

Atte Jokinen

Kasvilajien luokittelu kuvantunnistuksen avulla

Tietotekniikan kandidaatintutkielma

16. toukokuuta 2024

Jyväskylän yliopisto

Informaatioteknologian tiedekunta

Tekijä: Atte Jokinen

Yhteystiedot: atte.s.jokinen@student.jyu.fi

Työn nimi: Kasvilajien luokittelu kuvantunnistuksen avulla

Title in English: Plant species classification using image recognition

Työ: Kandidaatintutkielma

Sivumäärä: 19+0

Tiivistelmä: Kirjallisuuskatsaus kuvantunnistuksen käyttämisestä kasvilajien luokittelussa

Avainsanat: L^AT_EX, gradu3, kuvantunnistus,

Abstract: Literature review of plant species classification using image recognition

Keywords: L^AT_EX, gradu3, image recognition

Sisällys

1	JOHDANTO	1
2	KIRJALLISUUSKATSAUS.....	2
3	TUTKIMUKSEN TILA	3
4	SOVELLUKSET KÄYTÄNNÖSSÄ.....	8
5	YHTEENVETO.....	11
	LÄHTEET	13

1 Johdanto

Kasvilajien luokittelu voi olla haastavaa ja vaatii asiantuntemusta. Kasvien tunnistamisesta on hyötyä esimerkiksi maataloudessa ja itämaisten lääkekasvien tai uhanalaisten lajien tunnistamisessa, joten kasvien luokittelusta voi olla paljonkin taloudellista hyötyä. Invasiivisten kasvien tunnistaminen kuvista voi taas olla ympäristön kannalta hyvinkin tärkeää. Koneoppiminen ja kuvantunnistaminen voi tehdä luokittelusta paljon helpompaa ja se mahdollistaa monenlaisten sovelluksien tuottamisen.

Kasvilajien luokittelusta on jo olemassa paljon tutkimusta ja myös kirjallisuuskatsauksia. Tävoitteenani on siis tutkia mikä on tutkimuksen nykyinen tila ja missä on vielä kehityskohtia. Tutkimus tapahtuu kirjallisuuskatsauksen muodossa.

Tutkimuksen aiheena on kuvantunnistuksen käyttäminen kasvilajien luokittelussa. Aiheesta on olemassa olevaa tutkimusta, jota käyn läpi kirjallisuuskartoituksella. Olemassa on myös tuoreita kirjallisuuskatsauksia, joista löytyy lähteitä omaan tutkimukseen. Pysin tutkimuksessa tutkimaan aiheen nykyistä tilaa sekä mahdollisia ongelmakohtia tulevan tutkimuksen aiheeksi. Lisäksi mielenkiintona on aiheen sovellukset käytännössä. Sovelluksia on tutkittu erityisesti maanviljelyn ja metsänhoidon tarpeita varten.

Lähteiden hakemiseen käytetään pääosin Google Scholaria ja hakulauseena toimii "picture recognition plant species classification". Hakulause tulee vaihtelevaan tutkimuksen aikana, mutta pysyy pääosin samana.

2 Kirjallisuuskatsaus

Kasvien luokitteluun liittyen löytyy paljon tutkimusta. Tutkimuksissa on yleisesti käytetty CNN-mallia tai sen johdannaisia ja tulokset ovat päätyneet yli 90% tarkkuuteen. Tulevaisuuden haasteina tuntuu olevan kasvien tunnistaminen luonnollisessa ympäristössä ja muiden kasvien seasta, sekä muiden sovelluksien yhdistäminen kokonaisuudeksi. Nykyinen tutkimus kykenee hyvin tunnistamaan yksittäisiä lehtiä neutraalia taustaa vasten. Osa tutkimuksista keskittyvät sovelluksien kehittämiseen (Reda ym. (2022), Weiss ym. (2010)), osa taas matalamman tason ongelmien ratkomiseen (Lee ym. (2017), Pahikkala ym. (2015)).

Mielenkiintoa tutkimukseen löytyy esimerkiksi maatalouden potentiaalisen taloudellisen hyödyn ansiosta. Kasvien automaattinen luokittelu voi olla myös ympäristön kannalta tulevaisuudessa merkittävää, kun esimerkiksi lannoitteiden ja hoitoaineiden käyttö vähenee. Uusien kasvilajien tai invasiivisten kasvilajien tunnistaminen myös helpottuu, eikä siihen enää välttämättä vaadita ammattilaista.

Tulevaisuuden sovelluksien rakentamisessa yhdistyy monia tieteenaloja, kun tarvitaan tietoa kasveista, koneoppimisesta ja robotiikasta. Sovelluksien kehittämistä varten tarvitaankin enemmän poikkitieteellistä tutkimusta. (Weiss ym. 2010) ja (Boubin ym. 2019) käsittelevät tutkimuksissaan potentiaalia autonomisille maatalouskoneille, mutta sen tutkimus tuntuu olevan vielä vähäistä.

3 Tutkimuksen tila

Wu ym. (2007) julkaisivat tutkimuksen, jossa he luokittelivat kasveja probabilistisen neuroverkon avulla. Tutkimuksen yhteydessä he julkaisivat tietoaaineistonsa, jota alettiin sanoa Flavia-tietoaaineistoksi. Siitä on tullut vuosien varrella yksi käytetyimmistä tietoaaineistoista kasvilajien tunnistamisessa ja sitä käytetään laajasti kuvantunnistusmallien testaamisessa. Huomattava osa jatkossa viitattavista tutkimuksista käyttää Flavia-tietoaaineistoa mallinsa kouluttamiseen ja testaamiseen. Tutkimuksen malli pääsi noin 90% tarkkuuteen, mutta nykyään mallit yltävät jo melkein 100% tarkkuuteen samalla tietoaaineistolla.

Toinen laajasti käytetty tietoaaineisto on ‘Swedish Leaf’-tietoaaineisto, jonka Söderkvist (2001) julkaisi gradussaan. Sitä on käytetty Flavia-tietoaaineiston ohella suuressa osassa tutkimuksista, joissa luokitellaan kasvilajeja. Tietoaaineistot, jotka koostuvat lehtien kuvista, auttavat luokittelumallien vertailua toisiinsa ja antaa tutkijoille viitettä mallin laadusta. Käytännön sovelluksia varten tarvitaan tosin laajempia tietoaaineistoja, joissa on myös kuvia kasveista luonnollisessa ympäristössä. Tutkimuksen malli ei ollut kovin tarkka nykyisiin malleihin verrattuna. Jotkut lajit tunnistettiin jopa vain 36% tarkkuudella, kun nykyiset mallit toimivat jopa lähes 100% tarkkuudella.

Wäldchen ja Mäder (2018a) mukaan kuvantunnistus toimii erottelemalla kuvasta ominaisuuksia (‘features’), kuten tiettyjä muotoja, tekstuureja tai värejä. Kuvantunnistusmalli oppii tunnistamaan kuvasta relevantit ominaisuudet ja niiden avulla luokittelemaan kuvan kohteita. Kuvantunnistuksessa yleinen malli on konvoluutioneuroverkko (‘CNN’), jota ollaan kehitetty jo 80-luvulta. Uudet CNN-mallit ovat tarkkuudeltaan jo ihmisen tasolla.

Dalvi ja Kalbande (2023) kirjoittavat, että CNN-neuroverkot kykenevät jopa 98% tarkkuuteen kasvilajien luokittelussa. Niissä tosin on käytetty tunnistamiseen kuvaa pelkästä kasvin lehdestä ja kirjoittajien mukaan tutkimusta pitäisi laajentaa käsittämään useita kasvin osia (lehdet, juuret, siemenet) samanaikaisesti. Moniattribuuttisella tunnistamisella on potentiaalia olla sekä robustisempi että tarkempi kuin esimerkiksi pelkkää lehteä tunnistamiseen käyttävä malli, mutta vaatii suurempaa tietoaaineistoa ja ennakkokäsittelyä.

Kanda, Xia ja Sanusi (2021) käyttävät tutkimuksessaan generatiivisesti kilpailevaa neuro-

verkkoa ('GAN'), joka luo tietoaaineiston perusteella kuvia lehdistä. Heillä on myös CNN-malli, joka tunnistaa onko kuva aito. Sen perusteella luodaan uusia kuvia ja mallit kehittyvät yhdessä tarkemmaksi. Lopullinen malli kykeni luokittelemaan tarkasti eri lehtitietoaaineistojen lehdet.

Lee ym. (2017) käyttävät tutkimuksessaan myös CNN-neuroverkkoa ja heidän mukaansa lehden muoto ei ole lehden kriittisin ominaisuus kasvien tunnistamisessa, vaan lehden suonet. Heidän mukaansa lehden muoto on kuitenkin yleisimmin käytetty ominaisuus kasvien luokittelussa, koska se on helpoin ja ilmeisin ominaisuus tutkia. Heidän mallinsa ylittää myös noin 98% tarkkuuteen ja virheelliset luokittelut olivat toisiaan läheisiä saman sukuisia lajeja. He kokeilivat uudelleen samaa mallia, mutta kouluttivat sen kokonaisten lehtien sijaan leikatuilla osilla lehdistä. Tällöin lehden muoto ei vaikuttanut mallin kouluttamiseen ja sen tarkkuus nousi 99.5 prosenttiin. Tämä metodi toimii käytännön sovelluksissa paremmin, koska luonnossa lehdet ovat toistensa kanssa limittäin, jolloin lehden muoto ei ole tarkasti nähtävissä.

Siravenha ja Carvalho (2016) tutkivat kasvin tunnistamista lehden suonien perusteella. He pääsivät parhaimmillaan noin 91% tarkkuuteen. Heidän prosessissa lehden ominaisuudet kerättiin manuaalisesti ja luokitteluun käytettiin itse rakennettua neuroverkkoa. CNN-mallilla ominaisuuksien tunnistaminen on automaattista ja se pääsee tarkempiin tuloksiin, joten se on tähän verrattuna parempi.

Wei Tan ym. (2018) käyttivät tutkimuksessaan myös lehden suonia lajin ominaisuutena. Heidän kokeilemistään malleista parhaiten pärjäsi 'AlexNet', joka on esikoulutettu CNN-malli. Se pääsi yli 95% tarkkuuteen. Kolivand ym. (2019) tutkivat myös kasvin tunnistamista lehden suonien avulla. He pääsivät jopa 99% tarkkuuteen tunnistettaessa yksittäisiä lehtiä eri kasvisuvuista. Kun yritettiin luokitella samansukuisia vaahteroita, heidän mallinsa päätyi 91% tarkkuuteen. Ambarwari ym. (2020) käyttivät Support Vector Machine -mallia ('SVM') kasvin luokitteluun. He käyttivät myös lehden suonia lajin ominaisuutena. Heidän mallin tarkkuus oli keskimäärin 84%, mikä on huomattavasti vähemmän kuin CNN-mallin tarkkuus samoilla tietoaaineistoilla. CNN-mallin koulutus vaatii enemmän laskutehoa, mutta vaikuttaa olevan kaikin muin tavoin parempi kuin SVM.

Wäldchen ja Mäder (2018b) mukaan valtaosa heidän läpikäymistään tutkimuksista käytti kasvin lehtiä lajin luokiteluun. Pieni osa tutkimuksista käytti kasvin kukkia lajin tunnistamiseen. Suurin osa tutkimuksien käyttämistä kuvista oli neutraalilla taustalla, joten niiden tarkkuus käytännössä tuskin ylittää samalle tasolle.

Iso osa tutkimuksista käyttää kasvien tunnistamiseen kuvaa lehdestä neutraalia taustaa vasten. Pahikkala ym. (2015) tutkivat kasvien tunnistamista kuvista, joissa on useita lehtiä limittäin toistensa kanssa ja useita eri lajeja. Heidän tutkimuksessaan käyttämät kasvit olivat väritään hyvin lähellä toisiaan, joten väriin perustuva tunnistaminen ei onnistunut. Kuvissa lehdet olivat limittäin, minkä takia lehtien muoto oli suurimman osan ajasta piilossa. Tämä teki kasvien luokittelun myös lehtien muodon avulla haastavaksi. Tällöin kasvien tunnistaminen lehden tekstuurin perusteella jää kirjoittajien mukaan parhaaksi tavaksi tunnistaa kasveja luonnollisissa olosuhteissa. He pääsivät tutkimuksessaan tekstuuriin perustuvalla tunnistamisella 98% tarkkuuteen.

Aiemmin mainituista tutkimuksista moni pääsi 98-99.5% tarkkuuteen, kun tunnistettiin pelkkää kasvin lehteä. Tarkkuus heikkenee, kun yritetään tunnistaa kokonaista kasvia muiden kasvien keskellä. Kasvin tunnistaminen lehden tekstuurin tai suonien perusteella on tällöinkin mahdollista, mutta tällöin lehden muoto pitäisi jättää kokonaan huomiotta tunnistamisessa. Reda ym. (2022) kirjoittivat tekemästään mobiilisovelluksesta, joka kykenee tunnistamaan sekä kasvin lajin, että mahdollisen kasvitaudin mikä kasvilla on. Tämä näyttää, että sovellus on mahdollista pienillä laitteilla ja niillä on muitakin potentiaalisia käyttökohteita kuin pelkkä kasvilajien tunnistaminen.

Pereira, Morais ja Reis (2019) pyrkivät tutkimuksessaan tunnistaa viinirypälälajeja toisistaan lehden perusteella esikoulutettua CNN-mallia käyttämällä. Heidän mallinsa tarkkuus kärsi moneen muuhun tutkimukseen verrattuna, koska heidän tietoaineistonsa koostui luonnollisessa ympäristössä otetuista kuvista. Kuviin tulee maasta ja mahdollisesti muista kasveista melua, joka vaikeuttaa mallin koulutusta ja luokittelun tarkkuutta. Tarkkuutta parannetaan käyttämällä esikoulutettua mallia ja suurempaa tietoaineistoa. Viinilajien tunnistaminen voisi auttaa vähentämään työntekijäkustannuksia, jotka ovat viinin valmistamisessa huomattavia.

Abdullahi, Sheriff ja Mahieddine (2017) tutkivat terveiden kasvien erottamista epäterveistä. He käyttivät esiopetettua CNN-mallia, jonka he kouluttivat erottamaan terveitä ja epäterveitä kasveja. He pääsivät tutkimuksessaan parhaimmillaan yli 99% tarkkuuteen. Esikoulutetun mallin käyttäminen teki tietoaaineiston soveltamisesta helpompaa, nopeampaa ja halvempaa myös pienemmällä tietoaaineistolla. Tutkijat mainitsevat mallin potentiaalin esimerkiksi itseajavien traktoreiden ohjelmistoon integroituna.

Alimboyong, Hernandez ja Medina (2018) tutkivat nuorten taimien erottamista toisistaan ja väittävät päässeensä yli 99% tarkkuuteen. He käyttivät AlexNet-mallia, joka tunnisti jotkut lajit jopa 100% tarkkuudella. Korkea tarkkuus kuitenkin vaatii suuren tietoaaineiston ja paljon laskutehoa. Villaruz ym. (2018) myös tutkivat taimien luokittelua esikoulutettuja malleja käyttämällä. Heillä oli käytössä AlexNet, Googlen GoogLeNet ja Microsoftin ResNet50. Tietoaaineistona käytettiin tutkijoiden ottamia kuvia heidän kasvattamistaan kasvien taimista. Heidän tutkimuksessaan ResNet50 toimi parhaiten, melkein 99% tarkkuudella. Kaikki mallit olivat kuitenkin melko tarkkoja pienelläkin määrällä koulutuskuvia.

Nkemelu, Omeiza ja Lubalo (2018) tutkivat myös kasvien taimien luokittelua. He kehittivät CNN-mallin, jota verrattiin muihin koneoppimismalleihin ja malli ylsi koulutusdatalla yli 98% tarkkuuteen. Tutkimuksessa käytettiin julkista tanskalaista tietoaaineistoa (Giselsson ym. 2017). Tutkimus oli afrikkalaisten tutkijoiden tekemä, joten heille tanskalaisten kasvien luokittelulla on rajallinen hyöty. Tutkimuksessa listattiinkin yhdeksi tulevaisuuden kehityskohdaksi afrikkalaisten kasvien kerääminen tietoaaineistoksi.

Kaya ym. (2019) käsitelivät myös tutkimuksessaan esikoulutettujen mallien käyttöä kasvilajien luokittelun koulutuksessa. He kokeilivat viittä eri luokittelumallia ja pääsivät parhaimmillaan yli 99% tarkkuuteen. Alusta asti itse koulutettu malli ei pärjännyt millekään esikoulutetulle mallille, varsinkin kun kyseessä oli pieni tietoaaineisto. Esikoulutettujen mallien käyttäminen siis mahdollistaa pienempien tietoaaineistojen käyttämisen ilman, että tarkkuus kärsii huomattavasti. Siddharth, Kirar ja Agrawal (2022) käyttivät tutkimuksessaan VGG19-mallia, joka on sama kuin edellisen tutkimuksen parhaiten pärjännyt malli. Heidän malli oli samalla tietoaaineistolla suurin piirtein yhtä tarkka ja pääsi melkein 100% tarkkuuteen. Käytännössä mallin hyöty on kuitenkin vähäinen, koska käytössä olleen Swedish Leaf -tietoaaineiston kuvat koostuvat vain yksittäisistä lehdistä.

Hassan ym. (2021) tutkivat esikoulutettujen CNN-mallien eroa kasvien taimien luokittelussa. Heidän tutkimuksessaan VGG19 antoi tarkimman tuloksen yli 97% tarkkuudella. Kuitenkin myös Inception- ja ResNet-mallit olivat tarkkuudeltaan lähes yhtä hyviä.

4 Sovellukset käytännössä

Wäldchen ja Mäder (2018b) mainitsevat kirjallisuuskatsauksessaan useita olemassa olevia sovelluksia kasvilajien luokitteluun. Heidän läpi käymissään tutkimuksissa valtaosa toteutuksista oli mobiilisovelluksia, osa tietokoneohjelmia tai verkkosovelluksia. Myös kuluttajille on olemassa puhelinohjelmia, joita voi käyttää kasvien tunnistamiseen. Tutkimuksen julkaisun aikaan oli tosin vasta kolme julkisesti saatavilla olevaa puhelinohjelmaa, joiden tarkkuus ei kirjoittajien mukaan ollut vielä kovin tarkka.

Weiss ym. (2010) tutkivat 3D-sensorin käyttöä kasvien tunnistamisessa ja ehdottavat sen soveltamista esimerkiksi pienillä roboteilla. Robotit voisivat tutkilla luokitella kasveja ja tarpeen mukaan hoitaa kasveja tai hankkiutua rikkaruohoista eroon. Siitä syntyisi säästöjä muun muassa lannoitteiden ja rikkaruohomyrkkujen tarpeen vähentyessä. Tämä tutkimus oli osa RoniRob-hanketta, jossa oli tarkoituksena rakentaa autonominen robotti maanviljelyn avuksi.

Pahikkala ym. (2015) mainitsevat myös kuvantunnistamisen käytön maataloudessa. Se voi muuttaa maanviljelyä ympäristöystävällisemmäksi ja taloudellisemmaksi, kun rikkaruohojentorjunta-aineita säästyy jopa 94%. Heidän mukaansa kuitenkin käytännön sovellukset ovat vielä harvinaisia rikkaruohojen tunnistamiseen ja torjuntaan. Tulevaisuuden haasteina tulee olemaan sellaisen laitteen rakentaminen, joka tunnistaa kasvit ja osaa autonomisesti hoitaa tai torjua kasveja.

Olsen ym. (2019) julkaisivat tietoaaineiston, joka sisältää kuvia australialaisista rikkaruoholajeista. Aineisto sisältää kuvia sekä yksittäisistä lehdistä, että kokonaisista kasveista luonnollisissa olosuhteissa. Heidän tarkoituksena on auttaa kehittämään autonomista kasvientorjuntarobottia, joka osaisi erottaa rikkaruohot haastavammassakin olosuhteissa. He olivat jopa suunnitelleet prototyypin, joka osaisi tunnistaa kasvin ja tarvittaessa suihkuttaa rikkaruohot kasvintorjunta-aineella. Leminen Madsen ym. (2020) julkaisivat tietoaaineiston yleisistä tanskalaisista rikkaruoholajeista tarkoituksenaan auttaa maatalouden sovelluksien rakentamisessa. Kirjoittajien mukaan avoimet tietoaaineistot ovat kriittisiä tutkimuksien vertailua ja validointia varten.

Sunil ym. (2022) kirjoittavat kuvantunnistuksen käyttämisestä kasvihuoneissa. He tutkivat rikkaruohojen tunnistamista hyötykasvien seasta. He käyttivät tutkimuksessaan Support Vector Machine -mallia ('SVM'). Mallia verrattiin myös CNN-malliin, joka oli hiukan tarkempi kuin SVM. Tutkimuksessa todettiin, että vaikka molemmat mallit olivat melko tarkkoja, CNN oli tarkempi ja sen käyttäminen vaatii vähemmän työtä. Tutkimuksen tietoaaineisto koostui kuvista, joissa oli sekä rikkaruohoja, että hyötykasveja. Vaikka aineisto on haastava koulutettavaksi, tarkkuus oli kuitenkin yli 90%.

Sekä Dalvi ja Kalbande (2023), että Lee ym. (2017) mainitsevat tutkimuksissaan kasvien merkityksen lääketieteelle. Oli se sitten luontaista ”vaihtoehtolääketiedettä” tai uusien lääkeaineiden löytämistä, kuvantunnistamisella on paljon potentiaalia tällä saralla. Automaattinen tunnistaminen tehostaa kasvien löytämistä ja mahdollistaa maallikollekin tulonlähteen. Vastuullisuus on kuitenkin tärkeää, ettei myrkyllisiä kasveja päädy kulutukseen tai oikean lääketieteen ratkaisuja jää käyttämättä.

Deshmukh (2024) kirjoittavat myös kuvantunnistuksen merkityksestä Intialaisten lääkekasvien löytämisessä. He kokeilivat eri malleja kasvien luokitteluun, mutta jälleen CNN oli kaikista tarkin melkein 99% tarkkuudella. Tietoaaineisto koostui kuvista yksittäisistä lehdistä, joten mallin hyöty jää rajalliseksi. Duong-Trung ym. (2019) tutkivat myös lääkekasvien tunnistamista. He käyttivät tutkimuksessaan esikoulutettua CNN-mallia, joka myös ylsi melkein 99% tarkkuuteen. Tietoaaineistona käytettiin kuvia vietnamilaisista kasveista ja ne olivat myös kuvia yksittäisistä lehdistä neutraalia taustaa vasten.

Mulugeta, Sharma ja Mesfin (2024) olivat tehneet kirjallisuuskatsauksen kuvantunnistuksen käyttämisestä lääkekasvien tunnistamisessa. Valtaosa käsitellyistä tutkimuksista käytti CNN-mallia lajien luokitteluun. Tutkimuksissa oli pääosin kerätty omat tietoaaineistot ja lajit tunnistettiin lehtien perusteella. Lähes kaikki tutkimuksista oli Intiasta ja muista Aasian maista.

Tulevaisuudessa lienee mahdollista kehittää täysin autonomisia ajoneuvoja, jotka tunnistavat rikkaruohot, kasvitaudit ja tuholaiset ja osaavat itsenäisesti torjua ne. Lisäksi hyötykasveihin kohdistettu lannoitus olisi mahdollista. Tällöin maanviljely tehostuisi, muuttuisi automaattisemmaksi ja vähentäisi räsitystä ympäristölle. Pienimuotoisia prototyyppirobotteja

on jo aiemmin mainituissa tutkimuksissa mainittu, mutta tulevaisuudessa voidaan rakentaa laajemman kokonaisuuden hallitsevia laitteita.

Boubin ym. (2019) käsittelevät tutkimuksessaan automaattista kasvien hoitoa, joka toteutettaisiin kauko-ohjattavien lennokkien avulla. Lennokit kartoittaisivat ilmakuvien avulla peltoa ja joko tunnistaisivat tauteja ja rikkaruohoja tai tarkkailisivat sadon määrää. He olivat simuloineet järjestelmän toimintaa käyttämällä valmiita ilmakuvia ja heidän tuloksiensa mukaan järjestelmällä on mahdollista saada säästöjä. Järjestelmä vaatii kuitenkin vielä hienosäätöä polunetsintäalgoritmin ja lennokkien energianhallinnan saralla. Kirjoittajien mukaan tulevaisuuden haasteita on myös esimerkiksi järjestelmän rakentaminen skaalattavaksi.

Ferreira ym. (2020) tutkivat puiden luokittelua ilmakuvista. He tutkivat myös lennokkien käyttöä ja yrittävät tunnistaa niiden ottamista kuvista Brasilialaisia palmuja. Puiden luokittelu on hyödyllistä metsänhoidon kannalta, kun voidaan esimerkiksi pitää kirjaa puiden lukumäärästä. He käyttivät CNN-mallia, joka tunnisti jotkut palmulajit jopa 97% tarkkuudella, mutta huonoimmillaan jopa vain 69% tarkkuudella. Tarkkuutta voidaan parantaa kasvattamalla tietoaaineistoa, mutta se voi tulla kalliiksi. Lennokit ovat tutkimuksen mukaan halpa ja tehokas keino saada ilmakuvia, joista voidaan luokitella kasveja muun muassa metsänhoidon sovelluksiin.

Lopatin ym. (2019) tutkivat miten muiden kasvien varjot vaikuttavat lennokeilla otetuissa ilmakuvissa olevien kasvien luokitteluun. Puiden varjot saattoivat johtaa jopa 100% virheelliseen luokitteluun. Ilmakuvia ottaessa pitää siis ottaa myös esimerkiksi kellonaika huomioon, jotta varjojen koko olisi mahdollisimman pieni.

5 Yhteenveto

Koneoppiminen ja kuvantunnistus on kehittynyt viime vuosina paljon ja siitä on paljon käytännön hyötyä. Kuvantunnistusta on käytetty jo kaupallisissakin sovelluksissa kasvien luokitteluun (Esimerkiksi PictureThis-puhelinsovellus). Sillä on kuitenkin paljon muitakin potentiaalisia käyttökohteita. Dalvi ja Kalbande (2023) esimerkiksi kuvailevat kuvantunnistuksen käyttöä perinteisten Intialaisten lääkekasvien tunnistukseen. Eniten taloudellista hyötyä lienee maataloudessa, jossa säästöt voivat olla huomattavia.

Alalla on paljon tutkimusta ja mallit ovat kehittyneet yhä tarkemmiksi. Moni malli kykenee tunnistamaan kasvin 98+% tarkkuudella, kun tunnistetaan yksittäistä lehteä neutraalia taustaa vasten. Tulevaisuuden tutkimusaiheita voisi olla esimerkiksi kasvin tunnistaminen luonnollisella taustalla ja eri sovellusten yhdistäminen yhdeksi kokonaisuudeksi. On jo joitakin tutkimuksia joissa pyritään kehittämään käytännön sovelluksia, mutta ne ovat vielä melko alkeellisia tai teoreettisella tasolla. Kuvantunnistus ja autonomiset ajoneuvot ovat kehittyneet lähivuosina kovaa vauhtia, joten lähitulevaisuudessa on varmasti vielä suuria harppauksia tulossa.

Jo nykyään on olemassa esimerkiksi puhelinsovelluksia joilla voi tunnistaa kasveja, mutta tärkeimmät sovellukset tulevat varmasti olemaan maataloudessa ja ympäristön suojelun saralla. Kasvien automaattinen luokittelu ja sairauksien ja tuholaisien tunnistaminen vähentää maatalouden työntekijäkustannuksia ja tehostaa kasvienhoitoaineiden käyttöä. Maailman väkiluvun kasvaessa ja maanviljelytilan kutistuessa on tärkeää pyrkiä tehokkuuteen ruoantuotannossa. Lannoitteiden ja hoitoaineiden tehokkaampi käyttö myös vähentää luonnon rehevöitymistä ja myrkkujen leviämistä ympäristöön.

Kuvantunnistuksen standardina käytetään CNN-mallia, koska sillä saa tarkimmat tulokset. Esikoulutettujen mallien käyttö on myös lisääntynyt, koska niillä saa myös pienemmällä tietoineistolla ja laskuteholla tarkan mallin. Maatalouden sovelluksia varten tarvitaan siis enää tarpeeksi laajat tietoineistot muun muuassa rikkaruohoista ja erilaisista kasvitaudeista. Viime vuosina onkin julkaistu sellaisia aineistoja, mutta ne ovat vielä lajimääriltään suhteellisen suppeita.

Tutkimuksissa on ollut kahdenlaisia vaihtoehtoja autonomista maanviljelykonetta varten. Osa tutkimuksista ehdottaa lennokkien käyttöä, osa taas maanpinnalla ajettavien kulkuneuvojen. Lennokkien etuna on laajojen alueiden kuvaaminen lyhyessä ajassa, kun taas maanpinnalla on helpompi esimerkiksi suihkuttaa rikkaruohot. Kenties molemmat yhdessä muodostavat tulevaisuuden automaattisen maatilän.

Lähteet

Abdullahi, Halimatu Sadiyah, R Sheriff ja Fatima Mahieddine. 2017. “Convolution neural network in precision agriculture for plant image recognition and classification”. Teoksessa *2017 Seventh International Conference on Innovative Computing Technology (INTECH)*, 10:256–272. Ieee New York.

Alimboyong, Catherine R, Alexander A Hernandez ja Ruji P Medina. 2018. “Classification of plant seedling images using deep learning”. Teoksessa *TENCON 2018-2018 IEEE Region 10 Conference*, 1839–1844. IEEE.

Ambarwari, Agus, Qadhli Jafar Adrian, Yeni Herdiyeni ja Irman Hermadi. 2020. “Plant species identification based on leaf venation features using SVM”. *TELKOMNIKA (Telecommunication Computing Electronics and Control)* 18 (2): 726–732.

Boubin, Jayson, John Chumley, Christopher Stewart ja Sami Khanal. 2019. “Autonomic computing challenges in fully autonomous precision agriculture”. Teoksessa *2019 IEEE international conference on autonomic computing (ICAC)*, 11–17. IEEE.

Dalvi, Prachi ja DR Kalbande. 2023. “A Comprehensive Review of Plant Recognition Approaches: Techniques, Challenges, and Future Direction”. *SSGM Journal of Science and Engineering* 1 (1): 1–5.

Deshmukh, M. 2024. “Deep Learning for the Classification and Recognition of Medicinal Plant Species”. *Indian Journal of Science and Technology* 17 (11): 1070–1077.

Duong-Trung, Nghia, Luyl-Da Quach, Minh-Hoang Nguyen ja Chi-Ngon Nguyen. 2019. “A combination of transfer learning and deep learning for medicinal plant classification”. Teoksessa *Proceedings of the 2019 4th International Conference on Intelligent Information Technology*, 83–90.

Ferreira, Matheus Pinheiro, Danilo Roberti Alves de Almeida, Daniel de Almeida Papa, Juliano Baldez Silva Minervino, Hudson Franklin Pessoa Veras, Arthur Formighieri, Caio Alexandre Nascimento Santos, Marcio Aurélio Dantas Ferreira, Evandro Orfano Figueiredo ja Evandro José Linhares Ferreira. 2020. “Individual tree detection and species classification of Amazonian palms using UAV images and deep learning”. *Forest Ecology and Management* 475:118397.

Giselsson, Thomas Mosgaard, Rasmus Nyholm Jørgensen, Peter Kryger Jensen, Mads Dyrmann ja Henrik Skov Midtiby. 2017. “A public image database for benchmark of plant seedling classification algorithms”. *arXiv preprint arXiv:1711.05458*.

Hassan, Esraa, Mahmoud Shams, Noha A Hikal ja Samir Elmougy. 2021. “Plant seedlings classification using transfer learning”. Teoksessa *2021 International Conference on Electronic Engineering (ICEEM)*, 1–7. IEEE.

Kanda, Paul Shekonya, Kewen Xia ja Olanrewaju Hazzan Sanusi. 2021. “A deep learning-based recognition technique for plant leaf classification”. *IEEE Access* 9:162590–162613.

Kaya, Aydin, Ali Seydi Keceli, Cagatay Catal, Hamdi Yalin Yalic, Huseyin Temucin ja Bedir Tekinerdogan. 2019. “Analysis of transfer learning for deep neural network based plant classification models”. *Computers and electronics in agriculture* 158:20–29.

Kolivand, Hoshang, Bong Mei Fern, Tanzila Saba, Mohd Shafry Mohd Rahim ja Amjad Rehman. 2019. “A new leaf venation detection technique for plant species classification”. *Arabian Journal for Science and Engineering* 44:3315–3327.

Lee, Sue Han, Chee Seng Chan, Simon Joseph Mayo ja Paolo Remagnino. 2017. “How deep learning extracts and learns leaf features for plant classification”. *Pattern recognition* 71:1–13.

Leminen Madsen, Simon, Solvejg Kopp Mathiassen, Mads Dyrmann, Morten Stigaard Laurson, Laura-Carlota Paz ja Rasmus Nyholm Jørgensen. 2020. “Open plant phenotype database of common weeds in Denmark”. *Remote Sensing* 12 (8): 1246.

- Lopatin, Javier, Klara Dolos, Teja Kattenborn ja Fabian E Fassnacht. 2019. “How canopy shadow affects invasive plant species classification in high spatial resolution remote sensing”. *Remote Sensing in Ecology and Conservation* 5 (4): 302–317.
- Mulugeta, Adibaru Kiflie, Durga Prasad Sharma ja Abebe Haile Mesfin. 2024. “Deep learning for medicinal plant species classification and recognition: a systematic review”. *Frontiers in Plant Science* 14:1286088.
- Nkemelu, Daniel K, Daniel Omeiza ja Nancy Lubalo. 2018. “Deep convolutional neural network for plant seedlings classification”. *arXiv preprint arXiv:1811.08404*.
- Olsen, Alex, Dmitry A Konovalov, Bronson Philippa, Peter Ridd, Jake C Wood, Jamie Johns, Wesley Banks, Benjamin Girgenti, Owen Kenny, James Whinney ym. 2019. “DeepWeeds: A multiclass weed species image dataset for deep learning”. *Scientific reports* 9 (1): 2058.
- Pahikkala, Tapio, Kim Kari, Heta Mattila, Anna Lepistö, Jukka Teuhola, Olli S Nevalainen ja Esa Tyystjärvi. 2015. “Classification of plant species from images of overlapping leaves”. *Computers and Electronics in Agriculture* 118:186–192.
- Pereira, Carlos S, Raul Morais ja Manuel JCS Reis. 2019. “Deep learning techniques for grape plant species identification in natural images”. *Sensors* 19 (22): 4850.
- Reda, Mariam, Rawan Suwwan, Seba Alkafri, Yara Rashed ja Tamer Shanableh. 2022. “Agroaid: A mobile app system for visual classification of plant species and diseases using deep learning and tensorflow lite”. Teoksessa *Informatics*, 9:55. 3. MDPI.
- Siddharth, Thiru, Bhupendra Singh Kirar ja Dheeraj Kumar Agrawal. 2022. “Plant Species Classification Using Transfer Learning by Pretrained Classifier VGG-19”. *arXiv preprint arXiv:2209.03076*.
- Siravenha, Ana C ja Schubert R Carvalho. 2016. “Plant classification from leaf textures”. Teoksessa *2016 international conference on digital image computing: techniques and applications (DICTA)*, 1–8. IEEE.
- Sunil, GC, Yu Zhang, Cengiz Koparan, Mohammed Raju Ahmed, Kirk Howatt ja Xin Sun. 2022. “Weed and crop species classification using computer vision and deep learning technologies in greenhouse conditions”. *Journal of Agriculture and Food Research* 9:100325.

- Söderkvist, Oskar. 2001. *Computer vision classification of leaves from swedish trees*.
- Wei Tan, Jing, Siow-Wee Chang, Sameem Abdul-Kareem, Hwa Jen Yap ja Kien-Thai Yong. 2018. “Deep learning for plant species classification using leaf vein morphometric”. *IEEE/ACM transactions on computational biology and bioinformatics* 17 (1): 82–90.
- Weiss, Ulrich, Peter Biber, Stefan Laible, Karsten Bohlmann ja Andreas Zell. 2010. “Plant species classification using a 3D LIDAR sensor and machine learning”. Teoksessa *2010 Ninth International Conference on Machine Learning and Applications*, 339–345. IEEE.
- Villaruz, Jolitte A, Julie Ann A Salido, Dennis M Barrios ja Rogelio L Felizardo. 2018. “Philippine indigenous plant seedlings classification using deep learning”. Teoksessa *2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM)*, 1–5. IEEE.
- Wu, Stephen Gang, Forrest Sheng Bao, Eric You Xu, Yu-Xuan Wang, Yi-Fan Chang ja Qiao-Liang Xiang. 2007. “A leaf recognition algorithm for plant classification using probabilistic neural network”. Teoksessa *2007 IEEE international symposium on signal processing and information technology*, 11–16. IEEE.
- Wäldchen, Jana ja Patrick Mäder. 2018a. “Machine learning for image based species identification”. *Methods in Ecology and Evolution* 9 (11): 2216–2225.
- . 2018b. “Plant species identification using computer vision techniques: A systematic literature review”. *Archives of computational methods in engineering* 25:507–543.