
**Kuituverkoston yksityiskohtainen analysointi korkean
resoluution kolmiulotteisista kuvista**

Arttu Miettinen



Pro gradu - tutkielma
JYVÄSKYLÄN YLIOPISTO
FYSIIKAN LAITOS
2009

Tiivistelmä

Tässä työssä kehitetään menetelmä kuitumaisten objektien erotteluun kolmiulotteisista kuvista. Erotteluprosessi sisältää kuituverkoston ja muun materiaalin toisistaan erottamisen lisäksi verkoston yksittäisten kuitujen erottelun. Lisäksi esitellään menetelmiä erotettujen kuitujen analysoimiseen. Kehitettävä algoritmi käsittelee aidosti kolmiulotteista kuvadataa eikä sen toiminta vaadi käyttäjältä mitään ajonaikaisia toimenpiteitä, joten se soveltuu hyvin suurtenkin kuvien analysointiin.

Menetelmä osoittautuu luotettavaksi kun tutkittavan kuituverkoston kuidut ovat sattumanvaraisesti orientoituneita ja niiden osuus koko näytteen tilavuudesta ei ylitä kymmentä prosenttia. Mikäli suuri osa kuiduista on suuntautunut samaan suuntaan, erottelun tarkkuus huononee. Työn loppupuolella esitellään jatkokehitysehdotuksia, joilla tämä epätoivottava käyttäytyminen saataneen poistettua.

Työn ohjaajana toimi Markku Kataja.

Sisältö

1	Johdanto	1
2	Katsaus olemassaoleviin menetelmiin	4
3	Kuituverkostojen analysointi	11
3.1	Yleistä kuituverkostojen tutkimisesta	11
3.2	Määritelmiä	13
3.3	Kuitujen tunnistaminen ja erottelu toisistaan	17
3.3.1	Kuituvokselien ranko	18
3.3.2	Rangon pisteiden luokittelu ja risteysalueet muodostavien pisteiden etsiminen	21
3.3.3	Alueiden luokittelu ja yhdistely	24
3.3.4	Alkuperäisen kuituverkoston regenerointi	29
3.4	Menetelmiä yksittäisen kuidun analysointiin	29
3.4.1	Kuidun poikkileikkausten määrittäminen	31
3.4.2	Kuidun poikkileikkauksiin perustuvia piirteitä	38
3.4.3	Kuidun käyryys	46
4	Analyysimenetelmien testausta	48
4.1	Tietokoneella luodut rakenteet	48
4.2	Todellinen komposiittimateriaali	50
4.3	Parannusehdotuksia	52

5 Johtopäätökset

58

Viitteet

59

Kuvat

1	Alkuperäinen materiaali	5
2	Kuidun poikkileike ja sen summaprojektio	9
3	Keskimmäisen kuvapisteen 6-, 12-, 18- ja 26-ympäristöt	16
4	Keskiakselijoukko	19
5	Erilaisia rankoja	20
6	Ehdot kuvapisteen yksinkertaisuudelle	22
7	Rangon pisteiden luokittelu kaksiulotteisessa tapauksessa	23
8	Rangon pisteiden luokittelu kolmiulotteisessa tapauksessa	23
9	Epäsäännöllisen objektin ranko	25
10	Rangon alueiden sulauttaminen kaksiulotteisessa tapauksessa	27
11	Pääkomponenttianalyysi	27
12	Erotetut kuidut	30
13	Tasamittainen kuutiollinen B-splini	34
14	Kuitujen uudelleensiivutuksessa käytettävä koordinaatisto	37
15	Piirteiden vertailua	39
16	Konvekssi runko	41
17	Rasteroitu objekti, sen ala ja reunan pituus	45
18	Splinien energioiden vertailua	47
19	Tietokoneella luodulle näytteelle suoritettun kuitutunnistuksen tulos . . .	49

20	Tunnistettujen kuitujen lukumäärä kuitutilavuuden funktiona	51
21	Tunnistettuja kuituja	53

1 Johdanto

Komposiittimateriaaliksi sanotaan ainetta, joka koostu ainakin kahdesta erilaisesta materiaalista, jotka eivät ole lienneet tai muuten sulautuneet toisiinsa, mutta vaikuttavat materiaalin ominaisuuksiin yhdessä. Yleensä toinen materiaaleista koostuu kuiduista ja toinen yhtenäisestä massasta, kuten muovista. Massaa, johon kuidut on upotettu, sanotaan matriisimateriaaliksi. Komposiittimateriaaleja suunniteltaessa pyritään yhdistämään osamateriaalien ominaisuudet niin, että yhdistetyssä aineessa osamateriaalien hyvät ominaisuudet korostuvat ja huonot vaimenevat tai häviävät kokonaan. Optimoitavia ominaisuuksia voivat olla esimerkiksi kestävyys, hinta ja massa. [Wik09]

Komposiittimateriaaleja käytetään monissa arkipäiväisissäkin esineissä. Urheiluvälineissä, kuten jääkiekko- ja salibandy-mailoissa, käytetään hiilikuituisia komposiitteja kestävyden lisäämiseksi ja mailan massan pienentämiseksi. Auton renkaat ovat pitoa tuovaa kumia ja kestävyyttä lisääviä metallilankoja sisältävää komposiittimateriaalia. Monet huonekalut koostuvat erilaisista puusta valmistetuista levyistä, jotka usein luokitellaan komposiittimateriaaleiksi. Näitä ovat esimerkiksi vaneri ja MDF-levy (medium-density fiberboard) sekä muut kuitulevyt.

Oman komposiittimateriaaliluokkansa muodostavat puukuitukomposiitit, joiden tutkimukseen tässä työssä keskitytään. Näissä materiaaleissa kuituina käytetään selluloosakuituja, jotka valmistetaan samaan tapaan kuin paperiteollisuudessa. Matriisina toimii jokin muovi. Puukuitukomposiiteilla voidaan saavuttaa merkittäviä parannuksia massaan, hintaan ja kestävyteen verrattuna pelkkiin puukuitu- tai muovimateriaaleihin.

Komposiittimateriaalia voi tarkastella kokonaisuutena, matriisin näkökulmasta tai kuitujen muodostamaa verkostoa tutkien. Koko komposiittia tarkastelevat tutkimukset voidaan yleensä toteuttaa mittaamalla esimerkiksi materiaalin mekaanisia ominaisuuksia. Tällaiset mittaukset eivät kuitenkaan suoraan pysty erottamaan kuituverkostosta johtuvia ominaisuuksia matriisimateriaalista johtuvista ominaisuuksista. Erityisesti ne eivät pysty karakterisoimaan kuituverkostoa, jossa voi olla vaikkapa valmistusteknisistä seikoista johtuvia vikoja. Materiaalin ominaisuuksien kannalta keskeisiä tekijöitä ovat esimerkiksi verkoston levittäytyminen matriisimateriaalissa, kuitujen paakkuuntuminen, pituus sekä kuitukontaktien määrä ja pinta-ala. Puukuitukomposiittimateriaaleissa kui-

dut voivat muuttaa muotoaan ja esimerkiksi haljeta kuitujen ja materiaalin valmistusprosessista ja käyttöolosuhteista johtuen.

Tässä työssä ollaan kiinnostuneita kuituverkoston mikroskooppisten ominaisuuksien mittaamisesta ja erityisesti verkoston lokaalista rakenteesta eikä niinkään koko verkoston kollektiivisista ominaisuuksista. Työn päätarkoituksena onkin kehittää kuvankäsittelymenetelmä yksittäisten kuitujen erottelunsa komposiittimateriaalista otetuista röntgenmikrotomografiakuvista. Lisäksi tutkitaan menetelmiä, joilla erotettuja kuituja voi analysoida ja mahdollisesti kytkeä yksittäisten kuitujen ominaisuudet kuituverkoston ja komposiitin materiaalteknisiin ominaisuuksiin.

Kehitettävälle kuitujen erottelumenetelmälle asetettiin seuraavat vaatimukset:

Automaattisuus Tutkittavissa kuvissa on tuhansia kuituja, joten menetelmän on pystyttävä tunnistamaan ne ilman käyttäjän tekemiä valintoja tai merkintöjä.

Nopeus Tutkittavat kuvat ovat kooltaan tyypillisesti useita gigatavuja, joten menetelmän on pystyttävä käsittelemään suuria kuvia järkevässä ajassa.

Kolmiulotteisuus Menetelmän on oltava aidosti kolmiulotteinen niin, että sattumanvaraisestikin suuntautuneet kuidut pystytään tunnistamaan, eivätkä tiettyyn suuntaan orientoituneet kuidut tunnistu helpommin kuin toisiin suuntiin orientoituneet. Tätä vaatimusta tarkastellaan lisää kappaleessa 2.

Tarkkuus Menetelmän on erotettava mahdollisimman suuri osa kuiduista aika- ja järjestelmäresurssien puitteissa riippumatta esimerkiksi siitä, ovatko tutkittavat kuidut onttoja vai umpinaisia.

Seuraavissa kappaleissa analysoidaan ensin joitakin olemassaolevia kuitujen erottelumenetelmiä ja niiden toimintaa ylläolevien vaatimusten kannalta. Sen jälkeen esitellään tässä työssä kehitetty algoritmi sekä erotettujen kuitujen analysointiin käytettäviä menetelmiä, joita testataan tietokoneella luoduilla kuiturakenteilla sekä komposiittimate-

riaalista otetuilla tomografiakuvilla. Työn loppupuolella kerrotaan parannuksista, joita menetelmiin voi tehdä. Työn päättää johtopäätösosio.


2 Katsaus olemassaoleviin menetelmiin

Tässä osiossa esitellään olemassaolevia menetelmiä kuitujen erottelemiseksi tomografiakuvista.

Asian viemiseksi teorian tasolta käytännöllisemmäksi tarkastellaan kuvaa 1. Kuvassa on visualisointeja puukuitukomposiittimateriaalista otetussa tomografiakuvassa olevasta kuituverkostosta. Kuidut ovat vaaleita ja muu materiaali on läpinäkyvää. Tehtävä on siis erottaa tällaisesta kuvasta jokainen kuitu erilleen. Tehtävää vaikeuttaa se, että lähes kaikki kuidut koskettavat toisia kuituja niin, että niistä muodostuu kuituverkosto jonka liittyvyysaste on hyvin suuri. Suurin osa kuiduista on putkimaisia, mutta seassa on myös tankomaisia kuituja, joissa ei ole keskionteloa. Kuvan yläosassa vasemmalla nähdään ohuista säikeistä muodostuva rakenne, joka sekin voidaan luokitella yhdeksi kuiduksi. Moni putkimainen kuitu on haljennut ja jopa muuttunut levymäiseksi, muutenkin kuitujen paksuus- ja muotoerot ovat huomattavat. Suurin osa kuiduista on suorita mutta seassa on myös joitakin S-kirjaimen muotoisia rakenteita.

Fysikaalisesti kuitujen erottelua voi tarkastella käänteisenä prosessina kuituverkoston rakentamiselle yksittäisistä kuiduista. Mikäli asetetaan kuituja päällekkäin sopivan orientaatiojakauman mukaisesti johonkin tilavuuteen ja liitetään kuidut yhteen kosketuskohdistaan jonkinlaisilla kemiallisilla tai fysikaalisilla sidoksilla, saadaan lopputuloksena kuituverkosto. Jos kuituverkosto halutaan purkaa osiinsa, puretaan kuitujen sidokset ja nostetaan kuidut pois käänteisessä järjestyksessä lisäämiseen nähden.

Teknisesti absorptiokonstrastikuvassa kuituverkostoon kuuluvat ne kuvan alueet, joiden arvo on virherajojen ja kuvan normituksen puitteissa sama kuin kuitujen tiheys. Suoraan kuvaa lukemalla saadaan siis selville, mitkä kuvatun alueen pisteet kuuluvat mihinkin materiaalifaasiin, esimerkiksi matriisiin, kuituihin tai ilmaan. Kuvausprosessi kuitenkin hävittää tiedon kuitujen sidoksista, jota tarvittaisiin kuitujen erotteluun toisistaan luonnollisen, fysikaalisen prosessin perusteella. Jotta kuvassa oleva kuituverkko saadaan purettua yksittäisiksi kuiduiksi, täytyy tietä kuitujen sidoksista ja niiden sijainneista rekonstruoida kuitualueiden geometrisen rakenteen perusteella. Kuitujen erottelualgoritmia voi siis luonnehtia ”hyvin toimivaksi” mikäli se tekee tämän rekonstruktion oikein ja



Kuva 1: Ylhäällä selluloosakuituisesta komposiittimateriaalista otetun röntgenmikrotomografiakuvan palan kolmiulotteinen visualisointi. Alhaalla samankaltainen visualisointi muutamasta kuidusta mediaanisuodatuksen ja kynnystyksen jälkeen. Kuitujen rakenteen vaihtelevuus on huomattava.

erottaa kuidut toisistaan samoin kuin samat kuidut erottuisivat toisistaan fysikaalisten ja kemiallisten kuitusidosten purkamisen jälkeen.

Kuitujen tunnistaminen ja erottelu tomografiakuvista muistuttaa mekaniikaltaan hyvin paljon verisuonien erottelua sydäimestä tai muista kudoksista otetuista kolmiulotteisista kuvista. Sekä kuidut että verisuonet ovat usein putkimaisia rakenteita muun tasalaatuisemman materiaalin seassa. Tehtävissä on kuitenkin joitakin merkittäviä eroja: verisuonien seinämissä ei ole reikiä, mutta kuidut voivat olla jopa haljenneita. Kuidut taas eivät yleensä haaraudu, mutta verisuonet haarautuvat varsin voimakkaasti. Lisäksi verisuonet ovat paljon suurempia objekteja kuin kuidut komposiittimateriaalissa, verisuonen halkaisija mitataan millimetreissä, kuidun halkaisija taas mikrometreissä. Kuvankäsittelyalgoritmeille koko ei aseta erityisiä vaatimuksia, mutta kuvantamislaitteille kokoero on merkittävä: pienemmistä objekteista on hankalampaa saada tarkkaa kuvaa. Suonten tunnistamiseen on kuitenkin kehitetty paljon erilaisia menetelmiä, joita voi soveltaen käyttää myös kuitujen etsimiseen. Tehtävien eroavaisuuksista johtuen soveltaminen voi olla ongelmallista erityisesti kappaleen 1 vaatimusten valossa.

Aronsson kehittää väitöskirjassaan [Aro02] usemmankin menetelmän kuitujen erotteeluun viipalekuvista. Hän testaa ensin kaksiulotteisia, siivupohjaisia menetelmiä jotka vaativat paljon interaktiota käyttäjän kanssa. Nämä menetelmät hän toteaa työläiksi käyttää tai jollakin muulla tavalla hankaliksi ja päätyy lopulta ns. Ordered Region Growing -menetelmään (ORG).

ORG -menetelmä on kehitetty segmentoimaan verisuonia ja muita biologisia verkostoja [Ada94] [Yim00]. Syötteenä menetelmä ottaa käsiteltävän kuvan lisäksi segmentoitavan verkoston alku- ja loppupisteet, joita kumpiakin voi olla useita. Jokaisesta alkupisteestä lähdetään rakentamaan verkostoa. Ensimmäisellä algoritmin iteraatiolla verkostoon otetaan mukaan vain alkupisteet. Tämän jälkeen verkostoon otetaan mukaan verkostossa olevien pisteiden verkostoon kuulumattomista naapureista se, jossa kustannusfunktion f arvo on suurin. Iterointia jatketaan kunnes kaikki loppupisteet sisältyvät verkostoon. Tämän jälkeen lähdetään liikkeelle loppupisteistä ja liikutaan aina verkostoon kuuluvaan naapuripisteeseen. Mikäli mahdollisia liikkumissuuntia on useita, siirrytään siihen naapuripisteeseen, joka on kuulunut verkostoon pisimmän ajan. Näin jatketaan, kunnes ollaan palattu alkupisteisiin. Nyt segmentoitu verkosto on sama kuin niiden pisteiden joukko, jossa käytiin liikuttaessa loppupisteistä alkupisteisiin.

Verisuonia segmentoitaessa kustannusfunktion f arvona voidaan käyttää kuvan harmaasävyä, sillä verisuonet ovat yleensä kirkkaita keskeltä ja vaaleampia reunoilta. Kuituja segmentoitaessa Aronsson käyttää kustannusfunktiona lauseketta

$$f(\vec{x}) = DT(\vec{x}) + \frac{1}{\|\vec{x}_{loppu} - \vec{x}_{alku}\|} (\vec{x} - \vec{x}_{alku}) \cdot (\vec{x}_{loppu} - \vec{x}_{alku}), \quad (1)$$

jossa \vec{x}_{alku} on kuidun alkupiste ja \vec{x}_{loppu} kuidun loppupiste. DT merkitsee kuvan etäisyysmuunnosta. Tämä kustannusfunktio pyrkii pitämään ORG -polun kuidun keskellä olevassa reiässä mutta suosii askeleita kuidun loppupistettä kohti.

ORG -pohjainen kuidun keskiakselin etsintäalgoritmi toimii hyvin ja varsin tehokkaasti, mikäli kaikissa eroteltavissa kuiduissa on reikä keskellä ja kuitujen päätepisteet voidaan merkitä käsin. ORG -polun löytämisen jälkeen varsinainen kuidun seinämä täytyy tietenkin vielä etsiä. Seinämän löytämiseksi Aronsson etsii ensin kaikki kuidun keskellä olevaan reikään sisältyvät pikselit “SeparaSeed” -algoritmilla [Tiz02] ja sen jälkeen laajentaa tätä pikselijoukkoa ulospäin kunnes etäisyysmuunnokseen perustuva ehto täyttyy. Nyt poistamalla reikään kuuluvat pikselit saadaan kuidun seinämään kuuluvat pikselit.

Aronssonin mukaan hänen menetelmänsä erottaa oikein 10 % – 20 % käytetyn testitapauksen kuiduista. Tämä johtuu siitä, että moni kuiduista on liian lyhyt tai kuidun muoto on muuttunut niin, ettei siinä ole enää keskionteloa.

Bache-Wiigin ja Hendenin menetelmä [BW05] olettaa, että kaikki kuidut ovat putkimaisia. Kuitujen seinämissä saa olla reikiä, mutta kuidut eivät saa mutkitella kovinkaan paljoa.

Algoritmi perustuu kuitujen keskellä olevan kanavan tunnistamiseen. Tunnistaminen alkaa etsimällä jostakin kuvan siivusta (ks. määritelmä (3.1)) piste, joka on kanavan alueella. Tästä pisteestä lähtien täytetään koko kyseisessä siivussa oleva kanavan alue. Tämä alue kopioidaan edelliseen ja seuraavaan siivun, jonka jälkeen täytetään näissä siivuisä olevat kanava-alueet käyttäen siemenalueena kopioitua aluetta. Kuidun seinämissä olevat reiät etsitään etäisyysmuunnokseen perustuvan algoritmin avulla. Kun kanavaan kuuluvat pikselit tunnetaan, saadaan kuidun seinämä helposti erotettua laajentamalla kanava-aluetta ulospäin. Siemenpisteiden valintaan Bache-Wiig ja Henden esittävät siivusta löytyneiden alueiden pyöreyyden, konveksisuuteen ja eksentrisyyteen perustuvan


algoritmin, mutta he mainitsevat myös että tämä algoritmi määrittää vain 50% – 70% siemenpisteistä oikein.

Bache-Wiigin ja Hendenin menetelmä antaa fysikaalisia tuloksia mikäli kuiduilla on hyvin määritelty keskuskanava ja ne eivät haaraudu tai ole liian käyriä. Esimerkiksi kuitu, joka kääntyy puoliympyrän muotoon, jää pakosti osaksi tunnistamatta tällä menetelmällä. Mikäli kuidut ovat suorina mutta sattumanvaraisesti orientoituneita, algoritmi voidaan suorittaa tarkastellen kuvaa kolmesta toisiaan vastaan kohtisuorasta suunnasta, jolloin tunnistustarkkuus paranee.

Axelsson esittelee artikkelissaan [Axe07] kuitujen tunnistamismenetelmän, joka ei perustu kuvan siivuttamiseen jonkin koordinaattiakselin suunnassa. Menetelmä lähtee liikkeelle siemenpisteestä, joka on kuidun sisällä, sen keskellä. Pisteeseen liittyy myös siemensuunta, jonka tulee osoittaa kuidun suuntaan siemenpisteessä. Kuidun seuraamiseksi lasketaan kuvan summaprojektioita joissakin kuidun suuntaa vastaan kohtisuorissa suunnissa. Koko kuvan projektioita ei tietenkään tarvitse laskea, vaan vain pienen alueen siemenpisteen ympärillä. Näissä kuvissa onton kuidun reunat näkyvät kirkkaina alueina, ks. kuva 2. Jokaisesta projektioista tunnistetaankin siis viivat Radonin muunnoksen avulla. Näiden viivojen keskimääräinen suunta määritellään kuidun suunnaksi algoritmin seuraavassa askeleessa. Seuraavan askeleen siemenpisteeksi valitaan piste, joka saadaan tämänhetkisestä siemenpisteestä lisäämällä siihen lyhyt, määritellyn suunnan mukainen vektori.

Axelssonin mukaan tämä menetelmä tunnistaa oikein myös kuidut, joissa on reikiä, mutta ei haljenneita tai kokonaan umpeen luhistuneita kuituja. Yleisemmin sanottuna menetelmä tarvitsee luotettavasti toimiakseen kuidun, jonka muoto on sellainen, että summaprojektioissa näkyy kaksi viivaa. Esimerkiksi kokonaan kokoon puristuneen kuidun summaprojektioissa näkyy vain nauhamainen rakenne, jonka suuntaa ei helposti pysty määrittämään Radonin muunnoksen avulla.

Yang ja Lindquist kehittävät artikkelissaan [Yan00] automaattisen menetelmän umpinaisten kuitujen erotteliseksi. Heidän menetelmänsä perustuu binäärimuotoon saatetun kuituverkostokuvan keskiakseliin. Keskiakselin pisteet luokitellaan normaaleiksi pisteiksi, päätepisteiksi ja risteyspisteiksi. Luokitellut pisteet eristävät eri kuidut toisistaan, mutta ne “katkaisevat” myös samaa kuitua olevia alueita, joten osa alueista



Kuva 2: Kuidun poikkileike ja sen summaprojektio. Vasemmalla poikkileike kuidusta niin, että kuidun suunta osoittaa paperin sisään. Oikealla summaprojektio samasta kuidusta niin, että vasemmanpuoleisessa kuvassa paperin sisään osoittava suunta on pystysuorassa. Huomaa summaprojektiossa näkyvät kirkkaammat alueet, jotka muodostuvat kuidun seinämien kohdalle.

joudutaan yhdistämään. Risteyspisteissä kohtaavat alueet ovat potentiaalisesti samaa kuitua. Yhdistettävät haarat löydetäänkin vertaamalla jokaisessa risteyspisteessä risteävien haarojen suuntien keskinäisiä kulmia ja valitsemalla näistä parit, jotka muodostavat pienimmät kulmat. Lisäksi tehdään joitakin tilanteesta riippuvia korjauksia.

Mikäli on tarvetta saada selville alkuperäiset kuitupisteet, menetelmän tuloksena saatuja kuitujen keskiakseleita on helppo laajentaa ulospäin sillä ehdolla, että kuituun lisättävät kuvapisteen kuuluvat johonkin alkuperäisessä kuvassa olevaan kuituun. Yhdessä iteraatiossa lisättyjen kuitupisteiden määrästä saadaan myöskin lopetusehto laajentamisprosessille: Kun yhtään pistettä ei pystytä lisäämään, on laajennus valmis.

Tärkeä vaatimus Yangin ja Lindquistin menetelmän toimivuudelle on se, että tutkittavat kuidut ovat umpinaisia eli niiden keskellä ei saa olla onteloita. Tämä erottaa menetelmän edellä esitellyistä. Menetelmä täyttää kappaleessa 1 annetut vaatimukset automaattisuuden, kolmiulotteisuuden ja nopeuden osalta. Putkimaisten kuitujen tapauksessa kuvasta lasketut keskiakselit eivät vastaa kuitujen todellisia keskiakseleita eivätkä keskiakselien suunnat kuitujen todellisia suuntia. Tähän seikkaan palataan myöhemmissä kappaleissa.

Edellä kuvattujen menetelmien pohjalta on kehitetty muitakin samankaltaisia algoritmeja erilaisten kuitujen automaattiseen tai puoliautomaattiseen erotteluun [Hol04] [Lun02].

Näissä ja edellä esitellyissä tutkimuksissa kehitetyn menetelmän pääasiallisena sovellusalueena on ollut jonkinlainen muu materiaali kuin puukuitukomposiitti. Joissakin tapauksissa kuvadata on myös ollut häiriöttömämpää kuin röntgenmikrotomografialla saatu, esimerkiksi SEM-mikroskoopilla otetut kuvat. Näistä syistä johtuen menetelmien suorassa soveltamisessa puukuitukomposiittimateriaaliin nousee esiin seuraavat ongelmat ja vaatimukset.

1. Ontot ja umpinaiset kuidut. Puukuitukomposiittimateriaaleissa on kummankinlaisia kuituja sekaisin vaikka esimerkiksi paperissa ontot kuidut ovat yleensä huomattavasti yleisempiä kuin umpinaiset. Monissa muissa komposiitti- ja kuitumateriaaleissa kuidut ovat aina umpinaisia. Periaatteessa tämän ongelman voisi korjata käyttämällä kahta menetelmää, joista toinen tunnistaa toisen tyyppiset kuidut ja toinen toiset. Tämä ratkaisu tosin jättää edelleen käsittelyn ulkopuolelle ohuista säikeistä muodostuvat kuitumaiset objektit, ks. kuva 1.
2. Reiät kuitujen seinissä, kokoonpuristuneet kuidut, revenneet kuidut ja muut epä säännöllisyydet ovat yleisiä, suorastaan rakennetta dominoivia puukuitukomposiittimateriaaleissa, mutta eivät niinkään paperissa ja muissa kuitumateriaaleissa.
3. Luotettava tilastollinen analyysi vaatii suuren määrän tunnistettuja kuituja. Tämä korostuu erityisesti puukuitukomposiittimateriaaleissa kuitujen rakenteen epä säännöllisyyden vuoksi. Mikäli käytettävä tunnistamismenetelmä vaatii käyttäjän tekemiä päätöksiä, on mahdollista, että tunnistuksen tulos ei ole objektiivinen vaan riippuu käyttäjän vireystilasta ja ympäristötekijöistä.
4. Puukuitukomposiittimateriaalin tapauksessa tunnistamismenetelmän on syytä olla invariantti tarkastelusuunnan suhteen. Monesti kuitumateriaaleissa olevien kuitujen orientaatiojakaumasta on olemassa ennakkotietoa, jolloin kuvadata voidaan syöttää menetelmälle optimaalisessa asennossa. Komposiittimateriaalien tapauksessa tällaista tietoa ei välttämättä ole käytettävissä.

3 Kuituverkoston analysointi

Kuitumaisen materiaalin tutkimus jakautuu selkeästi kolmen eri mittakaavan prosesseihin: materiaalin tutkimiseen, kuituverkoston tutkimiseen ja yksittäisten kuitujen tutkimiseen [Aro02]. Materiaalin ominaisuuksia ovat esimerkiksi pinnanmuoto, massa(jakauma), materiaalin orientaatiojakauma ja huokoisuus. Materiaalitason ominaisuuksia on mahdollista mitata ilman tietoa kuituverkoston ja muun aineen keskinäisistä suhteista. Kuituverkoston ominaisuuksien tutkimiseen tarvitaan tieto verkoston rakenteesta, mutta ei välttämättä yksittäisten kuitujen rakenteesta. Tällaisia ominaisuuksia ovat esimerkiksi jakaumat kuitujen pituuksista, kuitukontaktien määrästä ja kuidun vapaasta matkasta eli kahden kuitukontaktin välisestä etäisyydestä kuitua pitkin mitattuna. Kuitutason ominaisuuksia taas ovat vaikkapa kuidun seinämäpaksuus, muoto ja kuitujen orientaatiojakauma. Tässä kappaleessa esitellään menetelmiä kuituverkoston ja yksittäisten kuitujen analysointiin lähtien liikkeelle kuitujen erottamisesta toisistaan.

3.1 Yleistä kuituverkoston tutkimisesta

Kuituverkostoja voi analysoida monesta eri näkökulmasta, kuten esimerkiksi verkkoteoreettisesti, tilastollisesti, fysikaalisesti, kemiallisesti tai kuvankäsittelyn keinoin.

Verkkoteoreettisesti voitaisiin analysoida esimerkiksi verkoston perkolaatio-ominaisuuksia eli sitä, miten “voimakkaasti” verkoston eri osat ovat yhteydessä toisiinsa. Tällaisen tutkimuksen tulosten avulla voitaisiin vaikkapa analysoida nesteen imeytymistä verkostoon ja sitä kautta verkoston sisältävän materiaalin imeytymisominaisuuksia. Yleisemmin erilaiset kuituverkon liitosten määrään liittyvät ominaisuudet ovat verkkoteoreettisesti mielenkiintoisia.

Tilastollinen analyysitapa [Sam01] [Den94] lähtee liikkeelle kokonaan erilaisesta näkökulmasta. Verkoston tilastollisia ominaisuuksia, kuten kuitujen suuntautumista tai muotoa, arvioidaan joistakin jakaumaoletuksista lähtien. Näiden oletusten valinnalla määritellään mitattavat ominaisuudet sekä käytettävän mallin tarkkuus ja monimutkaisuus. Yleensä monimutkaisuuden lisääminen huonontaa tulosten tulkittavuutta ja virherajoja. Tilastollinen tapa on matemaattisesti erittäin hyvin perusteltu, mutta monesti

käytännön tulosten johtaminen on hankalaa ja vaatii voimakkaita oletuksia materiaalin rakenteesta.

Kuitupitoisen materiaalin fysikaalisia ominaisuuksia kuten lujuutta, lämmönjohtavuutta jne. voidaan tutkia suoraan mittauksin. Materiaalin ominaisuudet voidaan kytkeä kuituverkoston ominaisuuksiin, mikäli materiaalin valmistusprosessia pystytään säätämään tarkasti niin, että tutkittavat näytteet ovat muuten identtisiä mutta kuituverkostoltaan eroavia. Näin tarkka prosessin säätely voi kuitenkin olla hankalaa. Yksittäisistä kuituista saadaan tietoa mittauksilla, joissa näytteenä toimii pelkästään yksi tai muutama kuitu. Kuidun pienestä koosta johtuen tällaiset mittaukset ovat hankalia toteuttaa.

Kemiallinen analyysi sisältää yleensä kuituverkostoa ympäröivän materiaalin liuotuksen niin, että materiaalista jää jäljelle vain kuidut. Kuitujen analysointia voi jatkaa kemiallisesti kuitumateriaalin koostumuksen selvittämiseksi tai muilla menetelmillä.

Kuituverkoston tutkiminen digitaalisen kuvankäsittelyn keinoin luo tarpeelliset kanavat, joita pitkin neljä edellä mainittua tutkimustapaa voidaan yhdistää. Kun verkostosta saadaan luotua riittävän tarkka geometrinen malli, jota voidaan käsitellä tietokoneella, verkkoteoreettiset ja tilastolliset analyysialgoritmit voidaan toteuttaa käytännössä ilman rajoittavia oletuksia verkoston rakenteesta. Lisäksi verkostosta luotua mallia voidaan käyttää syötegeometriana erilaisiin simulaatioihin, joiden avulla on mahdollista hankkia syvempää ymmärrystä verkon eri osien rooleista fysikaalisissa prosesseissa. Mikäli käytetty kuvantamismenetelmä (esim. röntgentomografia) ei tuhoa näytettä, tietokoneen avulla laskettuja tuloksia voidaan käyttää mittausten validointiin ja tulosten ennustamiseen.

3.2 Määritelmiä

Tässä kappaleessa esitetään määritelmiä, joita tarvitaan seuraavissa, menetelmää esittelevissä kappaleissa. Ensin määritellään muutamia matemaattisia käsitteitä ja sen jälkeen syvennyttään kuidun määritelmään.

Määritelmä 3.1. Kuva

- i. *Digitaalinen kuva on funktio f , jolle $f(\vec{x}) \in [0, \infty]$. Kuva on kaksiulotteinen, mikäli $\vec{x} = (x, y) \in \mathbb{N}^2, 0 \leq x < W, 0 \leq y < H$. Tällöin W on kuvan leveys ja H kuvan korkeus. Kuva on kolmiulotteinen, mikäli $\vec{x} = (x, y, z) \in \mathbb{N}^3, 0 \leq x < W, 0 \leq y < H, 0 \leq z < D$. Tällöin W on kuvan leveys, H kuvan korkeus ja D kuvan syvyys.*

Digitaalinen kaksiulotteinen kuva voidaan ilmoittaa matriisina \mathbf{A} muodossa

$$\mathbf{A} = \begin{pmatrix} f(0,0) & f(1,0) & \dots & f(W-1,0) \\ f(0,1) & f(1,1) & \dots & f(W-1,1) \\ \vdots & \vdots & & \vdots \\ f(0,H-1) & f(1,H-1) & \dots & f(W-1,H-1) \end{pmatrix}. \quad (2)$$

Jokainen matriisin \mathbf{A} alkio $a_{x,y} = f(x,y)$ on kuvan kuvapiste eli pikseli. Piste $\vec{r} = (x,y)$ on kuvapisteen sijainti. Vastaavasti digitaalinen kolmiulotteinen kuva \mathbf{B} voidaan ilmoittaa D :nä kaksiulotteisena kuvapistematriisina

$$\mathbf{B} = \left\{ \begin{pmatrix} b_{0,0,z} & b_{1,0,z} & \dots & b_{W-1,0,z} \\ b_{0,1,z} & b_{1,1,z} & \dots & b_{W-1,1,z} \\ \vdots & \vdots & & \vdots \\ b_{0,H-1,z} & b_{1,H-1,z} & \dots & b_{W-1,H-1,z} \end{pmatrix}, z \in [0, D-1] \right\}, \quad (3)$$

jossa $b_{x,y,z} = f(x,y,z)$ ovat kuvan kuvapisteen eli vokselit. Vastaavasti kuvapisteen sijainti on kolmikomponenttinen vektori (x,y,z) . Yhtä matriisia sanotaan kuvan siivuksi.

- ii. *Binäärikuva on kuva f , jolle $f(\vec{x}) \in \{0, 1\}$. Niiden kuvapisteen, joiden arvo on 0, muodostamaa joukkoa sanotaan kuvan taustaksi. Tässä työssä niitä kuvapisteitä, joiden arvo on 1, sanotaan objektipisteiksi.*

Määritelmä 3.2. *Ympäristö*

i. *Kuvapisteen $b_{x,y,z}$ 6-ympäristö on joukko B_6 , jolle*

$$B_6 = \{b_{x-1,y,z}, b_{x+1,y,z}, b_{x,y-1,z}, b_{x,y+1,z}, b_{x,y,z-1}, b_{x,y,z+1}\}. \quad (4)$$

ii. *Kuvapisteen $b_{x,y,z}$ 12-ympäristö on joukko B_{12} , jolle*

$$\begin{aligned} B_{12} = \{ & b_{x-1,y-1,z}, b_{x-1,y+1,z}, b_{x-1,y,z-1}, b_{x-1,y,z+1}, \\ & b_{x,y-1,z-1}, b_{x,y-1,z+1}, b_{x,y+1,z-1}, b_{x,y+1,z+1}, \\ & b_{x+1,y-1,z}, b_{x+1,y+1,z}, b_{x+1,y,z-1}, b_{x+1,y,z+1}\}. \end{aligned} \quad (5)$$

iii. *Kuvapisteen $b_{x,y,z}$ 18-ympäristö on joukko B_{18} , jolle*

$$\begin{aligned} B_{18} = \{ & b_{x-1,y,z}, b_{x-1,y-1,z}, b_{x-1,y+1,z}, b_{x-1,y,z-1}, b_{x-1,y,z+1}, \\ & b_{x,y-1,z-1}, b_{x,y-1,z+1}, b_{x,y+1,z-1}, b_{x,y+1,z+1}, \\ & b_{x,y-1,z}, b_{x,y+1,z}, b_{x,y,z-1}, b_{x,y,z+1}, \\ & b_{x+1,y,z}, b_{x+1,y-1,z}, b_{x+1,y+1,z}, b_{x+1,y,z-1}, b_{x+1,y,z+1}\}. \end{aligned} \quad (6)$$

iv. *Kuvapisteen $b_{x,y,z}$ 26-ympäristö on joukko B_{26} , jolle*

$$\begin{aligned} B_{26} = \{ & b_{x-1,y-1,z-1}, b_{x-1,y-1,z}, b_{x-1,y-1,z+1}, \\ & b_{x-1,y,z-1}, b_{x-1,y,z}, b_{x-1,y,z+1}, \\ & b_{x-1,y+1,z-1}, b_{x-1,y+1,z}, b_{x-1,y+1,z+1}, \\ & b_{x,y-1,z-1}, b_{x,y-1,z}, b_{x,y-1,z+1}, \\ & b_{x,y,z-1}, b_{x,y,z}, b_{x,y,z+1}, \\ & b_{x,y+1,z-1}, b_{x,y+1,z}, b_{x,y+1,z+1}, \\ & b_{x+1,y-1,z-1}, b_{x+1,y-1,z}, b_{x+1,y-1,z+1}, \\ & b_{x+1,y,z-1}, b_{x+1,y,z}, b_{x+1,y,z+1}, \\ & b_{x+1,y+1,z-1}, b_{x+1,y+1,z}, b_{x+1,y+1,z+1}\}. \end{aligned} \quad (7)$$

Mikäli kuvapisteeset oletetaan vierekkäin asetetuiksi kuutioiksi kuten kuvassa 3, 6-ympäristön muodostavat ne kuvapisteeset, joilla on tarkastelukuvapisteen kanssa yhteinen

tahko. 12-ympäristön taas muodostavat ne kuvapistet, joilla on tarkastelukuvapisteen kanssa yhteinen särmä mutta ei tahkoa. Vastaavasti 18-ympäristön muodostavat ne kuvapistet, joilla on yhteinen tahko tai yhteinen särmä tarkastelukuvapisteen kanssa ja 26-ympäristön muodostavat ne kuvapistet, joilla on yhteinen tahko, särmä tai kulma tarkastelukuvapisteen kanssa.

Kannattaa huomata, että

- i. $B_{18} = B_6 \cup B_{12}$
- ii. $B_6 \subset B_{18}$, $B_{12} \subset B_{18}$ ja $B_{18} \subset B_{26}$
- iii. $B_6 \not\subset B_{12}$.

Määritelmä 3.3. *m-polku*

m-polku kuvapistestä paikassa (x, y) kuvapisteeseen paikassa (x', y') on järjestetty jono kuvapistettä sijainneissa

$$(x_0, y_0), \dots, (x_n, y_n)$$


*joille $(x_0, y_0) = (x, y)$ ja $(x_n, y_n) = (x', y')$ sekä (x_{i+1}, y_{i+1}) kuuluu paikassa (x_i, y_i) olevan kuvapisteen *m*-ympäristöön kaikille $0 \leq i < n$. [Gon02]*

Määritelmä 3.4. *m-kytkeytyneet kuvapistet*

*Olkoon S joukko kuvapistettä ja $p_1, p_2 \in S$. Sanotaan, että p_1 ja p_2 ovat *m-kytkeytyneet*, mikäli on olemassa *m*-polku kuvapistestä p_1 kuvapisteeseen p_2 siten, että jokainen polun kuvapiste kuuluu joukkoon S . [Gon02]*

Määritelmä 3.5. *Käyrä γ on kuvaus $\gamma : [a, b] \rightarrow \mathbb{R}^n$, jossa $a, b \in \mathbb{R}$. [Kre91]*

Kuitujen tunnistamista varten “kuitu” täytyy määritellä kappaleessa 1 erottelumenetelmältä vaadittujen ominaisuuksien valossa. On selvää että kuitua ei voi määritellä sen keskellä olevan ontelon avulla, sillä kaikissa kuiduissa sellaista ei ole. Tästä seuraa se, että kaikilla kuiduilla ei ole seinämiä, joten määritelmää ei voi sitoa niihinkään. Seinämät olisivatkin epäkäytännöllinen kiintopiste, sillä niissä voi olla isojakin reikiä vaikka



Kuva 3: Keskimmäisen kuvapisteen 6-, 12-, 18- ja 26-ympäristöt.

kuitu ei olekaan katkennut. Lisäksi on otettava huomioon ohuista säikeistä muodostuvat kuidut. Tästä kaikesta seuraa välttämättä se, että kuidulle ei voi antaa kovin tarkkaa matemaattista määritelmää.

Yhteistä kaikille kuiduille on se, että ne ovat pitkänomaisia vaikka ne voivatkin olla kaarevia tai kiertyneitä. Kuidulle voidaan siis määritellä keskiakseli, jonka ei tarvitse olla suora, mutta se ei saa haarautua. Jokainen kuidun sisältämä kuvapiste täytyy olla kytkeytynyt kaikkiin muihin kuidun sisältämiin kuvapisteisiin, eli kuidun on oltava yhtenäinen. Yhtenäisyysehto voidaan muotoilla myös vahvempaan muotoon: kuidun kuvapisteyden täytyy olla yhteydessä toisiinsa “voimakkaasti” niin, että kaksi toisiaan hieman koskettavaa mutta eri suuntiin jatkuvaa rakennetta ovat määritelmällisesti eri kuituja. Yhteyden voimakkuuden karakterisointi on erittäin hankalaa ensinnäkin siksi, että yleispätevää määritelmää voimakkuudelle ei ole olemassa tai ainakaan tiedossa ja toiseksi siksi, että tiedossa olevien määritelmien mukaista voimakkuuden arvoa on hankalaa määrittää laskennallisesti. Tässä työssä kahden pisteen $\vec{x} \in X$ ja $\vec{y} \in X$ voimakkaalla yhteydellä joukossa X tarkoitetaan sitä, että voidaan valita suuri määrä eri polkuja pisteestä \vec{x} pisteeseen \vec{y} siten, että kaikkien polkujen kaikki pisteet kuuluvat joukkoon X . Suuri määrä on joukon X , eli tässä tapauksessa kuidun koosta riippuva parametri.

Tässä työssä kuitu on siis mikä tahansa pitkänomainen rakenne (kuvapistejoukko), jonka jokainen piste on “voimakkaasti” yhteydessä kaikkiin muihin samassa kuidussa oleviin pisteisiin.

3.3 Kuitujen tunnistaminen ja erottelu toisistaan

Tässä kappaleessa esitellään menetelmä kuitujen tunnistamiseen kolmiulotteisesta digitaalisesta kuvasta. Menetelmä koostuu jonosta hyvin tunnettuja kuvankäsittelyoperaatioita. Pohjimmiltaan se perustuu binäärikuvan kolmiulotteisen mediaanijoukon luokitteluun samoin kuin Yangin ja Lindquistin [Yan00] menetelmään. Ratkaiseva ero on se, että tätä työtä varten kehitelty menetelmä käyttää ns. pintamediaania Yangin ja Lindquistin käyttämän viivamediaanin sijasta. Tästä valinnasta johtuen menetelmä tunnistaa sekä putkimaiset että umpinaiset kuidut.

Syötteenä algoritmille annetaan luokiteltavaa kuituverkostoa esittävä kolmiulotteinen binäärikuva. Algoritmin tulos on kuva, jossa jokainen tunnistettu kuitu on väritetty eri värillä. Alkuperäinen kuva täytyy siis segmentoida ennen kuin se kelpaa syötteeksi kuitutunnistusalgoritmille. Testitapauksissa tähän alkusegmentointiin on käytetty yleisesti tunnettuja kohinanpoisto- ja kynnystysmenetelmiä, joista kerrotaan tarkemmin testitapauksia käsittelevissä osioissa.

Seuraavissa kappaleissa esitellään tarkemmin menetelmän päävaiheet, jotka ovat lyhyesti seuraavat.

1. Muodosta kuvan ranko eli mediaanijoukko.
2. Määritä jokaiselle rangon pisteelle sen 26-ympäristössä olevien rankopisteiden määrä.
3. Etsi rangon haarojen risteyskohdat kunkin pisteen naapuripisteiden määrän perusteella.
4. Laajenna löytyneitä risteyskohtia niin, että rangon haarat eivät ole edes 6-kytkettyneitä.
5. Luokittele haarat pieniin ja suuriin.
6. Yhdistä pienet osat suuriin osiin.
7. Yhdistä osat, joiden orientaatio on lähes sama sekä osat, joiden orientaatio on samankaltainen ja liitosalueen koko suuri.

8. Laajenna saatu luokiteltu ranko takaisin alkuperäisiin kuvapisteisiin.

Lisäksi ennen kuitujen analysointia suoritetaan yleensä kaksi lisävaihetta.

1. Määritä kunkin kuidun keskiakseli.
2. Siivuta kuitu uudelleen akselia vastaan kohtisuorin siivuin.

3.3.1 Kuituvokselien ranko

Kuitujen tunnistaminen lähtee liikkeelle syötteenä saadun binäärikuvan objektipisteiden rangon [Ros68] eli mediaanijoukon [Blu67] määrittämisestä. Rangon voi määrittellä monella tavalla. Yleisin määritelmä on kuitenkin seuraava.

Määritelmä 3.6. *Olkoon A kuvan f objektipisteiden joukko. Palloa B sanotaan maksimaaliseksi joukossa A , mikäli*


- $B \subset A$ ja
- jos D on toinen pallo ja $B \subset D$, niin $D \not\subset A$.

Kuvan f objektipisteiden ranko on nyt kaikkien joukon A maksimaalisten pallojen keskipisteiden yhdiste. [Gon02]

Intuitiivisemmin rangon määritelmän voi esittää kuvan objektipisteiden keskiakselijoukko.

Määritelmä 3.7. *Olkoon A kuvan f objektipisteiden joukko ja ∂A joukon A reuna. Piste $p \in A$ kuuluu rankoon, mikäli sillä on enemmän kuin yksi lähin naapuri joukossa ∂A . [Gon02]*

Keskiakselijoukon pisteet löydetään siis esimerkiksi etsimällä jokaisen $p \in A$ lähin naapuri joukossa ∂A . Mikäli lähimpiä naapureita on enemmän kuin yksi, p kuuluu joukon A rankoon. Esimerkki kaksiulotteisen objektin keskiakselijoukosta on esitetty kuvassa 4.




Kuva 4: Keskiakselijoukko. Joukon (harmaa alue) keskiakseli on kaikkien joukon maksimaalisten pallojen keskipisteiden muodostama joukko. Joidenkin maksimaalisten pallojen kehät on merkitty katkoviivalla ja keskipisteet mustilla pisteillä. Keskiakseli on merkitty yhtenäisellä viivalla.

Nämä määritelmät ovat riippumattomia kuvan dimensionaalisuudesta. Kolmiulotteista tapausta on kuitenkin syytä tutkia hieman tarkemmin. Tällöin edellä mainittujen määritelmien mukainen ranko on yhden kuvapisteen paksuinen taso, joka asettuu alkuperäisen kuvan objektipisteiden keskelle. Rangon tehtävä on kuvata objektipisteiden joukkoa yksinkertaisemmassa muodossa niin, että alkuperäisen joukon relevantti topologia ei muutu. Kolmiulotteisessa tapauksessa ei ole enää kovinkaan selkeää, miten paljon rangon topologia voi erota kuvan alkuperäisestä topologiasta. Joissain tapauksissa, kuten tämän työn kuidun keskiakselin määrittämisestä käsittelevässä osiossa, kolmiulotteinen ranko kannattaa määrittellä yhden kuvapisteen paksuisista viivoista koostuvaksi. Kuvassa 5 on vertailtu erilaisten rankoalgoritmien antamia tuoksia.

Rankojoukkoon kuuluvat kuvapisteen voi määrittää suoraan määritelmien perusteella, mutta huomattavasti tehokkaampiakin algoritmeja on olemassa. Tässä työssä käytettiin Gongin ja Bertrandin [Gon90] kehittämää, yksinkertaisten pisteiden poistamiseen perustuvaa menetelmää.

Gongin ja Bertrandin menetelmän yksi iteraatio sisältää kuusi ali-iteraatiota, joista jokaiseen kytketään yksi tarkastelusuunnista $+X$, $-X$, $+Y$, $-Y$, $+Z$ ja $-Z$. Yhden ali-iteraation aikana poistetaan kaikki ns. yksinkertaiset pisteet. Merkitään \vec{d} :llä ali-iteraatioon liitettyä suuntaa ja $p_{\vec{d}}$:llä tarkastelupisteen 6-ympäristön pistettä suunnassa \vec{d} . Olkoon lisäksi $N_{\vec{d}}(p) = N_6(p) - \{p_{\vec{d}}\} - \{p_{-\vec{d}}\}$. Tällöin tarkastelupiste on yksinkertainen, mikäli se täyttää seuraavat ehdot:



Kuva 5: Erilaisia tapoja kolmiulotteisen rangon määrittämiseen. Alkuperäinen kappale vasemmalla, pinnoista koostuva ranko keskellä ja viivoista koostuva ranko oikealla. Ylärivissä rangot on laskettu umpinaisesta palkista, jolloin viivoista koostuva ranko on selvästi selkeämpi. Keskimmäisessä rivissä rangot on laskettu putkesta, jolloin pinnoista koostuva ranko antaa odotetun tuloksen. Näin käy myös alimmaisessa rivissä, jossa alkuperäinen kappale on ontto kuutio. Kahden alimmaisen rivin rangot eivät ole säännöllisiä diskreetin laskentamenetelmän ja syötejoukon aiheuttamista epätarkkuuksista johtuen.

1. $p_{\vec{d}} = 0$
2. $p_{-\vec{d}} = 1$
3. Jos $p_i = 0$, niin $p_l = 0$ kaikille $p_i \in N_{\vec{d}}(p)$ ja p_l 6-kytkeytynyt pisteisiin p_i ja $p_{\vec{d}}$.
4. Jos $p_i = p_j = p_k = 0$, niin $p_m = 0$ kaikille
 - $p_i, p_j \in N_{\vec{d}}(p)$
 - p_j 12-kytkeytynyt pisteeseen p_i
 - p_k 6-kytkeytynyt pisteisiin p_i ja p_j
 - p_m 12-kytkeytynyt pisteeseen $p_{\vec{d}}$
 - p_m 6-kytkeytynyt pisteeseen p_k .


Nämä ehdot on visualisoitu kuvassa 6. Ali-iteraatio koostuu siis kaikkien vastaavassa tarkastelusuunnassa yksinkertaisten pisteiden poistamisesta. Iteraatio koostuu jokaiseen positiiviseen ja negatiiviseen koordinaattisuuntaan tehtävistä ali-iteraatioista. Iterointia jatketaan niin kauan kunnes kuvasta ei saada poistettua yhtäkään yksinkertaista pistettä. Tällöin kuva on muunnettu pinnoista koostuvaksi rangokseen.

Toinen yleisesti käytetty tapa muuntaa kuva rangokseen perustuu kuvan etäisyysmuunnoksen lokaalien maksimien etsimiseen [Ye88] [Rag92] [Cho03]. Tässä työssä ei kuitenkaan käytetty kyseistä tapaa, sillä se on hankalampi toteuttaa ja lisäksi Gongin ja Bertrandin menetelmä vaikutti käytännön testeissä tähän tilanteeseen sopivalta.

3.3.2 Rangon pisteiden luokittelu ja risteysalueet muodostavien pisteiden etsiminen

Kun kuitujen topologisen ja geometrisen rakenteen sisältävä joukko on supistettu minimikokoonsa, suoritetaan tunnistusmenetelmän kriittisin vaihe, eli kuitujen risteysalueiden etsiminen. Tätä varten rangon pisteet luokitellaan kahteen ryhmään: pisteisiin, jotka edustavat kuitujen risteysalueita sekä muihin pisteisiin.

Rangon pisteiden luokitteluun on olemassa monia erilaisia tapoja. Kaksiulotteisessa tapauksessa luokittelun peruste on intuitiivisesti selvä. Ne pisteet, joilla on yksi rankoon



Kuva 6: Ehdot kuvapisteen yksinkertaisuudelle. Tarkasteltava piste on merkitty harmaalla ja tarkastelusuunta on lukijasta poispäin. Ensimmäisen ehdon mukaan tarkastelusuunnassa kuvapisteen edessä täytyy olla tyhjä piste ja takana objektipiste (vasemmanpuoleinen kuvio). Keskimmäisessä ja oikeanpuoleisessa kuviossa pelkällä katkoviivalla merkityn pisteen on oltava tyhjä mikäli kysymysmerkillä merkityt pisteet ovat tyhjiä. Kaksi viimeistä ehtoa täytyy testata kaikissa neljässä tarkastelusuunnan suhteen symmetrisessä tapauksessa.


kuuluva naapuri, ovat rangon haarojen päätepisteitä. Pisteet, joilla on kaksi rankoon kuuluvaa naapuria, ovat ns. tavallisia pisteitä, jotka eivät ole haarojen päätepisteitä eivätkä risteyspisteitä. Muut pisteet, eli ne, joilla on enemmän kuin kaksi rankoon kuuluvaa naapuria, ovat risteyspisteitä. Kuvassa 7 on visualisoitu erilaisten pisteiden muodostumista kaksiulotteisessa tapauksessa. Tärkeää on se, että risteyspisteet erottavat rangon haarat toisistaan niin, että mitkään kaksi haaraa eivät ole edes 8-kytkeytyneitä.

Kolmiulotteisessa tapauksessa luokittelun periaate ei ole yhtä selvä. Esimerkiksi Bonnassie esittää artikkelissaan [Bon01] rankopisteen pallon muotoisen ympäristön Eulerin ja Bettin lukuihin perustuvan luokittelumenetelmän. Menetelmä luokittelee pisteet tarkasti oikein, mutta ympäristön halkaisijan tulee olla suurempi kuin objektin lokaali paksuus tarkastelupisteessä. Tästä johtuen joudutaan usein analysoimaan kohtalaisen suurta kuva-aluetta, joten Bonnassien menetelmän suorituskyky ei ole kilpailukykyinen seuraavana esiteltävän luokittelun kanssa.

Tässä työssä käytettiin kaksiulotteisen luokittelualgoritmin suoraa yleistystä kolmeen ulottuvuuteen. Jokaisen rangon pisteen rankoon kuuluvien 26-naapurien määrä lasketaan ja risteyspisteiksi valitaan ne pisteet, joille saatu naapuripisteiden määrä on välillä



Kuva 7: Rangon pisteiden luokittelu kaksiulotteisessa tapauksessa. Vasemmalla alkupe-
räinen kuva, keskellä sen ranko ja oikealla suurennos rangon neliöllä merkitystä alueesta.
Risteyspisteet on merkitty suurennokseen harmaalla.



Kuva 8: Rangon pisteiden luokittelu kolmiulotteisessa tapauksessa. Vasemmalla taso-
mainen alue, jota ei saa luokitella sisältämään risteyspisteitä. Keskellä kahden tason
leikkaus. Risteyspisteet on merkitty harmaalla. Oikealla pitkä, ohut kappale, joita taso-
maiseksi määritellyssä rangossa ei ole.

9–26. Tällöin tasomaisia alueita ei luokitella risteyspisteiksi mutta kahden tason leik-
kaukset luokitellaan. Kuva 8 visualisoi risteyspisteiksi luokiteltavia pisteitä. On syytä
huomata, että kuvan 8 oikeassa reunassa olevia yhden kuvapisteen paksuisia objekteja
ei kuulu rankoon, sillä tässä työssä käytetään tasomaista rankoa.

Tällä yksinkertaisella määritelmällä on kuitenkin huonot puolensa: Jotkin rangon haarat
voivat olla 26-kytkettyjä toisiinsa edellisessä kappaleessa esitellyn ensimmäisen vaiheen
suorittamisen jälkeen, vaikka mikään haara ei ole enää 6-kytketty toisiin haaroihin. Tä-
män ongelman korjaamiseksi suoritetaan toinen vaihe, jossa risteyspisteiksi luokiteltujen
pisteiden muodostamia risteysalueita laajennetaan rangon tavallisiin pisteisiin päin.

Ensimmäisen vaiheen antaman kuvan A , johon on merkitty ranko ja risteyspisteet, voidaan ajatella olevan muotoa $A = I + S$. Tässä esityksessä I on binäärikuva, joka saa arvon 1 risteyspisteissä ja S binäärikuva, joka saa arvon 1 rankopisteissä. Kuva A sisältää siis arvon 1 tavallisissa rangon pisteissä ja arvon 2 risteyspisteissä. Binäärikuvalle I suoritetaan kuvan S rankopisteisiin rajoitettu dilaatio-operaatio $3 \times 3 \times 3$:n kuvapisteen kokoisella ytimellä [Gon02], jolloin saadaan tulokseksi lopulliset risteysalueet sisältävä kuva I' :

$$I'(\vec{r}) = \begin{cases} 1, & \text{jos } I(\vec{r}) = 1, \\ 1, & \text{jos } S(\vec{r}) = 1 \text{ ja } 1 \in B_{26}(I, \vec{r}), \\ 0 & \text{muulloin,} \end{cases} \quad (8)$$

jossa $B_{26}(I, \vec{r})$ on kuvan I pisteen \vec{r} 26-ympäristö. Toisin sanoen laajennetut risteysalueet sisältävä kuva koostuu laajentamattomista risteysalueista ja niiden 26-kytkeytyneistä naapuripisteistä, jotka ovat myös rankopisteitä. Laajentamisen jälkeen risteysalueet erottavat rangon haarat toisistaan niin, että mikään haara ei ole 26-kytkeytynyt mihinkään toiseen haaraan.

3.3.3 Alueiden luokittelu ja yhdistely

Risteyksiksi luokitellut kuituverkoston pisteet jakavat nyt verkoston osiin. Ideaalisessa tilanteessa risteysalueiksi olisi merkitty vain todellisia kuitujen leikkausalueita ja jokainen risteysalueiden eristämä rangon haara edustaisi yhtä kuitua. Käytännön tilanne ei ole näin ideaalinen. Ranko ei kuvaa täydellisesti yksittäisen kuidun rakennetta, sillä yksittäinen kuitu ei välttämättä ole yksittäinen topologinen primitiivi. Esimerkiksi kuvassa 9 vasemmalla oleva kuitumainen objekti näyttää selkeästi yhdeltä kuidulta, mutta sen ranko koostuu kolmesta haarasta. Tämä sama ilmiö havaitaan myös kolmiulotteisessa tapauksessa. Rangon haaroja on siis yhdisteltävä niin, että samaan kuituun kuuluvat haarat yhdistetään yhdeksi haaraksi.

Tässä työssä päädyttiin yhdistämään rangon haaroja kahden kriteerin perusteella. Ensimmäisessä vaiheessa pienet alueet yhdistetään suuriin alueisiin. Toisessa vaiheessa toisiaan koskettavat alueet, joilla on samankaltainen orientaatio, yhdistetään toisiinsa. Pienten alueiden yhdistäminen suurempiin alueisiin poistaa rangon haarat, jotka



Kuva 9: Epäsäännöllinen objekti vasemmalla ja sen kolmihaarainen ranko oikealla. Kuitujen tunnistuksen aikana samaan kuituun kuuluvat haarat täytyy yhdistää.

kuvaavat kuitujen pinnassa olevia epätasaisuuksia ja säikeitä. Orientaatioon perustuva yhdistely korjaa rangon risteysalueiden virheellisesti katkaisemia kuituja.

Jotta pienet alueet voitaisiin yhdistää suuriin, täytyy alueiden koko mitata. Mittaukseen käytetään ns. tulvatäyttöalgoritmia (flood fill). Algoritmille annetaan syötteenä jokin piste täytettävältä alueelta, täytettävän alueen väri ja täyttöväri. Näiden tietojen perusteella se käy läpi siemenpisteeseen kytkeytyneen alueen, jonka jokaisen kuvapisteen väri on sama kuin siemenpisteen väri. Läpikäyty alue väritetään täyttövärillä ja samalla sen koko on helppo laskea. Olkoon p täytön alkupiste eli siemenpiste, c täytettävän alueen väri ja f täyttöväri. Tällöin kolmiulotteinen, 26-kytkeytynyt tulvatäyttöalgoritmi määritellään rekursiivisesti.

1. Mikäli p :n väri $\neq c$, lopeta.
2. Mikäli p :n väri $= f$, lopeta.
3. Aseta p :n väriksi f .
4. Suorita tulvatäyttöalgoritmi käyttäen vuorotellen siemenpisteenä jokaista pistettä p :n 26-ympäristössä. Säilytä c ja f vakioina.

Laskemalla kuinka monta kertaa vaiheeseen 3 saavutaan, saadaan täytettyjen kuvapisteen lukumäärä.

Alueiden yhdistäminen etenee siis kaikkien rangon alueiden koon laskennalla ja jokaisen alueen merkinnällä jollakin arvolla. Ne alueet, joiden koko on pienempi kuin kynnyсарvo A_s , merkitään samalla arvolla (testitapauksissa $A_s = 200$ kuvapistettä). Luokittelun jälkeen risteysalueiksi merkityjä alueita ei enää tarvita, joten ne sulautetaan alueisiin, joita ne koskettavat. Risteysalueiden sulauttamisen jälkeen pieneksi merkityt alueet sulautetaan suurempiin alueisiin. Alueen sulauttaminen suoritetaan tulvatäyttöalgoritmin muunnoksen avulla.

Olkoon C sulautettava joukko kuvapisteitä, eli siis jonkin risteysalueen kuvapisteet tai jonkin pieneksi merkityn alueen kuvapisteet. Etsitään ensin C :n reunaa koskettavat pisteet, jotka kuuluvat rankoon. Merkitään saatua joukkoa S :llä, jolle siis pätee

$$S = \{z \mid B_{26}(I, z) \cap C \neq \emptyset \text{ ja } z\text{:n väri ei ole taustaväri.}\}. \quad (9)$$

Käytetään nyt joukkoa S siemenpisteinä tulvatäyttöalgoritmille niin, että täyttö lähtee liikkeelle kaikista siemenpisteistä yhtä aikaa. Tulvatäyttöalgoritmi muuttuu nyt seuraavaan muotoon.


1. $c = C$:n kuvapisteiden väri.
2. Jokaiselle $p \in S$
 - (a) $f = p$:n väri.
 - (b) Jokaiselle pisteelle $p' \in B_{26}(p)$
 - i. jos $p' \notin C$, jatka seuraavaan p' :n arvoon
 - ii. jos p' :n väri ei ole c , jatka seuraavaan p' :n arvoon
 - iii. aseta p' :n väriksi f
 - iv. lisää p' joukkoon S .

Vaihe 2(b)i rajoittaa täytön C :n alueelle. Vaihe 2(b)ii taas estää täyttöä etenemästä toisella värillä täytettyihin kuvapisteisiin, eli toiseen rangon haaraan kuuluviin alueisiin. Kumpikin näistä vaiheista tarvitaan, sillä joukon C pisteiden väri muuttuu täytön edetessä. Kuvassa 10 on esitetty visualisointi yhden risteysalueen sulauttamisesta.

0	0	0	1	0	0
0	0	1	1	0	0
0	1	2	2	1	0
0	1	2	2	1	0
1	2	1	1	1	1
2	1	0	0	0	0

Kuva 10: Rangon alueiden sulauttaminen kaksiulotteisessa tapauksessa. Jokainen neliö kuvaa yhtä kuvapistettä. Alkuperäiset siemenalueet on merkitty nolilla, ensimmäisellä iteraatiolla alueisiin lisätyt kuvapisteeet on merkitty numerolla yksi ja vastaavasti toisella iteraatiolla lisätyt alueet numerolla kaksi. Harmaasävy erottaa eri alueet.

Alueiden suuntautumiseen perustuva yhdistely toteutetaan pääkomponenttianalyysin avulla. Pääkomponenttianalyysin tarkoitus on helpottaa monimuuttujaisten järjestelmien kuvailua korvaamalla alkuperäiset muuttujat pienemmällä muuttujajoukolla niin, että uudet muuttujat säilyttävät mahdollisimman suuren osan vanhojen muuttujien vaihtelusta [Mud]. Rangon alueen orientaatio määritetään pääkomponenttianalyysin avulla käyttämällä datajoukkona alueen kuvapisteen koordinaatteja. Esimerkki pääkomponenttianalyysin tuloksesta kaksiulotteiselle alueelle on kuvassa 11.



Kuva 11: Pääkomponenttianalyysi. Paperiliittimen muotoisen alueen pääkomponenttien suunnat on merkitty harmailla nuolilla.

Olkoon \mathbf{X} datamatriisi. Tällöin sen pääkomponenttimuunnos \mathbf{Y} saadaan lausekkeesta

$$\mathbf{Y}^T = (\mathbf{X} - E(\mathbf{X}))\mathbf{W} = \mathbf{V}\Sigma, \quad (10)$$

jossa $\mathbf{V}\Sigma\mathbf{W}^T$ on matriisin $\mathbf{X} - E(\mathbf{X})$ singulaariarvohajotelma. Mudrován [Mud] esitystä seurailleen matriisi \mathbf{X} on muotoa $\mathbf{X} = [\vec{x}_1, \vec{x}_2, \dots, \vec{x}_n]^T$, jossa \vec{x}_i , $i = 1, \dots, n$, ovat K -ulotteiset datavektorit. Pääkomponenttianalyysi antaa nyt matriisin \mathbf{Y} , joka on muotoa

$$\mathbf{Y} = \mathbf{A}(\mathbf{X} - E(\mathbf{X})). \quad (11)$$

Tässä lausekkeessa $E(\mathbf{X})$ on pystyvektori, joka sisältää matriisin \mathbf{X} rivien keskiarvot, jotka lasketaan kaavalla

$$E(\mathbf{X}) = \frac{1}{K} \sum_{j=0}^K \vec{x}_j. \quad (12)$$

Matriisin \mathbf{A} rivit ovat kovarianssimatriisin $\mathbf{C}_{\mathbf{X}}$ ominaisvektorit järjestettynä vastaavien ominaisarvojen mukaan suurimmasta pienimpään. Matriisi $\mathbf{C}_{\mathbf{X}}$ lasketaan kaavalla

$$\mathbf{C}_{\mathbf{X}} = E((\mathbf{X} - E(\mathbf{X}))(\mathbf{X} - E(\mathbf{X}))^T) = \frac{1}{K} \sum_{j=1}^K \vec{x}_j \vec{x}_j^T - E(\mathbf{X})E(\mathbf{X})^T. \quad (13)$$

Matriisissa \mathbf{X} on n riviä, joten matriisi $\mathbf{C}_{\mathbf{X}}$ on kooltaan $n \times n$ ja sen alkio $\mathbf{C}_{\mathbf{X}}(i, j)$ on muuttujien \vec{x}_i ja \vec{x}_j kovarianssi:

$$\mathbf{C}_{\mathbf{X}}(i, j) = E((\vec{x}_i - E(\vec{x}_i))(\vec{x}_j - E(\vec{x}_j))). \quad (14)$$

Rangon alueen orientaation määrittämistä varten lisätään jokaisen alueeseen kuuluvan kuvapisteen x -koordinaatti vektoriin \vec{a} , y -koordinaatti vektoriin \vec{b} ja z -koordinaatti vektoriin \vec{c} . Konstruoidaan matriisi \mathbf{X} vektorien \vec{a} , \vec{b} ja \vec{c} avulla: $\mathbf{X} = [\vec{a}, \vec{b}, \vec{c}]^T$. Matriisin $\mathbf{C}_{\mathbf{X}}$ järjestetyt ominaisvektorit \vec{e}_1 , \vec{e}_2 ja \vec{e}_3 ovat nyt kohtisuorassa toisiaan vastaan olevat pääakselit. Vektorin \vec{e}_1 suunta on rangon alueen pääasiallinen orientaationsuunta ja vektoreita vastaavien ominaisarvojen keskinäinen suuruus kertoo alueen muodosta eli orientaation voimakkuudesta.

Alueiden yhdistämiseksi jokaisen alueen orientaatio määritetään edellä esitellyllä pääakselimenetelmällä. Kahden pääakselin suunnan samankaltaisuuden määrittämiseksi lasketaan niiden välisen pistetulon itseisarvo, joka on sama kuin niiden välisen kulman kosini. Alueet yhdistetään jos niitä vastaavien pääakselien välinen kulma on pienempi kuin kynnysarvo α_1 tai jos alueiden välisen risteysalueen koko kuvapisteissä laskettuna on pienempi kuin parametri δ ja pääakselien välinen kulma pienempi kuin α_2 , jossa $\alpha_2 > \alpha_1$.

3.3.4 Alkuperäisen kuituverkoston regenerointi

Alueiden luokittelun ja yhdistelyn jälkeen jokainen rangon alue kuvaa yhden kuidun muotoa ja alkuperäisen kuvan aluetta, joka kuuluu ko. kuituun. Alkuperäisen datan luokitteluun laajennetaan luokiteltu ranko takaisin niihin kuvapisteisiin, joista ranko alunperin muodostettiin. Näin menetellen jokainen alkuperäisen datan kuitumateriaaliksi segmentoitu kuvapiste saadaan luokiteltua.

Rangon laajennus tehdään samalla tulvatäyttöalgoritmilla, jota käytettiin risteysalueiden ja pienten alueiden liittämiseen ympäröiviin rakenteisiin. Nyt siemenpistejoukkona S käytetään luokiteltua rankoa ja rajoittavana joukkona C niitä kuvapisteitä, joista ranko alunperin laskettiin. Tämän operaation tuloksena saadaan kuva, jossa kuidut on erotettu toisistaan ja taustasta, esim. kuva 12.

3.4 Menetelmiä yksittäisen kuidun analysointiin

Perinteisesti yksittäisten kuitujen ominaisuuksia on määritetty poikkileikekuvien perusteella. Poikkileikekuvissa ontelon sisältävät kuidut muodostavat yleensä varsin selkeitä rengasmaisia alueita, umpinaiset kuidut kiekkoja ja muun muotoiset kuidut epämääräisiä alueita. Näiden alueiden muodon ja koon määrittäminen on eräs kuituanalyysin perusmenetelmä.

Poikkileikekuvina voidaan käyttää esimerkiksi pyyhkäisyelektronimikroskoopilla (SEM) otettuja kuvia. Tutkittavaan näytteeseen hiotaan tai leikataan ensin suora pinta. Tämä



Kuva 12: Erotetut kuidut. Jokainen esitellyn algoritmin erottama kuitu on merkitty satumanvaraisella värillä. Käytetyt parametrit ovat $(A_s, \alpha_1, \delta, \alpha_2) = (200, 15^\circ, 200, 30^\circ)$.

pinta kuvataan, jonka jälkeen pinnasta hiotaan tai leikataan ohut kerros pois ja syntynyt uusi pinta kuvataan uudestaan. Tällä menetelmällä saadaan poikkileikekuvia, jotka ovat pinnan tasossa erittäin tarkkoja. Hionta tai leikkaus on kuitenkin varsin työläs ja aikaa vaativa operaatio, joten pinnan tasoa vastaan kohtisuorassa suunnassa resoluutio on yleensä heikompi. [Aro02]

Poikkileikkeisiin perustuvien mittausten huonoin puoli on se, että mittaustulokset riippuvat kuitujen orientaatiosta. Leikkaustasoa vastaan kohtisuorien kuitujen poikkileikkaukset ovat muodoltaan ja kooltaan erilaisia kuin leikkaustasossa olevien kuitujen. Tästä johtuen poikkileikkauksiin perustuvat menetelmät sopivat vain pääasiallisesti yhteen suuntaan orientoituneiden kuiturakenteiden analysointiin. Sillonkin tuloksiin joudutaan soveltamaan tilastollisia oletuksia kuitujen orientaatiojakaumasta ja käyttämään monimutkaisia korjauskertoimia jotka kumoavat orientaatiojakauman vaikutuksen mittauksien.

Kun yksittäiset kuidut voidaan erotella, voidaan jokaisen kuidun keskiakseli määrittää. Tämän jälkeen kuidusta voidaan luoda uudet poikkileikkaukset niin, että jokainen poikkileikkaus on keskiakselin normaalitasossa. Nyt poikkileikkauksiin perustuvia mittaamenetelmiä voidaan siis soveltaa uudelleensiivutettuihin kuituihin, jolloin saa-

daan orientaatiojakaumasta riippumattomia tuloksia ilman tilastollisia korjauksia. Lisäksi päästään helposti käsiksi kuidun keskiakseliin, jonka perusteella voidaan tehdä päätelmiä kuidun käyryydestä ja pituudesta.

Tässä osiossa käsitellään tunnistettujen kuitujen keskiakselin määrittämistä, uudelleensiivutusta ja kuidusta mitattavia piirteitä.

3.4.1 Kuidun poikkileikkausten määrittäminen

Tässä työssä erotellun kuidun analysointiin käytetään kuidun poikkileikkauksiin perustuvia menetelmiä. Näiden leikkausten määrittämiseksi täytyy ensin määritellä kuidun keskiakseli, jonka jälkeen voidaan määrittää akseliin sidottu koordinaatisto, jossa kuidun uudelleensiivutus suoritetaan.

Keskiakselin määrittäminen ei ole helppo tehtävä. Kuitujen käyryyden ja taitekohtien lisäksi on otettava huomioon erilaiset kuitutyypit, joita lueteltiin kappaleessa 3.2. Kuitujen mahdollisen käyryyden vuoksi akseli ei voi olla suora viiva, mutta se ei saa olla myöskään liian monimutkainen käyrä, sillä tällöin sen sovittaminen kuidun pisteisiin olisi vaikeaa. Jonkinlaisen keskiakselin voisi määritellä kuvapistepohjaisesti n -polkuna. Näin määritellyn akselin tangentilla on kuitenkin vain muutama mahdollinen suunta, esimerkiksi 26-kytkeytyneen polun tapauksessa 13 suuntaa. Kuidun uudelleensiivutus ei onnistu, mikäli tangentsivektorin arvot eivät muutu jatkuvasti. Akselin täytyy siis olla jatkuva ja jatkuvasti derivoituva funktio, joka on helppo sovittaa kuvadataan.

Edellä esitettyjen vaatimusten valossa akselifunktioksi valittiin B-splini [Boo78]. Se on paloittain määritelty funktio, jonka jatkuvuutta ja derivoituvuutta voi helposti säätää. Lisäksi käytettyjen palojen määrää muuttamalla voidaan vaikuttaa akseliin muodostuvien mutkien maksimimäärään. Splinin sovittaminen datapisteisiin on kohtuullisen helppoa ja stabiilia. Käytetty sovitusten menetelmä esitellään seuraavissa kappaleissa.

Määritellään ensin B-splini.

Määritelmä 3.8. *B-splini* $C(t)$ on käyrä

$$C(t) = \sum_{i=0}^n P_i N_{i,p}(t), \quad (15)$$

jossa P_0, \dots, P_n ovat splinin ohjauspisteet ja $N_{i,j}$ splinin kantafunktiot, jotka B-splinin tapauksessa ovat muotoa

$$N_{i,0}(t) = \begin{cases} 1, & \text{jos } t_i \leq t < t_{i+1} \text{ ja } t_i < t_{i+1}, \\ 0 & \text{muulloin} \end{cases} \quad (16)$$

$$N_{i,j}(t) = \frac{t - t_i}{t_{i+j} - t_i} N_{i,j-1}(t) + \frac{t_{i+j+1} - t}{t_{i+j+1} - t_{i+1}} N_{i+1,j-1}(t). \quad (17)$$

Pisteet $\{t_0, t_1, \dots, t_m\}$ muodostavat spliniin liittyvän solmuvektorin. Jokainen solmu $t_i \in [0, 1]$ ja $t_{i+1} \geq t_i$. Solmuja $t_{p+1}, \dots, t_{m-p-1}$ sanotaan sisäsolmuiksi.

Splinin aste p saadaan lausekkeesta $p \equiv m - n - 1$.

On syytä huomata, että määritelmä todellakin on paloittainen kantafunktioiden paloittaisesta määrittelystä johtuen, vaikei paloittaisuus näykään suoraan lausekkeesta (15). B-spliniä sanotaan tasamittaiseksi, mikäli kaikkien sisäsolmujen välimatka on sama. Kuutiollinen B-splini on B-splini, jonka aste on $p = 3$. Mikäli peräkkäiset ohjauspisteet yhdistetään viivoilla, saadaan splinin ns. ohjausmonikulmio.

Tässä työssä käytetään vain tasamittaisia kuutiollisia B-splinejä. Näillä splineillä on se kätevä ominaisuus, että yhteen splinin määrittelypalaan vaikuttaa vain neljä ohjauspistettä, mutta niillä on kuitenkin kaksi jatkuvaa derivaattaa. Kaavan (15) summa rajoittuu tällöin neljään termiin. Niinpä tällaisen splinin yhdelle määrittelypalalle, jota merkitään $X(t)$:llä, voidaan johtaa muoto

$$X(t) = \frac{1}{6}(4P_1 + P_2 - P_0(t-1)^3 + 3P_2t + 3(-2P_1 + P_2)t^2 + (3P_1 - 3P_2 + P_3)t^3) \quad (18)$$

lähtien liikkeelle B-splinin määritelmästä (16) (vertaa [Hof98]). Tässä lausekkeessa $t \in [0, 1]$ ja P_0, P_1, P_2 ja P_3 ovat kyseiseen palaan vaikuttavat ohjauspisteet. Jotta saadaan koko N :stä ohjauspisteestä $\{T_0, \dots, T_N\}$ muodostuva splinikäyrä, määritellään kaavaan

(18) sijoitettavat P_i :t ja t seuraavalla tavalla:

$$t' = t_a \cdot (N - 3) \quad (19)$$

$$i = \lfloor t' \rfloor \quad (20)$$

$$t = t' - i \quad (21)$$

$$P_0 = T_i \quad (22)$$

$$P_1 = T_{i+1} \quad (23)$$

$$P_2 = T_{i+2} \quad (24)$$

$$P_3 = T_{i+3}, \quad (25)$$

jossa $t_a \in [0, 1]$ on alkuperäinen käyräparametri, eli koko splinin ensimmäinen piste saadaan arvolla $t_a = 0$ ja viimeinen piste arvolla $t_a = 1$. Näissä määritelmässä ei enää ole eksplisiittisesti tietoa splinin solmujen arvoista, sillä tasamittaisuuden perusteella solmujen arvot tiedetään etukäteen.

Lausekkeesta (18) on helppo määrittää splinin derivaatta ko. välillä. Derivaataksi saadaan

$$\frac{dX}{dt} = \frac{1}{6}(-3P_0(t-1)^2 + 3P_2 + 6(-2P_1 + P_2)t + 3(3P_1 - 3P_2 + P_3)t^2). \quad (26)$$


Myöhemmin tarvitaan myös splinin toista derivaattaa, joten lasketaan sekin tässä:

$$\frac{d^2X}{dt^2} = -P_0(t-1) + (-2P_1 + P_2) + (3P_1 - 3P_2 + P_3)t. \quad (27)$$

Eräs tasamittainen kuutiollinen B-splini on piirretty kuvaan 13.

Splinin sovittaminen kuituun

Splini voitaisiin periaatteessa sovittaa suoraan kuidun muodostaviin kuvapisteisiin. Näitä kuvapisteitä on kuitenkin yleensä hyvin suuri määrä, joten hyvän sovituksen laskeminen kestäisi liian pitkään. On siis määritettävä sopivimmat sovituspisteet, eli tässä tapauksessa lähellä kuidun keskiakselia olevat kuvapisteet. Näiden pisteiden löytämiseksi



Kuva 13: Tasamittainen kuutiollinen B-splini. Splinikäyrä on merkitty jatkuvalla viivalla ja ohjausmonikulmio katkoviivalla. Mustat pisteet merkitsevät käyrän ohjauspisteitä.

kuidulle suoritetaan dilaatio-operaatio niin monta kertaa, että kuidun keskellä mahdollisesti oleva ontelo umpeutuu. Tämän jälkeen määritetään syntyneen rakenteen viivoista koostuva ranko kuten artikkelissa [Kle04]. Ranko muodostaa nyt kuidun kuvapisteistä koostuvan keskiakselin. Akselissakin on liikaa pisteitä sopivan sileän splinisovituksen aikaansaamiseksi, joten pisteitä vähennetään jakamalla kuva pieniin kuutioihin ja laske-
malla jokaisessa kuutiossa olevien keskiakseliin kuuluvien kuvapisteiden keskimääräinen paikka. Kyseisen kuution muut kuvapisteet merkitään taustaan kuuluviksi ja keskimääräisessä paikassa oleva keskiakseliin kuuluvaksi. Tällä menettelyllä keskiakseliin kuuluvien kuvapisteiden määrä saadaan laskettua sopivaksi splinisovitusta varten.

Splinin sovittamiseen käytettävässä kustannusfunktiossa on mitä ilmeisimmin oltava termi, jonka arvo riippuu jokaisen datapisteen etäisyydestä spliniin. Merkitään sovitettavaa tasamittaista kuutiollista B-spliniä P :llä ja sen arvoa $P(t)$:llä, $t \in [0, 1]$ kuten edellä. Tällöin datapisteiden X_k , $0 \leq k \leq m$, ja splinin välistä etäisyyttä kuvaa termi

$$\sum_{k=0}^m d^2(P, X_k). \quad (28)$$

Tässä kaavassa etäisyys d saa muodon

$$d^2(P, X_k) = \min_{t \in [0, 1]} \|P(t) - X_k\|^2. \quad (29)$$

Jotta splinin päät eivät karkaisi pois datapisteiden läheltä, lisätään kustannusfunktion termi, joka suosii sellaisia splinejä, joiden solmukohdissa olevat pisteet ovat lähellä datapisteitä:

$$\sum_{k=0}^n d^2(P(\frac{k}{n}), X), \quad (30)$$

jossa etäisyys d määritellään kaavalla

$$d^2(P(t), X) = \min_{i \in [0, m]} \|P(t) - X_i\|^2 \quad (31)$$

Yhdistämällä nämä termit saadaan minimoitavaksi kustannusfunktioksi

$$S = \alpha \sum_{k=0}^m d^2(P, X_k) + \beta \sum_{k=0}^n d^2(P(\frac{k}{n}), X). \quad (32)$$

Tässä työssä minimointiin käytettiin Levenbergin ja Marquardtin menetelmää [Pre02]. Kyseessä on iteratiivinen menetelmä funktion minimointiin. Menetelmä minimoi neliösummista koostuvaa funktiota

$$F(\vec{x}) = \frac{1}{2} \sum_{i=1}^m (f_i(\vec{x}))^2. \quad (33)$$

Jokaisella iteraatiolla parametrivektori \vec{x} korvataan vektorilla $\vec{x} + \vec{\delta}$, jossa $\vec{\delta}$ määritetään ratkaisemalla se kaavasta

$$(\mathbf{J}^T \mathbf{J} - \lambda \text{diag}(\mathbf{J}^T \mathbf{J})) \vec{\delta} = -\mathbf{J}^T \mathbf{f}(\vec{x}), \quad (34)$$

jossa

$$\mathbf{f}(\vec{x}) = \begin{bmatrix} f_1(\vec{x}) \\ \vdots \\ f_m(\vec{x}) \end{bmatrix} \quad (35)$$

ja \mathbf{J} on F :n Jacobin matriisi. Vaimennuskerroin λ on ensimmäisellä iteraatiolla yksi. Seuraavilla iteraatioilla vaimennuskertoimen arvoa kasvatetaan tai pienennetään. Mikäli iteraation tuloksena F :n arvo kasvaisi, tulos hylätään ja vaimennuskertoimen arvoa kasvatetaan (esimerkiksi kertomalla se kymmenellä) ja suoritetaan iteraatio uudestaan. Jos F :n arvo pienenee, saatu \vec{x} pidetään ja vaimennuskertoimen arvoa pienennetään (esi-

merkiksi jakamalla se kymmenellä). Iterointi loppuu, kun F :n arvo muuttuu vähemmän kuin ennalta säädetty kynnsarvo, iteraatioiden asetettu maksimimäärä tulee täyteen tai vaimennuskerroin kasvaa liian suureksi.

Menetelmälle tulee antaa jokin alkuarvaus parametrivektorista \vec{x} . Tässä työssä alkuarvauksena käytettiin datapistejoukon suurimman pääkomponentin suuntaista ja pituista, datapisteisiin keskitettyä spliniä. Suurin pääkomponentti määritettiin pääkomponenttimuunnoksella kuten kappaleessa 3.3.3.

Poikkileikkeiden määrittäminen keskiakselin suunnassa

Kun kuidun keskiakseli on löydetty, esitetään kuitu koordinaatistossa, jossa z -koordinaatti osoittaa aina keskiakselin tangentin suuntaan. Luodaan tätä varten sopiva koordinaatistomuunnos karteesisista koordinaateista keskiakselin Frenet'n koordinaatteihin käyttäen Frenet'n ja Serret'n kaavoja [Kre91]. Olkoon kuidun keskiakseli käyrä $\vec{\gamma} : [0, 1] \rightarrow \mathbb{R}^3$. Tällöin Gram-Schmidt -ortogonalisoinnin avulla saadaan

$$\vec{\gamma}'(t) = \frac{d}{dt}\vec{\gamma}(t), \quad (36)$$

$$\vec{\gamma}''(t) = \frac{d^2}{dt^2}\vec{\gamma}(t), \quad (37)$$


$$\vec{z}'(t) = \frac{\vec{\gamma}'(t)}{\|\vec{\gamma}'(t)\|}, \quad (38)$$

$$\hat{\vec{y}}'(t) = \vec{\gamma}''(t) - \langle \vec{\gamma}''(t), \vec{z}' \rangle \vec{z}', \quad (39)$$

$$\vec{y}'(t) = \frac{\hat{\vec{y}}'}{\|\hat{\vec{y}}'\|} \text{ ja} \quad (40)$$

$$\vec{x}' = \vec{y}'(t) \times \vec{z}'(t). \quad (41)$$

Nyt vektorit \vec{x}' , \vec{y}' ja \vec{z}' ovat käyrään sidotun koordinaatiston yksikkövektorit, jotka on visualisoitu kuvassa 14. Vektori \vec{z}' osoittaa käyrän tangentin suuntaan, \vec{y}' käyrän suurimman kaarevuuden suuntaan ja \vec{x}' kahta edellistä vastaan kohtisuoraan suuntaan.



Kuva 14: Kuitujen uudelleensiivutuksessa käytettävä koordinaatisto. Yhtenäinen viiva kuvaa kuidun keskiakselia. Uuden koordinaatiston z -akseli osoittaa kuidun keskiakselin tangentin suuntaan, y -akseli kuidun kaarevuuskeskipisteeseen päin ja x -akselin suuntaisen yksikkövektori on $\vec{x}' = \vec{y}' \times \vec{z}'$.

Nyt siis uudessa koordinaatistossa pisteessä $\vec{r}' = (\alpha, \beta, t)$ oleva arvo saadaan alkuperäisestä kuvasta koordinaateista

$$\vec{r} = \vec{\gamma}(t) + \alpha \vec{x}'(t) + \beta \vec{y}'(t). \quad (42)$$

Käytännössä tämä muunnos suoritetaan kuidulle niin, että luodaan uusi kolmiulotteinen kuva, jonka koordinaattiakselit vastaavat muunnettuja koordinaattiakseleita. Tämän kuvan jokaisen pikselin arvo lasketaan kaavalla (42). Näin saadaan kuva suorasta kuidusta, jota voidaan jälkikäsitellä kuten mitä tahansa tavallista kolmiulotteista kuvaa koordinaattimuunnoksesta välittämättä.

3.4.2 Kuidun poikkileikkauksiin perustuvia piirteitä

Kuidun poikkileikkausten analysoimiseksi niistä täytyy määrittää tarpeellisia tunnuslukuja, joita kutsutaan “piirteiksi”. Tässä kappaleessa esitellään yleisesti käytössä olevia piirteitä, joita tähän mennessä on käytetty esim. SEM-poikkileikkausten ja valomikroskooppikuvien analysointiin [BW04] [Xu93], mutta joita voidaan nyt soveltaa erotettuihin kuituihin ja niistä laskettuihin poikkileikkeisiin. On huomattava, että perusmuodossaan kaikki esiteltyt piirteet määritetään yksittäisestä poikkileikkeestä, joten jokaisen piirteen arvo on itse asiassa funktio kaavan (42) parametrin t suhteen. Piirteen yhteydessä esitellään myös vastaava kolmiulotteinen versio, mikäli sellaisen voi järkevästi johtaa. Kolmiulotteinen versio ei ole riippuvainen t :stä, sillä se lasketaan kuidun muodostavasta (kolmiulotteisesta) kuvapistejoukosta eikä yhdestä siivusta.


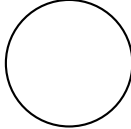
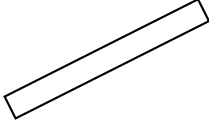

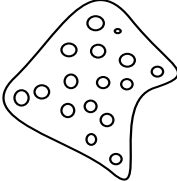
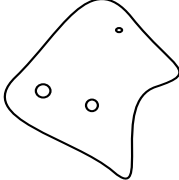
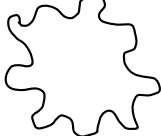
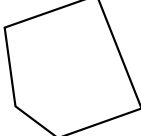

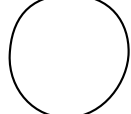
Yhteistä piirteille on se, että ne ovat dimensiottomia lukuja jotka voidaan määrittää kaikille geometrisille objekteille. Ne eivät saa riippua tutkittavan objektin paikasta, orientaatiosta tai skaalauksesta. Kuvassa 15 on visualisoitu seuraavaksi esiteltäviä piirteitä.

Pyöreys (Circularity) Pyöreys kuvaa tutkittavan objektin kompaktisuutta suhteessa ympyrään. Se on tutkittavan objektin pinta-alan suhde sellaisen ympyrän pinta-alaan, jonka kehän pituus on sama kuin objektin ulkoreunan pituus. Olkoon tutkittavan objektin pinta-ala A ja sen ulkoreunan pituus P . Tällöin pyöreys C saadaan lausekkeesta

$$C = 4\pi \frac{A}{P^2}. \quad (43)$$

Ympyräkiekolle pyöreys saa arvon 1, neliölle $C = \frac{\pi}{4}$ ja suoralle viivalle $C = 0$.

Kolmiulotteinen tapaus ei ole aivan näin suoraviivainen, sillä pallomaisuudelle (sphericity) on käytössä kaksi erilaista määritelmää. Olkoon A_{obj} objektin pinta-ala, A_s sellaisen pallon pinta-ala, jonka tilavuus on sama kuin objektin tilavuus, V_{obj} objektin tilavuus ja V_s sellaisen pallon tilavuus, jonka pinta-ala on sama kuin objektin pinta-ala. Näillä merkinnöillä voidaan kirjoittaa määritelmät muotoon

	Pieni	Suuri
Pyöreys		
Sivusuhte		
Kiinteys		
Konveksisuus		
Tiiviys		

Kuva 15: Piirteiden vertailua. Vasemmanpuolimmaisessa sarakkeessa on piirteen nimi. Keskimmäisessä sarakkeessa on objekti, jolle kyseisen piirteen arvo on pieni. Oikeanpuolimmaisessa sarakkeessa olevalle objektille piirteen arvo on suuri.

1. Objektin pinta-alan suhde sellaisen pallon pinta-alaan, jonka tilavuus on sama kuin objektin tilavuus:

$$\psi_1 = \frac{A_{obj}}{A_s} = \frac{A_{obj}}{\pi^{\frac{1}{3}}(6V_{obj})^{\frac{2}{3}}}. \quad (44)$$

Tällä määritelmällä pallolle $\psi_1 = 1$, kuutiolle $\psi_1 = \sqrt[3]{\frac{6}{\pi}}$ ja viivalle $\psi_1 = 0$.

2. Objektin tilavuuden suhde sellaisen pallon tilavuuteen, jonka pinta-ala on sama kuin objektin pinta-ala:

$$\psi_2 = \frac{V_{obj}}{V_s} = 6\pi^{\frac{1}{2}} \frac{V_{obj}}{A_{obj}^{\frac{3}{2}}}. \quad (45)$$

Tällä määritelmällä pallolle $\psi_2 = 1$, kuutiolle $\psi_2 = \sqrt{\frac{\pi}{6}}$ ja viivalle $\psi_2 = 0$.

Kumpikin määritelmä on yleisesti käytetty. On huomattava, että määritelmä (2) on suora yleistys pyöreiden kaksiulotteiselle määritelmälle kaavassa (43). Joissakin lähteissä käytetään pyöreiden määritelmänä myös tässä esiteltyjen määritelmien käänteislukuja (esim. [BW05]). Terminologia ei siis aina ole selkeää.

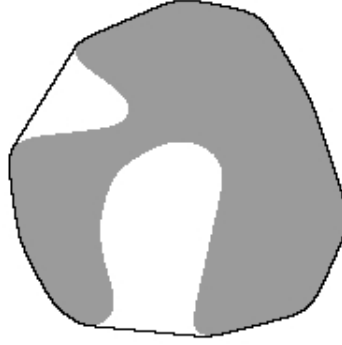
Sivusuhte (aspect ratio) Sivusuhte kuvaa kappaleen muodon pitkänomaisuutta. Se määritellään kaavalla

$$f_{asp} = \frac{d_{min}}{d_{max}}, \quad (46)$$

jossa d_{max} on objektin suurin halkaisija ja d_{min} pienin niistä objektin halkaisijoista, jotka ovat kohtisuorassa suurinta vastaan. Hyvin pitkälle objektille sivusuhte lähestyy nollaa kun taas pyöreälle tai nelikulmaiselle objektille sivusuhte on yksi. Kolmiulotteinen sivusuhte voidaan määritellä monella tavalla. Meridionaalinen sivusuhte saadaan, kun määritellään d_{max} objektin suurimmaksi halkaisijaksi ja d_{min} objektin pienimmäksi, suurinta halkaisijaa vastaan kohtisuoraksi halkaisijaksi. Mikäli taas otetaan luvuksi d_{max} suurin objektin halkaisija, joka on kohtisuorassa sekä pienintä että suurinta halkaisijaa vastaan ja luvuksi d_{min} objektin pienin halkaisija, saadaan ekvatoriaalinen sivusuhte.

Kiinteys (solidity) Kiinteys kuvaa objektin ”reikäisyyttä”. Se määritellään kaavalla

$$f_{sol} = \frac{A}{A_c}, \quad (47)$$



Kuva 16: Konvekssi runko. Objekti on merkitty harmaalla ja sen konveksin rungon reunat mustalla viivalla.

jossa A on objektin pinta-ala ja A_c objektin konveksin rungon pinta-ala. Konvekssi runko on pienin konvekssi joukko joka sisältää objektin. Kiinteys on pieni mikäli objektissa on paljon reikiä, kun taas reiättömässä, konveksissa objektissa kiinteys lähestyy arvoa 1. Kuvassa 16 on visualisoitu objekti ja sen konvekssi runko. On huomattava, että pieni kiinteyden arvo voi johtua myös objektin reunoissa olevista käytävistä objektin sisään, kuten kuvassa 16.

Kolmiulotteisessa tapauksessa kiinteys määritellään objektin tilavuuden ja vastaavan konveksin rungon tilavuuden suhteena:

$$f_{sol} = \frac{V}{V_c} \quad (48)$$

Konveksisuus tai aaltoilevuus (convexity, waviness) Konveksisuus kuvaa objektin reunan aaltoilevuutta. Sen määritelmä on

$$f_{con} = \frac{P_c}{P}, \quad (49)$$

jossa P on objektin reunan pituus ja P_{con} objektin konveksin rungon reunan pituus. Tämä piirre kuvaa kiinteyttä paremmin objekteja, joiden reunat ovat epäsäännölliset. Mikäli objekti on konvekssi, konveksisuus saa arvon yksi. Mikäli objekti ei ole konvekssi, eli sen reuna aaltoilee, $f_{con} < 1$, sillä konveksin rungon reuna on aina lyhyempi tai yhtä pitkä kuin sitä vastaavan objektin reuna. Kolmiulotteisessa tapauksessa määritelmä

täytyy muuttaa muotoon

$$f_{con} = \frac{A_c}{A}, \quad (50)$$

jossa A on objektin pinta-ala ja A_c objektin konveksin rungon pinta-ala.

Tilastolliset momentit Jatkuvan funktion $f : \mathbb{R}^2 \rightarrow \mathbb{R}$ (p, q) -momentti $m_{p,q}$ pisteen $\vec{c} = (c_x, c_y)$ suhteen on [Muk91]

$$m_{p,q} = \int_{x=-\infty}^{\infty} \int_{y=-\infty}^{\infty} (x - c_x)^p (y - c_y)^q f(x, y) dx dy. \quad (51)$$

Digitaaliset kuvat ovat kuitenkin luonteeltaan diskreettejä, joten integraaleja on approksimoitava jotenkin. Yksinkertaisimmillaan tulkitaan diskreetin kuvan arvot paloittain vakioiksi ja approksimoidaan integraaleja summilla. Näin saadaan kuvalle $f : [0, M] \times [0, N] \rightarrow [0, 1]$ (p, q) -momentti $m_{p,q}$ pisteen $\vec{c} = (c_x, c_y)$ suhteen:

$$m_{p,q} \approx \sum_{x=0}^M \sum_{y=0}^N (x - c_x)^p (y - c_y)^q f(x, y). \quad (52)$$

Kuten Mukundan artikkelissaan [Muk91] esittelee, on olemassa myös tarkempia approksimaatioita, jotka säilyttävät tiettyjen momenttien rotaatioinvarianssin paremmin.

Keskimomentti $\mu_{p,q}$ on momentti kuvassa olevan objektin keskipisteen (\bar{x}, \bar{y}) suhteen:

$$\bar{x} = \frac{\sum_{x=0}^M \sum_{y=0}^N x f(x, y)}{\sum_{x=0}^M \sum_{y=0}^N f(x, y)}, \quad (53)$$

$$\bar{y} = \frac{\sum_{x=0}^M \sum_{y=0}^N y f(x, y)}{\sum_{x=0}^M \sum_{y=0}^N f(x, y)}, \quad (54)$$

$$\mu_{p,q} = \sum_{x=0}^M \sum_{y=0}^N (x - \bar{x})^p (y - \bar{y})^q f(x, y). \quad (55)$$

Keskimomentit ovat translaatio-invariantteja, joten ne sopivat hyvin objektin orientaation kuvailuun. Orientaatiokulman ja -voimakkuuden määrittämiseksi luodaan kovarianssimatriisi \mathbf{C}

$$\mathbf{C} = \frac{1}{\mu_{0,0}} \begin{bmatrix} \mu_{2,0} & \mu_{1,1} \\ \mu_{0,2} & \mu_{1,1} \end{bmatrix} \quad (56)$$

ja lasketaan C :n ominaisarvot ja -vektorit. Suurinta ominaisarvoa λ_1 vastaava ominaisvektori osoittaa orientaatio-suunnan. Orientaation voimakkuusparametriksi käy ominaisarvoista laskettava eksentrisyys

$$\sqrt{1 - \frac{\lambda_2}{\lambda_1}}, \quad (57)$$

jossa λ_2 on C :n pienempi ominaisarvo. Kun objekti on pyöreä, ominaisarvot ovat samansuuruisia ja eksentrisyys on lähellä nollaa. Mikäli objekti on pitkänomainen, eksentrisyys lähestyy lukua yksi.

Tämä menetelmä redusoituu kappaleessa 3.3.3 käsitellyyn pääkomponenttimuunnokseen ja sen antama orientaatio-suunta on täsmälleen sama kuin keskimomenttien kautta johdettu orientaatio-suunta. Kappaleen 3.3.3 esitys ei ole dimensioriippuvainen, joten se toimii myös kolmiulotteisessa tapauksessa. Toki kolmiulotteisen kovarianssimatriisin kaavan voi johtaa myös keskimomenteista lähtien.

Ekvivalentti ellipsoidi Objektiin on mahdollista sovittaa ellipsi (2D) tai ellipsoidi (3D) esimerkiksi Fitzgibbonin menetelmällä [Fit99], joka on yleistettyyn ominaisarvohajotelmaan perustuva ei-iteratiivinen sovituskäytännö. Ellipsin tai ellipsoidin puoliakseleista voidaan laskea objektille jälleen uudet arviot sivusuhteesta ja eksentrisyydestä ja ellipsin pidemmän puoliakselin suunta on uusi arvio objektin orientaatiosta.

Efektiivinen halkaisija ja tiiviys Efektiivinen halkaisija on sellaisen ympyrän halkaisija, jonka ala on sama kuin objektin ala. Efektiivisen halkaisijan kaavaksi saadaan

$$f_r = 2\sqrt{\frac{A}{\pi}}, \quad (58)$$

jossa A on objektin pinta-ala. Efektiivisen halkaisijan yksikkö on pituuden yksikkö kuten suureen nimikin kertoo. Kolmiulotteisessa tapauksessa efektiivinen halkaisija on sellaisen pallon halkaisija, jonka tilavuus on sama kuin objektin tilavuus. Näin kaavaksi saadaan

$$f_r = 2\sqrt[3]{\frac{3V}{4\pi}}, \quad (59)$$

jossa V on objektin tilavuus. Efektiivinen halkaisija ei ole yksikötön suure, mutta se on silti varsin käyttökelpoinen monissa tapauksissa.

Efektiivisestä halkaisijasta saadaan dimensioton mittaluku kun se jaetaan objektin suurimmalla halkaisijalla. Suure tiiviys määritelläänkin juuri näin, objektin efektiivisen halkaisijan ja objektin suurimman halkaisijan suhteena:

$$f_{comp} = \frac{f_r}{d_{max}} = 2 \frac{1}{d_{max}} \sqrt{\frac{A}{\pi}}. \quad (60)$$

tai kolmiulotteisessa tapauksessa


$$f_{comp} = 2 \frac{1}{d_{max}} \sqrt[3]{\frac{3V}{4\pi}}. \quad (61)$$

Pallon tiiviys on siis yksi. Muille objekteille tiiviys on aina pienempi kuin yksi.

Piirteiden määrittämisestä

Edellä esiteltyjen piirteiden määritelmät näyttävät yksinkertaisilta ja helpoilta. Näin onkin, mikäli piirteiden arvoja lasketaan jatkuvilla funktioilla määritellyille objekteille. Digitaalisten kuvien diskreetin luonteen takia piirteiden arvojen määrittäminen ei kuitenkaan ole aivan triviaalia.

Diskreetille funktiolle laskettuna kaikki piirteet menettävät eksaktit invarianssi-ominaisuutensa, joita niillä jatkuvassa tapauksessa on. Erityisesti rotaatio-invarianssi heikenee, sillä \mathbb{Z}^2 -alueella määritellyn objektin käännetty versio ei ole enää määritelty \mathbb{Z}^2 :ssa. Jotta käännetty versio pystyttäisiin määrittelemään kokonaislukupisteissä, objektin pisteiden koordinaatteja täytyy approksimoida jonkin verran. Erityisesti binäärikuvia käytettäessä diskreetin määrittelyalueen merkitys korostuu, sillä tällöin yksi kuvapiste joko kuuluu objektiin tai ei. Tämä poistaa lähes kaikki interpolointimahdollisuudet, joita ei-binääristen kuvien tapauksessa voi käyttää. Ei-binäärisiä kuvia käytettäessä kuvapisteen arvo kertoo sen, kuinka suuri osa kuvapisteestä kuuluu objektiin ja kuinka suuri osa ei. Näin yhteen kuvapisteeseen sisältyy enemmän tietoa kuin binäärikuvan tapauksessa.



Kuva 17: Rasteroitu objekti, sen ala ja reunan pituus. Alkuperäinen objekti on merkitty harmaalla ja sen kuvapisteiksi muutettu versio mustilla neliöillä. Kuvapisteiksi rasteroidun objektin reuna on merkitty mustalla katkoviivalla. Reuna koostuu janoista, joiden pituus on $a = 1$ ja $b = \sqrt{2}$.

Objektin alan tai tilavuuden määrittämistä digitaalisesta kuvasta voi verrata suoraan objektin approksimointiin nelikulmioilla tai kuutioilla. Tällöin objektin alaksi määritellään yleensä yksinkertaisesti objektipisteiksi merkittyjen kuvapisteiden määrä mahdollisesti kerrottuna yhden kuvapisteen alalla. On selvää, että objektin reuna-alueilla tehdään virhe, jonka suhteellinen suuruus on verrannollinen objektiin kuuluvien kuvapisteiden määrään, ks. kuva 17. Yleensä virhe on pienehkö, sillä reunapisteen lukumäärä on normaalisti pieni verrattuna kokonaan objektin sisään mahtuvien pisteiden lukumäärään. Lisäksi kuvan kuvapisteiden määrän kasvaessa reunapisteen määrän suhde objektin alaan $\frac{p}{A} \rightarrow 0$ ja kuvapisteistä laskettu ala lähestyy objektin oikeaa pinta-alaa. Kolmiulotteisessa tapauksessa tilavuutta voidaan approksimoida samoin kuin alaa kaksiulotteisessa tapauksessa.

Suurempi virhe tehdään, mikäli objektin reunan pituus määritellään reunaan kuuluvien kuvapisteiden lukumääränä. Tämäkin approksimaatio on toki usein riittävä, mutta tarkempi pituus reunalta saadaan, mikäli määritetään reunaan kuuluvat kuvapistet ja määritellään reunan pituus peräkkäisten kuvapisteiden etäisyyksien summana. Tällöin kahden reunapisteen etäisyys on joko 1 tai $\sqrt{2}$ kerrottuna kuvapisteen sivun pi-

tuudella, ks. kuva 17. Tarkempaan reunan pituuden määrittämiseen voidaan käyttää “sisäreuna/ulkoreuna”-tekniikkaa, eli määritetään reunan pituus ensin objektin sisällä olevista reunapisteistä ja sen jälkeen objektin ulkopuolella olevista reunapisteistä. Lopullinen arvio reunan pituudelle saadaan saatujen pituuksien keskiarvosta. Mikäli halutaan vielä tarkempi approksimaatio reunan pituudelle, täytyy reunaan sovittaa (paloittain) jokin käyrä ja määrittää kahden reunapisteen välinen etäisyys sovitetun käyrän pituutena reunapisteiden välillä. Koko reunan pituus on tässäkin tapauksessa summa reunapisteiden välisistä etäisyyksistä. Kolmiulotteisessa tapauksessa objektin reunan alan määrittäminen onkin monimutkaisempi asia mikäli halutaan käyttää muuta mittaa kuin reunapisteiden lukumäärää. Alan määrittämiseen sopii yleensä visualisointiin käytettävä Marching Cubes -algoritmi [Lor87], joka määrittää objektille kolmioista koostuvan reunan. Approksimaatio reunan alasta saadaan laskemalla yhteen kaikkien tarvittavien kolmioiden alat.

Kuvan diskreettiyden aiheuttamat virheet pienenevät resoluution kasvaessa. Piirteiden määrittämiseen onkin siis syytä käyttää mahdollisimman suuriresoluutioisia kuvia. Tarkkoja kuvia käytettäessä ensimmäisenkin approksimaation antama arvio on monesti riittävän lähellä piirteen oikeaa arvoa.

3.4.3 Kuidun käyryys

Kuidun käyryyden määrittämiseksi voidaan käyttää kuidun keskiakselispliniä. Splinin käyryyttä kuvaava suure on sen energia, joka määritellään kuidun lokaalin käyryyden integraalina [Hor83] [BW05]. Kolmiulotteisessa tapauksessa energia saa muodon

$$E(\vec{\gamma}) = \int c^2 ds = \int_0^1 \left(\frac{\|\vec{\gamma}'(t) \times \vec{\gamma}''(t)\|}{\|\vec{\gamma}'(t)\|^3} \right)^2 \|\vec{\gamma}'(t)\| dt \quad (62)$$

ja kaksiulotteisessa tapauksessa kun $\vec{\gamma}(t) = (x(t), y(t))$

$$E(\vec{\gamma}) = \int_0^1 \left(\frac{x'y'' - y'x''}{(x'^2 + y'^2)^{\frac{3}{2}}} \right)^2 \sqrt{x'^2 + y'^2} dt. \quad (63)$$

Kuvassa 18 on vertailtu erimuotoisten splinien energioita, jotka on laskettu mainituilla kaavoilla. Kuvista voi huomata, että enemmän kaartuvien käyrien energia on suurem-



Kuva 18: Vasemmanpuoleisen splinin energia on 0,0026 , keskimmäisen 0,0094 ja oikeanpuoleisen 0,084 .

pi kuin vähemmän kaartuvien. Käyrän energiaa tarkasteltaessa täytyy huomata, että käyrän pituus ei vaikuta energian suuruuteen.


4 Analyysimenetelmien testausta

Tässä osiossa esitellään edellisissä osioissa kehitellyn kuitujen tunnistamis- ja erottelumenetelmän tuloksia. Menetelmää sovelletaan ensin tietokoneella luotuihin keinotekoiisiin rakenteisiin, joiden ominaisuudet tunnetaan etukäteen. Tämän jälkeen menetelmää testataan myös todellisiin röntgentomografiakuviin, jotka on otettu puukuitukomposiittimateriaaleista.

4.1 Tietokoneella luodut rakenteet

Menetelmän testaamista varten tarvittiin binäärikuvia, joissa olevien kuitujen määrä ja muut ominaisuudet tunnetaan. Tällaisia keinotekoisia näytteitä luotiin tarkoitukseen kehitetyllä yksinkertaisella tietokoneohjelmalla. Ohjelma sijoittaa onttoja sylintereitä halutun kokoiseen kuvaan annettua orientaatiojakaumaa mukailleen. Sylinterien säde, pituus ja seinämäpaksuus ovat myös käyttäjän määrättävissä. Sylinterit voivat mennä päällekkäin ja leikata toisiaan, joten ohjelma pystyy luomaan kohtuullisen monimutkaisiakin kuiturakenteita.

Testausta varten luotiin kymmenen erilaista kuituverkostoa. Verkostot generoitiin siten, että vähiten kuituja sisältävässä verkostossa kuitumateriaalin prosentuaalinen osuus koko kuvan tilavuudesta oli noin 2 % ja eniten kuituja sisältävässä noin 30 %. Täältä väliltä otettiin viisi tilavuusosuuden arvoa ja kullakin näistä arvoista luotiin kaksi näytettä, joista toisessa kuidut olivat sattumanvaraisesti orientoituneita ja toisessa hyvin paljon orientoituneita näytteen syvyysakselin suuntaan. Tilavuusosuusalue 2 %–30 % valittiin siksi, että seuraavassa kappaleessa tutkittavissa todellisesta materiaalista otetuissa näytteissä kuitujen tilavuusosuus on noin 6 %. Testauspisteitä osuu siis todellisen kuitumäärän kummallekin puolelle. Testaus erilaisilla orientaatiojakaumilla on kiinnostavaa siksi, että orientaatiojakauma vaikuttaa voimakkaasti kuitujen risteämien määrään. Menetelmän epäluotettavin ja samalla tärkein kohta on juuri risteysalueiden tunnistaminen ja yhdistäminen, joten oletettavasti risteysalueiden määrä vaikuttaa voimakkaasti menetelmän luotettavuuteen. Lisäksi risteysalueiden tunnistamisen tarkkuuteen vaikuttaa myös risteävien kuitujen keskinäinen kulma. Suorassa kulmassa olevat kuidut on helpompi erottaa toisistaan kuin lähes samansuuntaiset kuidut, sillä suorassa kulmassa ole-



Kuva 19: Tietokoneella luodulle näytteelle suoritetun kuitutunnistuksen tulos. Jokainen tunnistettu kuitu on merkitty sattumanvaraisella värillä. Näytteissä on kuitukuvapisteitä noin 7,6% näytteen kuvapisteiden kokonaismäärästä. Ylemmässä kuvassa on näyte, jonka kuidut ovat suuntautuneet sattumanvaraisesti. Alemman kuvan näytteessä kuitujen suuntajakauma on keskittynyt yhteen suuntaan. Valkoiset nuolet osoittavat virheellisesti tunnistettuja risteysalueita. Erityisesti orientoituneessa näytteessä on suuria virheellisesti käsiteltyjä alueita. Tunnistusmenetelmän parametrit olivat $(A_s, \alpha_1, \delta, \alpha_2) = (200, 15^\circ, 200, 30^\circ)$.

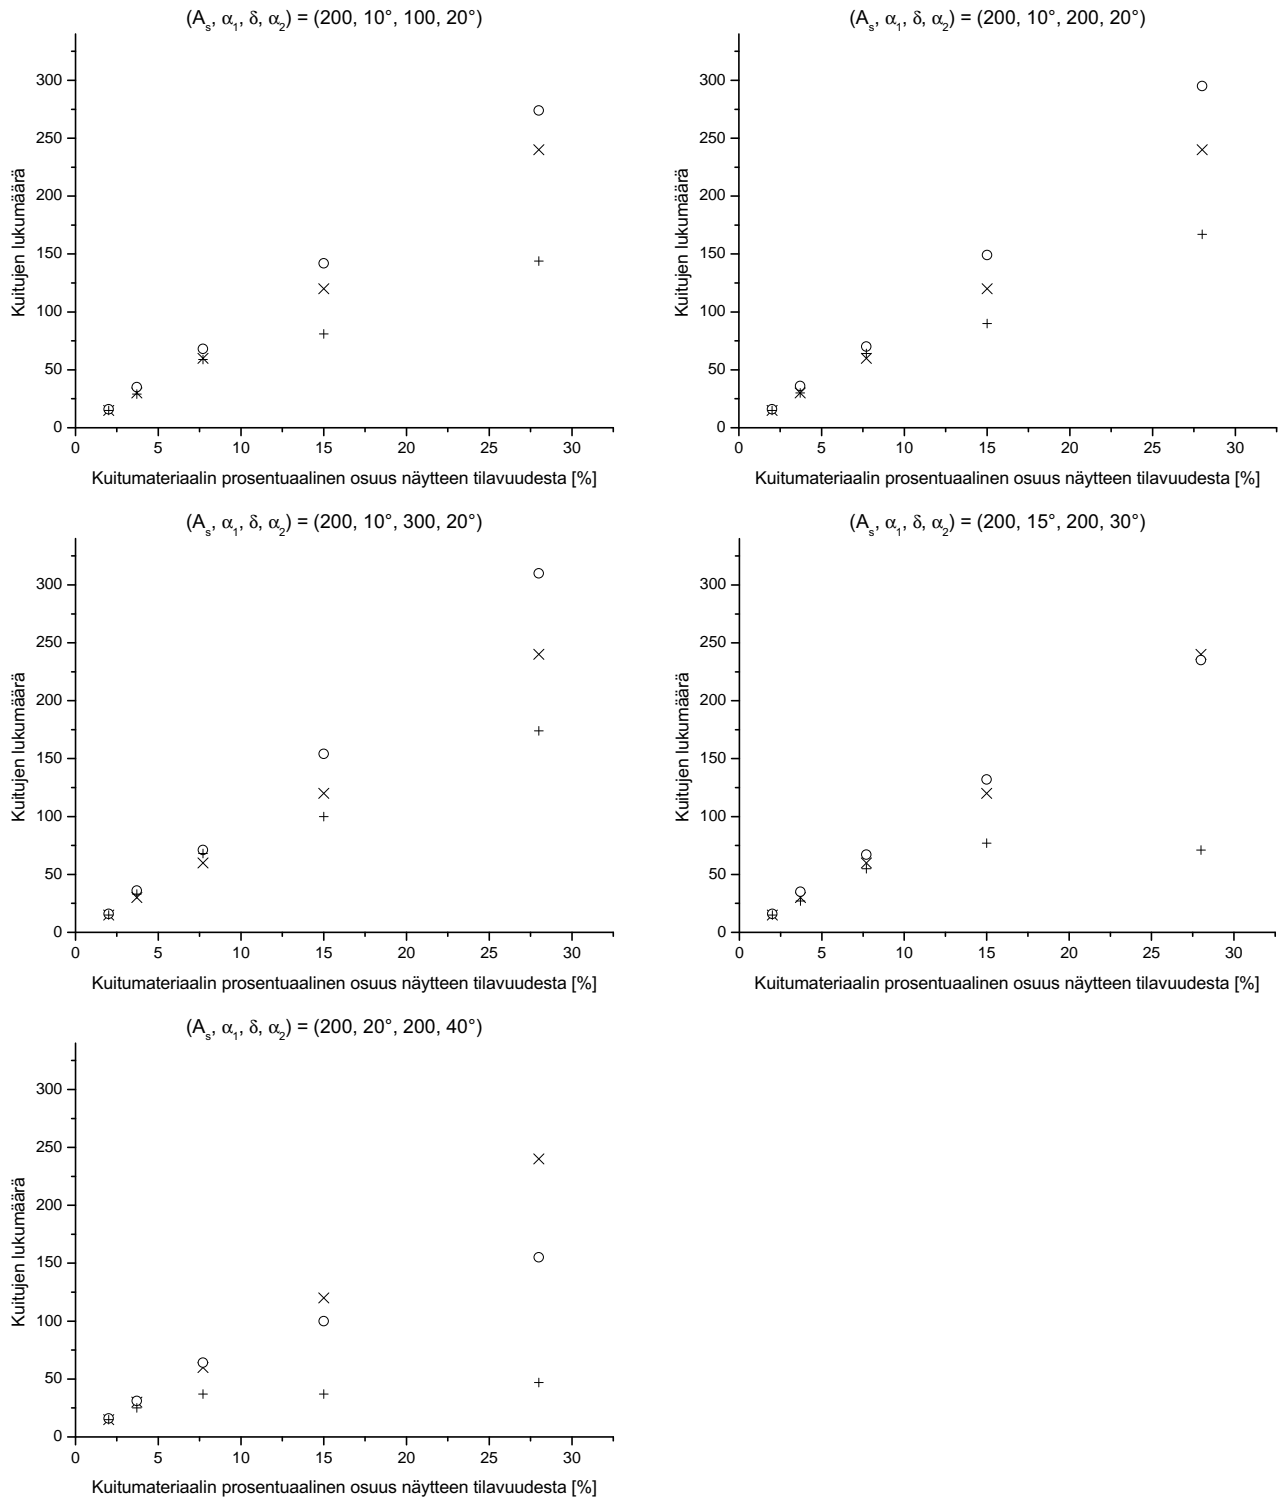
vien kuitujen risteysalueen koko on pienempi. Pienempi risteysalueen koko taas tarkoittaa todennäköisesti järkevämmin ja selkeämmin muodostunutta rankoa risteysalueen lähistöllä.

Kuvassa 19 on visualisoitu kuitutunnistuksen tulos sattumanvaraisesti suuntautuneelle näytteelle ja voimakkaasti orientoituneelle näytteelle, joissa kuituja on noin 7,6 % näytteen kuvapisteiden kokonaismäärästä.

Kuvaan 20 on piirretty kuitujen oikea määrä, sattumanvaraisesti orientoituneista näytteistä tunnistettu kuitujen määrä sekä yhteen suuntaan orientoituneista näytteistä tunnistettu kuitujen määrä kuitukuvapisteiden näytekuvasista varaaman prosentuaalisen tilavuuden funktiona. Tunnistus on suoritettu samoille näytteille moneen kertaan parametreja vaihdellen. Kuvasta nähdään hyvin se, että parametreista riippumatta samaan suuntaan orientoituneiden kuitujen tapauksessa tunnistusmenetelmän tarkkuus pienenee nopeasti käyttökelvottoman pieneksi kun kuitujen tilavuusosuus kasvaa yli kymmenen prosentin. Sattumanvaraisesti orientoituneiden kuitujen tapauksessa parametrien muuttaminen vaikuttaa tulosten oikeellisuuteen merkittävästi. Parametreilla $(A_s, \alpha_1, \delta, \alpha_2) = (200, 15^\circ, 200, 30^\circ)$ sattumanvaraisesti orientoituneista näytteistä tunnistettu kuitumäärä pysyy suhteellisen lähellä oikeaa kuitumäärää myös suurilla kuitupitoisuuksilla. Näitä parametrien arvoja käytetäänkin seuraavassa osiossa todellista puukuitukomposiittimateriaalia käsittelevässä testissä. Tunnistettujen kuitujen määrän käyttäytymisestä parametrien ja suhteellisen kuitutilavuuden funktiona voidaan tehdä se johtopäätös, että merkittävin menetelmän tarkkuuteen vaikuttava tekijä ei ole kuitujen risteysten määrä vaan keskimääräinen risteämiskulma. Sattumanvaraisesti orientoituneissa näytteissä keskimääräisen risteämiskulman täytyy olla merkittävästi suurempi kuin lähes yhteen suuntaan orientoituneissa näytteissä.

4.2 Todellinen komposiittimateriaali

Menetelmää testattiin tietokoneella luotujen rakenteiden lisäksi todellisesta puukuitukomposiittimateriaalista otettuihin röntgentomografiakuviin.



Kuva 20: Tunnistettujen kuitujen lukumäärä kuitutilavuuden funktiona. Rasti (×) merkitsee näytteissä olevien kuitujen lukumäärää. Pallo (○) merkitsee tunnistettujen kuitujen lukumäärää kun näytteen kuidut ovat sattumanvaraisesti suuntautuneita. Plusmerkki (+) merkitsee tunnistettujen kuitujen lukumäärää kun näytteen kuidut ovat orientoituneet lähes yhteen suuntaan. Käytetyt parametrit on ilmoitettu kunkin kuvan yläpuolella.

Ennen kuitujen tunnistamista kuvat piti tietenkin binärisoida. Tässä tapauksessa binärisoinnin tarkkuus ei ole kriittinen tekijä sillä tarkoituksena on vain testata menetelmän toimivuutta eikä tutkia materiaalin ominaisuuksia. Epätarkasti esikäsitellyssä kuvassa voi olla häiriöitä tai esimerkiksi kuitujen reunat voivat olla epämääräisiä. Tämä ei kuitenkaan haittaa sillä mikäli testattava menetelmä osoittautuu toimivaksi tällaisella kuvalla, se toimii myös tarkasti esikäsitellyllä kuvalla.


Binärisointiprosessi oli hyvin yksinkertainen: ensin kuvat suodatettiin mediaanisuodatimella jonka ikkunan koko oli $5 \times 5 \times 5$ kuvapistettä. Tämän jälkeen kuva kynnystettiin sopivalla kynnysarvolla, jonka jälkeen kuva olikin jo binäärimuodossa. Todellisessa tapauksessa kuituanalyysin tulosten todenperäisyyden varmistamiseksi kynnystykseen ja binärisointiin olisi syytä käyttää kehittyneempiä menetelmiä, joita on esitelty esimerkiksi lähteessä [Ant02].

Binärisoinnin jälkeen testikuville suoritettiin kuitujen erottelu. Kuvassa 21 on esitetty visualisointeja tunnistuksen tuloksista. Näissä kuvissa jokainen erilliseksi tunnistettu kuitu on merkitty eri värillä. Suuret, laakeat alueet ovat materiaalissa olevien ilmakuplien pinnoista ja näytteen pintakerroksista muodostuneita rakenteita.

Menetelmä tunnistaa suuren osan kuiduista oikein mutta tekee silti virheitä joissakin hankalissa tapauksissa. Esimerkiksi kuvassa 21 esitetyn näytteen kuidut ovat voimakkaasti orientoituneita, joten kuitujen leikkauskulmat ovat pieniä. Tämä huonontaa tunnistuksen tulosta samoin kuin kappaleessa 4.1 tietokoneella luotujen rakenteiden tapauksessa. Huonontuminen näkyy kuitukimppuina, joissa monta erillistä kuitua on merkitty yhdeksi kuiduksi.

4.3 Parannusehdotuksia

Edeltävissä kappaleissa suoritettu analyysi paljasti joitakin tunnistusmenetelmän heikkoja kohtia. Erityisesti menetelmän toimivuuden liiallinen riippuvuus kuitujen orientaatiojakaumasta on ongelma käsiteltäessä todellisia materiaaleja. Orientaatiojakaumarippuvuus haittaa esimerkiksi eri tavoin muodostettujen näytteiden tutkimista, sillä valmistusmenetelmä vaikuttaa voimakkaasti kuitujen orientaatiojakaumaan. Esimerkik-



Kuva 21: Komposiittimateriaalista otetusta röntgentomografiakuvasta tunnistettuja kuituja. Jokainen erilliseksi tunnistettu kuitu on merkitty sattumanvaraisella värillä. Tunnistusmenetelmän parametrit on valittu samoin kuin kuvan 12 tapauksessa.

si suulakepuristusta vastaavalla menetelmällä valmistettujen materiaalien kuidut ovat voimakkaasti orientoituneet puristussuuntaan kun taas valettujen materiaalien kuidut ovat monesti lähes sattumanvaraisesti orientoituneita. Tässä kappaleessa esitellään parannusehdotuksia löytyneisiin epäkohtiin keskittyen erityisesti orientaatiojakaumariippuvuuden poistamiseen.

Menetelmän epäkohdat keskittyvät osiin pilkottujen kuitujen yhdistämisen ympärille. Virheet syntyvät siitä, että joko väärään paikkaan syntynyt kuitujen leikkaus jää poistamatta ja kuitu yhdistämättä, tai siitä, että oikea kuitujen leikkaus poistetaan. Ensiksi mainittu tapaus luo katkenneita kuituja ja jälkimmäinen kuitukimppuja, jotka muodostuvat monesta, todellisuudessa erillisestä, kuidusta. Kuitukimput vääristävät jatkoanalyysin tuloksia merkittävämmiin kuin katkenneet kuidut. Yleensä kuituanalyysin tuloksista muodostetaan jakaumia eri suureista ja niistä tilastollisia tunnuslukuja, joten monesti ei ole väliä, analysoidaanko jokin kuitu yhdessä vai useammassa osassa. Monen yksittäisen kuidun yhdistäminen luo kuitenkin kuituverkostolle geometrisia ominaisuuksia, joita oikeassa materiaalissa ei ole.

Ensimmäiseksi kannattanee tarkastella sitä, mistä väärät risteysalueet saavat alkunsa. Perimmäinen syy on rangon laskentaan käytettävissä algoritmissa. Tässä työssä käytettiin levypohjaista rankoa, joka soveltuu hyvin putkien ja levyjen topologian kuvaamiseen. Sauvojen kuvaamiseen sopisi paremmin viivapohjainen ranko, mutta se ei taas toimi ollenkaan putkimaisia ja levymäisiä rakenteita sisältäville geometrioille. Paras tapa olisi laskea kuvan jokaiselle objektipisteelle tunnusluku, joka kertoo kuinka “putkimainen” tai “levymäinen” kyseisen pisteen ympäristö on. Lasketun arvon perusteella voitaisiin valita sovelletaanko kyseiseen ympäristöön viiva- vai levypohjaista rankoalgoritmia. [Auf06] Tällä tavoin saataisiin luultavasti hieman vähennettyä väärrien risteysalueiden määrää syntyvässä hybridirangossa. Menetelmän huono puoli on se, että se selvästikin lisää kuitujen tunnistamiseen tarvittavaa laskentaa.

Alueiden yhdistämisalgoritmi on tällä hetkellä hieman liian yksinkertainen. Pilkkoutuneiden kuitujen yhdistämisiongelmaa kannattaisi lähestyä verkkoajattelun pohjalta. Tunnistettu kuitujärjestelmä on verkosto, jossa jokainen kuitu muodostaa solmun ja jokainen risteysalue yhteyden solmujen välille. Tätä verkostoa on nyt tarkoitus optimoida niin, että väärät yhteydet poistetaan ja samaa kuitua kuvaavat solmut yhdistetään. Verkoston solmuihin voi varastoida solmua vastaavan kuidunpalan sopivien tunnuslukujen

arvoja, joiden perusteella yhdistäminen ja katkominen tehdään. Näin menetellen varsinainen kuvadata käydään läpi vain muutaman kerran jolloin prosessointi nopeutuu. Tässä työssä esitellyssä versiossa tarkastellaan vain yhtä risteysaluetta kerrallaan, joten menetelmä pystyy tekemään vain lokaalisti optimaalisia yhdistämis- ja erottamispäätöksiä. Verkkopohjainen lähestymistapa ohjaa risteysaluekeskeistä algoritmia kuitukeseen suuntaan, jolloin yhdistämis- ja erottamispäätökset pystytään tekemään askeleen verran globaalimmalla tasolla. Tämänhetkisessä versiossahan on hyvin mahdollista, että vaikka kaikki risteysalueet yhdistetään lokaalisti “oikein”, lopputulos on se, että koko kuitua tarkasteltaessa jotkin risteysalueet on yhdistetty väärin.

Kappaleessa 4.1 huomattiin että kuitujen risteämiskulmalla on suuri vaikutus yhdistämisprosessin tuloksen oikeellisuuteen. Jatkossa onkin siis syytä pyrkiä käyttämään yhdistämisalgoritmeja, jotka riippuvat yhdistämiskulmasta mahdollisimman vähän. Käytännössä kahden kuidun yhdistäminen täytyy olla sitä “kalliimpi” operaatio mitä yhden suuntaisempia ko. kuidunpalat ovat. Esimerkiksi tämänhetkisessä menetelmässä käytetty risteysalueen suurehkoon kokoon perustuva kuidun osien yhdistäminen täytyy muuttaa muotoon, jossa “suuri koko” määritellään kiinteän arvon sijaan kuitujen risteämiskulman funktiona niin, että samansuuntaisille kuiduille saadaan suuri arvo ja erisuuntaisille pienempi arvo.

Kappaleessa 3.3.3 esiteltyä alueiden yhdistämismenetelmää voidaan myös parannella. Tällä hetkellä sen yhdellä iteraatiolla laajennetaan jokaista yhdistettävää aluetta yhden kuvapisteen verran kaikkiin suuntiin, kunhan vain pysytään risteysalueella. Tästä johtuen risteysalueet eivät välttämättä jakaudu tasan kaikkien risteystä koskettavien alueiden kesken. Vaikka virhe on pieni, lopputulosta olisi mahdollista parantaa marginaalisesti käyttämällä yksinkertaisiin pisteisiin perustuvaa laajennusalgoritmia: lisätään yhdistettäviin alueisiin vain ne pisteet, jotka ovat kappaleessa 3.3.1 esitellyssä mielessä yksinkertaisia. Näin alueiden pitäisi ainakin periaatteessa laajentua tasaisemmin suhteessa toisiinsa.

Kuitujen yhdistelemissä tehtävien virheiden jälkeen seuraavaksi suurin virhe tehdään kuitenkin regeneroitaessa alkuperäistä kuituverkostoa sen rangosta. Käytettävä algoritmi on sama kuin risteysalueiden yhdistelyssä, joten prosessissa tehdään samankaltainen virhe kuin risteysalueiden yhdistelyssä. Tässä tapauksessa virhe on huomattavasti näkyvämpi. Virheen voi ainakin osittain korjata samalla tavalla kuin risteysalueiden

yhdistämisen tapauksessa tai käyttäen rankomuunnoksen palautuvuutta. Alkuperäisen datajoukon voi nimittäin regeneroida mikäli sen ranko ja rangon muodostanut etäisyysmuunnos tunnetaan [Str04]. Tässä lähestymistavassa on kuitenkin eräs ongelma. Kun regeneroidaan kahta toisiaan koskettavaa kuitua joilla on eri seinämäpaksuus, seinämälääntään ohuempi kuitu “syö” hieman paksumman kuidun seinämää. Näin tapahtuu, sillä ohutseinäisemmän kuidun seinämän laajentaminen valmistuu ennen paksuseinäisen kuidun seinämän laajentamista. Algoritmi näkee kuitenkin vapaata tilaa ohutseinäisen ja paksuseinäisen kuidun kosketuskohdassa ja laajentaa sekä ohutseinäistä että paksuseinäistä kuitua tyhjää tilaa kohti yhtä paljon. Tällöin ohutseinäisen kuidun seinämä pullistuu paksuseinäisen kuidun seinämän sisään. Tämä efekti voitaneen välttää muuttamalla seinämien paksuntamisnopeutta suhteessa alkuperäiseen seinämäpaksuuteen niin, että kaikki seinämät valmistuvat yhtä aikaa. Toinen vaihtoehto on estää seinämien paksuntaminen yli ko. kuidun alkuperäisen maksimiseinäämäpaksuuden. Jälkimmäisessä vaihtoehdossa ongelmaksi muodostuu sellaisten kuitujen regenerointi, joiden seinämäpaksuus vaihtelee paljon. Paras tapa lienee siis moduloida paksunnusnopeutta alkuperäisen kuvan lokaalilla paksuudella. Huonona puolena tässä menetelmässä on se, että lokaalin paksuuden määrittäminen on laskennallisesti kohtuullisen raskasta.

Kuidun keskiakselin määrittämistä varten metamallinnusmenetelmät ovat tutustumisen arvoisia, sillä niiden pitäisi olla laskennallisesti kevyitä mutta silti tarkkoja ja stabiileja [Kno08] [Bar94]. Tässä työssä esitellyssä splinisovitusversiossa pääasiallinen ongelma onkin sovituksen hitaus ja epästabiilisuus joissakin tapauksissa. Yhden näytteen analysoimiseksi splinisovituksia täytyy tehdä yhtä monta kuin näytteessä on kuituja, eli käytännössä tuhansia, joten yhden sovituksen laskemiseen ei saisi mennä liikaa aikaa jotta järjestelmä pysyy käyttökelpoisena.

Eräs mielenkiintoinen mahdollisuus tulosten parantamiseksi on binärisoidun kuitudatan rangon tutkimisen sijaan muodostaa jonkinlainen sumea jäsenyysfunktio, joka kertoo, millä todennäköisyydellä tietty kuvapiste kuuluu kuituun. Esitystä voi tarkentaa muuntamalla tilanne muotoon, jossa jokaiselle kuidulle muodostetaan oma funktio, joka kertoo, millä todennäköisyydellä kuvapiste kuuluu ko. kuituun ja millä ei. Jos tällaiset funktiot voitaisiin muodostaa, datan käsittely voisi, helpottua sillä alkukynnystysvaihe jäisi kokonaan pois ja kynnystys suoritettaisiin vasta kuitujen tunnistamisen jälkeen. Tällaisen järjestelmän rakentaminen vaatii kuitenkin täysin erilaiset algoritmit kuin mitä tässä työssä on esitelty.

Toisistaan eroteltuja kuituja analysoitaessa täytyy muistaa jatkuvan datan diskreetoinnista johtuvat häiriöt saaduissa tuloksissa. Esimerkiksi Yang [Yan00] tekee rangon avulla mittaamalleen kuitujen pituusjakaumalle tilastollisen korjauksen käyttäen tietokoneella luodusta kuitudatasta saatua korjausjakaumaa. Ilman tilastollista korjausta tuloksena saadun jakauman maksimivirhe olisi noin 30 %.

5 Johtopäätökset

Tässä työssä kehitettiin menetelmä kuitujen tunnistamiseksi kolmiulotteisista kuvista. Kuitujen tunnistaminen sisälsi kuitumassan ja -verkoston tunnistamisen lisäksi kuituverkoston jakamisen yksittäisiin kuituihin. Lisäksi esiteltiin menetelmiä yksittäisten kuitujen analysointiin ja testattiin kehitettyä menetelmää tietokoneella luotuihin näytteisiin sekä oikeaan, puukuitukomposiittimateriaalista otettuun röntgentomografiakuvaan. Lopuksi esitettiin parannus- ja jatkokehitysehdotuksia.

Ennen kehitystyön aloittamista menetelmälle asetettiin joitakin vaatimuksia, joita olivat automaattisuus, nopeus, kolmiulotteisuus ja tarkkuus, ks. kappale 1. Näistä vaatimuksista menetelmä toteuttaa hyvin kaksi ensimmäistä, mutta tarkkuuden ja kolmiulotteisuuden suhteen jää hieman toivomisen varaa. Erityisesti menetelmän antamien tulosten riippuvuus tutkittavan materiaalin rakenteen orientaatiojakaumasta on seikka, jonka korjaaminen vaatii jatkotutkimuksia. Kappaleessa 4.3 ehdotetut parannukset kuitenkin korjannevat menetelmän tarkkuutta ja nopeuttavat menetelmän käyttöä.

Kolmiulotteiseen pintarankoon perustuvana tässä työssä esitelty menetelmä on aidosti kolmiulotteinen ja sen tulokset ovat rotaatioinvariantteja. Lisäksi esitelty menetelmä on täysin automaattinen eikä vaadi minkäänlaista interaktiota käyttäjän kanssa, joten se soveltuu myös suurien datamäärien prosessointiin.

Kokonaisuudessaan kehitetty menetelmä tässä työssä esiteltyssä muodossaan kelpaa yksinkertaisten kuituverkostojen kuitujen erotteluun toisistaan. Menetelmä toimii luotettavimmin, mikäli verkosto ei ole liian tiheä, eli kuitujen osuus tutkittavasta tilavuudesta on alle 10%. Tulosten luotettavuus paranee, mikäli verkoston kuidut ovat mahdollisimman sattumanvaraisesti orientoituneita. Kuitujen muoto, halkeamat tai muut deformaatiot eivät kuitenkaan vaikuta menetelmän toimivuuteen paljoakaan.

Viitteet

- [Ada94] Adams, R. ja Bischof, L. Seeded region growing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16(6):641–648, 1994.
- [Ant02] Antoine, C., Nygård, P., Gregersen, Ø. W., Holmstad, R., Weitkamp, T. ja Rau, C. 3D images of paper obtained by phase-contrast X-ray microtomography: image quality and binarisation. *Nuclear Instruments and Methods in Physics Research A*, 490:392–402, 2002.
- [Aro02] Aronsson, M. *On 3D fibre measurements of digitized paper – from microscopy to fibre network*. Väitöskirja, Centre for Image Analysis, Swedish University of Agricultural Sciences, Ruotsi, 2002.
- [Auf06] Aufort, G., Jennane, R., Harba, R. ja Benhamou, C. L. Hybrid skeleton graph analysis of disordered porous media. Application to trabecular bone. *Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing 2006*, osa 2, 781–784, 2006.
- [Axe07] Axelsson, M. 3D tracking of cellulose fibres in volume images. *Proceedings of IEEE International Conference on Image Processing*, 2007.
- [Bar94] Barton, R. R. Metamodeling: A state of the art review. *Proceedings of the 1994 Winter Simulation Conference*, 237–244, 1994.
- [Blu67] Blum, H. A transformation for extracting new descriptors of shape. *Models for the Perception of Speech and Visual Form*, 362–380. MIT Press, 1967.
- [Bon01] Bonnassie, A., Peyrin, F. ja Attali, D. Shape description of three-dimensional images based on medial axis. *Proceedings of International Conference on Image Processing*, 2001.
- [Boo78] de Boor, C. *A Practical Guide to Splines*. Springer-Verlag, 1978.
- [BW04] Bache-Wiig, J. ja Henden, P. C. Measurements on microtomographic images of fibrous structures. Tekninen raportti, Department of Computer and Information Science, Norwegian University of Science and Technology, 2004.

- [BW05] Bache-Wiig, J. ja Henden, P. C. *Individual fiber segmentation of three-dimensional microtomograms of paper and fiber-reinforced composite materials*. Pro gradu, Department of Computer and Information Science, Norwegian University of Science and Technology, Norja, 2005.
- [Cho03] Choi, W.-P., Lam, K.-M. ja Siu, W.-C. Extraction of the Euclidean skeleton based on a connectivity criterion. *Pattern Recognition*, 36(3), 2003.
- [Den94] Deng, M. ja Dodson, C. T. J. *Paper – An engineered stochastic structure*. TAPPI Press, 1994. ISBN 0-89852-238-8.
- [Fit99] Fitzgibbon, A., Pilu, M. ja Fisher, R. B. Direct least square fitting of ellipses. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21(5):476–480, 1999.
- [Gon90] Gong, W. X. ja Bertrand, G. A simple parallel 3D thinning algorithm. *Proceedings of 10th International Conference on Pattern Recognition*, osa 1, 188–190, 1990.
- [Gon02] Gonzalez ja Woods. *Digital image processing, 2nd edition*. Prentice Hall, 2002.
- [Hof98] Hoffmann, M. ja Kovács, E. Interpolation possibilities using rational B-spline curve. *Acta Academiae Paedagogicae Agriensis, Sectio Mathematicae*, 25, 1998.
- [Hol04] Holen, R. ja Hagen, M. *Segmentation of absorption mode X-ray microtomographic images of paper*. Pro gradu, Norwegian University of Science and Technology, Norja, 2004.
- [Hor83] Horn, B. K. P. *The curve of least energy*. Tekninen raportti, Massachusetts Institute of Technology, USA, 1983.
- [Kle04] Klette, G. ja Pan, M. 3D topological thinning by identifying non-simple voxels. *Lecture Notes in Computer Science*, 3322/2005:164–175, 2004.
- [Kno08] Knowles, J. ja Nakayama, H. Meta-Modeling in multiobjective optimization. *Multiobjective Optimization*, osa 5252, 245–284. Springer Berlin/Heidelberg, 2008.
- [Kre91] Kreyszig, E. *Differential Geometry*. Dover Publications, 1991.

- [Lor87] Lorensen, W. E. ja Cline, H. Marching Cubes: A high resolution 3D surface construction algorithm. *Computer Graphics*, 21(4), 1987.
- [Lun02] Lunden, J. *Image analysis methods for evaluation of fibre dimensions in paper cross-sections*. Pro gradu, The Swedish Royal Institute of Technology, Ruotsi, 2002.
- [Mud] Mudrová, M. ja Procházka, A. Principal component analysis in image processing.
- [Muk91] Mukundan, R. A numerical approximation of two dimensional image moments. *Indian Journal of Pure and Applied Mathematics*, 22(10):879–886, 1991.
- [Pre02] Press, W. H. *Numerical recipes in C++: the art of scientific computing*. Cambridge University Press, 2002.
- [Rag92] Ragnemalm, I. The Euclidean distance transform in arbitrary dimensions. *Proceedings of the International Conference on Image Processing and its Applications 1992*, 290–293, 1992.
- [Ros68] Rosenfeld, A. ja Pfaltz, J. L. Distance functions on digital pictures. *Pattern Recognition*, 1(1):33–61, 1968.
- [Sam01] Sampson, W. The structural characterisation of fibre networks in papermaking processes – a review. *Proceedings of the science of papermaking, 12th Fundamental Research Symposium*, 1205–1288, 2001.
- [Str04] Strand, R. Surface skeletons in grids with non-cubic voxels. *Proceedings of the 17th International Conference on Pattern Recognition 2004*, osa 1, 548–551, 2004.
- [Tiz02] Tizon, X. ja Smedby, Ö. Segmentation with gray-scale connectedness can separate arteries and veins in MRA. *Journal of Magnetic Resonance Imaging*, 15:438–445, 2002.
- [Wik09] Wikipedia. Composite material — Wikipedia, the free encyclopedia, 2009. [Online; haettu 7.1.2009].
- [Xu93] Xu, B., Pourdeyhimi, B. ja Sobus, J. Fiber cross-sectional shape analysis using image processing techniques. *Textile Research Journal*, 63(12):717–730, 1993.

- [Yan00] Yang, H. ja Lindquist, B. W. Three-dimensional image analysis of fibrous materials. *Proceedings of Society of Photo-Optical Instrumentation Engineers (SPIE)*, osa 4115, 275–282, 2000.
- [Ye88] Ye, Q.-Z. The signed Euclidean distance transform and its applications. *Proceedings of the 9th International Conference on Pattern Recognition 1988*, osa 1, 495–499, 1988.
- [Yim00] Yim, P. J., Choyke, P. L. ja Summers, R. M. Gray-scale skeletonization of small vessels in magnetic resonance angiography. *IEEE Transactions on Medical Imaging*, 19(6):568–576, 2000.