

**Rautaniemi Perttu**

# **Peittymisongelma konenäön kontekstissa**

Tietotekniikan kandidaatintutkielma

29. joulukuuta 2019

Jyväskylän yliopisto

Tietotekniikka

**Tekijä:** Rautaniemi Perttu

**Yhteystiedot:** pemamira@student.jyu.fi

**Työn nimi:** Peittymisongelma konenäön kontekstissa

**Title in English:** Occlusion problem in the field of Machine Vision

**Työ:** Kandidaatintutkielma

**Sivumäärä:** 17+0

**Tiivistelmä:** Konenäön hyödyntämisessä esiin tuleva peittymisongelma esiintyy hyvin monella eri koneellisen näön sovellusalueella ja sitä on ratkaistu onnistuneesti erinäköisillä algoritmeilla. Ratkaisujen keskiössä ovat erilaiset konenäön menetelmät ja niiden onnistunut yhdistely

**Avainsanat:** konenäkö, tilastotieteelliset menetelmät, osittainen peittyminen

**Abstract:** The problem of partial and total occlusion effects many different fields of machine vision implementation, and it has been effectively been solved using different algorithms. Core parts in the solving of this problem are different types of machine vision processors and the successful combining of them

**Keywords:** machine vision, statistical methods, partial occlusion

## **Kuviot**

Kuvio 1. Päättösmetsät periytyvät päätöspuista .....	3
Kuvio 2. Karttojen muodostumishierarkia käytännössä ja havainnollistettuna (Felzen- szwalb ym. 2013) .....	4

# Sisältö

1	JOHDANTO .....	1
2	KONENÄÖN OHJELMALLISIA MENETELMIÄ .....	3
2.1	Muovattavien osien mallit .....	4
2.2	Syvät verkot .....	5
2.3	Päätöspuut .....	5
2.4	Päätösmetsät .....	6
2.5	Tukivektorikone .....	6
3	PEITTYMISEN ONGELMA .....	7
3.1	Tekniset ratkaisut .....	7
3.1.1	Video .....	8
3.1.2	Useampi kamera .....	8
3.2	Kuvankäsittely ja algoritmit .....	8
3.2.1	Neuroverkot .....	9
4	YHTEENVETO.....	10
	LÄHTEET .....	11

# 1 Johdanto

Tutkimusaiheena on objektien, pääasiassa kompleksisten objektien kuten ihmisten tunnistaminen konenäön menetelmillä ja tässä prosessissa tapahtuva ongelma, peittyminen. Toisinsanoen kyseessä on tilanne jossa jokin asia kuvassa peittää tunnistettavan objektin. Tämä tapahtuu joko kokonaisuudessaan, jolloin terminä käytetään täyttä peittymistä (engl. *total occlusion*) tai vain osittain, jolloin tapausta kutsutaan nimellä osittainen peittyminen (engl. *partial occlusion*). Osittainen peittymä on enemmän huomion keskipisteenä, sillä useimmat täydellisen peittymän tilanteet ovat sellaisia joissa informaatio tunnistettavan objektin olemassaolosta ei ole saavutettavissa yksittäisestä kuvasta millään tavalla. Kyseisen tilanteen ratkaisujakin on listattu monia, mutta niiden luonne on useasti erityyppinen ja ne menevät monesti aika-akselin konvoluution kautta esimerkiksi aikasarja-analyysillä.

Peittymisongelman ratkaiseminen on hyödyksi muun muassa, koska valvontakameroiden käytön jatkuvasti lisääntyessä niistä saatavan datan määrä kasvaa ja tätä voitaisiin hyödyntää huomattavasti tehokkaammin kuin nyt. Esimerkiksi koska kysyntää on erilaisille tavoille laskea sekä tilastoida tilojen täyttöastetta, tai seurata rikollisten liikkeitä ennen ja jälkeen jonkin rikoksen. Konenäön käytössä useampien tai vaikeasti havaittavien objektien, erityisesti ihmisten, autojen ja eläinten, löytämiseen kuvista löytyy myös paljon hyödyllisiä käyttökohteita liikennekäytössä, yhtenä selvänä käyttökohteena autojen parkkikamerat ja tulevaisuudessa itseohjautuvien autojen törmäyksenesto ja muut protokollat. Tällaisissa käyttökohteissa yhdeksi ongelmaksi voi tulla myös kameran osittainen tai kokonainen peittyminen esimerkiksi lumella. Tämänäyttötyyppisessä tilanteessa on useasti ratkaisuna hyvin nopea kuljettajan informointi ja automaattiohjauksen poistaminen, sekä tätä seuraava ihmisen toimesta tapahtuva peitteen poistaminen informaation saamiseksi takaisin automaatile. Pienempiä peittymisiä tulee tapahtumaan varmasti kun tien varrella on puskia, liikennemerkkejä ynnä muita vastaavia, joiden takana voi olla hirvi osittain piilossa, mutta tarkkaavaisen ihmisilmän selvästi nähdessä tuon eläimen aikovan auton eteen. Myös sota- ja tiedusteluteollisuus, sekä rikolliset löytävät käyttötapoja tämänäyttötyyppiselle teknologialle erittäin paljon. Yksi esimerkki on kasvavasta sosiaalisen median kuva- ja henkilötietotietokannasta kullekin taholle mielenkiintoisten henkilöiden louhiminen esiin esimerkiksi epävirallisista juhlati-

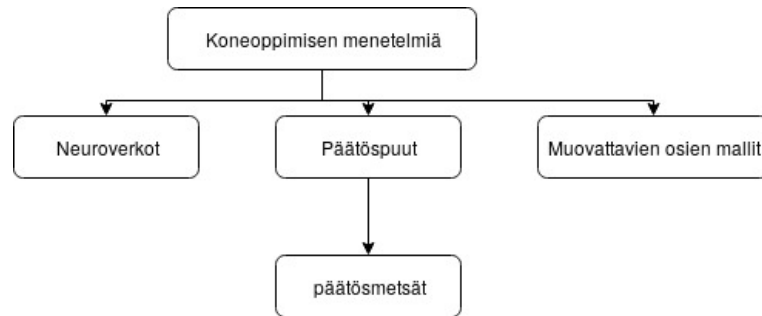
lanteista otetuista kuvista, joissa saattaa olla jopa yritetty piilotella tunnistettavissa olevia merkkejä henkilöllisyydestä, tai vain esimerkiksi joku toinen on vahingossa peittänyt kyseisen henkilön osittain, koska kuvaus ei ole ollut virallinen. Peittymisongelman kiertävien algoritmien tehostaminen on myös siksi erittäin tarpeellista, että ihmisillä on taipumus luottaa koneiden tekemiin päätelmiin virheettöminä laskuina, jonka takia moniin tilastotieteellisiin menetelmiin ja siten todennäköisyyksiin perustuvien menetelmien virhetapaukset ovat jopa vaarallisia ihmisten luottaessa niihin sokeasti ja samalla tehden jonkin merkittävän lopullisen päätöksen. Luonnollisesti sellaisen tapauksen mahdollisuus peräänkuuluttaa tunnistusmenetelmien avoimuutta, jotta voidaan todeta mikä asia aiheutti väärän päätelmän.

Tutkimus on suoritettu kirjallisuuskatsauksena ja artikkelien keräämiseksi on käytetty lumipallomenetelmää (engl. *snowballing*, joka on erittäin sopiva tapauksessa, jossa on paljon avattavia termejä ja konsepteja itse asiaan liittyen.

Alussa käsitellään hieman erilaisia menetelmiä ja termejä jotta teknologinen viitekehys aukeaa paremmin, Tämän jälkeen pureudutaan itse ongelman syihin ja merkityksiin, ja lopuksi käydään läpi lyhyesti muutamia erilaisia tapoja ratkaista kyseinen tilanne.

## 2 Konenäön ohjelmallisia menetelmiä

Konenäköalgoritmit ovat jaettavissa kolmeen erilaiseen ratkaisuperheeseen kuten kuviossa 1: muovattavien osien malli (engl. *deformable parts model*), syvät verkot, sekä päätösmetsät tai tuetut päätöspuut (Benenson ym. 2014). Erikseen on vielä mainittava, että useasti




Kuvio 1. Päättösmetsät periytyvät päätöspuista

näiden lisäksi käytetään perinteisiä kuvankäsittelymenetelmiä, esimerkiksi kynnystysefekti (engl. *image thresholding effect*). Näitä metodeja käytetään useasti kuvien jakamiseen palasiksi, tiettyjen alueiden korostamiseen sekä lopullisen tuloksen merkitsemiseen jos sellainen näytetään käyttäjälle jossain. Useat näistä menetelmistä ovat monimutkaisia ihan omassa kunniansa, mutta näiden päälle rakennetaan erityisesti konenäön tarpeelliset päätösrakennelmat. Jotta automaatio voi tietää onko kuvassa toivottu objekti, täytyy sitä erilaisilla keinoin korostaa. Sama pätee luonnolliseenkin näkemisprosessiin. On huomattavasti helpompi erottaa mustalla tussilla korostettu kohde kuvasta, kuin ilman tussausta jätetty.

Lisäksi konenäköalgoritmit ovat jaettavissa karkeasti myös kahteen erilaiseen luokkaan syvimmän tilastollisen olemuksensa pohjalta, mallipohjaiseen (engl. *model-based*), sekä piirreluokittelijapohjaiseen (engl. *feature classifier-based*). Nämä vastaavat taas vahvasti laajemmassa käsitteistössä olevia *generative model*, sekä *discriminative model* termejä, käytännössä tällä tarkoitetaan yhteisjakaumaa sekä ehdollista jakaumaa. Seuraavista esimerkiksi tukivektorikoneet kuuluvat ehdollisen jakauman malleihin ja päätöspuut taas yhteisjakumiin. Diskriminoivia malleja on ilmeisesti pidetty parempina generoivien mallien sijasta, ja kahden puhtaan tällaisen ratkaisun paremmuutta ovat tutkineet (Ng ja Jordan 2002).

## 2.1 Muovattavien osien mallit

Muovattavien osien mallit (engl. *Deformable Parts Model*) on periaatteeltaan aika yksinkertainen tapa tunnistaa objekteja. Felzenszwalb ym. (2013) kertoo, että se perustuu objektien tietyn muotoisuudelle ja sille että nuo objektit koostuvat pienemmistä osista, jotka ovat useimiten tietynlaisessa asennossa toisiinsa. Esimerkkinä toimii perinteinen kasvontunnistus. Kasvot ovat tässä objekti jota etsitään kuvasta. Tiedämme että kasvot koostuvat kahdesta silmästä, nenästä ja suusta, joille jokaiselle on oma tunnistimensa. Muovattavien osien malli on täten monikerroksinen ratkaisutapa, kuten useat muutkin monimutkaisempien objektien tunnistajat. Kun kuvasta on vedetty jokainen noista osien tunnistimista läpi ja on saatu kartta niiden todennäköisyyksistä, vedetään tämän kartan päälle tunnistus jossa etsitään sopivissa asennoissa olevia osien konfiguraatioita. Kasvoissa tämä tarkistaisi esimerkiksi sen että nenä on silmien ja suun välissä. Tämä periaate näkyy kuvassa 2. Tai koko ihmistä etsiessä tunnistaja tarkistaisi että kädet ovat keskiruumiin molemmilla puolilla, jalat sen alla, sekä pää päinvastaisella puolella keskiruumista kuin jalat. Jotta tunnistaja toimisi oikein, pitää sen osata tunnistaa myös jos ihminen on väärinpäin kuvassa, esimerkiksi seisomassa päällään voimistellessaan.



Kuvio 2. Karttojen muodostumishierarkia käytännössä ja havainnollistettuna (Felzenszwalb ym. 2013)



## 2.2 Syvät verkot

Syvät verkot, tarkemmin konvoluutioneuroverkot ovat korkean abstraktiotason koneoppimista, jossa tärkeimpänä komponenttina on data jolla tuo verkko opetetaan. Käytännössä neuroverkon muodostama malli on matemaattisesti logistinen regressio (Skansi 2018, s. 121). Meidän kontekstissamme tämä olisi vähintään satoja, mieluummin tuhansia erilaisia kuvia objekteista erilaisissa tilanteissa, joilla koulutettaisiin tunnistajaa, joka taas voidaan verrata joltain testiaineistoa, jossa on valmiiksi tunnistettu objekti, vasten ja verrataan onnistumisprosenttia. Näillä koulutus- ja testiaineistoilla on suuri merkitys kun lähdetään vertailemaan erilaisten metodien nopeutta ja onnistumisprosenttia ja monet tutkijat pyrkivätkin osoittamaan metodiensa tuottamaa etua vertaamalla aiempien metodien tilastoja omien metodiensa tuloksiin. Näissä on kuitenkin aina ylisovittamisen vaara, joka tarkoittaa käytännössä, että opetettu tunnistaja toimii koulutus- sekä testidatalla hyvin, mutta ei osaa enää muissa tapauksissa tunnistaa toivottua objektia. Helppo esimerkki on jos koulutus- sekä testidata ovat pelkästään korkean sävyeron tilanteissa, mutta koulutettu tunnistin laitetaan matalan sävyeron tilanteisiin. Ongelma koitetaan välttää koulutusdatan mahdollisimman suurella monimuotoisuudella, sekä luomalla tunnistusalgoritmiin jatkuvan oppimisen malli, jossa jokainen alkuperäisen koulutuksen jälkeinen datapalanen jatkojalostaa tuon osaamista. Ja tässä ollaan koneoppimisen käytännöllisyyden ytimessä. Muissa metodeissa jatkuva uudenoppiminen ilman konfiguraation tekijän puuttumista asiaan ei ole mahdollista.

## 2.3 Päättöpuut

Päättöpuut ovat mielekkäitä suhteellisen yksinkertaisissa päätöstilanteissa ja sopivat esimerkiksi luokittelutapauksiin tästä syystä. Monesti ne ovat kasa yksinkertaisia kyllä-ei kysymyksiä jotka voidaan kirjata itse, tai mielekkäämmin käyttää lähdemateriaalia ja evolutiivisia algoritmeja, joilla luodaan päätöspuu jota voi soveltaa uuden lähdemateriaalin luokitteluun. Luonnollisesti näitä malleja voidaan käyttää osana kuvan luokittelun algoritmistä ketjua, etenkin jos lopputulemat ovat yksinkertaisia, kuten välitulosten luokittelu muutamaan selkeään kategoriaan, esimerkkinä kissakuvaluokittelija joka luokittelee kuvia kahteen luokkaan sen mukaan sisältävätkö vai eivätkö ne sisällä kissoja. On myös olemassa tuettuja päätöspuita, joista on hyvä mainita hyvinkin perustavanlaatuinen meta-algoritmi AdaBoost, joka on lyhen-

nelmä sanoista Adaptive boosting, joka on hyvin varma ja yleisesti käytetty ratkaisu yhdessä päätöspuiden kanssa. Esimerkiksi Roe ym. (2005) käsittelee neuroverkkojen (ANN) sekä Adaboostilla tuettujen päätöspuiden vertailua hiukkasfysiikan kontekstissa.

## **2.4 Päätösmetsät**

Päätösmetsät ovat useamman uniikeilla parametreilla kasvatetun päätöspuun yhdistelmä, jolla on etuna mallin kehityksen nopeus. Päätösmetsä luodaan yksinkertaisimmillaan esimerkiksi ajamalla koko datasetti läpi useasta puusta, ja ottamalla puiden lopputuloksista keskiarvon, tämänsuuntaista ratkaisua käyttivät esimerkiksi kemiallisten aineiden aktiivisuutta tutkineet (Tong ym. 2003).

## **2.5 Tukivektorikone**

Tukivektorikone näkyy kirjallisuudessa useasti lyhenteellä SVM joka tulee sanoista support vector machine ja se on hyvin laajasti käytössä oleva ja jo useampia vuosia vaikuttanut malli, jota on käsitelty syvällisemmin esimerkiksi (Pontil ja Verri 1998). Perinteikkyydestään johtuen se on hyvin monessa ratkaisussa vähintään osana useamman vaiheen luokittelijoita. Cristianini, Shawe-Taylor ym. (2000) mukaan tukivektorikoneet ovat ohjatun koneoppimisen metodi, jossa roolinsa on lineaarisilla oppimiskoneilla kuten päätöspuilla, sekä kernelifunktioilla, joilla saadan vähennettyä oppimisvaiheen resurssi-intensiivisyyttä. Tukivektorikoneissa on myös ylisovittamisen ongelma ratkaistu erilaisilla painotuksilla.

### 3 Peittymisen ongelma

Konenäöllä on monia erilaisia tunnistamista haasteelliseksi muuttavia tilanteita, jotka saattavat jopa johtua käytettävissä olevasta teknologiasta, kuten esimerkiksi erityisesti sotateollisuuden käyttämästä infrapunakuvaamisesta. Jokaiselle näistä on niille räätälöityjä ratkaisuja, joita listaavat esimerkiksi (Soundrapandiyan ja Mouli 2015). Tämän tutkielman loppuosassa keskitytään peittymisongelmiin (engl. *occlusion problems*). Peittymisongelmat ovat yksi yleisimmistä konenäön soveltamisen kanssa tulevista haasteista, erityisesti nykyään kehityksen keskiössä olevissa kohteissa. Näitä ovat ihmisten tunnistaminen kadulta valvontakamerakuvasta, sekä autojen itseohjautumistoiminnallisuuden vaatiman kameradatan käsittely, molemmissa tapauksissa on hyvin todenköisesti ihmisiä peittyneenä ainakin osittain milloin milläkin asialla. Lisäksi ihmiset monesti kantavat tavaroita, kulkevat autojen ja pyöräilijöiden seassa, tai ovat puistoissa puskien ja puiden takana. Lisäksi sattuu se satunainen hetki kun joku perhonen tai lintu lentää kameran edestä peittäen näkyvyyttä. On siis paljon tilanteita joissa täytyy tunnistaa ihminen puutteellisella kokonaisuudella kuvasta. Lisähuomautuksena täytyy mainita, että peittymisongelmat ovat hallitsevia lähinnä muuttumattoman kuvan kanssa sekä siinä tilanteessa, että tunnistettava asia on pitkiä aikoja paikallaan videokuvassa. Luonnollisesti peittymisongelma tapahtuu myös siinä tilanteessa kun halutaan tunnistaa kasvat, mutta kasvoilla on peittäviä esineitä kuten aurinkolasit. Hyvin suuri osa peittymisongelmista tehdyistä julkaisuista käsittelee nimenomaan kasvojentunnistuksen haasteita ja ratkaisuja niihin.

Etenkin osittaisen peittymisen ongelmiin löytyy monenlaisia ratkaisutyyppisiä ja lähinnä kysymys alkaa olla niiden suoritusnopeudesta ja paikkansapitävyyden prosentuaalisista eroista. Ratkaisuissa on aina ohjelmallinen osuus mukana mutta joissain tapauksissa on mukana myös teknisen pohjan muutoksia.

#### 3.1 Tekniset ratkaisut

Tekniset ratkaisut avaavat erilaisia lähtökohtia peittyneisyyden poistamiseen periaatteessa tuottamalla laajempaa lähdemateriaalia ja siksi niiden kanssa itse ongelman ratkaisussa on

siten hieman erilaisia algoritmeja käytössä yhdessä niiden kanssa. Teknisillä ratkaisuilla voidaan ratkaista myös tilapäiset täyden peittymisen ongelmat, kuten Koller, Weber ja Malik (1994) olivat onnistuneesti tehneet.

### **3.1.1 Video**

Videot sisältävät useita peräkkäisiä kuvia, ja videomateriaalia tuotetaan valtavia määriä jatkuvasti esimerkiksi valvontakameroilla ympäri maailman. Tällaisessa datassa on omat selkeät etunsa jos halutaan ratkaista tilannetta jossa tapahtuu hetkittäistä peittymisongelmaa esimerkiksi ohiajavan auton peittäessä kadulla ihmisen joka kuvasta pitäisi löytää. Videoformaatti aikaansaa myös omat heikkoutensa, kuten Varga, Havasi ja Szirányi (2015) olivat huomanneet. Kuitenkin yksinkertaisimmillaan videoihin saa lisättyä kertaalleen tunnistetun objektin seuraamisen, jottei sitä tarvitse laskea uudestaan, ja tähän voi liittää jos jonkinlaista lisävarmennetta laitteiston tehokkuuden ja pilvipalvelujen mahdollisuuksien kasvaessa.

### **3.1.2 Useampi kamera**

Kaikista suoraviivaisin tapa on ottaa useampia kuvia eri kulmista, mutta tällä ratkaisulla tulee luonnollisesti ongelmaksi duplikaattien poistaminen laskuista, ja tällöin sidotaan resursseja henkilön tutuksi tunnistamiseen toisesta kulmasta. Kuitenkin tällaiseen ratkaisuun on osaratkaisuna päätyneet esimerkiksi Leibe, Seemann ja Schiele (2005) lopun ollessa puhdasta konvoluutioverkkojen statistista laskentaa.

## **3.2 Kuvankäsittely ja algoritmit**

Peittymisongelmalle on monenlaisia erityyppisiä algoritmillisia ratkaisuja, monesti tutkimuksissa kuitenkin ei ole pääasiallisesti lähdetty peittymistä ratkaisemaan, vaan se on yleisenä muuttujana testidatassa ja se pyritään huomiomaan osana yleispätevää luokittelijaa. Sovellukset ovat useasti hyvin sovitettuja käyttökohteeseensa, sillä yleisluokittelijan käyttö useimpiin tarkoituksiin ei ole tarpeeksi varmaa ja siksi järkevää. Kuitenkin nämä räätälöidyt sovellukset rakennetaan useasti yhteisistä metodeista, joita esittelin aiemmin luvussa 2. Esimerkiksi Hotta (2008) ovat käyttäneet kasvojentunnistuksen peittymisongelmassa tukivektorikonei-

ta, ja niitä on käytetty myös muiden yleisten 3d-olioiden luokitteluun onnistuneesti. Mathias ym. (2013) lähtivät eksplisiivisesti ratkomaan peittymistä ihmiskehon tunnistamistehtävässä ja päätyivät monien eri päälekäisyyteen keskittyneiden, tuettujen suodinten yhdistämiseen ja niiden painottamiseen yksinkertaisen kehontunnistamis-suotimen päälle onnistunein tuloksien. Noita tuettuja suotimia he itse kutsuivat franken-luokittelijoiksi. Ouyang ja Wang 2012 Yhdistivät syvän mallin muovattavien osien suodinten käyttöön sekä monikerroksisuuteen. Samalla he käsitelivät peittymisen mukaanottamista mallien viitekehyksiin piilotettuina muuttujina. Burgos-Artizzu, Perona ja Dollar (2013) Loivat kasvojen tunnistamisen avuksi kestävästä cascaded pose regression algoritmin, joka toi parannuksia aiempaan cascaded pose regression työkaluun jopa puolet, ja metodin kestävyys tuli nimenomaan peittymistilanteiden paremmalla käsittelyllä. Vertailussa käytettiin yleisessä käytössä olevaa Caltech Occluded Faces in the Wild -datasettiä

### **3.2.1 Neuroverkot**

Yksi puhdas konvoluutioverkkoon perustuva ratkaisu ottaa kantoajatuksensa siitä, että ihmisen kokonaisuus koostuu ruumiinosista ja näitä tunnistamalla ja yhdistämällä päästään jo syväoppimisen periaatteiden äärelle. Tarkemmin metodiksi Wu ja Nevatia 2005 olivat valinneet Baynesilaisen todennäköisyyslaskennan. peittymistä lähtivät ratkomaan konvoluutioneuroverkoilla myös Juefei-Xu ym. 2016 pyrkimyksessään luokitella kuvamuotoinen data kasvoista sukupuolten mukaan, painottaen tiettyjä alueita kasvoista, jotka olivat tutkimuksissa todistettu sukupuolidimorphisiksi. Käytännössä tämä tapahtui algoritmien huomion keskittämällä alueille sumentamalla muiden alueiden yksityiskohtia. Kyseisen ratkaisun erityisenä etuna oli hyvä onnistumisprosentti myös matalan resoluution datalla toimiessa.

## 4 Yhteenveto

Konenäkö on jatkuvasti kehittyvä teknologia, ja sen käyttöalueet näkyvät enenevässä määrin arjessamme. Sitä vaivaavia ongelmia on päästy korjaamaan hyvin pitkälle erilaisia kuvankäsittely- sekä tilastollisia metodeja yhdistelemällä. Tämä teknologia on edelleen nopeassa kehityksessä eteenpäin koska sitä ajaa niin valvonnan kuin autoteollisuuden tarpeet. Suuri osa tutkimuksesta painottuu tästä samasta syystä ihmisten ja autojen tunnistamiseen. Konenäössä on käytössä monet erilaiset tilastotieteelliset ja matemaattiset menetelmät, joita sovelletaan aina erikseen tarpeiden vaatimilla tavoilla toisiinsa ja kuvankäsittelyalgoritmeihin. Peittymisongelmalle kehitetään jatkuvasti uusia parempia ratkaisuja ja näitä sovelletaan laajalti kaikkialla missä konenäköä käytetään. Osittaisen peittymisen ongelman voisi siis katsoa olevan harrastelijoiden tarpeisiin ratkaistu. Tuleva kehitys painottuu järjestelmiin joissa osumatarkkuuden täsmällisyys on hyvin tärkeää.

## Lähteet

Benenson, Rodrigo, Mohamed Omran, Jan Hosang ja Bernt Schiele. 2014. “Ten years of pedestrian detection, what have we learned?” Teoksessa *European Conference on Computer Vision*, 613–627. Springer.

Burgos-Artizzu, Xavier P., Pietro Perona ja Piotr Dollar. 2013. “Robust Face Landmark Estimation under Occlusion”. Teoksessa *The IEEE International Conference on Computer Vision (ICCV)*.

Cristianini, Nello, John Shawe-Taylor ym. 2000. *An introduction to support vector machines and other kernel-based learning methods*. Cambridge university press.

Felzenszwalb, Pedro, Ross Girshick, David McAllester ja Deva Ramanan. 2013. “Visual Object Detection with Deformable Part Models”. *Commun. ACM* (New York, NY, USA) 56, numero 9 ( ): 97–105. ISSN: 0001-0782. doi:10.1145/2494532. <http://doi.acm.org/10.1145/2494532>.

Hotta, Kazuhiro. 2008. “Robust face recognition under partial occlusion based on support vector machine with local Gaussian summation kernel”. *Image and Vision Computing* 26 (11): 1490–1498. ISSN: 0262-8856. doi:<https://doi.org/10.1016/j.imavis.2008.04.008>. <http://www.sciencedirect.com/science/article/pii/S0262885608000887>.

Juefei-Xu, Felix, Eshan Verma, Parag Goel, Anisha Cherodian ja Marios Savvides. 2016. “Deepgenger: Occlusion and low resolution robust facial gender classification via progressively trained convolutional neural networks with attention”. Teoksessa *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, 68–77.

Koller, Dieter, Joseph Weber ja Jitendra Malik. 1994. “Robust multiple car tracking with occlusion reasoning”. Teoksessa *Computer Vision — ECCV '94*, toimittanut Jan-Olof Eklundh, 189–196. Berlin, Heidelberg: Springer Berlin Heidelberg. ISBN: 978-3-540-48398-4.

- Leibe, B., E. Seemann ja B. Schiele. 2005. "Pedestrian detection in crowded scenes". Teoksessa *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, nide 1, 878–885 vol. 1. doi:10.1109/CVPR.2005.272.
- Mathias, M., R. Benenson, R. Timofte ja L. V. Gool. 2013. "Handling Occlusions with Franken-Classifiers". Teoksessa *2013 IEEE International Conference on Computer Vision*, 1505–1512. doi:10.1109/ICCV.2013.190.
- Ng, Andrew Y, ja Michael I Jordan. 2002. "On discriminative vs. generative classifiers: A comparison of logistic regression and naive bayes". Teoksessa *Advances in neural information processing systems*, 841–848.
- Ouyang, W., ja X. Wang. 2012. "A discriminative deep model for pedestrian detection with occlusion handling". Teoksessa *2012 IEEE Conference on Computer Vision and Pattern Recognition*, 3258–3265. doi:10.1109/CVPR.2012.6248062.
- Pontil, Massimiliano, ja Alessandro Verri. 1998. "Support vector machines for 3D object recognition". *IEEE transactions on pattern analysis and machine intelligence* 20 (6): 637–646.
- Roe, Byron P., Hai-Jun Yang, Ji Zhu, Yong Liu, Ion Stancu ja Gordon McGregor. 2005. "Boosted decision trees as an alternative to artificial neural networks for particle identification". *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment* 543 (2): 577–584. ISSN: 0168-9002. doi:<https://doi.org/10.1016/j.nima.2004.12.018>. <http://www.sciencedirect.com/science/article/pii/S0168900205000355>.
- Skansi, Sandro. kirjoittaja. 2018. *Introduction to Deep Learning : From Logical Calculus to Artificial Intelligence*. 191. Undergraduate Topics in Computer Science. Cham: Springer International Publishing. <https://doi.org/10.1007/978-3-319-73004-2>.



Soundrapandiyam, Rajkumar, ja P.V.S.S.R. Chandra Mouli. 2015. "Adaptive Pedestrian Detection in Infrared Images Using Background Subtraction and Local Thresholding". Second International Symposium on Computer Vision and the Internet (VisionNet'15), *Procedia Computer Science* 58 (Supplement C): 706–713. ISSN: 1877-0509. doi:<https://doi.org/10.1016/j.procs.2015.08.091>. <http://www.sciencedirect.com/science/article/pii/S1877050915022024>.

Tong, Weida, Huixiao Hong, Hong Fang, Qian Xie ja Roger Perkins. 2003. "Decision forest: combining the predictions of multiple independent decision tree models". *Journal of Chemical Information and Computer Sciences* 43 (2): 525–531.

Varga, D., L. Havasi ja T. Szirányi. 2015. "Pedestrian detection in surveillance videos based on CS-LBP feature". Teoksessa *2015 International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS)*, 413–417. doi:10.1109/MTITS.2015.7223288.

Wu, Bo, ja R. Nevatia. 2005. "Detection of multiple, partially occluded humans in a single image by Bayesian combination of edgelet part detectors". Teoksessa *Tenth IEEE International Conference on Computer Vision (ICCV'05) Volume 1*, nide 1, 90–97 Vol. 1. doi:10.1109/ICCV.2005.74.