. Õpetuspiirkonnad digiteeriti ekraanil ning mooduli MAKESIG abil koostati pildilt eristatavate klasside spektraalsed signatuurid (heleduste ja värvide näidised). Kui pärast klassifitseerimist selgus, et algpildiga võrreldes on nähtavalt objekte, näiteks koort ning pruunikaid notiotsi, segi aetud, siis lisati konfliktsetele aladele õpetuspiirkondi ning tehti uued signatuurid ja klassifikatsioon.

Virnatäiuse koefitsiendi arvutamisel jäeti välja etaloniks ja rohelisteks okasteks klassifitseeritud pikslid.

Klassifikatsiooni headuse hindamine

Seitsme pildi jaoks koostati õige klassifikatsiooni pildid. Klasse oli kaks: notiots ja muu. Selleks digiteeriti programmis MapInfo (MapInfo 2000) notiotsad võimalusel ellipsi abil või siis hulknurksete polügoonidena. Saadud

andmed imporditi IDRISI32-te ning moodulite INITIAL ja POLYRAS abil koostati õige klassifikatsiooni rasterpilt. Mooduli CROSSTAB abil koostati veematriksid. Vaatenurgast tulenevaid vigu ei uuritud.

Teise testina võrreldi lihtsalt saadud klassifikatsiooni ja joonproovi abil saadud virnatäiuse koefitsiente.

Tulemused ja arutelu

Kõige rohkem klasse on vaja kasutada otsese valgustatusega kasepaberipuu virnadel. Ka silmaga vaadates on eristatav vähemalt kolme erinevat värvi koor – pruun, valge, must; ja kahte tooni puit. Lisaks tuleb eraldi klassifitseerida varjus alad.

MapInfos koostatud "õige" klassifikatsiooniga võrreldes selgus, et väga hästi õnnestub puhaste heledate notiotste pikslite klassifitseerimine (tabel 3). Lülipuidu, ränipuidu jms klassifitseerimise täpsus on oluliselt väiksem. Kõige problemaatilisem on varjus olevate alade klassifitseerimine. Selle põhjuseks on ülejäänud aladega võrreldes suhteliselt nõrk signaal ja seetõttu ka halb eristatavus.

Tabel 3. Piltidel olevate objektide klassifitseerimise täpsus võrreldes muu/puit õige klassifikatsiooniga


Table 3. Comparison of the Maxlike classification with digitised nonwood/wood images

Objekt/Object	Klassifitseerimise täpsus / Classification accuracy %						
	1238	1238	1246	1257	1260	1256	KsVirn
Hele puit / Bright wood	99.0	90.5	95.2	98.4	99.4	98.7	91.2
Muu puit / Other wood	91.7	93.4	87.5	81.6	89.1	84.1	80.3
Varjus puit / Shady wood	75.0	60.2	29.7	20.7	17.3	40.5	–
Keskmiselt puit Average wood	88.3	87.3	78.2	92.4	84.8	87.3	89.9
Koefitsient Coefficient (%)	61.2	54.2	51.8	56.9	40.1	56.9	55.9
Puit -> Muu Wood -> Other (%)	7.1	5.6	25.4	8.7	8.0	8.7	10.0
Muu -> Puit Other -> Wood (%)	12.3	13.6	20.8	7.5	16.5	7.5	4.0

Varjus alade paremaks eristamiseks võiks muuta digitaalkaamera tundlikkust. Siiski tuleb olla hoolikas, et ka heledad notiotics jääksid eristatavaks heledast taustast või muudest heledatest objektidest, nagu näiteks kasetoht.

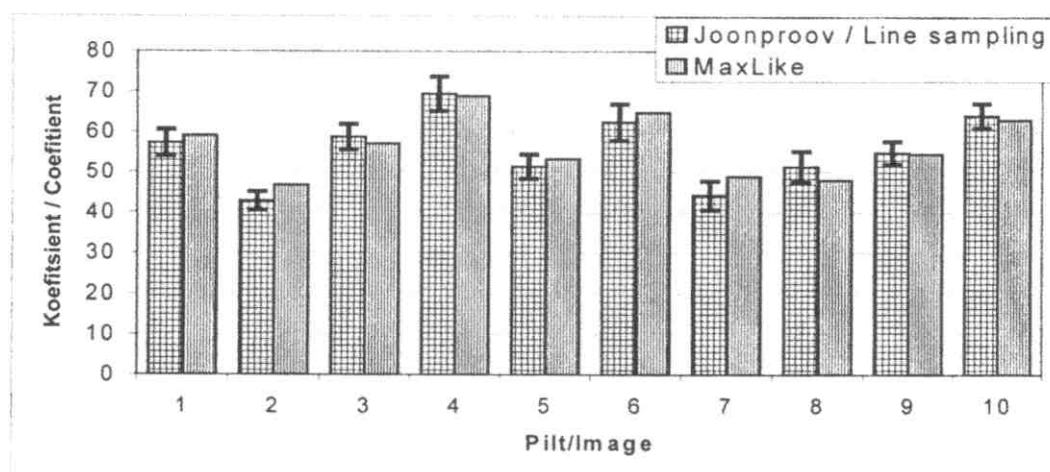
Väikesed vead puidu ja mittepuidu klassifitseerimisel ei ole tegelikult probleem, kui puidu suhtes jaotub viga võrdsele mõlemale poole. Tegelikult selgus, et paljudel juhtudel klassifitseeritakse puitu rohkem muudeks aladeks

ja vastupidi, mistõttu saadud hinnang on nihutatud (joonis 1). Tabelist 3 selgub, et enamasti jääb nihe klassifitseerimisel kokkuvõttes 7–8% piiresse, kui vaadata puiduks ja mittepuiduks klassifitseeritud pikslite arvu vahet. Põhilised veaallikad on õpetuspiirkondade määramise vead ning teisalt mõnede elementide, nagu näiteks varjus koor ning varjus puit, raske eristatavus. Õpetuspiirkondade määramiseks tuleb natuke harjutada, võimalikult hea kvaliteediga piltide saamine eeldab kasutatava aparraadi ja fotograafia algtõdede tundmist.



Joonis 1. MaxLike klassifitseerimise täpsus. Hinnatud virnatäiuse koeffitsient ja puit \leftrightarrow mittepuit klassifitseerimise viga

Figure 1. Accuracy of the Maxlike classification. Estimated are stack solid volume coefficients and the wood \leftrightarrow nonwood classification errors represented by the error bars



Joonis 2. MaxLike klassifikatsiooni ja joonproovide abil saadud virnatäiuse koeffitsientide võrdlus. Joonproovide alusel saadud keskmisele hinnangule on lisatud standardvea piirid

Figure 2. Comparison of solid volume coefficients estimated by line sample \pm standard error and the MaxLike classification

Joonproovide ning pildi klassifitseerimise abil saadud virnatäiuse koefitsientide võrdlus näitas, et saadud tulemused on üsna sarnased. Joonisel 2 on toodud virnatäiuse koefitsientide keskmiste hinnangud ning joonproovide seeriale on lisatud juurde \pm standardvea piirid tõenäosusel 68%. Enamikul juhtudel jääb pildi klassifitseerimisel saadud virnatäiuse koefitsiendi hinnang joonproovide hinnangu standardvea piiresse. Võrdluseks kasutatud pildid olid esimese testi seitsmest pildist parema kvaliteediga (kogemuste kasv).

Digitaalsetel piltidel on lisaks värviinfole olemas ka ruumiline informatsioon. Enamasti on nii, et kõrvuti asetsevad ja värvuse poolest vähe erinevad pikslid kuuluvad suure tõenäosusega samasse klassi. Kui rakendada mõnda segmenteerimisalgoritmi, mis oskab kasutada ka pildil olevat ruumilist infot, siis peaks klassifitseerimise täpsus paranema.

Kokkuvõte

Töös analüüsiti virnatäiuse koefitsiendi hindamise võimalusi digitaalkaameraga tehtud värvipiltidelt. Tööst saab teha järgmised järeldused.

1. Värvilistelt digitaalfotodelt on võimalik õpetava valimiga klassifitseerimistehnikat kasutades hinnata virnatäiuse koefitsienti.
2. Hinnangute vead sõltuvad peamiselt klassifitseerija kogemustest õpetuspiirkondade valimisel ja piltide kvaliteedist. Signaali kvaliteet peab olema hea just virna kujutavas alas. Kõige problemaatilisem on varjus notiotste ja teiste elementide eristamine.
3. Kontrollpiltidega, millel oli käsitsi digiteeritud notioticsad, võrdlemisel selgus, et virnatäiuse koefitsiendi hinnangu nihe võib olla kuni 8% tulenevalt õpetuspiirkondade määramisest.
4. Joonproovide ning klassifitseerimistehnika võrdlemisel selgus, et pilditöötlemisega saadud hinnang jääb enamasti \pm standardvea piiridesse tõenäosusel 68%.

Kasutatud kirjandus

- IDRISI32. <http://www.clarklabs.org> 24.04.03.
- Jänes, J., Lang, M., 2003. Joonproovide kasutamise võimalustest virnatäiuse koefitsiendi määramisel. – EPMÜ Metsandusteaduskonna toimetised nr 36, lk.
- MapInfo. <http://mapinfo.com> 24.04.03.
- Marjomaa, J., 1991. Accuracy of the AVM2000 measuring device for measurement of timber bundles. Metsäteho katsaus 4, 6 p.
- MultiSpec. <http://dynamo.ecn.purdue.edu/~biehl/MultiSpec> 24.04.03.
- Nikon Corporation. 2000. The Nikon guide to digital photography with the Coolpix 885 digital camera. Japan.

- Olympos Optical Co., LTD. 2000. Digitaalkaamera C-3040zoom Digital Camera Basic Manual (lühendatud kasutamisjuhend). 148 lk.
- Sairanen, P. 1993. Kehuskuvajärjestelmä kuitupuun mittaukseen tehtaalla. Puutavaran mittausseminaari 20.–21. 04. 1993. Hotelli Prinssi, Pori. Käsikirjoitus. 13 s.

Estimation of the Wood Solid Volume Coefficient from CCD Camera Images by the Maximum Likelihood Classification

Mait Lang, Jüri Jänes

Summary

Colour images taken with a CCD camera were used to estimate solid wood volume coefficients for roundwood stacks. The illumination conditions were 1) direct sunlight; 2) diffuse illumination on the shady side and 3) diffuse illumination in overcast conditions. The built-in flash was always used. Table 1 presents a short description of the images.

Image processing was carried out with IDRISI32. First, CLUSTER was used to study the separability distinctness of stack elements, such as bark, log tops, etc. The resultant classes are listed in Table 2. Finally, all the images were classified using the supervised technique. The training areas were digitised on the screen. The module MAKESIG was used to create spectral signatures and MAXLIKE for image classification. Where comparison with the original image evidenced substantial misclassification, new training areas were added and the classification procedure was repeated.

The classification accuracy was tested 1) by crosstabulation of the classified image with a Boolean wood/nonwood image where log tops were digitized by hand; 2) by comparing the estimates derived from the classified image with line sampling estimates.

Classification accuracy depends much on input image quality and user experience in creating training areas. The results are presented in Table 3. The table shows that the pixels representing bright log tops were always classified with 90% or higher accuracy. Other wood pixels (coloured sapwood, etc.) were classified with 80% or higher accuracy. The most problematic was the distinction between shady logtops and other dark elements due to the low signal. Figure 1 illustrates the fact that the

wood/nonwood classification error is not always equally distributed and therefore the classification can be biased.

A comparison of solid volume coefficients obtained by line sampling and by image classification is presented in Figure 2. The fairly good agreement between the two methods suggests that image classification techniques can be used to estimate solid volume coefficients of wood stacks.