



Oamk Journal

Oulun ammattikorkeakoulun julkaisuja

Tämä on alkuperäisen julkaisun rinnakkaistallenne. Rinnakkaistallenne saattaa erota alkuperäisestä sivutuksestaan ja painoasultaan.

This is an electronic reprint of the original publication. This version may differ from the original in pagination and typographic detail.

Käytä viittauksessa alkuperäistä lähdettä/Please cite the original version:

Niiranen, J. (2026). Maatalousdronit ja tekoäly 2026 – kohti reaaliaikaista päätöksentekoa. *Oamk Journal*, (53). Oulun ammattikorkeakoulu. <http://urn.fi/urn:nbn:fi-fe2026042734472>

METATIEDOT

Tyyppi: Artikkel

Julkaisija: Oulun ammattikorkeakoulu

Julkaisunumero: 53/2026

Julkaisuvuosi: 2026

Tekijätiedot: Niiranen Janne

Oikeudet: [CC BY-SA 4.0](https://creativecommons.org/licenses/by-sa/4.0/)

Kieli: suomi

Pysyvä osoite: <http://urn.fi/urn:nbn:fi-fe2026042734472>

Tiivistelmä: Dronien ja tekoälyn yhdistelmä mahdollistaa automaattisen tunnistuksen jopa 90–95 prosentin tarkkuudella. RGB-kuvaus on kustannustehokasta, ja multispektrikuvaus tuo lisäinformaatiota kasvillisuusindeksien kautta. Tekniikan siirtymistä käytäntöön hidastavat haasteet datan hallinnassa, mallien yleistettävyydessä ja järjestelmäintegraatiossa. Tulevaisuudessa alan painopiste siirtyy yksittäisistä laitteista kokonaisvaltaisiin järjestelmiin, joissa viljelijä toimii automaation valvojana.

Maatalousdronit ja tekoäly 2026 – kohti reaaliaikaista päätöksentekoa

29.4.2026 - Niiranen Janne

Miehittämättömät ilma-alukset (UAV, droni) ovat hakemassa asemaansa täsmäviljelyssä. Erityisesti ne toimivat kasvuston monitoroinnin, paikkatietopohjaisen kartoituksen sekä rikkakasvien ja kasvitautien havaitsemisen välineinä. Mihin kaikkeen dronit pystyvätään nyt ja lähitulevaisuudessa?

Tässä artikkelissa perehdytään siihen, mitä tutkimukset ja kirjallisuus kertovat dronikuvantamisen menetelmistä, kuten RGB ja multispektri sekä syväoppimisen roolista rikkakasvien ja tautien automaattisessa tunnistuksessa. Lisäksi mukana on pohdintaa keskeisistä rajoitteista, jotka vaikuttavat menetelmien siirtoon tutkimuksista ja pilotoinneista käytännön viljelyyn.

Kartoitus ja kasvuston seuranta: droni osana täsmäviljelyn mittausketjua

Zhang ja Kovacs (2012) kuvasivat jo varhaisessa katsauksessaan dronijärjestelmien ydinhyödyn täsmäviljelyssä. Droni tuottaa hyvin tarkkaa ja yksityiskohtia sisältävää aineistoa, jonka avulla lohkon sisäinen vaihtelu tulee selvästi näkyväksi. Vaikka laitteistot ja ohjelmistot ovat kehittyneet, sama peruslogiikka toimii edelleen. Dronokuvaus palvelee päätöksentekoa, kun aineisto kytkeytyy aitoon analyysiin ja paikkatietoon.

Rejeb ym. (2022) käsittelivät maatalousdronien tutkimuskenttää ja nostivat keskeisiksi teemoiksi muun muassa kaukokartoituksen, täsmäviljelyn, koneoppimisen ja IoT-kytkennät. Näkökulma kytkennöistä on tärkeä. Droni ei ole yksittäinen laite, vaan osa laajempaa automaattisen analytiikan ketjua, jossa data kerätään, prosessoidaan ja tulkitaan päätöksenteon tueksi.

Guebsi ym. (2024) kokosivat laajassa katsauksessaan yhteen dronien sovelluksia täsmäviljelyssä ja erottelivat käytännössä kaksi pääluokkaa: diagnostiset käyttötapaukset, kuten monitorointi ja kartoitus sekä interventiot, esimerkiksi täsmäruiskutus ja droniavusteinen kylvä. Jako auttaa myös ymmärtämään dronien käyttöä. Ensin mittaus

ja tulkinta, sitten toimenpiteiden kohdentaminen. Tällä hetkellä nämä tapahtuvat vielä yleensä erillisillä laitteilla.

Sensorit ja kuvantaminen: RGB, multispektrikuvaus ja kasvillisuusindeksit

Sandoval-Pillajo ym. (2025) osoittivat rikkakasvien tunnistusta käsittelevässä kirjallisuuskatsauksessaan, että dronitutkimuksissa korostuvat edelleen multikopterit ja RGB-sensorit. Samalla näkyy trendi kohti monisensorisuutta, esimerkiksi multispektri ja LIDAR. Tämä on ymmärrettävää, sillä RGB-data on edullista, helposti kerättävää ja soveltuu suoraan konenäkömenetelmiin, mutta se kärsii esimerkiksi valaistuksen vaihteluista ja kasvuston voimakkaasta peittävydestä.

Zhang ym. (2025) kokosivat dronilla suoritettavan multispektrisen kaukokartoituksen sovelluksia ja nimesivät keskeisiksi käyttökohteiksi kasvun monitoroinnin, tuholaisten ja tautien tunnistuksen, ravinnetilan arvioinnin sekä satopotentialin tarkastelun. Katsaus korostaa myös perinteisten kasvillisuusindeksien, kuten NDVI:n, vakiintunutta asemaa. Indeksit ovat jo toimivia työkaluja, mutta niiden käytön hyödyt riippuvat analysointiketjusta ja kontekstista, kuten lajike, kasvuvaihe sekä kuvausolosuhteet. On myös erittäin tärkeää valita käytettävä indeksi oikein käyttökohteen mukaan.

Käytännössä multispektridata on usein tutkimus- ja sovellustyössä kompromissi. Se lisää informaation määrää verrattuna RGB:hen, mutta ei vielä tuo hyperspektrin datamääriä ja käsittelytaakkaa. Guebsi ym. (2024) katsaus käsitteli sensoreita ja järjestelmätason haasteita, kuten alustat, sensorit, kommunikaatio ja sovellukset, yhtenäisenä ketjuna eikä yksittäisinä laitteina tai tekniikoina. Näistä olisikin hyvä siirtyä jo kohti järjestelmätason tutkimusta ja ratkaisuja. Yksittäinen laite ei ratkaise mitään, vaan sen älykäs käyttö.

Rikkakasvit ja taudit: syväoppiminen dronikuvista

Anam ym. (2024) tarkastelivat drooni- ja AI-integraatiota kasvitautien tunnistuksessa, rikkakasvien hallinnassa ja tuholaisten torjunnassa. Heidän mukaansa kirjallisuus painottaa nimenomaan koneoppimisen ja syväoppimisen liittämistä dronijärjestelmiin sekä tunnistaa samalla esteitä, kuten datan hallinta, algoritmien monimutkaisuus ja vaihtelevat ympäristöolosuhteet. Tästä voidaan vetää selkeä johtopäätös: menetelmät ovat

lupaavia, mutta kone- ja syväoppimisen käyttöönotto käytännön viljelyyn vaatii huolellista työtä sekä aineiston, valmistelun että itse työprosessin hallinnan suhteen.

Sandoval-Pillajo ym. (2025) selvittivät rikkakasvien tunnistamista (kuva 1) droonikuvista. He nimesivät yleisimmiksi syväoppimisen työhevosiksi konenäössä ihmisaivojen toimintaa jäljittelemään pyrkivät CNN-pohjaiset luokittelijat sekä tunnistus- ja segmentointimallit, kuten YOLO, U-Net, Mask R-CNN. Tavoitteena on reaaliaikainen tunnistus ja päätöksenteko. Katsaus nosti keskeiseksi käytännön haasteeksi rikkakasvien ja viljelykasvien samankaltaisuuden värin, muodon ja tekstuurin osalta. Tämä vaikeuttaa erottelua ja hidastaa siirtoa toimivaksi arjessa.



KUVA 1. Tulevaisuuden drooni tunnistaa rikkakasvit reaaliajassa (kuva tehty ChatGPT GPT-5.3:lla, tekijä: Janne Niiranen, 2026).

Saini ja Nagesh (2025) lähestyivät tunnistamisen ongelmaa toisesta näkökulmasta. He tutustuivat syväoppimiseen perustuviin rikkakasvien tunnistusratkaisuihin sekä drooni- että robottialustoilla ja korostivat haasteina tunnistamismallien yleistettävyyttä, laadukkaiden aineistojen niukkuutta ja skaalausongelmia. Tunnistaminen ei ole vain arkkitehtuurin ongelma tai ominaisuus, vaan se on aina sidoksissa käytettävissä olevaan aineistoon ja vallitseviin olosuhteisiin.

Parhaimmillaan CNN-pohjaiset (Convolutional Neural Network) mallit erottavat rikkakasveja 90–95 prosentin tarkkuudella. Myös tuholaisten ja kasvitautien aiheuttamia vaurioita kasveissa voidaan tunnistaa hyvin varhaisessa vaiheessa ja kauan ennen kuin ne olisivat ihmissilmin havaittavissa. (Mohanty ym., 2016). Hyperspektriset dronikuvat yhdistettynä koneoppimiseen voivat auttaa tunnistamaan kurkun tautityyppejä jo nyt 87,5 prosentin tarkkuudella. (Rahman ym., 2024.)

Kohti paikkakohtaisia toimenpiteitä: kartoitusdata päätöksenteon tukena

Kirjallisuus tukee hyvin seuraavaa, jo nyt meneillään olevaa askelta. Siinä dronikartoitus tuottaa tarkkaan paikkatietoon sidotun kuvan kasvuston vaihtelusta ja syväoppiminen mahdollistaa esimerkiksi rikkakasvien ja kasvitautien varhaisten oireiden automaattisen tunnistamisen ja siten kohdennetumman ja tehokkaamman torjunnan. Käyttöönotto riippuu kuitenkin aina olosuhteiden ja aineistojen hallinnasta. Ilman datan hallintaa toiminta jää teholtaan heikoksi. (Caroppo ym., 2026.)

Droonien sovelluskenttä kattaa jo nyt sekä diagnostiikan että interventiot, mutta järjestelmätason haasteet rajaavat kustannustehokkaita ja toistettavia työvaiheita. Lisäksi monissa maissa, kuten Suomessa, lainsäädäntö ja hidas lupien saaminen vaikeuttavat käytännön toimia tai niiden kokeiluja. Myös diagnostiikan ja interventioiden väliin jäävä analysointi ja päätöksenteko pitäisi vielä saada automaattiseksi osaksi prosessia. (Guebsi ym., 2024.)

Datasirpaleista kohti kokonaisvaltaisia järjestelmiä

Tutkimusten perusteella voidaan sanoa droonien olevan täsmäviljelyssä selkeästi yleistymässä, ja RGB- ja multispektrikuvaus yhdistettynä syväoppimiseen on keskeinen kehityslinja rikkakasvien ja tautioireiden automaattisessa tunnistuksessa. Samalla kuitenkin korostetaan yhteisiä pullonkaloja eli aineiston laatua ja vertailtavuutta, mallien yleistettävyyttä sekä operatiivisia reunaehtoja ja järjestelmätason integraatiota.

Kriittinen kysymys ei siksi ole löytyykö jostain jonkinlainen tekoälymalli, vaan kuinka rakennetaan toistettava ja validoitavissa oleva ketju mittauksesta tulkintaan ja edelleen paikkakohtaisiin täsmätoimenpiteisiin niin, että tulokset säilyvät käyttökelpoisina ja

hyödynnettävänä muuttuvissa olosuhteissa. Datan hallinta, älykäs käyttö ja myös datan omistaminen ovat jatkossa entistä kriittisempiä kysymyksiä.

Juuri nyt olisikin tärkeää saada toimivia kokonaisvaltaisia järjestelmiä ja syvempää integraatiota maatalouden datan hallintaan ja käyttöön. Tulevaisuudessa viljelijä voi olla pääasiassa valvoja, joka hyväksyy kerätyn datan perusteella tehtyjen simulointien ja ennustusten kautta automaattisesti valitut toimet, seuraa niiden toteutumista ja puuttuu vain tarvittaessa mahdollisiin ongelmiin. Viljely voikin pian muuttua traktorin ajamisesta älylaitteiden moniajoksi.

Janne Niiranen

tutkija

TKI-yksikkö/digitaaliset ratkaisut

Oulun ammattikorkeakoulu

[DATOP – Dronien avulla työllisyyttä ja osaamista Pohjois-Pohjanmaalle -hanke](#)

Tavoite: Hanke keskittyy droniteknologian hyödyntämiseen työllisyyden edistämiseksi, pk-yritysten kilpailukyvyyn vahvistamiseksi ja alueellisten työvoimatarpeiden ratkaisemiseksi Pohjois-Pohjanmaalla. Tavoitteena on kouluttaa työttömiä ja työelämän ulkopuolella olevia droniosaaajiksi sekä tuottaa innovatiivisia ratkaisuja maa- ja metsätalouden, viranomaisten ja yritysten tarpeisiin. Hankkeessa korostetaan erityisesti vihreän siirtymän ja kestävän kehityksen tavoitteita, joita tuetaan dronien resurssitehokkailla ja ympäristöystävällisillä sovelluksilla.

Kesto: 1.1.2025–30.9.2028

Rahoittajat: Euroopan unionin osarahoittama

Koordinaattori: Oulun ammattikorkeakoulu

[Kaikki hankkeen julkaisut Oamk Journalissa](#)

Lähteet

Anam, I., Arafat, N., Hafiz, M. S., Rahman Jim, J., Mohsin Kabir, M., & Mridha, M. F. (2024). A systematic review of UAV and AI integration for targeted disease detection, weed management, and pest control in precision agriculture. *Smart Agricultural Technology*, 9, 100647. <https://doi.org/10.1016/j.atech.2024.100647>

Caroppo, A., Diraco, G., & Leone, A. (2026). A systematic review of available multispectral UAV image datasets for precision agriculture applications. *Remote Sensing*, 18(4), 659. <https://doi.org/10.3390/rs18040659>

Guebsi, R., Mami, S., & Chokmani, K. (2024). Drones in precision agriculture: A comprehensive review of applications, technologies, and challenges. *Drones*, 8(11), 686. <https://doi.org/10.3390/drones8110686>

Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419. <https://doi.org/10.3389/fpls.2016.01419>

Rejeb, A., Abdollahi, A., Rejeb, K., & Treiblmaier, H. (2022). Drones in agriculture: A review and bibliometric analysis. *Computers and Electronics in Agriculture*, 198, 107017. <https://doi.org/10.1016/j.compag.2022.107017>

Saini, P., & Nagesh, D. S. (2025). A review of deep learning applications in weed detection: UAV and robotic approaches for precision agriculture. *European Journal of Agronomy*, 168, 127652. <https://doi.org/10.1016/j.eja.2025.127652>

Sandoval-Pillajo, L., García-Santillán, I., Pusedá-Chulde, M., & Giret, A. (2025). Weed detection based on deep learning from UAV imagery: A review. *Smart Agricultural Technology*, 12, 101147. <https://doi.org/10.1016/j.atech.2025.101147>

Zhang, C., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: a review. *Precision Agriculture*, 13(6), 693–712. <https://doi.org/10.1007/s11119-012-9274-5>

Zhang, S., Wang, X., Lin, H., Dong, Y., & Qiang, Z. (2025). A review of the application of UAV multispectral remote sensing technology in precision agriculture. *Smart Agricultural Technology*, 12, 101406. <https://doi.org/10.1016/j.atech.2025.101406>