

Tapio Kauppinen

**PAIKANNUS- JA
KARTOITUSTEKNOLOGIAT
AUTONOMISISSA LAITTEISSA**

Kandidaatintyö
Tekniikan ja luonnontieteiden tiedekunta
Tarkastaja: Eetu Friman
Toukokuu 2022

TIIVISTELMÄ

Tapio Kauppinen: Paikannus- ja kartoitusteknologiat autonomisissa laitteissa
Kandidaatintyö
Tampereen yliopisto
Konetekniikka
Toukokuu 2022

Itsenäiset mobiilirobotit ja autonomiset ajoneuvot tarvitsevat kyvyn paikantaa itsensä ja kartoittaa ympäristönsä. Mobiilirobottien ja autonomisen liikenteen yleistyminen vaatii toimivat ja luotettavat paikannus- ja kartoitusmenetelmät, koska ne vastaavat laitteiden turvallisuudesta. Erilaisia paikannus- ja kartoitusteknologioita mobiilirobottien ja autonomisten ajoneuvojen käyttöön on monia. Yksikään teknologioista ei ole yksiselitteisesti luotettavin. Tavoitteena on löytää teknologioista hyviä ja huonoja puolia, joiden perusteella teknologioiden soveltuvuutta arvioidaan. Lisäksi SLAM-teknologioiden tulevaisuutta tarkastelemalla voidaan tehdä päätelmiä erilaisista lähestymistavoista. Vertailun perimmäisenä tarkoituksena on löytää ja esitellä vaihtoehtoisia teknologioita paikannukseen ja kartoitukseen.

SLAM-teknologioiden tutkiminen kirjallisuuden avulla tuo oman haasteensa tutkimuksen luotettavuuteen. Akateemisten tekstien lisäksi tutkimustyöhön käytetään myös kaupallisia lähteitä. Monet tarkasteluun valikoituneista teknologioista ovat jo niin kypsiä paikannus- ja kartoitusmenetelmiksi, että niistä löytyy kaupallisia toteutuksia. Paikannukseen ja kartoitukseen käytetään yleisesti lidar-sensoreita ja kameroita, jotka ovat teknologioina keskenään hyvin erilaisia, mutta molempia käytetään autonomisissa laitteissa. Lidarin käyttö autonomisissa ajoneuvoissa jakaa mielipiteitä, koska sen käyttöön liittyy haasteita dynaamisen ympäristön ja hinnan kanssa. Esimerkiksi Tesla pyrkii käyttämään kameroita lidarin sijasta.

Paikantamiseen ja kartoittamiseen löytyy myös muita teknologioita, esimerkiksi radar- tai RFID-sensoreiden avulla. Radar on jo käytössä ajoneuvojen mukautuvissa vakionopeudensäätimissä, koska se pystyy havaitsemaan esteitä pitkältä kantamalta sankankin sumun lävitse. Paikantamiseen voi käyttää myös akustiikkaa tai verkkoyhteyksiä, mutta näiden lähestymistapojen tarkkuus on muita heikompi. Näillekin teknologioille on kuitenkin olemassa käyttökohteita myös autonomisten laitteiden ulkopuolella.

Tulevaisuudessa paikantamiseen ja kartoittamiseen tullaan tarvitsemaan enemmän laskentatehoa, kun olemassa olevat teknologiat kehittyvät tarkemmiksi ja luotettavammiksi. Kehitystä vaaditaan siis myös ympäröivissä teknologioissa. Esimerkiksi analogiset prosessorit matriisilaskentaan voivat olla yleisempiä tulevaisuudessa. Matriisilaskenta on tärkeässä osassa erityisesti koneoppimisessa, ja koneoppiminen toimii hyvin esimerkiksi kameroiden kanssa.

Esitellyistä teknologioista löydettyjen hyvien ja huonojen puolien avulla perustellaan kameroiden olevan paras teknologia autonomisen liikenteen ja mobiilirobottien tarpeisiin. Tähän vaikuttavat ensisijaisesti kameroiden halpa hinta ja joustavuus, jotka tekevät kameroista houkuttelevan vaihtoehdon. Kamerat tarjoavat ympäristöstään myös paljon sellaisia tietoja, joita muilla teknologioilla ei voida kerätä, kuten esimerkiksi objektien värejä tai pinnanlaatuja. Kamerat eivät kuitenkaan ole täydellinen teknologia ja kehitystyölle on vielä varaa. Kameroiden käyttäminen ei tietenkään sulje pois muiden teknologioiden käyttömahdollisuutta niiden rinnalla.

Avainsanat: lidar, SLAM, paikannus, kartoitus, mobiilirobotti, autonominen ajoneuvo.

SISÄLLYSLUETTELO

1. JOHDANTO	1
2. LIDAR-PAIKANNUS JA -KARTOITUS	3
2.1 Toimintaperiaate	3
2.2 Käyttökohteet	4
2.3 Haasteet	5
3. VAIHTOEHTOISET TEKNOLOGIAT	8
3.1 Kamerat	8
3.1.1 FastSLAM	11
3.1.2 RatSLAM	11
3.1.3 MonoSLAM	12
3.1.4 Koneoppiminen	13
3.2 Radar-paikannus	14
3.3 Akustinen paikannus	15
3.4 WLAN / Wi-Fi paikannus	16
3.5 RFID SLAM	17
4. SLAM KEHITYS JA TULEVAISUUS	19
5. YHTEENVETO	22
LÄHTEET	24

LYHENTEET JA MERKINNÄT

SLAM	Simultaneous location and mapping, samanaikainen paikannus ja kartoitus
LiDAR	Light detection and ranging, valotutka
RADAR	Radio detection and ranging, tutka
RFID	Radio frequency identification, radiotaajuinen etätunnistus

1. JOHDANTO

Autonomisten laitteiden lokalisaatio ja kartoitus on keskeinen osa lähiaikoina kehitettyjä autonomisia teknologioita, kuten mobiilirobotteja ja autonomisen liikenteen välineitä. Autonomiset laitteet eivät luonnostaan omaa samankaltaista kartoitus- ja paikannusmenetelmää kuin ihmiset (silmät, aivot), mutta vaihtoehtoja on kehitteillä useampia. Teollisuuden ottaessa käyttöön yhä enemmän mobiilirobotteja sekä autonomisen liikenteen realisoituessa näiden tekniikoiden tulee olla luotettavia, varmoja päätöksistään ja yksinkertaisia toiminnaltaan, jotta niiden käyttöönotto on mahdollista lähes missä tahansa ympäristössä. Esimerkiksi autonomisen ajoneuvon tulisi pystyä navigoimaan turvallisesti sekä tiheässä kaupunkiympäristössä että Suomen pimeässä talvessa. Näin ollen aihetta on syytä tutkia, jotta jokaiseen käyttökohteeseen löydetään paras ratkaisu.

LiDAR teknologiana jakaa mielipiteitä. Muun muassa Elon Musk sanoo, että sen käyttö on tuhoon tuomittua autonomisten ajoneuvojen paikannus- ja kartoitusteknologiana. Autonomisten ajoneuvojen on tunnistettava liikenteessä laaja joukko objekteja, jotta turvallisuus voidaan taata. Objektien tunnistaminen on helpompaa esimerkiksi kameroilla. Kuitenkin eurooppalaiset autovalmistajat käyttävät ja kehittävät lidaria. Työssä selvitetään, onko väitteessä perää. Lisäksi selvitetään, mitä vaihtoehtoja lidarin käytölle on. Tutkimuksen tarkoituksena on selvittää eri teknologioiden hyödyt ja haitat. Työssä tarkastellaan myös kehityksen suuntaa. Kysymyksiä ovat siis:

- Onko LIDAR paras teknologia kartoitukseen ja paikoitukseen?
- Mitä vaihtoehtoja autonomisten laitteiden paikannukselle ja kartoitukselle on?
- Mitä hyötyjä ja haittoja vaihtoehtoista on?
- Voidaanko jokin tietty teknologia yhdistää toimivaksi ratkaisuksi johonkin tiettyyn applikaatioon?
- Kuinka kartoituksen ja paikannuksen teknologiat tulevat kehittymään tulevaisuudessa?

Työ on rajattu teollisuuden mobiilirobotteihin ja autonomiseen liikenteeseen. Näistä tutkitaan nykyajan ratkaisuja paikannuksen ja kartoituksen toteuttamiseen, sekä listataan ja käsitellään vaihtoehtojen hyötyjä ja haittoja. Työn perimmäisenä tarkoituksena on löytää ja esitellä vaihtoehtoisia teknologioita lidarille paikannukseen ja kartoitukseen. Työssä tutkitaan tarkemmin lidaria teknologiana autonomisten laitteiden


kannalta. Muita vaihtoehtoja lidarille ovat mm. kamerat, radar ja RFID. Jokaisen teknologian kohdalla pohditaan sekä hyötyjä että haittoja autonomisten ajoneuvojen ja mobiilirobottien näkökulmasta. Löydetyt hyödyt ja heikkoudet esitellään yhteenvedossa. Hyötyjen ja haittojen perusteella pyritään myös määrittämään, kuinka hyvin teknologia soveltuu autonomisten laitteiden tarpeisiin.

2. LIDAR-PAIKANNUS JA -KARTOITUS

Lidar (*Light Detection and Ranging*) on teknologia, jolla mitataan etäisyyksiä laserpulsseja käyttäen (NOOA 2021). Toimintaperiaatetta käydään tarkemmin läpi alaluvussa 2.1. Lidar muodostaa etäisyysmittauksista pistepilven, josta voidaan muodostaa kolmiulotteinen malli. Lidar skaalautuu käytettäväksi autonomisiin laitteisiin, joita tässä työssä tarkastellaan, tuulen nopeuden mittaamiseen (Mann et al. 2020) ja vieraiden planeettojen pinnanmuotojen kartoittamiseen. Benewake-yrityksen (2019) mukaan nykyään lidaria käytetään liikenteessä mukautuvien vakionopeudensäätimien etäisyysmittauksiin ja muun liikenteen ajoneuvotyyppien tunnistamiseen. Kehityksen suuntana on käyttää lidaria autonomisten laitteiden paikannukseen ja kartoitukseen. Teollisuuden mobiiliroboteissa lidar on jo käytössä paikannuksen ja kartoituksen tarkoituksiin, ja kaupallisia tuotteita on jo saatavilla monelta yritykseltä.

2.1 Toimintaperiaate

Lidarin toiminta perustuu pulsseina lähetetyn valon heijastumiseen. Valoa lähetetään korkealla taajuudella, jotta mittauksia saadaan hyvin monta lyhyellä aikavälillä. Valon heijastuttua takaisin lidar-järjestelmä laskee heijastumiseen kuluneen ajan perusteella etäisyyden kohteeseen. Lidar-laitteisto on usein pyörivä tai kääntyvä, jolloin mittauksia saadaan useasta suunnasta. Lyhyessä ajassa muodostuu valtava joukko pisteitä, joista tiedetään suunta ja etäisyys. Tämä pistepilvi voidaan tulkita kolmiulotteisena mallina. (NOOA 2021) Esimerkki pistepilvestä on esitetty Kuvassa 1. Kyseinen pistepilvi on muodostettu kaksiulotteisella sensorilla, jolloin etäisyyksiä mitataan vain yhdessä tasossa. Esimerkin tapauksessa pisteistä muodostuu selkeitä muotoja, jotka vastaavat reaali maailmassa kerrostaloasunnon seiniä.



Kuva 1. Esimerkki pistepilvestä, joka on muodostettu kaksiulotteisella lidar-sensorilla kerrostaloasunnossa. (Laasonen Olli, 14.4.2022)

Muodostetusta mallista voidaan päätellä ympäristön muotoja, laitteen sijainti, sekä laitteen liikerata. Muutoksia aiemmin mitattujen pisteiden ja nykyisten välillä verrataan, jolloin saadaan arvioitua muutos laitteen sijainnissa ja sen nopeus. Koska mittauksia suoritetaan yleensä useita kertoja sekunnissa, saadaan sijainnin muutoksesta tarkka arvio. Kun kerätty data säilytetään, siitä voidaan muodostaa kartta. Kartoittamisen hyötynä on entuudestaan tutun alueen tunnistaminen ja reitin suunnittelu. Teollisuusrobotit tai ehkä ihmisille tutummin robottipölynimurit voivat käyttää lidaria tilan muotojen arviointiin ja näin suunnitella reitin etukäteen.

Autonomisissa laitteissa lidar toimii ympäristön mittaamisen työkaluna. Itse ympäristön tulkitseminen ja päätösten tekeminen on usein tietokoneen vastuulla. Lidar toimii autonomisen liikenteen keinona tunnistaa pinnanmuotoja, kartoittaa teitä, mitata etäisyyksiä, paikantaa ajoneuvon sijainti tiellä ja havaita muutoksia jo aiemmin kartoitetulla alueella.

2.2 Käyttökohteet

Lidarin käyttöä autonomisten laitteiden toiminnan tukemiseen on kehitetty erityisesti 2000-luvulta alkaen, kun ensimmäiset autonomiset ajoneuvot suoriutuivat urbaanista ajoympäristöstä *DARPA Urban Challenge* aikana. Tapahtuma todisti lidarin käytön hyödyt. Ajoneuvot käyttivät lidaria geometrinen muotojen kuten tien reunan ja

pientareen tunnistamiseen pitkällä kantamalla. (Buehler et al. 2009) Nykyään lidar mahdollistaa myös tarkemman ajoneuvojen ja kevyen liikenteen tunnistamisen sekä pitkän kantaman tarkkuuden. Yhdessä ajoneuvossa voi olla useampia lidar-järjestelmiä, jotka sisältävät pyöriviä ja suunnattuja lähettämiä.

Lidar toimii tärkeänä työkaluna etäisyyksien mittaamiseen myös ihmisten ajamissa autoissa. Esimerkiksi edellän ajavan auton mukaan säätyvä vakionopeudensäädin voi käyttää yksisuuntaista lidaria etäisyyden määrittämiseen. Aiemmin mainitussa *DARPA Urban Challenge* -tapahtumassa osallistujat käyttivät Velodyne Lidar -yrityksen valmistamia lidar-laitteita, ja sama valmistaja on tuomassa markkinoille halvan (noin US \$100) ihmisten ajamiin ajoneuvoihin tarkoitetun lidarin (Ross 2020). Halpojen lidareiden yleistyessä suurempi osa liikenteen ajoneuvoista on varustettu kehittyneillä kuljettajanavustusjärjestelmillä.

Teollisuuden mobiiliroboteissa lidar on tärkeä työkalu ympäristön kartoittamiseen. Yleensä roboteille ohjelmoidaan valmis reitti, jota robotit pyrkivät seuraamaan väistäen lidarin havaitsemat esteet. Robotit pystyvät tunnistamaan muutokset aiemmin kartoitetulla alueella. Kartoittaminen tapahtuu skannaamalla robotin ympäristö, joko kaksi- tai kolmiulotteisesti, minkä jälkeen kerätyt datapisteet liitetään aiemmin kerättyyn tietoon. Näin robotti pystyy myös sijoittamaan itsensä virtuaaliselle kartalle. Edellä mainitut robotti-imurit ovat hyvä esimerkki lidarin käytöstä autonomisissa laitteissa. Lidarin avulla kartoitettu alue on robotin käytettävissä myös ilman valoa, jolloin toimintaa voi jatkaa sellaisissa olosuhteissa, joissa ihminen ei näkisi mitään. Lidar ei myöskään tallenna väritietoa heijastavista pinnoista, eli käytännössä teknologia ei ota kuvia. Robotti-imurin tapauksessa lidar on siis parempi vaihtoehto kartoittamiseen kuin esimerkiksi kamera, joka ei yleensä ole tietoturvallinen vaihtoehto. Lidarin lähettämä säteily on myös yleensä aallonpituudeltaan sellaista, jota ei ihmissilmällä voi nähdä.

Lidar taipuu käytettäväksi moneen muuhunkin käyttötarkoitukseen. Esimerkiksi maanpinnan muotoja, metsän puiden korkeuksia (Adams 2011) ja tuulen nopeuksia (Mann et al. 2020) voidaan mitata lidarilla. Teknologiana lidar on siis monikäyttöinen ja siksi siihen panostetaan kehitystyötä. Lidarin voi olettaa pysyvän markkinoilla kartoitus- ja paikannusteknologiana.

2.3 Haasteet

Lidarin käyttöön kohdistuu useita haasteita, joiden takia sitä ei vielä käytetä kaikissa uusissa autonomisissa ajoneuvoissa. Ensimmäisenä ja todennäköisesti suurimpana haasteena lidarin käyttöönotossa on sen hinta. Halvimpien lidarien sijoittuessa noin 100

dollarin hintaluokkaan (Ross 2020) teknologiaa ei voida integroida markkinoiden jokaiseen robottipölynimuriin. Autonomisten ajoneuvojen käyttöön sopiva pyörivä kolmiulotteinen lidar-kokonaisuus voikin jo maksaa useita kymmeniä tuhansia. Hintansa puolesta kallista teknologiaa ei voi tuoda markkinoille yhtä laajamittaisesti kuin halpaa. Teknologia kaipaa kehitystä ja kypsenemistä, jotta siitä saadaan halvempi ja se pystytään tuomaan laajemmille markkinoille.

Toinen lidarin käytön haaste on dynaaminen ympäristö. Tästä hyvä esimerkki on autonomisten ajoneuvojen tarve selvitä erilaisista sääolosuhteista. Artikkelissa "Light Transmission in Fog" (Bernardin et al. 2019) käydään läpi sumun vaikutusta eri aallonpituuksiin. Aallonpituudet 1000–2000 nm välillä absorboituvat osittain sumuun, joka rajoittaa lidarin toimintasädettä. Samoin myös sankka lumisade heikentää näkyvyyttä. Muuttuvat sääolosuhteet ovat suuri ongelma, jonka ratkaisemiseen tarvitaan tukea muista teknologioista.

Dynaamiseksi ympäristöksi voidaan myös mieltää muut ympäristön fyysiset muutokset. Esimerkiksi lumisateen jälkeen kartoitettu alue muuttuu olennaisesti, kun tiet aurataan. Tien reunan tunnistaminen onnistuu edelleen, mutta aiemmin kerättyä dataa alueesta on hankala yhdistää uuteen. Teknologian tulee käyttää niin sivistyneitä algoritmeja, että se osaa reagoida ympäristön muutoksiin.

Koska ympäristö on muuttuva, on sitä tarpeen tutkia jatkuvasti. Seurauksena kerättyä dataa muodostuu viidestä lidar-sensorista jopa 100Mbps (Heinrich 2017). Tämä datamäärä on suuri suhteessa nykyisiin tallennusvälineisiin, ja nopeudeltaan verrannollinen esimerkiksi kotitalouksissa käytettyihin nettiyhteyksiin. Kaiken tiedon säilyttäminen on siis käytännössä mahdotonta, jolloin tiedon tallentaminen, prosessointi ja käsittely jo itsessään muodostavat oman haasteensa. Prosessoinnin vaatiessa paljon laskennallista tehoa se saattaa jopa rajoittaa laitteen muuta toimintaa, kuten mobiilirobotin kykyä liikkua akkukapasiteetin pienennyttyä vaativan laskennan seurauksena.

Lidarin toimiessa tietyllä aallonpituudella haasteeksi nousee myös signaalien erottaminen toisistaan, mikäli alueella on käytössä useampi lidaria hyödyntävä laite. Kuvitteellisessa tilanteessa, jossa jokaisessa liikenteen ajoneuvossa on lidar järjestelmä käytössä, on helppo nähdä, että signaaleja lähetetään paljon. Kun tilanne muuttuu vielä liikeneruuhkaksi, on tärkeää, että jokaisen ajoneuvon lähettämä signaali voidaan yksilöidä. Signaalien määrä kasvaa vieläkin suuremmaksi, kun yksittäiset ajoneuvot käyttävät useaa lidar järjestelmää. Pienet variaatiot aallonpituudessa riittävät vielä lidarin ollessa harvinaisempi ratkaisu, mutta sen yleistyessä on jokaisen laitteen käytettävä

jotain yksilöivää tunnistustapaa. Kenties myös datan prosessointia on kehitettävä, jotta väärät signaalit osataan tunnistaa vääriksi. Järjestelmän luotettavuus ei kuitenkaan saa tämän seurauksena heikentyä.

Autonomisten ajoneuvojen tarpeisiin kuuluu myös kyky väistää esteitä myös matkanopeudessa. Jo 10 cm korkea este voi osua ajoneuvon etupuskuriin. Jos haluamme havaita tällaisen esteen 150 metriä etukäteen väistöliikkeen tekemiseksi, se tarkoittaa, että lidarin on pystyttävä tekemään mittauksia 0,67 mrad välein. Jos luotettavan tunnistuksen tekemiseen vaaditaan 5 mitattua pistettä esteestä, on tarkkuuden oltava noin 0,13 mrad. Näin tarkan lidarin valmistaminen ja sen mahduttaminen ajoneuvoon on itsessään haaste, ja nostaa hintatasoa huomattavasti.

Elon Muskin on todettu sanovan, että lidarin käyttö autonomisissa ajoneuvoissa ei ole tarpeellista. Teslan strategiaan ei kuulu lidar, vaan he keskittyvät mieluummin kameroihin (The Verge 2018, Sharabok 2020). Edellä käsitellyt haasteet helpottavat tämän näkökannan ymmärtämistä. Lidar ei myöskään osaa tulkita ympäristöä kameran lailla, joten olemassa olevien liikennemerkkien ja kaistaviivojen lukemiseen siitä ei ole. Kuitenkin eurooppalaiset autovalmistajat, kuten Volkswagen, kehittävät lidaria ja sijoittavat siihen. Volkswagen käyttää kehitystyöhön myös täysin simuloitua lidaria (BeamNG GmbH 2022).

3. VAIHTOEHTOISET TEKNOLOGIAT

Lidar ei ole ainut teknologia kartoittamiseen ja paikantamiseen. Tässä työssä käydään tarkemmin läpi muutamia vaihtoehtoisia teknologioita, ja pohditaan, mitä vahvuuksia tai haittapuolia niillä on. Hyvin monessa autonomisessa laitteessa voi toki olla viisasta hyödyntää useampaa teknologiaa. Esimerkiksi autonomisissa ajoneuvoissa on usein sekä lidar, kamera ja muita sensoreita ympäristön kartoittamiseen ja tulkitsemiseen. Vaikka tässä työssä teknologioita käsitellään erikseen, ei tule unohtaa, että useimmiten teknologiat toimivat yhdessä toistensa kanssa ilman ongelmia.

Aiemmin työssä läpikäytyjen lidariin kohdistuvien haasteiden perusteella voidaan todeta, että kyseisen teknologian tarjoamat mahdollisuudet eivät vielä nykypäivänä vastaa autonomisen liikenteen tarpeita. Teollisuuden mobiiliroboteille asetetaan yleensä pienemmät vaatimukset, sillä työympäristö ei yleensä ole dynaaminen. Sisätiloissa liikkuvan mobiilirobotin ei tarvitse selviytyä lumimyrskystä, ja parhaimmassa tapauksessa sen ei myöskään tarvitse väistellä jalankulkijoita. Silloin tuleekin jo miettiä, onko lidar teknologiana jopa liian kallis tai monimutkainen, jos sen tarjoama tarkkuus ei ole tarpeen. Teknologiaa valitessa tulee siis tuntea käyttökohteen vaatimukset, jotta valittu teknologia ei ole yli- tai alimitoitettu kohteeseen.

3.1 Kameran

Kamera on teknologinen vaste ihmissilmälle. Kamerankin toiminta perustuu siihen tulevan ja heijastuvan valon määrään ja väriin. Tämä antaa kameralle teoriassa samat mahdollisuudet ja rajoitteet kartoittamiseen ja paikantamiseen kuin ihmisellekin. Kameran tuki omaavat omia rajoitteitansa, esimerkiksi resoluutiossa ja kirkkauden vaihtelussa. Mutta siinä missä ihmissilmä sopeutuu erilaisiin olosuhteisiin, voi kameran valmistaa tiettyä tarkoitusta varten, esimerkiksi yö- tai laajakuvaamista varten.

Kameran tärkeimpiä hyötyjä ovat sen kyky tallentaa värejä ja kirkkauksia. Käytännössä kameran ottamista kuvista voidaan siis tulkita esimerkiksi liikennemerkkeihin kirjattuja tietoja, kuten nopeusrajoituksia. Siinä missä lidar ei voi erottaa muovipussia töyssystä tiellä, kamera voi tulkita ympäristön kappaleiden todellista luonnetta (Sharabok 2020). Kamerasta saatua tietoa tutkiessa tekoälyllä voidaan tehdä päätöksiä siitä, mitkä esteet ja kappaleet ovat autonomisen laitteen kannalta merkittäviä. Koska nykyaikana tiet ovat rakennettu ihmisten käyttöön autonomisten ajoneuvojen sijasta, on lähes kaikki tien käyttöön tarvittava informaatio tulkittavissa visuaalisin keinoin. Mikäli kaikki liikenne

muuttuu tulevaisuudessa täysin autonomiseksi, on mahdollista, että kameroita ei enää tarvita. Tällä hetkellä kuitenkin autovalmistajat, etenkin Tesla (2022a), käyttävät kameroita autoissaan. Kameroiden luontaisiin etuihin kuuluvat myös ominaisuudet matkustajan informoimisessa (peruutuskamera) ja ympäristön valvomisessa (varkaudenestojärjestelmä).

Toinen kamerateknologian etu on sen hinta. Tesla (2022a) hyödyntää autoissaan useampaa kameraa kerrallaan, jolloin yksittäisen kameran hinta on hyvä saada mahdollisimman pieneksi. Lähivuosina älypuhelimien yleistettyä myös digitaaliset kamerat ovat kehittyneet huomattavalla vauhdilla. Yhdessä alle tuhannen euron älypuhelimessa saattaa olla jopa neljä kameraa, joista jokaisella on oma tehtävänsä. Kameroiden hintaa on siis saatu alas, ja jos useampi kamera mahtuu kämmenelle, on sellaisen mahdollisuus esimerkiksi auton puskuriin tai pieneen mobiilirobottiin hyvin suoraviivaista. Nykyaikana on myös mahdollista pieniä ja halpoja digitaalisia laajakuvat- tai pimeänäkökameroita, joilla on käyttöä älypuhelimien lisäksi myös autonomisissa laitteissa. Autonomisten laitteiden oletetaan toimivan myös pimeässä, ja laajakuvakameraa voi hyödyntää myös peruutuskamerana. Teoriassa kameran ei edes tarvitse olla sitä hyödyntävässä mobiilirobotissa, vaan kamera voi olla esimerkiksi robotin työalueella tehtaan katossa. Näin jo yhdellä kameralla voidaan paikantaa useampi robotti tai alueella liikkuvia ihmisiä, jolloin kustannukset pienenevät entisestään eikä kameran sijoittaminen robottiin aiheuta haasteita.

Kameroiden käyttö ei kuitenkaan täysin ongelmatonta. Dynaaminen ympäristö aiheuttaa ongelmia samalla tavalla kuin lidaria käyttäessä. Ympäristössä liikkuvat objektit on tunnistettava liikkuviksi, eikä niiden liikettä saa tulkita itse laitteen liikkeeksi. Hyvä esimerkki tästä on junassa istuminen, kun viereiseltä raiteelta lähtee liikkeelle juna. Visuaalisesti tilanne näyttää siltä, että se juna, jossa itse istuu, on liikkeessä, mutta todellisuudessa vain toinen junista liikkuu. On siis helppo ymmärtää, miksi vain visuaalisia keinoja käyttävä robotti voi helposti erehtyä omasta liikkeestään. Tällaisiin robotteihin voisi lisätä myös kiihtyvyyssanturit, joilla virheiden määrää voidaan vähentää. Ympäristön ominaisuuksien tunnistamiseen on olemassa jo useita erilaisia metodeja, joista tulee valita kohdekäyttöön sopivin.

Dynaamisen ympäristön lisähankaluus on vaihtuva valon määrä. Kun kameroilla etsitään tunnettuja pisteitä ympäristöstä, on oletus, että pisteet näyttävät samalta kuin ennenkin. Kuitenkin jos aamupäivällä kartoitettua työmatkaa yritetään seurata takaisin iltapäivällä autonomisen ajoneuvon kamerajärjestelmän avulla, on auringon asento muuttunut niin huomattavasti, että vanhojen kiintopisteiden käyttäminen ajoneuvon paikantamiseen on mahdotonta. Kiintopisteellä tarkoitetaan tässä kontekstissa sellaista helposti

tunnistettavaa muotoa tai kuviota, jonka autonominen laite pystyy tunnistamaan uudestaan ja paikoittamaan itsensä sen avulla. Kartoittaminen on siis suoritettava uudestaan. Kameroiden käyttö pimeässä on myös haasteellista, ellei kameraa ole erikseen suunniteltu siihen tarkoitukseen. Ongelmaa ei kuitenkaan tule, jos kameroita käytetään teollisuuden mobiiliroboteissa. Usein on mahdollista taata muuttumaton valaistus sisätiloissa työskenteleville roboteille.

Kameroiden resoluutio ja paikoitus tuovat myös oman haasteensa. Mikäli kameroita halutaan käyttää täysin autonomisen ajoneuvon kartoitusmenetelmänä, on suunniteltava sellainen kamera, joka pystyy tunnistamaan esteet riittävän kaukaa ajoneuvon kulkusuunnasta. Aiemmin esimerkkinä käytetty 150 m etäisyys ja 10 cm korkea este on ongelma myös kameralle, sillä esteenkin tunnistamiseen tarvitaan riittävä määrä pikseleitä, joka riippuu käytetystä algoritmista. Eräs ratkaisu voisi olla käyttää tutkaa kaukaisten kappaleiden paikantamiseen, ja kameraa niiden tunnistamiseen, kun ne ovat riittävän lähellä (Sharabok 2020). Kulkusuuntaan suunnatut ja optisesti kauas tarkentavat kamerat voivat olla ratkaisu, mutta tällöinkin kameroiden sijoittaminen on ongelma. Useampaa kameraa käytettäessä kolmiulotteisen mallin luomiseen tehdään oletus kameroiden välisestä etäisyydestä. Jos kameroita ei ole paikoitettu tarkasti, tulee myös mittatulos heittämään (Adheen et al. 2013). Tästä tulee ongelma erityisesti, jos esimerkiksi autonomisen ajoneuvon puskuri siirtyy paikaltaan hivenen vaikkapa kolarissa. Kameroiden sijaintia pitäisi pystyä arvioimaan toisiinsa nähden käytön aikana, jotta tältä ongelmalta vältyttäisiin.

Kameroiden käyttöön liittyy myös ongelma kuvamateriaalin tallentamisessa (Heinrich 2017). Yleensä kaikkea kerättyä tietoa ei säilytetä, joka tarkoittaa, että kerättyä tietoa on prosessoitava. Tallennettavaksi halutaan vain kiintopisteisiin liittyvää tietoa. Materiaalin käsittelyyn vaaditaankin riittävästi laskentatehoa, jotta autonominen laite pystyy tekemään liikkeitä ja päätöksiä reaaliajassa. Kuvamateriaalin tallentaminen on myös tietoturvariski, ja saattaa hermostuttaa esimerkiksi mobiilirobotin rinnalla työskentelevää ihmistä.

Seuraavissa kappaleissa käydään tarkemmin läpi erilaisia algoritmeja ja SLAM-metodeja, jotka toimivat kameroilla. Oikea valinta perustuu useimmiten ympäristön ominaisuuksiin, kuten muotoihin tai valon määrään. Erilaisia metodeja kannattaa tutkia ennen käyttöönottoa, sillä ne voivat asettaa omia vaatimuksiaan, rajoitteita ja mahdollisuuksia.

3.1.1 FastSLAM

FastSLAM ja FastSLAM 2.0 ovat algoritmeja, joiden toiminnot perustuvat partikkelisuodatukseen. Ympäristöstä otetaan paljon näytteitä kiintopisteiden muodossa. FastSLAM käy läpi robotin asennon ja data-assosiaatiot, ja laskee jokaiseen partikkeliin sijoitetut kiintopisteet. FastSLAM on suunniteltu niin, että se on edeltäjiään kevyempi ajaa laskentatehokkaasti. FastSLAM skaalautuu teoriassa havaittujen partikeleiden suhteen logaritmisesti. (Montemerlo 2007)

FastSLAM on sopiva metodi useaan tarkoitukseen, se on mahdollista toteuttaa usealla eri ohjelmointikielellä ja sen käyttöön voi hyödyntää monia erilaisia kameroita. Näistä syistä FastSLAM on yksi tunnetuimmista SLAM metodeista. FastSLAM ei itsessään aseta vaatimuksia autonomiselle laitteelle, mutta tarkempien arvioiden saavuttamiseksi kartoittamisessa tulisi käyttää useampia ympäristön partikkeleita ja kiintopisteitä. Tämä voi tarkoittaa tarkempia kameroita, pienempää näytteenottoväliä tai useampia kameroita, joiden seurauksena autonomisen laitteen hinta voi nousta. Toisaalta yksittäisen kameran hinta on suhteellisen pieni mobiiliroboteissakin, jolloin hinnan kasvaminen ei välttämättä vaikuta oleellisesti päätöksien tekemiseen.

3.1.2 RatSLAM

RatSLAM on edeltäjiinsä verrattuna täysin uudenlainen lähestymistapa paikannus- ja kartoitusongelmaan. RatSLAM on saanut nimensä siitä, että on kehitetty jyrksijöissä esiintyvien hippokampusmallien pohjalta. RatSLAM muodostaa ympäristöstä osittain topologisen, osittain ruutujakoisen mallin, ja pystyy pitämään yllä useaa hypoteesia tämänhetkisestä sijainnista. Kun ympäristöstä saadaan lisää informaatiota, luotto yhteen tai useampaan hypoteesiin vahvistuu. (Milford et al. 2004)

RatSLAM on nykyään saatavana avoimena lähdekoodina (Ball et al., 2013). RatSLAM on integroitavissa mm. Robot Operating System -käyttöjärjestelmään avoimen lähdekoodin avulla, jolloin sen käyttäminen on verrattain helppoa. RatSLAM ei myöskään vaadi toimiakseen tarkkoja kameroita, sillä jo kahden pikselin kokoisella kuvamateriaalilla kartoittaminen on mahdollista (Milford 2013).

RatSLAM on siis suhteellisen helppo ottaa käyttöön eikä vaadi toimiakseen uusinta ja kalleinta teknologiaa. RatSLAM soveltuukin käytettäväksi mobiiliroboteissa. Sitä on myös testattu ulkona erilaisissa sääolosuhteissa, mutta se ei pysty tunnistamaan päivällä kartoitettua aluetta myöhemmin illalla (Milford et al. 2012). Tästä syystä RatSLAM ei ole täydellinen ratkaisu autonomisten ajoneuvojen käyttöön. RatSLAM toki toimii yölläkin, mutta alueen uudelleen kartoittaminen sääolosuhteiden vaihduttua ei ole tehokas lähestymistapa. Mobiiliroboteille pystytään takaamaan lähes muuttumaton valon määrä

ja suunta tietyissä ympäristössä, esimerkiksi tehtaassa suljetussa tilassa kattovalojen avulla. Tällaisissa ympäristöissä RatSLAM toimii tehokkaammin.

RatSLAM perustuu hippokampusmalliin, mutta jyrksijöiden aivojen toimintaa ei vielä täysin ymmärretä. On siis syytä olettaa, että kehitys biologian alalla voi tuoda myös parempia paikannus- ja kartoitusmetodeja.

3.1.3 MonoSLAM

MonoSLAM on kartoitus- ja paikannusalgoritmi, jonka on tarkoitus toimia reaaliajassa yhdellä kameralla kuvatun videomateriaalin pohjalta. Videomateriaali voi olla taajuudeltaan esimerkiksi 30 Hz, mutta nykyaikaisilla laskentatehoilla myös 60 Hz:n materiaali pystytään käsittelemään reaaliajassa. Tärkein prioriteetti ei ole välitön tarkan kartan luominen ympäristöstä, vaan kameran sijainnin tunnistaminen ja liikeradan mallintaminen. Kartta luodaan, mutta sen pääasiallinen tarkoitus on toimia listana tunnetuista kiintopisteistä paikantamista varten. (Davison et al. 2007)

MonoSLAM:ia voidaan käyttää lisätyn todellisuuden (augmented reality, AR) toteuttamiseen (Davison et al. 2007) ja puettavien järjestelmien paikantamiseen (Castle et al. 2010). MonoSLAM on siis hyvä seuraamaan kameran liikettä ympäristön suhteen, mikä on tärkeää myös mobiiliroboteissa ja autonomisissa ajoneuvoissa. Davisonin et al. (2007) suorittamat testit osoittavat, että MonoSLAM kykenee kameran paikannukseen pienessä tilassa ilman ajan myötä kertyvän siirtymän syntymistä.

Teknologian hyviin puoliin kuuluvat sen tehokkuus, hinta ja laajat käyttömahdollisuudet. Tehokkuus taataan aktiivisella piirteiden haulla, joka varmistaa, ettei kuvamateriaalin käsittelyyn hukata laskentatehoa (Davison et al. 2007). MonoSLAM on teknologiana halpa käyttöönottaa, sillä se vaatii toimiakseen vain yhden kameran. Nykyaikaisilla prosessoreilla kuvamateriaalin käsittelyyn ei myöskään kulu suurta määrää laskentatehoa tai aikaa, mikä tarkoittaa, että mobiilirobotti voi suorittaa lokaalisti algoritmin ja itsensä ohjaamisen. Laajat käyttömahdollisuudet puolestaan viittaavat siihen, että teknologiaa kehitetään mahdollisesti jatkossakin. MonoSLAM pystyy myös toimimaan näköesteiden ilmaantuessa, kunhan joitakin kiintopisteitä on näkyvissä.

Teknologian huonona puolena pidetään sitä, että sen periaatteena on tunnistaa kameran liikkeitä kiintopisteiden avulla ympäristön kartoittamisen sijasta. Edellä esitellyt FastSLAM ja RatSLAM puolestaan keskittyvät lähtökohtaisesti kartoittamiseen. Mikäli ympäristöstä ei tunnisteta erikseen muotoja, kuten pintoja, ei reitin suunnittelu ole mahdollista. Mobiilirobottien tapauksessa liikkeille rajattu alue voi olla valmiiksi määritelty ja kartta etukäteen luotu, jolloin pelkkä paikantaminen riittää. Autonomiselle ajoneuvolle tämä on kuitenkin käytännössä mahdotonta. MonoSLAM kärsii myös muiden

kamerapohjaisten SLAM-teknologioiden tapaan muuttuvien valotusolosuhteiden aiheuttamista ongelmista. Toimintaan vaaditaan myös joitain yksityiskohtia näkökentässä, esimerkiksi pelkkä tasavärinen seinä ei riitä paikoittamiseen (Davison et al. 2007). MonoSLAM on myös alkujaan suunniteltu sisätiloihin käytettäväksi lyhyillä etäisyyksillä eikä siten oletusarvoisesti sovellu ulkona entuudestaan vieraissa ympäristöissä liikkuvien autonomisten ajoneuvojen paikannusteknologiaksi.

3.1.4 Koneoppiminen

Koneoppiminen (englanniksi machine learning) on nimensä mukaisesti teknologia, jossa algoritmit rakennetaan kerätyn tiedon perusteella ikään kuin oppimalla. Oppimisen etuna on se, että kerätyn tiedon lisääntyessä algoritmi voi kehittyä entistä tehokkaammaksi. Koneoppimiseen vaaditaan tiedon kerääminen, abstraktio ja generalisointi. Oppiminen ei siis ole niin sanottua ”ulkoa opettelua”. Tavoitteena on, että opetettu algoritmi osaa lopulta tehdä päätöksiä myös sellaisissa tilanteissa, joita ei ole käyty etukäteen läpi opetuksen aikana. (Chandramouli et al. 2018)

Koneoppimista voi lähestyä esimerkiksi vahvistusoppimisena, ohjattuna tai ohjaamattomana oppimisena. Näiden lähestymistapojen väliset erot eivät ole merkittäviä tämän työn kannalta, joten niitä ei käydä tarkemmin läpi. Jokainen koneoppimisen muoto tuo erilaiset vaatimukset, jotka määrittävät oppimisprosessin kulkua ja lopullista toteutusta. Koneoppiminen vaatii muodostaan huolimatta aina jonkinlaista koulutusta, mikä tarkoittaa, että uuteen käyttötarkoitukseen ei ole olemassa valmista algoritmia. Oletusarvoisesti koneoppiminen alkaa tilasta, jossa algoritmi on toiminnaltaan satunnainen eikä toimi tietoisesti mitään päämäärää kohti. Toistojen myötä tapahtuu ”oppimista”, jonka seurauksena algoritmi alkaa tuottamaan halutun kaltaisia tuloksia. Mitä enemmän toistoja sekä kerättyä tietoa, sitä varmemmin algoritmi osaa tuottaa halutun tuloksen.

Autonomisten laitteiden kameroiden kuvaa voidaan tulkita koneoppimisen keinoin. Esimerkiksi ajokaistan merkintöjä (Gang et al. 2017) ja ympäristöjä (Hunter et al. 2009) voidaan tunnistaa kuvamateriaalista. Koneoppiminen mahdollistaa siis paikantamisen ja muun hyödyllisen tiedon tulkitsemisen. Algoritmi voidaan kouluttaa tunnistamaan auton sijainti tiellä ja lukemaan nopeusrajoitus kylteistä, jotka molemmat ovat nykyisen infrastruktuurin lomassa kulkevien autonomisten ajoneuvojen perustarpeita.

Koska liikenteen infrastruktuuri on rakennettu ihmistä varten, on helppo ajatella, että autonomisen ajoneuvon tulisi ajatella kuten ihminen pärjätäkseen liikenteessä. Eräs koneoppimisen muoto onkin syväoppiminen, joka perustuu neuroverkkoihin. Neuroverkko mallintaa todellista aivotoimintaa, ja se pystyy oppimaan yksittäisiä

neuroneita säätelämällä. Esimerkiksi Tesla (2022b) käyttää neuroverkkoja ajoneuvojensa autonomisen toiminnan tukena ja myy teknologiaansa muille valmistajille. Neuroverkkojen ja kameroiden käyttö on siis autonomisten ajoneuvojen osalta jo nykypäivää.

Koneoppiminen on kuitenkin teknologiana epävarmaa ja hidasta kouluttaa. Teslan (2022b) mukaan autopilotti käyttää 48:aa eri neuroverkkoa, joiden kouluttamiseen aikaa kuluu 70 tuhatta tuntia näytönohjaimella. Tällaisiin lukuihin ei pienillä toimijoilla ole aikaa tai rahaa, joten muut teknologiat ovat helpompia ottaa käyttöön. Jotta varmuus koneoppimiseen kasvaa, on koulutusta myös tehtävä pitkän aikaa ja riittävän monimuotoisella kuvamateriaalilla. Tesla (2022b) väittääkin neuroverkkoihin käytetyn tiedon kertyvän lähes miljoonan eri ajoneuvon tuottamasta materiaalista. Jos esimerkiksi tehtaaseen on tarkoitus hankkia kaksi mobiilirobottia, on sanomattakin selvää, että kouluttamiseen järkevällä aikavälillä ei riitä yksinään niiden kuvaama materiaali.

3.2 Radar-paikannus

Radar, joka tulee sanoista ”Radio detection and ranging” on teknologiana hyvin lähellä lidaria. Radar toimii lähettämällä radioaaltoja ja laskemalla takaisin heijastuneiden aaltojen avulla etäisyyden kohteeseen. Käytännössä ero lidariin on siis käytetyn aallon tyyppi. Radar kehitettiin aluksi toisen maailmansodan aikana tunnistamaan vihollisen lentokoneita, laivoja sekä sukellusveneitä. (Nature 1943)

Nykyaikana radar on käytössä myös lennonjohdossa, meteorologisissa mittauksissa (Melvin & Scheer 2014) sekä SLAM-ongelman ratkaisussa (Adams et al. 2012). Lidarin tavoin radaria voidaan siis hyödyntää autonomisten laitteiden paikannukseen ja kartoitukseen. Koska radar on teknologiana hyvin samankaltainen lidarin kanssa, ovat hyödyt ja haitat pääpiirteittäin samat. Radar on kuitenkin sekä lidaria että kameroita parempi vaihtelevissa sääolosuhteissa. Radar pystyy radioaaltojen avulla havaitsemaan kohteita sankankin sumun lävitse. (Hong et al. 2021) Radar on siis hyvä valinta esimerkiksi mukautuvan vakionopeudensäätimen vaatimaksi etäisyysmittalaitteeksi. Autonomisilta laitteilta vaaditaan myös turvallisuutta liikenteessä, joten sumuisessa säässä radar on kameroita ja lidaria parempi.

Radarin suurimpiin kuuluva ongelma, joka erottaa sen lidarista, on häiriön määrä. Toisin kuin valo, radioaallot voivat heijastua helposti useammasta pinnasta muuttumatta, jonka seurauksena mittaustuloksissa esiintyy häiriötä. Radioaaltoja esiintyy myös atmosfäärissä radar-järjestelmien lisäksi muista lähteistä, jolloin mittauksiin tulee entistä enemmän häiriötä. (Hong et al. 2021)

3.3 Akustinen paikannus

Akustinen SLAM (aSLAM) on kartoitus- ja paikannusmenetelmä, joka perustuu vastaanotettujen äänisignaalien sijainnin arvioimiseen. aSLAM vaatii käytännössä toimiakseen mikrofoneja, joiden avulla saapuvan äänen suuntaa tulkitaan. (Evers & Naylor 2018) Esimerkiksi mobiilirobotissa voi olla useampi mikrofoni ympäri robottia, joilla äänen suuntaa arvioidaan. Toimintaperiaatteen toinen edellytys on, että ympäristössä on ääntä tuottavia kohteita järjestelmälle seurattavaksi tai järjestelmä itse lähettää ääntä, jonka heijastuksia tulkitaan.

Esimerkiksi tehtaassa, jossa on jatkuvia ja muuttumattomia äänilähteitä, voisi mobiilirobotti tunnistaa äänilähteiden sijainnin mikrofoniin avulla. Näin robotti voi muodostaa kartan tunnetuista pisteistä ja arvioida omia liikkeitään niiden suhteen (Evers & Naylor 2018). Äänilähteiden tulee kuitenkin olla jatkuvia. Esimerkiksi ihmisen katkonainen puhe voi johtaa puutteellisen arvioon äänilähteestä (Evers & Naylor 2018). aSLAM ei tästä syystä pelkkien ulkoisten äänilähteiden avulla sovi jokaiseen ympäristöön. Ihmisistä vapaassa ja lähes vakiotilaisessa ympäristössä, esimerkiksi tehtaassa, aSLAM voi toimia, mutta muuttuvassa ympäristössä, kuten liikenteessä, teknologia vaatii tukea muualta.

Toinen vaihtoehto on tuottaa ääni itse. Ääntä voidaan tuottaa pulsseina, jolloin heijastuneista ääniaalloista saadaan laskettua heijastuksen suunta ja etäisyys. Toimintaperiaatteeltaan tämä vastaa lidaria, mutta on teknologiana halvempi ja epätarkempi. Lähetetty ääni voidaan myös toteuttaa jatkuvana, jos sen taajuutta muutetaan ajan mukaan. (Cristea et al. 2019) Itsetuotetun äänen etuna on se, että sen tunnistaminen on helppoa, ja sen taajuus voidaan valita niin, että se ei sekoitu ympäristöön. Taajuuden valitsemisessa tulee ottaa huomioon, että mikäli kaksi teknologiaa hyödyntävää laitetta työskentelevät samassa tilassa, on laitteilla oltava toisistaan erottuvat äänet. Tämä ongelmaa on lidaria vastaava. Äänen tuottaminen voi myös olla haitallista, jos se häiritsee samassa tilassa olevia.

aSLAM voi tarjota tukea näköongelmista kärsiville. Osa näköongelmista kärsivistä ihmisistä pystyy suunnistamaan sisätiloissa napsauttamalla sormiaan ja kuuntelemalla syntyvän äänen kaikua. aSLAM toimii periaatteessa samalla tavalla, ja myös ihminen voi kuulla sen käyttämät äänisignaalit. (Cristea et al. 2019) aSLAM on siis teknologiana monikäyttöinen. aSLAM voi toimia tukena myös muille SLAM-teknologioille, esimerkiksi lidarille, sillä objektit voivat heijastaa ääntä eri tavalla kuin valoa. Äänen avulla objektien tyyppiä voitaisiin tarkastella lidarin tarjoamaa tietoa tarkemmin.

Akustisen paikannuksen suurimpia ongelmia ovat epätarkkuus, ympäristön äänien muuttuva määrä ja laatu sekä kaikuminen (Evers & Naylor 2018, Cristea et al. 2019). Kaikki ongelmat ovat teknologialle luonnollisia sen toimintaperiaatteen takia, mutta ne eivät tarkoita, etteikö aSLAM voisi toimia muiden paikannus- ja kartoitusmenetelmien apuvälineenä.

3.4 WLAN / Wi-Fi paikannus

Langattomien verkkojen yleistyessä on myös niiden käyttämistä paikantamiseen harkittu ja kokeiltu. Avoimien ja julkisten verkkojen hyödyntäminen on kustannustehokasta, sillä vaadittavat verkkoasemat ovat jo valmiiksi asennettuja ympäristöön. Koska verkkoja on erityisesti sisätiloissa, voidaan SLAM algoritmeja rakentaa sisätilakäyttöön pohjanaan verkkoyhteyksien voimakkuudet. (Jiang et al. 2015)

Langattomien verkkoyhteyden käyttäminen paikannukseen on toiminnaltaan melko yksinkertaista ymmärtää. Paikannettavan laitteen lähettämän signaalin vahvuutta voidaan mitata, jonka avulla voidaan muodostaa arvio laitteen etäisyydestä. Kun signaalin voimakkuutta mitataan useammasta suunnasta, voidaan etäisyyksien avulla laskea piste, jossa laite todennäköisimmin sijaitsee. (Liu 2019) Kyseessä ei siis ole kartoittava teknologia, vaan paikannusmenetelmä, joka kertoo arvion sijainnista ennestään määritellyn alueen sisällä. Verkkoyhteydet paikantavat laitteen GPS-signaalin tapaan. Liun (2019) mukaan Verkkoyhteyksien käyttö on yksi parhaista paikannusmenetelmistä, kun GPS-signaalia ei ole käytettävissä. Esimerkiksi sisätiloissa yhteys GPS-järjestelmän satelliitteihin voi olla niin huono, ettei GPS ole käyttökelpoinen ratkaisu paikannukseen. Tällöin eri verkkoyhteyksien hyödyntäminen esimerkiksi teollisuuden mobiilirobottien paikantamiseen on hyvä vaihtoehto. Signaalivoimakkuuden tulkintaan voidaan käyttää myös tekoälyä (Misikangas et al. 2002).

WifiSLAM niminen yritys kehitti mobiililaitteiden paikantamista ja ympäristön kartoitusta langattoman verkkoyhteyden avulla. Teknologijätti Apple osti yrityksen vuonna 2013, jonka seurauksena langattomien verkkoyhteyksien käyttämistä paikannus- ja kartoitusteknologiana odotettiin Applen mobiililaitteisiin. (Ankeny 2013) Teknologian avulla mobiililaitteen käyttäjä pystyisi ilman GPS-signaalia esimerkiksi konferenssitiloissa paikantamaan lähimmät saniteettitilat sekä suunnittelemaan tähän kohteeseen reitin. Samaa teknologiaa voisi helposti hyödyntää myös mobiiliroboteissa. WifiSLAM ei kuitenkaan ole ollut otsikoissa omistajuudenvaihdoksensa jälkeen. Lawlerin (2017) mukaan Applelle siirtynyt Huang, entinen wifiSLAM omistaja, on myös jättänyt Applen jälkeensä ja siirtynyt muihin tehtäviin. Nähtäväksi jää, millaisia kehityksiä teknologia kokee tai tullaanko sitä todellisuudessa hyödyntämään laajemmin.

Vahvan näytön puutteen lisäksi teknologiaa vaivaa tarkkuuden puute. Sisätilojen muodot ja seinät vaikuttavat olennaisesti signaalin vahvuuteen, jolloin paikannus hankaloituu. Tekoälyä hyödyntäen langattomien yhteyksien paikannustarkkuus saadaan alle muutaman metrin (Misikangas et al. 2002), mutta se ei ole riittävästi esimerkiksi mobiilirobotille, jonka tulisi toimia senttimetrien tarkkuudella.

3.5 RFID SLAM

RFID (Radio Frequency Identification) on teknologia, jolla tunnistetaan radiotaajuuksia etänä. Tiedon tallentamiseen ja lukemiseen käytetään RFID-tunnisteita eli tägejä. Yhden tägin hinta on saatu erittäin pieneksi teknologian kehittymisen myötä, eli alle kymmenen senttiä kappaleelta (Shi & Zhou 2008). Kooltaan tägit ovat myös pieniä, sillä alle 0,5 millimetrin kokoisena niitä on valmistettu jo 2000-luvulla (Kleiner 2006).

RFID-tunnisteen eli tägin lukemiseen vaaditaan lukija. Lukijan avulla voidaan lukea tägin sisältämä tieto, kuten sen yksilöivä tunnus. Jokaisella tägillä on yksilöivä tunnus, jonka avulla autonomisten laitteiden kontekstissa voidaan päätellä laitteen sijainti. Autonominen laite voi päätellä sijaintinsa, jos se lukee tunnetussa sijainnissa olevan RFID-tunnisteen. (Kleiner 2006) Näin mahdollistetaan paikannus RFID-tunnisteiden avulla.

Koska tägit ovat pieniä, voi mobiilirobotti kuljettaa niitä mukanaan saapuessaan entuudestaan tuntemattomaan ympäristöön. Mobiilirobotti voi uusia alueita tutkiessaan esimerkiksi pudottaa matkallaan tägejä, jolloin kuljetusta reitistä jää fyysinen jälki. Kulkiessaan uudestaan näiden yksilöityjen tägien yli mobiilirobotti voi helposti tulkita oman sijaintinsa. Näin robotilla voidaan toteuttaa myös paikantamisen lisäksi kartoitus. Kartoitukseen vaaditaan tietysti lisäksi muitakin sensoreita kuin RFID-lukija, kuten esimerkiksi kamera tai ultraäänisensori esteiden tai seinien havaitsemiseksi. (Kleiner 2006)

Tägien ollessa yksilöityjä on myös mahdollista jakaa tieto tägien sijainneista muiden mobiilirobottien kanssa. Käytännössä siis yksi robotti voi kartoittaa uuden alueen, ja samalla myös muut oppivat alueen. Kun mikä tahansa mobiilirobotti ylittää toisen asettaman tägin, voi robotti tulkita sijaintinsa, jos tieto tägien sijainnista on jaettu robottien välillä. (Kleiner 2006)

RFID-tunnisteiden sijoittaminen jo entuudestaan kartoitetulle alueelle on myös eräs lähestymistapa mobiilirobottien paikannus- ja kartoitusongelmaan. Jos alue on etukäteen tunnettu ja siitä on malli mobiilirobotin käytettävissä, voisi robotille riittää paikannukseen pelkästään tägeistä luettu tieto, mikäli myös tägien sijainti on etukäteen

tiedossa. Tämä ei siis vaadi mobiilirobotilta uuden kartoittamista, eikä tällainen robotti siihen pystyisikään. Sen sijaan tällaiseen lähestymistapaan vaaditaan etukäteistyötä, johon kuuluu ihmisen tai robotin kartoittama alue ja asettamat tagit.

RFID on ollut käytössä myös älykkään liikenteen tarpeisiin (Shi & Zhou 2008). Teknologian suurimpia hyötyjä ovat tágien halpa hinta ja niiden pieni koko. Suurin ongelma puolestaan on itse tági, sillä se on fyysinen vaatimus, joka ei saisi vaihtaa sijaintiaan, ja joka on jollain tavalla asetettava suunnistettavalle alueelle. Esimerkiksi autonomiset ajoneuvot eivät voi olettaa, että jokaiselle pikkutielle on sijoitettu tägejä.

4. SLAM KEHITYS JA TULEVAISUUS

Suurin osa viimeaikaisista kehityksistä SLAM-teknologioiden parissa on keskittynyt kehittämään ja optimoimaan kiintopisteistä kerättyjen tietojen käsittelyä ja kohdennusta tunnettuihin kiintopisteisiin (Taheri & Xia 2021). Tästä esimerkkinä toimii FastSLAM 2.0, jonka suurin etu edeltäjänsä oli entistä vähäisempi vaadittu laskennallinen teho. On järkevää olettaa, että samankaltaisia optimointeja kehitetään myös jatkossa.

Suurimpia ongelmia SLAM-teknologioiden käytössä ovat epävarmuus ja epätarkkuus. Esimerkiksi suuret tilat voivat tuoda ongelmia ja kasvattaa vaadittavaa laskentatehoa. Mitä enemmän tietoa ympäristöstä kerätään ja mitä enemmän kiintopisteitä haetaan, sen tarkempaa tietoa ympäristöstä saadaan, mutta myös virheellisten mittaustuloksien kokonaismäärä kasvaa ja laskentatehoa tarvitaan niiden korjaamiseen. Autonomisten ajoneuvojen kohdalla ympäristö on usein muuttuva sekä varsin laaja. Tällaisissa tapauksissa ympäristön tulkitseminen vaatii paljon laskentatehoa, ja entuudestaan tutun alueen tunnistaminen ei välttämättä onnistu. Usein ympäristössä kerätyssä tiedossa on myös häiriöitä, jotka aiheutuvat itse mittauslaitteistosta tai muista tekijöistä. Jo olemassa olevien teknologioiden kehittäminen ja optimointi voi osaltaan tuoda tähän ratkaisun, mutta myös täysin uusia lähestymistapoja tullaan todennäköisesti näkemään.

Eräs uusi lähestymistapa on ”artificial markers”, eli keinotekoiset kiintopisteet, jotka ovat suunniteltu robotin tai muun autonomisen laitteen tunnistettaviksi (Taheri & Xia 2021). Näitä ovat esimerkiksi aiemmin työssä esitellyt RFID-tägit tai kameralla tunnistettavat valkoisella pohjalla olevat mustat kulmikkaat muodot. Mikäli keinotekoisien kiintopisteiden sijainti on jo etukäteen tunnettu, esimerkiksi ihmisen asettaman merkin sijainti tiedetään tarkasti, voi tämän tarkan sijainnin kertoa autonomiselle laitteelle jo etukäteen. Kun autonominen laite havaitsee ennalta tunnetun kiintopisteen sijainnin, voi se tulkita oman sijaintinsa tarkasti, jonka seurauksena laite voi korjata aiemmin kartoitetun alueen virheitä ja omaa sijoitustaan kartalla. Tärkeintä keinotekoiselle kiintopisteelle on olla uniikki sekä helposti tunnistettava. Uniikkisuus voidaan varmistaa RFID-tägin tapauksessa tägin sisältämällä tiedolla, tai korkeakontrastisen kuvan ainutlaatuisilla muodoilla. Keinotekoiset kiintopisteet tuovat lisää varmuutta SLAM-teknologioiden tarkkuuteen. Ne eivät kuitenkaan ole nopea ratkaisu laajalla skaalalla, esimerkiksi autonomisten ajoneuvojen kohdalla, sillä kiintopisteitä on käytännössä mahdoton asettaa jokaiselle tienpätkälle ja risteykseen lyhyellä aikavälillä ja rajallisella budjetilla.

Epävarmuutta voidaan poistaa keräämällä ympäristöstä suuri joukko tietoa, josta hyödynnetään vain varmasti oikea tieto. Tiedon oikeutta voidaan tarkastella data-analyysin keinoin. Tavoitteena on saada väärät tulkinnat sekä mittausvirheet poistettua ennen tiedon hyödyntämistä. Tietoa voidaan puolestaan kerätä entistä enemmän tulevaisuudessa esimerkiksi korkeamman resoluution kameroilla sekä yhdistelemällä tietoa eri sensoreista. Tesla (2022) hyödyntää videokuvaa useammasta kamerasta yhtä aikaa. Kerätyn tiedon määrän kasvaessa tietysti myös sen tulkintaan vaadittava laskentateho kasvaa.

Tiedon kerääminen useammasta lähteestä ei ole uusi keksintö. Useimmat kehitystyöt kuitenkin luonnollisesti keskittyvät yksittäisen teknologian optimointiin ja kehittämiseen. Kehitys useamman teknologian yhteistyöhön tulevaisuudessa on looginen suunta, sillä siitä nähdään esimerkkejä luonnossakin. Ihminen on tästä hyvä esimerkki. Ihminen pystyy tunnistamaan itselleen tuttuja alueita näkemänsä, kuulemansa ja tuntemansa perusteella. Aistit toimivat yhteistyössä, jonka seurauksena itsensä paikantaminen ja ympäristön kartoittaminen onnistuu jo nuorelta ihmiseltä. Ihmisen aistit ovat analogisia autonomisten laitteiden eri sensoreille ja teknologioille. Koska eri teknologiat toimivat eri periaattein, tuottavat ne erilaista tietoa samasta ympäristöstä. Useamman teknologian hyödyntäminen on selkeä etu, sillä esimerkiksi kameran ja radarin tuottamat tiedot ovat hyvin erilaisia ja ne täydentävät toisiaan.

Kasvavan tietomäärän käsittelyyn tarvitaan myös yhä enemmän laskentatehoa. Tästä voisi päätellä, että yksi SLAM-metodien kehittymisen vaatimuksista on myös muiden ympäröivien teknologioiden kehittyminen. Ilman kehityksiä näissä ympäröivissä teknologioissa, kuten prosessoreissa, on vaikea löytää uusia keinoja käsitellä kasvavaa tietomäärää. Mooren lain on todettu lähiaikoina vastaavan yhä vähemmän todellisuutta, ja nykyaikana jopa osa Intelin työntekijöistä uskoo Mooren lain loppuvan lähiaikoina (Flamm 2018). Kehityksiä SLAM-teknologioissa ei siis voi laskea jatkuvasti kasvavan laskentatehon varaan, vaan kehitystyötä tulisi tehdä myös optimoinnin ja uusien lähestymistapojen osalta. Tulevaisuuden SLAM-teknologiat tulevatkin olemaan vähävirtaisia ja laskennallisesti tehokkaita, mikäli niitä halutaan käyttää useimmiten akkuvirralla toimivissa mobiiliroboteissa ja autonomisissa ajoneuvoissa.

Kehityksiä prosessoritekniikan osalta on kuitenkin tapahtunut lähivuosina. Esimerkiksi analogiset matriisilaskennan prosessorit voivat tarjota tulevaisuuden SLAM-teknologioille vähävirtaisen ratkaisun. Analogiset prosessorit toimivat laskemalla kerto- ja yhteenlaskuja jännitteen ja muutettavien vastuksien avulla. (Mythic 2021) Analogisilla prosessoreilla voidaan laskea matriisilaskuja, joita käytetään esimerkiksi tekoälyissä. Perinteisesti tekoäly on vaatinut paljon laskentatehoa ja kuluttanut paljon sähkövirtaa,

mutta käyttötarkoitukseen optimoiduilla analogisilla piireillä kulutusta voidaan laskea tulevaisuudessa.

Tekoälyn merkitys tulee myös todennäköisesti kasvamaan jokaisen SLAM-tekniikan osalta. Tällä hetkellä tekoälyä käytetään erityisesti kameroissa. Tekoälyä voidaan hyödyntää tietysti myös muiden teknologioiden kanssa. On vaikea sanoa, millä kypsyyssasteella tekoäly on tekniikkana, mutta sen yleistymistä on nähty viime vuosina. Tällä hetkellä kehitys suuntautuu tekoälyn yleistymiseen laajalti myös muilla markkina-alueilla. On mahdollista, että jonain päivänä tekoälyä pidetään yhtenä ohjelmistokehityksen perustekniikoista, kuten esimerkiksi olio-ohjelmointia nykyään.

Tulevaisuudessa SLAM-tekniikoille tulee löytymään enemmän käyttökohteita, joka puolestaan tuo painetta kehittää niitä edelleen. Esimerkiksi virtuaalitodellisuuslasien on pystyttävä seuraamaan lasien sijaintia. Myös mobiilirobotit tulevat yleistymään. Omasta kokemuksestani entisenä Postin työntekijänä voin sanoa, että esimerkiksi Suomessa Postilla sekä mobiilirobottien että autonomisten ajoneuvojen käyttöönotto helpottaisi ja nopeuttaisi postin lajittelua ja jakamista. Kun teknologiat kypsyvät siihen pisteeseen, että niiden käyttöä voidaan vakavasti harkita useimmissa käyttökohteissa, tulevat mobiilirobotit ja autonomiset ajoneuvot yleistymään nopeasti.

5. YHTEENVETO

Onko lidarin käyttö autonomisissa laitteissa kartoitukseen ja paikannukseen tuohon tuomittua? Tässä työssä käytiin läpi lidarin toimintaa ja siihen kohdistuvia ongelmia, joista tärkeimpiä lienevät lidarin kallis hinta sekä toimintakyky dynaamisessa ympäristössä. Esimerkiksi sumu heikentää lidarin toimintaa huomattavasti (Bernardin et al. 2019). Hintansa puolesta lidar on työssä esitellyistä teknologioista kalliimmassa päässä. Lidaria käytetään jo moneen tarkoitukseen, myös autonomisen liikenteen ja mobiilirobottien ulkopuolella, joten sen voidaan todeta olevan teknologiana kypsä. Lidar on hyvä tunnistamaan muotoja, kuten esimerkiksi tien reunoja, koska lidar-sensorit voivat tuottaa tarkkaa etäisyystietoa nopeasti. Tähän tarkkuuteen ja nopeuteen syynä on lidarin toimintaperiaate, joka perustuu valonsäteiden heijastumien mittaamiseen. Lidar yksinään ei kuitenkaan pysty havaitsemaan ympäristöstä kaikkea tarvittavaa informaatiota, kuten liikennemerkkien sisältöä tai pintojen materiaaleja. Autonomisten laitteiden tulee aina olla turvallisia käyttäjilleen ja ulkopuolisille henkilöille, ja lidar yksinään ei pysty turvallisuutta täysin takaamaan.

Lidarin toiminnan tukena voi toimia tietysti myös muita sensoreita ja teknologioita, jotka parantavat kerätyn tiedon määrää ja laatua. Esimerkiksi kamerat voivat tulkita liikennemerkkejä, tunnistaa ajoneuvotyyppisiä tai huomata tehtaan lattialla olevan lätkön. Kameroiden avulla autonomiset laitteet voivat siis toimia ympäristössään turvallisemmin. Kameroita varten on kehitetty jo useampia paikannus- ja kartoitusalgoritmeja, ja kameroita voi käyttää melko joustavasti. Esimerkiksi jo yhdellä kameralla voidaan luoda kartta ympäristöstä (Davison et al. 2007). Toisaalta kameroita voi myös asentaa useamman yhteen autonomiseen laitteeseen (Tesla 2022a). Tämä joustavuus ja matala hinta tekevät kameroista paremman vaihtoehdon sekä autonomisiin ajoneuvoihin että mobiilirobotteihin. Lidarin tavoin kameroiden käyttö dynaamisissa ympäristöissä on kuitenkin haasteellista, sillä myös kamerat vaativat suoran näkölinjan kohteeseen sen havaitakseen. Lisäksi kuvamateriaalin tallentaminen myöhempää käyttöä varten on ongelmallista, koska materiaalia tulee helposti enemmän kuin sille on varattu tallennustilaa.

Teollisuuden mobiilirobottien vaatimukset ovat yleensä yksinkertaisempia kuin autonomisen liikenteen. Mobiilirobottien paikannus- ja kartoitusteknologiaksi voi muuttumattomassa ympäristössä riittää esimerkiksi työssä esitelty RFID- tai radar-paikannus. Nämä teknologiat voivat olla yksinään riittäviä erityisesti silloin, kun ympäristö on ihmisistä vapaa, sillä RFID ja radar eivät yksinään pysty tulkitsemaan ihmisen

läsnäoloa. Radaria käytetään myös ajoneuvoissa, esimerkiksi vakionopeudensäätimissä, koska se pystyy mittaamaan etäisyyksiä lidaria paremmin sumunkin lävitse (Hong et al. 2021). Autonomisissa ajoneuvoissa tullaankin todennäköisesti käyttämään useamman sensorin ja teknologian yhdistelmää, joihin radar ja kamerat lukeutuvat.

Akustinen sekä verkkoyhteyksiin pohjautuva paikannus on tarkkuudeltaan huonoa. Tämän takia niiden käytettävyys autonomisissa laitteissa on tässä työssä esitetyistä teknologioista huonointa. Akustista paikannusta voidaan kuitenkin hyödyntää näkövammoista kärsivien ihmisten apuna (Cristea et al. 2019), ja verkkoyhteyksiin pohjautuvaa paikannusta mobiililaitteissa. Teknologioina ne eivät siis ole missään nimessä turhia, mutta eivät sovellu parhaiten autonomisiin laitteisiin.

Koska kameroiden käyttö on hyvä valinta autonomisissa laitteissa, tulee tulevaisuuden kehitys kohdistumaan niihin ja niitä ympäröiviin teknologioihin, kuten tekoälyyn. Autonomisia laitteita ei vielä käytetä laajasti, vaikka mobiiliroboteille olisi jo paljon käyttökohteita. Kasvavan kysynnän myötä kehitys painottuu todennäköisesti kamerapohjaisten paikannus- ja kartoitusmenetelmien luotettavuuden parantamiseen. Kehitys laskentatehon osalta jatkuu myös, josta hyvä esimerkki ovat lähiakana ilmestyneet analogiset prosessorit.

Tehty kirjallisuustutkimus on onnistunut tavoitteiden mukaisesti. Työssä esitellyistä teknologioista löytyi selkeitä haittoja ja hyötyjä. Kamerat ovat hyvä valinta autonomisten laitteiden paikannukseen ja kartoittamiseen, ja todennäköisesti Tesla käyttää kameroita tähän tarkoitukseen syystäkin. Teknologiat ovat kuitenkin usein kaupallisia, joten tutkimustyössä on jouduttu käyttämään paljon kaupallisia lähteitä. Lähteissä on siis voitu käyttää kaunisteltua kieltä teknologioiden kyvykkyydestä, ja tutkimuksen laatu olisi todennäköisesti parantunut, jos tutkimustyötä olisi tehty myös esitellyillä teknologioilla reaali maailmassa.

LÄHTEET

- Adams, T., Brack, C., Brownlie, R., Farrier, T. & Pontl, D. (2011). So You Want to Use LiDAR? - A Guide on How to Use LiDAR in Forestry. New Zealand journal of forestry (New Zealand Institute of Forestry) pp. 19–23.
- Adams, M., Jose, E., Mullane, J. & Vo, B. (2012). Robotic Navigation and Mapping with Radar. Artech House. p. 285.
- Adheen, A. & Venkataraman, D. (2013). A Survey on Sensing Methods and Feature Extraction Algorithms for Slam Problem. International journal of computer science, engineering and applications. Vol.3 (1). pp. 59–63.
- Ankeny, J. (2013). Apple Acquires Indoor Mapping Startup WifiSLAM. FierceMobileContent. <https://www.proquest.com/docview/1466497600?accountid=14242> Luettu 20.03.2022
- Ball, D., Corke, P., Heath, S., Milford, M., Wiles, J. & Wyeth, G. (2013). OpenRatSLAM: An Open Source Brain-Based SLAM System. Autonomous robots. Vol.34. pp. 149–150. <https://doi.org/10.1007/s10514-012-9317-9>
- BeamNG GmbH (2022). About Our Technology. <https://web.archive.org/web/20220311233307/https://beamng.tech/> Luettu 8.3.2022.
- Benewake. (2019). LiDAR in Adaptive Cruise Control (ACC). <https://web.archive.org/web/20200814195856/http://en.benewake.com/news/detail/5ca572a54d839408076b6141.html> Luettu 20.2.2022.
- Bernardin, F., Colomb, M. & Duthon, P. (2019). Light Transmission in Fog: The Influence of Wavelength on the Extinction Coefficient. Applied sciences. Vol.9. (14) pp. 16–17 <https://doi.org/10.3390/app9142843>
- Buehler, M., Iagnemma, K. & Singh, S. (2009). The DARPA Urban Challenge Autonomous Vehicles in City Traffic. Springer Berlin Heidelberg. Vol.1, pp. 188–190. <https://doi.org/10.1007/978-3-642-03991-1>
- Castle, R.O., Klein, G. & Murray, D.W. (2010). Combining monoSLAM with Object Recognition for Scene Augmentation Using a Wearable Camera. Image and vision computing. Vol.28. pp. 1548–1556. <https://doi.org/10.1016/j.imavis.2010.03.009>
- Chandramouli, Das, A., Dutt, S. & Subramanian. (2018). Machine Learning. Pearson Education India. Vol.1.
- Davison, A.J., Molton, N.D., Reid, I.D. & Stasse, O. (2007). MonoSLAM: Real-Time Single Camera SLAM. IEEE transactions on pattern analysis and machine intelligence pp. 1052–1067. <https://doi.org/10.1109/TPAMI.2007.1049>
- Evers, C. & Naylor, P. (2018). Acoustic SLAM. IEEE/ACM Transactions on Audio, Speech, and Language Processing. Vol.26 (9). pp. 1484–1485. <https://doi.org/10.1109/TASLP.2018.2828321>
- Flamm, K. (2018). Measuring Moore's Law : Evidence from Price, Cost, and Quality Indexes. National Bureau of Economic Research. pp. 11–12.

- Gang, L., Hu, J., Zhang, L. & Zhang, M. (2017). Automatic Road Marking Recognition for Intelligent Vehicle Systems Application. *Advances in mechanical engineering*. Vol.9. pp. 1–10. <https://doi.org/10.1177/1687814017706267>
- Hawkins, A.J. (2018). Elon Musk still doesn't think LIDAR is necessary for fully driverless cars. *The Verge*. <https://web.archive.org/web/20220419005406/https://www.theverge.com/2018/2/7/16988628/elon-musk-lidar-self-driving-car-tesla> Luettu 20.2.2022.
- Heinrich, S. (2017). Flash Memory in the emerging age of autonomy. *Proceedings of the Flash Memory Summit*. pp. 7–10. https://web.archive.org/web/20220320072015/https://www.flashmemorysummit.com/English/Collaterals/Proceedings/2017/20170808_FT12_Heinrich.pdf Luettu 12.03.2022
- Hong, Z., Petillot, Y., Wallace, A. & Wang, S. (2021). Radar SLAM: A Robust SLAM System for All Weather Conditions. *arXiv*. p. 1.
- Hunter, J.E., Tugcu, M., Wilkes, M. & Xiaochun, W. (2009). Exploration of Configural Representation in Landmark Learning Using Working Memory Toolkit. *Pattern recognition letters*. Vol.30. pp. 66–79. <https://doi.org/10.1016/j.patrec.2008.09.002>
- Jiang, Q., Qiu, F., Tian, Z., Zhang, Q. & Zhou, M. (2015). WLAN Localization Without Location Fingerprinting Using Logic Graph Mapping. *The Proceedings of the Third International Conference on Communications, Signal Processing, and Systems. Lecture Notes in Electrical Engineering*. Vol.322. https://doi-org.libproxy.tuni.fi/10.1007/978-3-319-08991-1_56
- Kleiner, A., Nebel, B. & Prediger, J. (2006). RFID Technology-Based Exploration and SLAM for Search And Rescue. *IEEE/RSJ International Conference on Intelligent Robots and Systems*. pp. 4054–59. <https://doi.org/10.1109/IROS.2006.281867>
- Lawler, R. (2017). StartX, the accelerator for Stanford-affiliated entrepreneurs, gets a new CEO. *TechCrunch*. <https://web.archive.org/web/20210615065611/https://techcrunch.com/2017/03/08/startx-new-ceo/> Luettu 20.3.2022.
- Liu, Y., Tian, Z., Wang, Y. & Zhou, M. (2019). An Information-Theoretic View of WLAN Localization Error Bound in GPS-Denied Environment. *IEEE Transactions on Vehicular Technology* Vol.68 p. 4089. <https://doi.org/10.1109/TVT.2019.2896482>
- Mann, J., R. Menke, R., Oncley, S.P., Vasiljević, N. & Wagner, J. (2020). Multi-lidar wind resource mapping in complex terrain. *Wind Energy Science*. Vol.5, pp. 1059–1073. <https://web.archive.org/web/20220309100725/https://wes.copernicus.org/articles/5/1059/2020/> Luettu 20.2.2022
- Melvin, W. & Scheer, J. (2014). *Principles of Modern Radar. Volume III, Radar Applications*. SciTech Publishing. pp. 543–549, 591–594.
- Milford, M.J. (2013). Visual Route Recognition with a Handful of Bits. *Robotics: Science and Systems*. Vol.8. pp. 297–304.
- Milford, M.J., Prasser, D. & Wyeth, G.F. (2004). RatSLAM: a Hippocampal Model for Simultaneous Localization and Mapping. *IEEE International Conference on Robotics and Automation*. Vol.1. p. 403 <https://doi.org/10.1109/ROBOT.2004.1307183>

Milford, M.J. & Wyeth G.F. (2012). SeqSLAM: Visual Route-Based Navigation for Sunny Summer Days and Stormy Winter Nights. IEEE International Conference on Robotics and Automation. pp. 1644. <https://doi.org/10.1109/ICRA.2012.6224623>

Misikangas, P., Myllymäki, P., Roos, T., Sievänen, J. & Tirri, H. (2002). A Probabilistic Approach to WLAN User Location Estimation. International Journal of Wireless Information Networks. Vol.9. pp. 155–162 <https://doi.org/10.1023/A:1016003126882>

Montemerlo, M. & Thrun, S. (2007). FastSLAM: A Scalable Method for the Simultaneous Localization and Mapping Problem in Robotics. Springer Berlin Heidelberg. Vol.27. pp. 27–90. <https://doi.org/10.1007/978-3-540-46402-0>

Mythic (2021). AN EVOLUTION IN POWER MANAGEMENT WITH MYTHIC'S ANALOG MATRIX PROCESSOR. <https://web.archive.org/web/20220316011825/https://www.mythic-ai.com/an-evolution-in-power-management-with-mythics-analog-matrix-processor/> Luettu 26.3.2022

Nature (1943). RADIO DETECTION AND RANGING. Nature. Vol.152. pp. 391–392. <https://doi.org/10.1038/152391b0>

NOOA (2021). What is lidar? <https://web.archive.org/web/20220422165445/https://oceanservice.noaa.gov/facts/lidar.html> Luettu 20.2.2022.

Cristea, M., Cristea, S., O'Reilly, J. & Zhang, J. (2019). A Novel Development of Acoustic SLAM. 2019 International Aegean Conference on Electrical Machines and Power Electronics (ACEMP) & 2019 International Conference on Optimization of Electrical and Electronic Equipment (OPTIM). p.525. <https://doi.org/10.1109/ACEMP-OP-TIM44294.2019.9007217>

Ross, P.E. (2020). Velodyne Will Sell a Lidar for \$100. IEEE Spectrum. <https://web.archive.org/web/20220331214852/https://spectrum.ieee.org/velodyne-will-sell-a-lidar-for-100> Luettu 22.2.2022.

Sharabok, G. (2020). Why Tesla Won't Use LIDAR. Towards Data Science. <https://towardsdatascience.com/why-tesla-wont-use-lidar-57c325ae2ed5> Luettu 01.03.2022

Shi, J. & Zhou, J. (2008). RFID Localization Algorithms and Applications—a Review. Journal of Intelligent Manufacturing. Vol.20. pp. 695–698. <https://doi.org/10.1007/s10845-008-0158-5>

Taheri, H., & Xia, Z.C. (2021). SLAM; Definition and Evolution. Engineering Applications of Artificial Intelligence. Vol.97. p. 16 <https://doi.org/10.1016/j.engappai.2020.104032>

Tesla (2022). Autopilot. <https://web.archive.org/web/20220404132034/https://www.tesla.com/autopilot> Luettu 4.4.2022

Tesla (2022). Artificial Intelligence & Autopilot. <https://web.archive.org/web/20220309090811/https://www.tesla.com/AI> Luettu 8.3.2022.