

1 Sensorid

Sensorid, mis aitavad keskkonnast koguda teavet, jagatakse esmalt passiivseteks ja aktiivseteks. **Passiivsete** sensorite puhul mõõdetakse objektilt tagasipeegelduvat (päikese)valgust või objekti poolt enda kiiratavat energiat (nt soojust või radioaktiivset kiirgust). Teada-tuntud fotokaamera salvestab just objektilt peegelduvat nähtavat elektromagnetkiirgust. Passiivsete sensorite alla kuuluvad samuti atmosfääri ja geofüüsika valdkonnaga seotud andurid, mis mõõdavad atmosfääris näiteks gaaside sisaldust või magnetvälja parameetreid.

Aktiivsete sensorite korral saadetakse elektromagnetkiirguse impulss droonilt teele ning anduri abil mõõdetakse objektilt tagasipeegelduva impulsi omadusi. Tüüpiline näide on laserskanner, kus mõõdetakse laserimpulsside tagasijõudmiseks kuluvat aega ja tagasipeegelduse intensiivsust võrreldes algse impulsi tugevusega. Taoline mõõtmine aitab määrata objekti kaugust andurist, kui me teame signaali levimiskiirust õhus.

Tihtilugu on drooni külge kinnitatud korraga mitu andurit. Näiteks on laserskanneriga tavaliselt kaasas sünkroniseeritud fotokaamera. Mõningal juhul võib droon koos anduriga olla ainult osa suuremast mõõtesüsteemist, kus maapinnal paikneb püsiseirejaam ning drooniga tehakse aeg-ajalt andmete suurema katvuse huvides seirelende. Tegelikult on ka drooni enese tegevuse jälgimiseks mitmeid andureid (nt baromeeter, et määrata kõrgust). Samas ei kasutata tänapäeval veel taolisi, drooni „sisemisi“ andmeid märkimisväärselt, kuid potentsiaal on olemas.

Sensorite puhul on peale anduri tehniliste omaduste olulised veel anduri kaal, suurus, voolutarve droonist ja ühildatus drooniga.

Neist kaks esimest mõjutavad põhiliselt lennudünaamikat ehk siis kaudsemalt lennuaega ja manööverdamisvõimet. Voolutarve sõltub esmalt sellest, kas anduril on autonoomne akutoide või kasutavad andurid drooni akusid. Esimesel juhul tuleb piloodil arvestada veel ühe akukomplekti laadimise ja kestvuse jälgimisega, samuti tõuseb seetõttu drooni kogukaal. Teisel juhul on drooni kogukaal väiksem, kuid lendamiseks jääb aku mahtuvusest alles ainult osa, mida lennuplaneerimise tarkvara ei oska üldjuhul välja arvutada.

Ühildatus drooniga võib olla väga mitmel tasemel: ainult toite jagamine, ühe- või kahepoolne drooni sidekanali kasutamine ja selle abil sensori juhtimine; reaajas andurilt tulevate andmetöötluse abil drooni lennutrajektoori muutus jne.

- Kõige lihtsamal juhul on droon ja andur lihtsalt füüsiliselt ühendatud ja mingit n-ö suhtlust omavahel ei toimu: droon tassib ainult andurit ringi.
- Ühepoolse side puhul drooni ning anduri vahel saab piloot vaadata „pilti“ ja telemeetriat aga andurit kuidagi juhtida ei saa;
- Kahepoolse side korral saab piloot vaadata anduri edastatavat „pilti“ ja telemeetriat ning vajadusel muuta anduri parameetreid lennu ajal, kasutades selleks drooni ja maapealse kontrolleri vahelisi sidekanaleid. Piloodil on sidekanalite võimalik kaamerat suunata huvipunktidele (POI – *point of interest*), muuta suurendust, teha suvalisel hetkel pilti/videot, lülitada andurit energia säästmiseks välja jne.
- Kõrgel tasemel sensori ja drooni ühildamisel muutub sensor drooni „osaks“, kus temalt saadud andmeid töödeldakse tavaliselt masinõppe algoritmidega reaajas ning

vastavalt tulemusele muudetakse ka lendu ennast. Heaks näiteks on nn jälitamise (*tracking*) või järgnemise (*follow me*) funktsioon. Nende puhul tuvastab droon kaamerapildist pidevalt objekti, suudab seda jälgida ning muudab lendu nõnda, et ta jääb liikuvast objektist pidevalt kindlale kaugusele, vältides samal ajal kokkupõrget teiste objektidega.

Oluliseks vahelüliks drooni ja paljude andurite, eelkõige kaamerate, vahel on gimbal e kaamera stabilisaator, mis vähendab drooni liikumise mõju kaamerale (vt joonis 10). Nii jääb andur ettenähtud asendisse vaatamata drooni kallutamisele, mis on lendamisega paratamatult alati kaasneb. Korraliku gimballi kasutus on andmekorje täpsema planeerimise eeldus, sest võimaldab välja arvutada piltide või mõõtmiste maapealset projektsiooni, vajalikke ülekatteid ning lõpuks saavutatava maapealse lahutuse (GSD – *ground sampling distance*). Juhul, kui me gimballit ei kasuta, peame oluliselt pikendama lennutrajektoore, et uuringualal kohal oleks drooni lend võimalikult ühtlane; vähendama lennuradade vahelist kaugust, et kõikumisest tulenevalt ei jääks andmetesse katmata alasid jne. Kõik need sammud vähendavad andmetega kaetud alal pindala sama andmemahu juures.

Eriti oluline on gimbal multirootorite puhul, sest nende liikumisel on vaja kallutada kogu drooni. Lennukdroonid lendavad juba oma ülesehituse tõttu oluliselt stabiilsemalt ning seetõttu on gimballit kindlasti vaja ainult pikemate fookuskaugustega kaamerate kasutamisel.

Gimbalid vajavad sujuvaks töötamiseks üsna täpset tasakaalustamist ja temperatuurist sõltuvat kalibreerimist, mida tuleb anduri vahetamisel alati korrata. Seetõttu on tänapäeval suurem osa droonikaameratest juba gimballiga ühildatud. Taoline lahendus muudab küll gimbalkaamerad hõlpsasti vahetatavaks, aga seda vaid ühe droonitootja ja pigem isegi ainult ühe drooni mudeli piires pakutavate variantide vahel. Suureks miinuseks on siinjuures, et tootjaüleseid standardühendusi ja -kinnitusi pole (veel) kokku lepitud. See tähendab, et uut drooni ostes on tihti vaja uuendada ka kõik gimbalkaamerad ja drooniakud. Võimalik on osta ka nn tühja gimballi, mille seadistamine konkreetse anduri jaoks sobivaks jääb kasutaja teha. Tuntuim eraldi gimballite tootja on Gremsy.




Joonis 1. Vasakult paremale: Gremsy Mio gimbal, Yuneec E90 gimbalkaamera ja DJI H20N gimbalkaamera mitme sensori ja laserkaugusmõõtmisega.

Kaardistamiste jaoks piisab üldiselt 2-teljelisest gimballist, mis stabiliseerib andurit kahe horisontaaltelje suhtes. Millegi otsimiseks ja/või jälitamiseks on vaja aga 3-teljelist gimballit, et

saaks andurit pöörata ümber oma vertikaaltelje. Sellisel juhul peab anduri ümbrus olema ideaalis 360° vaba, multirootor-droonil peavad sel juhul olema tugijalad, mida saab lennu ajaks üles tõsta.


Droonidel kasutatakse kõige enam tavalisi fotokaameraid ehk RGB-kaameraid või nende modifitseeritud variante. Populaarsuselt järgnevad multi- ja hüperspektraalkaamerad, termokaamerad ning laserskannerid (kõnekeeles *lidarid*). Hea ülevaate kõige levinumatest anduritest (v.a termokaamerad) leiab huviline Nexi *et al* poolt kirjutatud artiklist (2022). Lisaks saab droonide külge kinnitada või integreerida ka palju muid andureid: sonareid, radareid, magnetomeetreid, veeproovi võtjaid, putukapüüniseid jms. Viimased loetelust on suurem osa siiski nišikasutus või suisa üksikarendused.

Enne andurite detailsemat tutvustamist on hea meelde tuletada elektromagnetiline spekter (Joonis 2).



Joonis 2. Elektromagnetiline spekter ja sellega seotud kaugeire meetodid (Toth and Józków, 2016).

1.1 RGB- e fotokaamerad



Joonis 3. Bayeri filter fotokaamera sensori ees.

Tavalised fotokaamerad salvestavad nähtava valguse spektrivahemikust kolme „värvi“ ehk kitsamat spektrivahemikku – punast (R), rohelist (G) ja sinist (B) (Joonis 7). Värvide eraldamine käib filtritega, mis katavad üksikuid andurelemente ehk piksleid, moodustades Bayeri filtri. Tähelepanelik lugeja märkab, et võrreldes rohelise ja punasega, on rohelisi piksleid joonisel kaks korda rohkem. See tuleb asjaolust, et inimese silm on rohelise erinevatele toonidele kõige tundlikum.

Erinevate värvitoonidega pilt saadakse interpoleerides ja liites igale pikslile naabritelt saadud värviinformatsiooni. See protsess võib toimuda otse kaameras, kus lõppversioon salvestatakse kas .jpeg- või .tiff-failina või siis hiljem arvutis, sel juhul salvestatakse pilt kaameras mõnes toorformaadis (.dgn, .arw, .raw jne). Toorformaadis salvestatud failis on kogu sensori salvestatud informatsioon, seetõttu on selle hilisema töötlemise võimalused kõige suuremad, aga samal ajal on tegemist väga mahuka failiga, millega enamik pilditöötluste tarkvarast ei oska otse midagi peale hakata. Lisaks värvide „kokkusegamisele“ tehakse kaameras veel (tootja- ja seadetepõhiseid!) pildiparandusi: eemaldatakse moonutusi, muudetakse värvitasakaalu ja küllastust, ühtlustatakse heledust jne. Viimastel aastatel on järjest lisandunud tehisintellekti poolt tehtavad muudatused, mis muudavad pilti juba väikeste alade kaupa: vanaemast fotodel kaotavad ära kortsud jne. Kui droonifotosid kasutatakse teadus- ja seiretöös, on hea sellised kaamera automaatparandused välja lülitada.

(Martínez-Fernández *et al.*, 2022) tegid huvitava katse erinevate pildiformaatide kasutamise mõjust fotogramm-meetrias. Üldiselt ei näinud nad suurt mõju ei 3D-mudelite ega ka ortofotode genereerimisel, v.a juhul, mil nad lubasid .jpeg-formaadi kasutamisel automaatse moonutuste eemaldamise kaameras. Seetõttu tuleks selline funktsioon kaameras võimalusel välja lülitada. Ka isiklik praktika on suunanud kasutama kõige rohkem .jpeg-formaati, mille muudatused on minimaalsed. Ainult raskete valgusolude (ere päike, vähe valgust, suured kontrastid) korral on hea kasutada piltide toorformaati. Lennuplaneerimise seisukohalt ei tohi unustada, et mahukamate toorpiltide salvestamine mälukaardile võtab kauem aega ning seega peab lendama aeglasemalt.

Droonilt kasutatava fotokaamerate puhul on kõige olulisemad parameetrid:

- Kaamera sensori füüsiline suurus
- Kaamera sensori pikslite arv
- Kaamera sensori dünaamiline ulatus ja pildi värvisügavus
- Kaamera pildisalvestuse kiirus

Kõigi nende parameetrite puhul kehtib reegel, et mida suurem, seda parem. Droonikaameratel on tavaliselt anduri füüsiline suurus ja dünaamiline ulatus kehvapoolne ja objektiive saab vahetada ainult väga vähestel mudelitel. Samuti kipuvad ka objektiivid olema pigem lahjema kvaliteediga ning muudetavate parameetrite arv ning muutmisulatus väike. Lisaks on odavamate droonide kaameratel elektrooniline katik (*electronic rolling shutter*), kus kaamerasensorilt loetakse andmeid rida-rea haaval. See tähendab, et taolise lahenduse korral on pildid pisut moonutatud, sest kaamerasensorilt andmete lugemise ajal jõuab droon liikuda. Mõned fotogramm-meetria tarkvarad (nt Metashape, Pix4D) oskavad seda täpsuse mõttes negatiivset efekti kompenseerida, aga mitte kõik. Täpsemalt kirjutab sellest probleemist oma artiklis (Vautherin *et al.*, 2016).

Üpris populaarne on drooni abil ümbruse jäädvustamisel kasutada tavalist **kompaktkamerat** (nt Sony Alpha kaameraseeria), sest need võimaldavad kiiremat salvestusaega, suurt valikut objektiive ning paremat pildikvaliteeti. Kompaktkamerate miinuseks on kasutajamugavuse langus, sest nad pole vaikumisi drooniga kuidagi seotud. Sellisele kaamerale on vähemalt multirootorite puhul juurde vaja gimbalit, mis oleks kalibreeritud vastavale kaamerale ja objektiivile. Samuti on vaja ühildada lennukontroller kaameraga, et kaameraga oleks võimalik pildistada, kasutades drooni sidekanaleid või lennuplaani. Siiski pole integreeritavus kaamera ja drooni vahel, vähemalt minimaalsel tasemel, tänapäevastele kaameratele ja lennukontrolleritele suur probleem ning selleks piisab mõnest odavast kaablist ja/või adapterist.

Lisaks eelpoolnimetatule, muudab kompaktkamera kasutamise ebamugavamaks suhteliselt suurem kaal, võrreldes spetsiaalsete droonikaameratega. Suurem kaamera kaal avaldub paraku eelkõige lühenevas lennuajas. Üldiselt kasutatakse kaardistamiseks lainurkobjektiive ning pildistamiskäsk tuleb lennukontrollerist vastavalt eelprogrammeeritud lennuplaanile. Objektiivide puhul on peamiseks piiravaks teguriks samuti nende kaal, seetõttu eelistatakse nn *pancake*-tüüpi objektiive, mis on kõige kergemad ja väiksemad.

Valiku ja kvaliteedi kasvades on integreeritud ning vahetatavad gimbalkaamerad muutunud järjest populaarsemaks. Nii pakub enamik suurematest droonitootjatest (nt DJI ja Yuneec) arvestatavat valikut kaameraid (sh multispektraal- ja termokaameraid) oma professionaalidele mõeldud platvormidele (nt DJI Matrice) (vt ka Joonis 4) või Yuneec H520. DJI on olemas lausa eraldi fotogramm-meetria jaoks optimeeritud kaamera Zenmuse P1, millel on väga hea pildikvaliteet.



Joonis 4. DJI Matrice seeriale mõeldud integreeritud gimbalkaamerad, fotod pärinevad tootja kodulehelt.

Parimat pildikvaliteeti ja sellega kaasnevat kõige kõrgemat hinda pakuvad spetsiaalselt droonide abil aerokaardistamiseks konstrueeritud kaamerad (nt Phase One P3). Omaette uue suunana on hakatud pakkuma sünkroniseeritud kaamerakomplekte, kus erinevate nurkade alla suunatud kaamerad teevad üheaegselt pilte (nt Rainpoo D64P). Selline lahendus on efektiivne linnakeskkonna 3D-kaardistamisel, et saada ühe lennu kestel korraga palju eri nurkade alt tehtud fotosid. Tarkvara abiga täidab DJI M300 koos P1 kaameraga sarnast ülesannet, tehes aeglasema lennu jooksul gimbalit keerates eri nurkade alt pilte (*smart oblique* funktsioon).

Fotokaamerad koos kaasaegse fotogramm-meetriaga on kasutajale suhteliselt odav võimalus saada pilooti huvitavast objektist nii 3D-punktipilv, digitaalne pinnamudel ning ortofoto. Viimast üritatakse omakorda tavaliselt klassifitseerida (nt eristada erinevaid taimkattetüüpe) kasutades selleks ennekõike spektraalset infot, mida fotokaamera annab kolme spektrivahemiku ehk kanali kohta. Tavaliste fotokaamerate puhul tulevad aga spektraalinfo kasutamisel ilmsiks küllalt olulised puudujäägid (Logie & Coburn, 2018):

- kolm salvestatavat spektervahemikku on väga laiad (tavaliselt 70-100 nm) ja osaliselt kattuvad;
- andurid on spektraalselt ja radiomeetriliselt kalibreerimata ning eri kaameratel on erinevad spektervahemikud;
- anduri piksli poolt väljastatav DN (*digital number*) on mitte-lineaarses seoses valgustugevusega ning kasutaja seda seost kalibreerimiseta ei tea;
- JPEG-piltide kasutamisel toimub kaamerasiseselt oluline infotöötlus ja -moonutus, mille täpne sisu pole aga kasutajale teada (Cramer *et al.*, 2017).

Osade loetletud puuduste vastu aitab konkreetse kaamera ja objektiivi kalibreerimine, aga see nõuab erivahendeid ja -teadmisi ning on seega suhteliselt kallis tegevus. Nende puuduste tõttu on tavaliste fotokaamerate spektraalinfo kasutamine üsna töömahukas ning potentsiaalselt suurte vigadega näiteks valgusolude muutumisel. Seetõttu sobib fotokaamera abil saadud ortofoto vaid üsna jämedakoeliseks klassifitseerimiseks, kus eristatavate objektide spektraalsignatuur peab samuti üksteisest selgelt eristuma.

Täpsema ja kontrollituma spektraalinfo saamiseks on vaja kasutada kalibreeritud multi- või hüperspektraalkaamerasid.

1.2 Multispektraalkaamerad

Võrreldes tavalise fotokaameraga, on **multispektraalkaameras** peale keelt sõlme ajava nime ka võimekus salvestada kuni kümnekond mittekattuvat spektrivahemikku ehk kanalit laiusel 10–40 nm.

Peamiselt kasutatakse neid kaamerasid taimestiku uuringuteks, milleks mõõdetakse lisaks nähtavale (VIS - *Visible*) spektrile ka lähi-infrapuna (NIR – *Near-InfraRed*) spektriosa, sest see spektrivahemik on tundlik klorofüllile.

Hüperspektraalkaamerasid salvestavad juba sadu kanaleid, mis on tavaliselt laiusel 3–10 nm. Tavaliselt katab üks kaamera kas VIS-NIR (*visible – near-infrared*) vahemiku (400–1000 nm) või lühi-infrapuna (SWIR – *short-wave infraRed*) spektrivahemiku lainepikkusega 1000–2500 nm. VIS-NIR vahemik on sobivam taimestiku uuringuteks ja SWIR-i kasutatakse rohkem geoloogilisteks/mineroloogilisteks kaardistamiseks (Joonis 2). Enamik saadaolevaid kaamerasid on optimeeritud kas ühe või teise vahemiku katmiseks.

Head ülevaateartiklid nii multi- kui ka hüperspektraalkaameratest on koostanud Aasen *et al* (2018) ning Nex *et al.*, (2022).

Multispektraalkaamerad on üldiselt üles ehitatud modulaarselt, mis tähendab, et iga lainepikkust pildistavad samaaegselt eraldi kaameramoodulid, mille ees on ainult ühte spektrivahemikku läbi laskev filter. Näiteks AgEagle Micasense RedEdge koosneb kuuest eraldi kaamerast: viis neist pildistavad oma kindlas spektrivahemikus ja üks on tavaline RGB-kaamera. Mõnel juhul saab multispektraalkaamera kokku panna viisil, kus nii moodulite arvu kui ka nende ette käivaid filtreid saab kasutaja ise valida (nt Maia M2 või Mapir Kernel2 kaamerad). Mõnedel kaamerasüsteemidel (nt AgEagle Micasense Altum-PT või Sentera 6XT), on multispektraal- ja fotokaameraga ühildatud veel samas korpuses olev termokaamera (Joonis 6).

Siinkohal on oluline meeles pidada, et erinevatel kaameratel on tõenäoliselt pisut erinevad filtrid, kuigi tootjad võivad vastavat kanalit nimetada ühe ja sama nimega. Seetõttu ei saa erinevate kaameratega saadud spektraalsignatuure otseselt võrrelda, sedalaadi erinevusele lisandub veel kalibreerimisest tulenevad erinevused.


Müügil on ka multispektraalkaamerad, mille ülesanne on siduda kogutavaid andmeid satelliitandmestikuga. Selliste kaamerate salvestatavad spektrikanalid on (peaaegu) samad satelliitidelt jälgitavate spektrikanalitega – nt satelliit Sentinel 2 „ühildub“ multispektraalkaameraga Maia S2 või satelliit WorldView-2 Maia WV kaameraga.

Kirjeldatud kaamerad on drooniga integreeritud peamiselt vaid toite ja pildipäästiku kaudu. Mõned mudelid võimaldavad lisaks veel droonil oleva täppis-GNSS kasutamist piltide georefereerimiseks. Üldiselt saab multispektraalkaamerat seadistada ja näha pildi eelvaadet kaamera enda Wifi või Bluetooth-i ühenduse abil. Suurematel droonitootjatel on olemas ka täielikumalt integreeritud multispektraalkaameratega droonid (nt DJI Mavic 3M või Delair UX11 AG), millega saab reaajas drooni puldist näha anduri(te) kogutavat infot ja isegi sellest arvutatud tuletise nagu NDVI (*Normalized Difference Vegetation Index*) kaarti.

Multispektraalkaamerate andurite pikslite arv on tunduvalt väiksem kui tüüpistel fotokaameratel. Tavaline pikslite arv algab umbes 1,2 Mpx (nt Micasense RedEdge, Maia) juurest, uuemad mudelid on anduritega, mille resolutsioon on kuni 5 Mpx (nt DJI Mavic 3 M). See tähendab, et ka saavutatav maapealne lahutus (GSD) on pikslite vahel väiksem ja samasuguse detailsuse nägemiseks, võrreldes RGB-kaameraga, tuleb lennata oluliselt madalamal. Kaamerasüsteemidel, kus on drooni küljes lisaks ka RGB-kaamera, kipuvad tootjad ennekõike reklaamima vaid fotokaamera resolutsiooni. Spektraalkaamera mooduli resolutsioon on oma tagasihoidlikuma lahutusvõimega tavaliselt kusagil dokumentatsioonis peidus. Multispektraalkaamerate objektiivid pole üldiselt vahetatavad, küll on mõnel kaameral võimalik vahetada kaameramooduli ees olevat filtrit.

Anduri poolt algselt salvestatud digitaalsest numbrist (DN) spektraalse peegeldusväärtuse (*spectral reflectance*) saamiseks kasutatakse üsna mitme etapilist kalibreerimist. Spektraalinfo ambitsioonikamal kasutajal on hea tutvuda (Aasen *et al.*, 2018) poolt tehtud ülevaatega. Samuti on hea lugemismaterjal (Cao *et al.*, 2020) kirjeldatud näide drooni multispektraalkaamera andmete kalibreerimisest (Joonis 5).

Fig. 1. Simplified flow of information from surface radiance to reflectance maps using multispectral drone sensors. Surface radiance is measured as at-sensor radiance for each band by the drone sensor and saved as digital numbers (DNs) in an image file. Image DNs are then converted (“calibrated”) into reflectance values using an image of a reflectance standard acquired at the time point of the survey. The resulting reflectance maps for each of the sensor’s bands can then be used to calculate VIs or as direct inputs for classification. Drone symbol by Mike Rowe from the Noun Project (CC-BY, <http://thenounproject.com>).



Joonis 5. Lihtsustatud töövoog drooni pealt multispektraalkaameraga kogutud infost vastavalt (Assmann *et al.*, 2019).

Suur osa kaamera ja objektiiviga seotud kalibreerimisest tehakse ära juba kaamera sees, aga lõplike peegeldusväärtuste saamiseks kasutatakse tavaliselt referentspaneele. Nendel paneelidel on mõõdetud laboritingimustes väga täpsed peegeldusväärtused ja nendest vahetult enne ja pärast tehtud pilte kasutakse ka lennu ajal tehtud piltide kalibreerimiseks. Kuna tihtipeale on need üks või kaks pilti referentspaneelist kalibreerimise ainus lähtekoht, siis tuleb nende tegemisel erilise hoolega jälgida tootjapoolseid juhiseid. Lisaks muutuvad kasutamisel aja jooksul referentspaneelide enda väärtuseid – neid peaks laskma laboris aasta-paari tagant üle mõõta.

Selline kalibreerimisele lähenemine eeldab, et lennu ajal päikesekiirgus ei muutu või muutub lineaarselt – tegelikult pole see eeldus kunagi päris täidetud. Valgusolude muutlikkuse jälgimiseks lennu ajal kasutatakse kiirgussensori (ILS - *Incident Light Sensor*) andmeid. Enamikul multispektraalkaamerate pakkujatest on ILS vähemalt lisana saadaval. Häid nõuandeid Eestile lähedastes oludes droonilt multispektraalkaameratega töötamiseks jagab (Assmann *et al.*, 2019). Oma mõju on kaamera sisetemperatuuril tulemustele – kaamera peaks vähemalt 15 minutit töötama stabiilse sisetemperatuuri saavutamiseks enne päris andmekogumist nagu selgitavad Olsson ja teised (2021).

Väga kiiresti suureneb multispektraalkaamerate kasutus täppisviljeluses, kus selle abil saab jälgida põlluosade kaupa toitainete- või veepuudusega kaasnevat taimede stressi või kaardistada kahjurite levikut juba enne taimede suremist. Täpsemalt saab droonide kasutusest täppisviljeluses lugeda (Rejeb *et al.*, 2022) koostatud artiklist.

Peatüki lõpetuseks mõni sõna ka **hüperspektraalkaameratest**. Need seadmed annavad kõige rikkalikumat ja täpsemat spektraalset informatsiooni, kuid nad on väga kallid ja andmed nõuavad spetsiifilist ning seadmepõhiselt erinevat töötlust. Hüperspektraalkaamerad kasutavad mitmeid erinevaid viise anduritelt andmete maha lugemiseks. Erinevalt RGB- ja

multispektraalkaameratest, ei ole hüperspektraalkaameratelt võimalik veel üheaegselt lugeda kõiki andmeid kõigilt pikslitelt. Andmelugemise viise on küllalt erinevaid (Aasen *et al.*, 2018), kuid kõik need muudavad hüperspektraalkaamerate andmetöötluse väga mahukaks. Erinevate hüperspektraalsetes kaamerates kasutatavate tehnoloogiatega tutvumiseks saab lugeja soovi korral tutvuda Adão *et al* ülevaateartikliga (2017) ning pisut uuema, Nex-i *et al.*, artikliga (2022).



Joonis 6. Mõned peatükis mainitud multi- ja hüperspektraalkaamerad, pildid pärinevad tootjate kodulehtedelt.

1.3 Termokaamerad

Termokaamerad võimaldavad näha objektide temperatuurierinevusi. Selle jaoks on nende sensorid tundlikud lainepikkustele 7–14 μm . Soojuskiirguse puhul on tegemist kiirguva, mitte peegelduva kiirgusega. Nii pole vaja soojuskaamera toimimiseks välist kiirgusallikat nagu tavalise fotokaamera puhul, vaid iga objekt, mille temperatuur on üle absoluutse nulli, eraldab ise soojuskiirgust. Ühelt poolt võimaldab see näha objekte inimese jaoks täielikus pimeduses, aga teiselt poolt tekitab see palju müra, sest kaamera ise on samuti mõõdetava kiirguse allikas.

Kõige levinumad droonidel kasutatavad termokaamerad on mikro-bolomeetrid, millel ei ole temperatuurikontrolli ja on seetõttu tundlikud nii välitemperatuuri kui ka kaamerasisese temperatuuri muutustele. Militaarvaldkonnas kasutatakse aktiivselt jahutatud termokaameraid, mis on stabiilsemad, väiksema müratasemega ning tundlikumad temperatuurimuutustele. Kõik need hüved tingivad samas kõrgema hinna, kaamerad on suuremad, raskemad ning tarbivad rohkem energiat.

Soojuskiirgusele tundliku anduri üksik piksel on oluliselt suurem kui RGB- ehk fotokaameral ja nad ei saa üksteist oluliselt segamata olla nii tihedalt üksteise kõrval nagu RGB-andurites. Seetõttu on termokaamera anduritel madal resolutsioon – tsiviilkasutuses droonidele mõeldud parimate termokaamerate lahutusvõime on üldjuhul 640x512 pikslit (nt Workswell WIRIS 640 ja FLIR Vue Pro). Vahel kasutatakse ka kaamerasisest üksikute kaadrite liitmist, et saada näiteks HD (1920x1080) resolutsiooniga termopilte (nt FLIR Ultramax ja Wiris Superresolution tehnoloogiad).


Saada on radiomeetriliselt kalibreeritud (nt FLIR VUE PRO R) ja kalibreerimata (nt FLIR VUE PRO) termokaameraid. Kalibreerimine toimub tehase laboris mitmete kindla temperatuuriga katsekehade suhtes ja selle protseduuri tulemusena saab konkreetse piksli mõõtmised teisendada absoluuttemperatuuriks. Seetõttu on radiomeetriliselt kalibreeritud termokaamerad umbes kaks korda kallimad võrreldes kalibreerimata kaameratega. Kalibreeritud kaamerate salvestatud väljundis, tavaliselt rjpeg-formaadis, on igal pikslil oma, kalibreerimisega ühtlustatud temperatuuriväärtus ning lisaks saab pilti järel töötamise käigus spetsiaalse tarkvaraga piksli kaupa absoluutsesse temperatuuri ümber arvutada. Kalibreerimata kaamerad näitavad ainult temperatuuri suhtelisi erinevusi ühe kaadri sees, seega absoluuttemperatuurid on väiksema täpsuse ja ühtlusega.

Samas on ka kalibreeritud termokaamerate puhul absoluuttäpsus (*accuracy*) oluliselt kehvem, võrreldes anduri enese tundlikkusega (*sensitivity*). Näiteks kallimate termokaamerate absoluutne täpsus on $\pm 2\%$ ehk $\pm 2^\circ\text{C}$ (nt WIRIS Enterprise), samal ajal kui kaamera ise suudab eristada 0,03 kraadi suurust temperatuurierinevust. Odavamatel kaameratel on absoluuttäpsused tavaliselt $\pm 5\%$ või $\pm 5^\circ\text{C}$. Tekstilõigu selgituseks väike näide igapäevaelust – termokaameraga on raske tuvastada üksiku inimese palavikku, sest see on defineeritud absoluutskaalas maksimaalselt 2–3 kraadise erinevusena „normaalsest“ – nii jääb erinevus mõõtevea piiridesse. Aga samas on väga kerge ära tunda palavikus inimest, kui ta on termopildil kõrvuti „normaalse“ kehatemperatuuriga inimesega.

Jahutamata termokaamerate anduri pikslite näidud hakkavad üsna kiiresti, vahel minutitega, „ujuma“ tänu vastuvõtlikkusele välitingimustele ning lisaks on pikslid iseenesestki pisut erineva tundlikkusega. Pikslite omavaheliste näitude stabiliseerimiseks kasutatakse pikslite vahekalibreerimist – nn NUC-meetod (*non-uniformity correction*), vahel kasutatakse ka terminit FFC (*flat field correction*). Selleks soojendatakse kõiki piksleid korra täpselt ühe palju ning näitude muutuse erinevusi kasutatakse juba pikslite omavaheliseks kalibreerimiseks. Vahekalibreerimiste ajal (tavaliselt mõni sekund) ei saa kaamera termopilti teha. Pildistamise tihedus sõltub konkreetsest kaameramudelist, tootja juhistest ning välikeskkonna muutlikkusest.

Kuna NUC-kalibreerimine toimub kaamera sees, siis see ei leevenda optikast põhjustatud moonutusi (nt vinjet) jne. Termokaameratele on saada välised kalibraatoreid (nt Teax Calibrator), mis paiknevad

objektiivi ees ja aitavad (osaliselt) vähendada optikast põhjustatud moonutusi. Väli- ja kaameratemperatuuri, tuule ning optika moonutuste mõjust termokaamera näitudele ning nende mõjude nn väljakalibreerimisest on hea näide (Aragon *et al.*, 2020) artikkel, kust pärineb ka Joonis 15. ja (Kelly *et al.*, 2019).



Joonis 7. Kalibreerimata ja kalibreeritud termopilt. Pildistatud katsekeha temperatuur oli 34.44 °C.

Ühe praktilise probleemina võib termokaamerate puhul välja tuua selle, et madala ruumilise resolutsiooni tõttu on ainult termopildi põhjal raske aru saada, mis objekt põhjustab temperatuurianomaaliat. Samuti on probleemiks lähestikku paiknevad mitmed objektid, näiteks karjalise eluviisiga loomad, keda pole võimalik termopildi põhjal individini eristada. Nii on järjest rohkem levinud kaamerasüsteemid, mis kombineerivad termokaamera fotokaameraga – termokaamera aitab objekti leida temperatuurianomaalia abil ning fotokaamera abil saab seda täpsemalt iseloomustada (nt FLIR DUO või Teax ThermalCapture).

Mõned droonitootjad müüvad professionaalseks kasutuseks mõeldud vahetatavaid gimbalkaameraid, millega tehakse termograafilisi vaatlusi (nt gimbalkaamerad DJI H20T, Yuneec E10T). Sellistel lahendustel on lisaks suurendus ja lainurk-fotokaamera ning termokaamerale integreeritud laser-kaugusmõõtja, mille abil saab droonilt reaalajas määrata maa/vee peal oleva objekti koordinaadid. Põhiliselt kasutatakse selliseid lahendusi kellegi otsimiseks.

Toodetakse ka kompaktseid, kokkuvolditavaid droone (nt DJI Mavic 3T ja Autel Dual EVO II), mille kaameras

on täielikult ühildatud termo- ja fotokaamera ja mis kvaliteedilt ei jää palju alla kallimatele analoogidele.

Militaar- ja päästevaldkonna jaoks toodetakse ka termo- ja optiliste kaamerate süsteeme (EO/IR), kus tarkvaras on märkimisväärselt rakendatud masinõpet, mille abil droon suudab identifitseerida ja jälitada huvipakkuvaid objekte. Samuti on neil droonidel tüüpiliselt võimsad zoom-objektiivid (nt gimbaliga integreeritud andursüsteem Thred ORCA) (Joonis 8).





Joonis 8. Mõned pildinäited peatükis mainitud termokaamerateist.

1.4 Fotogramm-meetria lühikirjeldus

Drooni abil saadavate andmete fotogramm-meetria on üks enamlevinud andmetöötlusviis, mille tulemusel parandatakse üksikute fotode geomeetrisi moonutusi, luuakse objektist 3D-mudeleid ning mosaiigitakse kokku ortofotosid. Fotogramm-meetria edukas kasutus nõuab kindlat fotode paigutust ning arvestamist mitmete asjaoludega.

Võrreldes klassikaliste, väga täpselt kalibreeritud meetriliste aerofotokaameratega, põhjustavad droonide ja kalibreerimata kaamerate kasutamine kaameraplatvormi ebastabiilsust ja tulemuseks on kehvema kvaliteediga aerofotod (Hardin ja Jensen, 2011). Drooni fotogramm-meetria kasutajale mõeldud väljakutsed toob esil Turner *et al.* (2014) oma artiklis: varieeruva mõõtkavaga pildid, suured ülekatted, väga erineva orienteeritusega pildid ja madalast lennukõrgusest ning reljeefist tingitud suured asukohanihked. Kuna probleemide loetelu on pikk, siis ei sobigi enam traditsioonilise fotogramm-meetria võtted selliste piltide töötlemiseks, vaid on vaja teistsugust lähenemist.

Uuenenud lähenemisviisi on ära kirjeldanud Snavely (2008). Drooni fotogramm-meetria tähendab siinkohal *Structure from Motion – Multi View Stereo* töövoogu (SfM-MVS, edaspidi SfM). Tegemist on klassikalise fotogramm-meetria printsiipi kasutava meetodiga, mis seob klassikalise töövoogu arvutinägemise ja matemaatilise optimeerimisega. See ongi Snavely (2008) poolt tehtud uuendus, kes sidus esimesena eelnimetatud arenguloo ühte protsessi kokku. SfM töövoogu tulemusel luuakse piltide põhjal 3D-punktipilv, arvutatakse jooksvalt kaamera geomeetrisi moonutuse parameetrid, asukohad ja vaatesuunad. Loogilise jätkuna saab 3D-punktipilvest luua pinnamudeli, mille üksikute fotode abil nn sulatatakse kokku ortofoto.

SfM-töövoogu saab lisada ka maapealseid referentspunkte, mis aitavad loodud, esialgu suhtelises ja ilma skaalata, 3D-mudeli siduda reaalse objekti skaala ning asukohaga ruumis.


Kokkuvõtvalt on SfM fotogramm-meetria peamised etapid järgmised:

1. Fotodelt otsitakse unikaalsed võtmepunkte (*key points*), kasutades värvigradiiente ehk muutusi erinevas skaalas. Otsimiseks kasutatakse erinevaid masin-nägemise algoritme (nt SIFT-algoritm);
2. Fotod on sobitatakse omavahel, kasutades selleks eelnevalt leitud võtmepunkte. Kokkusobivad võtmepunktid ühendatakse ja nii tekivad sõlmpunktid (*tie points*);
3. Sobitatud piltide sõlmpunktide põhjal arvutatakse välja kaamera matemaatiline mudel, mille abil korrigeeritakse piltide geomeetrisi moonutused ning koostatakse kogu objekti ja pildistamiskohtade paigutuse suhteline 3D-mudel. See kõik toimub ühe suure iteratiivse

optimeerimisprotsessi (*bundle adjustment*) käigus. Tulemuseks saadakse kaamera matemaatiline mudel, pildistamise suhtelised asukohad ning objektist hõre punktipilv (*sparse point cloud*) ;

4. Neid kasutatakse sisendina MVS algoritmide abil tiheda punktipilve (*dense point cloud*) loomiseks;
5. Tihedat punktipilve kasutatakse objektist lihtsustatud, katkematu 3D-pinna (*mesh*) või pinnamudelite (DSM – *Digital Surface Model*) arvutamiseks. Nende andmete abil on võimalik üksikutest fotodest juba kokku mosaiikida ortofoto.
6. Tihedat punktipilve on võimalik klassifitseerida, eraldades näiteks maapinna punktid hoonete ning taimestiku punktidest. Ainult maapinna klassi kuuluvatest punktidest saab arvutada digitaalse maapinna mudeli (DEM – *Digital Elevation Model*, ka DTM – *Digital Terrain Model*). Taimestiku puhul saadakse tehte DSM – DEM abil võramudel (CHM – *Canopy Height Model*), mis iseloomustab taimestiku kõrgust. Tänapäeval on punktipilve klassifitseerimise võimekus olemas kõigis enam-levinud SfM-programmides. Enamasti kasutatakse punktipilve klassifitseerimiseks suhteliselt lihtsaid geomeetriapõhiseid lävendeid, aga järjest kasvab masinõppemeetodite kasutamise osatähtsus.

SfM fotogramm-meetria seotud protsessist, probleemidest jne. on oma artiklites kokku võtnud näiteks Harwin ja Lucieer (2012), kelle artiklist on võetud ka alljärgnev kokkuvõttev Joonis 9. SfM fotogramm-meetria põhietapid (Harwin & Lucieer, 2012).




Joonis 9. SfM fotogramm-meetria põhietapid (Harwin & Lucieer, 2012).

SfM-meetodi kasutamine eeldab kokkuvõtvalt järgmist:

- 1) pildistatavad objektid on piisavalt unikaalse tekstuuriga, kuna SfM-meetod ei toimi vee, tugevalt peegeldavate objektide, väga ühtlast värvi või ühtlase mustri objektide puhul.

- 2) objekt (peaaegu) ei muutu pildistamise ajal (nt tüüpiline probleem on tuule käes liikuvad oksad ja sõitvad autod, aga foto mõttes muutuvad piltidel ka peegeldavad objektid, sest eri nurga alt pildistades paistab objektilt uus peegeldus. SfM meetod on tolerantsem valguse, skaala, orientatsiooni muutumisele, aga väga suured muutused ka nendes parameetritest halvendavad meetodi täpsust.
- 3) Vajalik on fotode suur ülekate – tüüpiliselt ca 70% nii piki- kui põiksuunas ja keerulisemate objektide korral isegi kuni 90%. Iga punkti, mida me tahame hiljem mudelis näha, peaksime pildistama minimaalset 3–5 erinevast asukohast ja punkti peab ümbritsema mõningane värvimuutus, mida SfM saab ära tunda. Näiteks mets on SfM-meetodi jaoks raske objekt, sest tegemist on väga sarnase ja ennast kordava mustriga ning lisaks on puude vahel palju kitsaid tühimikke, mida ei saa mitme eri nurga alt pildistada. Selliste raskete objektide korral peab pildistamise ülekate ning erinevate nurkade alt tehtud fotode hulk olema suurem. Kõrgemalt lennates katab üks pilt suurema ala, kust ehk õnnestub unikaalseid võtmepunkte leida, lisaks saab pildistada suurema radiomeetrilise lahutusega, et väikeseid erinevusi paremini tabada. Üldiselt SfM vähegi tihedamast metsast „läbi“ ei näe. Erinevate nurkade alt pildistamine aitab oluliselt parandada matemaatilist kaameramudelit ja seetõttu on kasulik ka tavalise „otse-alla“ kaardistuslennu lõppu lisada mõned nurga alt tehtud pildid (James *et al.*, 2019).

NB! Siinkohal peab rõhutama SfM-punktipilve erinevust laserskanneritega toodetud andmestikust, sest laseri osapeegelduste abil toodetud punktipilv tungib üldjuhul läbi taimestiku ja annab infot taimestiku sisemise struktuuri ning selle all oleva maapinna kohta (Joonis 10).



Joonis 10. Fotogramm-meetria ja lidari punktipilve võrdlus (Lisein *et al.*, 2013).

Drooni fotogramm-meetria punktipilv peegeldab seega pigem „pealmist kihti“ objektidest, mida pildistatakse.

Kõige tuntumad SfM-meetodit rakendavad programmid on Agisoft MetaShape ja Pix4D. Viimasega käib kaasas ka spetsiaalne lennuplaneerija Pix4Dcapture. Ka suurimal droonitootjal, DJI, on olemas oma SfM-tarkvara (DJI Terra). Vabavaralisi programme on samuti loodud, millest tuntuimad on MicMac ja WebODM. Kommertstarkvarad on tänapäeval juba üpris automatiseeritud ja suure osa nüanssidega ei pruugi kasutaja üldse kokku puutuda. Teadlikumale kasutajale on samas jäetud võimalused, et tulemusi detailselt üle kontrollida ja vajadusel muuta erinevaid seadistusi. Interneti otsingumootorite toel leiab huviline erinevaid töövooge ja heade praktikate kirjeldusi, kuidas nende tarkvarade abil saavutada parimat tulemust. Üsna värske ülevaate SfM-tarkvarast ja töövoost koos droonide kasutamisega leiab lugeja Pepe *et al.*, (2022) ülevaateartiklist.

Lisaks tavapärasele n-ö oma arvutisse installeeritud tarkvarale, on huvilistele saadaval mitmed pilveteenused. Sellisel juhul saab kasutaja oma fotod üles laadida ning mõne aja pärast saadetakse juba vastu ortofoto ja 3D-mudel. Nende puhul on aga kasutajal oluliselt väiksem võimalus kuidagi kontrollida töövoogu või täpsust. Tuntuim sellist teenust pakkuv koht on DroneDeploy.

Kindlasti tuleb fotogramm-meetria töövoos puhul arvestada suurte arvutusmahtudega, mis nõuavad suuremate andmehulkade läbitöötamisel võimekat arvutit. Osad arvutusetapid on paljudes tarkvarades optimeeritud graafikaprotsessorite (GPU – *Graphical Processing Unit*) kasutamiseks – hea videokaart on SfM-tööjaama hädavajalik osa.

Mõni tarkvara võimaldab ka osalist pilvearvutust, kus kõige mahukamate etappide arvutamise saab kasutaja tellida võrgust, säilitades samas täieliku kontrolli parameetrite üle. Kuna SfM-meetod on suure arvutusmahuga ja toodab ka üsna mürist infot, siis kõik tarkvarad kasutavad sisemist optimeerimist ja filtreerides vaheprodukte. Samuti on omavahel erinevad nii algoritmid kui ka nende rakendamise viisid. Kõik need asjaolud avalduvad ka tulemustes – erinevatest programmidest saame sama sisendiga pisut erinevaid tulemusi. Seetõttu peaks suurt täpsust nõudvates ning korduvates uuringutes kasutama võimalusel sama riist- kui ka tarkvara ja töötlemise parameetreid. Enamik tarkvaradest koostab kogu töövoost automaatse kokkuvõtte, kus on parameetrid kirjas. See kokkuvõte tuleb metaandmetena salvestada SfM abil saadud tulemuste juurde.

Kokkuvõttena saab öelda, et SfM fotogramm-meetria on hetkel üks kõige odavam meetod, et teha objektidest 3D-mudeleid ja ortofotosid. Kusjuures andmeallikatenä viivad SfM fotogramm-meetria sisendiks olla ka multispektraal- või termopildid. Kui vaadata seda meetodid kriitiku pilgu läbi, on tegemist ka pirtsaka meetodiga, mille rakendamisel tuleb arvestada päris paljude kvaliteeti mõjutavate teguritega. Eelnevat väidet toetab allolev tabel (Tabel 1), kus Iglhaut *et al.*, (2019) on teinud põhjaliku kokkuvõtte.

Tabel 1. SfM fotogramm-meetria tulemusi mõjutavad parameetrid (Iglhaut *et al.*, 2019).

Valdkond	Muutuja	Soovitus
Objekt	Tekstuur	Suur kontrastsus, mis võimaldab tuvastada võtmepunkte
	Korduvad mustrid	Suurenda ülekatteid ja georefereerimise täpsust!
	Liikuvad objektid	Välgi!
	Varjus olevad alad	Suurenda kattuvust ja vaatenurki!
Valgusolud	Päikese nurk	Kõrge! Keskpäev on parim aeg!
	Ilm	Pilvealune ühtlane valgus on parim 3D-mudelite koostamise jaoks; spektraalvaatluste puhul eelistatud selge taevast.
	Muutuv valgus	Välgi!
Kaamera parameetrid	Fookuskaugus	28–35 mm on vaikimisi sobivaim, et vähendada moonutusi.
	Heledus	Ühtlane üle pildi, kontrastne. Välgi pildil tugevalt ala- ja ülesäris alasid.
	- Ava	Väike, maksimaalse fookussügavuse jaoks*. Objektiivid on tavaliselt parima teravusega f 5,6–8 avaga.
	- Säriaeg	Kiire, et vähendada liikumisest tingitud hägusust*.
	- ISO	Madal minimaalne pildimüra* saamiseks, soovitatav vaikimisi automaatne ISO
Pildistamise plaan	Piksli füüsiline suurus anduril	*Ideaalne stsenaarium, kuid on alati selle kolme parameetri kompromiss Võimalikult suur, sest mõjutab positiivselt dünaamilist ulatust ja tundlikkust
	Ülekatted Vaatenurgad Kaugus objektist	Kõrge, > 70% piki- ja põiki, metsade puhul min 80%, termopiltide puhul 90%. Lisa kaldfotosid kaamera ja 3D-modeli paremaks arvutamiseks! Ortofoto tootmiseks kasuta ainult pinnaga risti pildistatud fotosid! Suureneva kaugusega kasvab GSD ja langeb mudelite täpsus.
Töötamise parameetrid	SfM - sobitamine - Pildi skaleerimine - Võtmepunktid MVS - tihe punktipilv Teisendused	Pildi allaskaleerimine vähendab oluliselt arvutusmahtu, kuid vähendab ka leitud sõlmpunktide hulka Erinevatel skaaladel võib piltide sobitamine olla erineva tulemuslikkusega. Tiheda punktipilve puhul võib samuti pilte allapoole skaleerida, vähendades arvutusmahtu koos lõpliku leitud punktide arvuga Punktipilvede teisendamiseks pindadeks on palju erinevaid meetodeid, mis annavad ka erineva tulemuse.

2 Kasutatud kirjandus

- Aasen, H., Honkavaara, E., Lucieer, A., & Zarco-Tejada, P. (2018). Quantitative Remote Sensing at Ultra-High Resolution with UAV Spectroscopy: A Review of Sensor Technology, Measurement Procedures, and Data Correction Workflows. *Remote Sensing*, 10(7), 1091. <https://doi.org/10.3390/rs10071091>
- Adão, T., Hruška, J., Pádua, L., Bessa, J., Peres, E., Morais, R., & Sousa, J. J. (2017). Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry. *Remote Sensing*, 9(11), 1110. <https://doi.org/10.3390/rs9111110>
- Aragon, B., Johansen, K., Parkes, S., Malbeteau, Y., Al-Mashharawi, S., Al-Amoudi, T., Andrade, C. F., Turner, D., Lucieer, A., & McCabe, M. F. (2020). A Calibration Procedure for Field and UAV-Based Uncooled Thermal Infrared Instruments. *Sensors*, 20(11), Article 11. <https://doi.org/10.3390/s20113316>
- Assmann, J. J., Kerby, J. T., Cunliffe, A. M., & Myers-Smith, I. H. (2019). Vegetation monitoring using multispectral sensors—Best practices and lessons learned from high latitudes. *Journal of Unmanned Vehicle Systems*, 7(1), 54–75. <https://doi.org/10.1139/juvs-2018-0018>
- Cao, H., Gu, X., Wei, X., Yu, T., & Zhang, H. (2020). Lookup Table Approach for Radiometric Calibration of Miniaturized Multispectral Camera Mounted on an Unmanned Aerial Vehicle. *Remote Sensing*, 12(24), Article 24. <https://doi.org/10.3390/rs12244012>
- Cramer, M., Przybilla, H.-J., & Zurhorst, A. (2017). UAV CAMERAS: OVERVIEW AND GEOMETRIC CALIBRATION BENCHMARK. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W6, 85–92. <https://doi.org/10.5194/isprs-archives-XLII-2-W6-85-2017>
- Hardin, P. J., & Jensen, R. R. (2011). Small-Scale Unmanned Aerial Vehicles in Environmental Remote Sensing: Challenges and Opportunities. *GIScience & Remote Sensing*, 48(1), 99–111. <https://doi.org/10.2747/1548-1603.48.1.99>
- Harwin, S., & Lucieer, A. (2012). Assessing the Accuracy of Georeferenced Point Clouds Produced via Multi-View Stereopsis from Unmanned Aerial Vehicle (UAV) Imagery. *Remote Sensing*, 4(6), 1573–1599. <https://doi.org/10.3390/rs4061573>

- Iglhaut, J., Cabo, C., Puliti, S., Piermattei, L., O'Connor, J., & Rosette, J. (2019). Structure from Motion Photogrammetry in Forestry: A Review. *Current Forestry Reports*, 5(3), 155–168. <https://doi.org/10.1007/s40725-019-00094-3>
- James, M. R., Chandler, J. H., Eltner, A., Fraser, C., Miller, P. E., Mills, J. P., Noble, T., Robson, S., & Lane, S. N. (2019). Guidelines on the use of structure-from-motion photogrammetry in geomorphic research. *Earth Surface Processes and Landforms*, 44(10), 2081–2084. <https://doi.org/10.1002/esp.4637>
- Kelly, J., Kljun, N., Olsson, P.-O., Mihai, L., Liljeblad, B., Weslien, P., Klemedtsson, L., & Eklundh, L. (2019). Challenges and Best Practices for Deriving Temperature Data from an Uncalibrated UAV Thermal Infrared Camera. *Remote Sensing*, 11(5), 567. <https://doi.org/10.3390/rs11050567>
- Logie, G. S. J., & Coburn, C. A. (2018). An investigation of the spectral and radiometric characteristics of low-cost digital cameras for use in UAV remote sensing. *International Journal of Remote Sensing*, 39(15–16), 4891–4909. <https://doi.org/10.1080/01431161.2018.1488297>
- Martínez-Fernández, A., Serrano, E., Pisabarro, A., Sánchez-Fernández, M., de Sanjosé, J. J., Gómez-Lende, M., Rangel-de Lázaro, G., & Benito-Calvo, A. (2022). The Influence of Image Properties on High-Detail SfM Photogrammetric Surveys of Complex Geometric Landforms: The Application of a Consumer-Grade UAV Camera in a Rock Glacier Survey. *Remote Sensing*, 14(15), Article 15. <https://doi.org/10.3390/rs14153528>
- Nex, F., Armenakis, C., Cramer, M., Cucci, D. A., Gerke, M., Honkavaara, E., Kukko, A., Persello, C., & Skaloud, J. (2022). UAV in the advent of the twenties: Where we stand and what is next. *ISPRS Journal of Photogrammetry and Remote Sensing*, 184, 215–242. <https://doi.org/10.1016/j.isprsjprs.2021.12.006>
- Olsson, P.-O., Vivekar, A., Adler, K., Garcia Millan, V. E., Koc, A., Alamrani, M., & Eklundh, L. (2021). Radiometric Correction of Multispectral UAS Images: Evaluating the Accuracy of the Parrot Sequoia Camera and Sunshine Sensor. *Remote Sensing*, 13(4), Article 4. <https://doi.org/10.3390/rs13040577>
- Pepe, M., Alfio, V. S., & Costantino, D. (2022). UAV Platforms and the SfM-MVS Approach in the 3D Surveys and Modelling: A Review in the Cultural Heritage Field. *Applied Sciences*, 12(24), Article 24. <https://doi.org/10.3390/app122412886>

- Rejeb, A., Abdollahi, A., Rejeb, K., & Treiblmaier, H. (2022). Drones in agriculture: A review and bibliometric analysis. *Computers and Electronics in Agriculture*.
<https://doi.org/10.1016/J.COMPAG.2022.107017>
- Turner, D., Lucieer, A., & Wallace, L. (2014). Direct Georeferencing of Ultrahigh-Resolution UAV Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 52(5), 2738–2745.
<https://doi.org/10.1109/TGRS.2013.2265295>
- Vautherin, J., Rutishauser, S., Schneider-Zapp, K., Choi, H., Chovancova, V., Glass, A., & Strecha, C. (2016). PHOTOGRAMMETRIC ACCURACY AND MODELING OF ROLLING SHUTTER CAMERAS. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, III–3, 139–146.
<https://doi.org/10.5194/isprsannals-III-3-139-2016>