



Henri Hietala

MELANOOMAOIREIDEN ANALYYSIOHJELMISTO

MELANOOMAOIREIDEN ANALYYSIOHJELMISTO

Henri Hietala
Opinnäytetyö
25.02.2013
Tietotekniikan koulutusohjelma
Oulun seudun ammattikorkeakoulu

TIIVISTELMÄ

Oulun seudun ammattikorkeakoulu
Tietotekniikan koulutusohjelma, langaton tietoliikenne

Tekijä(t): Henri Hietala

Opinnäytetyön nimi: Melanoomaoireiden analyysiohjelmiston testaus

Työn ohjaaja(t): Kari Jyrkkä, Manne Hannula

Työn valmistumislukukausi ja -vuosi: Kevät 2013 Sivumäärä: 67 + 2 liitettä

Työn tilaaja oli Oulun seudun ammattikorkeakoulun Tekniikan yksikkö. Työssä tarkoituksena oli testata Ihomittari-projektiin aiemmin toteutettuja analyysialgoritmeja, jotka analysoivat luomia käyttäen VARO-muistisäännön mukaisia parametreja, jotka ovat halkaisija, symmetria, värin tasaisuus ja reunojen säännöllisyys sekä pidempiaikaisessa seurannassa luomen kasvu. Tavoitteena oli saada kunkin algoritmin luotettavuudesta niitä vastaavat korrelaatiokertoimet, sensitiivisyys- ja spesifisyysprosentit ja optimaaliset raja-arvot algoritmeille.

Työssä käytetty kuvamateriaali pyrittiin saamaan ensisijaisesti SOTE:n ja OYS:n kautta, mutta lopulta päädyttiin käyttämään Internetistä saatua kuvamateriaalia. Kuvamateriaali käytiin läpi mittaamalla niistä halkaisijan ja kasvun arvot ja luokittamalla ne värin, symmetrian ja reunojen suhteen. Testaus toteutettiin kahdessa vaiheessa, joista ensimmäisessä kuvamateriaali käytiin algoritmeilla läpi yhdellä raja-arvolla. Toisessa vaiheessa algoritmien tulostus laajennettiin kattamaan useita eri raja-arvoja, jotka asetettiin ensimmäisen vaiheen testien perusteella sopivin välein. Testien tekemisen jälkeen saadut tulokset käsiteltiin tekemällä siihen tarkoitettu ohjelma, jonka jälkeen käsitellyt tulokset koostettiin tekemällä siihenkin ohjelma ja tulostamalla ne lopullisiin työssä esitettyihin tulostaulukoihin.

Halkaisijan ja kasvun seuraamisesta saatujen tulosten perusteella algoritmit ovat erittäin luotettavia, kunhan luomi segmentoidaan oikein. Kummankin korrelaatiokertoimet olivat erittäin lähellä arvoa 1. Värin tasaisuuden, symmetrian tunnistuksen ja reunojen säännöllisyyden kohdalla käytettyjen luokitusten perusteella niistä saatujen sensitiivisyys- ja spesifisyysarvojen mukaan värin ja symmetrian tunnistukset toimivat hyvin, mutta kyseiset algoritmit kaipaavat vielä jatkokehitystä erityisesti spesifisyyden suhteen. Niiden sensitiivisyys/spesifisyys tulokset olivat 93 %/72 % värille ja 89 %/63 % symmetrialle. Reunojen säännöllisyyden tulokset sen sijaan olivat odotetusti algoritmin yksinkertaisuudesta johtuen välttäviä sekä vaikeammin korjattavissa algoritmin jatkokehityksellä. Johtopäätöksenä olikin, että koko algoritmi tulisi tehdä täysin uusiksi. Reunan säännöllisyyden tulos oli 56 %/78 %, joista spesifisyyden arvo johtui enemmän algoritmin yleisestä toimimattomuudesta kuin sen kyvystä erottaa säännölliset reunat epäsäännöllisistä.

SISÄLTÖ

TIIVISTELMÄ	3
LYHENTEET	6
1 JOHDANTO	7
2 MELANOOMAN ANALYSOINTI KUVANKÄSITTELYN AVULLA.....	8
2.1 Kuvankäsittelyn päätyypit	8
2.2 Konepohjaisen kuvankäsittelyn haasteet.....	8
2.3 VARO-sääntö	10
2.4 Ihomittari-projekti.....	11
3 KUVAUS JA ALGORITMIT	15
3.1 Kuvausolosuhteiden vaikutukset analyysiin.....	15
3.1.1 Valaistus ja intensiteetti	15
3.1.2 Kuvattavan asento	17
3.1.3 Etäisyys	18
3.2 Objektin ominaisuuksien käsittely.....	19
3.3 Algoritmit	20
3.3.1 Pääohjelma.....	20
3.3.2 Luomien käsittely ennen analyysia	23
3.3.3 Luomien käsittely	25
3.4 Keskeneräiset asiat	32
3.5 Testaaminen.....	33
4 TYÖN SUORITTAMINEN	34
4.1 Lähdemateriaalin hankinta	34
4.2 Mittausjärjestelyt.....	36
4.2.1 Halkaisija	36
4.2.2 Symmetria, reunat ja väri	37
4.2.3 Kasvu.....	38
4.3 Testauksen suorittaminen	39

5 TULOSTEN ANALYSOINTI	41
5.1 Segmentoinnin analyysi.....	41
5.2 Korrelaatio, sensitiivisyys ja spesifisyys	45
5.3 Tulosten analysointi.....	46
5.3.1 Halkaisija	46
5.3.2 Kasvun vertaus	47
5.3.3 Symmetria.....	48
5.3.4 Värin tasaisuus	54
5.3.5 Reunojen säännöllisyys	59
6 JOHTOPÄÄTÖKSET	61
7 LOPPUSANAT	63
LÄHTEET.....	65
LIITTEET	
LIITE 1. Tulostaulukot	
LIITE 2. Parhaat tulokset	

LYHENTEET

ABCD(E)-sääntö	Englanninkielinen muistisääntö melanooman tunnistamiseen (ks. 2.3)
HSI-järjestelmä	Ihmiselle intuitiiviseksi suunniteltu värimalli, joka tulee sanoista Hue, Saturation ja Intensity (ks. 2.2)
OAMK	Oulun seudun ammattikorkeakoulu
OYS	Oulun yliopistollinen sairaala
PPSHP	Pohjois-Pohjanmaan sairaanhoitopiiri
RGB-järjestelmä	Punaisen, vihreän ja sinisen sekoittamiseen perustuva värijärjestelmä, joka tulee sanoista Red, Green ja Blue (ks. 2.2)
R-kanava	RGB-kuvan punaiset sävyt sisältävä harmaasävykerros
SOTE	Sosiaali- ja terveystieteiden yksikkö
VARO-sääntö	ABCD(E) kaltainen muistisääntö melanooman tunnistamiseen suomenkielisistä sanoista (ks. 2.3)

1 JOHDANTO

Vuonna 2012 Oulun seudun ammattikorkeakoulussa (OAMK) käynnistyi hyvinvointitekniikan laboratoriossa Ihomittari-projekti, jossa tavoitteena oli kehittää melanooman tunnistusmenetelmiä terveydenhuollon työvoimaresurssien säästämiseksi sekä käytännöllisyyden ja arkistoinnin parantamiseksi. Hyvinvointitekniikan opiskelija Niina Lundbom teki aiheesta OAMK:n Tekniikan yksikölle tutkivan opinnäytetyön, jonka pohjalta kesällä 2012 aloitettiin varsinaisen projektin toteuttaminen, jossa itse olin myös mukana. Opinnäytetyössä päädyttiin tavoittelemaan ratkaisua, jossa ihmisen koko iho voidaan kuvata kerralla kuvauskopissa ja analysoida siitä löydetty luomet VARO-säännön mukaisten parametrien perusteella. Tämä helpottaa lääkärin diagnoosia tehtyjen analyysien perusteella, ja samalla potilaan tiedot luomien kehityksestä voidaan arkistoida järjestelmällisesti. Tähän ratkaisuun päädyttiin, koska todettiin, että algoritmien toiminnan kannalta kuvausolosuhteiden tulisi olla mahdollisimman standardit.

Projektissa työskenteli minun lisäksi yksi hyvinvointitekniikan opiskelija. Minun tehtäväni tietotekniikan opiskelijana oli kehittää algoritmit, joilla luomi tunnistetaan kuvasta ja analysoidaan. Projektin toinen työntekijä työsti varsinaista kuvausjärjestelmää, josta on Tekniikan yksikössä käytettävissä tällä hetkellä tämän työn tarkoituksiin riittävä prototyyppi, mutta tässä työssä keskitytään yksinomaan algoritmien testaukseen, joten kuvausjärjestelmään ei oteta kantaa, ellei se ole algoritmien kannalta merkittävää.

Tavoitteena tässä työssä on projektin vieminen seuraavalle tasolle siirtymällä alustavassa toiminnallisuustestauksessa käytetyistä yksinkertaisista kaksivärisistä kuvista testaamaan algoritmien toimintaa oikean kuvamateriaalin perusteella ja laskea parametrit, jotka kuvaavat sitä, kuinka hyvin algoritmien analyysit vastaavat todellisuutta. Kuvamateriaalin hankinnassa pyritään tekemään yhteistyötä Oulun yliopistollisen sairaalan (OYS) ja Sosiaali- ja terveysalan yksikön (SOTE) kanssa, mutta tarvittaessa materiaalina voidaan käyttää myös muista lähteistä saatua materiaalia.

2 MELANOOMAN ANALYSOINTI KUVANKÄSITTELYN AVULLA

2.1 Kuvankäsittelyn päätyypit

Kuvankäsittelyä tehdään pääasiassa kahteen tarkoitukseen: ihmiselle ja koneelle. Ihmissilmälle tarkoitettu kuvankäsittely on hyvin yleistä ja havaittavissa useissa arkipäiväisissä asioissa. Ihmisen informaation käsittelykyky on kuitenkin hyvin rajoittunut. Esimerkiksi jo kahden parametrin analysointi 100 kuvasta on ihmiselle hyvin hidasta ja virheiden todennäköisyys suuri johtuen sekä ihmisen keskittymiskyvystä että inhimillisistä virheistä. Varsinkin jos nämä 100 kuvaa on ensin löydettävä samasta kuvasta satunnaisista paikoista, on erittäin todennäköistä, että ihmiseltä jää objekteja huomaamatta. Näin ollen on sovelluksia, joissa kone on sekä varmempi että nopeampi tekemään saman asian. Yksi näistä on tässäkin työssä käsitelty melanooman analysointi ihosta. Ihmisellä voi olla jopa satoja luomia, joiden seuraaminen kattavasti on likipitään mahdotonta ihmisresurssein.

2.2 Konepohjaisen kuvankäsittelyn haasteet

Kuvankäsittely konetta varten tuo kuitenkin mukanaan omat haasteensa. Löydetyistä objektista on toki helppo saada mitattua koneellisesti kaikki ominaisuudet, mutta ensin pitää löytää kyseinen objekti. Konetta ei voida käskää kuten ihmistä etsimään kuvasta luomi, vaan sille on ensin annettava parametrit, millaisia objekteja kuvasta haetaan, ja kuvattavasta kohteesta riippuen joskus myös, millaisia ei haeta. Näitä parametreja voivat olla esimerkiksi objektin minimi- ja maksimikoko, väri, muoto, yhtenäisyys jne. Näiden kuvaileminen koneelle edellyttää tietysti matematiikan soveltamista kuvainformaatioon, jonka perusteella kone laskee, onko kyseessä haettu objekti.

Sen lisäksi, että objektin kuvaileminen koneelle poikkeaa ihmiselle kuvatusta, on myös huomioitava, että ihminen ja kone käsittelevät värejä eri tavalla. Ih-

miselle luontainen värimalli on HSI-järjestelmä (Hue, Saturation, Intensity), jossa värin kuvaaminen perustuu itse väriin, sen voimakkuuteen ja kirkkauteen. HSI ei kuitenkaan toimi yhtä hyvin koneen käsittelyssä laskennallisten erojen takia. Koneen on laskennallisesti helpompi käyttää esimerkiksi RGB-järjestelmää (Red, Green, Blue), joka koostuu kolmesta päällekkäisestä 8-bittisestä harmaasävykuvasta. Jokainen harmaasävykuva kertoo kunkin kolmen päävärin intensiteetin voimakkuuden kullakin pikselillä, ja kasaamalla ne päällekkäin saadaan yhdisteltyä kaikki mahdolliset 24-bittiset värikombinaatiot. (1, s. 291, 295.)

Kuvan jakamista objekteihin kutsutaan segmentoinniksi. Segmentoinnin tarvittava tarkkuus on erittäin tärkeää saada kohdalleen. Tavoite on, että sillä saadaan erotettua kuvasta kaikki tarvittavat yksityiskohdat, muttei mitään ylimääräistä, sillä tämä tarkkuus ratkaisee jo lähtökohtaisesti, onnistuuko objektin analysointi. Ongelma tässä on, mitä kuvataan ja millaisissa olosuhteissa. (1, s. 567–568.) Kuvatessa staattista objektia staattisella kameralla ei tarvitse ottaa yhtä paljon asioita huomioon kuin kuvatessa epästaattista kohdetta, kuten ihmistä, joka ei varmasti ole aina tismalleen samassa asennossa ja jonka ihossa voi olla suuriakin muutoksia ja poikkeavuuksia yksilöiden välillä ja eri aikoina, kuten tatuointeja tai rusketusta. Lisäksi on huomioitava, että kameran laatu ja kuvaolosuhteet valaistuksen ja kuvausetäisyyden suhteen vaikuttavat suoraan siihen, miten kone kuvan näkee annettujen parametrien perusteella. Tämä on varsinkin objektin reunojen havaitsemisessa olennaista, sillä se määrää, ovatko löydetyt reunat tarkat vai hyvin leveät ja siten epätarkat. (1, s. 572.) Lisäksi segmentointiin vaikuttaa myös yllä kuvattu värimalli. Kuten jo mainittu, koneen on helpompi laskennallisesti erotella sävyjä perustuen RGB-mallin eri 8-bittisiin värivektoreihin, mikä johtaa parempaan segmentointiin kuin HSI-järjestelmän käyttö. (1 s. 333.)

Vaikka siis yllä mainittujen parametrien käyttö staattisilla raja-arvoilla toimiikin tiettyyn pisteeseen ja ehkä jopa riittävän hyvin tarpeeksi yksinkertaisille objekteille, on kuvantunnistuksessa tiukasti rajattujen parametrien sijaan yleisenä käytäntönä opettaa ohjelmalle segmentoitavia objekteja. Opettaminen sekä poistaa rajoituksia että myös helpottaa ei-haluttujen objektien pois

jättämistä segmentoitaessa. Luomia kuvattaessa tällaisia objekteja ovat esimerkiksi tatuoinnit, silmät, hiukset ja vastaavat tummat alueet, joita voidaan havaita objektin rakenteellisen tunnistuksen perusteella. Tärkeimpänä kuitenkin algoritmin opettaminen auttaa vaikeimpien rajatapauksen tunnistamisessa, sillä ohjelma voi näissä tapauksissa laskea todennäköisyyden ja etäisyyden tunnistusparametreista, täyttääkö kyseinen objekti halutut ehdot. (1, s. 732. , 698–712.) Algoritmien opettaminen vaatii kuitenkin hyvin laajaa kuva-aineistoa, jota ei aina ole käytössä, joten karkeampaa tunnistusta voidaan käyttää tarvittaessa.

Vastaavasti monet yllä mainituista asioista vaikuttavat myös löydetyn objektin analysointiin. Projektissa, johon tämäkin insinööriytyö perustuu, tarkoituksena on seurata henkilön luomien kehitystä pitkällä ajalla, joten analyysille on asetettava standardit, joiden perusteella kaikki myöhemmätkin kuvaukset ovat verrattavissa ensimmäiseen kuvaukseen ja toisiinsa luotettavasti, erityisesti luomen kokoa käsiteltäessä. Koska ihmisten ihon pigmentti poikkeaa yksilökohtaisesti, ei jokaista voida tutkia samoilla parametreilla ja raja-arvoilla.

Projektin pohjana toimivassa insinööriytyössä onkin päädytty ehdotukseen, jossa kuvaus tapahtuu aina standardissa paikassa eli kuvauskopissa, jossa valaistus, etäisyys ja kamerat ovat aina samat ja kuvattavan henkilön asento siinä määrin sama, ettei se pääse sekoittamaan luomien tunnistusjärjestystä tai analyyseja (2).

2.3 VARO-sääntö

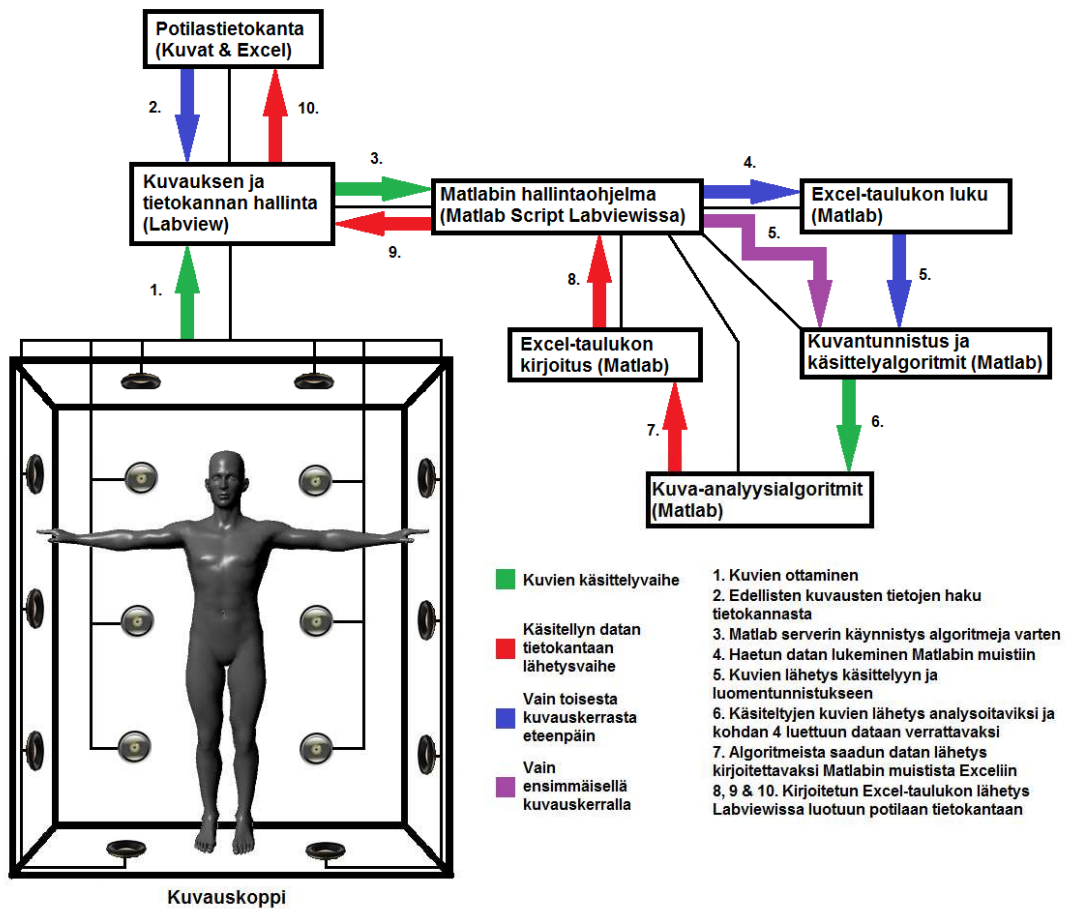
VARO on terveydenhuollossa yleisesti sovellettu muistisääntö, jonka avulla luomesta voidaan tunnistaa epäilyttävät piirteet helposti (3). Se vastaa hyvin paljon englanninkielen sanoihin pohjautuvaa ABCDE-sääntöä:

V = Värin epätasaisuus (C = Colour)
A = Alueen halkaisija > 6mm (D = Diameter)
R = Reuna epätasainen (B = Border)
O = Osat epäsymmetriset (A = Asymmetry).

VARO-sääntö pätee luonnollisesti kuhunkin luomeen vain sillä hetkellä, ja luomen pidempiaikaisessa seurannassa on esimerkiksi seurattava myös sen kasvua ja muita muutoksia suhteessa aikaan, mikä on ABCDE-säännön E eli Evolution (4) tai joidenkin lähteiden mukaan Enlargement. Hyvälaatuisia muutoksia voi kuitenkin tapahtua myös terveessä luomessa (5), mikä on yksi syy siihen, miksi algoritmit ovat analyysin, eivät diagnoosin tekemistä varten.

2.4 Ihomittari-projekti


Ihomittari -projektissa tarvittavat algoritmit on tehty noudattaen aiemmin OAMK:lle tehdyssä insinööriyössä annettuja VARO- ja ABCDE-sääntöjä. Lopullisena ehdotuksena tavoiteltavaksi lopputuotteeksi oli rakentaa kuvauskoppi, jolla ottaa useilla kameroilla panoraamakuva henkilön ihosta, josta jokainen luomi analysoidaan erikseen ja kirjoitetaan taulukkoon. Kuvassa 1 on kuvattu, miten ehdotetun järjestelmän tulisi pääpiirteittäin toimia. Ehdotukseen kuvauskopin käytöstä päädyttiin useista syistä, mutta algoritmien kannalta olennaisin syy on, että kotikuvauksessa eli potilaan itsensä kotioloissa millä tahansa kameralla ottamissa kuvissa on liian suuri riski sille, että kuvat eivät ole vertailukelpoisia (2).



KUVA 1. Kuvausjärjestelmän toimintakaavio

Projektin tässä vaiheessa ei ollut käytettävissä algoritmien opettamiseen tarvittavaa materiaalia, joten segmentointi perustuu tämän hetkessä versiossa siihen, että luomi on ihossa tummempi kuin muu iho, joten se voidaan eristää kuvasta omaksi objektikseen ja analysoida. Tehdyissä algoritmeissa on staattiset arvot, kuinka tummat objektit valitaan, ja minimi- sekä maksimikoko niille. Objektin tummuus onkin pyritty keskiarvoistamaan segmentoinnin parantamiseksi nykyisessä versiossa. Kaikkia valaistuksesta johtuvia värinmuutoksia ei voida välttää kuitenkaan, joten projektin edetessä tulee siirtyä modernimpaan algoritmien opettamiseen.

Varsinaisen luomen analysointi toimii hyödyntämällä Matlabin bwlabel- ja regionprops-komentoja. Kuvassa 2 nähdään, kuinka havaitut luomet ovat muuttuneet valkeiksi objekteiksi. Käytetty Matlab-versio oli r2007b, jossa on pakko muuttaa kuva binäärikuvaksi, jotta metodia voidaan käyttää. Myöhemmissä versioissa on mahdollista suorittaa samat toiminnot myös tavalliselle intensiteettikuvalle, joten uuden version myötä olisi ehdottomasti hyvä siirtyä sen käyttöön, koska se helpottaa analyysia monessa suhteessa. Kun objekti on havaittu annettujen kirkkaus- ja kokoarvojen perusteella, se merkitään numerolla, mikä myös nähdään kuvassa 2. Tämän jälkeen se irrotetaan analyysin ajaksi erikseen, jotta muut luomet eivät vaikuta siihen mitenkään. Kun analyysi on tehty, kirjoitetaan saadut arvot Excel-taulukkoon kyseistä algoritmia vastaavalle välilehdelle ja jokaisen luomen informaatio tulee sille aiemmin merkatun numeron mukaiselle riville kuvan 3 mukaisesti.



KUVA 2. Luomien merkitseminen (6)

	A	B	C	D	E	F	G	H	I	J	K
1	50,92729										
2	44,80958										
3	54,97882										
4											
5											
6											
7											
8											
9											
10											
11											
12											
13											
14											
15											

KUVA 3. Exceliin kirjoitetut arvot kuvan 2 luomista ja välilehdet

Ensimmäinen analyysi myös suorittaa ihon kirkkauden keskiarvon mittaamisen yms., joita käytetään tulevissa analyyseissä samalle henkilölle, joten nämä arvot pysyvät aina samana tulevissa mittauksissa. Siten ihon muutokset kuvausten välillä eivät pääse vaikuttamaan mitenkään objektien eli luomien havaitsemisen herkkyyteen. Tämä muuttuu todennäköisesti tarpeettomaksi toimenpiteeksi tunnistuksen kehittyessä, mutta on ohjelman nykyversiossa välttämätöntä. Yllä kuvatun metodin käytön vuoksi objektit havaitaan aina samassa järjestyksessä, ja koska henkilö on kuvauskopissa aina samassa asennossa, voidaan näin päätellä esimerkiksi kolmantena löytyneen luomen olevan sama kuin edellisellä kerralla kolmantena löytynyt, vaikka objektin kuvakoordinaatit poikkeaisivatkin toisistaan kuvien välillä, mikä tapahtuu välttämättä, kun kyseessä on ihmisen kaltaisen epästabiilin kohteen kuvaaminen. Toisin sanoen kuvien ei tarvitse olla identtisiä, kunhan kuvattu henkilö on aina samoin päin kuvassa. Aiemmin mainitun rakenteellisen tunnistuksen käyttö ei ole tässä kovinkaan käyttökelpoinen luomien samoiksi varmistamiseen, sillä luomi saattaa muuttua paljonkin kuvauskertojen välillä.

3 KUVAUS JA ALGORITMIT

3.1 Kuvausolosuhteiden vaikutukset analyysiin

3.1.1 Valaistus ja intensiteetti

Valaistus vaikuttaa kuvankäsittelyssä suoraan intensiteettiin. Sen vaikutusta voidaan minimoida käyttämällä väriin pohjautuvaa laskentaa mahdollisimman vähän. Kuitenkin esimerkiksi tässä projektissa täytyy VARO-säännön mukaisesti analysoida luomen väriä, joten se täytyy ottaa huomioon. Voimakkaat valaistuksen muutokset voivat vaikuttaa kuvan histogrammiin merkittävästi. Jos riittävän suuri määrä pikseleitä tummenee tai vaalenee liikaa, se voi johtaa joko pikselien määrän muutokseen suhteessa intensiteettiin tai tietyn intensiteetin määrän kasvuun kuvassa. Tämä hankaloittaa sekä analyysia että segmentointia, sillä selkeästi histogrammissa toisistaan erottavien objektien sijaan saattavat intensiteetit tulla hyvin lähelle toisiaan, joten objektin reunan havaitseminen voi hankaloitua merkittävästi. Tällöin myös luomesta havaitaisiin väärin värissä tapahtunut muutos, joten vertauskelpoisuuden vuoksi tulee valaistuksen olla mahdollisimman standardi. (1, s. 596–597.)

Huonon valaistuksen vaikutuksia voidaan jossain määrin korjata objektin alakuviin jakamisella, jolloin tunnistuksen raja-arvo olisi jokaiselle alakuvulle eri, mitä kutsutaan adaptiiviseksi raja-arvoistamiseksi. Tällöin himmeänkin objektin osan ja sen reunan havaitseminen helpottuu, ja erikseen havaituista alakuvien osista voidaan kasata kokonaisobjekti. (1, s. 600.) Analyysin kannalta tämän objektin väri voitaisiin myös tasoittaa ja käsitellä suhteessa aiempiin kuviin, mutta varmasti vertailukelpoisen kuvan aikaan saaminen ilman informaation katoamista tai muuttumista voi silti olla vaikeaa, joten tämä tilanne on aina parempi ennaltaehkäistä.

Projektin nykyisessä vaiheessa käytetyssä tiukkoihin väriparametreihin perustuvassa segmentoinnissa sen merkitys on tietysti vielä suurempi, sillä liian tummassa kuvassa objekti ei välttämättä erotu ja jää havaitsematta tai siitä havaitaan vain osa. Jos luomen reunoista jää osa pois liian voimakkaan valaistuksen nostaessa niiden intensiteetin liian ylös, luomen pinta-ala ja halkaisija eivät näy oikein. Samoin reunojen tunnistus kärsii, sillä ne alkavat näyttää liian epäsäännöllisiltä. Riskinä on myös, että lähempänä ihon sävyä olevien kohtien jäädessä pois segmentoinnista luomi näyttääkin koneelle usealta pieneltä luomelta kuvassa 4 esitetyllä tavalla. Tämä voi myös johtaa siihen, ettei koko luomea havaita.




KUVA 4. Intensiteetin vuoksi väärin segmentoitu luomi (7)

Koska ihon sävy kuitenkin vaihtelee voimakkaasti, ja varsinkin luomien ympärillä intensiteetissä on paljon vaihtelua, ei pelkkään väriin pohjautuva segmentointi ole kovin toimiva ratkaisu. Niinpä väri soveltuukin paremmin reunojen tunnistukseen perustuen intensiteetin nopeisiin muutoksiin vierekkäisten pikselien välillä. (Yksinkertaisia objekteja ja kuvia, kuten binäärikuvia, käsitellessä sitä voidaan käyttää helposti koko objektin havaitsemiseen ja käsitteilyyn (1, s. 335–338, 66).

3.1.2 Kuvattavan asento

Kuvattavan asennolla on kaksi vaikutusta. Ensimmäinen on, että luomi näkyy aina jotakuinkin samasta kulmasta, mutta tärkeimpänä on vertauksen kannalta se, että luomet havaitaan aina samassa järjestyksessä. Luomet haetaan aina ensisijaisesti ylhäältä alas ja toiseksi vasemmalta oikealle järjestyksessä kuvasta, kuten kuvassa 5, joten erilainen käsien asento tai eri päin seisominen voivat vaihtaa luomien sijaintia kopissa muodostetussa pano-raamakuvassa. Näinpä henkilön asento on kopissa myös standardi, jotta samat luomet tulevat aina segmentoinnissa samassa järjestyksessä vastaan. Tietysti jos potilaalle muodostuu uusi luomi kuvauskertojen välillä, se sekoittaa järjestyksen. Tämän ehkäisemiseksi tulisi jatkokehityksessä varmistaa tallennettujen luomien määrän olevan sama kuvauskertojen välillä. Mikäli ei, tehdään sen perusteella tarkistus, mikä luomi on mikäkin, esimerkiksi lähimpien koordinaattien perusteella, ja sijoitetaan uusi luomi viimeiseksi taulukkoon.




KUVA 5. Luomien segmentointijärjestys

Asento vaikuttaa kuvauskulmaan luonnollisesti siten, että luomen jäädessä liian voimakkaasti sivuprofiiliin sen koko näyttää koneelle erilaiselta kuin todellisuudessa, mikä on jälleen yksi syy algoritmien toiminnan kannalta minimoida kotikuvauksessa väistämättä vastaan tuleva inhimillinen tekijä käyttämällä kuvauskoppia.

3.1.3 Etäisyys

Etäisyys kamerasta vaikuttaa suoraan siihen, miten ohjelma voi tulkitta mittakaavan. Etäisyys voidaan saada etäisyysantureilla luonnollisesti tarkasti mitattua ja siitä voidaan johtaa mittakaava. Se ei kuitenkaan ole ainoa vaihtoehto, sillä mittakaava voidaan selvittää käyttämällä suhteellisuutta hyväksi eli hyödyntämällä ihmisen vakituisia ominaisuuksia, kuten silmien väliä kuvassa, johon voidaan suhteuttaa kuvassa näkyvät luomet. Myöskin tarpeeksi kattavan potilastietokannan avulla pystyttäisiin hakemaan potilaan pituus, johon luomien koon voi suhteuttaa hyvin tarkasti. Harkinnan arvoisia vaihtoehtoja siis on, ja osa voi lopulta olla yksinkertaisuudestaan huolimatta varsin kilpailukyisiä hienostuneemmille ratkaisuille.

Kun ohjelmalle annetaan mittakaava, jolla ilmaista kutakin pikselimäärää, tulee objektin olla aina asetetulla etäisyydellä kamerasta tai mittakaava alkaa vääristyä. Tässä työssä esimerkiksi yhtenä parametrina on VARO-säännön mukainen halkaisija, joka ei saa olla suurempi kuin 6 mm (2. s. 20). Jos kuvattava kohde viedään kamerasta esimerkiksi 2 m:n päähän ja ohjelma käyttää staattista etäisyyttä 1 m, luomi näyttää ohjelmalle kaksi kertaa pienemältä kuin se oikeasti on. Tämä on yksi syy siihen, miksi projektissa on päädytty kotikuvauksen sijasta standardin kuvauskopin ehdottamiseen terveyskeskuksen omahoituhuoneeseen, sillä kotikuvauksissa ihminen voi ottaa kuvan miltä etäisyydeltä tahansa, eikä mikään luomen kokoa mittaava algoritmi siten tuottaisi vertauskelpoisia tuloksia. Lisäksi isommalla pikselimäärällä esitetystä kohteesta voidaan selvemmin erottaa yksityiskohtia, kuten kuvassa 6.



KUVA 6. Etäisyyden vaikutus (8)

Kopissakin luonnollisesti pätee vielä se tosiasia, että ihmiset ovat eri kokoisia ja siten luomet eivät ole aina samalla etäisyydellä kamerasta. Koppi kuitenkin mahdollistaa ratkaisuja, joita kotikuvaus ei mahdollista, kuten etäisyydsanturi- en tai suhteuttamisen käytön kaikkien potilaiden kuvauksessa. Niillä ohjel- malle voidaan kertoa, millaista mittakaavaa käyttää milloinkin.

3.2 Objektin ominaisuuksien käsittely

Kun objekti on onnistuneesti havaittu, on se merkittävä ja sen ominaisuudet mitattava. Monille ominaisuuksille on Matlabissa suoraan niitä mittaavat toi- minnot, mutta esimerkiksi objektin histogrammin luomisessa ja käsittelyssä täytyy maskata kaikki objektin ulkopuoliset pikselit siten, etteivät ne jakaannu käsiteltävien pikselien kanssa histogrammiin.

Maskaus tarkoittaa yleensä kahden kuvan intensiteettien toisistaan vähen- tämistä, jolloin vähennettävä kuva toimii maskina ja poistaa vähennettävästä kuvasta ei-halutun informaation. Siten kuvassa vahvistetaan informaatiota, jota halutaan tarkastella. (1 s. 111) Maskaus voidaan tehdä muillakin tavoin,

kuten luomalla segmentoinnista binäärikuva ja kertomalla sillä alkuperäinen harmaasävykuva. Tällöin segmentoidut pikselit pysyvät yhdellä kertomisen vuoksi ennallaan ja kaikki muu muuttuu nolalla kertomisen vuoksi tasaiseksi mustaksi eli intensiteetti arvoon 0, mikä on helppo eristää.

Kun ominaisuudet on saatu muistiin, pitää niillä vielä tehdäkin jotain, sillä ominaisuuksista kone ei voi suoraan sanoa, onko luomessa jotain hälyttävää. Niinpä jo mainitun mittakaavan antamisen lisäksi on kehitettävä säännöt, joilla ominaisuuksista saadaan ulos tuloksia, jotka ovat ihmiselle luettavissa ja helposti löydettävissä.

Haaste tässä on, että jotkut parametrit ovat objektin ominaisuuksista vaikeampi havaita. Niinpä sen lisäksi, että algoritmeille tehdään testejä virheiden ja toimivuuden suhteen, on myös testattava, kuinka hyvin algoritmit pystyvät todellista kohdetta analysoidessaan vastaamaan todellisuutta eli on muodostettava korrelaatiokertoimet mittaamaan, kuinka luotettava mikäkin algoritmi on ja millaisilla raja-arvoilla.

3.3 Algoritmit

3.3.1 Pääohjelma

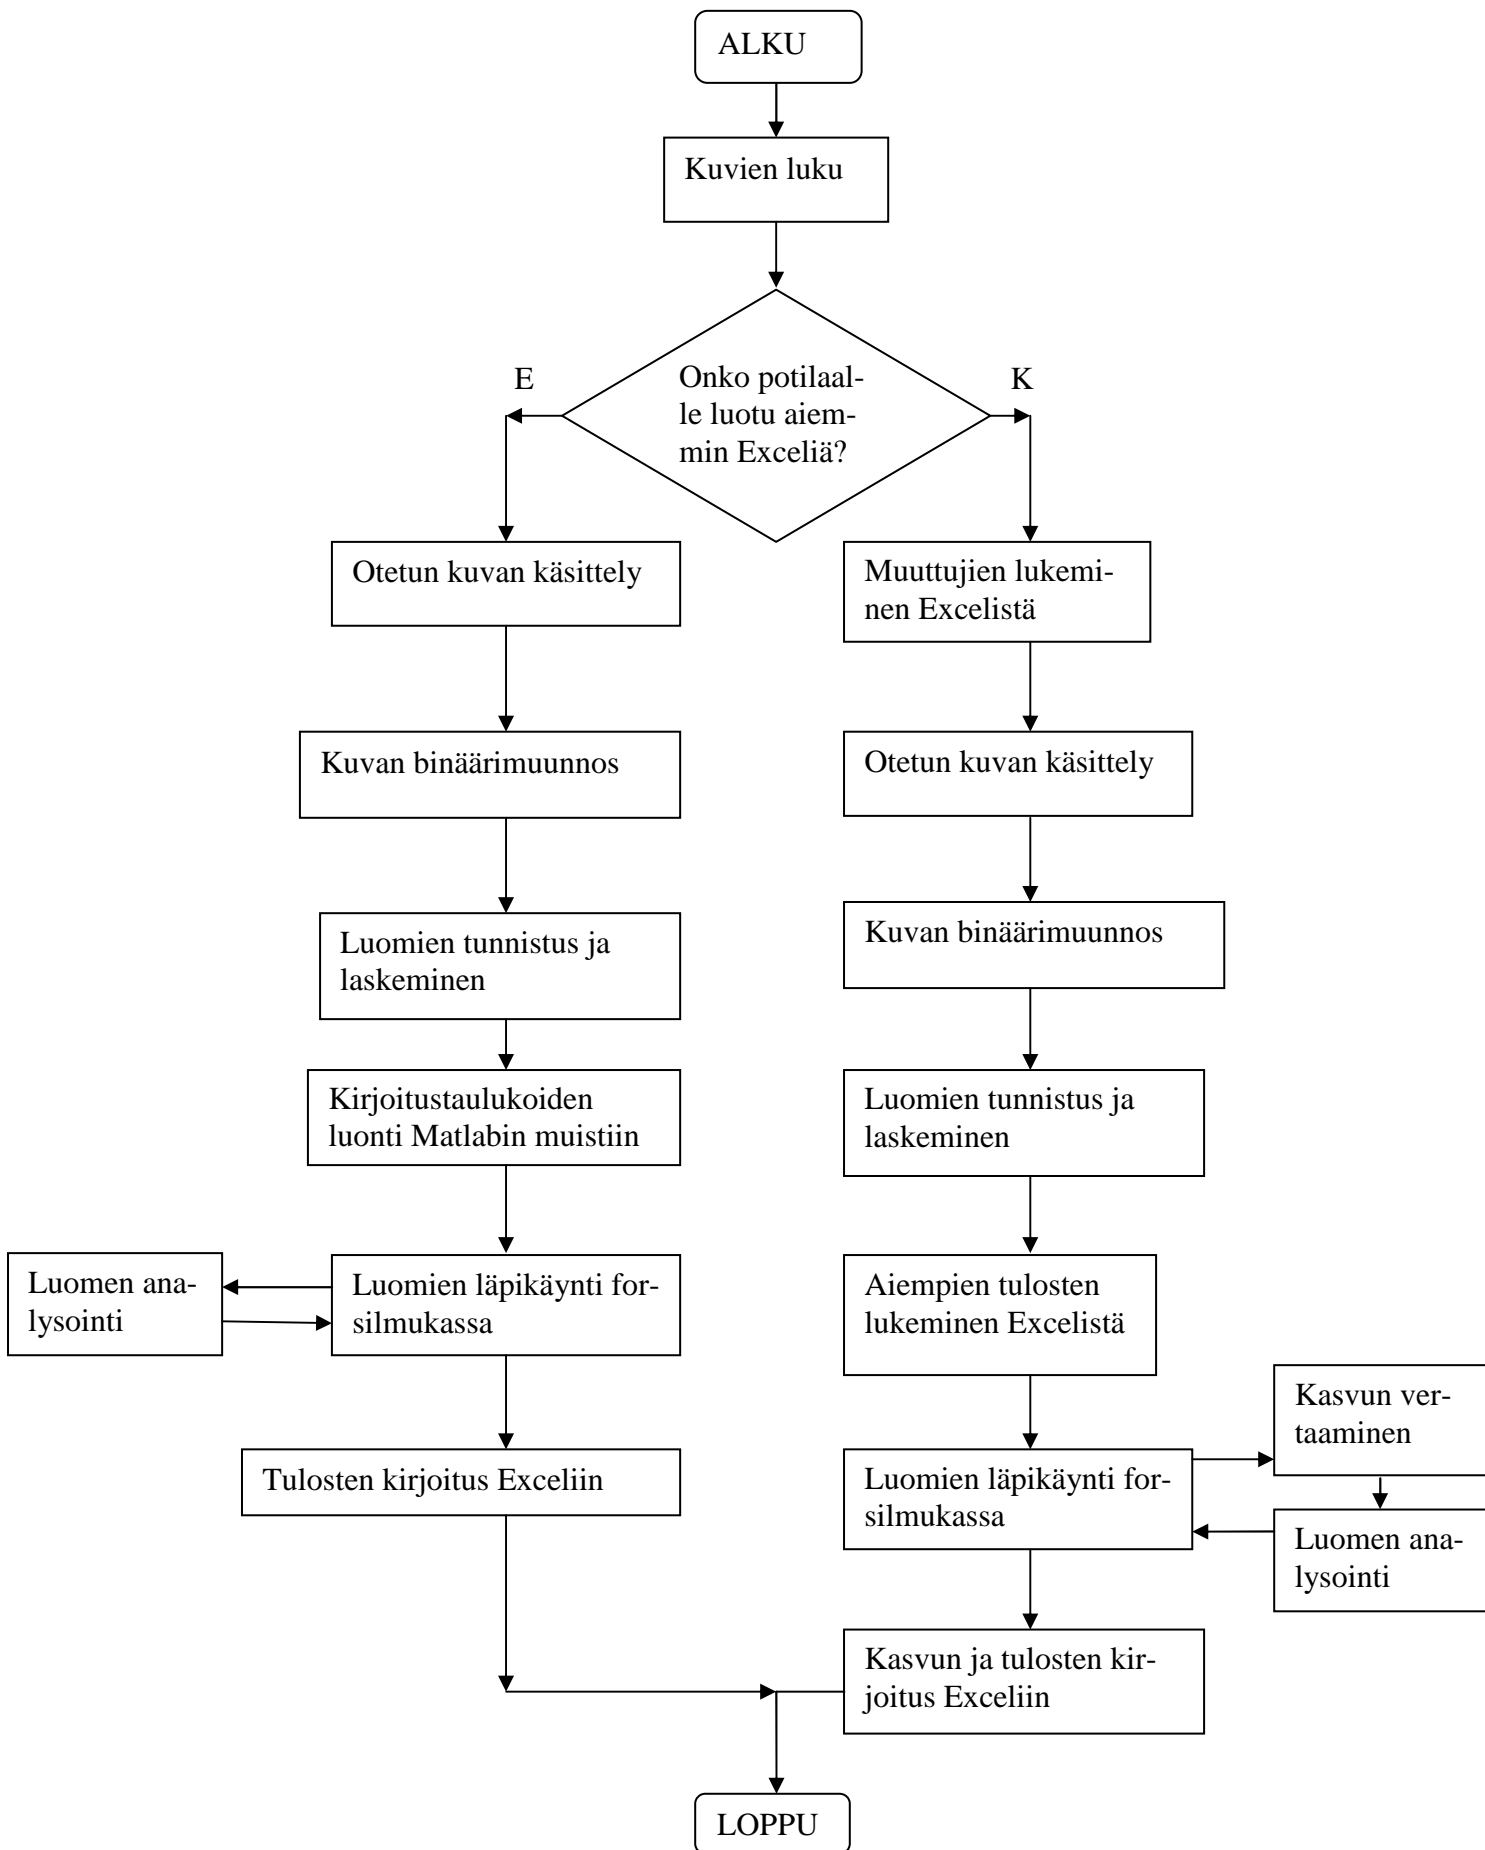
Luomet.m

Kaikki algoritmit ajetaan pääohjelmasta, joka on nimeltään luomet.m. Varsinaiset algoritmit on erotettu kahdesta syystä:

1. Ohjelma ajetaan Labviewin Matlab Scriptillä (Labview versio 2011), johon syötetään nimenomaan tämä kaiken ajava pääohjelma. Testauksessa kävi selväksi, että tämän ohjelman pitäisi olla mahdollisimman kevyt, sillä ison ohjelman ajaminen suoraan Labviewissa käytännössä jäädyttää koko ohjelman suorituksen. Näinpä kaikki algoritmit ja jopa alun kuvan käsittelyt ovat suorituksen keventämiseksi omissa skripteissään, jotka suoritetaan pääohjelmassa run-komennolla.

2. Vaikka Labviewin Matlab Script toimiikin paljon paremmin kuin Mat Script, jossa lähes kaikki komennot aiheuttavat ongelmia, ei senkään toiminta ole täydellistä. Matlab Scriptiin laitettu Matlab-ohjelma ei osaa Labviewin kautta suorittaa tarvittavia Excel-taulukon luku- ja kirjoitus-toimintoja, joten kaikki lukeminen ja kirjoittaminen niihin on pakko suorittaa aliohjelmissa.

Kuvan 7 mukaisesti pääohjelma tarkistaa, onko analyysia tehty aiemmin, tarkistamalla, onko luomet.xls-tiedostoa olemassa. Mikäli ei ole, ohjelma suorittaa tarvittavat alkuanalyysit ihon sävyille, kuvan koolle jne. ja ohittaa vertaus-algoritmit. Mikäli luomet.xls löytyy, ohjelma suorittaa luomien analyysit ja tekee aiempien luomien koko- ja tummuusinformaation perusteella vertaukset näistä muutoksista.




KUVA 7. Pääohjelman lohkoakaavio

3.3.2 Luomien käsittely ennen analyysia

Alkukasittely.m

Kuvassa 8 esitetyllä tavalla alkukäsittelyssä RGB-kuvasta erotetaan R-kanava (RGB-kuvan Red-kerros). Tämä tehdään siksi, että R-kanavalta luomen intensiteetti-informaatio on selkein. Alkuperäisessä suunnitelmassa kuva muutettiin negatiivikuvaksi kasvun esittämiseksi kasvavana, mutta projektin edetessä tämä ei ole enää tarpeellista. Negatiivimuunnos on kuitenkin jätetty ohjelmaan, koska se tekee luomien tarkastelusta mielekkäämpää testaamisen kannalta, sillä vaaleita objekteja on helpompi tarkastella silmällä kuin kirkkauden ympäröimiä tummia objekteja. Mitään laskennallista merkitystä sillä ei kuitenkaan ole. Lopuksi lasketaan kuvan kirkkauden keskiarvo, josta saadaan laskettua raja-arvo sille, kuinka kirkkaita objekteja kuvasta valitaan, sekä kuvan koko myöhempää käyttöä varten.



KUVA 8. Kuvan negatiivimuunnos (värikuva → R-kanava → negatiivi) (8)

Alkubinaarimuunnos.m

Binäärimuunnos muuttaa kuvan binäärimuotoon eli valitut alueet muuttuvat arvoon 1 ja muut arvoon 0. Kuvassa 9 arvon 1 saaneet pikselit ovat valkoisia ja arvon 0 saaneet mustia. Tämän lisäksi skripti korjailee objektiin mahdollisesti jäävät pikseliaukot, merkkää jokaisen objektin numerolla (labeledImage), hakee niistä kaikki ominaisuudet (regionprops) ja määrittää objektin maksimi- ja minimikoot pikseleinä.



KUVA 9. Luomen binäärikuva. Luomeksi havaitut pikselit arvossa 1 (valkoinen), havaitsemattomat 0 (musta) (alkuperäinen kuva (9)).

Alku/vertausmaara.m

Alku/vertausmaara.m-skriptit laskevat luomien määrän kuvasta ja tulostavat havaituista luomista kuvan, jossa ne näkyvät ja niiden päällä on punaisella värillä oleva numero, joka näyttää, mikä mikäkin luomi on. Käytetty skripti valitaan pääohjelman kuvauksen mukaisesti kuvauskerran perusteella.

Alku/vertausmatriisit.m


Alku/vertausmatriisit.m-skriptit alustavat matriisit, joihin mittaustulokset kirjoitetaan nolliksi. Tämä tehdään siksi, ettei kirjoittamista Excelliin tarvitse tehdä kuin kerran ja käsittelyn aikana muuttuvat matriisit voidaan pitää Matlabin muistissa.

3.3.3 Luomien käsittely


Tästä eteenpäin ohjelma suorittaa luomia käsittelevät algoritmit alun käsittelyssä saaduilla arvoilla merkatuille binäärikuville. Luomet käydään läpi yksi kerrallaan erottamalla ne imcrop-komennolla kokokuvasta, jolloin jokainen voidaan käsitellä ilman muiden luomien vaikutusta mittauksiin.

Kasvuvertaus.m

Tämä skripti vertaa ensimmäisellä analyysikerralla saatua luomen pikselien määrää samaan luomeen myöhemmin. Kuvassa 10 on esitetty, miten pikselien määrä lasketaan. Mikäli luomen koko poikkeaa ensimmäisestä, voidaan sen nähdä kasvaneen. Tämän skriptin tarkoitus on ensisijaisesti muodostaa dataa, jolla voidaan piirtää seurantakäyrää luomen kasvusta suhteessa aikaan, kuten kuvassa 11 on esitetty.




KUVA 10. Havaittu objekti (vasen), jonka pinta-ala on 45 pikseliä (oikea) 16 x 16 resoluution kuvassa



*KUVA 11. Luomen kasvu pikseleinä kuvauskertojen välillä
 X-akseli = kuvauskerta
 Y-akseli = kasvua vastaavien pikselien määrä*

Alku/Vertaushalkaisija.m

Regionprops-komennolla saadaan haettua luomen reunojen äärikohtat, joista haetaan koordinaattien perusteella suurin etäisyys kahden koordinaattipisteen välillä eli halkaisija, kuten kuvassa 12 on esitetty. Kunhan projekti etenee, voidaan nämä pikselit sitten muuttaa kuvan mittakaavan mukaan ihmiselle luettavaan muotoon. Tässä insinööriyössä tavoitteena olisi saada mittakaavan avulla nähtyä korrelaatiokerroin siitä, kuinka hyvin tämä vastaa luomen todellista halkaisijaa.



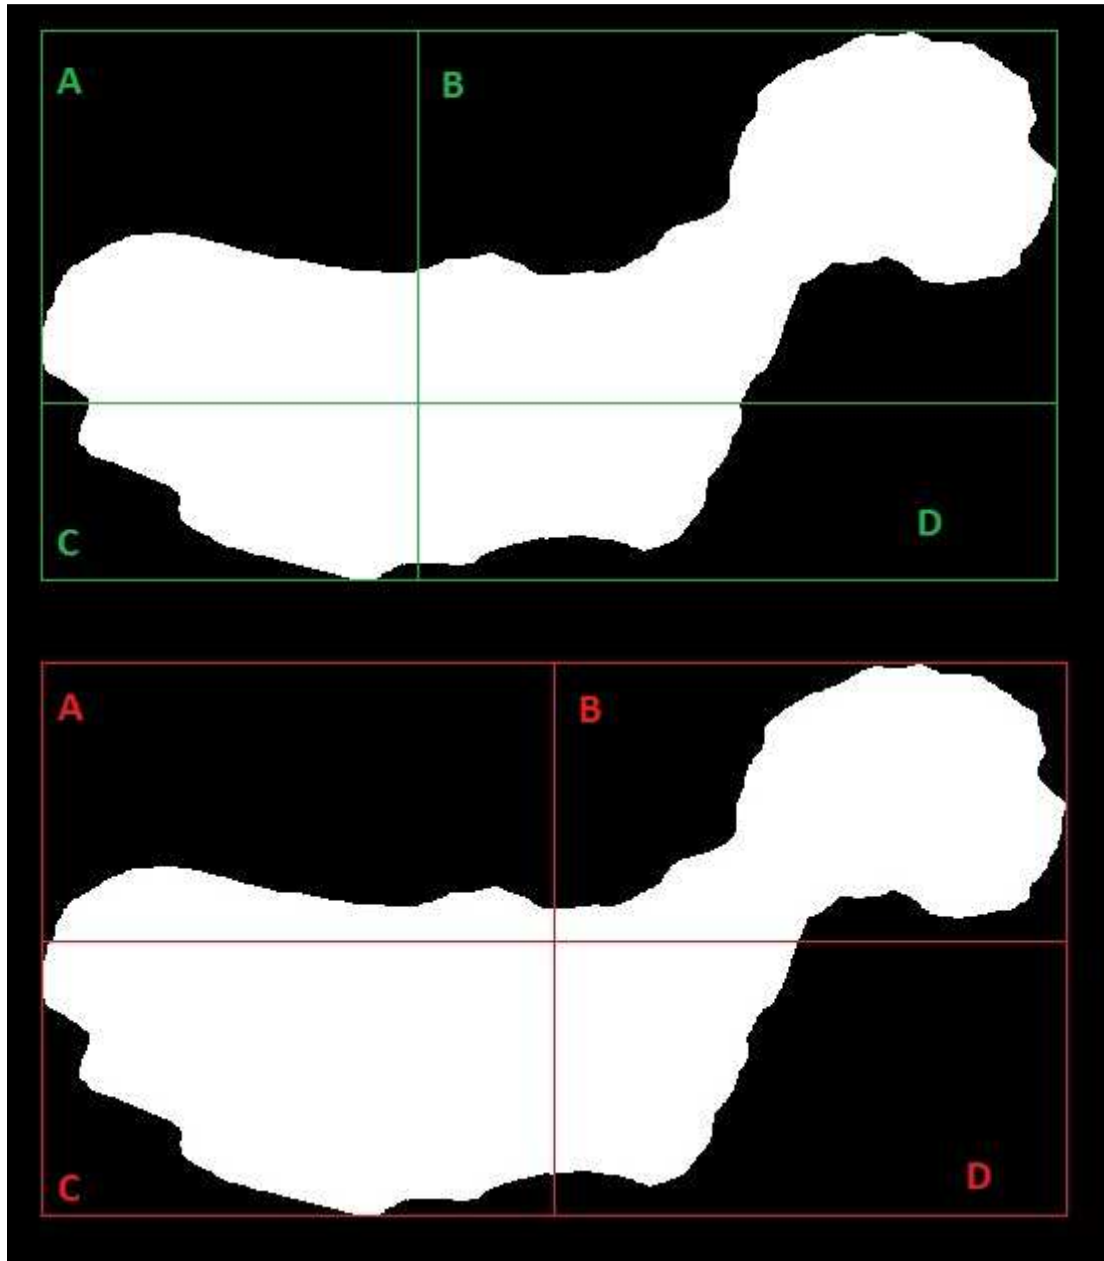
KUVA 12. Objektin halkaisijan mittaaminen (alkuperäinen kuva (9))

Alku/Vertaussymmetria.m

Alku/vertausymmetria.m-skriptit pilkkovat objektin neljään lohkokseen keskipisteestä. Tarkemmin sanottuna se tehdään kahdesti. Ensimmäinen laskelma tehdään luomen äärireunojen perusteella kuva 13 yläosan mukaisesti. Toinen tehdään arvioidun alkuperäisen keskipisteen perusteella, joka mitataan äärireunojen keskipisteen perusteella siirtämällä se keskelle vaakasuunnassa kuvan 13 alaosaan mukaan. Kummassakin lasketaan neljän lohkon sisältämien luomen osien koko pikseleinä ja summataan niitä yhteen sen mukaan, tehdäänkö pysty- vai vaakasuunnan symmetrian mittaaminen. Luomen koosta lasketun raja-arvon avulla lasketaan, ylittääkö jokin puolikkaista sallittu rajan. Jos esimerkiksi pystysuunnassa luomen yläosa on selvästi isompi kuin alaosa, voidaan päätellä, että luomi on epäsymmetrinen pystysuunnassa.

Esimerkkikuvassa 13 käytetty objekti on selkeästi epäsymmetrinen oikean reunan ulokkeen vuoksi. Kuitenkin kun kuvan 13 yläosan lohkoja tarkastellaan, huomataan, että sekä pysty- että vaakasuunnassa tunnistettujen pikselien (valkoinen) määrä jakaantuu voimakkaasti lohkoihin B ja C ja vähän lohkoihin A ja D. Tällöin vertauksessa on suuri riski, ettei epäsymmetriaa tunnistetakaan. Taas kuvan alaosan keskipiste on siirretty oletettuun alkupe- räiseen keskipisteeseen, jolloin nähdään, että lohko B on huomattavasti isompi kuin muut, joten se aiheuttaa puolikkaita verratessa varmasti epäsymmetrian havaitsemisen.

Kuvan 13 yläosan mukainen jako saattaa kuitenkin joissain tapauksissa tunnistaa epäsymmetrian paremmin kuin alaosan mukainen. Täytyy siis testata kumpi on parempi vai tuottavatko nämä parhaan tuloksen yhdessä.




KUVA 13. Luomen lohkoihin jako alkuperäisen (yllä) ja oletetun (alla) keskipisteiden perusteella

Syy kahden keskipisteen käyttöön on, että ne varmistavat toisiaan, sillä toiminnallisuustestauksessa selvisi, että toinen voi löytää selvän epäsymmetrian, kun taas toinen ei. Yleisesti alkuperäisen keskipisteen perusteella tehty oli toiminnallisuustestauksessa luotettavampi, mutta äärireunojen perusteella tehty jätettiin varmuuden vuoksi myös skriptiin. Se voi kuitenkin osoittautua turhaksi käytännössä, mikä myös pitäisi selvittää tämän työn yhteydessä.

Alku/Vertausvari.m


Alku/vertausvari.m-skriptit tutkivat, onko luomen väri epätasainen. Ne mas-
kaavat (ks. 3.2) alkuperäisestä kuvasta luomen halutut intensiteettikohdat
erilleen muuttamalla kaiken muun arvoon 0 kuvan 14 esittämällä tavalla.

Tämän jälkeen luomen intensiteeteistä tehdään histogrammi. Histogrammis-
ta otetaan eniten esiintyvä intensiteetti-arvo ja jaetaan se, jolloin saadaan ta-
saisin välein rajakohtia, joista voidaan tarkistaa, miten intensiteetit ovat ja-
kautuneet milläkin pikselien määrällä.



KUVA 14. Maskattu luomi (alkuperäinen kuva (9))

Nykyisellään korkein pikselien määrä jaetaan viidellä ja tarkistettuina rajakohtina käytetään korkeinta arvoa sekä 4/5 että 3/5 korkeimmasta arvosta. Algoritmi tarkastelee, onko milläkin rajakohdalla liikaa hajontaa (asetettu siten, että löydettyjen intensiteettien erotus ≥ 10) pikselien intensiteettien välillä. Jos siis 4/5 kohdalta löytyy 5 sen ylittävää intensiteettiarvoa, katsotaan ovatko ne lähekkäin vai etäällä toisistaan. Jos ne ovat selvästi erillään, voidaan päätellä että luomen väri on selvästi epätasainen. Kuvassa 15 on esitettyinä nämä rajakohdat ja ne leikkaavat intensiteettiarvot on ympäröity punaisella. Kuvasta voidaan nähdä, ettei missään kohdassa ole selviä "rotkoja" havaittujen intensiteettiarvojen välillä, vaan ne ovat tiiviisti vierekkäin. Voidaan siis päätellä, että kuvan 14 luomen väri on tasainen.



KUVA 15. Kuvan 14 maskatun luomen histogrammi tarkistuskohtineen

Toinen mitattava asia histogrammista on myös, ettei tarkastuskohdissa ole liikaa intensiteettiarvoja, sillä jos esimerkiksi kuvan 15 histogrammissa olisi kohdassa 3/5 100 kappaletta sen suuruisia tai suurempia intensiteettiarvoja, voitaisiin myös sanoa, että sävyjä on 0–255 intensiteettiskaalaan ja mitattavaan kohtaan nähden paljon eli väri olisi epätasainen, vaikkei siitä aiheutuisikaan histogrammiin selviä piikkejä. Kuvassa 15 kohdassa 4/5 on 20 arvoa ja kohdassa 3/5 49, joten ne eivät muodosta erityisen leveitä intensiteettivektoreita.

Alku/Vertausreunat.m

Tämä skripti tarkistaa ovatko luomen reunat epätasaiset. Se laskee luomen äärireunojen perusteella, kuinka pitkä luomen ympärysmitta tulisi olla, ja sitten vertaa luomen todellista ympärysmittaa siihen. Jos se on pidempi kuin arvioitu ympärysmitta + raja-arvo, voidaan päätellä, että reunat ovat epätasaisia liian suuren pituuden vuoksi. Jos reuna on epätasainen, skripti tulostaa 1, jos ei, niin 0.

3.4 Keskeneräiset asiat

Skripteissä on insinööriyöhön käytettävissä olleen rajallisen ajan vuoksi vielä luonnollisesti puutteita, jotka eivät kuitenkaan vaikuta tämän työn suorittamiseen, mutta jotka on hyvä pitää mielessä jatkokehitystä ajatellen:

- Värien epätasaisuuden optimointi muistin allokoinnilla ja yleisesti skriptien optimointi siltä osin kuin mahdollista on tekemättä.
- Tavoitteena oli, että ohjelma kirjoittaisi ensimmäisellä kuvauskerralla kaikki algoritmeissa tarvittavat muuttujat Excel-taulukoihin, mutta tätkään ei ajan puitteissa ehditty saada loppuun. Ohjelmassa on tällä hetkellä kirjoitus ja luku luomen tummuuden raja-arvolle, kuvan koolle ja alkuperäisen kuvan intensiteetin summalle. Luku on kuitenkin pääohjelmassa, missä se ei toimi Labviewissa, vaikka se Matlabissa testattaessa onkin aivan toimivaa. Ne siis tulisi siirtää omaan skriptiinsä.

Ennen kaikkea ensimmäisen analyysin antamat luomien koot tulisi sekä kirjoittaa että lukea Excelistä kasvuvvertausta varten, mitä ei edes ehditty ajan puitteissa aloittaa. Nämä tulisi tehdä siksi, että ohjelman ei tarvitsisi turvautua missään tilanteessa Matlabin omiin muuttujiin eri kuvausten välillä, vaan ne voitaisiin aina tyhjentää Matlabin muistista ja hakea sitten tarvittaessa Excelistä.

3.5 Testaaminen

Tämän insinööriyön puitteissa testataan seuraavia asioita:

- korrelaatiokerroin halkaisijan ja kasvun vertaamisen tulosten ja todellisuuden välillä
- sensitiivisyys- ja spesifisyysarvot symmetrian, värin tasaisuuden ja reunojen säännöllisyyden tunnistuksesta
- algoritmien raja-arvojen testaaminen, jotta ne saadaan asetettua parhaiten toimivalle arvolle
- epäsymmetrian analysoinnissa tarkastelua siitä, tarvitaanko molempien keskipisteiden perusteella tehtyä analyysia vai riittääkö vain toinen
- tarkastelua värin tasaisuudessa käytetyistä kahdesta erilaisesta tunnistuksesta
- segmentoinnin luotettavuus siinä määrin, kuinka paljon sitä täytyy avustaa kiinteillä arvoilla
- lopullisista tuloksista virheen suunta (väärin tunnistettu vai tunnistamaton eli sensitiivisyys ja spesifisyys) ja mistä se johtuu.

Työssä ei testata:

- kuvausjärjestelmän prototyyppiä (ks. 4.1)
- algoritmien nopeutta, koska optimointia ei ole ehditty tehdä.

4 TYÖN SUORITTAMINEN

4.1 Lähdemateriaalin hankinta

Kuvamateriaalin hankinnassa pyrittiin tekemään ensisijaisesti yhteistyötä OAMK:n SOTE:n kanssa sekä Pohjois-Pohjanmaan sairaanhoitopiiriin (PPSHP) eli käytännössä OYS:n kanssa. Tämän lisäksi otosta tuli täydentää Internetistä löytyvällä materiaalilla.

SOTE:lla ei itsellään ole yhteys henkilön mukaan kuvia melanoomasta, vaan he käyttävät opetustarkoitukseen Internetistä löytyvää materiaalia, joka on mukana tähän työhön otetuissa kuvissa annetun lähteen perusteella. PPSHP:stä yhteys henkilöitä löytyi kaksi. Heistä toinen oli yhteys henkilö tämän insinööriyön pohjana olleessa insinööriyössä ja ottamalla yhteyttä alkuperäisen työn tekijään sain kyseisen lääkärin numeron. Valitettavasti useista soittoyrityksistä huolimatta yhteyttä häneen ei saatu. Toinen henkilö löytyi työn tekoon nähden suhteellisen myöhään vasta aivan lokakuun lopussa. Häneen olin sähköpostitse yhteydessä ja hän välitti tiedot eteenpäin tarvittaville henkilöille selvittääkseen, onko kuvamateriaalia antaa ja jos ei ole, voitaisiinko kuvia ottaa ja saadaanko niiden luovutukseen lupa. Valitettavasti työn valmiin version luovutuspäivänmäärään mennessäkään kuvista ei ole kuulunut mitään, joten nekin jäivät pois tämän työn otoksesta.

Lopullisesti siis kuvamateriaali koostuu erinäisten lääkärin ja lääketieteellisten sivustojen kuvista ja kokonaisuudessaan otos on noin 145 Internet-kuvaa. Tuo määrä on hyvin pitkälle kaikki kuvat, jotka erinäisiä melanoomaan liittyviä hakuja tekemällä löytyvät ja jotka kelpaavat työn tarkoitukseen. Kaikkia kuvia ei voitu kelpuuttaa otokseen niissä olevien puutteiden tai ominaisuuksien vuoksi. Liian huonolaatuisia tai pieniä ei luonnollisesti voitu kelpuuttaa, tai kuva oli otettu esimerkiksi liian voimakkaasti sivuprofiilista.

Testeissä päädyttiin käyttämään valmiita Internet-kuvia, koska työtä tehdes-
sä projektin tavoitteena olevaa kuvauskoppia ei vielä ole. Kuvauksen ja ar-
kistoinnin kehittämiseen tarkoitettu prototyyppi sen sijaan on. Se on toteutet-
tu siten, että n. 50 cm x 50 cm:n alustan päällä olevaan telineeseen on
kiinnitetty kaksi kameraa osoittamaan alustaa kohti. Sen tarkoitus on tällä
hetkellä avustaa kuvausjärjestelmän (kuvanotto, toiminta Matlabin kanssa ja
panoraaman muodostus) ja potilastietokannan hallinnan kehittämisessä eikä
niinkään toimia vielä lopullista kuvausta vastaavana fyysisenä kokonaisuute-
na. Tämä rajoittaa käyttöä sen suhteen mistä kuvia voidaan sillä ottaa, mutta
esimerkiksi käsivarret olisivat mahdollisia kuvata.

Järjestelmän käytössä tässä työssä on kuitenkin kaksi ongelmaa:

1. Algoritmien testaamisen kannalta otoksen saatavuus, sillä kuvattavaksi pitäisi saada huomattava määrä ihmisiä, sekä terveitä että melanoomaa sairastavia, jotta otoksesta tulisi tarpeeksi laaja. Varsinkin melanoomapotilaiden saaminen riittävässä määrin kuvattavaksi olisi käytännössä mahdotonta ainakin projektin ollessa vielä näin alkuvaiheessa, sillä yhteydenotoissa OYSiin on käynyt selväksi, ettei kuvien ottaminen potilaista ole heillekään yksiselitteistä.
2. Oltuani yhteydessä kuvausjärjestelmää opintojensa yhteydessä projektina työstävään opiskelijaan kävi ilmi, että kuvausjärjestelmän toiminnassa on ongelma tietojen Excel-taulukkoon kirjoittamisessa. Se kirjoittaa laskennassa käytetyt muuttujat, muttei analyysien tuloksia, joten sen käyttö ei ole tätä työtä tehdes-
sä valitettavasti lainkaan mahdollista. Onneksi algoritmeja kuitenkin voidaan käyttää itsenäisesti, joten tämä ei estä työn tekemistä täysin.

4.2 Mittausjärjestelyt

Saaduille kuville tuli tehdä kuvankäsittelyllisiä muokkauksia tarpeen mukaan ennen varsinaisten kuvausten aloittamista. Niistä täytyi esimerkiksi poistaa analyysien kannalta tiellä olevia objekteja, kuten viivoittimia. Tämän lisäksi kuvan käsittelyn avulla kuvista voidaan mitata luomen halkaisijan kaltaisia ominaisuuksia, jotta niitä voidaan käyttää lopullisessa analyysissä katsottaessa halkaisijamittauksen luotettavuutta.


Saaduissa kuvissa on kussakin erilaisia melanooman oireita, jotka sopivat VARO-säännön määrittelyihin. Jotta niitä voidaan käyttää algoritmien testauksessa, täytyy alkuperäisille kuville tehdä halkaisijan, reunojen, symmetrian ja värin epätasaisuuden mittauksia ja luokituksia.

4.2.1 Halkaisija

Halkaisijan tunnistuksen korrelaatiokertoimen laskemiseksi on kuvista ensin mitattava käsin niiden halkaisijat, jotta niitä voidaan verrata algoritmeilta saatuihin. Koska korrelaatiokertoimen saamiseksi ei ole väliä, lasketaanko halkaisijat kuvista pikseleinä vai ihmisen ymmärtäminä mittoina, tehdään tämä analyysin helpottamiseksi ja tarkkuuden parantamiseksi pikseleillä. Varsinainen pikselihalkaisijan mittaus on tehtävä rajaamalla kuvasta luomen levein väli. Koska minulle käytettävissä olevilla ohjelmilla kuvasta voidaan saada suoraan vain leveys ja korkeus, on ensin kuvasta rajattava osa, jossa rajauksen mitoituksi tulee levein ja korkein kohta luomesta, ja sitten laskettava siitä varsinainen halkaisija Pythagoraan lauseella (kaava 1), kuten kuvassa 16.

$$c = \sqrt{a^2 + b^2}$$

KAAVA 1. Pythagoraan lause



KUVA 16. Halkaisijan laskenta (pohjakuva (7))

4.2.2 Symmetria, reunat ja väri

Symmetriassa, reunoissa ja värissä ongelmana on, ettei niistä voida tehdä halkaisijan tapaan suoraan manuaalista mittausta verrattavaksi algoritmeihin. Niinpä nämä kolme ominaisuutta tulee luokitella sen mukaan, mitä ominaisuuksia niissä on. Tämä toteutetaan antamalla jokaiselle kuvalle kutakin ominaisuutta vastaava luokitus 0, 0,5 tai 1 kuvassa 17 esitetyn esimerkin tavalla. Jos esimerkkinä käytetään symmetriaa, luomelle, jossa ei ole epäsymmetriaa, annetaan luokitus 0, sellaiselle, jossa sitä selvästi on, annetaan 1, ja sellaiselle, josta ei voida varmasti sanoa, onko epäsymmetriaa havaittavissa, annetaan luokitus 0,5. Algoritmit tulostavat jo hyvin lähelle näitä luokituksia tulevia tuloksia ja pienellä muutoksilla niihin saadaan tulostettavat arvot tarvittaessa vastaamaan hyvinkin paljon tehtyjä luokituksia tulosten analysointia varten.



Halkaisija = 309 px

Symmetria = 0

Väri = 1

Reunat = 1

KUVA 17. Luomen luokitukset (esimerkkikuva (7))

4.2.3 Kasvu

Koska materiaalissa ei ole valitettavasti käytettävissä yhtään luomea, josta olisi otettu kuvia pidemmällä tähtäimellä, on kasvun seuraamisen testaamiseksi moisia kuvasarjoja luotava jo saaduista kuvista keinotekoisesti kuvankäsittelyllä. Tähän tarkoitukseen kuvista valitaan erilaisia VARO-säännön ominaisuuksia sisältäviä luomia, joista kustakin tehdään kuvasarja, jossa niissä tapahtuu erilaisia muutoksia. Osa muokataan kasvamaan, osa ei. Näin voidaan analyysien perusteella muodostaa testikäyrät, joista nähdään, vastaavatko luomille tehdyt muutokset käyrällä niille tehtyjä tai tekemättömiä kasvumuutoksia.

Lisäksi tätä voidaan käyttää myös laajentamaan muiden ominaisuuksien otosta. Kasvun myötä luomen halkaisija, reunat ja symmetria muuttuvat itsestään, jonka lisäksi kasvavat alueet voidaan toteuttaa muusta luomesta poikkeavalla sävyllä epätasaisen värin luomien kuvien tapaan. Näillekin ku-

ville luonnollisesti tehdään samat luokitukset kuin muillekin, vaikka ne eivät kuvankäsittelyn vuoksi täysin vastaakaan aitoja.

4.3 Testauksen suorittaminen

Testauksessa haetaan kullekin kuvalle sopivat segmentointiparametrit, jotta väärä tunnistus ei pääse vaikuttamaan analyysiin. Tunnistus koon ja värin perusteella tiedetään hyvin kankeaksi jo valmiiksi. Siksi useille kuville on asetuksia sen suhteen muutettava tai jopa avustettava kuvanmuokkauksella, jotta segmentointi tapahtuu oikein. Niinpä tunnistuksesta kirjataan vain mielenkiinnosta ylös, monessako kuvassa joitain muutoksia oli tehtävä vakioarvoista tai kuvaa muokattava luomen ympäriltä esimerkiksi varjojen suhteen.

Varsinainen analyysi ajetaan jokaiselle luomelle useamman kerran. Tämä johtuu siitä, että vaikka halkaisijan laskennassa ei ole muutoksen varaa, kunhan segmentointi onnistuu, niin symmetriassa, värin epätasaisuudessa ja reunojen epäsäännöllisyydessä käytetään raja-arvoja. Sopivan raja-arvon löytäminen kullekin on yksi testattavista asioista, ja lisäksi yhdellä raja-arvolla tehdyistä testeistä ei voida sanoa suoraan algoritmin luotettavuudesta, jos vakio raja-arvo on väärin asetettu. Useammilla raja-arvoilla tehdyistä testeistä sen sijaan voidaan sulkea sen vaikutus pois, kunhan paras arvo löytyy, ja siten antaa myös luotettava analyysi algoritmin toiminnasta.

Koska tuloksia tuli lukuisten raja-arvojen vuoksi valtava määrä, ne käsiteltiin ohjelmallisesti sekä ajan säästämiseksi että myös virheiden minimoimiseksi. Tätä varten tuli ohjelmoida erikseen sekä raakatulosten käsittelyohjelma että käsiteltyjen tulosten koostamisohjelma lopun tulostaulukoiden tekemiseksi, sillä koostaminen edellytti huomattavan paljon laskentaa tulosten ja luokitusten välillä.

Testejä tehdessä selvisi myös joitain algoritmeihin jääneitä virheitä ja ongelmia. Ensimmäinen oli, että huomattiin halkaisijan laskennassa käytetyn ominaisuuden olevan tarkoitettu vain ympyrän halkaisijalle ($\text{EquivDiameter} = 4 \cdot$

pinta-ala / π), joten sen laskenta ohjelmoitiin nopeasti uusiksi, missä lähinnä piti hetki miettiä, miten saada halkaisijan pisteiden x- ja y-koordinaatit objektiin äärireunojen sijaan.

Muita ongelmia ilmeni kuvissa, joissa oli useampi luomi. Ei ole selvää miten nämä eivät tulleet aiemmin ilmi, koska asiaa kuitenkin testattiin. Joka tapauksessa ongelmia tässä suhteessa ilmeni kaksi kappaletta.

Ensimmäinen huomattu ongelma on, että vaikka ohjelma tunnistaa ja merkkää luomet oikeassa järjestyksessä, se käsittelee ne väärin päin eli esimerkiksi luomet 1, 2, 3 ja 4 käsitellään järjestyksessä 4, 3, 2 ja 1. Tämä luo ongelman tulosten kirjoittamisen kannalta, sillä tulosten tulisi olla taulukossa siten, että ensimmäinen luomi on ensimmäisellä rivillä jne. Kuitenkin tässä järjestyksessä läpikäyminen kirjoittaa tulokset väärinpäin eli viimeinen luomi on ensimmäisellä rivillä ja ensimmäinen luomi viimeisellä.

Toinen ongelma oli paljon vakavampi ja luultavasti haastavampi korjata. Kun kuvassa on useampi luomi, ohjelma osaa irrottaa ensimmäisen (tai siis viimeisen) ja kirjata sen ominaisuudet analysoitavaksi. Tuloksiin alkoi kuitenkin kirjautua muiden luomien kohdalle outoja tuloksia, ja asiaa tutkimalla selvisi, että luomen irrotuksessa jostain syystä ensimmäisen luomen jälkeen ohjelma irrottaakin kunkin luomen yläkulmasta vain yhden pikselin kokoisen alueen. Esimerkiksi kaikki koordinaatit ovat (13,8), kun pitäisi olla (13,8), (13,60), (54,8) ja (54,60).

Kumpikaan yllä mainituista ongelmista ei vaikuttanut testien tekemiseen, sillä ne olivat kierrettävissä käyttämällä tunnistusta siten, että kuvissa, joissa oli useampi luomi, havaittiin niistä yksi kerrallaan ja yhdisteltiin tulokset lopuksi. Toisin kuin siis halkaisijan kohdalla, näitä ongelmia ei ryhdytty korjaamaan, koska ne eivät kierrettävyytensä vuoksi vaikuttaneet työhön, ja työn aikataulun puitteissa niiden ratkaisuun olisi saattanut kuluu suhteettoman paljon aikaa. Molemmat ovat luonnollisesti ongelmia, jotka tässä insinööriyössä on mainittava.

5 TULOSTEN ANALYSOINTI

5.1 Segmentoinnin analyysi

Tehdyissä testeissä vakioarvoina käytettiin kuvan intensiteetin keskiarvo + 10:tä ja luomen minimikokoa 2000 pikseliä sekä maksimikokoa 100 000 pikseliä. Alkuperäisestä kuvamateriaalista 60 % ei segmentoitunut oikein joko muuttamalla näitä arvoja suuntaan tai toiseen tai ilman täyttää ongelma-alueiden poistamista manuaalisesti.

Syitä on useita, joista itsestään selvin on tietysti luomen koko, sillä siinä missä jossain kuvassa minimikoon on oltava suurempi, jotta analyysiin ei tule mukaan ei-haluttuja objekteja, on joissain kuvissa sen oltava selvästi pienempi, jotta luomi voidaan havaita siitä.

Intensiteetti vaati paljon enemmän muokkaamista erilaisten varjostusalueiden ja luomen ympäröivien poistamiseen, eikä sekään aina riittänyt, vaan kyseiset alueet oli peitettävä täysin ennen kuin segmentointi onnistui. Kuvassa 18 jo hyvin lievästi alaosa tummempi yläosa riitti aiheuttamaan sen, että sen poistaminen poisti myös osan kuvan luomesta.



KUVA 18. Yläreunan varjostus (materiaalin kuva 61)(10)

Joissain kuvissa taas osa luomesta on intensiteettinsä puolesta hyvin vaikea erottaa terveestä ihosta, kuten kuvissa 19 ja 20, joissa luomen ympärillä oleva alue on vaikea saada käytetyllä segmentoinnilla kokonaan havaittua. Kuvassa 21 vasemman reunan vaalea alue on selvästi osa luomea, mutta hyvin vaikea erottaa ihosta.



KUVA 19. Ympärys 1 (materiaalin kuva 113)(11)



KUVA 20. Ympärys 2 (materiaalin kuva 141)(12)



KUVA 21. Epäselvä vasen reuna (materiaalin kuva 15)(11)

Luomi voi olla myös jakaantunut tummaan ja hyvinkin vaaleaan lohkoon, kuten kuvissa 22 ja 23.



KUVA 22. Puolikkaat 1 (materiaalin kuva 53)(12)

KUVA 23. Puolikkaat 2 (materiaalin kuva 94)(11)

Samoin joissain kuvissa luomen päälle tuleva ihokarvoitus tuli hyvin helpolla mukaan analyysiin, mikäli sitä ei poistettu luomen ympäriltä, kuten kuvassa 24 . Myös hiukset on saatava pois analyysistä, mikäli luomi sijaitsee niiden lähellä, kuten kuvassa 25.



KUVA 24. Ihon karvoitus (materiaalin kuva 93)(11)



KUVA 25. Hiukset (materiaalin kuva 116)(11)

Muitakin ongelmallisia luomia voi olla, joista osa enemmän analyysin kannalta, mutta ne voivat tuoda myös segmentointiin haasteen. Osa vaatii myös varmasti lääketieteellistä näkemystä, jotta ne osattaisiin segmentoida sekä analysoida oikein. Kuvissa 26–29 on muutamia esimerkkejä.



KUVA 26. Pigmentitön? (materiaalin kuva 89)(13)



KUVA 27. Mitä huomioidaan ja miten? (materiaalin kuva 42)(12)



KUVA 28. Korvalehdessä (materiaalin kuva 32)(11)



KUVA 29. Jälleen mitä huomioidaan ja miten? (materiaalin kuva 74)(14)

5.2 Korrelaatio, sensitiivisyys ja spesifisyys

Koska kyseessä on kuvaotos, lasketaan korrelaatiokertoimet otoskorrelaation kaavalla (kaava 2).

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}}$$

KAAVA 2. Otoskorrelaation kaava (Excelin käyttämä kaava)

Kaavassa \bar{x} ja \bar{y} ovat otoskeskiarvoja (kaava 3).

$$\bar{x} = \sum_{i=1}^n \frac{x_i}{n}$$

KAAVA 3. Otoskeskiarvon kaava

Otoskorrelaatiota voidaan käyttää kasvun ja halkaisijan kaltaisten mitattavien muuttujien laskemisessa. Symmetrian, värin ja reunan tasaisuuden käsitteelyyn käytettyjen luokitusten kanssa käytetään sensitiivisyyden ja spesifisyyden kaavoja (kaavat 4 ja 5).

$$\text{Sensitiivisyys} = \frac{a}{a + b}$$

KAAVA 4. Sensitiivisyyden kaava (15)

Kaavassa:

a = oikein tunnistettujen määrä

b = virheellisesti tunnistamatta jääneiden määrä

$$\textit{Spesifisyys} = \frac{c}{c + d}$$

KAAVA 5. Spesifisyyden kaava (15)

Kaavassa:

c = oikein tunnistamatta jääneiden määrä

d = virheellisesti tunnistettujen määrä

Sensitiivisyyden ja spesifisyyden avulla voidaan siis laskea, kuinka luotettavasti algoritmi tunnistaa ominaisuuden tai jättää olemattoman ominaisuuden tunnistamatta. Samoin niistä voidaan suoraan nähdä ovatko mahdolliset virheet tunnistuksessa vai tunnistamatta jättämisessä ja kuinka voimakkaasti.

5.3 Tulosten analysointi

Ennen tulosten analysointia on huomautettava liitteenä olevista tuloksista, että tuloksia olisi yhteenlaskettuna lähes 60 000, joten työssä on liitettyä vain parhaimpien raja-arvojen tulokset ja tulostaulukot (liitteet 1 ja 2). Muut tulokset toimitetaan kuvamateriaalin ohella sähköisesti työn tilaajalle.

5.3.1 Halkaisija

Halkaisijan tulostaulukon (liite 2/1) perusteella laskettu korrelaatiokerroin:

$$r = 0,98205$$

Halkaisijan korrelaatiokertoimesta voidaan nähdä, että kunhan segmentointi onnistuu, halkaisijan mittaus on erittäin luotettava. Varsinkin kun huomioi-

daan inhimillinen tekijä halkaisijan mittaamisessa luokitukseen, jo valmiiksi pieni heitto täydestä korrelaatiosta selittyy paljolti sillä. Tämä tulos oli odotettavissa, sillä halkaisijan laskennassa ei käytetä mitään raja-arvoja, joten sen tulos riippuu vain segmentoinnin onnistumisesta.

5.3.2 Kasvun vertaus

Luomien kasvun seuraamisen testaukseen luotiin 5 kappaletta kymmenen kuvan sarjoja muissa testeissä käytettyjen kuvien pohjalta. Niiden koon perusteella tehtyjen laskutoimitusten perusteella saatiin seuraava mittaustaulukko niiden kokoeroista (taulukko 1).

TAULUKKO 1. Kuvista mitatut kokoerot

Mitatut	Kuva 1	Kuva 2	Kuva 3	Kuva 4	Kuva 5	Kuva 6	Kuva 7	Kuva 8	Kuva 9	Kuva 10
Kuvasarja 1	0	312	649	1057	1440	2129	3081	3702	4539	5156
Kuvasarja 2	0	207	630	1094	2130	2130	2130	2130	2143	2598
Kuvasarja 3	0	801	1381	2187	3568	3646	4524	5219	5876	6833
Kuvasarja 4	0	2420	4002	4512	5485	7148	9701	10871	11067	12093
Kuvasarja 5	0	1012	1823	1864	3178	3920	6437	7501	8543	8543

Algoritmien mittaamien tulosten perusteella muodostettu vastaava tulostaulukko (taulukko 2).

TAULUKKO 2. Algoritmien mittaamat arvot

Tulokset	Kuva 1	Kuva 2	Kuva 3	Kuva 4	Kuva 5	Kuva 6	Kuva 7	Kuva 8	Kuva 9	Kuva 10
Kuvasarja 1	0	314	655	1055	1442	2148	3022	3766	4532	5062
Kuvasarja 2	0	197	616	1065	2070	2070	2070	2070	2070	2546
Kuvasarja 3	0	795	1391	2134	3580	3687	4553	5186	5877	6768
Kuvasarja 4	0	2381	3967	4437	5421	7095	9630	10732	10922	12014
Kuvasarja 5	0	1004	1811	1854	3161	3912	6428	7560	8422	8417

Tulosten ja mittausten välinen korrelaatiokerroin on siis

$$r = 0,999925.$$

Kuten halkaisijankin kohdalla, kasvun vertaamisen tulos on odotetusti erittäin hyvä, sillä laskukaava on erittäin yksinkertainen. Kasvun vertaaminen on kuitenkin kaikista analysoiduista algoritmeista alttein segmentoinnin virheille sen laskennan vuoksi, joten segmentoinnin täytyy ehdottomasti olla luotettava, jotta kasvun vertaaminen onnistuu.

5.3.3 Symmetria

Ennen symmetriatulosten analysointia huomautettakoon oudoista raja-arvoprosenteista. Raja-arvot asetetaan algoritmeissa jostain syystä oudosti ja tarpeettoman monimutkaisesti erillisen kertoimen avulla, josta kuitenkin lopputuloksena on puhdas prosenttikerroin varsinaiseen puolikkaiden vertaukseen. Tästä syystä symmetrian raja-arvot ovat outoja prosenttilukuja kymmenesosineen.

Symmetrian tunnistuksessa käytettiin kahta keskipistettä ja testattiin myös niiden yhdistämistä. Eri raja-arvoilla mittaamisen seurauksena luomen ominaisuuksista mitatulle alkuperäiselle keskipisteelle parhaan tuloksen antoi raja-arvo 12,4 % (liite 1/1), jolla sensitiivisyys on ~66 % ja spesifisyys ~80 %. Se on myös keskiarvoltaan hieman parempi kuin oletetun keskipisteen paras tulos raja-arvolla 18,6 %, jolla sekä sensitiivisyys että spesifisyys ovat ~70 %.

On huomion arvoista, että kummissakin tuloksissa on nähtävissä selkeä yhteys sensitiivisyyden ja spesifisyyden välillä. Kun sensitiivisyys paranee, spesifisyys huononee ja päinvastoin. Tästä yhteydestä johtuen kaikki tulokset eivät ole saman arvoisia, sillä korkea spesifisyys ja matala sensitiivisyys tarkoittaa vain, ettei algoritmi tunnista mitään. Sen sijaan korkea sensitiivisyys ja matalampi spesifisyys tarkoittaa, että algoritmi toimii, mutta siinä on ongelmia.

Tämä huomioiden alkuperäisen keskipisteen paras tulos johtuu algoritmin toimimattomuudesta, sillä sen tuloksen vahvuus on spesifisyydessä. Sen sijaan kummankin keskipisteen yhdistetty tulos raja-arvolla 18,6 % antaa sensitiivisyydeksi ~79 % ja spesifisyydeksi ~69 % (liite 1/3). Huomion arvoista on, että kummankin keskipisteen sensitiivisyystulokset ovat yksistään ~9–13 % huonompia, joten niiden yhdistäminen parantaa tunnistusta ~11 % spesifisyyden pudotessa paljon vähemmän kuin vastaavan tuloksen saaminen yksittäisellä keskipisteellä vastaavan sensitiivisyyden saamiseksi.

Yksittäisistä keskipisteistä kuitenkin huomataan, että niiden parhaat tulokset ovat eri raja-arvoilla. Niinpä on syytä testata, voisiko yhdistettyjen keskipisteiden tulos parantua, jos siihen käytetään kumpaakin keskipistettä eri raja-arvoilla.

Liitteen 1/4 tuloksista muodostetun taulukon 3 perusteella nähdään, että alkuperäinen keskipisteen yhdistäminen oletetun keskipisteen 31 % raja-arvolla saatuun tulokseen tuottaa kokonaisuutena parhaan tuloksen, mitä symmetrian mittauksesta näillä algoritmeilla voidaan saada. Sensitiivisyys on tällä yhdistelmällä ~82 % ja spesifisyys ~73 %. Lisäksi suurempien oletetun keskipisteen raja-arvojen yhdistäminen tuottaa varsin tasaisesti päälle 70 % tulosta sekä sensitiivisyyden että spesifisyyden suhteen. Voidaan siis todeta, että alkuperäisen keskipisteen tunnistuksen yhdistäminen itseään suurempaa raja-arvoa käyttävään oletettuun keskipisteeseen kompensoi sen heikkouksia jonkin verran. On kuitenkin selvää, että näistä tuloksista on vielä parantamisen varaa.

TAULUKKO 3. Alkuperäisen keskipisteen raja-arvon 12,4 % ja oletetun keskipisteen raja-arvon 31,0 % yhdistetty paras tulos

Raja-arvo	A	B	C	D	E	F	Sensitiivisyys	Spesifisyys	Keskiarvo
yhd. 6,2%	69	2	20	2	9	103	0,984	0,1375	0,56075
yhd. 12,4%	49	9	16	6	29	96	0,92562	0,416667	0,671143
yhd. 18,6%	27	25	12	10	51	80	0,786325	0,693182	0,739753
yhd. 24,8%	22	42	8	14	56	63	0,628319	0,76087	0,694594
yhd. 31,0%	14	49	7	15	64	56	0,5625	0,849462	0,705981

A = väärin tunnistetut

B = tunnistamatta jääneet

C = 0,5 luokitus tunnistettu

D = 0,5 luokitus ei-tunnistettu

E = oikein tunnistamattomat

F = oikein tunnistetut

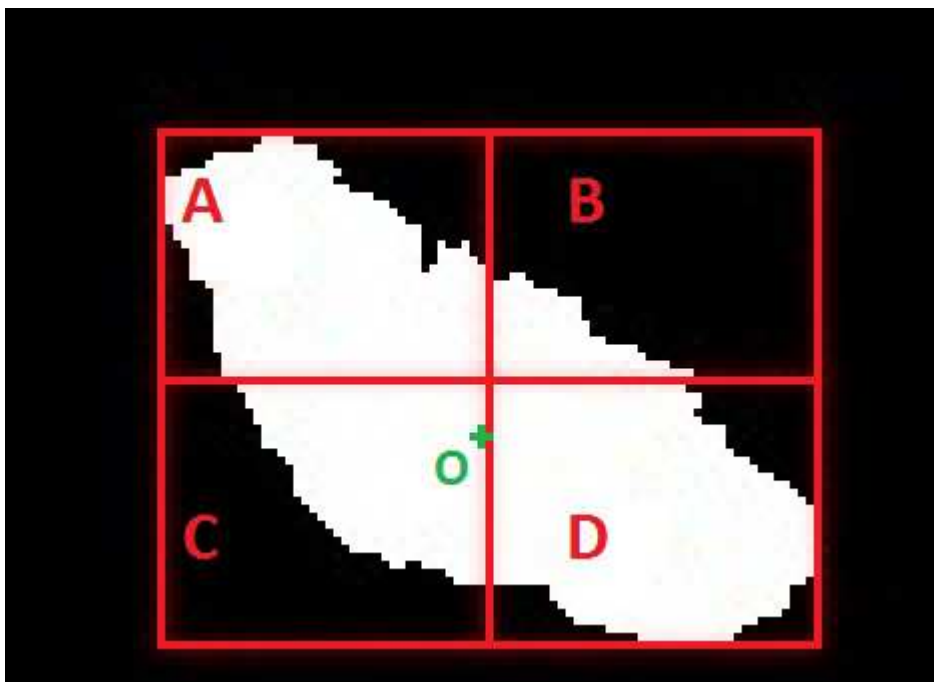
Virheanalyysi

Virheanalyysissä käytetään parhaan tuloksen antanutta yhdistelmää alkuperäisen keskipisteen raja-arvo 12,4 % + oletetun keskipisteen raja-arvo 31,0 %.

Virheellisesti tunnistettuja luomia olivat 17, 22, 24, 25, 32, 37, 48, 52, 56, 95, 106, 107, 111(3), 112(2), 116, 120, 129, 135, 144, 166, 176, 177, 186, 188 ja 189.

Ensimmäinen virhe on suhteellisen harvinainen ja ilmenee lähinnä vaikeissa kuvissa, joissa itse luomessa on vaikeasti erotettavia alueita, kuten aiemmin segmentoinnin analyysissä nähtiin. Paljon yleisempiä ongelmia ovat keskipisteiden sijoittuminen ja luomien asento.

Mikäli luomi on juuri sopivan kokoinen ja sen halkaisija oikeassa kulmassa, on mahdollista, että huomattavan iso osa koosta sijoittuu keskipisteeseen nähden johonkin lohkoon aiheuttaen virheellisen tunnistuksen. Kuten voidaan päätellä, tämä ei niinkään ole alkuperäisen keskipisteen ongelma, vaikka oikean mallisella luomella senkin on mahdollista tuottaa sama virhe. Esimerkiksi kuvassa 30 lohko B:n osuus luomesta on niin pieni, että kaikki puolikkaiden vertaukset aiheuttavat selvän kokoeron. Myös oletettu keskipiste liikkuu vain alaspäin suurentaen lohkoa A ja pienentäen lohkoa D niin paljon, että sekään ei tuota kuvasta oikeaa tulosta.



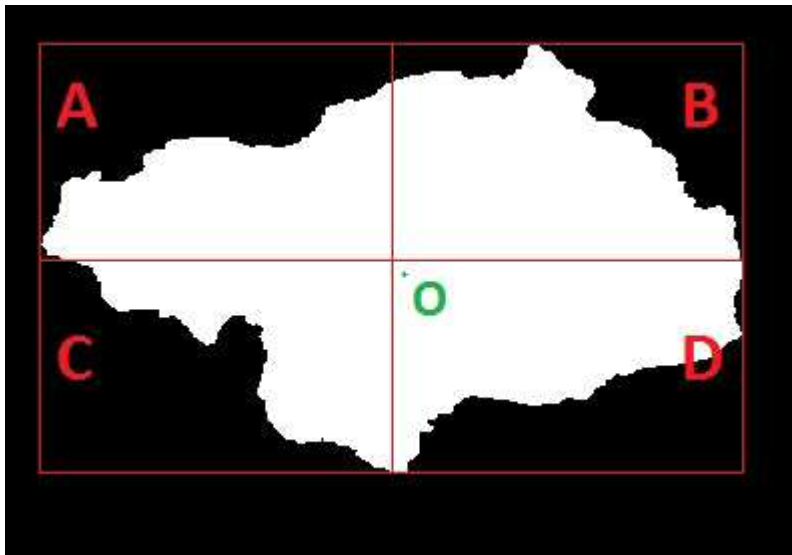
KUVA 30. Kummankin keskipisteen virhe (alkuperäinen kuva (8))

Oletetun keskipisteen ongelma on siis sen sijoittuminen uudelleen x- ja y-akselilla mitaten alkuperäisen keskipisteen etäisyyttä luomen reunoista. Kun luomi on vinossa, on todennäköistä, että se liikkuu alkuperäisestä keskipisteestä tarpeeksi vain yhteen suuntaan, ja yksi lohkoista kasvaa niin suureksi, että sen katsotaan tuottavan epäsymmetrian.

Selkeästi yleisin virhe väärin tunnistamisessa on kuitenkin alkuperäisen keskipisteen sijoittumisessa. Oletettu keskipiste tuottaisi samalla raja-arvolla vielä enemmän virheitä, mutta koska se on paljon korkeampi parhaassa yhdistelmässä, sen virheet karsiintuvat pois ja kompensoivat oikein tunnistuksessa alkuperäisen keskipisteen heikoimpia kohtia. Syy virheeseen on muuten sama kuin kuvassa 30, mutta luomen mallista johtuen oletettu keskipiste siirtyy paremmin, ja siksi vain alkuperäinen tuottaa virheen.

Tunnistamatta jääneitä olivat 6, 7, 15, 19, 23, 39, 53, 57, 72, 77, 78, 90, 97, 100, 102, 108, 109(1), 115, 117 ja 168.

Muutamaa segmentoinnin kannalta vaikeaa kuvaa lukuun ottamatta kaikki tunnistamatta jääneet johtuivat myös keskipisteiden sijoittumisesta luomeen nähden huonosti. Tähän syynä on yleensä itse luomen malli. Esimerkiksi kuvassa 31 oleva luomi on selvästi epäsymmetrinen, mutta juuri sen verran tasaisesti jakaantunut, ettei se aiheuta tunnistusta alkuperäisellä keskipisteellä ja oletettu siirtyy hyvin vähän ja tasaisesti, joten sekään ei kompensoi.



KUVA 31. Tunnistamatta jäänyt epäsymmetria (alkuperäinen kuva (10))

Jatkokehitys ja korjaus

Segmentoinnin kehittämisen ohella symmetrian tunnistuksessa tulisi pystyä poistamaan asennon aiheuttama virhetunnistus ja mahdollisuus, että luomen osat jakaantuvat kokonsa puolesta liian tasaisesti. Ensimmäinen voitaisiin yrittää ratkaista esimerkiksi kääntämällä luomi halkaisijansa suhteen pystytai vaakasuuntaan ennen analyysiä. Paljon parempi ratkaisu olisi kuitenkin laajentaa nykyisellään käytettyä koon mittausta, hyödyntäen sitä löytämään mahdollisimman paljon toistensa suuruiset lohkot ja vertaamaan niiden sisällä olevan objektin mallia toisiinsa. Yksi mahdollisuus olisi etsiä suurin ja toiseksi suurin lohko ja kääntämällä ne samoin päin vähentää ne toisistaan ja ottaa jäljelle jäävästä binäärikuvamatriisista itseisarvo, jolloin mahdolliset -1-arvot muuttuisivat myös arvoon 1. Tästä voitaisiin laskea, kuinka paljon pikseleitä jäi jäljelle kun toistensa kanssa täsmäivät on poistettu. Tällöin siis vain erot jäisivät jäljelle, ja niitä voitaisiin asetetun raja-arvon perusteella analysoida. Etuna olisi myös, ettei tähän tarvittaisi kuin alkuperäisen keskipisteen käyttöä, ja se luultavasti eliminoisi kuvissa 13, 30 ja 31 kuvatut virheet.

Yksi mahdollisuus olisi myös hyödyntää Matlabin jo nykyisellään hakemia objektin reunojen koordinaatteja ja verrata vastaavasti kahden mahdollisimman saman suuruisen lohkon reunoja toisiinsa, mikä myös tarkoittaisi, että kuvissa 13 ja 31 esitetyt virheet korjaantuisivat samalla kun kuvan 30 luomi tunnistettaisiinkin symmetriseksi sen huomattavasti enemmän toisiaan muistuttavien reunojen lohkoissa A ja D. Matlabista saatujen reunojen koordinaatteja pitää luultavasti kuitenkin hyödyntää reunan tasaisuuden tunnistuksen parantamiseen (ks. 5.3.5), joten sitä voitaisiin hyödyntää.

Parhaaseen mahdolliseen tulokseen kuitenkin luultavasti päästään analysoimalla luomi useilla eri algoritmeilla ja niiden yhteistuloksien perusteella tehdä lopullinen analyysi. Projektiin täytyy tehdä sen kehittyessä joustavalle raja-arvolle todennäköisyyslaskenta, joten sitä voitaisiin myös hyödyntää eri algoritmien tulosten painotuksessa lopullista analyysia tehtäessä.

5.3.4 Värin tasaisuus

Värin tasaisuutta testattiin tarkastelemalla intensiteettioppiikkien etäisyyksiä toisistaan ja värien intensiteettien jakaantumisen laajuutta. Yksittäin tarkasteltuna intensiteettioppiikkien etäisyyden tunnistuksessa parhaan tuloksen antoi 9:n intensiteetin raja-arvo (9i)(liite 1/6). Kuten symmetrian tunnistuksessa, värituloksien sensitiivisyyden ja spesifisyyden välillä on vastaava yhteys, ja raja-arvon 9i tulos on paras sen spesifisyyden vuoksi. Sen sensitiivisyys on vain ~60 % ja spesifisyys ~91 %. Parempia sensitiivisyyden arvoja saatiin ki-ristämällä raja-arvoa, eikä tulos raja-arvolla 4i ole kokonaisuutena paljoa heikompi. Sen tulokset ovat tasaisemmat sensitiivisyys ~79 % ja spesifisyys ~69 %.

Toisena testatun intensiteetin laajuuden paras tulos on saatu raja-arvoilla 25px/45px/100px (a/b/c), jossa a on rajakohdan 4/5 intensiteettien määrä, b rajakohdan 3/5 ja c ensimmäisten testien perusteella lisätty rajakohta 2/5 (ks. s. 31–32). Sensitiivisyydeksi saatiin ~86 % ja spesifisyydeksi 80 % (liite 1/7). Käytännössä samantasoinen tulos saatiin myös yhdistämällä näiden kahden tunnistuksen tulokset, jolloin parhaan tuloksen antoi yksittäisten testien parhaiden tulosten yhdistelmä (liite 1/13). Tällöin sensitiivisyys nousi ~93 %:iin, mutta spesifisyys laski ~72 %:iin (taulukko 4). 9i:n yhdistäminen myös muihin a/b/c-raja-arvoihin 25px/45px/100px:n ympärillä antoi saman tuloksen, mutta arvoa 25px/45px/100px voidaan pitää luotettavimpana sen yksittäisen tuloksen paremmuuden vuoksi.

TAULUKKO 4. 9i+25/45/100 paras tulos

9i +	A	B	C	D	E	F	Sensitiivisyys	Spesifisyys	Keskiarvo
15/40/80	16	10	35	10	32	102	0,931973	0,724138	0,828055
20/45/90	16	10	35	10	32	102	0,931973	0,724138	0,828055
25/45/100	16	10	35	10	32	102	0,931973	0,724138	0,828055
30/50/110	16	11	35	10	32	101	0,92517	0,724138	0,824654
35/55/120	16	10	35	10	32	102	0,931973	0,724138	0,828055

A = väärin tunnistetut

B = tunnistamatta jääneet

C = 0,5 luokitus tunnistettu

D = 0,5 luokitus ei-tunnistettu

E = oikein tunnistamattomat

F = oikein tunnistetut


Virheanalyysi

Virheanalyysissä käytetään parhaan tuloksen antanutta yhdistelmää 9i+25/45/100.

Virheellisesti tunnistettuja luomia olivat 11, 13(3), 24, 29, 35, 51, 57, 72, 86, 98, 109(3), 111(3), 117, 138, 140 ja 146.


Virheellisesti tunnistettu väri aiheutuu kuvien ja niiden histogrammien analysoinnin perusteella kahdesta asiasta, joista kumpikin vaikuttaa eri algoritmiin. 9i:hin eli intensiteettiä suuremman etäisyyden tunnistukseen vaikuttaa selvästi kuvan laatu siten, että sen histogrammi saattaa pirstoontua aiheuttaen paljon erillisiä intensiteettiä suurempia, vaikka kokonaisuudesta nähdäänkin värin jakaantuvan tasaisesti. Esimerkiksi kuvassa 32 oleva luomi on selvästi tasainen väriltään, mutta sen histogrammin voidaan nähdä pirstoontuneen, koska kuvan värit eivät ole jakaantuneet tasaisesti, vaan harvoille intensiteetti-arvoille. Petollisesti tätä ei edes selvästi huomaa vain itse kuvaa katsomalla helposti. Tämä virhe kuitenkin on analyysin perusteella harvinaisempi kahdesta virhetunnistuksesta ja johtuu yleisesti joko huonosta valaistuksesta kuvassa tai suhteellisen huonosta kuvanlaadusta.

Huomautuksena ennen kuvien katsomista tulee huomioida, että esitetyt histogrammit ovat negatiivikuvista.




KUVA 32. Pirstoutunut histogrammi (materiaalin kuva 11)(16)

Paljon yleisempi virhe tapahtuu histogrammin laajuuden tunnistuksessa. Koska a/b/c:ssä ideana on, että tasavärisen luomen histogrammi on tiivis ja korkea ja epätasainen on jakaantunut laajemmalle, syntyy ongelma, kun tasavärisen luomen histogrammi onkin jakaantunut tasaisemmin varsinkin histogrammin yläosasta. Kuvassa 33 nähdään selkeästi tasavärinen luomi, jonka histogrammi myös tukee tätä, sillä se laskeutuu tasaisesti kumpaankin suuntaan. Algoritmin kannalta kuitenkin laskeutuminen on liian hidasta, ja siksi histogrammi on rajakohdissa leveämpi kuin käytetty raja-arvo sallii. Tässäkin virheessä oli joissain kuvissa vaikutusta kuvanlaadulla ja valaistuksella, mutta käytetyssä esimerkikuvassa ei ole kyse kummastakaan, joten ongelma on myös algoritmista.




*KUVA 33. "Liian" tasaisesti jakaantunut väri (materiaalin kuva 72)(14)
X-akseli = intensiteetti-arvo
Y-akseli = pikselien määrä*

Tunnistamatta jääneitä olivat 16, 25, 46, 55, 60, 70, 85, 89, 102 ja 123. Tunnistamatta jääneissä on kaikissa histogrammeja tarkastelemalla sama ominaisuus. Niissä on kuvissa selvästi kaksi eri väriä, mutta vain toinen niistä muodostaa histogrammiin piikin. Toinen jakaantuu hyvin tasaisesti lähes koko intensiteettiskaalalle ja jää näin kummankin algoritmin suhteen alimman rajakohdan alapuolelle. Kuvassa 34 vaaleamman alueen intensiteetit jäävät juuri rajakohdan alle, kun taas kuvassa 35 tämä näkyy vielä selkeämmin tumman osan jakaantuessa todella tasaisesti ja matalalle. Algoritmien toiminnan ideana on, että kaksi selvästi eri väriä muodostavat kaksi selvästi toisistaan erillään olevaa piikkiä, kuten yleensä tapahtuukin.



*KUVA 34. Epätasainen tunnistamaton väri 1 (materiaalin kuva 70)(8)
X-akseli = intensiteetti-arvo
Y-akseli = pikselien määrä*



*KUVA 35. Epätasainen tunnistamaton väri 2 (materiaalin kuva 16)(11)
X-akseli = intensiteettiarvo
Y-akseli = pikselien määrä*

Jatkokehitys ja korjaus

Väärin tunnistamisen suhteen on vaikeahko keksiä itse algoritmeihin, miten niitä voisi parantaa, sillä muuttelemalla raja-arvoja tai rajakohtia syntyy vain uusia ongelmia joko tunnistamiseen tai tunnistamattomuuteen. Adaptiivisuus voisi auttaa esimerkiksi kuvan 32 tapauksessa, jos algoritmi tunnistaisi laskeutumisen olevan kummallakin puolella hyvin tasaista. On kuitenkin muistettava, että värin tunnistuksen sensitiivisyys on jo nykyisellään hyvin korkea eli noin 93 %. Lisäksi suurin osa virheellisistä tunnistuksista liittyi enemmän kuvanlaatuun ja valaistukseen. Niinpä tulosta voidaan varmasti parantaa paremmin kehittämällä symmetrian jatkokehityskappaleen tavoin useampia algoritmeja, joiden tuloksien pohjalta muodostetaan lopullinen analyysi.

Tunnistamatta jäämisessä sen sijaan ongelma on selkeämpi. Rajakohtien laskeminen ei ole ratkaisu, sillä se johtaisi vain spesifisyyden heikentymiseen. Sen sijaan voidaan nähdä, että mikäli toista piikkiä ei synny, epätasaisen värin luomen intensiteetit jakaantuvat hyvin matalalle ja laajalle toispuoleisesti. Tätä ominaisuutta voidaan hyödyntää lisäämällä algoritmiin tarkistus, joka tarkistaa rajakohtien ylittävien intensiteettien määrän kummaltakin puolelta erikseen. Jos toisella puolella on hyvin selvä laajalle jakaantunut intensiteettien määrä ja toisella hyvin vähäinen, voidaan päätellä, että se aiheutuu epätasaisesta väristä. Tasaisen värin histogrammi on joko tiivis ja korkea tai laskeutuu tasaisesti kummallekin puolelle. Poikkeuksena on tietysti kuvan 32 kaltainen tilanne, jossa laskeutuminen pysähtyy oikealle puolelle intensiteettiarvon 255 tullessa vastaan, joten se tulee huomioida.

5.3.5 Reunojen säännöllisyys

Reunojen tasaisuus testattiin erittäin yksinkertaisella ympärysmitan vertauksella, joten sen selvästi heikompi tulos oli odotettavissa. Parhain tulos saatiin alkuperäisestä ideasta poiketen negatiivisella raja-arvolla, kun alunperin toimintaperiaatteena oli, että rönkyilevät reunat tekisivät ympärysmitasta pidemmän kuin sen oletetusta soikeasta ympärysmitasta. Paras tulos siis saatiin raja-arvolla -18 % (liite 1/21), joka kuitenkin jälleen perustuu spesifisyyden suhteelliseen vahvuuteen sen ollessa ~80 % sensitiivisyyden jäädessä ~56 %:iin (taulukko 5). Raja-arvon pudottaminen vielä alemmas parantaa sensitiivisyyttä, mutta laskee spesifisyyttä samassa suhteessa, joten tasapainoisin tulos on viimeisellä raja-arvolla -24 %. Ero tasoittuisi vielä pienemmällä raja-arvoilla, mutta tulosten kehityksestä voidaan nähdä, ettei kumpikaan tulos pääse yli 70 %:in ilman toisen voimakasta heikkenemistä.

TAULUKKO 5. -18% paras tulos.

Raja-arvo	A	B	C	D	E	F	Sensitiivisyys	Spesifisyys	Keskiarvo
-15 %	23	42	15	39	58	28	0,505882	0,808333	0,657108
-16 %	25	39	15	39	56	31	0,541176	0,791667	0,666422
-18 %	26	38	17	37	55	32	0,563218	0,779661	0,67144
-19 %	28	38	17	37	53	32	0,563218	0,762712	0,662965
-20 %	29	38	18	36	52	32	0,568182	0,752137	0,660159

A = väärin tunnistetut
B = vunnistamatta jääneet
C = 0,5 luokitus tunnistettu
D = 0,5 luokitus ei-tunnistettu
E = oikein tunnistamattomat
F = oikein tunnistetut

Virheanalyysi

Virheanalyysissä käytetään parhaan tuloksen antanutta raja-arvoa -18 %

Virheellisesti tunnistettuja luomia olivat 1, 4, 13(3), 32, 34, 45, 50, 51, 54, 55, 58, 59, 61, 79, 87, 90, 100, 103, 105, 111(3), 115, 117, 118, 121, 126, 131.

Tunnistamatta jääneitä olivat 11, 20, 27, 33, 41, 53, 63, 66, 77, 81, 83, 86, 109(2), 111(1), 112(1), 124, 130, 140, 150, 151, 154, 155, 156, 169, 170, 171, 172, 173, 174, 175, 188, 189, 190, 191, 192, 193, 194 ja 195.

Reunantunnustuksen virheissä ei ole mitään yllättävää, sillä käytetty algoritmi on aivan liian yksinkertainen ratkaisuyritys erittäin monimuotoiseen ongelmaan, eikä siihen oltu edes kehitysvaiheessa tyytyväisiä. Tulosten välistä yhteydestä nähdään, että näin yksinkertaisella ratkaisulla on aina ongelma joko sensitiivisyyden tai spesifisyyden kanssa, ja tasapainoisimmillaankin päästään vain välttävään tulokseen.

Reunantunnistukseen tulisi siis kehittää aivan toisenlainen ratkaisu, ja hylätä nykyinen ympärysmittan vertaus täysin. Matlab tallentaa jo nykyisellään objektin reunojen koordinaatit, joten niitä voitaisiin hyödyntää esimerkiksi tarkastelemaan, kuinka voimakasta, nopeaa ja tiheää niiden suunnanmuutos on.

6 JOHTOPÄÄTÖKSET

Työssä oli päätavoitteena testata VARO-säännön mukaisten parametrien analysointialgoritmeja käyttäen kuvia oikeista melanoomaluomista tehden yhteistyötä SOTE:n ja OYS:n kanssa kuvamateriaalin hankinnassa. Algoritmit testattiin onnistuneesti, mutta kuvamateriaali täytyi hankkia yksinomaan Internetistä. Alkuperäisestä suunnitelmasta poiketen korrelaatiokertoimet laskettiin vain halkaisija- ja kasvudatalle, ja luokitusta vaativille parametreille laskettiin niiden sijaan paremmin luokitukseen sopivat sensitiivisyys- ja spesifiyysarvot. Työn päätavoitteen saavuttamiseksi täytyi myös etsiä kullekin algoritmille parhaat tulokset tuottavat raja-arvot, mikä myös saavutettiin.

Tulosten perusteella todettiin, että halkaisijan tunnistus ja kasvunvertaaminen toimivat jo nykyisellään erinomaisesti. Värin tasaisuuden ja varsinkin epäsymmetrisyyden tunnistusta täytyy jatkokehittää, ja reunan tasaisuuden tunnistus täytyy tehdä täysin uusiksi. Tulosten yhteenveto on esitetty taulukossa 6.

TAULUKKO 6. Parhaat tulokset yhteenveto.

Algoritmi	Paras raja-arvo	Korrelaatiokerroin	Sensitiivisyys	Spesifiisyys	Arvio
Halkaisija	-	0,98205	-	-	Erinomainen
Kasvu	-	0,999925	-	-	Erinomainen
Symmetria	alk. 12,4% + ole. 31%	-	89 %	63 %	Hyvä, kehitettävä
Väri	9i+25/45/100	-	93 %	72 %	Hyvä, kehitettävä
Reunat	-18 %	-	56 %	78 %	Välttävä, uusittava

Tavoitteena oli myös selvittää, miten kahden eri keskipisteen käyttö vaikuttaa epäsymmetrian tunnistuksessa koon perusteella. Tässä tuloksena oli, että kahden keskipisteen käyttö parantaa tulosta verrattuna yhdenkeskipisteen käyttöön. Lisäksi analysoitiin myös, miksi kahden keskipisteen käyttö tuottaa paremman tuloksen. Kuitenkin myös todettiin, että algoritmi ei yksistään ole vielä riittävä, vaan joko sen rinnalle on kehitettävä muita algoritmeja, tai sitä täytyy kehittää älykkäämmäksi pelkän koon mittaamisesta, mikä voisi poistaa kahden keskipisteen käytön tarpeen.

Virheiden tarkastelussa saatiin selville sensitiivisyyden ja spesifisyyden avulla algoritmien virheiden tyypit ja syyt. Kaikkien algoritmien virheet olivat hyvin samankaltaisia kunkin algoritmin kohdalla eli kunkin algoritmin sensitiivisyyttä ja spesifisyyttä tarkasteltaessa virhetyyppien määrä oli vähäinen. Tämän perusteella pystyttiin myös työn tavoitteiden lisäksi tekemään jatkokehitysehdotuksia tulosten parantamiseksi. Myös segmentoinnin analyysi tehtiin tavoitteen mukaisesti siinä määrin, että sen perusteella tiedetään, että sen ongelmat ovat vaaleat alueet, erityisesti luomen reunoilla, mahdolliset varjotukset, ihon karvoitus luomen ympärillä ja joidenkin luomien epäselvä luonne, esimerkiksi epäyhtenäisyys.

7 LOPPUSANAT

Työn tekeminen oli lähtökohtaisesti kiinnostavaa, sillä olen vapaa-ajallani ollut harrastuksen puolesta jo tekemisissä kuvankäsittelyn kanssa myös tekniemmältä kantilta. Lisäksi koska olin tekemässä testattavia algoritmeja, oli kiinnostavaa nähdä oman käden jälkensä toiminta ja analysoida sitä.

Työn vähiten miellyttävä vaihe oli kuvamateriaalin hankkiminen, koska se ei ollut vain itsestäni kiinni ja vei siksi paljon aikaa ilman että mikään muu edistyi siinä samalla. Materiaalin hankkiminen Internetistä oli myös hieman epämiellyttävää, sillä kuten kuvitella saattaa, etsimällä kuvamateriaalia ihosairauksista tulee vastaan paljon vähemmän miellyttävää katseltavaa.

Kuvamateriaaliksi olisin halunnut laajemman otoksen, mutta koska SOTE:lla ei sellaista ollut ja OYS:ssa tuli lähinnä hidas ja kankea byrokratiamuuri vastaan, oli käytettävä sitä mitä Internetistä löytyi.

Kiinnostus aiheeseen oli erityisesti tarpeeseen varsinaisen testausvaiheen alettua. Uskoin pitkään, ettei itse testaaminen veisi kauan, mutta vähitellen testejä tehdessä alkoi valjeta, kuinka laajasti ne pitää todella tehdä ja kuinka paljon niissä on otettava huomioon. Testien suunnitteleminen siten, että niistä saatiin tulokset kohtuudella kasaan, vaati paljon suunnittelua, ja algoritmien erilaisuuden vuoksi myös tulosten käsittelemiseksi täytyi tehdä tulostenkäsittelyohjelma erikseen huolella, sillä lopullisia tuloksia oli hieman alle 60 000. Työn levitessä täytyi myös olla huolellinen, jotta kaikki tulokset olivat oikein ja oikeissa paikoissa lopullisissa työssä esitetyissä tuloksissa.

Työn tekeminen kuitenkin auttoi ymmärtämään määrittelyn tärkeyttä ja kehitti ohjelmointipäätä. Työn tekemisen aikana alkoi huomata paljon asioita, jotka olisi voinut toteuttaa itse algoritmeissa paljon paremmin. Osittain syynä on tietysti, että projektin alussa sen lopullinen tavoiteltu tuote ei ollut vielä täysin selvillä. Algoritmeissa on kuitenkin myös tuotteesta ja sen kehitysvaiheista riippumattomia asioita, kuten jo mainittu symmetrian raja-arvon kummallinen asettaminen. Monet algoritmit on myös jaettu kahtia eli yksi on ensimmäiselle kuvalle ja toinen sen jälkeisille. Tämäkin johtuu osittain siitä, että tuote ei ollut

alussa täysin selvä, ja esimerkiksi pääohjelmassa käytetään jo älykkäämpää ehtorakennetta, sillä se tehtiin myöhemmin. Kyseiset algoritmit saadaan tosin helposti yhdistettyä, kunhan vain lisätään jokunen ehtorakenne, muutetaan pari muuttujaa ja toiminnallisuutta sekä lisätään luomen koon vertaukseen alkuperäisen koon kirjoitus ja luku muuttujiin, sillä itse kasvutaulukkoon tulostetaan luomien kokoero eikä itse kokoa. Tietysti sen voisi muuttaa suoraan tulostamaan luomien koot sellaisinaan, mutta erotuksen tulostamisen avulla on tarkempi seurata kasvua käyrältä.

Varsinaisesta työstä ei jäänyt montaa asiaa kaivelemaan, sillä huomioin ja kävin läpi omasta mielestäni kaiken sellaisen, minkä voi olettaa. Tuloksetkin ovat varsin laajat, joten lopullisten johtopäätösten kanssa ei jää paljoa varaa spekulointiin. Symmetrian raja-arvon typeryys ja sen huomaaminen vasta testien teon jälkeen alkaessani muuttaa sen raja-arvoja prosenteiksi vähän harmittaa. Tämä oli omalle työlle sokaistumista selvästi, mutta onneksi tulosten perusteella siitä ei suurempaa haittaa ollut. Tilaajalle lähetettäviin algoritmeihin voinee niiden suhteen käyttää likiarvoja 12 % ja 31 %. Kokonaisuutena voin siis olla tyytyväinen työn lopputulokseen ja koen myös itse kehittyneeni työn tekemisen aikana.

LÄHTEET

1. Gonzalez C. Rafael, Woods E. Richard. 2002. Digital Image Processing Second Edition. Prentice-Hall, Inc. Upper Saddle River, New Jersey 07458.

2. Lundbom Niina. 2012. Melanooman arvioinnissa sovellettavat menetelmät ja teknologiat, Insinööriyö, Oulun seudun ammattikorkeakoulu.

Saatavissa:

https://publications.theseus.fi/bitstream/handle/10024/45721/Lundbom_Niina.pdf?sequence=1. Hakupäivä 28.9.2012.

3. Suomen Ihotautilääkäriyhdistys ry. 2004. Polttopisteessä melanooma.

Saatavissa:

<http://www.cancer.fi/@Bin/24403/Polttopisteess%C3%A4+melanooma.pdf>.

Hakupäivä 2.10.2012.

4. Käypä Hoito. 2012. Melanooma. Saatavissa:

<http://www.kaypahoito.fi/web/kh/suosituksset/naytaartikkeli/tunnus/hoi50038>.

Hakupäivä 2.10.2012.

5. Dermaklinikka.fi. Luomet ja maligni melanooma.

Saatavissa: <http://dermaklinikka.fi/doctor/Luomet/3/2285.html>.

Hakupäivä 2.10.2012.

6. Health & Medicine for Senior Citizens. 2009. People with Most Moles are Most Likely to Develop Deadly Melanoma Cancer, Study Finds.

Saatavissa: <http://seniorjournal.com/NEWS/Health/2009/20090706->

[PeopleWithMostMoles.htm](http://seniorjournal.com/NEWS/Health/2009/20090706-PeopleWithMostMoles.htm). Hakupäivä 2.10.2012.

7. Information for Medical Professionals. 2003–2012. Malignant Melanoma.

Saatavissa:

http://skincancer.dermis.net/content/e04typesof/e154/e156/index_eng.html.

Hakupäivä 5.10.2012.

8. Dermatlas. 2001–2012. Melanoma.

Saatavissa:

<http://dermatlas.med.jhmi.edu/?search=diagnosis:%27melanoma%27>.

Hakupäivä 5.10.2012.

9. Pulse Today. 2010. Taskforce Calls For Better Melanoma Awareness. Saatavissa: <http://www.pulsetoday.co.uk/taskforce-calls-for-better-gp-melanoma-awareness/11044264.article#.USIx32fdhYI>. Hakupäivä 5.10.2012.
10. Skin cancer guide. 2004–2010. Melanoma. Saatavissa: http://www.skincancerguide.ca/melanoma/images/melanoma_images.html. Hakupäivä 5.10.2012.
11. Suhonen, Raimo. 2011. Melanooma. http://www.ihotauti.net/moni_melanooma.htm. Hakupäivä 4.10.2012.
12. American Skin Cancer Information center. Malignant Melanoma. Saatavissa: http://www.skin-cancer-mole-picture.com/Malignant_Melanoma.html. Hakupäivä 5.10.2012.
13. Top News.in. 2010. How melanoma tumours evade drug treatment. Saatavissa: <http://www.topnews.in/health/how-melanoma-tumours-evade-drug-treatment-29353>. Hakupäivä 5.10.2012.
14. Hardin MD. 2010. Melanoma Pictures. Saatavissa: <http://hardinmd.lib.uiowa.edu/dermnet/melanoma.html>. Hakupäivä 4.10.2012.
15. Wikipedia. 2012. Sensitivity and Specificity. Saatavissa: http://en.wikipedia.org/wiki/Sensitivity_and_specificity. Hakupäivä 23.12.2012.
16. Cancer Pictures. 2011. Melanoma Cancer Pictures. Saatavissa: <http://cancer-pictures.net/melanoma-cancer-pictures/>. Hakupäivä 5.10.2012.
17. MTV3. Studio55 kuvagalleria. Saatavissa: <http://www.mtv3.fi/studio55/kuvagalleria.shtml?1541629>. Hakupäivä 4.10.2012.
18. About.com, Cancer. 2011. Skin Cancer Pictures. Saatavissa: <http://cancer.about.com/od/skincancermelanoma/ig/Skin-Cancer-Photo-Gallery/>. Hakupäivä 4.10.2012.

19. Cosmetic & Laser Surgery Institute. 2011. Melanoma. Saatavissa: <http://www.cosmetic-lasersurg.com/main/medical-dermatology/skin-cancer/melanoma.html>. Hakupäivä 4.10.2012.
20. Usmlle Rescue. 2010. Photos. Saatavissa: <http://usmlerescue.com/aagupta2/photo/view/nodular-melanoma/>. Hakupäivä 4.10.2012.
21. The Melanoma Skin Cancer. 2010. The Four Major Types of Melanoma Tumor. Saatavissa: <http://themelanomaskincancer.com/the-four-major-types-of-melanoma-tumor/>. Hakupäivä 4.10.2012.
22. NDJ World. 2010. Skin Cancer Cure Only A Pill Away. Saatavissa: <http://www.nodeju.com/2488/skin-cancer-cure-pill.html>. Hakupäivä 4.10.2012.
23. Interactive Images of Disease. Saatavissa: <http://web.med.unsw.edu.au/pathmus/m0322093.htm>. Hakupäivä 5.10.2012.
24. Skin Cancer Guide Canadian Edition. 2004–2012. Superficial Spreading Melanoma. Saatavissa: http://www.skincareguide.ca/glossary/m/melanoma_superficial_spreading.html. Hakupäivä 5.10.2012.
25. eHealth Frontier. Melanoma Skin Cancer 2nd Stage. Saatavissa: <http://ehealthfrontier.com/melanoma-skin-cancer-2nd-stage/>. Hakupäivä 5.10.2012.
26. Käytetyin kuvamateriaalin lähde. Saatavissa: <http://leftsidestomachpain.net/malignant-melanoma-are-your-signs-and-symptoms-a-sign-that-it-has-spread/>. Hakupäivä 5.10.2012.
27. Medical Health Reports. 2011. Life Saving Skin Cancer Pictures. Saatavissa: <http://www.medicalhealthreports.com/life-saving-skin-cancer-pictures.html>. Hakupäivä 5.10.2012.
28. Syöpäjärjestöt. 2010. Syövän ehkäisy. Saatavissa: <http://www.cancer.fi/syovanehkaisy/omatarkkailu/luomet/>. Hakupäivä 4.10.2012.

TULOSTAULUKOT
LIITE 1/2

Raja-arvo	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamatomat	Oikein tunnistamatomat	Oikein tunnistetut
ole. 3,72%	69	3	21	1	9	102
ole. 4,34%	66	3	21	1	12	102
ole. 4,96%	66	5	21	1	12	100
ole. 5,58%	63	6	20	2	15	99
ole. 6,2%	64	4	19	3	14	101
ole. 12,4%	46	18	16	6	32	87
ole. 18,6%	26	35	12	10	52	70
ole. 24,8%	22	45	8	14	56	60
ole. 31,0%	14	54	7	15	64	51
ole. 37,2%	13	60	6	16	65	45
ole. 43,4%	12	68	4	18	66	37
ole. 49,6%	10	74	4	18	68	31
ole. 55,8%	7	79	3	19	71	26
ole. 62,0%	7	82	2	20	71	23
ole. 68,2%	7	84	2	20	71	21
ole. 74,4%	4	85	1	21	74	20

Sensitiivisyys	Spesifisyys	Keskiarvo
0,97619	0,126582	0,551386
0,97619	0,164557	0,570374
0,960317	0,164557	0,562437
0,952	0,2125	0,58225
0,967742	0,209877	0,588809
0,85124	0,452381	0,65181
0,700855	0,704545	0,7027
0,60177	0,76087	0,68132
0,517857	0,849462	0,68366
0,459459	0,861702	0,660581
0,376147	0,875	0,625573
0,321101	0,895833	0,608467
0,268519	0,927835	0,598177
0,233645	0,928571	0,581108
0,214953	0,928571	0,571762
0,198113	0,959596	0,578855

TULOSTAULUKOT
LIITE 1/3

Raja-arvo	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
yhd. 3,72%	74	0	22	0	4	105
yhd. 4,34%	73	1	22	0	5	104
yhd. 4,96%	73	1	22	0	5	104
yhd. 5,58%	69	2	21	1	9	103
yhd. 6,2%	69	2	20	2	9	103
yhd. 12,4%	49	9	16	6	29	96
yhd. 18,6%	27	25	12	10	51	80
yhd. 24,8%	22	42	8	14	56	63
yhd. 31,0%	14	49	7	15	64	56
yhd. 37,2%	13	59	6	16	65	46
yhd. 43,4%	12	68	4	18	66	37
yhd. 49,6%	10	74	4	18	68	31
yhd. 55,8%	7	79	3	19	71	26
yhd. 62,0%	7	82	2	20	71	23
yhd. 68,2%	7	84	2	20	71	21
yhd. 74,4%	4	85	1	21	74	20

Sensitiivisyys	Spesifisyys	Keskiarvo
1	0,051282	0,525641
0,992126	0,064103	0,528114
0,992126	0,064103	0,528114
0,984127	0,126582	0,555355
0,984	0,1375	0,56075
0,92562	0,416667	0,671143
0,786325	0,693182	0,739753
0,628319	0,76087	0,694594
0,5625	0,849462	0,705981
0,468468	0,861702	0,665085
0,376147	0,875	0,625573
0,321101	0,895833	0,608467
0,268519	0,927835	0,598177
0,233645	0,928571	0,581108
0,214953	0,928571	0,571762
0,198113	0,959596	0,578855

TULOSTAULUKOT
LIITE 1/4

ALKUPERÄINEN KESKIPISTE RAJA-ARVO 12,4% YHDISTETTYNÄ MUIHIN

alk. 12,4% +	Väärin tun- nistetut	Tunnistamatta jääneet	Ehkä tun- nistetut	Ehkä tunnistamat- tomat	Oikein tunnistamat- tomat	Oikein tun- nistetut	Sensitiivisyys	Spesifisyys	Keskiarvo
ole. 3,72%	69	1	21	1	9	104	0,992063	0,126582	0,559323
ole. 4,34%	66	1	21	1	12	104	0,992063	0,164557	0,57831
ole. 4,96%	66	2	21	1	12	103	0,984127	0,164557	0,574342
ole. 5,58%	63	3	20	2	15	102	0,976	0,2125	0,59425
ole. 6,2%	65	3	19	3	13	102	0,975806	0,197531	0,586669
ole. 12,4%	49	9	16	6	29	96	0,92562	0,416667	0,671143
ole. 18,6%	32	13	13	9	46	92	0,889831	0,632184	0,761007
ole. 24,8%	30	18	9	13	48	87	0,842105	0,67033	0,756217
ole. 31,0%	25	20	8	14	53	85	0,823009	0,728261	0,775635
ole. 37,2%	25	24	7	15	53	81	0,785714	0,731183	0,758449
ole. 43,4%	24	27	6	16	54	78	0,756757	0,744681	0,750719
ole. 49,6%	23	27	6	16	55	78	0,756757	0,755319	0,756038
ole. 55,8%	22	29	5	17	56	76	0,736364	0,768421	0,752392
ole. 62,0%	22	29	4	18	56	76	0,733945	0,770833	0,752389
ole. 68,2%	22	30	4	18	56	75	0,724771	0,770833	0,747802
ole. 74,4%	21	30	4	18	57	75	0,724771	0,78125	0,75301

VÄRIN TASAISUUSTULOKSET ERILLÄÄN

Raja-arvo	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
4i	20	29	28	17	28	83
5i	15	39	24	21	33	73
6i	13	46	21	24	35	66
7i	12	49	19	26	36	63
8i	9	51	18	27	39	61
9i	7	52	17	28	41	60
10i	16	64	14	31	32	48
12i	15	68	11	34	33	44
14i	12	73	10	35	36	39
16i	10	78	10	35	38	34
18i	10	80	9	36	38	32
20i	10	82	8	37	38	30

Sensitiivisyys	Spesifisyys	Keskiarvo
0,792857	0,692308	0,742582
0,713235	0,782609	0,747922
0,654135	0,819444	0,73679
0,625954	0,837838	0,731896
0,607692	0,88	0,743846
0,596899	0,907895	0,752397
0,492063	0,797468	0,644766
0,447154	0,817073	0,632114
0,401639	0,855422	0,628531
0,360656	0,879518	0,620087
0,338843	0,880952	0,609898
0,316667	0,882353	0,59951

TULOSTAULUKOT
LIITE 1/7

Raja-arvo	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	29	20	43	2	19	92
6/15/45	29	20	43	2	19	92
7/20/50	28	20	42	3	20	92
8/20/55	30	20	43	2	18	92
8/25/60	29	21	42	3	19	91
9/30/65	30	21	43	2	18	91
10/35/70	18	19	35	10	30	93
15/40/80	14	23	32	13	34	89
20/45/90	13	23	33	12	35	89
25/45/100	12	21	33	12	36	91
30/50/110	13	25	29	16	35	87
35/55/120	14	22	32	13	34	90

Sensitiivisyys	Spesifisyys	Keskiarvo
0,870968	0,42	0,645484
0,870968	0,42	0,645484
0,87013	0,45098	0,660555
0,870968	0,4	0,635484
0,863636	0,431373	0,647504
0,864516	0,4	0,632258
0,870748	0,689655	0,780202
0,840278	0,770492	0,805385
0,841379	0,783333	0,812356
0,855172	0,8	0,827586
0,822695	0,796875	0,809785
0,847222	0,770492	0,808857

VÄRIN TASAISUUSTULOKSET YHDISTETTYNÄ

4i +	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	32	8	44	1	16	104
6/15/45	32	8	44	1	16	104
7/20/50	32	8	44	1	16	104
8/20/55	32	8	44	1	16	104
8/25/60	32	8	44	1	16	104
9/30/65	32	8	44	1	16	104
10/35/70	28	5	41	4	20	107
15/40/80	26	5	39	6	22	107
20/45/90	26	5	39	6	22	107
25/45/100	26	5	39	6	22	107
30/50/110	26	5	39	6	22	107
35/55/120	26	5	39	6	22	107

Sensitiivisyys	Spesifisyys	Keskiarvo
0,948718	0,346939	0,647828
0,948718	0,346939	0,647828
0,948718	0,346939	0,647828
0,948718	0,346939	0,647828
0,948718	0,346939	0,647828
0,948718	0,346939	0,647828
0,96732	0,461538	0,714429
0,966887	0,518519	0,742703
0,966887	0,518519	0,742703
0,966887	0,518519	0,742703
0,966887	0,518519	0,742703
0,966887	0,518519	0,742703

TULOSTAULUKOT
LIITE 1/9

5i +	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	31	8	44	1	17	104
6/15/45	31	8	44	1	17	104
7/20/50	31	8	44	1	17	104
8/20/55	31	8	44	1	17	104
8/25/60	31	8	44	1	17	104
9/30/65	31	8	44	1	17	104
10/35/70	26	7	41	4	22	105
15/40/80	22	7	39	6	26	105
20/45/90	22	7	39	6	26	105
25/45/100	22	7	39	6	26	105
30/50/110	22	7	39	6	26	105
35/55/120	22	7	39	6	26	105

Sensitiivisyys	Spesifisyys	Keskiarvo
0,948718	0,367347	0,658032
0,948718	0,367347	0,658032
0,948718	0,367347	0,658032
0,948718	0,367347	0,658032
0,948718	0,367347	0,658032
0,948718	0,367347	0,658032
0,954248	0,5	0,727124
0,953642	0,592593	0,773117
0,953642	0,592593	0,773117
0,953642	0,592593	0,773117
0,953642	0,592593	0,773117
0,953642	0,592593	0,773117

TULOSTAULUKOT
LIITE 1/10

6i +	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	31	8	43	2	17	104
6/15/45	31	8	43	2	17	104
7/20/50	31	8	43	2	17	104
8/20/55	31	8	43	2	17	104
8/25/60	31	8	43	2	17	104
9/30/65	31	8	44	1	17	104
10/35/70	25	8	39	6	23	104
15/40/80	21	8	37	8	27	104
20/45/90	21	8	37	8	27	104
25/45/100	21	8	37	8	27	104
30/50/110	21	8	37	8	27	104
35/55/120	21	8	37	8	27	104

Sensitiivisyys	Spesifisyys	Keskiarvo
0,948387	0,38	0,664194
0,948387	0,38	0,664194
0,948387	0,38	0,664194
0,948387	0,38	0,664194
0,948387	0,38	0,664194
0,948718	0,367347	0,658032
0,94702	0,537037	0,742028
0,946309	0,625	0,785654
0,946309	0,625	0,785654
0,946309	0,625	0,785654
0,946309	0,625	0,785654
0,946309	0,625	0,785654

TULOSTAULUKOT
LIITE 1/11

7i +	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	31	8	43	2	17	104
6/15/45	31	8	43	2	17	104
7/20/50	31	8	43	2	17	104
8/20/55	31	8	43	2	17	104
8/25/60	31	8	43	2	17	104
9/30/65	31	8	44	1	17	104
10/35/70	25	9	38	7	23	103
15/40/80	21	10	36	9	27	102
20/45/90	21	10	36	9	27	102
25/45/100	21	10	36	9	27	102
30/50/110	21	10	36	9	27	102
35/55/120	21	10	36	9	27	102

Sensitiivisyys	Spesifisyys	Keskiarvo
0,948387	0,38	0,664194
0,948387	0,38	0,664194
0,948387	0,38	0,664194
0,948387	0,38	0,664194
0,948387	0,38	0,664194
0,948718	0,367347	0,658032
0,94	0,545455	0,742727
0,932432	0,631579	0,782006
0,932432	0,631579	0,782006
0,932432	0,631579	0,782006
0,932432	0,631579	0,782006
0,932432	0,631579	0,782006

TULOSTAULUKOT
LIITE 1/12

8i +	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	30	8	43	2	18	104
6/15/45	30	8	43	2	18	104
7/20/50	30	8	43	2	18	104
8/20/55	31	8	43	2	17	104
8/25/60	31	8	43	2	17	104
9/30/65	31	8	44	1	17	104
10/35/70	22	9	37	8	26	103
15/40/80	18	10	35	10	30	102
20/45/90	18	10	35	10	30	102
25/45/100	18	10	35	10	30	102
30/50/110	18	11	35	10	30	101
35/55/120	18	10	35	10	30	102

Sensitiivisyys	Spesifisyys	Keskiarvo
0,948387	0,4	0,674194
0,948387	0,4	0,674194
0,948387	0,4	0,674194
0,948387	0,38	0,664194
0,948387	0,38	0,664194
0,948718	0,367347	0,658032
0,939597	0,607143	0,77337
0,931973	0,689655	0,810814
0,931973	0,689655	0,810814
0,931973	0,689655	0,810814
0,92517	0,689655	0,807413
0,931973	0,689655	0,810814

TULOSTAULUKOT
LIITE 1/13

9i +	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	30	8	43	2	18	104
6/15/45	30	8	43	2	18	104
7/20/50	29	8	43	2	19	104
8/20/55	31	8	43	2	17	104
8/25/60	30	8	43	2	18	104
9/30/65	31	8	44	1	17	104
10/35/70	20	9	37	8	28	103
15/40/80	16	10	35	10	32	102
20/45/90	16	10	35	10	32	102
25/45/100	16	10	35	10	32	102
30/50/110	16	11	35	10	32	101
35/55/120	16	10	35	10	32	102

Sensitiivisyys	Spesifisyys	Keskiarvo
0,948387	0,4	0,674194
0,948387	0,4	0,674194
0,948387	0,42	0,684194
0,948387	0,38	0,664194
0,948387	0,4	0,674194
0,948718	0,367347	0,658032
0,939597	0,642857	0,791227
0,931973	0,724138	0,828055
0,931973	0,724138	0,828055
0,931973	0,724138	0,828055
0,92517	0,724138	0,824654
0,931973	0,724138	0,828055

TULOSTAULUKOT
LIITE 1/14

10i +	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	38	12	43	2	10	100
6/15/45	38	12	43	2	10	100
7/20/50	37	12	42	3	11	100
8/20/55	38	12	43	2	10	100
8/25/60	37	12	43	2	11	100
9/30/65	38	12	44	1	10	100
10/35/70	28	9	37	8	20	103
15/40/80	25	10	35	10	23	102
20/45/90	25	10	35	10	23	102
25/45/100	25	10	35	10	23	102
30/50/110	25	10	35	10	23	102
35/55/120	25	10	35	10	23	102

Sensitiivisyys	Spesifisyys	Keskiarvo
0,922581	0,24	0,58129
0,922581	0,24	0,58129
0,922078	0,27451	0,598294
0,922581	0,24	0,58129
0,922581	0,26	0,59129
0,923077	0,22449	0,573783
0,939597	0,5	0,719799
0,931973	0,568966	0,750469
0,931973	0,568966	0,750469
0,931973	0,568966	0,750469
0,931973	0,568966	0,750469
0,931973	0,568966	0,750469

TULOSTAULUKOT
LIITE 1/15

12i +	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	38	13	43	2	10	99
6/15/45	38	13	43	2	10	99
7/20/50	37	13	42	3	11	99
8/20/55	38	13	43	2	10	99
8/25/60	37	13	43	2	11	99
9/30/65	38	13	44	1	10	99
10/35/70	28	11	37	8	20	101
15/40/80	24	12	35	10	24	100
20/45/90	24	12	35	10	24	100
25/45/100	24	12	35	10	24	100
30/50/110	24	12	35	10	24	100
35/55/120	24	12	35	10	24	100

Sensitiivisyys	Spesifisyys	Keskiarvo
0,916129	0,24	0,578065
0,916129	0,24	0,578065
0,915584	0,27451	0,595047
0,916129	0,24	0,578065
0,916129	0,26	0,588065
0,916667	0,22449	0,570578
0,926174	0,5	0,713087
0,918367	0,586207	0,752287
0,918367	0,586207	0,752287
0,918367	0,586207	0,752287
0,918367	0,586207	0,752287
0,918367	0,586207	0,752287

TULOSTAULUKOT
LIITE 1/16

14i +	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	35	13	43	2	13	99
6/15/45	35	13	43	2	13	99
7/20/50	34	13	42	3	14	99
8/20/55	36	13	43	2	12	99
8/25/60	35	13	43	2	13	99
9/30/65	36	13	44	1	12	99
10/35/70	25	12	37	8	23	100
15/40/80	21	13	35	10	27	99
20/45/90	21	13	35	10	27	99
25/45/100	21	13	35	10	27	99
30/50/110	21	13	35	10	27	99
35/55/120	21	13	35	10	27	99

Sensitiivisyys	Spesifisyys	Keskiarvo
0,916129	0,3	0,608065
0,916129	0,3	0,608065
0,915584	0,333333	0,624459
0,916129	0,28	0,598065
0,916129	0,3	0,608065
0,916667	0,265306	0,590986
0,919463	0,553571	0,736517
0,911565	0,637931	0,774748
0,911565	0,637931	0,774748
0,911565	0,637931	0,774748
0,911565	0,637931	0,774748
0,911565	0,637931	0,774748

TULOSTAULUKOT
LIITE 1/17

16i +	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	34	13	43	2	14	99
6/15/45	34	13	43	2	14	99
7/20/50	33	13	42	3	15	99
8/20/55	35	13	43	2	13	99
8/25/60	34	13	43	2	14	99
9/30/65	35	13	44	1	13	99
10/35/70	24	12	37	8	24	100
15/40/80	20	14	35	10	28	98
20/45/90	20	14	35	10	28	98
25/45/100	20	13	35	10	28	99
30/50/110	20	13	35	10	28	99
35/55/120	20	13	35	10	28	99

Sensitiivisyys	Spesifisyys	Keskiarvo
0,916129	0,32	0,618065
0,916129	0,32	0,618065
0,915584	0,352941	0,634263
0,916129	0,3	0,608065
0,916129	0,32	0,618065
0,916667	0,285714	0,60119
0,919463	0,571429	0,745446
0,904762	0,655172	0,779967
0,904762	0,655172	0,779967
0,911565	0,655172	0,783369
0,911565	0,655172	0,783369
0,911565	0,655172	0,783369

TULOSTAULUKOT
LIITE 1/18

18i +	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	34	13	43	2	14	99
6/15/45	34	13	43	2	14	99
7/20/50	33	13	42	3	15	99
8/20/55	35	13	43	2	13	99
8/25/60	34	13	43	2	14	99
9/30/65	35	13	44	1	13	99
10/35/70	24	12	37	8	24	100
15/40/80	20	14	35	10	28	98
20/45/90	20	14	35	10	28	98
25/45/100	20	13	35	10	28	99
30/50/110	20	13	34	11	28	99
35/55/120	20	13	34	11	28	99

Sensitiivisyys	Spesifisyys	Keskiarvo
0,916129	0,32	0,618065
0,916129	0,32	0,618065
0,915584	0,352941	0,634263
0,916129	0,3	0,608065
0,916129	0,32	0,618065
0,916667	0,285714	0,60119
0,919463	0,571429	0,745446
0,904762	0,655172	0,779967
0,904762	0,655172	0,779967
0,911565	0,655172	0,783369
0,910959	0,661017	0,785988
0,910959	0,661017	0,785988

TULOSTAULUKOT
LIITE 1/19

20i +	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
5/15/40	34	13	43	2	14	99
6/15/45	34	13	43	2	14	99
7/20/50	33	13	42	3	15	99
8/20/55	35	13	43	2	13	99
8/25/60	34	13	43	2	14	99
9/30/65	35	13	44	1	13	99
10/35/70	24	13	37	8	24	99
15/40/80	20	15	35	10	28	97
20/45/90	20	15	35	10	28	97
25/45/100	20	14	35	10	28	98
30/50/110	20	14	33	12	28	98
35/55/120	20	15	34	11	28	97

Sensitiivisyys	Spesifisyys	Keskiarvo
0,916129	0,32	0,618065
0,916129	0,32	0,618065
0,915584	0,352941	0,634263
0,916129	0,3	0,608065
0,916129	0,32	0,618065
0,916667	0,285714	0,60119
0,912752	0,571429	0,74209
0,897959	0,655172	0,776566
0,897959	0,655172	0,776566
0,904762	0,655172	0,779967
0,903448	0,666667	0,785057
0,89726	0,661017	0,779139

REUNANTASAISUUSTULOKSET

Raja-arvo	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
4,50 %	10	56	7	47	71	14
4 %	10	55	7	47	71	15
3,50 %	10	54	7	47	71	16
3 %	10	53	7	47	71	17
2,50 %	10	53	7	47	71	17
2 %	11	53	8	46	70	17
1,50 %	11	53	9	45	70	17
1 %	11	53	10	44	70	17
-0,02	9	50	10	44	72	20
-3 %	10	50	11	43	71	20
-4 %	10	50	11	43	71	20
-5 %	10	50	11	43	71	20
-6 %	13	49	11	43	68	21
-7 %	81	0	54	0	0	70
-8 %	15	49	11	43	66	21

Sensitiivisyys	Spesifisyys	Keskiarvo
0,272727	0,921875	0,597301
0,285714	0,921875	0,603795
0,298701	0,921875	0,610288
0,311688	0,921875	0,616782
0,311688	0,921875	0,616782
0,320513	0,913386	0,616949
0,329114	0,912698	0,620906
0,3375	0,912	0,62475
0,375	0,928	0,6515
0,382716	0,919355	0,651035
0,382716	0,919355	0,651035
0,382716	0,919355	0,651035
0,395062	0,895161	0,645112
1	0	0,5
0,395062	0,879032	0,637047

TULOSTAULUKOT
LIITE 1/21

Raja-arvo	Väärin tunnistetut	Tunnistamatta jääneet	Ehkä tunnistetut	Ehkä tunnistamattomat	Oikein tunnistamattomat	Oikein tunnistetut
-10 %	16	47	11	43	65	23
-11 %	16	46	12	42	65	24
-12 %	19	45	12	42	62	25
-13 %	20	44	13	41	61	26
-14 %	22	43	14	40	59	27
-15 %	23	42	15	39	58	28
-16 %	25	39	15	39	56	31
-18 %	26	38	17	37	55	32
-19 %	28	38	17	37	53	32
-20 %	29	38	18	36	52	32
-21 %	29	38	19	35	52	32
-22 %	32	37	20	34	49	33
-23 %	33	36	20	34	48	34
-24 %	36	33	21	33	45	37

Sensitiivisyys	Spesifisyys	Keskiarvo
0,419753	0,870968	0,64536
0,439024	0,869919	0,654472
0,45122	0,845528	0,648374
0,46988	0,836066	0,652973
0,488095	0,818182	0,653139
0,505882	0,808333	0,657108
0,541176	0,791667	0,666422
0,563218	0,779661	0,67144
0,563218	0,762712	0,662965
0,568182	0,752137	0,660159
0,573034	0,75	0,661517
0,588889	0,721739	0,655314
0,6	0,713043	0,656522
0,637363	0,684211	0,660787

HALKAISIJA

Luomen nro.	Tulos	Luokitus
1.	148,0844	144
2.	137,4809	137
3.	145,6743	154
4.	165,3269	157
5.	252,7924	241
6.	238,7677	240
7.	728,4538	720
8.	224,6286	227
9.	158,2688	159
10.	118,9496	120
11.	172,4094	183
12.	198,2826	182
13(1).	293,8248	286
13(2).	210,6229	219
13(3).	128,0156	110
13(4).	139,9178	135
14.	231,0346	230
15.	324,0015	300
16.	176,6154	199
17.	148,6607	159
18.	148,3543	139
19.	182,9891	178
20.	292,2259	289
21.	289,4426	309
22.	71,56815	69
23.	211,6837	208
24.	62,00806	56
25.	113,0708	136
26.	143,9618	149
27.	60,13319	56
28.	222,8991	218
29.	149,3452	151
30.	139,1761	137
31.	163,1962	164
32.	179,1201	140
33.	83,60024	86
34.	538,0149	504
35.	150,2165	158
36.	266,9232	294
37.	87,66413	94
38.	146,0034	153
39.	301,5245	285

Luomen nro.	Tulos	Luokitus
40.	227,0705	246
41.	139,2623	321
42(1).	185,7767	198
42(2).	117,1708	92
43.	82,8553	81
44.	300,3748	308
45.	388	269
46.	171,0468	190
47.	250,3917	250
48.	53,23533	58
49.	82,0061	76
50.	258,8745	245
51.	316,242	324
52.	59,03389	51
53.	195,9311	212
54.	242,72	226
55.	144,0139	131
56.	148,2228	152
57.	355,9508	359
58.	287,3917	234
59.	95,27329	101
60.	209,6783	205
61.	233,2381	247
62.	216,1782	219
63.	321,8229	333
64.	107,042	109
65.	284,6928	288
66.	337,1469	355
67.	326,5471	336
68.	149,2716	144
69.	113,0177	106
70.	374,9573	381
71.	108,2266	105
72.	489,2535	489
73(1).	405,0938	381
73(2).	365,7609	389
74.	226,241	210
75.	427,4248	454
76.	167,4873	169
77.	144,17	145
78.	314,7348	331
79.	223,7543	235

PARHAAT TULOKSET
LIITE 2/2

Luomen nro.	Tulos	Luokitus
80.	77,41447	79
81.	361,3585	353
82.	220,9887	223
83.	47,01064	47
84.	456,3957	449
85.	144,3918	137
86.	61,40033	68
87.	323,2739	302
88.	304,1989	298
89.	248,1149	260
90.	216,3724	237
91.	239,0084	256
92.	158,5339	156
93.	70,00714	75
94.	158,3982	156
95.	293,8656	254
96.	73,97973	75
97.	265,3696	264
98.	72,1734	72
99.	260,8927	262
100.	426,6767	434
101.	145,4957	146
102.	156,9235	154
103.	273,3368	300
104.	148,0034	153
105.	167,863	169
106.	47,67599	45
107.	51,62364	55
108.	191,0419	180
109(1).	223,7878	247
109(2).	95,07891	96
109(3).	52,00961	50
110.	153,5513	153
111(1).	112,0179	107
111(2).	85,58621	82
111(3).	74,33034	74
112(1).	133,1503	129
112(2).	46,51881	36
113.	178,2134	176
114.	126,7517	90
115.	209,4612	209
116.	230	227
117.	189,6154	185

Luomen nro.	Tulos	Luokitus
118.	101,1385	93
119.	267,4023	277
120.	66,09841	65
121.	165,7377	169
122.	202,0817	219
123.	164,3472	168
124.	105,9481	115
125.	166,012	156
126.	227,3697	229
127.	171,4205	170
128.	228,6154	220
129.	141,2268	133
130.	241,0332	244
131.	200,8781	178
132.	178,059	167
133.	148,4756	154
134.	151,1622	141
135.	65,73431	63
136.	153,4438	150
137.	94,41398	97
138.	147,7058	134
139.	89,02247	89
140.	126,0159	125
141.	124,4588	128
142.	179,4018	166
143.	136,3562	142
144.	66,85058	63
145.	68,65858	71
146.	61,03278	56
147.	63,78871	64
148.	72,56032	74
149.	72,56032	74
150.	85,70298	79
151.	88,02272	87
152.	99,29753	100
153.	115,2779	113
154.	115,2779	116
155.	135,5175	137
156.	81,7435	86
157.	81,7435	86
158.	81,7435	88
159.	94,04786	98
160.	111,4271	116

PARHAAT TULOKSET
LIITE 2/3

Luomen nro.	Tulos	Luokitus
161.	111,4271	116
162.	111,4271	116
163.	111,4271	116
164.	111,4271	116
165.	111,4271	116
166.	77,41447	79
167.	91,41663	94
168.	88,56636	97
169.	101,9215	107
170.	119,8541	118
171.	119,8541	118
172.	120,075	120
173.	132,7742	133
174.	132,7742	133
175.	147,4924	149
176.	89,02247	89
177.	100,449	98
178.	109,8954	108
179.	115,5249	112
180.	119,2057	115
181.	133,1353	129
182.	144,5441	143
183.	149,4824	145
184.	149,4824	145
185.	157,0032	153
186.	70,93659	63
187.	82,20097	66
188.	93,55747	84
189.	93,55747	84
190.	110,7249	107
191.	112,2854	110
192.	134,2125	137
193.	149,1208	143
194.	149,1208	143
195.	149,1208	143

SYMMETRIA, ALKUPERÄINEN 12,4% JA OLETETTU KESKIPISTE 31,0%

Luomen nro.	Tulos alk. 12,4%	Tulos ole. 31,0%	Luokitus
1.	1	0	1
2.	1	0	1
3.	0	0	0
4.	0	0	0
5.	0	0	0
6.	0	0	1
7.	0	0	1
8.	0	0	0
9.	0	0	0
10.	1	1	1
11.	0	0	0,5
12.	0	0	0
13(1).	0	1	1
13(2).	0	0	0,5
13(3).	1	1	1
13(4).	0	1	0,5
14.	0	1	1
15.	0	0	1
16.	1	1	1
17.	1	1	0
18.	0	0	0
19.	0	0	1
20.	1	1	1
21.	0	0	0
22.	1	0	0
23.	0	0	1
24.	0	1	0
25.	1	1	0
26.	0	1	1
27.	1	1	1
28.	0	0	0
29.	0	0	0
30.	0	0	0,5
31.	0	0	0,5
32.	0	1	0
33.	1	1	1
34.	0	0	0
35.	0	0	0,5
36.	0	1	1
37.	1	1	0
38.	0	0	0

Luomen nro.	Tulos alk. 12,4%	Tulos ole. 31,0%	Luokitus
39.	0	0	1
40.	0	0	0
41.	0	0	0,5
42(1).	1	0	1
42(2).	1	1	1
43.	0	0	0
44.	0	1	1
45.	0	0	0
46.	0	0	0
47.	1	0	1
48.	1	1	0
49.	0	0	0
50.	0	0	0
51.	1	0	1
52.	1	0	0
53.	0	0	1
54.	0	0	0
55.	0	0	0
56.	0	1	0
57.	0	0	1
58.	0	0	0
59.	1	1	1
60.	0	1	1
61.	1	1	1
62.	0	0	0
63.	0	1	1
64.	1	1	1
65.	1	1	1
66.	0	0	0
67.	0	0	0,5
68.	0	1	0,5
69.	0	0	0
70.	0	0	0
71.	0	0	0,5
72.	0	0	1
73(1).	0	1	1
73(2).	0	0	0
74.	1	1	1
75.	1	1	1
76.	1	0	1
77.	0	0	1

PARHAAT TULOKSET
LIITE 2/5

Luomen nro.	Tulos alk. 12,4%	Tulos ole. 31,0%	Luokitus
78.	0	0	1
79.	0	0	0
80.	1	1	1
81.	0	0	0
82.	1	0	1
83.	1	1	1
84.	0	1	1
85.	1	0	1
86.	1	1	1
87.	0	0	0,5
88.	0	0	0
89.	0	0	0
90.	0	0	1
91.	1	0	1
92.	0	0	0
93.	0	1	1
94.	0	0	0
95.	1	1	0
96.	1	1	0,5
97.	0	0	1
98.	1	0	1
99.	0	0	0,5
100.	0	0	1
101.	0	0	0
102.	0	0	1
103.	0	0	0
104.	1	0	1
105.	0	0	0
106.	1	0	0
107.	1	1	0
108.	0	0	1
109(1).	0	0	1
109(2).	1	0	1
109(3).	0	1	1
110.	0	0	0
111(1).	1	1	1
111(2).	0	0	0
111(3).	1	0	0
112(1).	0	1	1
112(2).	0	1	0
113.	0	0	0,5
114.	1	1	1

Luomen nro.	Tulos alk. 12,4%	Tulos ole. 31,0%	Luokitus
115.	0	0	1
116.	0	1	0
117.	0	0	1
118.	0	1	0,5
119.	0	0	0
120.	1	1	0
121.	1	0	1
122.	1	0	1
123.	1	1	1
124.	1	0	0,5
125.	0	1	1
126.	1	0	1
127.	0	0	0
128.	0	0	0
129.	1	1	0
130.	0	0	0,5
131.	1	0	1
132.	0	0	0,5
133.	1	1	1
134.	0	0	0
135.	1	0	0
136.	1	0	1
137.	1	1	1
138.	0	0	0
139.	0	0	0
140.	0	0	0,5
141.	1	1	0,5
142.	1	0	1
143.	0	1	1
144.	1	0	0
145.	0	1	1
146.	0	0	0
147.	1	1	0,5
148.	0	1	0,5
149.	1	1	1
150.	1	1	1
151.	1	1	1
152.	1	1	1
153.	1	1	1
154.	1	1	1
155.	1	1	1
156.	1	1	1

PARHAAT TULOKSET
LIITE 2/6

Luomen nro.	Tulos alk. 12,4%	Tulos ole. 31,0%	Luokitus
157.	1	1	1
158.	1	0	1
159.	1	1	1
160.	1	0	1
161.	1	0	1
162.	1	0	1
163.	1	0	1
164.	1	0	1
165.	1	0	1
166.	1	0	0
167.	1	1	1
168.	0	0	1
169.	1	0	1
170.	0	1	1
171.	0	1	1
172.	1	0	1
173.	1	0	1
174.	1	0	1
175.	1	0	1
176.	0	1	0
177.	1	0	0
178.	0	0	0
179.	0	0	0
180.	0	0	0
181.	0	0	0
182.	0	0	0
183.	0	0	0
184.	0	0	0
185.	0	0	0
186.	1	0	0
187.	0	0	0
188.	1	0	0
189.	1	0	0
190.	1	1	1
191.	1	1	1
192.	1	0	1
193.	1	0	1
194.	1	0	1
195.	1	0	1

PARHAAT TULOKSET
LIITE 2/7

VÄRIN TASAISUUS 9i + 25/45/100

Luomen nro.	Tulos 9i	Tulos 25/45/100	Luokitus
1.	1	1	1
2.	1	1	1
3.	1	1	0,5
4.	0	1	0,5
5.	1	1	0,5
6.	0	1	0,5
7.	0	1	1
8.	1	1	0,5
9.	0	0	0,5
10.	0	0	0
11.	1	0	0
12.	1	0	1
13(1).	0	1	1
13(2).	1	1	1
13(3).	0	1	0
13(4).	1	0	1
14.	1	1	1
15.	0	1	1
16.	0	0	1
17.	0	1	1
18.	0	0	0
19.	1	1	1
20.	0	1	1
21.	0	1	1
22.	0	0	0
23.	0	0	0,5
24.	1	0	0
25.	0	0	1
26.	1	1	1
27.	1	1	0,5
28.	0	0	0
29.	0	1	0
30.	0	1	1
31.	1	1	1
32.	0	1	1
33.	1	1	0,5
34.	0	1	1
35.	1	1	0
36.	1	1	1
37.	0	0	0
38.	0	1	1

Luomen nro.	Tulos 9i	Tulos 25/45/100	Luokitus
39.	0	1	1
40.	0	1	1
41.	0	1	1
42(1).	0	0	0
42(2).	0	0	0,5
43.	0	0	0,5
44.	0	1	1
45.	0	1	0,5
46.	0	0	1
47.	0	1	1
48.	1	0	0,5
49.	1	1	1
50.	0	1	1
51.	0	1	0
52.	0	0	0
53.	0	1	1
54.	1	1	1
55.	0	0	1
56.	1	1	1
57.	0	1	0
58.	0	1	1
59.	0	0	0,5
60.	0	0	1
61.	0	0	0,5
62.	0	1	0,5
63.	0	1	1
64.	1	1	1
65.	0	1	1
66.	0	1	1
67.	1	1	1
68.	1	1	0,5
69.	0	1	1
70.	0	0	1
71.	0	1	0,5
72.	0	1	0
73(1).	0	1	1
73(2).	0	0	0
74.	1	1	1
75.	1	0	1
76.	0	0	0
77.	0	1	1

PARHAAT TULOKSET
LIITE 2/8

Luomen nro.	Tulos 9i	Tulos 25/45/100	Luokitus
78.	0	1	1
79.	0	1	0,5
80.	0	0	0
81.	1	1	1
82.	0	0	0,5
83.	0	0	0
84.	0	1	1
85.	0	0	1
86.	0	1	0
87.	0	1	1
88.	1	1	1
89.	0	0	1
90.	0	1	1
91.	1	1	1
92.	1	1	1
93.	0	0	0
94.	1	1	1
95.	1	1	1
96.	1	1	0,5
97.	1	1	1
98.	0	1	0
99.	0	1	1
100.	0	1	1
101.	1	1	0,5
102.	0	0	1
103.	1	1	0,5
104.	0	0	0,5
105.	1	1	1
106.	0	0	0
107.	1	0	1
108.	1	1	1
109(1).	0	1	1
109(2).	0	0	0
109(3).	1	0	0
110.	1	1	1
111(1).	1	1	1
111(2).	1	0	1
111(3).	1	1	0
112(1).	0	1	0,5
112(2).	0	0	0
113.	0	1	1
114.	1	1	0,5

Luomen nro.	Tulos 9i	Tulos 25/45/100	Luokitus
115.	1	0	1
116.	0	1	1
117.	0	1	0
118.	1	0	1
119.	0	1	0,5
120.	0	0	0,5
121.	1	1	1
122.	0	0	0,5
123.	0	0	1
124.	1	1	1
125.	1	1	1
126.	1	1	1
127.	0	1	1
128.	0	1	1
129.	0	0	0
130.	0	1	0,5
131.	0	1	0,5
132.	0	1	0,5
133.	1	0	1
134.	0	0	0
135.	1	0	0,5
136.	1	0	1
137.	1	1	1
138.	0	1	0
139.	1	1	1
140.	1	1	0
141.	1	1	1
142.	1	1	1
143.	1	1	0,5
144.	0	0	0
145.	1	1	0,5
146.	1	0	0
147.	1	1	1
148.	1	1	1
149.	1	1	1
150.	1	1	1
151.	1	1	1
152.	1	1	1
153.	1	1	1
154.	0	1	1
155.	1	1	1
156.	0	1	0,5

PARHAAT TULOKSET
LIITE 2/9

Luomen nro.	Tulos 9i	Tulos 25/45/100	Luokitus
157.	0	1	0,5
158.	1	1	0,5
159.	1	1	0,5
160.	0	1	0,5
161.	0	1	0,5
162.	0	1	0,5
163.	0	1	0,5
164.	0	1	0,5
165.	1	1	0,5
166.	0	0	0
167.	0	0	0
168.	0	0	0
169.	0	0	0
170.	0	0	0
171.	0	0	0
172.	0	0	0
173.	0	0	0
174.	0	0	0
175.	0	0	0
176.	1	1	1
177.	1	1	1
178.	1	1	1
179.	1	1	1
180.	0	1	1
181.	0	1	1
182.	0	1	1
183.	0	1	1
184.	0	1	1
185.	0	1	1
186.	0	0	0
187.	0	0	0
188.	0	0	0
189.	0	0	0
190.	1	0	1
191.	1	0	1
192.	1	1	1
193.	1	1	1
194.	1	1	1
195.	1	1	1

REUNOJEN TASAISUUS -18%

Luomen nro.	Tulos	Luokitus
1.	1	0
2.	0	0
3.	1	0,5
4.	1	0
5.	0	0
6.	1	1
7.	1	1
8.	1	1
9.	0	0
10.	0	0,5
11.	0	1
12.	0	0
13(1).	1	1
13(2).	1	1
13(3).	1	0
13(4).	1	1
14.	1	1
15.	1	0,5
16.	1	1
17.	1	1
18.	0	0
19.	0	0,5
20.	0	1
21.	1	1
22.	0	0,5
23.	0	0,5
24.	0	0
25.	1	0,5
26.	1	0,5
27.	0	1
28.	0	0,5
29.	0	0,5
30.	0	0,5
31.	0	0
32.	1	0
33.	0	1
34.	1	0
35.	0	0
36.	1	0,5
37.	0	0
38.	0	0,5

Luomen nro.	Tulos	Luokitus
39.	1	1
40.	1	0,5
41.	0	1
42(1).	1	1
42(2).	1	1
43.	0	0,5
44.	1	0,5
45.	1	0
46.	0	0
47.	1	1
48.	0	0
49.	0	0
50.	1	0
51.	1	0
52.	0	0
53.	0	1
54.	1	0
55.	1	0
56.	0	0
57.	1	1
58.	1	0
59.	1	0
60.	0	0
61.	1	0
62.	0	0,5
63.	0	1
64.	0	0,5
65.	1	1
66.	0	1
67.	1	0,5
68.	0	0
69.	0	0,5
70.	0	0,5
71.	0	0
72.	1	1
73(1).	1	1
73(2).	1	0,5
74.	0	0
75.	1	1
76.	0	0,5
77.	0	1

PARHAAT TULOKSET
LIITE 2/11

Luomen nro.	Tulos	Luokitus
78.	1	1
79.	1	0
80.	0	0,5
81.	0	1
82.	0	0
83.	0	1
84.	1	0,5
85.	1	0,5
86.	0	1
87.	1	0
88.	0	0
89.	1	0,5
90.	1	0
91.	1	1
92.	0	0,5
93.	0	0
94.	1	1
95.	1	0,5
96.	0	0,5
97.	0	0
98.	0	0
99.	1	0,5
100.	1	1
101.	1	0
102.	0	0,5
103.	1	0
104.	0	0,5
105.	1	0
106.	0	0,5
107.	0	0
108.	1	1
109(1).	1	1
109(2).	0	1
109(3).	0	0
110.	0	0
111(1).	0	1
111(2).	0	0
111(3).	1	0
112(1).	0	1
112(2).	0	0
113.	1	1
114.	0	0

Luomen nro.	Tulos	Luokitus
115.	1	0
116.	0	0
117.	1	0
118.	1	0
119.	0	0
120.	0	0
121.	1	0
122.	1	0,5
123.	1	1
124.	0	1
125.	1	1
126.	1	0
127.	1	0,5
128.	1	0,5
129.	1	1
130.	0	1
131.	1	0
132.	0	0
133.	0	0
134.	0	0
135.	0	0
136.	0	0
137.	0	0,5
138.	0	0
139.	0	0
140.	0	1
141.	1	1
142.	1	1
143.	1	1
144.	0	0
145.	0	0,5
146.	0	0
147.	0	0
148.	0	0
149.	0	0,5
150.	0	1
151.	0	1
152.	0	0,5
153.	0	0,5
154.	0	1
155.	0	1
156.	0	1

PARHAAT TULOKSET
LIITE 2/12

Luomen nro.	Tulos	Luokitus
157.	0	0,5
158.	0	0,5
159.	0	0,5
160.	0	0,5
161.	0	0,5
162.	0	0,5
163.	0	0,5
164.	0	0,5
165.	0	0,5
166.	0	0,5
167.	0	0
168.	0	0,5
169.	0	1
170.	0	1
171.	0	1
172.	0	1
173.	0	1
174.	0	1
175.	0	1
176.	0	0
177.	0	0
178.	0	0
179.	0	0
180.	0	0
181.	0	0
182.	0	0
183.	0	0
184.	0	0
185.	0	0
186.	0	0
187.	0	0,5
188.	0	1
189.	0	1
190.	0	1
191.	0	1
192.	0	1
193.	0	1
194.	0	1
195.	0	1