

In opdracht van

Agentschap voor Natuur en Bos



**Onderzoek naar de bestaande
innovatieve technieken van drones i.k.v.
maislachtoffers.**

Datum:05/07/2023

COLOFON

Titel	Onderzoek naar de bestaande innovatieve technieken van drones i.k.v. maaislachtoffers.
Datum	05/07/2023
Versie	Finaal
Opdrachtgevers	Agentschap voor Natuur en Bos
Uitgevoerd door	Landmax bv - Part of United Experts Biezeweg 15a 9230 Wetteren
Projectleider	Jan Kempeneers
Projectmedewerkers	Jonas Lequeu Samuel Van de Walle Sebastiaan Verbesselt (ILVO)

INHOUD

1	Situering.....	4
1.1	Structuur van het document	4
1.2	Relevantie van maaislachtoffers	4
1.3	Remote sensing en beeldherkenning	6
2	Overzicht van de regelgeving	7
2.1	Kernpunten	7
2.2	Algemeen	7
2.3	Categorie “Open”	9
2.3.1	Subcategorieën	9
2.3.2	Vluchtvereisten	10
2.3.3	Vliegzones	10
2.3.4	Natuurbescherming	13
2.3.5	Certificering.....	14
2.3.6	Registratie	14
2.3.7	Verzekering	14
2.4	Categorie “Specifiek”	15
2.4.1	Aanleiding voor gebruik categorie specifiek	15
2.4.2	Bijkomende vluchtvoorwaarden	15
2.4.3	Vergunningsopties	16
2.5	Categorie “Gecertificeerd”	19
2.6	Verdere info	19
3	Luik beschikbare technieken	20
3.1	Kernpunten	20
3.2	Algemeen	21
3.3	Detectiemethoden	21
3.3.1	Algemeen	21
3.3.2	RGB en geautomatiseerde beeldverwerking	21
3.3.3	Warmtebeeldcamera’s.....	22
3.3.4	Multispectraal en hyperspectraal	24
3.4	Commerciële drone en camera modellen	25
3.4.1	DJI Mavic 3 Enterprise thermal	26
3.4.2	Yuneec Typhoon H520E	26
3.4.3	DJI Mavic 2 Enterprise Advanced	28
3.4.4	DJI Matrice 300 RTK	29
3.4.5	DJI Matrice 30T	30
3.4.6	DJI Phantom 4 Pro RTK.....	31
3.4.7	Teledine flir SIRAS	32
3.4.8	Parot Anafi USA.....	33
3.4.9	Auel Evo II dual.....	34

3.4.10 Recreatieve drones	34
4 Literatuurstudie koppeling met beeldverwerking	35
4.1 Kernpunten	35
4.2 Gebruik van remote sensing	35
4.3 Materiaal en methoden	36
4.4 Resultaten en discussie	37
4.4.1 De modelorganismen	37
4.4.2 Vlieg- en sensorspecificaties	40
4.4.3 Omgevingsomstandigheden	44
5 Commerciële bedrijven en verenigingen in en rond Vlaanderen	46
5.1 Vlaanderen	46
5.2 Wallonië	47
5.3 Nederland.....	47
5.4 Duitsland	48
5.5 Frankrijk.....	48
6 Conclusies in Vlaamse context	49
7 Referenties.....	52
7.1 Beeldanalyse technieken om fauna te detecteren	52
7.2 Manuele tellingen van fauna o.b.v. dronebeelden	54
7.3 Bijkomende literatuur	55
8 Bijlages.....	57
8.1 Informatieve figuren	57
8.2 Tabellen.....	57
8.3 Beeldanalyse	57
8.3.1 Data verzameling	57
8.3.2 Preprocessing.....	59
8.3.3 Analyse en post-processing.....	59
8.4 Flyer Dronedivision	70
8.5 Flyer Robor-Nature.....	71

1 Situering

1.1 Structuur van het document

In dit rapport wordt een overzicht gegeven van de technische aspecten, regelgeving en technieken die relevant zijn bij het gebruik van drones voor het voorkomen van maaislachtoffers.

Hoofdstuk 2 schetst de huidige regelgeving en de verwachte evolutie daarin. De wetgeving is de voorbije jaren sterk geëvolueerd en deze reorganisatie is nog niet afgerond. Bij het uitwerken van een praktisch plan voor het inzetten van drones i.k.v. maaislachtoffers moet dus rekening gehouden worden met toekomstige wetgeving waarvan de datum van inwerkingtreding nog niet vaststaat. Het voordeel is wel dat de wetgeving nu Europees is geüniformeerd en met name voor laag risico vluchten is vereenvoudigd.

Hoofdstuk 3 geeft een overzicht van de technieken die in het verleden al zijn toegepast voor het detecteren van maaislachtoffers. Dit omvat een omschrijving van de gebruikte technologie en de behaalde resultaten. Hierbij hoort ook een overzicht van commerciële drone modellen die momenteel op de markt beschikbaar zijn. Dit om een beeld te vormen van de benodigde investering om dergelijke technieken te kunnen toepassen.

Uit recente pilootprojecten blijkt dat het succes van vluchten met warmtebeeld camera's afhankelijk is van de omgevingstemperatuur van dat moment. Zo is het succes het grootst op de koudste momenten van de dag, wanneer het temperatuurverschil tussen de dieren en de omgeving het grootst is. Dit is een belangrijke beperking op de toepasbaarheid van dergelijke benadering. De zoektocht naar "betere" technieken gaat dus verder. Toepassing van beeldherkenningstechnieken die vertrekken van normale videobeelden zijn daarbij een belangrijke piste.

Hoofdstuk 4 gaat daarom in op de wetenschappelijke literatuur die beeldherkenning toepast op het detecteren van fauna. Dit gaat dus breder dan enkel het detecteren van maaislachtoffers, maar de gebruikte technieken overlappen sterk met wat ook in dit kader toepasbaar zou zijn.

In hoofdstuk 5 bespreken we de praktijksituatie in Vlaanderen en de ons omliggende regio's (landen). Daarbij wordt ook de input gebruikt van bedrijven die praktijkervaring hebben met het inzetten van drones ter voorkoming van maaislachtoffers.

Hoofdstuk 6 is een algemene synthese die de conclusies en informatie uit de voorgaande hoofdstukken bundelt om concreet de huidige toepasbaarheid van deze technologieën in de Vlaamse context te schetsen.

De technische hoofdstukken 2,3 en 4 vangen aan met een overzicht van de kernpunten. Door enkel deze kernpunten door te nemen zal de lezer de belangrijkste conclusies en inzichten uit dit document verkrijgen zonder daarbij in te gaan op de technische achtergrond. Deze paragrafen staan steeds in grijs aangeduid.

1.2 Relevantie van maaislachtoffers

In de afgelopen decennia heeft de intensivering in de landbouwsector geleid tot de ontwikkeling van zeer efficiënte landbouwmachines. Deze intensivering heeft geleid tot een verbetering van de efficiëntie van de verplaatsingstechnieken, waardoor bijvoorbeeld gras maaien gepaard gaat met werksnelheden van meer dan 15 km/h en werkbreedten van meer dan 14 m (Prosekov et al., 2020).

Hoewel het moeilijk te beoordelen is in welke mate de populaties van wilde dieren negatief beïnvloed worden door maai-beheer, bestaat er geen twijfel over dat het risico van accidenten en onopzettelijke doding van wilde dieren tijdens routinematige landbouwactiviteiten in de loop der jaren sterk is toegenomen.

Enkele soorten hebben een verhoogd risico op maai-accidenten, met name grond broedende akker- en weidevogels tijdens hun broedtijd, jonge hazen en reekalven. Bij de vogels zijn het voornamelijk de nesten die kapot gereden worden en/of het broedend vrouwtje dat verwond/gedood wordt (Prosekov et al., 2020). Jonge hazen en reekalven hebben de eerste weken na de geboorte het natuurlijk instinct om stil te blijven liggen in de hoge vegetatie om zo predatoren te mijden (Israël, 2011; Curkor, 2019; Prosekov et al., 2020). Dit verhoogt het risico op verwonding of doding tijdens maaioperaties.

Er zijn geen recente cijfers gekend over het aantal maaislachtoffers in Vlaanderen of omliggende regio's en welk effect het huidige maai-beheer heeft op de wildpopulaties. Ter illustratie: schattingen in Duitsland uit 1976-1977 geven aan dat het sterftecijfer van de maaislachtoffers in verhouding tot het jaarlijkse totale afschotcijfer voor reeën 14,5%, voor hazen 13,4%, voor konijnen 1,1%, voor fazanten 22,9%, en voor patrijzen 21,9% bedraagt (Prosekov et al., 2020). Voor pasgeboren reekalven wordt in Duitsland zelfs een mortaliteit van 25% geschat door maai-accidenten (Israël, 2011). Sinds voorgaande studies werden uitgevoerd zijn de maai-frequenties enkel maar toegenomen zodat we er van kunnen uitgaan dat de negatieve impact op de wildpopulaties is toegenomen. Ondanks het ontbreken van recente cijfers over het aantal maaislachtoffers in Vlaanderen wordt verwacht dat maaien (zeker indien te frequent of tijdens de kwetsbare perioden) ook in Vlaanderen een significant negatieve invloed heeft op de populaties van bepaalde wildsoorten.

Maaislachtoffers zijn niet enkel een probleem op vlak van dierenwelzijn maar ook op vlak van gezondheid. Indien de karkassen onopgemerkt in het kuilvoer komen, produceren bacteriën als *Clostridium botulinum* een dodelijk gif (botulinetoxine) tijdens het afbraakproces (Israël, 2011). Dit gif zorgt voor gezondheidsrisico's in het voer voor koeien, wat een groot economisch verlies kan betekenen voor de landbouwer.

Steeds meer ecologische studies gebruiken remote sensing (in Vlaanderen soms ook teledetectie genoemd) om fauna te detecteren. Dit is te merken aan de verschillende review papers (Chabot & Bird, 2015 en 2016; Corcoran et al., 2021; Hyun et al., 2020; Linchant et al., 2015; Wirsing, Johnston & Kiszka, 2022; Charbonneau & Lemaître, 2021; Prosekov et al., 2020) die gepubliceerd zijn in de afgelopen 22 jaar omtrent deze technologie. Metingen vanuit de lucht (bemande en onbemande luchtvoertuigen) hebben als voordeel dat een groter gebied in kaart kan gebracht worden in vergelijking met terreinmetingen. Ook kan fauna in minder toegankelijke gebieden hiermee in kaart worden gebracht. Verder kunnen terreinmetingen meer nestverstoringen, beschadiging aan nesten, geursporen en stress bij de dieren veroorzaken in vergelijking met luchtmetingen (Chabot & Bird, 2015; Hyun et al., 2020; Linchant et al., 2015; Prosekov et al., 2020; Tuia et al., 2022; Wang et al., 2019; Wirsing et al., 2022). Dieren die (deels) verscholen liggen tussen vegetatie of op het terrein zijn moeilijker te observeren/detecteren vanuit de lucht. Wat detectie vanuit de lucht betreft zijn dronevluchten zijn veel goedkoper in vergelijking met bemande luchtmetingen waardoor deze technologie de laatste jaren meer verkozen wordt bij onderzoek.

Er zijn reeds talrijke pilootprojecten met drones om maaislachtoffers te vermijden bekend in Vlaanderen, Nederland, Wallonië, Frankrijk. Er zijn eveneens onderzoeksprojecten die gesteund worden door de Europese gemeenschap.

1.3 Remote sensing en beeldherkenning

Het maaien van graslanden, bermen, akkers en ruigte kan voornamelijk maaislachtoffers veroorzaken bij jonge hazen (*Lepus europaeus*), reekalveren (*Capreolus capreolus*) en grond broedende akker- en weidvogels. Omdat de detectie van deze soorten een lastig en tijdrovend proces is via terreinmetingen, stijgt de interesse in detectie vanuit de lucht door middel van drones en het gebruik van kleurencamera's (RGB) en thermische/warmtecamera's. Deze technologie kende al een evolutie in verschillende ecologische studies in het kader van populatietellingen, nestdetectie, broedpaardetectie, predator-prooi interacties, epidemiologiestudies en gedragsstudies (Chabot & Bird, 2015 en 2016; Corcoran et al., 2021; Hyun et al., 2020; Linchant et al., 2015; Wirsing, Johnston & Kiszka, 2022; Charbonneau & Lemaître, 2021; Prosekov et al., 2020). Via dronebeelden kunnen dieren gedetecteerd, geteld en eventueel op soort gebracht worden. Omdat de manuele identificatie van diersoorten via dronebeelden tijdsintensief kan zijn (vb. bij zeer grote populaties of bij weinig zichtbare soorten) en daarbij ook onderworpen is aan een observator bias, gebruiken recentere studies steeds meer beeldverwerkingstechnieken en machine learning om dit proces meer automatisch (en in sommige gevallen meer objectief) te laten verlopen. De literatuurstudie (hoofdstuk 4) laat zien dat er vele mogelijkheden bestaan voor (semi)automatische detectie van dieren, met zowel RGB- of warmtebeeldcamera alsook een combinatie van beide sensoren. In het kader van maaislachtoffers blijkt de warmtebeeldcamera de voorkeur te krijgen doordat de dieren dankzij hun camouflage weinig kleurencontrast hebben t.o.v. hun omgeving. Het vooraf kalibreren van de camera, het afstellen van de vliegparameters en het vliegen bij het hoogste warmtecontrast met de omgeving (vb. 's nachts en in de vroege ochtend) zijn cruciale stappen om de vluchtmissie en dataverzameling te doen slagen. Waarschijnlijk zijn deze stappen nog belangrijker dan het kiezen van het beeldverwerkingsalgoritme achteraf. Momenteel zijn er al enkele studies die machine learning modellen (Christiansens et al., 2014; Israël & Evers, 2011) hebben ontwikkeld op basis van warmtebeelddata om fauna te detecteren in het kader van maaislachtoffers, maar verdere studies zijn nodig om de effectiviteit hiervan volledig te bepalen. In niet-wetenschappelijke kringen zijn commerciële bedrijven reeds bezig met het toepassen van beeldherkenning op gecombineerde RGB/warmtebeeld data maar van hun resultaten en nauwkeurigheid zijn geen verifieerbare data voorhanden.

2 Overzicht van de regelgeving

2.1 Kernpunten

De nieuwe Europese wetgeving (gepubliceerd op 31/12/2021 en in werking getreden vanaf 01/01/2022) voorziet 3 categorieën; “Open”, “Specifiek” en “Gecertificeerd”. Deze categorieën komen overeen met “Laag”, “Matig” en “Hoog” risico en hebben naventante regelgeving. Vooral de “Open” categorie is van belang in het kader van de preventie van maaislachtoffers. Enkel als buiten het zicht van de piloot moet worden gevlogen, als een hoogte van 120m wordt overschreden of als met drones van >4kg dicht bij bevolkte gebieden wordt gevlogen zal de complexere regelgeving van de categorie “Specifiek” van toepassing zijn. Met de huidige technologie is dit voor de detectie van maaislachtoffers in de meeste gevallen niet nodig en heeft de “Open” categorie dus de voorkeur. De categorie “Gecertificeerd” is gericht op bv. luchtvaarttoepassingen en heeft geen relevantie in deze studie.

Op basis van het gewicht, of in de toekomst Cx-Labels, van de gebruikte drone valt een vlucht onder de “Open” subcategorieën A1 tot A3. Tot de Cx-labels zijn geïmplementeerd, vermoedelijk begin 2024, geldt een overgangsregeling. De subcategorieën leggen beperkingen op over hoe dicht bij mensen/bewoonde gebieden mag worden gevlogen. In subcategorie A3 mag niet dichterbij dan 150m van bebouwing, industrie en recreatiegebieden gevlogen worden. De subcategorieën A1 (niet over bijeenkomsten van mensen vliegen) en A2 (30m afstand houden van niet betrokken mensen) zijn daarom het meest geschikt voor het detecteren van maaislachtoffers. In de praktijk komt dit neer op drones met een C0, C1 of C2 label of in de overgangsregeling drones van <2kg.

Om in de “Open” categorie te vliegen moet de piloot een online opleiding voltooien en slagen voor een examen. Dit volledige parcours neemt ongeveer 4u tijd in beslag en is volledig gratis. Eens de kandidaat geslaagd is voor het examen, is een bewijs van verzekering nodig om het certificaat te bekomen. Behalve voor C0-drones is een verzekering voor burgerlijke aansprakelijkheid vereist voor het vliegen met een drone. Voor de subcategorie A2 moet de piloot bijkomend aan het certificaat praktijkervaring kunnen aantonen (praktijkopleiding of ervaring op zelfstandige basis). Het examen kan afgelegd worden op de website van het examenplatform van de Federale overheidsdienst mobiliteit en vervoer.

Voor elke vlucht moet de piloot nagaan of er op de locatie van de vlucht beperkingen gelden. Dit kan op de website van Skeyes. Dit is het overheidsbedrijf verantwoordelijk voor de veiligheid van het luchtverkeer. Op de website zijn zogenaamde “geozones” te vinden waarin specifieke beperkingen of een verbod kunnen gelden. Deze zones zijn momenteel allen gericht op de bescherming van luchthavens en andere maatschappelijk gevoelige locaties.

2.2 Algemeen

De wetgeving omtrent onbemande vliegende objecten spreekt over UAV's (Unmanned Aerial Vehicle) . De multirotor systemen die tegenwoordig veelvuldig beschikbaar zijn op de commerciële markt worden over het algemeen “drones” genoemd. Deze veelgebruikte maar niet-officiële

benaming “drones” zal ook verder in dit document gebruikt worden tenzij het specifiek over wetgevende terminologie gaat.

Vanaf 1 januari 2021 gelden Europese regels voor UAV's. De verschillen in regelgeving tussen landen worden hierdoor kleiner en er wordt ook geen onderscheid meer gemaakt tussen recreatief en beroepsmatig vliegen met een UAV.

De wetgeving voorziet 3 categorieën naargelang het risicoprofiel; “Open”, “Specifiek” en “Gecertificeerd” welke overeenkomen met een “low”, “medium” of “high” risico. In het kader van het voorkomen van maaislachtoffers of het inventariseren van nesten is vooral de “open” categorie van belang. Het gaat dan om vluchten binnen het zicht van de piloot, op minder dan 120m hoogte en met een drone van <25kg. Als het om complexere vluchten gaat die aan het voorgaande niet voldoen zal de categorie “specifiek” van toepassing zijn, maar de mogelijke voordelen moeten afgewogen worden tegen de complexere regelgeving. De categorie “gecertificeerd” zal nooit van toepassing zijn voor vluchten in het kader van maaislachtoffers.

Hoewel de Europese wetgeving van kracht is bevinden we ons in 2023 nog in een overgangsfase. Voor de “open” categorie is de wetgeving namelijk georganiseerd rond de opdeling van drones volgens model specifieke Cx-labels (C0 tot C4) afhankelijk van hun gewicht en technische specificaties. Alle modellen van drones die momenteel op de markt of in omloop zijn bevinden zich nog in de overgangsregeling doordat er momenteel nog onderhandeld wordt over de technische vereisten voor de labels. De huidige drones hebben dus nog geen Cx-label en worden enkel op basis van gewicht geclassificeerd. Er kan geen inschatting worden gedaan over hoe dit verder zal evolueren zolang er geen overeenkomst wordt gevonden tussen de fabrikanten en de Europese wetgever.

2.3 Categorie “Open”

2.3.1 Subcategorieën

Voor veel van de vluchten met als doel het voorkomen van maaislachtoffers of het inventariseren van nesten zullen drones in de open categorie volstaan.

Vluchten in de open categorie worden verdeeld in 3 subcategorieën (A1-A3) elk met hun eigen regelgeving en technische specificaties. Hoe groter en zwaarder de drone is, hoe hoger de klasse en hoe strenger de voorzorgmaatregelen. Dit impliceert niet noodzakelijk dat er meer opleiding/certificering nodig is om in een hogere subcategorie te kunnen vliegen.

In onderstaande tabel (Tabel 1) zijn de subcategorieën, voorzorgmaatregelen en hun certificering opgesomd.

Tabel 1 Voorzorgsmaatregelen en certificering subcategorieën

Subcategorie	Voorzorgsmaatregelen	Certificering
A1	Over mensen vliegen mag in beperkte mate, maar niet over een bijeenkomst	Online examen A1/A3
A2	Niet over mensen vliegen en afstand van 30m van personen behouden (of 5m in lage snelheidsmodus)	Online examen A1/A3 + certificaat praktijkervaring
A3	Afstand van 150m van bevolkte gebieden* behouden en 30m afstand van personen behouden	Online examen A1/A3

*bebouwing, industrie en recreatiegebieden

Gezien de strengere beperkingen wordt voor A3 het risico zelfs lager ingeschat dan voor A2. Voor vliegen onder A2 omstandigheden (dichter bij mensen en middelgrote drones) is dan ook een bijkomend bewijs van praktische ervaring nodig. Een drone mag ook steeds in een hogere subcategorie gevlogen worden dan waarin hij standaard ingedeeld is. In de praktijk komt dat neer op meer voorzorgsmaatregelen nemen dan wettelijk verplicht.

Enkel in subcategorie 1 mag in beperkte mate over mensen gevlogen worden. Het mag echter niet gaan om een bijeenkomst van mensen. Een bijeenkomst wordt niet gedefinieerd door een specifiek aantal mensen, maar houdt verband met de mogelijkheid van individuen om zich te verplaatsen ten einde niet door de drone geraakt te worden. Indien een groep mensen zo dicht op elkaar staat dat de mogelijkheid om te vluchten of weg te lopen van de drone beperkt is, wordt deze groep beschouwd als een bijeenkomst van mensen. Het is de verantwoordelijkheid van de piloot om dit correct in te schatten. Voorbeelden kunnen zijn: sport-, culturele, religieuze of politieke evenementen, winkelstraten of drukke stranden en parken...


In welke subcategorie een drone mag vliegen hangt af van zijn gewicht en technische specificaties. Op basis hiervan krijgen drones een zogenaamd “Cx-label” dat bepaalt in welke subcategorie ze vallen. De lijst technische specificaties is nog niet volledig en drones die nu op markt zijn hebben dus nog geen Cx-label. Vanaf 1 januari 2023 vallen drones die zonder label in de handel gebracht werden automatisch onder A1 indien ze < 250g wegen, onder A2 als ze minder dan 2kg wegen en onder A3 indien ze <25kg wegen. Deze overgangsmaatregel zal niet meer gelden voor drones op de markt gebracht na 01 januari 2024. De wetgever rekent er op dat alle drones vanaf dan een Cx-label zullen hebben; als dit niet het geval is mag er in principe niet mee gevlogen worden. In de sector heerst

enige ongerustheid dat niet-Europese fabrikanten zich niet naar de strenge Europese wetgeving zullen willen schikken.

Onderstaande tabel (Tabel 2) geeft per subcategorie het Cx-label weer en de beperking qua maximaal gewicht en grootte. Figuur 1 geeft het logo weer dat aangebracht moet worden op de drones met de vermelding van de subcategorie.

Tabel 2 Labels en kenmerken subcategorieën

Subcategorie	Cx-Label	gewicht en grootte
A1	C0	<250g
A1	C1	<900g
A2*	C2	<4kg
A3*	C2	<4kg
A3	C3	<25kg & <3m
A3	C4	<25kg
Subcategorie	Zonder Cx-Label**	Gewicht
A1	Non-Cx	<250g
A2	Non-Cx	<2kg
A3	Non-Cx	<25kg



Figuur 1: Het logo van een C1 drone

*C2 drones vallen normaal onder A3 tenzij een certificaat van praktijkervaring kan worden voorgelegd; in dat geval mag ermee onder A2 gevlogen worden.

**Deze overgangsmaatregel zal niet meer gelden voor drones op de markt gebracht na 01/01/2024

2.3.2 Vluchtvereisten

Ongeacht de klasse of het label gelden binnen de “open” categorie een aantal regels.

-Hoogte: De maximale hoogte is 120m boven het opstijgpunt.

-Zicht: De piloot moet ten allen tijde het toestel kunnen zien (=Visual line of sight; VLOS behouden). Nachtvluchten zijn in deze categorie toegestaan als de drone voorzien is van een groen knipperlicht en de piloot steeds het toestel visueel kan waarnemen.

-Automatische vluchten: Geautomatiseerde vluchten met GPS-waypoints zijn toegestaan op voorwaarde dat de piloot op elk moment klaar staat om de manuele controle terug over te nemen. Een uitzondering hierop zijn C4 toestellen waarvoor voorgeprogrammeerde vluchten niet zijn toegestaan.

-Weersomstandigheden: Het is de plicht van de piloot zich vooraf te informeren over de te verwachten weersomstandigheden en te oordelen of dit binnen de technische specificaties van zijn toestel (en binnen zijn eigen kunnen) valt.

Het is niet wettelijk verplicht een vluchtlogboek bij te houden in de “Open” categorie. Het is echter steeds raadzaam dit te doen zodat de UAV-vliegers geregistreerd zijn. Deze gegevens zijn nuttig voor het onderhoud van het dronetoestel en om de ervaring van de piloot aan te tonen.

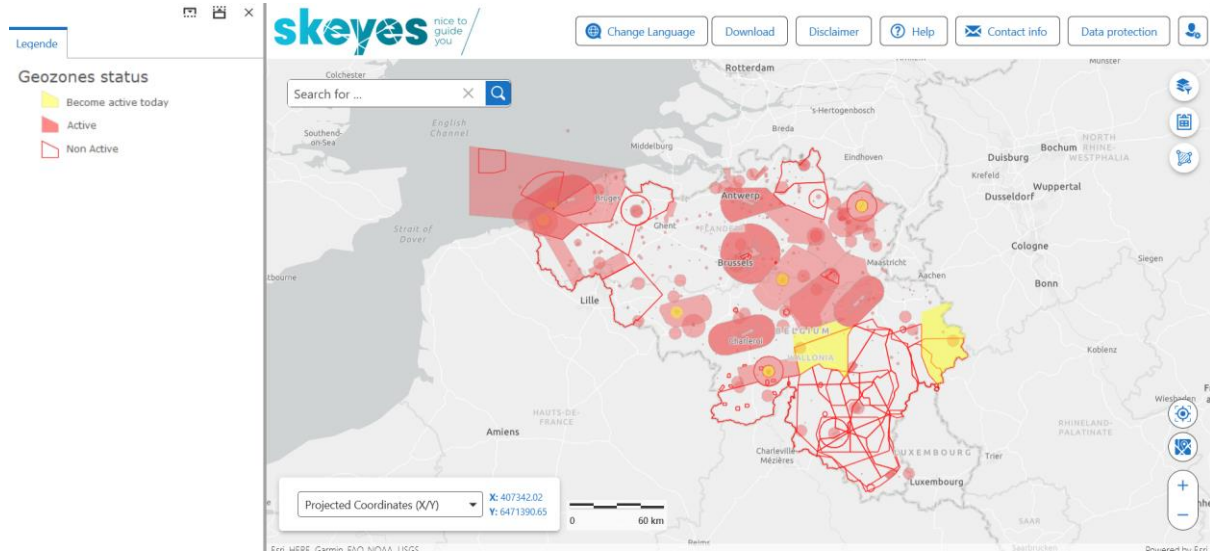
2.3.3 Vliegzones

Om redenen van veiligheid, beveiliging, privacy of milieubescherming werden op initiatief van het Directoraat Van de Luchtvaart (DGLV) geografische UAS-zones gecreëerd (in deze context ook wel “geozones”). De toegang van drones tot deze zones is onderworpen aan aanvullende voorwaarden of in bepaalde gevallen zelfs verboden. Zij hebben tot doel de veiligheid in de omgeving van

Belgische luchthavens en andere luchtvaartterreinen te garanderen, maar ook om bepaalde gevoelige sites zoals gevangenissen, nucleaire sites, koninklijke domeinen, enz. tegen mogelijke indringing met drones te beschermen. Er zijn ook geografische UAS-zones gecreëerd in overleg met skeyes (de luchtruimbeheerder) en Defensie om een gecoördineerde toegang tot zowel civiele als militaire gecontroleerde luchtruimzones (CTR) mogelijk te maken.

Vóór elke vlucht moet de piloot nagaan of er in de geplande zone geen vluchtbeperkingen gelden. Hiervoor moet de volgende website geraadpleegd worden (Figuur 2):

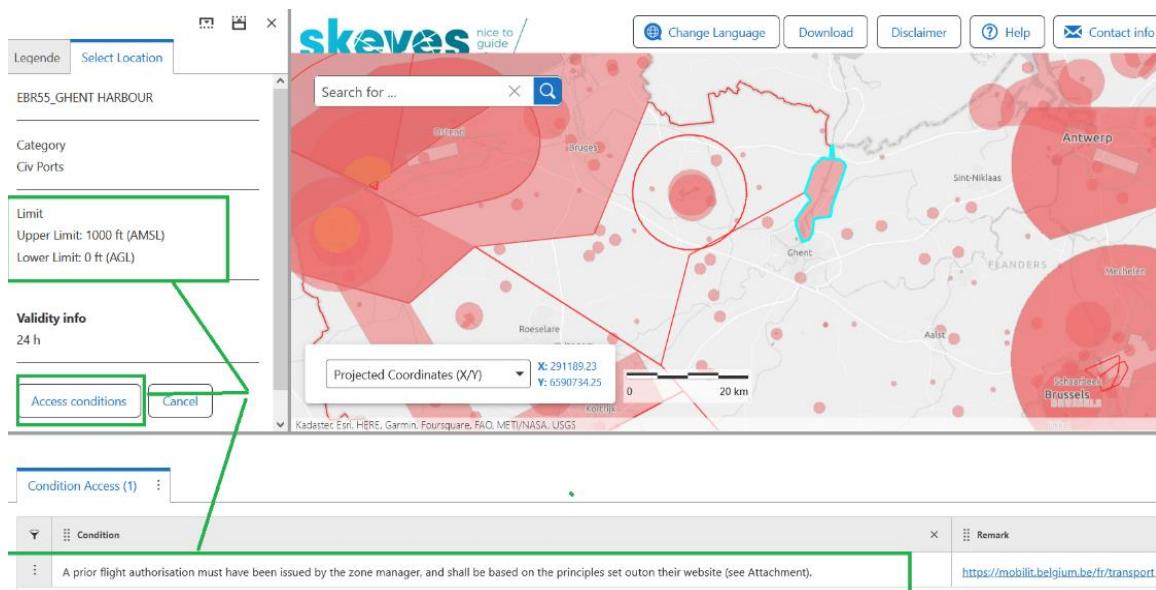
<https://map.droneguide.be/>



Figuur 2: De geozones op 22 december 2022 volgens map.droneguide.be

Alle bestaande zones zijn op deze kaart aangeduid. De zones kunnen ofwel actief of niet actief zijn. Of er kan meegegeven worden dat een zone later op de dag actief zal worden.

Door een specifieke zone te selecteren verschijnen de hoogtebeperkingen en een knop om de access conditions (Figuur 3) te raadplegen. De hoogtebeperkingen zijn in veel gevallen niet relevant omdat ze vaak hoger zijn dan de limiet van 120m die staat op "Open" vluchten. Als meerdere zones overlappen verschijnt een keuzemenu om de gewenste zone te selecteren.



Figuur 3: Bij selectie van een geozone worden de beperkingen weergegeven en kunnen de "acces conditions" bekeken worden.

Voor sommige zones gelden uitgebreide voorwaarden (Figuur 4). Zo kan er bijvoorbeeld naast een maximumhoogte ook een minimale operationele hoogte zijn, kunnen er beperkingen zijn voor de toegelaten (sub-) categorieën of moet vooraf toestemming gevraagd worden aan de zonebeheerder.

Condition	Remark
UAS operations in the 'open' category must not be conducted at a height above one hundred and fifty feet AGL.	
UAS operations in the 'specific' category must not be conducted at a height above four hundred feet AGL.	
The flight must be reported at least three hours before the start in such a way as prescribed by the zone manager; if no conditions or p	
The start and the end of each flight must be reported in such a way as prescribed by the zone manager.	
Using a direct remote identification system is mandatory, but for UAS operations performed in the "open" category with a UAS with a m	
Using a geo-awareness system is mandatory, but for UAS operations performed in the "open" category with a UAS with a maximum tak	
The pilot must be available at all times during the flight on a dedicated telephone registered in advance with the zone manager.	
A flight may be cancelled at any time for safety or security reasons by the ATS unit concerned.	

Figuur 4: Voorbeeld van bijkomende voorwaarden.

2.3.4 Natuurbescherming

Binnen Natura2000-gebieden is het Natuurdecreet van 21/10/1997, artikel 35, paragraaf 2, deel 12 van toepassing. Dit stelt dat het verboden is om “*het terrein op geringe hoogte te overvliegen of er te landen met vliegtuigen, helikopters, luchtballons en andere luchtvaartuigen van om het even welke aard*” tenzij het tegendeel is opgenomen in een goedgekeurd beheerplan. Er is echter geen definitie van “op geringe hoogte overvliegen” waardoor de wetgeving vaag is. Bovendien stamt dit van ver voor de opkomst van drones. De overheid lijkt dit te erkennen want op een schriftelijke vraag¹ in 2020 over het onderwerp geeft bevoegd minister Demir aan dat hoewel Natura2000 gebieden onder deze wetgeving als beschermd opgenomen zijn, er bijkomende bescherming mogelijk is onder de nieuwe dronewetgeving. “Het nieuwe KB voorziet echter ook in een procedure waarbij overheidsinstanties of rechtspersonen die zich op een belang kunnen beroepen, bij het DGLV een gemotiveerde aanvraag kunnen indienen voor de afbakening van bijkomende geografische UAS-zones. Dit kunnen ook specifieke milieuzones zijn, bijvoorbeeld in functie van de bescherming van Natura 2000 gebieden of andere natuurgebieden.” Het zal dus in de toekomst mogelijk zijn geozones af te bakenen met bescherming van natuurgebieden als enige doel.

De geozones zijn momenteel volledig gericht op het beschermen van maatschappelijk gevoelige sites en luchtvaartveiligheid. Momenteel zijn er nog geen geografische UAS-zones afgebakend met het oog op natuurbeheer. In opdracht van ANB leverde INBO een advies² over de invloed van drones op Natura-2000 gebieden en mogelijke beschermingsmaatregelen.

Omdat drones een redelijk recent fenomeen zijn is er nog maar beperkt onderzoek gedaan naar de impact van drones op biodiversiteit. Volgens het INBO advies wijst de beschikbare literatuur vooral op de gevoeligheid van (broed)vogels en grote zoogdieren maar er zijn veel kennishiaten. De verstoring zou het grootst zijn bij lage en onregelmatige vluchten. In het kader van maaislachtoffers zijn vooral systematische vluchten van toepassing en wordt meestal een vluchthoogte van >20m behouden. Dit is voor de meeste weidevogels voldoende om geen gedragsverandering te veroorzaken. Herhaalde verstoring kan ertoe leiden dat een voorheen geschikt leefgebied ongeschikt wordt en/of dat de reproductieve output van individuen daalt (als gevolg van stress en verhoogd energiegebruik), wat uiteindelijk negatieve effecten kan veroorzaken op populatieniveau voor de soort (afname van de populatie). Vanaf welk niveau van verstoring (intensiteit, frequentie) een blijvende impact op populaties te verwachten is, is soort- en contextafhankelijk en daardoor zeer moeilijk te bepalen. Daarom wordt gepleit voor het voorzorgsprincipe.

INBO acht het zinvol om gevoelige zones als geozone aan te wijzen waarin er een verbod komt op recreatief dronegebruik, waar een maximum spanwijdte van 1,5m geldt en waar een operationele vlieghoogte van minstens 70m moet worden aangehouden. Voor het opstellen van temporele beperkingen (bv. broedseizoen) is verder onderzoek nodig. Onder deze maatregelen zouden vluchten voor maaislachtoffers nog grotendeels kunnen doorgaan in de buurt van beschermde natuurgebieden.

¹ SV 930: <http://docs.vlaamsparlement.be/pfile?id=1598699>

² Advies INBO.A.3943 2020 <https://purews.inbo.be/ws/portalfiles/portal/19331861/INBO.A.3943.pdf>

Ongeacht specifieke geozones en het natuurdecreet zijn voor de bescherming van Natura2000-gebieden ook de betreffende beheerplannen van toepassing om dronevluchten te beperken. Daarin is beschreven welke activiteiten al dan niet toegestaan zijn. Omdat dronevluchten een relatief recente ontwikkeling zijn, staan deze vaak niet opgenomen in de beheerplannen. De wetgeving moet hier dus nog verder evolueren om duidelijkheid te scheppen.

2.3.5 Certificering

Om in subcategorie A1 en A3 te vliegen moet de piloot een online opleiding voltooien en slagen voor een bijkomend examen. Dit volledige parcours neemt ongeveer 4u tijd in beslag en is volledig gratis. Eens de kandidaat geslaagd is voor het examen, is een bewijs van verzekering nodig om het certificaat te bekomen.

Het examen kan afgelegd worden op de website van het examenplatform³ van de Federale overheidsdienst mobiliteit en vervoer.

Voor de subcategorie A2 moet de piloot, bijkomend aan het A1/A3 certificaat, een praktijkopleiding volgen. Deze mag eventueel als zelfstudie worden uitgevoerd volgens de exploitatievoorwaarden van subcategorie A3. Vervolgens moet de kandidaat de opgedane kennis aantonen door te slagen voor een extra theoretisch examen dat in de lokalen van het DGLV wordt georganiseerd.

2.3.6 Registratie

Elke exploitant moet zich registreren bij het directoraat-generaal voor de luchtvaart (DGLV). De exploitant moet niet noodzakelijk de piloot zijn, maar kan bv. ook de werkgever of eigenaar van de drone zijn. Het is de verantwoordelijkheid van de exploitant erop toe te zien dat de piloot over de vereiste bekwaamheid en certificering beschikt. De registratie als "UAS exploitant" moet gebeuren via het online portaal van de Federale overheidsdienst mobiliteit en vervoer. Zonder registratie zijn geen vluchten toegestaan.

Aan het einde van de registratieprocedure ontvangt de UAS exploitant een registratienummer, dat op alle door de exploitant gebruikte drones moet aangebracht worden. Het is dus niet nodig om individuele drones te registreren. Met het registratienummer mag in alle Europese lidstaten gevlogen worden. Individuele vluchten moeten niet geregistreerd worden tenzij de geozone dit specifiek vereist.

2.3.7 Verzekering

In de meeste gevallen is een burgerlijke aansprakelijkheidsverzekering nodig voor de exploitant. Voor drones met een gewicht van >20kg is een specifieke verzekering vereist. Enkel voor drones met een C0 label is geen verzekering vereist maar in dat geval wordt een familiale verzekering wel aangeraden.

³ <https://mobilit.belgium.be/nl/luchtvaart/vliegen-met/drones-uas/opleidingen-en-examens>

2.4 Categorie “Specifiek”

2.4.1 Aanleiding voor gebruik categorie specifiek

Voor een groot deel van de vluchten met als doel het voorkomen van maaislachtoffers of het inventariseren van nesten zullen drones in de open categorie volstaan. Maar in specifieke gevallen kan ook de categorie “specifiek” van toepassing zijn. Binnen de categorie “specifiek” zijn er verschillende pistes om de benodigde vergunning te bekomen eventueel met bijkomende voorwaarden voor de uitvoering van de vlucht.


Een eerste belangrijke reden om vluchten in de categorie “specifiek” uit te voeren is de afstand tot bevolkte gebieden. Grote delen van Vlaanderen bevinden zich op minder dan 150m van bevolkte gebieden (residentieel, commercieel, industrie en recreatiegebieden,...). Om daarin te kunnen vliegen komen binnen de open categorie enkel C0, C1 en C2 drones in aanmerking wat het gewicht beperkt tot 4kg. Tot eind 2023 kan met niet-Cx drones wel nog in A1 condities gevlogen worden voor zover ze minder dan 500g wegen en in A2 condities bij minder dan 2kg. Als met zwaardere drones dichtbij bewoonde gebieden moet worden gevlogen is de categorie “specifiek” van toepassing.

Een andere reden is wanneer de hoogte van 120m overschreden moet worden, buiten het gezichtsveld van de piloot geopereerd moet worden⁴, of wanneer modellen van >25kg gebruikt zullen worden. Ook dan zou de categorie “specifiek” van toepassing zijn.

2.4.2 Bijkomende vluchtvoorwaarden

Binnen de categorie “specifiek” kan het afbakenen van een gecontroleerde grondoppervlakte een bijkomende voorwaarde zijn voor vluchten. Een gecontroleerde grondoppervlakte is een gebied op de grond waarin een drone wordt geëxploiteerd en waarin kan gegarandeerd worden dat alleen betrokken personen aanwezig zijn. Deze oppervlakte is opgebouwd uit de geplande vluchtruimte (vluchtgeografie) zowel in hoogte als oppervlakte, uitgebreid met een zone voor onvoorziene voorvallen (Figuur 5). Samen geven deze het operationeel volume aan. Rondom het operationeel volume komt nog een grondrisicobuffer. Het totaal hiervan is de gecontroleerde grondoppervlakte. De zone voor onvoorziene voorvallen moet steeds minstens 10m zijn. Voor de grondrisicobuffer kunnen bijkomende voorwaarden gelden afhankelijk van het type vergunning (zie 2.4.3).

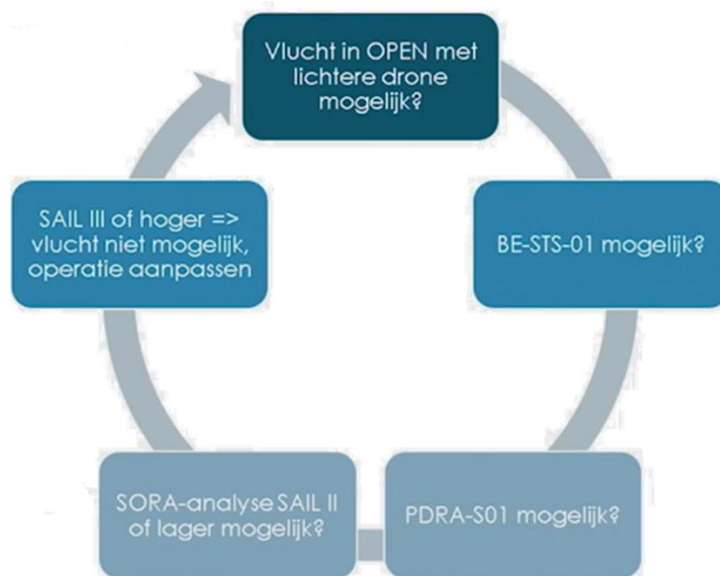
⁴ BVLOS – “Beyond visual line of sight”



Figuur 5: Afbakening zones in kader van veiligheid

2.4.3 Vergunningsopties

Om in de categorie “specifiek” te kunnen vliegen is toelating nodig. Hiervoor zijn verschillende opties mogelijk die hieronder beschreven worden. Het advies van DGLV is om steeds vooraf te bekijken of de doelstellingen alsnog niet in de categorie ‘open’ kunnen behaald worden (Figuur 6). Ook in het kader van maaislachtoffers is het dus aan te raden zoveel mogelijk binnen de ‘open’ categorie te werken.



Figuur 6: Controleproces voor bepaling vlucht

Bron: DGLV

2.4.3.1 Standaardscenario's

Het werken volgens een standaardscenario of “STS” is de meest eenvoudige manier om operaties uit te voeren binnen de ‘specifiek’ categorie. Binnen een STS zijn zowel de veiligheidsrisico's als de mitigerende maatregelen voor een bepaald type operatie vastgesteld. De operator dient enkel te beschikken over een zogenaamd operationeel handboek, en dient vervolgens een verklaring bij de nationale luchtvaartautoriteit in dat men volgens een bepaald STS vluchten gaat uitvoeren. De piloot

dient daarbij wel te beschikken over de juiste opleiding. Voordat men een standaardscenario (of STS) kan gebruiken, moet bij het DGLV een verklaring afgelegd worden als UAS-exploitant.

Momenteel is het Belgische standaardscenario, ofwel BE--STS--01, het enige beschikbare STS. Het is sinds 31 december 2020 van toepassing en houdt een lijst van precieze voorwaarden in om het risico voor anderen te beperken:

- Maximale hoogte 120m (+ max. 30m voor onvoorziene voorvallen)
- Geen vervoer van gevaarlijke goederen
- Ten allen tijde in het zicht van de piloot
- Maximumsnelheid van 5m/s (=18km/u)
- Enkel boven gecontroleerde grondoppervlakte.
- Het opmaken van een geschikt vluchthandboek (met o.a. noodinterventieplan, bewijs geschiktheid toestel, dimensionering gecontroleerde grondoppervlakte. Voor het dimensioneren van de gecontroleerde grondoppervlakte geldt onderstaande tabel (Tabel 3).

Tabel 3: Tabel met vlieghoogtes en minimale grondrisicobuffers

Maximale vlieghoogte	Minimumafstand grondrisicobuffer	
	≤10kg	>10kg
30m	10m	20m
60m	15m	30m
90m	20m	45m
120m	25m	60m

Pas vanaf 3 december 2023 wordt het mogelijk te vliegen onder twee Europese standaardscenario's (ten gevolge van de uitstelling van de inwerkingtreding van Verordening EU 2021/1166). Vanaf dan zullen verklaringen op basis van het Belgische standaardscenario niet meer mogelijk zijn maar gedane verklaringen blijven wel geldig tot 1 januari 2025 binnen het Belgische luchtruim. Gezien de meervoudige uitstelling bestaat het risico dat de Europese standaardscenario's er tegen 3 december 2023 eveneens nog niet zullen zijn.

De Europese standaardscenario's hebben het voordeel dat ze in heel Europa van toepassing zijn en openen (in geval van STS-02) ook de mogelijkheid om buiten het zicht van de piloot te vliegen. Deze STS'en zullen nauw aansluiten bij de in onderstaand hoofdstuk behandelde PDRA's (S01 & S02) en houden de volgende voorwaarden in:

- STS-01
 - Er mag niet hoger gevlogen worden dan 120 meter boven grondniveau of 15 meter boven een obstakel.
 - De drone moet altijd **in zicht** blijven
 - De vluchtuitvoering wordt verricht overeenkomstig een operationeel handboek

- De vluchtuitvoering wordt verricht boven een gecontroleerde grondoppervlakte bestaande uit het vluchtgeografiegebied, de zone voor onvoorziene omstandigheden en de grondrisicobuffer
 - De drone heeft een maximale grondsnelheid van 5 m/s
 - De vlucht wordt uitgevoerd door een gecertificeerd piloot
 - De vlucht wordt uitgevoerd met een drone gemarkeerd als **klasse C5**
- STS-02
 - De afstand tussen drone en piloot mag maximaal 1 kilometer zijn (en 2 km met waarnemer) en mag **buiten het zicht** van de piloot komen
 - De afstand tussen drone en piloot maximaal 2 kilometer is (met waarnemer)
 - Er mag niet hoger gevlogen worden dan 120 meter boven grondniveau of 15 meter boven een obstakel.
 - Er dient minimaal 5 kilometer zicht te zijn
 - De drone dient tijdens opstijgen en landen in het zicht van de piloot te zijn
 - De vluchtuitvoering wordt verricht overeenkomstig een operationeel handboek
 - De vluchtuitvoering wordt verricht boven een gecontroleerde grondoppervlakte die volledig ligt in een dunbevolkt gebied, bestaande uit het vluchtgeografiegebied, de zone voor onvoorziene omstandigheden en de grondrisicobuffer
 - De vlucht wordt uitgevoerd door een gecertificeerd piloot
 - De vlucht wordt uitgevoerd met een drone gemarkeerd als **klasse C6**

2.4.3.2 Pre-Defined Risk Assessment

Als je als operator meer mogelijkheden wenst dan waarin de Standaard Scenario's voorzien, dan is er de mogelijkheid om te werken volgens een pre-defined risk assesment (**PDRA**). Een PDRA beschrijft voor een vastgesteld type operatie de grond- en luchtrisico's. Een PDRA heeft dus geen volledig uitgewerkt formaat, maar de operator dient zelf te beschrijven hoe bepaalde risico's geminimaliseerd gaan worden. De uitgewerkte PDRA dient vervolgens door de nationale luchtvaartautoriteit te worden goedgekeurd. Samen met een operationeel handboek, de juiste opleiding en de goedgekeurde PDRA kan men dus onder een PDRA vluchten uitvoeren. Er zijn momenteel vier Europese PDRA's beschikbaar:

- PDRA-S01 (**S**pecifiek)
- PDRA-S02 (**S**pecifiek)
- PDRA-G01 (**G**eneriek)
- PDRA-G02 (**G**eneriek)

De PDRA-S01 en PDRA-S02 zijn praktisch hetzelfde als de STS-01 en STS-02. Voor beide PDRA's gelden dezelfde operationele mogelijkheden als onder STS-01 en STS-02. Echter, het C5/C6 keurmerk van de drone is onder PDRA-S01 en PDRA-S02 niet verplicht.

Binnen de generieke PDRA's zijn een beperkt aantal algemene bepalingen opgesteld. Het is vervolgens aan de operator om de mogelijke risico's te analyseren en te formuleren hoe deze geminimaliseerd gaan worden. DGLV moet de PDRA vervolgens goedkeuren.

PDRA G-01

- De drone heeft een maximale spanwijdte van 3 meter
- De operatie vindt plaats boven dunbevolkt gebied
- De operatie vindt plaats in ongecontroleerd luchtruim
- De maximale hoogte van de operatie bedraagt 150 meter boven grondniveau

PDRA G-02

- De drone heeft een maximale spanwijdte van 3 meter
- De operatie (BVLOS) vindt plaats in gereserveerd luchtruim
- De operatie vindt plaats boven dunbevolkt gebied

2.4.3.3 Specific Operations Risk Analysis (SORA)

Deze meer geavanceerde optie is waarschijnlijk niet van toepassing voor de doelstellingen van vluchten waarop dit document betrekking heeft. Bovendien gaat er vaak lange tijd over de goedkeuringsprocedure.

De SORA-methode begint met een beschrijving van het concept van de beoogde operatie (de "ConOps"). Aan de hand van deze ConOps dient de operator zelf een volledige 'Risk Assessment' uit te voeren. Binnen deze analyse wordt onder meer bekeken wat de initiële grond- en luchtrisico's zijn. Aan de hand van verschillende risico mitigerende maatregelen is het vervolgens mogelijk om deze risico's te verlagen zodat het 'Specific Assurance and Integrity Level' (SAIL) van de operatie laag blijft. Op basis van het SAIL-niveau dient de operator te voldoen aan een aantal Operational Safety Objectives (OSO's). Voordat men de vlucht kan uitvoeren moet de nationale luchtvaartautoriteit de volledige SORA goedkeuren.

2.4.3.4 Light UAS operator certificate

Een laatste optie, enkel toegevoegd voor de volledigheid, houdt in dat een organisatie de bevoegdheid haalt om zelf als Light UAS Operator Certificate (LUC) PDRA's of SORA's te mogen goedkeuren. Dit is eerder gericht naar bv. startup bedrijven in de luchtvaartindustrie.

2.5 Categorie "Gecertificeerd"

De laatste categorie 'gecertificeerd' is gericht op grootschalige drones met een risicoprofiel vergelijkbaar aan dat van de bemande luchtvaart. Deze categorie valt dus buiten de scope van deze studie en is bijvoorbeeld gericht op vervoer van mensen of gevaarlijke stoffen.

2.6 Verdere info

De wetgeving is complexer dan hierboven aangegeven maar de aspecten die relevant zijn in dit kader zijn behandeld. Diepgaandere aspecten van de wetgeving, met name operationeel technische

vereisten, zijn enkel relevant voor de piloot. Als meer informatie gewenst is kunnen onderstaande bronnen dienen ter ondersteuning.

-FOD Mobiliteit

Op de website van FOD Mobiliteit staat onder UAV een overzicht van de wetgeving met FAQ en didactische ondersteuning. Met name een webinar over de nieuwe wetgeving bevat veel interessante details.

-Dronedepot

Dronedepot is een webwinkel gespecialiseerd in de verkoop van (hobby-)drones. Op hun website is een toegankelijk overzicht van de Europese wetgeving te vinden.

-FDR1

FDR1 ("F-DR'ONE") is een online community van drone liefhebbers. Eens men zich gratis lid heeft gemaakt is er toegang tot relevante blogs en samenvattingen.

3 Luik beschikbare technieken

3.1 Kernpunten

Verschillende detectietechnieken kunnen gebruikt worden in combinatie met drones. In het kader van maaislachtoffers zijn warmtebeeldcamera's en gewone kleurencamera's (RGB) de belangrijkste detectietechnieken. Van andere detectiemethodes zijn in de literatuur of praktijk geen voorbeelden gevonden van gebruik voor de detectie van maaislachtoffers.

Camouflage en beschutting maken dat veel diersoorten moeilijk te herkennen zijn op RGB-beelden. Het afspeuren van grote oppervlaktes op zoek naar dieren en nesten op basis van de live RGB video beelden is daarom niet tijdsefficiënt.

Op warmtebeelden daarentegen zijn alle warme objecten wel duidelijk zichtbaar, maar is herkenning van de dieren veel moeilijker. Daarom wordt voornamelijk met een combinatie van beide camera's gewerkt. De warmtebeelden dienen om potentiële dieren te lokaliseren waarna met de RGB-camera nadere inspectie kan worden gedaan. Voor het toepassen van deze gecombineerde techniek zijn in Vlaanderen en daarbuiten verschillende commerciële pakketten en opleidingen beschikbaar. Er zijn ook piloten met eigen materiaal die ingehuurd kunnen worden. Vrijwilligersorganisaties die zich inzetten voor de maaislachtoffers maken veelvuldig gebruik van dergelijke piloten. Hiervan zijn verschillende voorbeelden in Vlaanderen, Wallonië, Nederland, Frankrijk en Duitsland gevonden.

Om goede resultaten te hebben met een warmtebeeldcamera moeten de opnames gebeuren bij maximaal temperatuurcontrast. De vluchten moeten daarom in de vroege ochtend of late avond uitgevoerd worden. De tijdsspanne tussen ~20u en 08u is het meest geschikt. Deze tijdsbeperving is een groot nadeel bij het gebruik van warmtebeeldcamera's.

Daarom is ook bekeken of computergestuurde beeldherkenning op basis van enkel RGB-beelden werkbaar is. In de praktijk zijn er voorbeelden van pilootprojecten die het potentieel hiervan hebben

aangetoond. Het gaat wel om gespecialiseerde software die niet kant-en-klaar of vrij te verkrijgen is. Het Vlaamse Dronedivision, biedt een commercieel pakket aan gefocust op wilddetectie.

3.2 Algemeen

In het volgende luik worden de verschillende detectiemethodes opgesomd die momenteel gekoppeld kunnen worden aan het gebruik van drones. Naast de verschillende detectiemethodes wordt er ook gekeken welke commerciële drones modellen er op de markt verkrijgbaar zijn.

3.3 Detectiemethoden

3.3.1 Algemeen

Van volgende detectiemethoden wordt beschreven hoe ze functioneren en wanneer deze bruikbaar zijn voor de detectie van mogelijke maaislachtoffers.

- RGB camera's (met beeldverwerking)
- Warmtebeeld camera's
- Multispectrale en hyperspectrale camera's

Voorts werd in de literatuur (zie hoofdstuk 4) ook het gebruik van akoestische detectie, Lidar en Sonar aangetroffen. Er werden echter geen voorbeelden gevonden waaruit blijkt dat deze technieken geschikt zouden zijn voor het detecteren van potentiële maaislachtoffers. Tot slot werd ook een voorbeeld studie gevonden die gebruik maakt van microwave detectie gemonteerd op tractoren voor het detecteren van maaislachtoffers maar met beperkte performantie. Deze technieken (Lidar, Sonar, Microwave) worden hier dan ook niet verder behandeld.

3.3.2 RGB en geautomatiseerde beeldverwerking

RGB staat voor Red Green Blue. Dit zijn de gewone (kleuren)camera's, zoals ze in dagelijkse toepassingen gebruikt worden. Met goede camera's kunnen zeer gedetailleerde beelden gemaakt worden waarop dieren te onderscheiden zijn. RGB beelden hebben in tegenstelling tot thermale beelden het voordeel dat ze overdag en bij warme temperaturen bruikbaar zijn.

De grootste uitdaging is dat de beelden in detail moeten bekeken worden om de dieren waar te nemen. In de praktijk is dit arbeidsintensief om op grote schaal toe te passen.

Om de arbeidsintensiteit te verminderen wordt bekeken of geautomatiseerde beeldverwerking kan worden toegepast om de gewenste diersoorten automatisch te detecteren.

Hier wordt specifiek verwezen naar beeldverwerkingstechnieken en niet naar artificiële intelligentie (A.I.). Niet alle beeldverwerking is immers gebaseerd op A.I. Voor eenvoudigere/consistente toepassingen kunnen ook algoritmes gecodeerd worden waarbij bepaalde parameters nog beeldspecifiek worden bepaald. In deze gevallen komt een (groot) deel van de "intelligentie" van de data-analist zelf en niet van de computer. Het is dan aan de ontwerper om te beslissen/testen op basis van welke parameters een algoritme de beelden het best kan classificeren. Machine learning en vooral deep learning modellen zijn geautomatiseerde vormen van beeldverwerking, die echt worden beschouwd als vormen van A.I. binnen de tak van "computer visie".

Deze modellen kunnen zeer krachtige toepassingen zijn van beeldanalyse mits de modellen correct getraind zijn op een voldoende kwantitatieve en kwalitatieve dataset. Het nadeel is wel dat de gebruiker soms nog nauwelijks inzicht kan krijgen in de beslissingstappen (de zogenaamde “black box” A.I.).

In de Vlaamse context kennen we 2 pilootprojecten die gebruik maakten van machine learning voor de analyse van drone beelden. In beide gevallen ging het om detectie van nesten en eieren.

De eerste toepassing⁵ was een pilootproject voor het detecteren van meeuwnesten in Oostende. Hoewel de eerste poging in 2019 veelbelovend was, waren de resultaten in het vervolgtraject in 2020 minder bemoedigend. Uit een samenvatting van de geleerde lessen bleek dat de nauwkeurigheid van detectie te wensen overlaat. Slechts ongeveer een derde van de nesten werd gedetecteerd in vergelijking met de bevindingen van het gemeentelijke meeuwenteam. Over het aantal vals positieve detecties zijn geen data beschikbaar gemaakt. Bovendien bemoeilijkte de dronewetgeving en de nabijgelegen luchthaven de organisatie van de vluchten. De conclusie was dat de techniek nog niet voldoende op punt stond. Een tweede project⁶ in 2022 ging na of een vergelijkbare techniek toe te passen was op de detectie van kievitnesten voorafgaand aan het maaien; de resultaten zijn momenteel nog niet beschikbaar.

Beeldverwerkingssoftware geschikt voor het detecteren van maaislachtoffers is niet kant-en-klaar beschikbaar. Er is wel voldoende open source software beschikbaar om een toepassing op maat te maken en/of een bestaand model te hertrainen op het detecteren van maaislachtoffers. Hiervoor is echter diepgaande expertise en ervaring nodig. Het is dus aangewezen dat de gebruiker samenwerkt met (commerciële) partners (bijvoorbeeld Dronedivision in Vlaanderen) die deze kennis kunnen aanleveren.

3.3.3 Warmtebeeldcamera's

Warmtebeeldcamera's of thermische camera's (ook wel thermale camera's genoemd) zijn een vaak gebruikte techniek bij observatie met drones. Omdat ze grote waarde hebben voor onder meer brandbestrijding, search & rescue, monitoring/ziekte detectie in de landbouw of industriële (lek)detectie, is er heel wat kant en klare technologie beschikbaar. Hoewel thermische camera's 's nachts kunnen gebruikt worden mogen ze niet verward worden met nachtvisie camera's die werken bij een lage lichtbeschikbaarheid.

Een warmtebeeldcamera is een infraroodcamera waarbij de stralingswarmte die objecten afgeven gemeten wordt. Warmtebeeldcamera's geven geen duidelijke aflijning van objecten als er geen of een te klein temperatuurverschil is met de omgeving. Zo zal bijvoorbeeld een door de zon opgewarmd grasland als één enkel vlak beeld zichtbaar worden.

Het infrarode licht dat zoogdieren en vogels door hun lichaamswarmte afgeven opent mogelijkheden om hen te onderscheiden van hun omgeving. Dit geldt in beperkte mate zelfs als zij

⁵<https://www.vvsg.be/kennisitem/vvsg/een-drone-met-beeldherkenning-voor-het-detecteren-van-meeuwnesten-oostende-deelt-geleerde-lessen>

⁶ <https://www.boerennatuur.be/maak-mee-het-verschil-voor-de-kievit/>

zich deels verscholen houden. De voorwaarde blijft dan wel dat hun lichaamstemperatuur duidelijk verschilt van de omgevingstemperatuur. In de praktijk wil dit zeggen dat de omgeving voldoende koel moet zijn. Dit beperkt het gebruik van thermische opsporing vaak tot de vroege ochtend, late avond of nacht. De precieze uren waarin geopereerd kan worden hangen dus af van de weersomstandigheden.

Door de combinatie van een RGB camera en een warmtebeeld camera kan extra informatie uit een vlucht verkregen worden. De kostprijs van een warmtebeeld camera is hoger dan van een RGB camera. Camera's die beide technieken combineren bestaan, en zijn erg prijzig.


Op de commerciële markt zijn drone piloten te vinden die geschikte toestellen bezitten en zich op dit onderwerp hebben toegelegd. Zowel in Vlaanderen (voorbeeld Falcoflight⁷) als in het buitenland zijn voorbeelden te vinden⁸. Het uitvoeren van een reeks vluchten op één ochtend begint momenteel bij een prijs €300 in de 'open' categorie (zie ook 5.1).

Uit de ervaring van piloten blijkt dat vluchten tussen ~20u00 en 08u00 het beste resultaat leveren. Een vlieghoogte tussen de 40m en 60m geeft een optimale verhouding tussen geobserveerd oppervlakte en resolutie. De hoogte is dus in de 1^e plaats beperkt door de resolutie en de kwaliteit van de camera.



⁷ <https://www.falcoflight.be/>

⁸ <https://flug-modus.de/>



Figuur 7: Illustratie van thermische beelden. Bron: flir.com en <https://enterprise-insights.dji.com/user-stories/wildlife-protection-drones-save-baby-deer>

Geavanceerde thermische camera's kunnen ook de temperatuur van de waargenomen objecten inschatten in plaats van enkel temperatuurverschillen weer te geven. Deze functie heeft voor het detecteren van wild weinig meerwaarde. Thermische camera's maken ook minder opnames per seconde dan gewone RGB camera's. Ongeveer 9Hz volstaat voor statische beelden, maar 30Hz is aangewezen om beweging te detecteren. Nog hogere frequenties hebben weinig voordeel.

3.3.4 Multispectraal en hyperspectraal

Multispectrale camera's registreren en meten de reflectie bij verschillende golflengten van licht. Voor elke golflengte wordt door de camera een beeld geproduceerd. Dit golflengtebereik is doorgaans beperkt tot spectrale banden in de blauwe, groene, rode en bijna-IR-bereiken. Hyperspectrale metingen trekken dit door tot wijder in het elektromagnetische spectrum. De techniek is hier vermeld omdat hij veelvuldig in combinatie met drones wordt toegepast in de precisielandbouw om stressgebieden in gewassen te identificeren en een objectieve meting van de plantengroei te verkrijgen. Ook voor natuurbeheer kan dit nuttig zijn. Voor het detecteren van dieren zijn geen voorbeelden gevonden waarin multispectrale of hyperspectrale beelden een voordeel opleveren ten opzichte van gewone RGB beelden.

3.4 Commerciële drone en camera modellen

Een overzicht wordt gegeven van veel gebruikte drone modellen die geschikt zijn voor gebruik in het kader van maaislachtoffers. Hiervoor werden online algemene reviews⁹ bekeken met aandacht voor camera-types. Alle beschreven drones hebben een RGB camera en de meerderheid heeft ook een thermische camera. De drone markt evolueert snel en niet al deze modellen zullen nog lange tijd beschikbaar blijven. Bovendien heeft geen enkel van de huidige modellen al een Cx-label (zie categorieën & wetgeving). Vanaf 2024 zouden nieuwe modellen deze labels moeten hebben. Het is bovendien de vraag hoe fabrikanten hierop gaan reageren aangezien deze strenge wetgeving alleen in Europa van toepassing is. Het is niet ondenkbaar dat oude modellen niet meer zullen mogen gebruikt worden. Daarmee zal rekening moeten gehouden worden om vluchten in de geschikte (sub-) categorieën uit te kunnen voeren.

Hoeveel hectaren gemiddeld per vluchtuur kunnen worden afgespeurd kan heel variabel zijn en is onder andere afhankelijk van de omgevingsomstandigheden, de gezochte diersoort en de ervaring van de piloot. Een ruwe inschatting op basis van persoonlijke informatie-inwinning en online gedeelde ervaringen resulteert in ongeveer 3 tot 8 hectare per uur (zonder geautomatiseerde beeldverwerking).

Hoewel DJI in 2022 de duidelijke marktleider was, worden ook enkele andere producenten en modellen belicht. Actueel lijkt de meest gebruikte drone voor detectie van maaislachtoffers de DJI Mavic 3 te zijn.

⁹ <https://www.dronefly.com/blogs/news/the-best-thermal-drones-and-thermal-cameras/>

<https://www.droneblog.com/drone-thermal-imaging/>

<https://www.dji.com/be/downloads/software/dji-dtat3>

<https://www.flir.eu/suas/>

https://dl.djicdn.com/downloads/dji_dtat/20221108/DJI%2BThermal%2BAnalysis%2BTool%2B3_User%2BGuide_en.pdf

<https://www.digitalcameraworld.com/buying-guides/best-thermal-drone>

3.4.1 DJI Mavic 3 Enterprise thermal



Richtprijs:	~ €4500 excl. BTW
Gewicht:	~900g
Thermische camera:	640 x 512p, 28x digital zoom
RGB camera:	wide 48MP + tele 12MP, 56x hybrid zoom
Vliegtijd:	max 45 min

De opvolger van de Mavic 2 Enterprise. Verbeterde vluchtduur en camera's inclusief een 2^e RGB camera voor detailfoto's. De bedrijven, piloten en winkels die in deze studie zijn opgenomen (zie hoofdstuk 5) hanteren veelal dit toestel of bieden het aan.

3.4.2 Yuneec Typhoon H520E



Richtprijs: ~ €3500 excl. BTW (incl. E90X thermische camera)
Gewicht: ~1645g
Thermische camera: E90X - 20 MP
RGB camera: wide 48MP + tele 12MP, 56x hybrid zoom
Vliegtijd: max 28 min

Deze drone heeft standaard geen warmtebeeldcamera maar die kan erop gemonteerd worden. Deze combinatie wordt in Duitsland vaak als pakket aangeboden (zie hoofdstuk 5). Lager in aankoop prijs dan de DJI Mavic 3 maar met minder vliegtijd en een hoger gewicht.

3.4.3 DJI Mavic 2 Enterprise Advanced



Richtprijs:	~ €6000 incl. BTW
Gewicht:	~900g
Thermische camera:	640 x 512p, 16x digital zoom
RGB camera:	48MP, 32x digital zoom
Vliegtijd:	max 31 min

Lange tijd een standaard voor thermische detectie voor industriële toepassingen maar intussen opgevolgd door de 3^e versie. Zowel thermische als RGB camera ingebouwd en gestabiliseerd.

3.4.4 DJI Matrice 300 RTK



Richtprijs:	~ €7500 excl. BTW
Gewicht:	~6 to 9kg afhankelijk van sensor opties
Thermische camera:	Verschillende camera opties
RGB camera:	Verschillende camera opties
Vliegtijd:	max 55 min afhankelijk van sensor opties

Een groter model dat veel flexibiliteit geeft voor industriële toepassingen. Eén of meerdere camera's/sensoren kunnen op de drone bevestigd worden in functie van de noden (incl. thermische camera's en camera's met hoge optische zoom), wat een groot voordeel is. Twee daarvan bevinden zich op gimbles/stabilisatoren onder de drone en één bovenaan de drone.



Specifiek op te merken is de DJI zenmuse H20T camera. Deze DJI beschikt over meerdere sensoren in één toestel; een 23x optische zoom en ook een warmtebeeld camera. Aangezien deze camera ~€8600 euro excl. BTW kost, is de prijs categorie van deze drone en zijn accessoires vermoedelijk te hoog voor zijn potentieel nut in de toepassing voor maaislachtoffers.

3.4.5 DJI Matrice 30T



Richtprijs:	~ €10 700 excl. BTW
Gewicht:	~4kg
Thermische camera:	640 x 512p, 28x digital zoom
RGB camera:	wide 48MP + tele 12MP, 56x hybrid zoom
Vliegtijd:	max 41 min

Kleinere uitvoering van de Matrice 300 zonder verwisselbare camera's. De T versie heeft naast RGB camera een thermische camera. Een laser gebaseerde afstandsmeter en first person view camera voor het besturen met virtual reality bril maakt deze drone vooral zeer geschikt voor search & rescue toepassingen. First person view kan ook interessant zijn voor detectie van maaislachtoffers maar er moet rekening mee gehouden worden dat een 2^e persoon aanwezig moet zijn; anders wordt de vlucht als "buiten het zicht van de piloot" beschouwd.

3.4.6 DJI Phantom 4 Pro RTK



Richtprijs:	~ €5600 excl. BTW
Gewicht:	~1,5kg
RGB camera:	4k, 20MP
Vliegtijd:	max 27 min

Het beproefde maar stilaan verouderde Phantom 4 chassis uitgerust met een RGB camera en gimble. De camera heeft een mechanische sluiters. Dit voorkomt vervormingen bij beelden van snel bewegende objecten of bij hoge vliegsnelheid.

3.4.7 Teledine flir SIRAS



Richtprijs:	~ €9700 excl. BTW
Gewicht:	~1,5kg
Thermische camera:	640 x 512, radiometric, 5x zoom
RGB camera:	20 MP mapping mode, 128x zoom
Vliegtijd:	max 31 min

Een zeer recente drone van het merk FLIR, marktleider in thermische camera's. De MSX technologie van FLIR maakt het mogelijk om beelden van de RGB camera te combineren met die van de thermische camera zodat de randen van visueel waarneembare objecten geprojecteerd kunnen worden op het warmtebeeld.

3.4.8 Parot Anafi USA



Richtprijs:	~ €7000 excl. BTW
Gewicht:	~600g
Thermische camera:	320px256p
RGB camera:	21 MP
Vliegtijd:	max 32min

Deze drone, geproduceerd door de Amerikaanse afdeling van het Franse Parot, is één van de meest compacte drones voor professioneel gebruik en is uitgerust met zowel RGB als thermische camera. Niet te verwarren met de standaard Parot Anafi zonder thermische camera.

3.4.9 Auel Evo II dual



Richtprijs:	~ €8000 excl. BTW
Gewicht:	~1,2kg
Thermische camera:	640p×512p
RGB camera:	48MP
Vliegtijd:	max 38min

Uitgerust met een thermische camera van FLIR en RGB camera die video's kan maken tot 33MP (foto's tot 48MP), is dit één van de betere drones wat betreft beeldkwaliteit. Er is ook een versie zonder thermische camera te verkrijgen.

3.4.10 Recreatieve drones

Als enkel met RGB beelden wordt gewerkt zijn er ook drones in lagere prijs categorie die kunnen volstaan. Deze aanpak is niet efficiënt genoeg voor het in kaart brengen van grote oppervlaktes maar kan gezien de lage kostprijs mogelijk wel ingezet worden voor kleinschalige analyses van visueel duidelijk herkenbare reekitsen. Voor beter gecamoufleerde of verscholen soorten duurt het afspeuren van de beelden zonder automatische beeldverwerking simpelweg te lang om tijds-efficiënt te zijn. Voorbeelden zijn de Parot Anafi en DJI Mavic serie (de niet thermale versie). Deze drones uit het geavanceerdere segment van de recreatieve markt kunnen ook zeer kwalitatieve beelden maken.



4 Literatuurstudie koppeling met beeldverwerking

4.1 Kernpunten

De literatuurstudie bekijkt de mogelijkheden om fauna te detecteren op basis van dronebeelden en beeldverwerkingstechnieken, en wat daarvan eventueel toepasbaar is in het kader van maaislachtoffers. De resultaten uit de literatuur laten zien dat er vele mogelijkheden bestaan voor (semi)automatische detectie van dieren, met zowel RGB- als warmtebeeldcamera's en de combinatie van beide. De dieren (en/of hun replica's) die beschouwd werden in deze studies zijn (1) hazen en konijnen, (2) hertachtigen en (3) grond broedende vogels.

Voor de detectie van maaislachtoffers lijkt de warmtebeeldcamera de voorkeur te krijgen omdat de dieren weinig kleurencontrast hebben t.o.v. hun omgeving en het de dieren beter detecteert in dichte begroeiing. Het vooraf kalibreren van de camera, het afstellen van de vliegparameters en het vliegen bij het hoogste warmtecontrast met de omgeving zijn cruciaal om de dataverzameling te doen slagen.

De meeste eenvoudige vormen van beeldverwerking omvatten segmentatie-, eigenschapextractie-, classificatie- en beeldversterkingstechnieken (zie sectie 8.3.3). Datawetenschappers gebruiken deze technieken als puzzelstukken in hun analyseproces. In oudere studies (voor 2012) gebeurde nog veel interpretatie/verwerkingstappen door de wetenschapper zelf, maar gezien manuele verwerking tijdsintensief is (vb. bij zeer grote populaties of bij weinig zichtbare soorten) probeert men dit proces meer en meer te automatiseren. De 'regelset' van faunadetectie in de dronebeelden kende hierbij een evolutie van "menselijke interpretatie" (harde programmeercode) naar steeds meer "artificiële interpretatie/intelligentie". De kampioenen hierin zijn de deep learning modellen van het type "convolutional neural networks" (CNN). Deze op het menselijk brein gebaseerde modellen kunnen volledig automatisch patronen herkennen in beelden, zolang ze maar getraind zijn op een voldoende kwantitatieve en kwalitatieve dataset. Tussen hard-coding en deep learning vallen de nog semi-automatische beeldverwerkingstechnieken als object-based image classificatie (OBIA) en conventionele machine learning (ML).

De meeste studies over automatische beeldverwerking gebruiken RGB-data. Dit omdat de oudere modellen van warmtebeeldcamera's nog te zwak waren om goede beelden te verzamelen. Er zijn al enkele studies die OBIA en ML toepassen op warmtebeelden maar verdere studies zijn nodig om na te gaan of deze operationeel gebruikt kunnen worden. Geautomatiseerde beeldverwerking kan een krachtig werktuig zijn maar er zijn (nog) geen kant en klare oplossingen. Daarvoor is samenwerking nodig met gespecialiseerde dienstverleners (zie hoofdstukken 5 en 6).

4.2 Gebruik van remote sensing

Studies die drones gebruiken om fauna te detecteren doen dit vaak in het kader van populatiegrootte bepaling (nesten (Albores-Barajas et al., 2018; Sardà-Palomera et al., 2017; Scholten et al., 2019), adulten (Hodgson et al., 2016; McMahan et al., 2020; Patterson et al., 2015; Preston et al., 2021)), broedparen (Chabot et al., 2015; McMahan et al., 2020)), gedragsstudies (Graves et al., 2022; McMahan et al., 2020) en epidemiologiestudies (Graves et al., 2022; Laguna et al., 2018). Fauna detectie in het kader van maaiongevallen is echter beperkt onderzocht (Cukor et al., 2019). Twee studies die wel focussen op dit onderwerp hebben voorgesteld om sensoren (o.a.

microwave, RGB en thermisch infrarood camera's) rechtstreeks te monteren op maaimachines (al dan niet met een wildredder) (Cerra et al., n.d.; Steen et al., 2012). Hierbij werd het gebied voor de machine gescand, waarbij beeldverwerkingsmodellen reekalven (Cerra et al., n.d.) of kippen en konijnen (Steen et al., 2012) detecteerden op basis van de sensordata. Praktijkexperimenten van dezelfde onderzoeksgroep van (Cerra et al., n.d.) tonen echter aan dat de performantie van hun detectiesysteem beperkt is doordat de beeldkwaliteit sterk wordt beïnvloed door de snelheid (maximaal 15km/uur) en de trillingen van de maaimachine (Israel et al., n.d.). Steen et al. (Steen et al., 2012) gaf wel aan dat de performantie hoog was voor de detectie van konijnen (zelfs bij hoge snelheden die representeerbaar zijn voor de praktijk), maar minder voor kippen als er een te dichte begroeiing was van de vegetatie. Bijkomend werd op basis van de warmtebeeldcamera een gebied gescand van slechts 2,1 meter breed op 5 meter voor de maaimachine. Dit is kleiner dan de werkbreedte van de maaimachine zelf, waardoor dit systeem nog niet volledig operationeel is.

Verschillende types sensoren kunnen gemonteerd worden op drones. Zo zijn er 'passieve sensoren' zoals gewone RGB, multispectrale, hyperspectrale en thermale camera's. Typische 'actieve sensoren' zijn radar, lidar en sonar sensoren. Hoewel voornamelijk RGB en thermale camera's gebruikt worden voor faunadetectie, kunnen vogels en vleermuizen ook gemonitord worden door middel van akoestiek sensoren (Broset et al., n.d.). Gezien manuele foto-interpretatie van dronebeelden of dronevideo's tijdsintensief kan zijn (Kellenberger et al., 2021) probeert men dit proces te automatiseren via beeldverwerkingstechnieken (Chabot & Francis, 2016; Corcoran et al., 2021).

We evalueerden 26 studies, gepubliceerd tussen 2000 en 2022, om deze evolutie in kaart te brengen. Hierbij werd er ook gekeken naar technische beperkingen, omgevingscondities en de ecologische eigenschappen van de studie-organismen in deze papers. Daarnaast werden deze studies vergeleken met 33 bijkomende studies waarbij ofwel (1) drones ingeschakeld werden om dezelfde studie organismen te monitoren maar waarbij de tellingen gebeurden o.b.v. manuele foto-interpretatie, ofwel (2) gelijkaardige beeldverwerkingstechnieken werden toegepast op andere remote sensing platformen (bemande luchtvaartuigen, satellieten en tractoren).

4.3 Materiaal en methoden

Met behulp van Google Scholar is een overzicht gemaakt van beschikbare literatuur waarin dieren met behulp van beeldverwerkingstechnieken zijn gedetecteerd in door drones verkregen beelden. De trefwoorden, 'uav', 'uas', 'rpas', 'drone', 'wildlife', 'monitor', 'detect', 'automated' en 'image processing' werden gebruikt om deze database te screenen. De zoekacties vonden plaats van oktober tot december 2022, met een datalimiet van januari 2000 tot heden. De leverde 1050 zoekresultaten. De doelsoorten werden beperkt tot Cervidae (hertachtigen), grond nestende vogelsoorten (niet beperkt tot akker- en weidevogels wegens een te beperkt aantal publicaties) en Leporidae (hazen en konijnen). Wetenschappelijke artikels, review papers, conferentieartikelen en gepubliceerde doctoraatsthesisen werden opgenomen; ongepubliceerde rapporten en scripties werden uitgesloten.

4.4 Resultaten en discussie


Studies die beeldverwerkingstechnieken gebruiken om dieren te detecteren, tellen en eventueel per soort te klasseren worden weergegeven in Tabel 1 – 3. Deze tabellen zijn gebaseerd op de studie van van Corcoran, Winsen, Sudholz et al. (2021) (Corcoran et al., 2021), en aangevuld met nieuwe studies en informatie. Studies die niet relevant waren zijn weggelaten en informatie is gecorrigeerd indien deze niet in overeenstemming was met de informatie van de individuele studies. Bijkomende informatie over deze tabellen is terug te vinden in de S1 – Tabel literatuurstudie.

4.4.1 De modelorganismen

4.4.1.1 Landzoogdieren

Finaal werden voor de doelsoorten acht studies gevonden die landzoogdieren detecteerden aan de hand van drone-gemonteerde sensoren en beeldverwerkingstechnieken: twee studies met haasachtigen en zes studies met hertachtigen. Hierbij werden zowel middelgrote tot grote zoogdieren (de adulte hertachtigen (Chrétien et al., 2015, 2016; Oishi et al., 2018; Sudholz et al., 2022)) als kleine zoogdieren (reekalven (Figuur 8) en konijnen (Christiansen et al., 2014; Israel, 2012; Israel & Evers, 2011; Psiroukis et al., 2021)) gedetecteerd. Deze studies gebruikten thermische infrarood camera's (al dan niet in combinatie met een gewone RGB camera) om deze soorten te detecteren (Tabel 2). De dieren beschikken over een camouflage of drukken zich tegen de grond in dichte vegetatie. Psiroukis *et al.* (Psiroukis et al., 2021) rapporteerden dat de konijnen in hun studies voornamelijk 's nachts actief zijn (hoogste activiteit tussen 02:00 en 04:00 's nachts), terwijl de dieren overdag voornamelijk in hun hol onder de grond lagen. Dit maakt het onmogelijk om de dieren met een RGB camera te detecteren vanop een drone.


Doordat zoogdieren warmbloedig zijn kan hun stralingswarmte op sommige momenten voldoende contrasterend zijn met de stralingswarmte van de omliggende omgeving, afhankelijk van de periode in het jaar of het moment van de dag. Dit wordt verder besproken in secties 4.4.2 Vlieg- en sensorspecificaties en 4.4.3 Omgevingsomstandigheden.



Figuur 8: Vergelijking van een kleurenbeeld met een warmtebeeld (spectraal bereik 8 - 14 μm) van een graanveld waarin een reekalf ligt. Opnamehoogte: ongeveer 10m. Afbeelding overgenomen uit [47].

4.4.1.2 Vogels

Dertien studies werden gevonden voor de detectie van grondbroedende vogels op basis van drone-gemonteerde sensoren en beeldverwerkingstechnieken. Deze vogels vallen onder de termen akker- en weidvogels (Christiansen et al., 2014; Israel & Reinhard, 2017) en water-, wadden- en zeevogels (Abd-Elrahman & Pearlstine, 2005; Borowicz et al., 2018; Chabot & Bird, 2012; Chabot & Francis, 2016; Grenzdörffer, 2013; Hinke et al., 2022; Hong et al., 2019; Israel et al., 2015; Kellenberger et al., 2021; Lee et al., 2019; Liu et al., 2015; Rush et al., 2018). De vogels van de eerste groep hebben een onopvallend verenkleed (Christiansen et al., 2014) of nest (Israel & Reinhard, 2017) (Israel & Reinhard, 2017) t.o.v. de omgeving, terwijl vogels van de tweede groep een opvallend verenkleed hebben (met uitzondering van de bontbekplevier in (Lee et al., 2019)). Hierdoor werd voor de eerste groep een thermische camera gebruikt voor detectie, terwijl voor de tweede groep hoofdzakelijk een RGB camera gebruikt werd (met uitzondering van bontbekplevier (Lee et al., 2019))(Tabel 2).



Figuur 9: Afbeelding links: VIS-beeld (gewone kleurfoto gemaakt met een RGB camera). De rode cirkel markeert de positie van het kievitsnest. Afbeelding rechts: Thermisch beeld. Het kievitsnest is goed te zien. Beide afbeeldingen zijn genomen vanop een drone op een hoogte van 30m. Afbeeldingen zijn overgenomen uit .

4.4.1.3 Replica

Drie studies gebruikten replica om hun detectiemodellen op basis van RGB beelden uit te testen als proof-of-concept (Abd-Elrahman & Pearlstine, 2005; Hodgson et al., 2018; Hong et al., 2019) (Figuur 10). Eén studie gebruikte zelfs uitsluitend valse lokvogels (Hodgson et al., 2018). Ook studies die manueel dieren tellen op basis van dronebeelden gebruiken soms replica (Dulava et al., 2015; Patterson et al., 2015). Patterson et al. (Patterson et al., 2015) bestudeerden o.a. de effecten van vegetatie, omgeving, weersomstandigheden, de ervaring van de foto-analist, en vluchtparameters op manuele detectie van rendier replica uit dronebeelden. Dulava et al. (Dulava et al., 2015) onderzochten de optimale vliegparameters (hoogte, brandpuntafstand lens en spatiale resolutie) om waterwild te detecteren op basis van wilde vogels en replica. Verder werden eventuele veranderingen in gedrag door de aanwezigheid van de drone ook bestudeerd.

Het gebruik van replica levert enkele voordelen op in tegenstelling tot het detecteren van wilde vogels: (1) de auteurs weten exact hoeveel replica's er aanwezig zijn op het terrein, (2) de totale hoeveelheid aan te detecteren objecten kan niet veranderen tijdens de opname van de beelden (dieren bewegen niet, hergroeperen niet of scheiden zich niet af tijdens de dronenvlucht), (3) het labelen van foto's blijft beperkt tot de trainingsdataset. Vooral het bewegen van dieren kan een probleem opleveren voor accurate tellingen (Hong et al., 2019) en datafusie als men meerdere sensoren gebruikt (Lee et al., 2019). Het nadeel van replica's is dat ze geen echte dieren maar slechts een kopie van het na te bootsen dier zijn.

Sommige studies proberen juist beweging van dieren deels te monitoren/identificeren op basis van tracking algoritmes (Christiansen et al., 2014; Psiroukis et al., 2021) of slagen er enkel in dieren te identificeren indien ze bewegen aan bepaalde snelheidsintervallen (Oishi et al., 2018).

In Tabel 1 wordt ook omschreven hoe het verspreidingspatroon van de dieren was in de dronebeelden. Kolonies en kuddes van dieren, waarbij de dieren ongeveer op een vaste afstand van elkaar staan (uniforme verdeling) zijn makkelijker te detecteren en tellen op basis van een manuele foto-interpretatie of op basis van een algoritme (Corcoran et al., 2021). Dieren die echter zeer dicht op/tegen elkaar zitten zijn dan weer moeilijk accuraat te tellen vanop een luchtbeeld (Laliberte, 2003).




Figuur 10: Foto's van de replica's die gebruikt werden in (Hodgson et al., 2018) (bovenaan), (Abd-Elrahman & Pearlstine, 2005) (linksonder) en (Hong et al., 2019) (rechtsonder).

4.4.2 Vlieg- en sensorspecificaties

Tabel 2 geeft informatie over de vlieg- en sensorspecificaties en de omgevingscondities waarin er gevlogen werd per studie. De supplementaire data vermelden specifiek per studie welk model- en sensortype er gebruikt werden (S1 – Tabel literatuurstudie).

4.4.2.1 Platform type

Een rijke mix aan droneplatformen wordt gebruikt in remote sensing studies (Figuur 11). Hieronder vallen multirotor, fixed-wing, hybride en flapping-wings drones.



Figuur 11: Schema van het bovenaanzicht van de verschillende vormen van drones en hun grootte. A - D: multirotor/multicopter drones, van helicopter (A) t.e.m. een octoopter (D). E - H: Fixed-wing drones. I: Hybride drone. Aangepast uit [(Charbonneau & Lemaître, 2021)]

Lichte multirotor en fixed-wing drones (maximum take-off weight (MTOW) < 1,5 kg) hebben een prijsrange van tussen de €500 – €5.000 en €5.000 – €50.000, respectievelijk. Zware multirotor en fixed-wing drones (MTOW > 2 kg) hebben een prijsrange van tussen de €5.000 – €50.000 en €20.000 – €200.000, respectievelijk. Lichte drones zijn makkelijk transporteerbaar (kleinere verpakking, licht gewicht), hebben meestal een goed geïntegreerde RGB of dubbele camera (RBG + warmtebeeld). Ze zijn echter wel gevoeliger voor hoge windsnelheden (omgevingswind moet onder de 4 m/s en 8-10.7 m/s voor multirotor en fixed-wings, respectievelijk), hun camera's zijn vast gemonteerd aan de drone zelf (soms onder een vaste hoek).

Zwaardere drones zijn stabiel in de lucht (kunnen windsnelheden aan van meer dan 7,9 m/s), kunnen zwaardere (of meerdere) sensoren dragen die bijkomend makkelijk op en af te monteren zijn. Het nadeel is dat ze vallen onder een strengere wetgeving en ze mindere makkelijk transporteerbaar zijn.

Algemeen zijn multirotor drones makkelijker manoeuvreerbaar en hebben ze een compacter design in vergelijking met fixed-wing drones. Het grootste nadeel van multirotor drones is hun beperkte vliegrange (< 1 km² t.o.v. ≤ 10 km²) doordat veel energie gaat naar het in de lucht houden van de drone [(Su et al., 2023)] Bij fixed-wing drones gaat alle energie van de drone naar de laterale

verplaatsing van de drone zelf, terwijl de stijve vleugels zorgen voor de opwaartse stuwkracht, waardoor deze modellen meer energie-efficiënt zijn. Verder zijn fixed-wing drones stabiel in winderige condities, kunnen ze sneller vliegen en kunnen ze bij vermogenverlies hersteld worden door het vervangen van onderdelen. Fixed-wing drones hebben als nadeel dat ze vaak een opstijgen- en landingszone vereisen, door hun grotere afmetingen beschikken ze over een beperktere manoeuvreerbaarheid, hogere kost en kleinere spatiale resolutie in hun sensor beelden doordat ze op hogere hoogte moeten vliegen (≥ 40 m) [(Su et al., 2023).

Hybride UAV's hebben zowel de voordelen van fixed-wing en multi-rotor drones. Rotoren tussen de vleugels laten toe om verticaal op te stijgen, te dalen en ter plaats te vliegen (Su et al., 2023). Daarnaast kunnen ze zweefvluchten realiseren als een fixed-wing drone door van vluchtmodus te veranderen. Hierdoor kunnen ze lange afstandsvluchten uitvoeren, zonder veel vereisten voor de landingsplaats. De technologie is echter nog volop in zijn ontwikkelingsfase, waarbij verder ontwikkelingen in stabiliteit, veiligheid en zekerheid in uitvoering cruciaal zijn (Su et al., 2023).

Flapping-wing drones zijn drones die vliegen op basis van het wapperen van hun vleugels. Deze drones worden enkel gebruikt als het natuurlijk nabootsen van een vogels of insect een meerwaarde heeft (vb. spionage drones voor militaire doeleinden of 'afschrik drone' die een roofvogel nabootsen om vogels weg te houden van vb. luchthavens¹⁰). Deze manier van vliegen is echter weinig efficiënt (vereist veel energie en de drone is minder manoeuvreerbaar) waardoor dit type drones nog niet gebruikt zijn om fauna te detecteren, voor zover de literatuur dit beschrijft.

Fixed-wing drones in combinatie met thermale camera's zijn populair bij het monitoren van populatiegrootte bij hertachtigen, vooral in zeer grote bosrijke gebieden (Laguna et al., 2018; McMahon et al., 2020; Witczuk et al., 2018). Hierbij worden o.a. gebieden gemonitord van 4,54 km² (Witczuk et al., 2018) en 6 km² (Laguna et al., 2018) op één dag, wat praktisch onhaalbaar lijkt met een multirotor drone. Voor het monitoren van zeevogelkolonies op kleine eilanden lijken multirotor drones met een RGB camera dan wel ideaal (Hodgson et al., 2016). Hierbij kon de prijs van de drone en sensor beperkt blijven tot \$2.100 (tropische kolonies van grote kuifsternen en kleine fregatvogels) en \$3.600 (Arctische kolonies van grote kuifsternen).

Voor de studies die beeldverwerkingstechnieken gebruikten om fauna te detecteren, gebruikte slechts drie van de 20 studies een fixed-wing drone in de studie (Abd-Elrahman & Pearlstine, 2005; Chabot & Francis, 2016; Liu et al., 2015). Eén studie simuleerde monitoring van drones aan de hand van een afstelbare hef-arm (Christiansen et al., 2014).

4.4.2.2 Sensor type

De twee type sensoren die gebruikt werden in de literatuurlijst zijn RGB camera's en thermische infrarood (TIR) camera's. RGB camera's zijn de gewone kleurencamera's die de rode, groene en blauwe kleuren meten in het zichtbaar licht (Engels: 'visible light' (VIS), golflengtes tussen de 380 nm (violet) en 761 nm (donkerrood)) gedeelte van het elektromagnetisch spectrum. Door deze drie kleuren te combineren kan men alle kleuren maken die ook zichtbaar zijn met het menselijk oog. Dit 'gemeten' licht is gereflecteerd licht afkomstig van de zon dat via radiometrische correcties wordt omgezet naar 'reflectantiewaarden'. Zowel analoge als digitale camera's werden gebruikt in de finale literatuurlijst (zie S1 – Tabel literatuurstudie).

Hoewel thermisch infrarood normaal alle golflengtes omvat van 5 μm – 14 μm , meten thermale camera's enkel in het 'long wavelength' infrarood gedeelte van het elektromagnetisch spectrum (golflengtes tussen de 8 μm en 14 μm). De camera's meten hierbij stralingsemissies door warme objecten. Bij metingen dient men rekening te houden met eventueel externe warmtebronnen (vb. de zon, lampen, volle maan,...) die mogelijks de resultaten kunnen beïnvloeden. Er bestaan twee soorten thermische camera's: gekoelde fotonen detector en ongekoelede microbolometer camera's (Israel et al., 2015). Gezien ongekoelede microbolometer camera's veel lichter kunnen gemaakt worden, wordt dit type voornamelijk gebruikt op drones. Het materiaal van de 'focal plane array' van een microbolometer camera bestaat actueel uit twee types materialen: vanadiumoxide of amorf silicium (Israel et al., 2015). Hierdoor hebben ze een verschillend karakter, voornamelijk in integratietijd. Zo moet bij het veranderen van FPA materiaal van amorf silicium naar vanadiumoxide voor de Tau 640 camera de maximale vliegsnelheid tijdens beeldopnamen met meer dan de helft gereduceerd worden om geen bewegingsonscherpte te hebben in de dronebeelden (Israel et al., 2015).

Doordat het zichtbaar licht hogere energetische waarden heeft (foto-energie: 1,63 eV (donkerrood) – 3,26 eV (violet)) dan long wavelength infrarood (foto-energie: 0,09 eV – 0,15 eV) kunnen RGB camera's een fijnere 'ground sampling distance' (GSD) of een hoger spatiale resolutie behalen dan thermisch infrarood camera's. Desondanks behalen de nieuwste sensoren voldoende spatiale resolutie om zeer kleine warme objecten manueel te spotten vanuit dronebeelden, zoals de grondnesten van bontbekplevieren (Hyun et al., 2020) en veldgorzen (*Spizella pusilla*) (Scholten et al., 2019).

Voor de 20 studies die beelverwerkingstechnieken gebruikten om fauna te detecteren, gebruikten negen studies een RGB camera, vijf studies een warmtebeeldcamera en zes studies beide types camera's. In de laatste groep waren er drie studies die enkel de RGB beelden gebruikten bij visuele controle tijdens of na de vlucht, zonder ze te gebruiken in de analyse (Israel & Reinhard, 2017; Lee et al., 2019; Sudholz et al., 2022).

RGB camera's worden voornamelijk gebruikt om dieren te detecteren die een opvallend kleurencontrast hebben t.o.v. hun omgeving. De auteurs Hinke et al., 2022 concludeerden dat het detectiemodel van pinguïns *Pygoscelis antarcticus* en *P. papua* op Cape Shirreff, Livingston Island, Antarctica voldoende werkte op basis van enkel RGB beelden. Hun convolutional neural network (CNN) verbeterde niet significant in performantie als men ook warmtebeelden gebruikte als input data om hun model te trainen. Dit ondanks dat de auteurs verwachtten dat het warmtecontrast tussen de dieren en de omgeving voldoende groot zou zijn tijdens de vluchten.

Warmtebeeldcamera's hebben wel aangetoond om voldoende performant te zijn om grotere zoogdieren en vogels te detecteren. Ook slagen ze er beter in om cryptische dieren of soorten die deels beschut zitten onder vegetatie te detecteren, in vergelijking tot RGB camera's (Chrétien et al., 2015, 2016; Preston et al., 2021). De auteurs Graves et al., 2022 maakten dan weer slim gebruik van de seizoensgebonden gedragspatronen van hun studieorganismen (wapiti hert, *Cervus canadensis*) om hun tellingen toch te kunnen uitvoeren op basis van RGB beelden op een UAV i.p.v. met warmtebeelden. De dieren verlaten jaarlijks in de winter de dichte bossen en komen samen in grote kuddes in de open vlakten. In deze periode is er voldoende kleurcontrast (bruine dieren t.o.v. de besneeuwde achtergrond) en is er geen hinder van vegetatie om hen van bovenaf te detecteren.

4.4.3 Omgevingsomstandigheden

4.4.3.1 Weerscondities en achtergrond

De meeste papers rapporteerden dat er gevlogen werd in goede condities (Tabel 2). Dit wil gewoonlijk zeggen dat de windsnelheid (hoewel vaak niet gerapporteerd) niet te hoog was en neerslag weinig tot niet aanwezig was tijdens de vlucht. Neerslag en wind kunnen leiden tot beschadiging en/of verlies van de drone en tot ruis in de beelden (Hinke et al., 2022; Sudholz et al., 2022).


Voor de RGB camera's zijn de beste vliegcondities wanneer (i) voldoende omgevingslicht aanwezig is en (2) deze niet te veel verandert tijdens de vluchtopname (stralende dag met compleet heldere hemel of compleet grijze dag met diffuus licht) (Corcoran et al., 2021). Dit is essentieel om de radiometrische correctie te doen slagen, die reflectiewaarden omzet naar reflectantiewaarden. De reflectantiewaarden zijn sterk gelinkt met de biochemische en fysieke eigenschappen van het materiaal waarop het licht weerkaatst wordt en zijn een primaire bron van informatie bij RGB remote sensing.

Warmtebeeldcamera's meten rechtstreeks de hoeveelheid stralingssterkte, die gekoppeld is aan de oppervlaktewarmte van het dier/het object. Het blijft moeilijk om stralingswarmte in verband te brengen met de eigenschappen van een object. De aanwezigheid van andere warme objecten (vb. verandering in stralingswarmte van de zon bij zonsopgang), de isolatiecapaciteit van het verenkleed of de vacht (die bijkomend kan veranderen per seizoen) en het contrast met de omgevingstemperatuur zal het oppervlaktewarmtepatroon van het dier veranderen (Israel, 2012). Naarmate de sensor verder verwijderd is van het warme object zal ook het gemeten warmteprofiel meer afwijken van het werkelijke warmteprofiel door (i) absorptie van warmte door waterdamp, (ii) wind/convectie en (iii) het effect van gemixte pixels (een pixel met een warmteprofiel dat bestaat uit een mix van warmteprofielen van verschillende objecten) (Christiansen et al., 2014; Israel & Reinhard, 2017). Alle studies die gebruik maken van warmtebeeldcamera's kregen de beste resultaten uit hun modellen indien ze beelden gebruikten met een groot warmte contrast tussen het studieorganisme en de omgeving en wanneer dit contrast ongeveer constant bleef tijdens de vlucht. Gezien vogels en zoogdieren endotherme dieren zijn worden dronevluchten voornamelijk uitgevoerd wanneer (i) de omgeving koud is (vb. in vorstperiode, 's nachts), (ii) bij een lage luchtvochtigheidsgraad, en (iii) wanneer de omgevingstemperatuur constant blijft (na zonsondergang en voor zonsopgang, tijdens bewolkte dag) (Cukor et al., 2019; Israel & Reinhard, 2017). De studie van Lee et al., 2019 lijkt hierin een uitzondering te zijn, waarbij het studieorganisme (kleine lepelaars) een kouder temperatuur profiel vertoonde dan de omgeving (wadden in een getijdengebied in de Republiek van Korea). De auteurs vermoeden op basis van hun modelresultaten dat niet enkel de goede isolatie van de veren van de vogels voor een contrast zorgde met de omgeving, maar ook hun schaduwprofiel.

4.4.3.2 Habitat

Dertien van de 20 studies detecteerden dieren in habitats met geen of een lage vegetatiebedekkingsgraad. Merk op dat dit relatief beschouwd wordt t.o.v. de grootte van het dier. Zo kan een open schraal grasland als een lage bedekkingsgraad beschouwd worden als het gaat over de detectie van grote zoogdieren (vb. edelhert), terwijl dit een dichte vegetatie is voor een groundbroedende akkervogel. Zeven studies rapporteerden een gemiddelde (Christiansen et al., 2014; Grenzdörffer, 2013; Oishi et al., 2018; Psiroukis et al., 2021; Sudholz et al., 2022) en/of hoge bedekkingsgraad (Israel, 2012; Israel & Evers, 2011; Sudholz et al., 2022). Zes van de zeven studies gebruikten warmtebeeldcamera's om de dieren te detecteren. Grenzdörffer (2013) (Grenzdörffer, 2013) gebruikte echter een RGB camera en slaagde er toch in vrij accuraat stormmeeuwen te detecteren in gras- en rietland op basis van hun CNN model.

Het is cruciaal om vegetatie in rekening te brengen om een dronemissie te doen slagen. Op basis van trigonometrie berekende de onderzoeker Israel, 2012 dat men best een camera met een hoeklens van minstens 34° neemt om een pasgeboren reekalf, opgerold (diameter ± 30 cm) in hoog gras van 1 meter hoog te kunnen detecteren. Hun thermale camera (Tau640 van FLIR Systems, 640×512 pixels) had een 'field of view' (FOV) van $32^\circ \times 26^\circ$, die bijna voldoet aan de grenswaarden van 34° . Cukor et al. (2019) (Cukor et al., 2019) gebruikten wel een thermale camera met een hoeklens $\geq 34^\circ$ (Workswell WIRIS 2nd generation, 640×512 pixels, FOV $45^\circ \times 37^\circ$) om reekalven te detecteren in alfalfa in Tsjechië (40 – 70 cm hoog bij oogst).



Figuur 5: Geometrische randvoorwaarden bij het bekijken van een reekalf in de wei (Israel, 2016). D_k : diameter van de reekalf, h_w : hoogte gras, h_w : altitude sensor (gemonteerd op drone), $w = w' =$ helft van de hoeklens van de sensor $= \pm 17^\circ$.

5 Commerciële bedrijven en verenigingen in en rond Vlaanderen

In Vlaanderen en daarbuiten zijn verschillende bedrijven en verenigingen actief die diensten, ondersteuning of materiaal aanbieden om fauna-detectie uit te voeren met behulp van drones. Maaislachtoffers en jacht zijn daar belangrijke luiken in. In dit hoofdstuk wordt een overzicht gegeven van bedrijven en organisaties die actief zijn in de sector. Met enkele daarvan is er ook actief contact genomen en hun inzichten (en eventuele diensten) werden mee opgenomen in het rapport.

Verder besteedt dit onderdeel van het rapport ook aandacht aan subsidies die in het buitenland afgeleverd worden door landbouwinstanties voor de aanschaf of het inhuren van drones.

5.1 Vlaanderen

Falcoflight

Falcoflight is het éénmansbedrijf van Wannes Dermout. Als dronepiloot heeft hij uitgebreide praktische ervaring met drones in de context van natuurbeheer. Dit omvat specifieke projecten rond maaislachtoffers; met name voor weidevogels. De aanpak van Falcoflight bestaat uit een vlucht waar eerst detectie met warmtebeelden gebeurt om vervolgens de gevonden hotspots met RGB beelden nader te inspecteren. Er wordt geen gebruik gemaakt van A.I.

Er is aan Falcoflight gevraagd om prakrijkinzichten te delen maar hierop werd niet ingegaan. Falcoflight kan ingehuurd worden om dergelijke vluchten uit te voeren. Afhankelijk van doelsoort en weersomstandigheden kan op een ochtend 15 à 35 ha gescreend worden op +/- 4u vluchttijd. De kostprijs hiervoor start vanaf 300 euro exclusief BTW.

<https://www.falcoflight.be/>

Dronedivision

Dronedivision is in de eerste plaats gespecialiseerd in het gebruik van dronebeelden voor industriële toepassingen. Denk bijvoorbeeld aan het inspecteren van telecom infrastructuur of hoogspanningskabels. In deze sector deden zij veel ervaring op met het ontwikkelen van machine learning modellen. Deze kennis hebben zij, doorheen enkele pilootprojecten¹¹, ook toegepast op detectie van fauna. Tijdens overleg met Dronedivision liet het bedrijf weten de technologie klaar te hebben om een totaalpakket aan te bieden waarmee gebruikers aan de slag kunnen (materiaal, training en onlineplatform voor beeldverwerking). De gebruikte drone is niet in de handel verkrijgbaar want deze bevat geïntegreerde software. Het gaat wel om onderliggende hardware van DJI. Hun beeldverwerkingsalgoritmes kunnen op specifieke diersoorten ingesteld worden en in de

¹¹ <https://dronedivision.be/blog/2021/12/10/drones-verminderen-maaislachtoffers/>

toekomst kunnen deze ook voor andere soorten worden getraind. Het totaalpakket was ten tijde van het overleg nog niet op de markt, en het bedrijf liet verstaan nog op zoek te zijn naar de juiste geïnteresseerde partijen om op basis daarvan de prijszetting en het exacte model vorm te geven. Als richtprijs werd €7000 aanschaf + €250/jaar gebruikerslicentie gegeven. Omwille van de hoge investeringskost wordt ook een huur-formule bekeken maar de prijs daarvan moet nog bepaald worden op basis van onderhandeling met de verzekeraar.

<https://dronedivision.be/>

5.2 Wallonië

Sauvons bambi

In Wallonië is de organisatie Sauvons bambi actief. Hun doel is het in contact brengen van drone piloten met boeren die hun weiland willen laten overvliegen om maaislachtoffers te voorkomen. Het gaat in de eerste plaats over reekitsen. Ze voeren ook tellingen en populatiemonitoring uit.

Sauvons bambi verkoopt zelf ook drones en doet beroep op giften om dit toegankelijker te maken voor drone piloten die zich inzetten binnen hun netwerk. Momenteel werken ze eveneens met de veel gebruikte DJI Mavic 3 Thermal. Hun werkwijze is op basis van warmtebeelden en nadere inspectie op basis van RGB.

Daarnaast is er aandacht voor vorming van vrijwilligers voor het redden van reekitsen. Sauvons bambi kan voor de pas beginnende piloot dus een goede partner zijn om kennis op te bouwen.

<https://sauvonsbambi.be/nl/>

5.3 Nederland

Robor-nature

Dit bedrijf is de op natuur en landbouw gerichte tak van Robor-electronics. Daar waar de electronics tak zich op gebied van drones bezig houdt met toepassingen voor hulpdiensten heeft de nature tak een specifiek dronepakket voor faunadetectie.

In dit “faunadrone” pakket bevindt zich opnieuw een DLI Mavic 3 Thermal en een tweede scherm voor op de grond met alle bijhorende voeding en opslagsystemen. Bijhorende software is ontwikkeld om voorgeprogrammeerde vluchtplannen op te zetten en automatisch hot spots op basis van de warmtebeelden te markeren. Hierbij is geen verdere beeldverwerking op basis van RGB beelden. Alle warme objecten worden dus gemarkeerd en het is aan de piloot hieruit dieren te herkennen.

Dit pakket kwam tot stand door de samenwerking van Dronexpert (hardware) en Aeret (software) die samen ervaring opdeden in pilootprojecten¹². Beide verwijzen nu naar Robor voor deze diensten. Een informatie flyer is toegevoegd in bijlage (zie8.5).

<http://www.robtor-nature.eu/>

5.4 Duitsland

In Duitsland is het gebruik van drones voor jacht en het voorkomen van maaislachtoffers duidelijk al meer ingeburgerd. Verschillende aanbieders van drone hardware hebben specifiek aandacht voor deze toepassingen. De overheid voorziet subsidies¹³ voor jachtverenigingen om drones met warmtebeeld camera aan te schaffen zodat deze gebruikt kunnen worden in wildbeheer en specifiek voor het redden van reekitsen. Het gaat om een subsidie van 60% van de aanschaffingskosten (tot 4000 euro) afkomstig van het nationaal ministerie landbouw. De subsidie kan al voor het derde jaar op rij aangevraagd worden voor een maximum van 2 drones per jaar en per jachtgebied.

Copterpro

Dit bedrijf is gespecialiseerd in drone toepassingen voor zowel jacht, industrie als landbouw. Ze doen zowel verkoop van drones als het aanbieden van specifieke opleidingen. In het aanbod zit zowel een opleiding voor het redden van reekitsen als voor gebruik van drones voor de jacht. Naast Mavic 3 Thermal van DJI werken ze ook met het merk Yuneec. In verschillende artikels in het tijdschrift Wild und Hund worden hun diensten positief onthaald.

<https://copterpro.de/>

Kitzrettungsdrohne

Een webwinkel specifiek voor het gebruik van drones in het kader van maaislachtoffers. Ze raden de DJI Mavic 3 Thermal aan en de Yuneec H520E met afzonderlijk bij aan te schaffen E20Tvx warmtebeeld camera.

<https://kitzrettungsdrohne.de/Start>

5.5 Frankrijk

In Frankrijk lijkt het gebruik van drones voor deze toepassingen minder ingeburgerd. In individuele departementen (Doubs, Jura, Haute Saône en Belfort) zijn met behulp van subsidies van het Office français de la biodiversité pilootprojecten opgezet. Interessant is dat jachtfederaties zelf drones en getrainde personeelsleden voorzien. De doelstellingen gaan ook verder dan enkel het voorkomen van maaislachtoffers. Ook monitoring van populaties door middel van tellingen of het opsporen van verloren geraakte jachthonden behoort tot de doelstellingen¹⁴.

SOS Sauvons les faons

Deze VZW is gelijkaardig aan het Waalse Sauvons bambi. Ze brengen drone piloten, vrijwilligers en landbouwers met elkaar in contact. De detectie gebeurt op basis van warmtebeelden. Uniek is dat de dronepilot deze beelden gebruikt om vrijwilligers op het veld aan te sturen. Als dan blijkt dat het inderdaad om een reekalf gaat wordt er een kooi over geplaatst zodat het dier beschermd is tijdens de maaiwerken. Na de maaiwerken wordt de kooi verwijderd en blijft het reekalf achter in een kleine ongemaaide zone in de hoop dat de moeder het daar weer zal ophalen. Dat het kalf dus

¹³ https://www.ble.de/DE/Projektfoerderung/Foerderungen-Auftraege/Rehkitz/Rettung_node.html
<https://www.agrarheute.com/management/finanzen/4000-euro-pro-drohne-fuer-rehkitzrettung-579074>

¹⁴ <https://www.lechasseurfrancais.com/chasse/plan-chasse-haute-savoie-engagement-faillie-departement-73290.html>

niet moet worden aangeraakt of verplaatst is een voordeel, maar men kan zich vragen stellen bij de stress dat het dier moet ondergaan in de kooi tijdens de maaiwerken.

<https://www.sauvonslesfaons.org/>

6 Conclusies in Vlaamse context

Zowel volgens de literatuurstudie als uit relevante praktijkervaring lijkt het gebruik van een combinatie van warmtecamera en RGB-camera in het kader van maaislachtoffers nog steeds de voorkeur te hebben t.o.v. enkel een RGB-camera. De dieren (of de eieren) hebben te weinig kleurencontrast t.o.v. hun omgeving en bevinden zich vaak beschut in een dichte begroeiing. Met de verdere evolutie van beeldverwerkings- en cameratechnologie zou enkel RGB in de toekomst mogelijk kunnen volstaan.

Het gebruik van een warmtebeeld camera verhoogt de investeringskost voor een drone aanzienlijk. Er zijn verschillende modellen op de markt met prijzen variërende van ongeveer €5000 tot €10 000 en meer. Het model dat momenteel het meest gebruikt wordt in het kader van maaislachtoffers is de DJI Mavic 3 Enterprise Thermal¹⁵. Deze drone heeft een zeer goede prijs-kwaliteitsverhouding en is mede door zijn geringe gewicht gebruiksvriendelijk. Hij valt ook onder de categorie “open” wat de regelgeving toegankelijker maakt. Er moet wel in gedachten gehouden worden dat deze drone geen Cx-label heeft en het moeilijk te voorspellen is hoe de wetgeving hier vanaf 2024 op aangepast zal worden (zie 2.3.1).

De beelden worden van de sensor naar de remote controller gestuurd, waar de piloot real time een foto-interpretatie kan doen. Het is moeilijk in te schatten hoe tijdsefficiënt dit voor een ongetraind persoon is. Begeleiding of opleiding is dus wenselijk. Op lange termijn is het uiteraard niet kosten efficiënt om de vluchten steeds door een derde te laten uitvoeren. Om de efficiëntie op het terrein te vergroten kan het raadzaam zijn om een 2^e (goed leesbaar) scherm en statief te voorzien zoals bv. aangeboden in het faunadrone pakket van het Nederlandse Robor-nature¹⁶.

De efficiëntie op basis van warmtebeelden is sterk onderhevig aan de omgevingsomstandigheden. Het vooraf kalibreren, het toepassen van beeldversterkingstechnieken, het afstellen van de vliegparameters en vooral het vliegen bij het hoogste of voldoende hoge warmtecontrast met de omgeving ('s nachts, 's morgens of bij koud weer) zijn cruciaal voor de nauwkeurigheid.

Bij vliegparameters zal de afweging tussen resolutie, vliegsnelheid en hoogte belangrijk zijn om een voldoende groot gebied met voldoende sensitiviteit in kaart te brengen (Israel, 2016). Studies rapporteren dat bij een operationele vlieghoogte van ongeveer 40 meter boven de grond, 14 ha in kaart kan gebracht worden met één batterij voor een professionele drone (\pm 25 minuten vliegen) (Cukor et., al 2019). Praktische ervaringen en inzichten in specifiek uit Vlaanderen zijn moeilijk te bekomen.

Uit de literatuur blijkt dat de steeds beter wordende sensoren, grotere rekenkracht van computers en het gebruik van neurale netwerkmodellen het potentieel lijken te hebben om het beeldverwerkingsproces steeds accurater te laten verlopen (Cukor et al., 2019). Echter, het moet

¹⁵ <https://www.aerialsolutions.be/en/product/dji-mavic-3-enterprise-thermal/>

¹⁶ <https://www.robor-nature.eu/oplossingen/faunadrone/>

benadrukt worden dat correcte vluchtuitvoering, kalibratie van de warmtecamera en een goede trainingsdataset veel belangrijker zijn dan de complexiteit van het beeldverwerkingsalgoritme. Heel wat goede machine learning modellen, getraind op RGB beelden, zijn vrij beschikbaar als open software en kunnen getraind worden met een dataset aan gelabelde (drone)foto's van de gewenste dieren. De meeste standaardcomputers hebben tegenwoordig de nodige rekenkracht om deze modellen opnieuw te trainen binnen een aanvaardbare tijd. Dit is echter gespecialiseerd werk waar de doorsnee gebruiker niet de nodige kennis voor heeft. Onderzoekinstellingen als ILVO of VITO zouden hier adviesverlening/expertise kunnen voorzien.

Om geautomatiseerde beeldverwerking te kunnen toepassen is momenteel dus de hulp van een commerciële partner aangewezen. Bedrijven die ervaring hebben met beeldverwerking uit de industriële sector hebben hier de nodige kennis. Tijdens persoonlijke communicatie met Dronedivision gaf het bedrijf aan hiervoor een commercieel pakket te kunnen voorzien. Voor een richtprijs van 7000€ + 250€ jaarlijkse abonnementskosten kan de gebruiker rekenen op het benodigde materiaal, training voor het instellen van een geschikt voorgeprogrammeerd vluchtpad, training voor de instelling van de correcte parameters en toegang tot een online platform waar de beelden na het beëindigen van de vlucht onmiddellijk kunnen geanalyseerd worden met behulp van machine learning. Online is dan binnen korte tijd de locatie van eventuele dieren terug te vinden. De nauwkeurigheid van de software kon niet geverifieerd worden. In bijlage is een flyer te vinden (zie 8.4). De vraag is of de efficiëntiewinst die met machine learning te behalen is in de praktijk opweegt tegen die van een getrainde piloot met de juiste kennis van fauna.

Voor thermale beelden zijn tot op heden nog maar weinig machine learning algoritmes gemaakt. Dit zal waarschijnlijk in de toekomst veranderen doordat ook deze sensoren krachtiger en goedkoper zijn geworden. Uit het gesprek met Dronedivision blijkt dat ze het beste van beide camera's gebruiken. Ze gebruiken warmtebeelden om (potentiële) dieren te detecteren tijdens de vlucht en analyseren vervolgens selectief de RGB beelden van zones met warme objecten en dus verhoogde waarschijnlijkheid op aanwezigheid van het gezochte dier. Het algoritme gaat dan finaal bepalen of het warme object al dan niet het dier betreft. Dit twee-staps proces zou de post-processing tijd terugbrengen naar iets wat op het veld werkbaar is. In de praktijk wil dit zeggen dat de beelden na de vlucht van de geheugenkaart van de drone worden gehaald en in de cloud verwerkt worden.

Live toepassen van beeldanalyse tijdens de vlucht is in de praktijk nog maar beperkt mogelijk omdat het doorsturen van data over het mobiele netwerk een limiterende factor is¹⁷. Op redelijk korte termijn kan daar wel verandering in komen als het 5G netwerk verder wordt uitgerold. Dit zou de doorlooptijd tussen start van de vlucht en de beschikbaarheid van de resultaten verder verkleinen.

Samenvattend heeft de eindgebruiker dus 3 opties:

Ten eerste kan men zelf een geschikte drone aanschaffen en in de praktijk ervaring gaan opbouwen. Specifieke opleidingen voor het gebruik van warmtebeelden (normaal eerder gericht op industriële toepassingen) zijn daarvoor een meerwaarde. Ook de nodige kennis om vooraf geprogrammeerde vluchtpaden in te stellen is een must.

Ten tweede kan ervoor gekozen worden om piloten en het benodigde materiaal in te huren. Met de benodigde ervaring en kennis zal dit tot betere resultaten leiden en dus kan dit nuttig zijn als

¹⁷ Persoonlijke communicatie met Dronedivision.

kennismaking met de techniek of voor eenmalige of kortlopende projecten. Het lijkt niet kostenefficiënt op lange termijn om dit bij veelvuldig gebruik uit te besteden.

Ten derde kan gekozen worden om voluit de kaart van geautomatiseerd beeldverwerking te trekken. Deze techniek wordt nog niet wijd toegepast. Buiten de wetenschappelijke context en pilootprojecten met experimenteel karakter is de enige in dit onderzoek naar boven gekomen optie een samenwerking met Dronedivision.

Zowel de markt als de wetgeving evolueren momenteel zeer snel waardoor de situatie er de komende jaren al anders kan uitzien. Dit neemt niet weg dat de huidige werkmethode (op basis van warmtebeelden zonder geautomatiseerde beeldverwerking) al veelvuldig wordt toegepast met goede resultaten.

Voorbeelden uit het buitenland tonen aan dat subsidies voor de aanschaf van het benodigde materiaal de toepassing van drones voor maaislachtoffers (en fauna detectie in het algemeen) laten toenemen. In Vlaanderen zijn deze er tot op heden echter niet.

7 Referenties

7.1 Beeldanalyse technieken om fauna te detecteren

1. Abd-Elraham, A., Pearlstine, L., & Percival, F. (2005). Development of Pattern Recognition Algorithm for Automatic Bird Detection from Unmanned Aerial Vehicle Imagery - ProQuest. *Surveying and Land Information Science*, 65(1), 37–45.
<https://www.proquest.com/openview/f55c12aa3e1010dc2176f4ad51a3e9db/1?pq-origsite=gscholar&cbl=27246>
2. Borowicz, A., McDowall, P., Youngflesh, C., Sayre-Mccord, T., Clucas, G., Herman, R., Forrest, S., Rider, M., Schwaller, M., Hart, T., Jenouvrier, S., Polito, M. J., Singh, H., & Lynch, H. J. (2018). Multi-modal survey of Adélie penguin mega-colonies reveals the Danger Islands as a seabird hotspot. *Scientific Reports*, 8(1). <https://doi.org/10.1038/s41598-018-22313-w>
3. Chabot, D., & Bird, D. M. (2012). Evaluation of an Off-the-shelf Unmanned Aircraft System for Surveying Flocks of Geese. *Waterbirds: The International Journal of Waterbird Biology*, 35(1), 170–174. <https://www.jstor.org/stable/41432487>
4. Chabot, D., & Francis, C. M. (2016). Computer-automated Bird detection and counts in high-resolution aerial images: a review. *Journal of Field Ornithology*, 87(4), 343–359.
<https://doi.org/10.1111/JOFO.12171>
5. Chrétien, L. P., Théau, J., & Ménard, P. (2015). WILDLIFE MULTISPECIES REMOTE SENSING USING VISIBLE AND THERMAL INFRARED IMAGERY ACQUIRED FROM AN UNMANNED AERIAL VEHICLE (UAV). *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-1-W4(1W4), 241–248.
<https://doi.org/10.5194/ISPRSARCHIVES-XL-1-W4-241-2015>
6. Chrétien, L. P., Théau, J., & Ménard, P. (2016). Visible and thermal infrared remote sensing for the detection of white-tailed deer using an unmanned aerial system. *Wildlife Society Bulletin*, 40(1), 181–191. <https://doi.org/10.1002/WSB.629>
7. Christiansen, P., Steen, K. A., Jørgensen, R. N., & Karstoft, H. (2014). Automated Detection and Recognition of Wildlife Using Thermal Cameras. *Sensors 2014, Vol. 14, Pages 13778-13793*, 14(8), 13778–13793. <https://doi.org/10.3390/S140813778>
8. Corcoran, E., Winsen, M., Sudholz, A., & Hamilton, G. (2021). Automated detection of wildlife using drones: Synthesis, opportunities and constraints. *Methods in Ecology and Evolution*, 12(6), 1103–1114. <https://doi.org/10.1111/2041-210X.13581>
9. Grenzdörffer, G. J. (2013). UAS-based automatic Bird count of a common gull colony. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-1/W2, 169–174. <https://doi.org/10.5194/isprsarchives-xl-1-w2-169-2013>
10. Hinke, J. T., Giuseffi, L. M., Hermanson, V. R., Woodman, S. M., & Krause, D. J. (2022). Evaluating Thermal and Color Sensors for Automating Detection of Penguins and Pinnipeds in Images Collected with an Unoccupied Aerial System. *Drones*, 6(9).
<https://doi.org/10.3390/drones6090255>
11. Hodgson, J. C., Mott, R., Baylis, S. M., Pham, T. T., Wotherspoon, S., Kilpatrick, A. D., Raja Segaran, R., Reid, I., Terauds, A., & Koh, L. P. (2018). Drones count wildlife more accurately and precisely than humans. *Methods in Ecology and Evolution*, 9(5), 1160–1167.
<https://doi.org/10.1111/2041-210X.12974>
12. Hong, S. J., Han, Y., Kim, S. Y., Lee, A. Y., & Kim, G. (2019). Application of Deep-Learning Methods to Bird Detection Using Unmanned Aerial Vehicle Imagery. *Sensors 2019, Vol. 19, Page 1651*, 19(7), 1651. <https://doi.org/10.3390/S19071651>

13. Hyun, C. U., Park, M., & Lee, W. Y. (2020). Remotely piloted aircraft system (Rpas)-based wildlife detection: A review and case studies in maritime Antarctica. In *Animals* (Vol. 10, Issue 12, pp. 1–17). MDPI AG. <https://doi.org/10.3390/ani10122387>
14. Israël, M. (2011). A UAV-BASED ROE DEER FAWN DETECTION SYSTEM. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XXXVIII-1/C22*, 51–55. <https://doi.org/10.5194/isprsarchives-xxxviii-1-c22-51-2011>
15. Israël, M., & Evers, S. (2011). *Mustererkennung zur Detektion von Rehkitzen in Thermalbildern*. Bornimer Agrartechnische Berichte, 1-6. 17. Workshop Computer-Bildanalyse in der Landwirtschaft 2011. Leibniz-Institut für Agrartechnik Potsdam-Bornim e.V. (ATB) <https://elib.dlr.de/71467/>
16. Israël, M., Mende, M., & Keim, S. (2015). UAVRC, a generic MAV flight assistance software. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 40(1W4)*, 287–291. <https://doi.org/10.5194/isprsarchives-XL-1-W4-287-2015>
17. Israël, M., & Reinhard, A. (2017). Detecting nests of lapwing Birds with the aid of a small unmanned aerial vehicle with thermal camera. *2017 International Conference on Unmanned Aircraft Systems, ICUAS 2017*, 1199–1207. <https://doi.org/10.1109/ICUAS.2017.7991393>
18. Kellenberger, B., Veen, T., Folmer, E., & Tuia, D. (2021). 21 000 Birds in 4.5 h: efficient large-scale seabird detection with machine learning. *Remote Sensing in Ecology and Conservation, 7(3)*, 445–460. <https://doi.org/10.1002/rse2.200>
19. Lee, W. Y., Park, M., & Hyun, C. U. (2019). Detection of two Arctic Birds in Greenland and an endangered Bird in Korea using RGB and thermal cameras with an unmanned aerial vehicle (UAV). *PLoS ONE, 14(9)*. <https://doi.org/10.1371/journal.pone.0222088>
20. Linchant, J., Lisein, J., Semeki, J., Lejeune, P., & Vermeulen, C. (2015). Are unmanned aircraft systems (UASs) the future of wildlife monitoring? A review of accomplishments and challenges. *Mammal Review, 45(4)*, 239–252. <https://doi.org/10.1111/MAM.12046>
21. Liu, C. C., Chen, Y. H., & Wen, H. L. (2015). Supporting the annual international black-faced spoonbill census with a low-cost unmanned aerial vehicle. *Ecological Informatics, 30*, 170–178. <https://doi.org/10.1016/J.ECOINF.2015.10.008>
22. Oishi, Y., Oguma, H., Tamura, A., Nakamura, R., & Matsunaga, T. (2018). Animal Detection Using Thermal Images and Its Required Observation Conditions. *Remote Sensing 2018, Vol. 10, Page 1050, 10(7)*, 1050. <https://doi.org/10.3390/RS10071050>
23. Psiroukis, V., Malounas, I., Mylonas, N., Grivakis, K.-E., Fountas, S., & Hadjigeorgiou, I. (2021). Monitoring of free-range rabbits using aerial thermal imaging. *Smart Agricultural Technology, 1*, 100002. <https://doi.org/10.1016/j.atech.2021.100002>
24. Rush, G. P., Clarke, L. E., Stone, M., & Wood, M. J. (2018). Can drones count gulls? Minimal disturbance and semiautomated image processing with an unmanned aerial vehicle for colony-nesting seabirds. *Ecology and Evolution, 8(24)*, 12322–12334. <https://doi.org/10.1002/ECE3.4495>
25. Sudholz, A., Denman, S., Pople, A., Brennan, M., Amos, M., & Hamilton, G. (2022). A comparison of manual and automated detection of rusa deer (*Rusa timorensis*) from RPAS-derived thermal imagery. *Wildlife Research, 49(1)*, 46–53. <https://doi.org/10.1071/WR20169>
26. Wirsing, A. J., Johnston, A. N., & Kiszka, J. J. (2022). Foreword to the Special Issue on ‘The rapidly expanding role of drones as a tool for wildlife research.’ *Wildlife Research, 49(1)*, i–v. <https://doi.org/10.1071/WR22006>

7.2 Manuele tellingen van fauna o.b.v. dronebeelden

27. Albores-Barajas, Y. v., Soldatini, C., Ramos-Rodríguez, A., Alcalá-Santoyo, J. E., Carmona, R., & Dell’Omo, G. (2018). A new use of technology to solve an old problem: Estimating the population size of a burrow nesting seabird. *PLoS ONE*, *13*(9).
<https://doi.org/10.1371/journal.pone.0202094>
28. Chabot, D., Craik, S. R., & Bird, D. M. (2015). Population Census of a Large Common Tern Colony with a Small Unmanned Aircraft. *PLOS ONE*, *10*(4), e0122588.
<https://doi.org/10.1371/JOURNAL.PONE.0122588>
29. Cukor, J., Bartoška, J., Rohla, J., Sova, J., & Machálek, A. (2019). Use of aerial thermography to reduce mortality of roe deer fawns before harvest. *PeerJ*, *2019*(5).
<https://doi.org/10.7717/peerj.6923>
30. Graves, T. A., Yarnall, M. J., Johnston, A. N., Preston, T. M., Chong, G. W., Cole, E. K., Janousek, W. M., & Cross, P. C. (2022). Eyes on the herd: Quantifying ungulate density from satellite, unmanned aerial systems, and GPS collar data. *Ecological Applications*, *32*(5).
<https://doi.org/10.1002/eap.2600>
31. Hodgson, J. C., Baylis, S. M., Mott, R., Herrod, A., & Clarke, R. H. (2016). Precision wildlife monitoring using unmanned aerial vehicles. *Scientific Reports*, *6*.
<https://doi.org/10.1038/srep22574>
32. Laguna, E., Barasona, J. A., Triguero-Ocaña, R., Mulero-Pázmány, M., Negro, J. J., Vicente, J., & Acevedo, P. (2018). The relevance of host overcrowding in wildlife epidemiology: A new spatially explicit aggregation index. *Ecological Indicators*, *84*, 695–700.
<https://doi.org/10.1016/j.ecolind.2017.09.039>
33. McMahon, M. C., Ditmer, M. A., & Forester, J. D. (2022). Comparing unmanned aerial systems with conventional methodology for surveying a wild white-tailed deer population. *Wildlife Research*, *49*(1), 54–65. <https://doi.org/10.1071/WR20204>
34. Patterson, C., Koski, W., Pace, P., McLuckie, B., & Bird, D. M. (2015). Evaluation of an unmanned aircraft system for detecting surrogate caribou targets in Labrador. *Journal of Unmanned Vehicle Systems*, *4*(1), 53–69. <https://doi.org/10.1139/juvs-2015-0014>
35. Preston, T. M., Wildhaber, M. L., Green, N. S., Albers, J. L., & DeBenedetto, G. P. (2021). Enumerating White-Tailed Deer Using Unmanned Aerial Vehicles. *Wildlife Society Bulletin*, *45*(1), 97–108. <https://doi.org/10.1002/WSB.1149>
36. Sardà-Palomera, F., Bota, G., Padilla, N., Brotons, L., & Sardà, F. (2017). Unmanned aircraft systems to unravel spatial and temporal factors affecting dynamics of colony formation and nesting success in birds. *Journal of Avian Biology*, *48*(9), 1273–1280.
<https://doi.org/10.1111/jav.01535>
37. Sardà-Palomera, F., Bota, G., Viñolo, C., Pallarés, O., Sazatornil, V., Brotons, L., Gomáriz, S., & Sardà, F. (2012). Fine-scale Bird monitoring from light unmanned aircraft systems. *Ibis*, *154*(1), 177–183. <https://doi.org/10.1111/j.1474-919X.2011.01177.x>
38. Scholten, C. N., Kamphuis, A. J., Vredevoogd, K. J., Lee-Strydhorst, K. G., Atma, J. L., Shea, C. B., Lamberg, O. N., & Proppe, D. S. (2019). Real-time thermal imagery from an unmanned aerial vehicle can locate ground nests of a grassland songbird at rates similar to traditional methods. *Biological Conservation*, *233*, 241–246.
<https://doi.org/10.1016/j.biocon.2019.03.001>
39. Witczuk, J., Pagacz, S., Zmarz, A., & Cypel, M. (2018). Exploring the feasibility of unmanned aerial vehicles and thermal imaging for ungulate surveys in forests - preliminary results. *International Journal of Remote Sensing*, *39*(15–16), 5504–5521.
<https://doi.org/10.1080/01431161.2017.1390621>

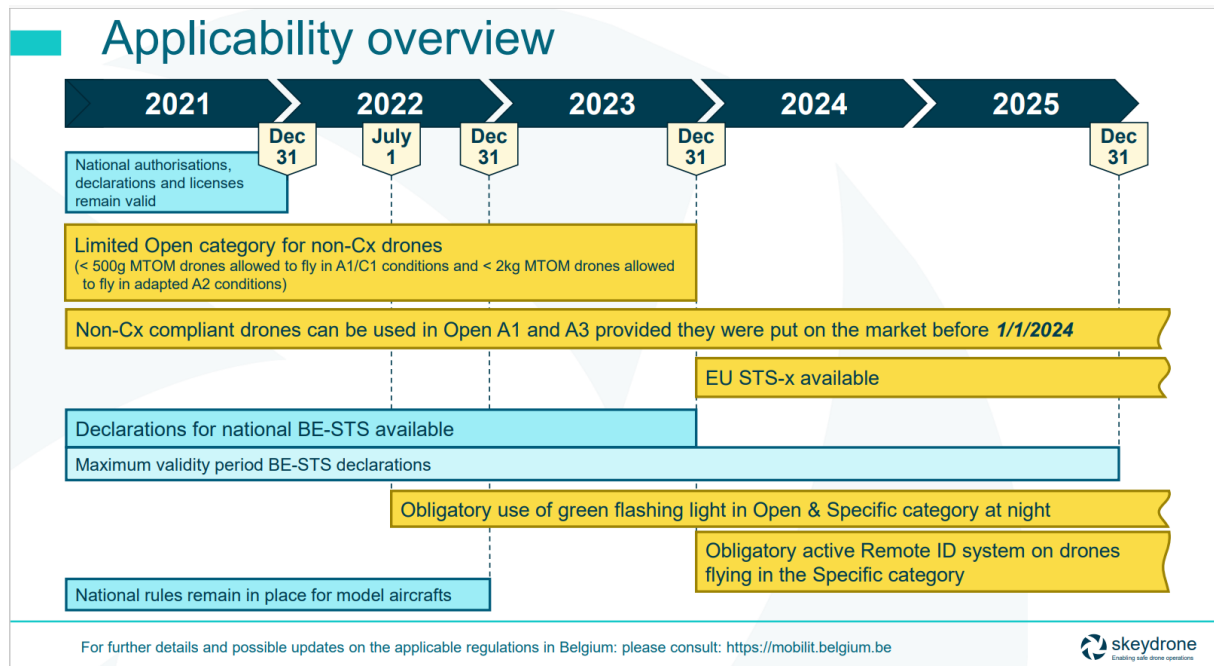
7.3 Bijkomende literatuur

40. Broset, S. (Auteur), Lejeune, P. (Promoteur), & Michez, A. (Promoteur). (2018). *Assessment of UAV potential for bioacoustic monitoring of Birds and bats: Tests under controlled conditions in Belgium*. <http://lib.uliege.behttps://matheo.uliege.be>
41. Cerra, D., Israel, M., & Datcu, M. (2009). PARAMETER-FREE CLUSTERING: APPLICATION TO FAWNS DETECTION. In IEEE Xplore (Ed.), *Wildretter*. Conference: Geoscience and Remote Sensing Symposium, 2009 IEEE International, IGARSS 2009 Volume: 3. <https://doi.org/10.1109/IGARSS.2009.5418293>
42. Chabot, D., & Bird, D. M. (2015). Wildlife research and management methods in the 21st century: Where do unmanned aircraft fit in? *Journal of Unmanned Vehicle Systems*, 3(4), 137–155. <https://doi.org/10.1139/JUVS-2015-0021>
43. Charbonneau, P., & Lemaître, J. (2021). Revue des applications et de l'utilité des drones en conservation de la faune. *Le Naturaliste Canadien*, 145(2), 3–34. <https://doi.org/10.7202/1080620ar>
44. Dulava, S., Bean, W. T., & Richmond, O. M. W. (2015). Environmental Reviews and Case Studies: Applications of Unmanned Aircraft Systems (UAS) for Waterbird Surveys. In *Environmental Practice* (Vol. 17, Issue 3, pp. 201–210). Cambridge University Press. <https://doi.org/10.1017/S1466046615000186>
45. Groom, G., Petersen, I. K., Anderson, M. D., & Fox, A. D. (2011). Using object-based analysis of image data to count Birds: Mapping of Lesser Flamingos at Kamfers Dam, Northern Cape, South Africa. *International Journal of Remote Sensing*, 32(16), 4611–4639. <https://doi.org/10.1080/01431161.2010.489068>
46. Groom, G., Stjernholm, M., Nielsen, R. D., Fleetwood, A., & Petersen, I. K. (2013). Remote sensing image data and automated analysis to describe marine Vogel distributions and abundances. *Ecological Informatics*, 14, 2–8. <https://doi.org/10.1016/j.ecoinf.2012.12.001>
47. Israël M. (2016). *Entwicklung eines UAV-basierten Systems zur Rehkitzsuche und Methoden zur Detektion und Georeferenzierung von Rehkitzen in Thermalbildern*. https://elib.dlr.de/108446/1/thesis_israel.pdf
48. Jones, H. G., & Vaughan, R. A. (2010). *Remote Sensing of Vegetation: Principles, Techniques and Applications*. Oxford University Press.
49. Pauly, K. (2020, 28th of November). *OpsDrone: Technical workshop – Data acquisition* [Powerpoint-slides]. remotesensing.vito.be. Consultant on 6th of February, 2023. Internal document, available upon request: <https://forms.office.com/Pages/ResponsePage.aspx?id=m3f8PDj19kCE2FWM650avWwnL6RdgLhFrGdVdBXyfJdUQU81RIk5MEIJUU8zREhHSU03RDcxRk1JNC4u>
50. Kellenberger, B., Marcos, D., & Tuia, D. (2018). Detecting mammals in UAV images: Best practices to address a substantially imbalanced dataset with deep learning. *Remote Sensing of Environment*, 216, 139–153. <https://doi.org/10.1016/j.rse.2018.06.028>
51. Kucharczyk, M., Hay, G. J., Ghaffarian, S., & Hugenholtz, C. H. (2020). Geographic object-based image analysis: A primer and future directions. In *Remote Sensing* (Vol. 12, Issue 12). MDPI AG. <https://doi.org/10.3390/rs12122012>
52. Kumar, V., Pandey, S., Pal, A., & Sharma, S. (n.d.). (PDF) *Edge Detection Based Shape Identification*. Retrieved January 6, 2023, from https://www.researchgate.net/publication/301926246_Edge_Detection_Based_Shape_Identification
53. Laliberte, A. S., & Ripple, W. J. (2003). Automated Wildlife Counts from Remotely Sensed Imagery. *Wildlife Society Bulletin*, 31(2), 362–371. http://www.jstor.org/stable/3784314http://www.jstor.org/stable/3784314?seq=1&cid=pdf-reference#references_tab_contents

54. Prosekov, A., Kuznetsov, A., Rada, A., & Ivanova, S. (2020). Methods for Monitoring Large Terrestrial Animals in the Wild. *Forests*, *11*(8), 808–819. <https://doi.org/10.3390/f11080808>
55. Steen, K. A., Villa-Henriksen, A., Therkildsen, O. R., & Green, O. (2012). Automatic detection of animals in mowing operations using thermal cameras. *Sensors (Switzerland)*, *12*(6), 7587–7597. <https://doi.org/10.3390/s120607587>

8 Bijlages

8.1 Informatieve figuren



Figuur 12 Tijdslijn omtrent wetgeving over subcategorieën drones Bron: FOD Mobiliteit

8.2 Tabellen

Tabellen op A3 formaat met een overzicht van de geraadpleegde literatuur zijn te vinden in een afzonderlijke bijlage.

8.3 Beeldanalyse

De technische achtergrond van beeldverwerking is dieper verkend dan in hoofdstuk 4 weergegeven. Wegens technisch te diepgaand voor de gebruiker die enkel op zoek is naar praktische toepassing, is dit onderdeel enkel als bijlage toegevoegd.

8.3.1 Data verzameling

De meeste dronevluchten worden vooraf gepland op basis van dronemissie software. Zo bestaan er zowel open-source software platformen (vb. MissionPlanner, QgroundControl) als commerciële software (vb. DJI GS Pro, Pix4D Capture, DroneDeploy, UGCS, Altizure, Waypoint Master) die dronepiloten toelaten hun vliegparameters te optimaliseren (grondresolutie, vliegsnelheid, altitude drone, aanmaak vluchtplan), rekening houdend met de drone en sensor eigenschappen/instellingen. Vooral bij warmtebeeldcamera's (langere integratietijd en grotere GSD waarden t.o.v. RGB camera's) of bij zeer hoge vluchten met fixed-wing drones is het correct instellen van de vluchtsnelheid en vluchthoogte cruciaal om voldoende kwaliteitsvolle informatie te verzamelen over de te detecteren dieren. Studies die verschillende vluchtparameters hebben uitgetest en de invloed op de beeldkwaliteit (en bijgevolg de waarschijnlijkheid van detectie) zijn voor RGB camera's (Hodgson et al., 2018) en (Cukor et al., 2019; Hinke et al., 2022; Israel, 2012; Israel & Reinhard, 2017) voor warmtebeeldcamera's.

De pixelgrootte van de afbeelding in de camera (s , vergelijking 1), de hoogte van de drone (h_f , vergelijking 2), de zoomafstand van de lens (c_k) en de afbeeldingsgrootte van de camera/sensor (in pixels) bepalen de spatiale resolutie/GSD (d_{GSD}) en de afmetingen van het in beeld genomen gebied (geprojecteerd op de grond, in meter).

$$s = \frac{\text{sensor breedte}}{\text{aantal pixels in de afbeeldingsbreedte}} = \frac{\text{sensor lengte}}{\text{aantal pixels in de afbeeldingslengte}} \quad (1)$$

$$h_f = \frac{d_{GSD} \cdot c_k}{s} \quad (2)$$

Op basis van het geprojecteerde gebied op de grond, de vliegsnelheid van de drone en capaciteit van de batterijen weet de piloot hoeveel gebied hij in kaart kan brengen in één vlucht. De maximale vliegsnelheid ($v(h_f)$, vergelijking 3) wordt op zijn beurt berekend uit de integratietijd van de sensor (t_i), de vlieghoogte (de altitude van de drone ten opzichte van de grond/maaiveld) van de drone en de maximaal toegelaten bewegingsonscherpte van p pixels in de beelden (Israel & Reinhard, 2017).

$$v(h_f) = \frac{h_f \cdot p \cdot s}{t_i \cdot c_k} \quad (3)$$

Om voldoende spectrale informatie te hebben over het object dat men wil detecteren met de sensor, gaat men bij dronebeelden een GSD nemen die kleiner is dan het object (in dit geval het dier) zelf. Verschillende vuistregels worden gehanteerd, zoals onder andere:

- de Nyquist-Shannon sampling theorie (vergelijking 4) (Israel, 2012), waarbij de maximale GSD kleiner is dan of gelijk aan tweemaal de lengte van het object; en
- bij objecten die verondersteld worden bijna perfecte cirkels te zijn (vb. een opgerolde reekalf, een kievitsnest), ongeveer een derde nemen van de diameter van het object (vergelijking 5) (Cukor et al., 2019; Israel & Reinhard, 2017).

$$d_{GSD} = \frac{2 \cdot \text{lengte}_{dier}}{s} \quad (4)$$

$$d_{GSD} = \frac{r_{nest}}{\sqrt{2}} \quad (5)$$

Onder vergelijking 4 of 5 zou men in theorie een opgerolde reekalf van 20 à 30 cm kunnen detecteren met een Workswell WIRIS (Cukor et al., 2019) of Tau640 TIR camera (Israel, 2012) vanop een maximale vlieghoogte van 50 of 166 meter, respectievelijk. Voor een nest van een kievit met een diameter van 9 cm zou de maximale vlieghoogte met een Tau640 TIR camera rond de 35,5 meter hoogte zijn (Israel & Reinhard, 2017). Na het uitvoeren van de dronevluchten zelf werd eerder een vlieghoogte/altitude van rond de 40 meter genomen (Cukor et al., 2019; Israel, 2012; Israel & Reinhard, 2017), als zijnde een goede balans tussen beeldkwaliteit/detectie succes en operationele uitvoering (snelheid uitvoering en totaal in kaart gebracht gebied). Voor het detecteren van konijnen met een warmtebeeldcamera lijkt de ideale vlieghoogte rond de 25 meter te zijn (FLIR Vue Pro camera) (Psiroukis et al., 2021), hoewel het dynamisch algoritme van (Christiansen et al., 2014) problemen had met detectie vanaf een vlieghoogte hoger dan 22 meter (camera model niet vermeld).

Voordat de data verzameld wordt moeten de sensoren ook geometrisch gecontroleerd worden. Het doel is dat de camera/sensor gekalibreerd wordt om de restfouten bij schattingen van de interne parameters van een camera (brandpuntafstand, scheefstand, vervorming,...) te minimaliseren om de systematische fout doorheen de vlucht te beperken (Pauly, 2020). Zo wordt standaard voor elke vlucht de GPS sensor (positie) op de drone, RGB camera (reflectantie-kalibratie en beeldrectificatie) en/of warmtebeeldcamera (niet-uniforme correctie, thermale stabilisatie en beeldrectificatie) gekalibreerd (Cukor et al., 2019). Ook tijdens de vlucht moeten soms kalibraties of validaties gedaan worden door

wisselend terrein of lichtcondities (vb. histogram matching op basis van een zonnensensor) (Pauly, 2020).

8.3.2 Preprocessing

Bij de meeste dronevluchten worden tijdens de vlucht foto's genomen met een overlap (voorwaarts en zijwaarts, ongeveer 20 t.e.m. 80% van de afbeeldingsgrootte) (Chrétien et al., 2015). Deze foto's worden dan aaneengehecht met gespecialiseerde verwerkingssoftware als PIX4Dmapper, Agisoft Metashape, DJI Terra, DroneDeploy of de open-source software OpenDroneMap. Uit deze data kan dan 2D (orthofotomozaïeken) of 3D data gehaald worden (digitale oppervlakte modellen of puntenwolken) via het principe 'structure from motion'. Hierbij worden ook enkele grond controle punten (GCP's, ongeveer 90 euro/stuk) gebruikt, waarvan de ruimtelijke coördinaten gemeten zijn, om de beelden te geo-refereren (voor elk punt in de beelden is de geo-locatie gekend).

Hoe groter de overlap, hoe makkelijker de software de beelden correct aaneen kan hechten, maar ook hoe groter de kans dat een dier meermaals gedetecteerd kan worden (doordat het voorkomt in meerdere beelden) (Chrétien et al., 2015, 2016). Men probeert het probleem van dubbele tellingen te mijden door de overlap tussen beelden minimaal te maken (Psiroukis et al., 2021). Indien meerdere beelden van éénzelfde locatie genomen worden (vb. beeldopname waarbij de drone ter plaatsen zweeft, selecteert men het beeld met de beste datakwaliteit) (Christiansen et al., 2014; Psiroukis et al., 2021). De opkomst van drones met GNSS-RTK/GNSS-PPK (Global Navigation Satellite System - Real Time Kinematic of – Post processed Kinematic) sensoren laat toe om de overlap in beelden te beperken (tot zelfs geen overlap) en alsnog een centimeter accurate positie te hebben (mits verder correctie op basis van één of meerdere GCP's) van de drone en camera (Pauly, 2020). Op basis van 'differential global position system' (DGPS) wordt een real-time correctie uitgevoerd op de positie van de drone tijdens de vlucht. Deze real-time correctie (NTRIP standaard) wordt in België gratis beschikbaar gesteld via de mobile netwerken van FLEPOS en Walcor. Internationaal betaalt men gewoonlijk 600 euro per jaar voor zo'n RTK correctie (Pauly, 2020).

Het grote voordeel van RTK/PPK sensoren (kost rond de €1,5-2k) is dat men deze kan gebruiken om sensorbeelden direct te geo-refereren. Hierdoor moet men niet de beelden aaneenhechten (wat soms 2 à 3 dagen kan duren afhankelijk van de grootte en spatiale resolutie van het veld) wat een enorme tijds winst kan opleveren. Verder laat het toe om vluchten met een minimale overlap tussen de beelden te hebben, waardoor de kans op dubbele detectie van dieren enorm verkleint (Hong et al., 2019).

Nadat de data verzameld wordt moet ze vervolgens verder geometrisch en radiometrisch gecorrigeerd worden en eventueel samengevoegd tot foto-mozaïeken (Chrétien et al., 2016). Dit kan in eerder vernoemde processing software of in geografische informatiesystemen software (vb. QGIS (open-source) of ArcGIS/ArcMap).

8.3.3 Analyse en post-processing

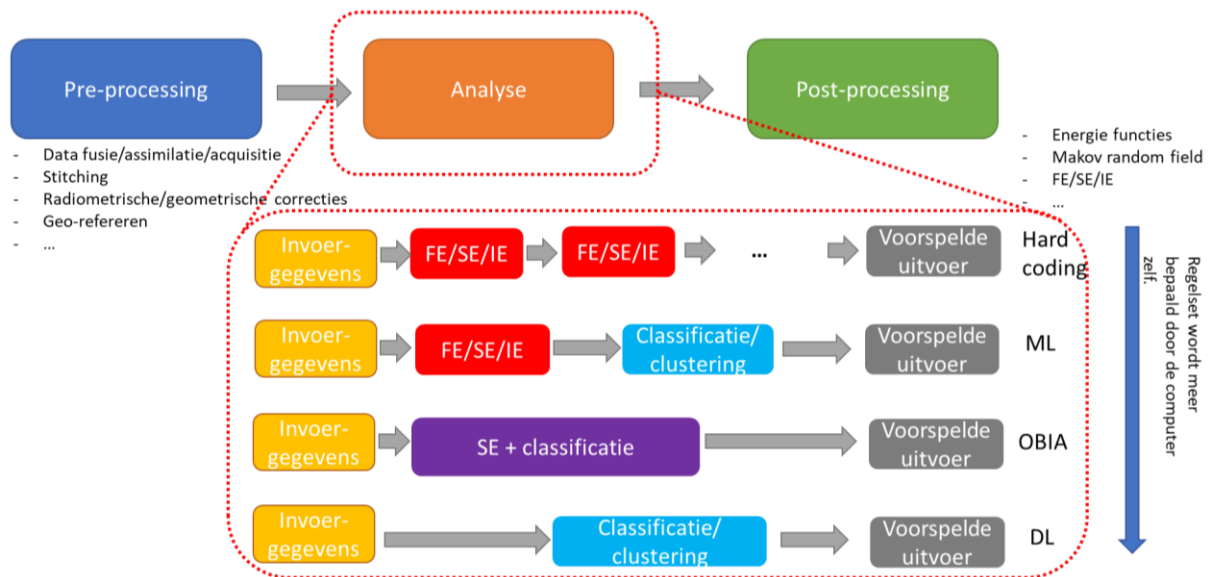
8.3.3.1 Beeldverwerkingstechnieken

Onder beeldverwerkingstechnieken worden in dit rapport er een viertal groepen beschouwd (Jones et al., 2010; Kumar et al., nd) :

- Beeldversterkingstechnieken (vb. contrast stretching, spectrale indices, ruimtelijke filtertechnieken, intensiteit-, tint- en verzadigingstransformaties, gegevensfusie, gegevensassimilatie).

- Eigenschap extractie methoden (Engels: “feature extraction”) (vb. ruimtelijke eigenschappen, getransformeerde eigenschappen, randen en grenzen, vorm eigenschappen, textuur, beeld moment).
- Beeldsegmentatie (vb. template matching, drempelwaarden, grensdetectie, clustering modellen quad-trees, textuur matching).
- Classificatie modellen.

De meest eenvoudige vormen van beeldanalyse zijn beeldversterkingstechnieken en eigenschap-extractie methoden. Deze technieken maken louter gebruik van ruimtelijke, spectrale en textuur informatie waardoor het contrast tussen het te detecteren object (in dit geval een dier) en de achtergrond in de beelden verhoogd wordt. Die informatie kan dan gebruikt worden in beeldsegmentatie of classificatiemodellen. Bij beeldsegmentatie kan een ‘vaste regelset’ zelf door de data-analist bepaald worden door een code in een programmeertaal, of kan bepaald worden via een unsupervised machine-learning algoritme waarbij de data-analist slechts enkele inputparameters moet geven. Classificatie is naast regressie een typisch voorbeeld van supervised learning, waarbij de computer categorische data (vb. een dier of geen dier) moet ‘leren’ op basis input data en heel veel gelabelde outputdata (zie sectie Machine learning). Naarmate het probleem te complex werd (de detectie van de dieren) werd de regelgeving te moeilijk om volledig zelf te programmeren en werd de patroonherkenning meer overgelaten aan de computer zelf. Een overzicht van de verschillende (semi)automatische beeldanalyse-technieken wordt gegeven in Figuur 6.



Figuur 6: Stappenplan van beeldverwerking: preprocessing, beeldanalyse en postprocessing. In de analyse fase zijn er verschillende opties om de verwerking (semi)automatisch te laten verlopen. Zo kan er gekozen worden voor ‘hard coding’, waarbij een regelset wordt bepaald door de data-analist zelf. Hierbij worden opeenvolgende regels gedefinieerd van eigenschap extractie (FE), segmentatie (SE) en/of beeldversterking (IE) technieken om uiteindelijk de gewenste objecten te detecteren (in dit geval een dier). Ook kan men er voor kiezen om de regelset te laten bepalen door de computer zelf onder de vorm van machine learning (ML), object-based image analysis (OBIA) en deep learning technieken.

8.3.3.2 (Semi)automatische beeldverwerking

Hieronder wordt een overzicht van de verschillende technieken van (semi)automatische beeldanalyse die gebruikt zijn in de literatuurstudie om dieren te detecteren uit drone gemonteerde camera’s (Tabel 3). Hierbij worden de voor- en nadelen besproken over de technieken en vergeleken

op basis van hun efficiëntie in het detecteren van dieren. Merk op dat de ‘waarschijnlijkheid van detectie’ of ‘sensitiviteit’ van een model slechts één van de vele performantie-maten is om een classificatiemodel te beoordelen. Deze maat is de ratio van het aantal gedetecteerde dieren (door het algoritme) t.o.v. het werkelijk totaal aantal aanwezige dieren. Verder is er het type referentiedata, dat de werkelijke hoeveelheid aanwezige dieren weergeeft, verschillend over de verschillende studies heen. Zo wordt dit onder andere bepaald door grondtellingen (Chrétien et al., 2015, 2016; Christiansen et al., 2014), grondtellingen op afstand (Hodgson et al., 2018; Israel & Reinhard, 2017), schattingen op basis van fecale pellets (Prosekov et al., 2020) of op basis van manuele foto-interpretatie (Kellenberger et al., 2021; Sudholz et al., 2022) van de dronebeelden door de data-analist. De methoden evalueren op basis van één performantiemaat is echter onvoldoende om een volledig beeld te krijgen van accuraatheid en precisie van de modellen en bijkomend misleidend indien men geen rekening houdt met de verschillende typen aan referentiedata. Bijgevolg zijn er ook studies die geen rekening houden met (mogelijke) correlaties tussen hun trainings-, validatie- en testdataset, waardoor deze niet onafhankelijk zijn van elkaar en de maat van performantie overschat kan zijn (Christiansen et al., 2014).

8.3.3.3 Hard coding

Sommige dieren hebben voldoende contrast in temperatuur en/of kleur in vergelijking met hun omgeving. Zo kan met eenvoudige beeldversterkingstechnieken (Israel, 2012; Israel & Reinhard, 2017), spectrale- (Abd-Elrahman & Pearlstine, 2005; Chabot & Bird, 2012) en/of thermale drempelwaarden (Lee et al., 2019) en/of op basis van vorm (Abd-Elrahman & Pearlstine, 2005; Chabot & Bird, 2012) het dier herkend worden t.o.v. de omgeving. Deze manier van analyse kan zeer hoge sensitiviteit halen (> 90% (Chabot & Bird, 2012; Israel & Reinhard, 2017; Lee et al., 2019; Oishi et al., 2018)). Het manueel coderen (hard coding) van een regelset, waarbij beeldversterkings-, eigenschap extractie- en/of segmentatie methoden gebruikt worden, kan beschouwd worden als de oudste vorm van beeldanalyse in remote sensing. Een van de eerste papers die beeldanalyse technieken gebruikte om dieren te tellen waren (Abd-Elrahman & Pearlstine, 2005; Laliberte, 2003). Hierbij werden regelsets opgesteld op basis van spectrale-, spatiale- (grootte) en vorm eigenschappen om dieren te tellen op basis van kleurenfoto's genomen per bemand vliegtuig (Laliberte, 2003), hoge resolutie satellietbeelden (Laliberte, 2003) of dronebeelden (Abd-Elrahman & Pearlstine, 2005). Het nadeel van deze methoden is dat de regelset vaak manueel bepaald is (vb. manueel drempelwaarden instellen) en dat ze vaak enkel voor eenvoudige problemen werkt. Als het gaat om de detectie van meerdere soorten dieren in meerdere achtergronden/habitats wordt het probleem te complex om zelf te programmeren. Vandaar dat men vanaf 2011 begint over te schakelen naar meer geautomatiseerde algoritmes, waarbij de computer zelf de regelset van de modellen bepaalt (machine learning).

8.3.3.4 Machine learning

Conventionele machine learning (en deep learning) kan onderverdeeld worden in drie groepen op basis van de manier van ‘learning’, met name supervised-, unsupervised en reinforcement learning.

- Supervised learning: een voorspellingsmodel is gemaakt op basis van een grote trainingsdataset aan gelabelde data (vb. elke foto is gelabeld als dier of geen dier) om

eigenschappen/kenmerken (de inputdata) aan de gelabelde data te koppelen zodat het in staat is om labels van nieuwe en ongeziene data automatisch te voorspellen.

- Unsupervised learning: omvat het extraheren van zinvolle representaties om belangrijke kenmerken van de dataset te verklaren. Er zijn geen labels nodig om van de gegevens te leren, hoewel labels soms nuttig zijn voor de evaluatie van algoritmen. Het doel is om de ongelabelde dataset in afzonderlijke groepen of clusters te verdelen, die soortgelijke eigenschappen binnen de clusters delen, maar verschillen van andere clusters. Een ander doel kan zijn om vanuit een grote set van eigenschappen, de belangrijkste te identificeren die bepalend zijn voor de clusters (dimensiereductie/patroonherkenning).
- Reinforcement learning: een intelligent 'agent' leert om een bepaalde set (gelimiteerd) van acties te ondernemen in een echte of gesimuleerde omgeving om het begrip 'cumulatieve beloning' te maximaliseren. Door trial-en-error, verkent de agent de omgeving en gebruikt feedback om zijn prestaties te verbeteren. Hierbij zijn ook geen kenmerk-labelparen nodig.

Bijkomend bestaat er ook semi-supervised learning, wat kan beschouwd worden als een mix van supervised- en unsupervised learning. Supervised en unsupervised learning zijn de machine learning (ML) methoden die gebruikt worden om dieren te detecteren o.b.v. dronebeelden, met de eerste methode de dominante vorm (Tabel 3).

Gezien het probleem categorisch van aard is, met name het groeperen van pixels/pixelclusters in 'wel een dier' of 'geen dier' gaat het om classificatie (supervised learning) of clustering (unsupervised) modellen gaan. Tabel 3 geeft weer dat de eerste machine learning technieken gebruikt worden vanaf 2011 om grondbroedende vogels, hertachtigen, hazen en konijnen te detecteren uit drone data (Christiansen et al., 2014; Grendörffer, 2013; Hodgson et al., 2018; Israel & Evers, 2011; Liu et al., 2015; Rush et al., 2018).

De studies die conventionele machine learning (CML) modellen gebruiken gaan een classificatie of clustering uitvoeren op pixel niveau, waarbij de kenmerken van de kleurenwaarden (rood, groen, blauw) of de thermale waarden van de pixels gebruikt worden om deze te klasseren. Sommige studies gebruiken gewoon de ruwe reflectantiewaarden van rood, groen en blauw (Grendörffer, 2013; Liu et al., 2015; Rush et al., 2018) of de stralingsemisatie (Chrétien et al., 2016) in het LWIR die bepaald zijn in de post-processing fase. Anderen gebruiken eigenschap-extractiemethoden waarbij de waarden getransformeerd worden naar een variabele die meer karakteristiek is aan het dier zelf, zoals:

- invariante Fourier histogrammen van georiënteerde gradiënten voor RGB waarden (Hodgson et al., 2018),
- fast compression distance (Lempel-Ziv-Welch algoritme) als een "gelijkheidsmaat" tussen warmtebeelden verzameld met de drone en referentie warmtebeelden verzameld op de grond (Israel & Evers, 2011),
- discrete cosinus transformaties van warmtebeelden als benadering van het soort-specifieke warmtespectrum (van de koudere rand naar het warmere centrum van het dier) (Christiansen et al., 2014),
- principaal componenten van zowel RGB als warmtebeeld informatie van het dier (Chrétien et al., 2016).

Pixelgewijze classificatie heeft als nadeel dat ze vaak ‘zout en peper’ patroon geven, vooral als er een bepaalde klasse weinig of niet aanwezig is in een beeld, wat vaak het geval is als de dieren random aanwezig zijn in het in kaart gebrachte gebied (Chrétien et al., 2016). De studies voeren daarom na elke classificatie nog post-processing stappen uit om foutief geklasseerde pixels te verwijderen. Dit wordt opnieuw gedaan op basis van hard-coding van eigenschap extractie-, beeldversterkings- en segmentatiemethoden (manuele drempelwaardenbepaling). De regelset heeft als doel een pixelcluster van dezelfde klasse te identificeren als één object (dier). Dit kan op basis van biologische eigenschappen van het dier zelf, zoals bijvoorbeeld:

- de afstanden tussen pixels (welke pixels behoren tot éénzelfde dier, welke tot verschillende dieren) en de vorm van de pixelcluster (Grenzdörffer, 2013; Liu et al., 2015) ;
- het filteren van pixels met over-gesatureerde spectrale waarden (vb. overbelichte zandpixels)(Grenzdörffer, 2013); en
- het minimaliseren van speciaal gecodeerde energiefuncties die op basis van spatiale interacties en spectrale eigenschappen van de pixels de overbodig geklasseerde objecten wegfiltert (Hodgson et al., 2018).

Deze postprocessing kan alsnog veel werk zijn om de juiste regelset te bepalen die de gewenste performantie geeft van het finale model. Hoewel vele van deze algoritmes een sensitiviteit halen van boven de 90%, is de precisie in bepaalde studies beperkt door de hoge hoeveelheid aan ‘vals positieven’ (Chrétien et al., 2016). Bijkomend zijn de modellen vaak gebaseerd op een beperkte dataset, voor één diersoort en voor één bepaalde achtergrond. Hierdoor zijn ze gevoelig voor ‘overfitting’, waardoor de modellen misschien perfect werken voor de trainingsdataset, maar waarbij de performantie sterk achteruitgaat voor nieuwe data. Bijvoorbeeld wanneer er gevlogen is met andere licht- en weerscondities, een andere omgevingsstructuur of habitat. Dit probleem wordt gekend als de bias-variantie afweging, en kan enkel geëvalueerd worden met een onafhankelijke testdataset. Ensemble modellen, regularisatie technieken, resampling technieken en voldoende kwaliteitsdata kunnen dit probleem beperken. Verder kan een model dat slechts getraind is op het herkennen van één dier nooit een diersoort correct klasseren waarop het nooit getraind is (Corcoran et al., 2021).

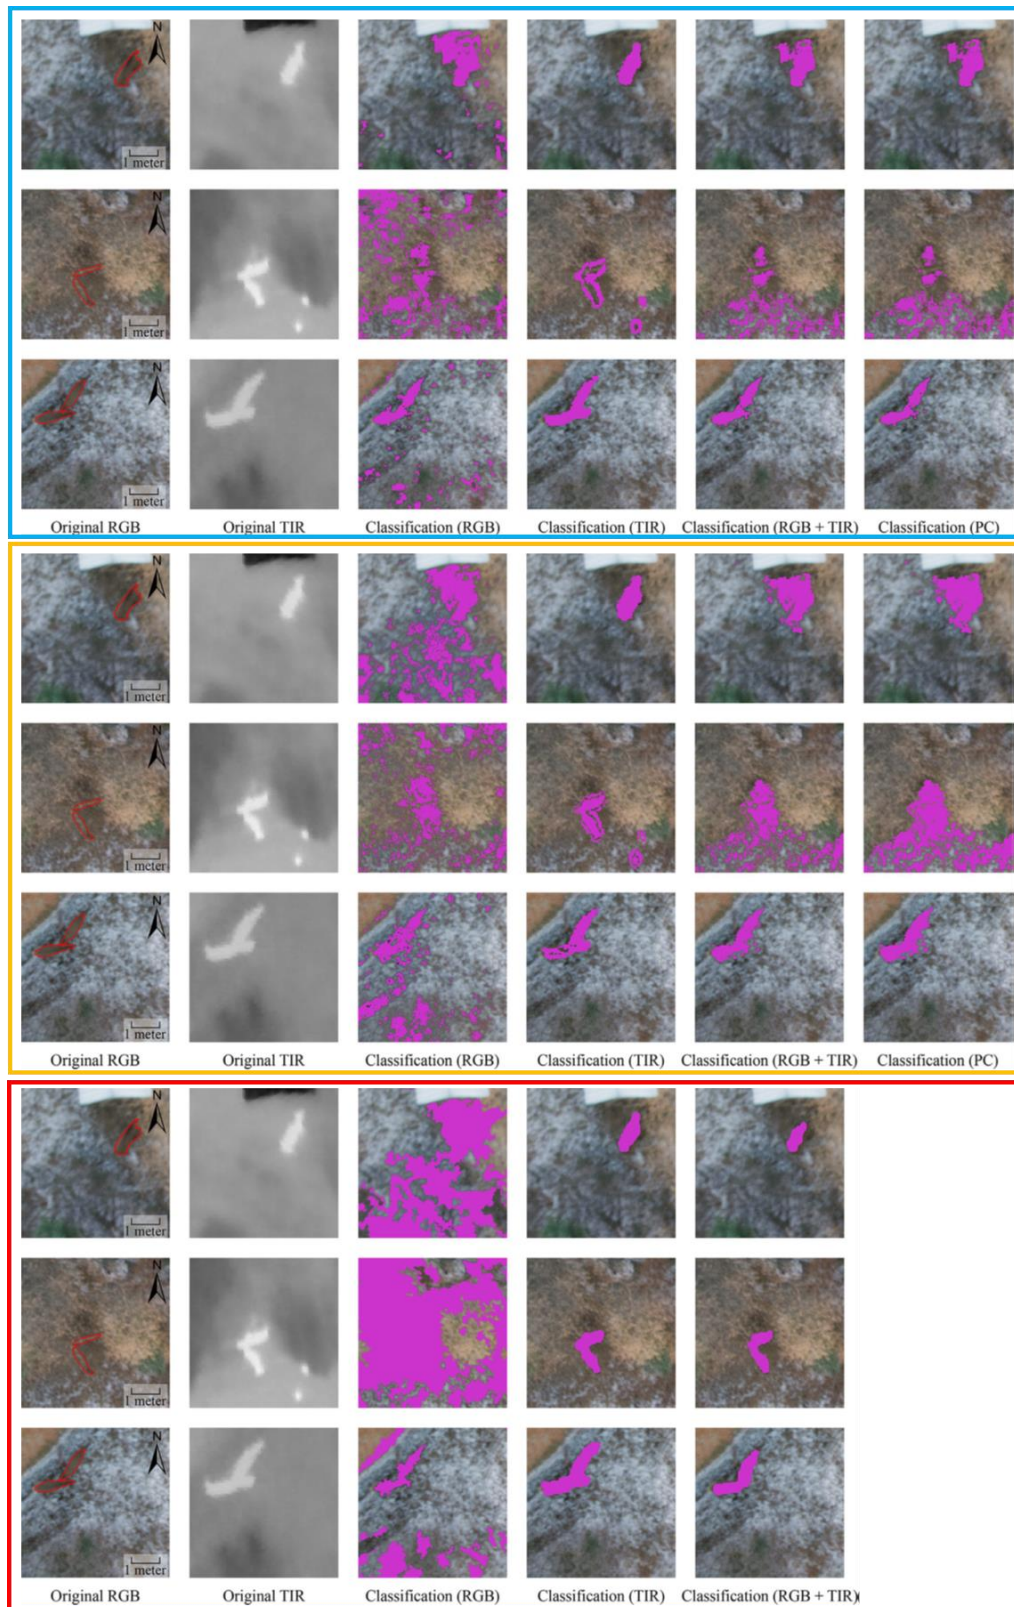
8.3.3.5 OBIA

Het probleem van het ‘zout en peper’ effect van pixelgewijze classificatie/clustering op basis van ML kan opgelost worden door middel van object-based image analysis (OBIA). Hierbij worden pixels eerst gegroepeerd in clusters op basis van segmentatie technieken (Chrétien et al., 2015, 2016; Groom et al., 2011, 2013). Dit omvat zowel het instellen van manuele regelsets/drempelwaarden als het toepassen van unsupervised learning technieken. De pixels kunnen geclusterd worden op basis van gelijkaardige spectrale, texturele, vorm, context en grootte eigenschappen. De beschrijvende statistieken (vb. gemiddelde, variantie) van deze eigenschappen kunnen dan gelinkt worden aan label (dier of geen dier), waarmee een supervised classificatie model wordt getraind. Het succes van segmentatie is bepalend voor de performantie van het classificatie model.

Deze methode wordt gebruikt vanaf 2011 in beeldanalyse van camera’s aan boord van bemande luchtvoertuigen voor de detectie van dieren (Groom et al., 2011). Sinds het ontstaan van de eerste

commerciële OBIA software Trimble eCognition® in 2000, is OBIA een belangrijke vorm van automatische beeldanalyse geworden (Kucharczyk et al., 2020). Sindsdien zijn er een hoop nieuwe open-source en commerciële softwares ontstaan en probeert men OBIA mee te integreren in een workflow met CNN modellen (Kucharczyk et al., 2020). OBIA software heeft gewoonlijk een gebruiksvriendelijke interface om gemakkelijker databronnen te combineren (vb. van meerdere camera's) en een regelset te bepalen voor de segmentatie en classificatie.

De studies van Chrétien et al. (Chrétien et al., 2015, 2016) laten zien dat deze methoden makkelijk toelaten data van zowel RGB als TIR data te combineren in een classificatiemodel, wat een verbetering gaf in model performantie. Bijkomend was het mogelijk één model te maken dat meerdere soorten zoogdieren kon detecteren van meerdere types achtergronden (Chrétien et al., 2016). Hierbij was de performantie van het OBIA model duidelijk beter dan de pixelgewijze supervised CML modellen (Figuur 7). Merk op dat in deze studies de dieren zich niet in een natuurlijk habitat bevinden (een dierenopvang) waardoor ook de variatie in omgeving beperkt is (Chrétien et al., 2015, 2016). Bijkomend gaven de onderzoekers aan dat het vinden van de juiste regelset voor OBIA die werkt voor alle beelden zeer tijdsintensief kan zijn (tot zelfs enkele dagen) (Chrétien et al., 2015, 2016).



Figuur 7: Voorbeelden van de classificatie resultaten van de supervised pixel methode (blauwe kader), unsupervised pixel methode (oranje kader) en object-based image analysis (OBIA) methode (rode kader). Voor de kolommen van links naar rechts zien we de originele kleurenfoto (RGB), het warmtebeeld (TIR), de classificatie waarbij enkel de RGB als inputdata is gebruikt, de classificatie waarbij enkel TIR als inputdata is gebruikt, de classificatie waarbij zowel TIR als RGB als inputdata is gebruikt en classificatie van de eerste 3 principaalcomponenten (PC), afgeleid van de RGB en TIR data (niet voor de OBIA methode). Dit voor de detectie van witstaartherten. Magenta elementen vertegenwoordigen pixels in de klasse "hart" en de rode grens vertegenwoordigt de lichaamsomtrek van elk hert. Afbeeldingen zijn overgenomen en aangepast uit (Chrétien et al., 2015).


8.3.3.6 Deep learning

Deep learning (DL) is een vorm van machine learning, waarbij de architectuur van het model een mimicry is van de neuronencellen in hersenen ('artificial neural network'). Voor de befaamde Convolutional Neural Networks (CNNs) zijn zeer populaire vormen van Deep Neural Networks (DNNs) om afbeeldingen te classificeren. De enorme hoeveelheid parameters (gewichten, biases en hyperparameters) kunnen enkel berekend worden door de computer als het model beschikt over een voldoende grote dataset om te trainen.

In tegenstelling tot CML, moeten bij supervised DL geen eigenschappen/kenmerken gelinkt worden met gelabelde data. De ruwe inputdata kan linkt worden met een label, en de computer zal zelf de eigenschappen 'herkennen' zolang het maar over een voldoende grote gelabelde trainingsdataset beschikt. Een keten van convolutie filters, activatiefuncties en pooling filters zorgt ervoor dat relevante eigenschappen uit de beelden gelinkt worden met een 'label'. Er bestaan vele verschillende types van CNNs, die onderverdeeld kunnen worden in het type classificatie die ze moeten uitvoeren (Su et al., 2023).

- beeldherkenning: een volledige foto wordt geklasseerd als een label. Varianten hiervan zijn patch-based en pixel-based CNN, waarin de foto verdeeld wordt in kleinere regio's (patches) en de beeldherkenning gebeurt op de kleinere patches waarna het geklasseerd resultaat terug opgeschaald wordt naar de volledige foto.
- beeldsegmentatie: gaat elke pixel in de foto klasseren naar een bepaalde label.
- object detectie: het model lokaliseert en klasseert speciale objecten in een beeld en geeft ze een begrenzingsvlak.
- instantie-segmentatie: het model segmenteert de pixels van een object dat gedetecteerd wordt in het begrenzingsvlak.

De terminologie kan verwarrend zijn met de zaken die besproken zijn in voorgaande secties. Daarom dat een fictief voorbeeld gegeven wordt in Figuur 8 om deze te illustreren.



Figuur 8: Fictief voorbeeld van een afbeelding (online Bing afbeelding: auteur is onbekend, licentie onder CC BY-SA-NC) classificaties van verschillende convolution neural networks (CNNs) types. De afbeelding link bovenaan zou door een beeldherkenning algoritme geklasseerd kunnen worden als 'zoogdieren'. De afbeelding rechtsboven zou het resultaat van een fictieve beeldsegmentatie kunnen zijn, met in het geel: achtergrond, rood: hond, blauw: rivierotter en groen: mens. Afbeelding linksonder: een fictief resultaat van een object detectie algoritme, waarbij het model begrensvlakken voorstellen van objecten die het detecteert (zelfde kleurencode als bij segmentatie). Afbeelding rechtsonder: een fictief resultaat van een instantie-segmentatie classificatie, waarbij een segmentatie gebeurt voor de gedetecteerde objecten in een begrensvlak.

De publicaties die deep learning modellen gebruiken om hertachtigen, hazen, konijnen of grondbroedende vogels te detecteren zijn van de types 'beeldherkenning' (Borowicz et al., 2018; Kellenberger et al., 2021) of 'object detectie' (Hinke et al., 2022; Hong et al., 2019; Psiroukis et al., 2021; Sudholz et al., 2022). Drie studies gebruikten hierbij RGB data (Borowicz et al., 2018; Hong et al., 2019; Kellenberger et al., 2021), twee warmtebeelddata (Psiroukis et al., 2021; Sudholz et al., 2022) en één beide types data (Hinke et al., 2022) (hoewel de warmtebeelddata weinig meerwaarde gaf in performantie van het model) als input voor de modellen.

Kellenberger et al. (Kellenberger et al., 2021) gebruikte een beeldherkenning CNN (een aangepast ResNet-18 architectuur), waarbij het model een nieuw raster voorspelt waarvan de pixels vergroot worden tot ongeveer de grootte van het dier zelf (stern- en meeuwsoorten). Na de classificatie werd nog een Markov random field algoritme uitgevoerd in de post-processing stap om foutieve klassen weg te filteren. Een patch-based CNN (DetectNet) werd gebruikt door (Borowicz et al., 2018) om een RGB orthofotomozaïek van een kolonie adeliëpinguïns te verdelen in kleinere patches, waarna elke patch geklasseerd wordt op het aantal pinguïns aanwezig in de patch.

CNNs die object detectie uitvoeren kunnen de objectbepaling laten gebeuren in één stadium (het simultaan voorstellen van een begrensvlak en een classificatie) of twee stadia (sequentieel voorstellen van een begrensvlak en een classificatie). Eén stadium object detectie modellen hebben algemeen een hogere rekensnelheid (het object wordt sneller gedetecteerd) t.o.v. twee-stadia object detectie modellen, maar dit kan ten koste gaan van een lagere accuraatheid (Hong et al., 2019).

You-only-look-once (YOLO) is één van de CNN modellen die objectbepaling in één stadium laten verlopen die veel gebruikt wordt om dieren te detecteren (Hinke et al., 2022; Hong et al., 2019; Psiroukis et al., 2021). Faster Region-Based Convolutional Neural Network (Faster-RCNN) is een CNN

model dat objectbepaling in twee stadia laat verlopen, en dat geliefd is wegens zijn hoge performantie (Hong et al., 2019). Een ensemble model van YOLO en Faster-RCNN werd gebruikt in de studie van (Sudholz et al., 2022), waarbij Javaanse herten enkel werden “gedetecteerd” via warmtebeelden wanneer ze door beide modellen voorspeld werden. Dit maakt de performantie van het model meer robust (minder kans op ‘overfitting’) en voorspellingen van nieuwe data meer betrouwbaar.

Ondanks dat de performantiematen van de modellen in Tabel 3 onvolledig zijn is het niet uit te sluiten dat de komst van CNN modellen, in combinatie met steeds meer rekenkrachtige computers, de automatische detectie/classificatie revolutionair heeft doen veranderen (Corcoran et al., 2021). Dit zowel in performantie als in de complexiteit die deze modellen aankunnen. Zo slaagt het model van (Kellenberger et al., 2021) erin om meerdere soorten te klasseren met een hoge accuraatheid. Enkel soorten die zelfs via manuele foto-interpretatie van dronebeelden zeer moeilijk te klasseren zijn tot op soort kunnen uiteraard niet voorspeld worden door de computer (zoals de twee meeuwsoorten uit de laatste studie).

Dit kan met relatief weinig labels (Kellenberger et al., 2021). De auteurs beweren dat het labelwerk slechts ongeveer een half uur duurde. Hiermee was hun volledige verwerkingstijd gereduceerd naar ongeveer viereneenhalf uur, in tegenstelling tot hun verwerkingstijd van manuele foto-interpretatie en labelwerk van drie weken. Wat cruciaal is volgens de onderzoekers is dat de trainingsdata gebalanceerd is (Kellenberger et al., 2018, 2021). Dit wil zeggen dat elke klasse ongeveer evenveel moet voorkomen in de trainingsdataset. Anders gaat het model ‘overfitten’ op de meest voorkomende soort in de trainingsdata en elk object als deze soort voorspellen (Kellenberger et al., 2018, 2021). Dit kan in praktijk soms moeilijk gerealiseerd worden als men luchtfoto’s wil nemen van cryptische dieren of zeldzame soorten.

8.3.3.7 Het vereenvoudigen van het label werk

Heel wat onderzoekers proberen het labelwerk te verminderen voor de training-, validatie- en test datasets voor supervised ML, OBIA en DL modellen. Active learning, semi-supervised learning, weak-supervised learning, transfer learning, few-shot learning en synthetische data (o.a. gegevensvergroting (Engels: data augmentation), generative adversarial networks, etc.) data zijn allemaal technieken die ontwikkeld zijn om de totale hoeveelheid labelwerk te verminderen. Al deze technieken overlopen valt buiten de scope van dit rapport, maar de relevante technieken voor dit rapport worden kort aangehaald:




- Transfer learning (Borowicz et al., 2018; Hinke et al., 2022; Kellenberger et al., 2021; Sudholz et al., 2022): is een onderzoeksprobleem bij ML dat zich richt op het opslaan van kennis die is opgedaan bij het oplossen van één probleem en het toepassen daarvan op een ander maar gerelateerd probleem. Zo kunnen modellen die getraind zijn op grote datasets (vb. de ImageNet en COCO datasets), worden geherkalibreerd naar een nieuwe dataset die een gelijkaardig probleem wil oplossen.
- Gegevensvergroting (Psiroukis et al., 2021): dit zijn technieken die de hoeveelheid gelabelde data verhogen, door hiervan kopieën te nemen en ze licht aan te passen (vb. door ze te spiegelen, roteren, verschuiven of hun textuur, randen, kleuren, etc. te veranderen).

Deze technieken hebben aangetoond dat de totale hoeveelheid gelabelde data zo kan dalen. Zo was de verhouding van het aantal gelabelde vogels voor (Borowicz et al., 2018) slechts 0,34% van de totale hoeveelheid vogels aanwezig in de kolonie. Ook (Kellenberger et al., 2021) labelde slechts 3.615 vogels (3 soorten) en telde hiermee een kolonie van 21.066 vogels aan een sensitiviteit van 90% (koningsstern), 68% (reuzenstern) en 88% (meeuwsoorten). De totale hoeveelheid label-werk kan dus

sterk verminderd worden door o.a. transfer learning, zonder dat het model te sterk in performantie daalt.

8.4 Flyer Dronedivision





Drone Division introduces Animal Detection

Drone Division provides data-driven insight into detecting and geolocating mowing victims


DRAW - FLY - ANALYSE

Drone Division total solution to detect & geo locate mowing victims

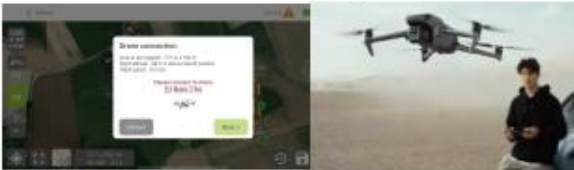
DRAW the area to map

Draw the area to map on your controller and set perfect flight height .



FLY autonomous

Connect controller to drone to upload flightpath.
Press GO and drone will launch take-off, fly and land autonomous.



ANALYSE your data

Upload SD card to Drone Division cloud based platform.
Convolutional neural network will analyse all data.
Detected animals will be geo located at our heatmap.
Extract csv file and import geolocation into your mowers GPS.

Fly & Analyze

10Ha in less than 1 hour

- ⚠️ Plug and play, easy to use small drone
- ⚠️ 1 hour training included.
- ⚠️ Fast analysis.
- ⚠️ Free access to cloud based geo portal.

The benefit of animal detection:

Our proven technology indicates the right geolocation of the mowing victim on a geo map

Why is ROI of detecting mowing victims positive:


- ✅ 90% faster than other detection methods
- ✅ 90% more accurate even for large areas
- ✅ 80% cost reduction on manual efforts
- ✅ Leaves no trailing traces for predators

By detecting mowing victims in no time on a large area we help conservationists to preserve nature.


This technology can lead to **significant life savings** and improve overall reliability and performance for agrobusiness and nature conservation.

Let's get in touch!

Drone Division
www.dronedivision.be
info@dronedivision.be



DRONE DIVISION



IS IT A PLANE GROUP

8.5 Flyer Robor-Nature

Faunadrone



Hardware

- Systeem door 1 persoon te bedienen.
- Compact, alles past in één koffer.
- Alle accu's op te laden in de koffer.
- Handzaam, lichtgewicht.
- Compleet en gebruiksklaar.
- Alles draait op de Mavic 3 accu, dus ook de remote en een ultrabright 2^e scherm hoeven niet afzonderlijk opgeladen te worden.
- Standaard 6 accu's meegeleverd met een totale vliegtijd tot 4 uur.
- Hoog kwaliteit statief, voor eenvoudige bediening van software, drone en camera's in het veld.



Wat zit er in een pakket

- Drone DJI Mavic 3 Thermal.
- Met gestabiliseerde optische camera en high-res thermische camera in één.
- Ultrabright 2^e scherm, maakt optimale bediening software en camera mogelijk.
- One for All Poweradapter (accu-voeding voor remote en scherm).
- Hoog kwaliteit statief.
- Koffer met geïntegreerd oplaadsysteem.
- 32Gb U3 SD-card.

Software

- Speciaal voor deze toepassing ontwikkelde software "Fauna Detect".
- Maakt het zoeken van weidevogelnesten en/of reekalfjes heel efficiënt en eenvoudig.
- Vluchtplan maken binnen enkele seconden.
- Posities van de nesten worden opgeslagen in de Fauna Detect APP.
- 2^e APP "Spot finder" beschikbaar met overzicht van hotspot locaties met foto's, voor loonwerker of boer die het gras maait.
- Koppeling met andere apps zoals Boerenlandvogelmonitor, Google-maps, Telegram, etc.
- Overzicht van het aantal bevolgen hectares en loggen van de vluchten.
- 3 jaar support en recht op updates van de doorontwikkeling.



www.rob-or-nature.eu

nature@rob-or.nl



Opleidingen

Reekalf cursus:

- 1 dagdeel; 4 uur.
- Opleiding vliegen met een drone in praktijk.
- Opleiding reekalf zoeken in praktijk.
- Tips & tricks.

Weidevogel cursus:

- 1 dag; 8 uur.
- Opleiding vliegen met een drone in praktijk.
- Opleiding weidevogel nesten zoeken in praktijk.
- Tips & tricks.

Extra Service/onderhoud voor 2 jaar

- Standaard 2 jaar fabrieksgarantie.*
- Jaarlijkse APK beurt voor de drone en alle componenten.
- Onderhoudsrapportage en accucapaciteit rapportage.
- Bij schade, welke niet binnen 5 werkdagen te herstellen is, een ruil-drone beschikbaar.
- Jaarlijkse terugkom dagen, voor uitleg updates en nieuwe innovaties met betrekking tot hardware en software.
- Technische supportdesk.

Overzicht prijzen

Faunadrone compleet pakketprijs	€9995,-
Cursus Reekalf zoeken (1 dagdeel, tot max 4 personen)	€595,-
Cursus Weidevogels zoeken (1 dag, prijs per persoon)	€595,-
Optioneel: 2 ^e scherm, accu-adapter, statief (meekijken in het veld)	€695,-
Extra service/onderhoud 2 jaar	€1250,-

Prijzen exclusief 21% BTW

*Garantie

Wij bieden 2 jaar fabrieksgarantie op onze producten.

Bovenstaande garanties gelden niet in geval van:

- Onoordeelkundig of oneigenlijk gebruik.
- Onvoldoende onderhoud.
- Het niet naleven van de onderhoudsinstructies van de besturing.
- Ondeskundige montage of reparatie door derden of door de opdrachtgever zelf.
- Het serienummer en/of classificatielabel is verwijderd.
- Water- of val (crash) schade.
- Batterijen/accu's hebben 6 maanden fabrieksgarantie.

Interesse?

Maak dan gerust een afspraak voor een demonstratie in Bentelo!

+31-547-292090
+31-651783232

Robor Electronics B.V.
Suetersweg 6A
7497 MZ Bentelo

www.robor-nature.eu

nature@robor.nl

Tabel 1: Kenmerken van doelsoorten gedetecteerd met beeldverwerkingstechnieken van dronebeelden sinds 2000. Naast de individuele studies (kolom 2) worden ook de review papers vermeld (indien van toepassing) die verwezen naar deze studies (kolom 1). De tabel is gebaseerd uit de paper van Corcoran, Winsen, Sudholz et al. (2021) [8] en aangevuld met de nieuwe zoekcriteria. Indien valse studieorganismen gebruikt zijn (replica) staan deze onderstreept in kolom 4.

Referentie		Informatie over de doelsoort				
Review paper	Studie	Type studie-organisme	Lijst met soorten	Lichaamsgrootte van het studie organisme (kg)	Verspreidingspatroon van de soorten	Lichaamstemperatuur van het studieorganisme (°C)
Linchant et al. (2015) [20]	Israël (2011) [14]	Landzoogdier	Reekalf <i>Capreolus capreolus</i> fawns	Kalf: ~ 1,3 - 1,5 (bij geboorte)	Random	~ 38,8
	Israël & Evers (2011) [15]					
Chabot & Francis (2016) [4]	Abd-Elrahman, Pearlstine & Percival (2005) [1]	Vogel	<u>Niet gespecificeerde witte waadvogels + valse vogels (lokvogels)</u>	N/A	Geaggregeerd	N/A
	Chabot & Bird (2012) [3]		Sneeuwvangans <i>Anser caerulescens</i> en Grote Canadese gans <i>Branta canadensis</i>	1,6 - 3,3 (Sneeuwvangans); 3 - 9 (Grote Canadese gans)	Uniform	N/A
	Grenzdörffer (2013) [9]		Stormmeeuw <i>Larus canus</i>	0,3 - 0,48	Uniform	N/A
	Christiansens et al. (2014) [7]	Vogel + landzoogdier	Kip <i>Gallus gallus domesticus</i> + konijn <i>Oryctolagus cuniculus</i>	1,8 – 4,5 kg (kip) ; 2 - 4 kg (konijn)	Random	Konijn: 38 ; kip: 40,6 - 43
Hyun, Park & Lee (2020) [13]	Lee, Park & Hyun (2019) [19]	Vogel	Klein rietgans <i>Anser branchyrhynchus</i>, bontbekplevier <i>Charadrius hiaticula</i>, kleine lepelaar <i>Platalea minor</i>	1,2 - 1,5 (lepelaar) ; 2,2 - 2,7 (rietgans) ; 0,055 - 0,057 (plevier)	Random - geaggregeerd	39 - 43
Corcoran, Winsen, Sudholz et al. (2021) [8]	Hodgson et al. (2018) [11]	Vogel	<u>Valse vogels (lokvogels)</u> als simulatie voor de grote kuifstern <i>Thalasseus bergii</i>	0,34	Uniform	N/A
	Hong et al. (2019) [12]		Indische vlekbekeend <i>Anas poecilorhyncha</i>, wintertaling <i>Anas crecca</i>, grote zilverreiger <i>Ardea alba</i>, blauwe reiger <i>Ardea cinerea</i> + valse vogels (lokvogels)	0,79 - 1,5	Uniform	N/A
	Liu, Chen & Wen (2015) [21]		Kleine lepelaar <i>Platalea minor</i>	1,2 - 1,5	Uniform	N/A
	Rush et al. (2018) [24]		Kleine mantelmeeuw <i>Larus fuscus</i>	0,77	Uniform	N/A
	Chrétien et al. (2015) [5]	Landzoogdier	Americaanse bison <i>Bison bison</i>, wapiti <i>Cervus canadensis</i>, damhert <i>Dama dama</i>, wolf <i>Canis lupus</i>	30 - 1.000	Geaggregeerd	38,7 - 40
	Chrétien et al. (2016) [6]		Witstaarthert <i>O. virginianus</i>	40 - 136	Geaggregeerd	38,6
	Oishi et al. (2018) [22]		Sikahert <i>Cervus nippon</i>	66 - 154	Geaggregeerd	37,5
Wirsing, Johnston & Kiszka (2022) [26]	Sudholz et al. (2022) [25]	Landzoogdier	Javaans hert <i>Rusa timorensis</i>	74 - 160	Random - geaggregeerd	37,5 - 39,5
/	Israël & Reinhard (2017) [17]	Vogel	Kievit (nesten/eieren) <i>Vanellus vanellus</i>	N/A (de volwassen vogels zijn niet het doel). De nesten bevatten vaak 4 eieren. 1 ei is gemiddeld 47 x 33 mm groot. Een ideaal cirkelvormig nest is ongeveer 9 cm in diameter.	Random	De eieren hadden ± een stralingstemperatuurverschil van 10 °C met de omgeving (vlieghoogte 30 m).
	Borowicz et al. (2018) [2]	Vogel	Adeliepinguïn <i>Pygoscelis adeliae</i> (op nesten)	3,2 - 5,8	Uniform - geaggregeerd - random	N/A
	Kellenberger et al. (2021) [18]	Vogel	Koningsstern <i>Thalasseus maximus</i>, Reuzenstern <i>Hydroprogne caspia</i> en meeuwsoorten (grijskopmeeuw <i>Chroicocephalus cirocephalus</i> en dunbekmeeuw <i>Chroicocephalus genei</i>)	0,35 - 0,45 (koningsstern) ; 0,53 - 0,78 (reuzenstern)	Uniform - geaggregeerd	N/A
	Psiroukis et al. (2021) [23]	Landzoogdier	Konijn <i>Oryctolagus cuniculus</i>	2 - 4 kg	Random	38
	Hinke et al. (2022) [10]	Vogel	Pinguïns <i>Pygoscelis</i> spp. (<i>P. antarcticus</i> en <i>P. papua</i>) + Kerguelenzeebeer <i>Arctocephalus gazella</i> (pups en adulten)	3,2 - 5,7 (Pinguïns)	Geaggregeerd	36,9 - 39

Tabel 2: Vlieg- en sensorspecificaties, milieu- en weersomstandigheden van dronemissies voor studies die beeldverwerkingstechnieken gebruiken om doelsoorten te detecteren sinds 2000. Naast de individuele studies (kolom 2) worden ook de review papers vermeld (indien van toepassing) die verwezen naar deze studies (kolom 1). De tabel is gebaseerd uit de paper van Corcoran, Winsen, Sudholz et al. (2021) [8] en aangevuld met de nieuwe zoekcriteria. Indien studies meerdere sensoren gebruikte zijn de rood aangeduide sensortype de voornaamste data-input van die studie indien van toepassing.

Referentie		Vlucht- en sensorspecificaties + omgevingsomstandigheden									
Review paper	Studie	Platform type	Sensor type	Vluchthoogte boven de grond (m)	Vluchtsnelheid (km/u)	Grond resolutie (cm/pixel)	Omgevingstemperatuur tijdens de vlucht (°C)	Windsnelheid (km/u)	Weerscondities	Habitat	Bedekkingsgraad vegetatie
Linchant et al. (2015) [20]	Israël (2011) [14]	Multirotor	TIR video	30-50	Niet vermeld	≤ 15	Niet vermeld	Niet vermeld	Verschillende weers- en belichtingscondities werden uitgetest.	Landbouwgrond en graslanden	Dicht omdat de kalveren in hoog gras liggen.
	Israël & Evers (2011) [15]										
Chabot & Francis (2016) [4]	Abd-Elrahman, Pearlstine & Percival (2005) [1]	Fixed-wing	RGB video	Niet vermeld	64	N/A	N/A	Niet vermeld	Niet vermeld	Velden / kanalen	Laag
	Chabot & Bird (2012) [3]	Fixed-wing	RGB	183	60	4,5	N/A	≤ 30	Niet vermeld (wel geen regen)	Grasland	Laag
	Grenzdörffer (2013) [9]	Multirotor	RGB video	50-55	18	~1,6	N/A	Bijna windstil (2e vlucht)	Goed (2e vlucht)	Grasland en rietland	Laag - gemiddeld
	Christiansens et al. (2014) [7]	Beelden handmatig vastgelegd vanaf een hef-arm (simulatie laagvliegende UAS).	TIR video	3-35	N/A	Niet vermeld	15 - 19°C en 16 - 23°C	N/A	Niet vermeld	Landbouwgrond (geen volledig natuurlijke omgeving)	Gemiddeld (grasvegetatie is hoog t.o.v. de dieren)
Hyun, Park & Lee (2020) [13]	Lee, Park & Hyun (2019) [19]	Multirotor	RGB + TIR	110 (ganzen + lepelaars); 20 (plevieren)	5	RGB: 4,19 ; TIR: 20,37 (gans + lepelaar) ; RGB: 0,95 ; TIR: 3,68 (plevier)	7,8 - 8°C (Groenland) ; 17°C (de Republiek Korea)	Niet vermeld (maar geen sterke wind).	Goed	Zee-ijs ; rotsen met beperkte hoeveelheid vegetatie ; wadden (getijdengebieden)	Geen - laag
Corcoran, Winsen, Sudholz et al. (2021) [8]	Hodgson et al. (2018) [11]	Multirotor	RGB	30, 60, 90 en 120	N/A (Ter plaatsen blijven vliegen terwijl de beelden worden genomen)	0,82, 1,64, 2,47 en 3,29	N/A	9 - 37	Goed (de bewolking varieerde van 15% tot 75%, zichtbaarheid > 500 m).	Stranden	Geen
	Hong et al. (2019) [12]	Multirotor	RGB	100 (wilde vogels) - 50 (valse vogels)	Niet vermeld	1,04 – 1,48: de grootte van een label box voor 1 vogel = 40 x 40 pixels.	N/A	Niet vermeld	Goed	Rivieren, stranden, reservoirs, landbouwgrond	Geen - laag

Tabel 2 (vervolg)

Referentie		Vlucht- en sensorspecificaties + omgevingsomstandigheden									
Review paper	Studie	Platform type	Sensor type	Vluchthoogte boven de grond (m)	Vluchtsnelheid (km/u)	Grond resolutie (cm/pixel)	Omgevingstemperatuur tijdens de vlucht (°C)	Windsnelheid (km/u)	Weerscondities	Habitat	Bedekkingsgraad vegetatie
Corcoran, Winsen, Sudholz et al. (2021) [8]	Liu, Chen & Wen (2015) [21]	Fixed-wing	RGB	200-300 (data validatie op 50)	Niet vermeld	~1,3 (op 50 m), 6,3 (op 200 m), 9,5 (op 300m)	N/A	Niet vermeld	Goed	Kustgebied (stranden en lagune)	Geen
	Rush et al. (2018) [24]	Multirotor	RGB	15	10,8 -14,4	1, ook herschaald tot 2 en 4 cm/pixel	N/A	< 24	Niet vermeld	Kliffoppen	Geen
	Chrétien et al. (2015) [5]	Multirotor	RGB + TIR	60	18-35	0,8 (RGB) en 5,4 (TIR)	Niet vermeld	19	Goed	Dierenverblijven (geen natuurlijke leefomgeving)	Laag
	Chrétien et al. (2016) [6]	Multirotor	RGB + TIR	60	22	0,8 (RGB) en 5,4 (TIR)	Niet vermeld	Niet vermeld	Niet vermeld	Dierenverblijven (geen natuurlijke leefomgeving)	Laag
	Oishi et al. (2018) [22]	Multirotor	TIR	30	Niet vermeld	5	Niet vermeld	Niet vermeld	Goed	Grasland	Gemiddeld
Wirsing, Jonhnston & Kiszka (2022) [26]	Sudholz et al. (2022) [25]	Multirotor	RGB + TIR video	50-70	Niet vermeld	Niet vermeld	6,7 – 18,5°C	Niet vermeld	2 dagen met ongunstige weersomstandigheden.	Mozaïek van dichte vegetatie, gegroepeerde vegetatie en schaarse vegetatie.	Variëren van laag tot hoog.
/	Israël & Reinhard (2017) [17]	Multirotor	RGB + TIR video	35,5 - 40 (range tussen 20 en 80m)	Max: 19,8 maar door de vele tussenstops eerder 7,56	3,18 (TIR)	Tussen 11 en 27 °C.	Niet vermeld	Variërend van zonnig tot geheel bewolkt. Van 10:26 tot 20:13 (zonsondergang).	Landbouwgrond	Geen
	Borowicz et al. (2018) [2]	Multirotor	RGB	25-45	Niet vermeld	Niet vermeld	N/A	Niet vermeld	Niet vermeld	De achtergrond bestaat uit sneeuw, ijs, water, rotsen, verlaten nesten, keien, guano, mos en grassen.	Geen – laag
	Kellenberger et al. (2021) [18]	Multirotor	RGB	20-50	10,8 - 18	0,92 – 1,20	N/A	≤ 36	Niet vermeld	Stranden	Laag
	Psiroukis et al. (2021) [23]	Multirotor	TIR	25	N/A (ter plaatsen blijven vliegen voor 3 seconde bij elke routepunt).	Niet vermeld	~ 0 (winter) en 8 - 12 (zomer)	Niet vermeld	Goed	Veld A: een verlaten veld bedekt met middelhoge kruidachtige vegetatie en Veld B: een wijngaard van het lokale type met lage wijnstokken in rijen.	Laag - gemiddeld
	Hinke et al. (2022) [10]	Multirotor	RGB + TIR	30-90	Niet vermeld	Niet vermeld	Niet vermeld	Niet vermeld	Niet vermeld (maar er was beeldonscherpte en de auteurs geloven dat dit komt door de wind).	De achtergrond bestaat uit sneeuw, ijs, water, rotsen, verlaten nesten, keien, guano, mos en grassen.	Geen - laag

Tabel 3: Informatie over de beeldanalyse voor studies die beeldverwerkingstechnieken gebruiken om doelsoorten te detecteren sinds 2000. Naast de individuele studies (kolom 2) worden ook de review papers vermeld (indien van toepassing) die verwezen naar deze studies (kolom 1). De tabel is gebaseerd uit de paper van Corcoran, Winsen, Sudholz et al. (2021) [8] en aangevuld met de nieuwe zoekcriteria.

Referentie		Beeldanalyse							
Review paper	Studie	Beeldverwerkings-techniek(en)	Type van beeldwerkings-techniek	Waarschijnlijkheid van detectie (%)	Level van automatisatie, verwerkingsstappen, voor- en nadelen?	Type van learning?	Object- / pixel-based	Opmerkingen	Gebruikte software
Linchant et al. (2015) [20]	Israël (2011) [14]	Automatische versterkingsregeling om een hoger contrast te krijgen. De auteurs paste de standard FLIR instellingen aan en gebruikte hierbij lineaire histogram egalisatie.	Beeld-optimalisatie + filteren	Niet vermeld	Het proces is niet geautomatiseerd <ul style="list-style-type: none"> ➢ enkel beeld-optimalisatie technieken ➢ manuele classificatie Preprocessing: Directe georeferentie van de beelden dankzij de GPS aan boord van de Falcon-8. Stop-and-go modus op de routepunten. Een patroonherkenningsalgoritme verwerkt de beelden aan boord van de UAV (in plaats van het grondstation).	Geen machine learning	N/A	De maximale hoekafwijking van alfa tussen de kijkrichting (camera) en het nadir is ca. 17° om in een weiland met een gemiddelde grashoogte h van 1 m door visuele occlusie een reekalf van 30 cm te detecteren.	Niet vermeld
	Israël & Evers (2011) [15]	Beeldoptimalisatie (zie rij hierboven) + eigenschap extractie: 'fast compression distance' + k-Nearest neighbor (kNN) classificatie	Beeld-optimalisatie + kenmerkextractie + machine learning	88,4 – 99,1%	Automatische classificatie Preprocessing: (zie rij hierboven)	Supervised - classificatie	Object-based	De kenmerken zijn afgeleid van een referentie dataset, gegenereerd door een compressie-algoritme. Deze kenmerken zijn schaal invariant maar niet rotatie invariant + het gebruik van absolute temperatuur metingen (ongeldig wanneer de dieren worden verwarmd door de zon) [7].	Niet vermeld
Chabot & Francis (2016) [4]	Abd-Elrahman, Pearlstine & Percival (2005) [1]	Template matching gebaseerd op spectrale / grootte eigenschappen	Eenvoudige spectrale drempelwaarden/template matching	Valse vogels: 86,5 % (gemiddeld) - 7,2% (standaarddeviatie). Wilde vogels: 89,6 % (gemiddeld) - 8,7% (standaarddeviatie).	Vereist nog steeds handmatige instelling van drempelwaarden (genormaliseerde kruiscorrelatie). Nadeel: Beperkt aantal beelden van specifieke soorten in een bepaalde omgeving.	Geen machine learning	Object-based	/	Intel Open Source Computer Vision Library ; G++ Graphical User Interface (GUI) ; Dazzle image capture software.
	Chabot & Bird (2012) [3]	Spectrale drempelwaarden, object analyse en classificatie (voor sneeuwganzen)	Eenvoudige spectrale drempelwaarden/template matching	99,07%	Proces is semi-automatisch voor sneeuwganzen detectie. Manuele tellingen aan de hand van UAV beelden voor Grote Canadese gans. Preprocessing: Beelden moeten gehecht, georeferereerd en geometrisch gecorrigeerd worden. Nadeel: Relatief kleine dataset.	Geen machine learning	Object-based	Ganzen vluchtten, voegden zich bij de groep of verlieten het tijdens het onderzoek.	Adobe Photoshop ; Extended CS4

Tabel 3 (vervolg)

Referentie		Beeldanalyse							
Review paper	Studie	Beeldverwerkings-techniek(en)	Type van beeldwerkings-techniek	Waarschijnlijkheid van detectie (%)	Level van automatisatie, verwerkingsstappen, voor- en nadelen?	Type van learning?	Object- / pixel-based	Opmerkingen	Gebruikte software
Chabot & Francis (2016) [4]	Grenzdörffer (2013) [9]	Maximum likelihood classificatie + filteren (zand pixels, fusie van nabijgelegen pixels + een drempelwaarde voor grootte).	Machine learning + postprocessing	90,75% (1ste vlucht) en 94,75% (2e vlucht).	<p>Preprocessing: Beelden moeten gehecht, georeferereerd en geometrisch gecorrigeerd worden.</p> <p>Postprocessing: Vereist extra grootte/nabijheidfiltering. Eerste vlucht: er was veel onscherpte in de orthofotomosaïek door het aaneenhechten van de beelden zonder goede GCP's + de groothoeklens van de Sony NEX5.</p> <p>Nadeel: relatief kleine dataset.</p>	Supervised - classificatie	Pixel-based (classificatie) + object-based (finaal object bepaling)	Stellen een protocol voor om "nestparen" te tellen door de vlucht uit te voeren op het juiste moment (een van de ouders is op jacht), met een goede zonnestand en door schaduwen te detecteren tussen "nestelende meeuwen" (= een broedpaar = een legsel) en "staande meeuwen". Werkt beter in duin gebieden dan in grasgebieden (vegetatie zorgt voor schaduw).	ArcGIS ; Eerste vlucht: Autopano Giga 2.5 (commerciële software voor aerotriangulatie (het was niet mogelijk om GCP te leveren + de GPS nauwkeurigheid op de drone zelf was te laag voor de meeste open source software) voor georeferencing en stitching + handmatige correctie). Imagelron voor correctie van radiale vervorming. Tweede vlucht: fotogrammetrische gegevensanalyse met Pix4D (enkele gesignaleerde controlepunten werden gemeten met een RTK GPS aan een rand van het eiland.
	Christiansens et al. (2014) [7]	<p>Detectie: Drempelwaarden voor detectie zijn dynamisch/automatisch bepaald voor elke frame</p> <p>Eigenschap extractie: temperatuur profielen (discrete cosinus transformatie, DCT) + kNN classificatie + temporele video analyse (Bayesian updating).</p>	Dynamische drempelwaarden + machine learning + Bayesian updating	<p><u>Lage altitude (3 - 10m)</u> zonder tracking algoritme: 83,4% ; met tracking algoritme: 96,2%</p> <p><u>Hoge altitude (10 - 20m)</u> zonder tracking algoritme: 63,0% ; met tracking algoritme: 63,4%</p>	<p>Voordeel: De eigenschap extractie techniek is invariant voor rotatie, schaling en gedeeltelijk, houding. Dynamisch drempelwaarden bepaling, temporele video analyse en tracking algoritme maken de voorspelling meer robuust.</p> <p>Nadeel: De procedure wordt ongeschikt voor hoogten boven 20-22m. Kleine dataset. Geen overlappende beelden >< typische UAV beelden. Trainings- en testset waren gecorreleerd. <u>Niet getest op een echte UAV.</u></p>	Supervised - classificatie	Object-based	De toepasbaarheid van de gebruikte methoden moet worden geëvalueerd aan de hand van beeldmateriaal afkomstig van een echte UAV in beweging om de effecten van wind, bewegingen van de UAV en (eventueel) bewegende dieren mee te nemen en om de variatie van de dataset gemakkelijker uit te breiden. Er moeten meer experimenten worden uitgevoerd, met verschillende weersomstandigheden, vegetatie, dieren en meer niet-dierlijke kandidaten om de variatie van de beperkte dataset uit te breiden.	Niet vermeld

Tabel 3 (vervolg)

Referentie		Beeldanalyse							
Review paper	Studie	Beeldverwerkings-techniek(en)	Type van beeldwerkings-techniek	Waarschijnlijkheid van detectie (%)	Level van automatisatie, verwerkingsstappen, voor- en nadelen?	Type van learning?	Object- / pixel-based	Opmerkingen	Gebruikte software
Hyun, Park & Lee (2020) [13]	Lee, Park & Hyun (2019) [19]	Eigenschap extractie: contour temperatuur profielen + drempelwaarden (ganzen en lepelaars). Geen eigenschap extractie voor plevieren.	Eigenschap extractie technieken en eenvoudige spectrale drempelwaarden.	Onzeker (kan gebiased zijn): 100% (zeer kleine dataset)	Preprocessing: Beelden moeten gehecht, georeferend en geometrisch gecorrigeerd worden. Enkel relevante beelden met de beste kwaliteit werden geselecteerd voor analyse. Nadeel: Relatief kleine dataset. RGB beelden werden manueel getrokken door de piloot via zijn remote controller. Voordeel: Thermale beelden werden wel automatisch getrokken (elke seconde). Detectie gebeurde automatisch, maar de dieren werden wel manueel geteld . De procedure werd enkel per soort getest en is niet noodzakelijk soort-specifiek .	Geen machine learning	Object-based	De verschillende strategieën voor het nemen van beelden en het selecteren van onscherpe warmtebeelden veroorzaakten verschillen in beeldtijd, zodat de ganzen een andere opstelling hadden na het kleine tijdsverschil tussen het RGB-beeld en het warmtebeeld. Een optimale timing met inachtneming van de thermische inertie is van cruciaal belang. Een hoog oppervlaktetemperatuurcontrast tussen de dieren en het omringende materiaal is van cruciaal belang.	PhotoScan Pro Software (Agisoft LLC) + ArcGIS 10.3 + FLIR Tools software (FLIR Systems Inc.)
Corcoran, Winsen, Sudholz et al. (2021) [8]	Hodgson et al. (2018) [11]	Eigenschap extractie: Invariante Fourier histogrammen van georiënteerde gradiënten + lineaire Support vector machine (2 klassen) voor classificatie + drempelwaarden predicties (50%).	Machine learning	92 - 98	Nadeel: Beperkte beelden van specifieke soorten in een bepaalde omgeving. Relatief kleine dataset. Enkel binaire classificatie. Voordeel: Enkel 10% van de dataset was nodig voor training van het model. Preprocessing: Het model is getraind op bounding boxes die geen vogels of vogels bevatten. Postprocessing: Een special gecodeerde energie functie filtert overbodige voorspellingen van het model.	Supervised - classificatie	Pixel-based (classificatie) + object-based (finaal object bepaling)	Opmerkingen review paper [8]: "Soorten die in RGB werden onderzocht, waren meestal wit, zwart of donkerbruin van kleur tegen een groene, grijze of lichtbruine achtergrond, waardoor een hoog contrast ontstond en de kans kleiner werd dat dieren werden gemist of habitatkenmerken verkeerd werden geïdentificeerd als dieren". "Bij multirotor ontwerpen met een grotere beeldoverlap werden dubbele waarnemingen van dezelfde individuen aangemerkt als de grootste uitdaging om tot nauwkeurige tellingen van soorten te komen".	Matlab + R

Tabel 3 (vervolg)

Referentie		Beeldanalyse							
Review paper	Studie	Beeldverwerkings-techniek(en)	Type van beeldwerkings-techniek	Waarschijnlijkheid van detectie (%)	Level van automatisatie, verwerkingsstappen, voor- en nadelen?	Type van learning?	Object- / pixel-based	Opmerkingen	Gebruikte software
Corcoran, Winsen, Sudholz et al. (2021) [8]	Hong et al. (2019) [12]	<p>CNNs:</p> <ul style="list-style-type: none"> • <u>2 stadia object detectie</u> <ul style="list-style-type: none"> o Region-based Fully Convolutional Network (R-FCN) o Faster Region-based Convolutional Neural Network (Faster R-CNN) • <u>1 stadium object detectie</u> <ul style="list-style-type: none"> o Single Shot MultiBox Detector (SSD) o Retinanet o You Only Look Once (YOLO) 	Deep learning	100	<p>Preprocessing:</p> <ul style="list-style-type: none"> • Individuele beelden: geen hechting beelden. • Beeld bijsnijden + gegevensvergroting (Engels: data augmentation). <p>Toepassing van het model: Als beelden worden aaneengehecht kunnen dieren kunnen dubbel gedetecteerd door overlapping van de beelden. Dit kan worden deels opgelost worden door directe geo-referentie (vereist een GNSS-RTK op de drone) zonder aaneenhechten van de beelden. Hierdoor wordt de verwerkingstijd aanzienlijk verkort.</p>	Supervised - classificatie	Object-based	Faster R-CNN: meest accurate model. YOLO: snelste model.	Niet vermeld
	Liu, Chen & Wen (2015) [21]	<ul style="list-style-type: none"> • k-means clustering • k-means clustering + HOM transform (template matching/filtering) • k-means clustering + BLOB analysis (template matching/filtering) 	Machine learning + postprocessing	43-99	<p>Preprocessing: Beelden moeten gehecht, georeferereerd en geometrisch gecorrigeerd worden. Postprocessing: filter- en template matching technieken (vb. om zon glitters op het water weg te filteren) om resultaat te verbeteren. Nadelen: De clustering is niet soortspecifiek (gelijkaardige soorten waren aanwezig in de dataset en werden foutief gedecteerd door het algoritme (<i>Ardea alba</i> en <i>Mesophoyx intermedia</i>), tenzij je de postprocessing toepast. Relatief kleine dataset met weinig soorten en weinig variërend habitat.</p>	Unsupervised – clustering	Pixel-based (clustering) + object-based (finaal object bepaling)	/	Google Earth, ENVI®, Kolor Autopano® (stitching) or Agisoft Photoscan® (stitching)

Tabel 3 (vervolg)

Referentie		Beeldanalyse							
Review paper	Studie	Beeldverwerkings-techniek(en)	Type van beeldwerkings-techniek	Waarschijnlijkheid van detectie (%)	Level van automatisatie, verwerkingsstappen, voor- en nadelen?	Type van learning?	Object- / pixel-based	Opmerkingen	Gebruikte software
Corcoran, Winsen, Sudholz et al. (2021) [8]	Rush et al. (2018) [24]	Maximum likelihood classificatie + buffering/spatiale filtering technieken	Machine learning + postprocessing	76-98	Preprocessing: De beelden moeten gehecht (170 GCP), ge-georeferend (ondanks dat de UAV had een intern GPS-systeem bevat) en geometrische gecorrigeerd worden. Postprocessing: buffering of filtering o.b.v. afstand/oppervlakte polygonen. Nadelen: Verschillen in vluchtomstandigheden (verenkled, licht, schaduwen) maken het trainen van algemene modellen moeilijk.	Supervised - classificatie + template matching/manuele correcties	Pixel-based (classificatie) + object-based (finaal object bepaling)	De auteurs wilde het model testen voor verschillende soorten meeuwen (vergelijking met <i>L. argentatus</i> en <i>L. marinus</i>). Er werden spectrale verschillen opgemerkt, maar geen beoordeling van de nauwkeurigheid wegens gebrek aan gegevens.	Agisoft PhotoScan v1.2.4 (stitching), ArcGIS, IBM SPSS Statistics (statistical analysis)
	Chrétien et al. (2015) [5]	MOBIA (multicriteria object-based image analysis)	Object-based image analysis	50-100	Preprocessing. Beelden moeten gehecht (22 GCP's), georeferend en geometrisch gecorrigeerd worden + data fusie. Nadeel: Kleine dataset. Het trainen voor de segmentatie kan tijdsintensief zijn. Voordeel: 1 model kan meerdere dieren classificeren.	Segmentatie + supervised - classificatie	Object-based	/	eCognition Developer 8.7 (MOBIA)
	Chrétien et al. (2016) [6]	<ul style="list-style-type: none"> • OBIA (object-based image analysis) • Maximum likelihood classificatie • K-means clustering 	Object-based image analysis ; machine learning	32-53	Preprocessing. Beelden moeten gehecht (22 GCP's), georeferend en geometrisch gecorrigeerd worden + data fusie. Nadeel: Zeer kleine dataset. Het trainen voor de segmentatie kan tijdsintensief zijn. Postprocessing: Tellingen (de validatie) vereist nog een filter (low-pass filter) voor supervised en unsupervised pixel classificatie	<ul style="list-style-type: none"> • Segmentatie + supervised - classificatie (OBIA) • Supervised – classificatie (Maximum likelihood) • Unsupervised – clustering (K-means clustering) 	<ul style="list-style-type: none"> • Object-based (OBIA) • Pixel-based (clustering en classificatie) + object-based (finaal object bepaling) 	OBIA slaagde beter in de classificatie dan de supervised - en unsupervised beeld classificatie.	eCognition Developer 8.7 (OBIA)
	Oishi et al. (2018) [22]	Detection moving wild animals (DWA) algorithm	Eenvoudige spectrale drempelbenaderingen/template-matching	77.3	Preprocessing: Beelden moeten gehecht, georeferend en geometrisch gecorrigeerd worden. Nadeel: om dieren te detecteren, moeten ze bewegen. De opname-intervallen veroorzaken een thermische kloof tussen twee beelden door stralingskoeling.	Geen machine learning	Object-based	De snelheid van het dier en de sluitertijd van de camera bepalen of het dier al dan niet gedetecteerd worden (vb. Als de opname-intervallen te lang zijn, kunnen doelen zich buiten het overlappingsgebied tussen twee beelden verplaatsen. Als de schietintervallen daarentegen te kort zijn, kunnen doelen niet worden geëxtraheerd omdat de bewegingsafstand in een bepaald interval langer moet zijn dan de lichaamslengte).	Niet vermeld

Tabel 3 (vervolg)

Referentie		Beeldanalyse							
Review paper	Studie	Beeldverwerkings-techniek(en)	Type van beeldwerkings-techniek	Waarschijnlijkheid van detectie (%)	Level van automatisatie, verwerkingsstappen, voor- en nadelen?	Type van learning?	Object- / pixel-based	Opmerkingen	Gebruikte software
Wirsing, Jonhnston & Kiszka (2022) [26]	Sudholz et al. (2022) [25]	CNN ensemble + transfer learning: <ul style="list-style-type: none"> • 2 stadia object detectie <ul style="list-style-type: none"> o Faster Region-based Convolutional Neural Network (Faster-RCNN) • 1 stadium object detectie <ul style="list-style-type: none"> o You Only Look Once (YOLO) 	Deep learning	66,7 - 100% (89,5% wanneer alleen gegevens van vluchten met gunstige weersomstandigheden worden gebruikt).	Nadeel: Binaire classificatie. Preprocessing: Niet duidelijk of de videobeelden direct gegeoreferereerd zijn.	Supervised - classificatie	Object-based	Er is aangetoond dat lage bewolking tussen de sensor en het doelobject de thermische sensoren aanzienlijk belemmert. Vocht in de lucht absorbeert infraroodstraling, wat resulteert in een verminderd contrast tussen de achtergrond en de doelsoort en andere prominente objecten in de afbeelding.	Matlab (version R2018a) + DJI (flight planning) + free video-editing software VSDC (ver. 6.4.2.108, Flash Integro)
/	Israël & Reinhard (2017) [17]	Microbolometer Optimizatie (MbOpt) algoritme	Beeldversterking: beeldcorrectie (o.b.v. een opzoektabel) + filtering + bit diepte compressie	93	Nadelen: Het proces is niet geautomatiseerd (manuele telling). De beelden worden direct gegeoreferereerd (onzekerheid ~ 5m). De camera moet worden pre-processed (gekalibreerd) met behulp van opzoektabelen van dode pixels + low pass filtering. Er gebeurt geen segmentatie of classificatie.	Geen machine learning	N/A	Het artikel richt zich op het opsporen van kievitseieren niet de lokalisatie van de eieren (georeferentie). Er werd geen "mobben" (behalve enkele roepen) waargenomen door de ouders. Adulten vliegen weg als de drone ≤ 40m verwijderd is. Elk geïdealiseerde nest varieert van 4 zuivere pixels (+ 8 gemengde pixels) tot 1 zuivere pixel (+ 8 gemengde pixels).	uavRC flight planning software [16].
	Borowicz et al. (2018) [2]	CNN: Deep Neural Network (DetectNet) van de open source software NVIDIA DIGITS. Detectnet is gebaseerd op het GoogLeNet kader voor beeldclassificatie.	Deep learning + spatiale filtering (aantal nabijgelegen burenen) + locatie-specifieke eenvoudige lineaire regressie voor telling	Niet beschikbaar. De automatische tellingen hebben een accuraatheid van +- 10%. Maar voor het gemiddelde verschil tussen de geautomatiseerde nesttellingen van UAV en tellingen op de grond in situ van hetzelfde deel van de kolonie was 0,6%.	Preprocessing: aaneenhechten beelden en georferencing. Beelden moeten worden bijgesneden tot kleinere tegels voordat ze kunnen worden ingevoerd in het CNN-model. Voordeel: de hoeveelheid nodige gelabelde data is relatief weinig door transfer learning . Postprocessing: het aantal fout-positieven verminderen door een ruimtelijk filter toe te passen.	Supervised - classificatie	Object-based		Mission planning software Map Pilot App + Photoscan (Agisoft LLC) + NVIDIA DIGITS (NVIDIA Corporation)
	Kellenberger et al. (2021) [18]	CNN: deep CNN (gemodificeerd ResNet-18 architectuur). Sommige lagen waren reeds voorgetraind op ImageNet (warmstarten van het model: Transfer Learning).	Filtering/maskeren: heuristische modellering (convex hull/Euclidische afstand) in trainingsfase + deep learning + post-processing (klasse-specifieke niet-maximum onderdrukking + Markov random field).	90% (Koningsstern), 68% (Reuzenstern) en 88% (meeuwsoorten)	Preprocessing. De beelden moeten worden gehecht (niet in het testbeeld), georeferereerd en bijgesneden tot kleinere tegels. Voor de achtergrond is gebruik gemaakt van ' curriculum ' leren (eerst het model voeden met 'gemakkelijke' achtergrond-patches en later de 'moeilijke' achtergrondpatches). Dit zorgde ervoor dat het model de detectie van vogels kan leren voordat het overweldigd wordt door de grote complexe achtergrondpolygonen.	Supervised - classificatie	Object-based	Door voorafgaande kennis (heuristische modellering) van de ruimtelijke verdeling van de vogelkolonies waren slechts ~200 vogelannotaties per klasse nodig. Ook de afstemming (Engels: 'tuning') van de gewichten wordt bepaald door middel van voorafgaande ecologische kennis.	Agisoft Metashape, QGIS, AIDE, PyTorch

Tabel 3 (vervolg)

Referentie		Beeldanalyse							
Review paper	Studie	Beeldverwerkings-techniek(en)	Type van beeldwerkings-techniek	Waarschijnlijkheid van detectie (%)	Level van automatisatie, verwerkingsstappen, voor- en nadelen?	Type van learning?	Object- / pixel-based	Opmerkingen	Gebruikte software
/	Psiroukis et al. (2021) [23]	CNN: • <u>1 stadium object detectie</u> o You Only Look Once (YOLO): YOLOv5x CNN model met een YOLOv5 architectuur (Ultralytics archief)	Deep learning	83% - 95% - 63%	Preprocessing: Om dubbeltellingen te voorkomen werd er in beide datasets gewerkt met minimale overlap tussen twee opeenvolgende beelden. De beelden moeten worden bijgesneden voordat ze kunnen dienen als invoergegevens voor het model. Tijdens de trainingsfase werden gegevensuitbreidingen (Engels: 'data augmentation') toegepast om de generalisatie van het netwerk te verbeteren. Bij het labelen werd telkens een reeks beelden gebruikt. <u>Als een object kandidaat (potentieel konijn) stil bleef staan in meer dan 2 frames, dan werd dit object niet beschouwd als konijn en dus niet geannoteerd.</u>	Deep learning	Object-based	Men bepaalde een optimale vlieghoogte van 25 m boven de grond (trade-off tussen spatiale resolutie en verstoring). Elke vlucht werd uitgevoerd met een "hover and capture" missie, waarbij de UAV in totaal 3s boven elk routepunt zweefde, 1 thermische opname/seconde (om ervoor te zorgen dat ten minste één frame vrij was van bewegingsonscherpte). Thermische beeldvorming vormt t.o.v. RGB een grotere uitdaging vanwege de overmatige ruis in de gegevens. Bovendien maken de kleine verschillen in temperatuur tussen de doelen en hun omgeving, alsmede de temporele variatie in de dagelijkse temperatuur die vaak temperatuurschommelingen veroorzaakt, de doelen nauwelijks van de achtergrond te onderscheiden.	Python + Pytorch deep-learning library + Ultralytics repository + Lablmg
	Hinke et al. (2022) [10]	CNN: • <u>1 stadium object detectie</u> 7 onafhankelijke classificatiemodellen gebaseerd op het YOLOv3 CNN-model. Een gevoeligheidsanalyse (Engels: 'sensitivity analysis') suggereert een betrouwbaarheids grens van 0,2 drempelwaarde en een overlappingsdrempelwaarde van 0,5 voor zowel voorspelling als waarheids-overlapping.	Deep learning	85 - 96% (pinguïns).	De auteurs ontvingen real-time vluchtinformatie en videogegevens tijdens het onderzoek. Nadeel: Relatief kleine dataset. Het is niet duidelijk of het model werd voorgetraind (transfer learning) (gehint in de discussie). Er wordt geen informatie gegeven over de preprocessing stappen .	Supervised - classificatie	Object-based	Het toevoegen van thermisch infrarood gegevens leverde geen significant betere resultaten op voor de detectie/classificatie van pinguïns (en pelsrobber). Ook het toevoegen van annotaties van niet-doelkenmerken leverde geen duidelijk voordeel op voor de detectie en correcte classificatie van doelklassen die in het model werden getraind.	Video and Image Analytics for Marine Environments (VLAIME) software + R (vvipr + skiny package)

Referenties

Beeldanalyse technieken om fauna te detecteren

1. Abd-Elraham, A., Pearlstine, L., & Percival, F. (2005). Development of Pattern Recognition Algorithm for Automatic Bird Detection from Unmanned Aerial Vehicle Imagery - ProQuest. *Surveying and Land Information Science*, 65(1), 37–45.
<https://www.proquest.com/openview/f55c12aa3e1010dc2176f4ad51a3e9db/1?pq-origsite=gscholar&cbl=27246>
2. Borowicz, A., McDowall, P., Youngflesh, C., Sayre-Mccord, T., Clucas, G., Herman, R., Forrest, S., Rider, M., Schwaller, M., Hart, T., Jenouvrier, S., Polito, M. J., Singh, H., & Lynch, H. J. (2018). Multi-modal survey of Adélie penguin mega-colonies reveals the Danger Islands as a seabird hotspot. *Scientific Reports*, 8(1). <https://doi.org/10.1038/s41598-018-22313-w>
3. Chabot, D., & Bird, D. M. (2012). Evaluation of an Off-the-shelf Unmanned Aircraft System for Surveying Flocks of Geese. *Waterbirds: The International Journal of Waterbird Biology*, 35(1), 170–174. <https://www.jstor.org/stable/41432487>
4. Chabot, D., & Francis, C. M. (2016). Computer-automated Bird detection and counts in high-resolution aerial images: a review. *Journal of Field Ornithology*, 87(4), 343–359.
<https://doi.org/10.1111/JOFO.12171>
5. Chrétien, L. P., Théau, J., & Ménard, P. (2015). WILDLIFE MULTISPECIES REMOTE SENSING USING VISIBLE AND THERMAL INFRARED IMAGERY ACQUIRED FROM AN UNMANNED AERIAL VEHICLE (UAV). *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-1-W4(1W4), 241–248.
<https://doi.org/10.5194/ISPRSARCHIVES-XL-1-W4-241-2015>
6. Chrétien, L. P., Théau, J., & Ménard, P. (2016). Visible and thermal infrared remote sensing for the detection of white-tailed deer using an unmanned aerial system. *Wildlife Society Bulletin*, 40(1), 181–191. <https://doi.org/10.1002/WSB.629>
7. Christiansen, P., Steen, K. A., Jørgensen, R. N., & Karstoft, H. (2014). Automated Detection and Recognition of Wildlife Using Thermal Cameras. *Sensors 2014, Vol. 14, Pages 13778-13793*, 14(8), 13778–13793. <https://doi.org/10.3390/S140813778>
8. Corcoran, E., Winsen, M., Sudholz, A., & Hamilton, G. (2021). Automated detection of wildlife using drones: Synthesis, opportunities and constraints. *Methods in Ecology and Evolution*, 12(6), 1103–1114. <https://doi.org/10.1111/2041-210X.13581>
9. Grenzdörffer, G. J. (2013). UAS-based automatic Bird count of a common gull colony. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-1/W2, 169–174. <https://doi.org/10.5194/isprsarchives-xl-1-w2-169-2013>
10. Hinke, J. T., Giuseffi, L. M., Hermanson, V. R., Woodman, S. M., & Krause, D. J. (2022). Evaluating Thermal and Color Sensors for Automating Detection of Penguins and Pinnipeds in Images Collected with an Unoccupied Aerial System. *Drones*, 6(9).
<https://doi.org/10.3390/drones6090255>
11. Hodgson, J. C., Mott, R., Baylis, S. M., Pham, T. T., Wotherspoon, S., Kilpatrick, A. D., Raja Segaran, R., Reid, I., Terauds, A., & Koh, L. P. (2018). Drones count wildlife more accurately and precisely than humans. *Methods in Ecology and Evolution*, 9(5), 1160–1167.
<https://doi.org/10.1111/2041-210X.12974>
12. Hong, S. J., Han, Y., Kim, S. Y., Lee, A. Y., & Kim, G. (2019). Application of Deep-Learning Methods to Bird Detection Using Unmanned Aerial Vehicle Imagery. *Sensors 2019, Vol. 19, Page 1651*, 19(7), 1651. <https://doi.org/10.3390/S19071651>
13. Hyun, C. U., Park, M., & Lee, W. Y. (2020). Remotely piloted aircraft system (Rpas)-based wildlife detection: A review and case studies in maritime Antarctica. In *Animals* (Vol. 10, Issue 12, pp. 1–17). MDPI AG. <https://doi.org/10.3390/ani10122387>

14. Israël, M. (2011). A UAV-BASED ROE DEER FAWN DETECTION SYSTEM. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XXXVIII-1/C22*, 51–55. <https://doi.org/10.5194/isprsarchives-xxxviii-1-c22-51-2011>
15. Israël, M., & Evers, S. (2011). *Mustererkennung zur Detektion von Rehkitzen in Thermalbildern*. Bornimer Agrartechnische Berichte, 1-6. 17. Workshop Computer-Bildanalyse in der Landwirtschaft 2011. Leibniz-Institut für Agrartechnik Potsdam-Bornim e.V. (ATB) <https://elib.dlr.de/71467/>
16. Israël, M., Mende, M., & Keim, S. (2015). UAVRC, a generic MAV flight assistance software. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, 40(1W4)*, 287–291. <https://doi.org/10.5194/isprsarchives-XL-1-W4-287-2015>
17. Israël, M., & Reinhard, A. (2017). Detecting nests of lapwing Birds with the aid of a small unmanned aerial vehicle with thermal camera. *2017 International Conference on Unmanned Aircraft Systems, ICUAS 2017*, 1199–1207. <https://doi.org/10.1109/ICUAS.2017.7991393>
18. Kellenberger, B., Veen, T., Folmer, E., & Tuia, D. (2021). 21 000 Birds in 4.5 h: efficient large-scale seabird detection with machine learning. *Remote Sensing in Ecology and Conservation, 7(3)*, 445–460. <https://doi.org/10.1002/rse2.200>
19. Lee, W. Y., Park, M., & Hyun, C. U. (2019). Detection of two Arctic Birds in Greenland and an endangered Bird in Korea using RGB and thermal cameras with an unmanned aerial vehicle (UAV). *PLoS ONE, 14(9)*. <https://doi.org/10.1371/journal.pone.0222088>
20. Linchant, J., Lisein, J., Semeki, J., Lejeune, P., & Vermeulen, C. (2015). Are unmanned aircraft systems (UASs) the future of wildlife monitoring? A review of accomplishments and challenges. *Mammal Review, 45(4)*, 239–252. <https://doi.org/10.1111/MAM.12046>
21. Liu, C. C., Chen, Y. H., & Wen, H. L. (2015). Supporting the annual international black-faced spoonbill census with a low-cost unmanned aerial vehicle. *Ecological Informatics, 30*, 170–178. <https://doi.org/10.1016/J.ECOINF.2015.10.008>
22. Oishi, Y., Oguma, H., Tamura, A., Nakamura, R., & Matsunaga, T. (2018). Animal Detection Using Thermal Images and Its Required Observation Conditions. *Remote Sensing 2018, Vol. 10, Page 1050, 10(7)*, 1050. <https://doi.org/10.3390/RS10071050>
23. Psiroukis, V., Malounas, I., Mylonas, N., Grivakis, K.-E., Fountas, S., & Hadjigeorgiou, I. (2021). Monitoring of free-range rabbits using aerial thermal imaging. *Smart Agricultural Technology, 1*, 100002. <https://doi.org/10.1016/j.atech.2021.100002>
24. Rush, G. P., Clarke, L. E., Stone, M., & Wood, M. J. (2018). Can drones count gulls? Minimal disturbance and semiautomated image processing with an unmanned aerial vehicle for colony-nesting seabirds. *Ecology and Evolution, 8(24)*, 12322–12334. <https://doi.org/10.1002/ECE3.4495>
25. Sudholz, A., Denman, S., Pople, A., Brennan, M., Amos, M., & Hamilton, G. (2022). A comparison of manual and automated detection of rusa deer (*Rusa timorensis*) from RPAS-derived thermal imagery. *Wildlife Research, 49(1)*, 46–53. <https://doi.org/10.1071/WR20169>
26. Wirsing, A. J., Johnston, A. N., & Kiszka, J. J. (2022). Foreword to the Special Issue on ‘The rapidly expanding role of drones as a tool for wildlife research.’ *Wildlife Research, 49(1)*, i–v. <https://doi.org/10.1071/WR22006>

Manuele tellingen van fauna o.b.v. dronebeelden

27. Albores-Barajas, Y. v., Soldatini, C., Ramos-Rodríguez, A., Alcalá-Santoyo, J. E., Carmona, R., & Dell’Omo, G. (2018). A new use of technology to solve an old problem: Estimating the population size of a burrow nesting seabird. *PLoS ONE, 13(9)*. <https://doi.org/10.1371/journal.pone.0202094>

28. Chabot, D., Craik, S. R., & Bird, D. M. (2015). Population Census of a Large Common Tern Colony with a Small Unmanned Aircraft. *PLOS ONE*, *10*(4), e0122588. <https://doi.org/10.1371/JOURNAL.PONE.0122588>
29. Cukor, J., Bartoška, J., Rohla, J., Sova, J., & Machálek, A. (2019). Use of aerial thermography to reduce mortality of roe deer fawns before harvest. *PeerJ*, *2019*(5). <https://doi.org/10.7717/peerj.6923>
30. Graves, T. A., Yarnall, M. J., Johnston, A. N., Preston, T. M., Chong, G. W., Cole, E. K., Janousek, W. M., & Cross, P. C. (2022). Eyes on the herd: Quantifying ungulate density from satellite, unmanned aerial systems, and GPS collar data. *Ecological Applications*, *32*(5). <https://doi.org/10.1002/eap.2600>
31. Hodgson, J. C., Baylis, S. M., Mott, R., Herrod, A., & Clarke, R. H. (2016). Precision wildlife monitoring using unmanned aerial vehicles. *Scientific Reports*, *6*. <https://doi.org/10.1038/srep22574>
32. Laguna, E., Barasona, J. A., Triguero-Ocaña, R., Mulero-Pázmány, M., Negro, J. J., Vicente, J., & Acevedo, P. (2018). The relevance of host overcrowding in wildlife epidemiology: A new spatially explicit aggregation index. *Ecological Indicators*, *84*, 695–700. <https://doi.org/10.1016/j.ecolind.2017.09.039>
33. McMahan, M. C., Ditmer, M. A., & Forester, J. D. (2022). Comparing unmanned aerial systems with conventional methodology for surveying a wild white-tailed deer population. *Wildlife Research*, *49*(1), 54–65. <https://doi.org/10.1071/WR20204>
34. Patterson, C., Koski, W., Pace, P., McLuckie, B., & Bird, D. M. (2015). Evaluation of an unmanned aircraft system for detecting surrogate caribou targets in Labrador. *Journal of Unmanned Vehicle Systems*, *4*(1), 53–69. <https://doi.org/10.1139/juvs-2015-0014>
35. Preston, T. M., Wildhaber, M. L., Green, N. S., Albers, J. L., & Debenedetto, G. P. (2021). Enumerating White-Tailed Deer Using Unmanned Aerial Vehicles. *Wildlife Society Bulletin*, *45*(1), 97–108. <https://doi.org/10.1002/WSB.1149>
36. Sardà-Palomera, F., Bota, G., Padilla, N., Brotons, L., & Sardà, F. (2017). Unmanned aircraft systems to unravel spatial and temporal factors affecting dynamics of colony formation and nesting success in birds. *Journal of Avian Biology*, *48*(9), 1273–1280. <https://doi.org/10.1111/jav.01535>
37. Sardà-Palomera, F., Bota, G., Viñolo, C., Pallarés, O., Sazatornil, V., Brotons, L., Gomáriz, S., & Sardà, F. (2012). Fine-scale Bird monitoring from light unmanned aircraft systems. *Ibis*, *154*(1), 177–183. <https://doi.org/10.1111/j.1474-919X.2011.01177.x>
38. Scholten, C. N., Kamphuis, A. J., Vredevoogd, K. J., Lee-Strydhorst, K. G., Atma, J. L., Shea, C. B., Lamberg, O. N., & Proppe, D. S. (2019). Real-time thermal imagery from an unmanned aerial vehicle can locate ground nests of a grassland songbird at rates similar to traditional methods. *Biological Conservation*, *233*, 241–246. <https://doi.org/10.1016/j.biocon.2019.03.001>
39. Witczuk, J., Pagacz, S., Zmarz, A., & Cypel, M. (2018). Exploring the feasibility of unmanned aerial vehicles and thermal imaging for ungulate surveys in forests - preliminary results. *International Journal of Remote Sensing*, *39*(15–16), 5504–5521. <https://doi.org/10.1080/01431161.2017.1390621>

Additionele literatuur

40. Broset, S. (Auteur), Lejeune, P. (Promoteur), & Michez, A. (Promoteur). (2018). *Assessment of UAV potential for bioacoustic monitoring of Birds and bats: Tests under controlled conditions in Belgium*. <http://lib.uliege.behttps://matheo.uliege.be>
41. Cerra, D., Israel, M., & Datcu, M. (2009). PARAMETER-FREE CLUSTERING: APPLICATION TO FAWNS DETECTION. In IEEE Xplore (Ed.), *Wildretter*. Conference: Geoscience and Remote

- Sensing Symposium, 2009 IEEE International, IGARSS 2009 Volume: 3.
<https://doi.org/10.1109/IGARSS.2009.5418293>
42. Chabot, D., & Bird, D. M. (2015). Wildlife research and management methods in the 21st century: Where do unmanned aircraft fit in? *Journal of Unmanned Vehicle Systems*, 3(4), 137–155. <https://doi.org/10.1139/JUVS-2015-0021>
 43. Charbonneau, P., & Lemaître, J. (2021). Revue des applications et de l'utilité des drones en conservation de la faune. *Le Naturaliste Canadien*, 145(2), 3–34.
<https://doi.org/10.7202/1080620ar>
 44. Dulava, S., Bean, W. T., & Richmond, O. M. W. (2015). Environmental Reviews and Case Studies: Applications of Unmanned Aircraft Systems (UAS) for Waterbird Surveys. In *Environmental Practice* (Vol. 17, Issue 3, pp. 201–210). Cambridge University Press.
<https://doi.org/10.1017/S1466046615000186>
 45. Groom, G., Petersen, I. K., Anderson, M. D., & Fox, A. D. (2011). Using object-based analysis of image data to count Birds: Mapping of Lesser Flamingos at Kamfers Dam, Northern Cape, South Africa. *International Journal of Remote Sensing*, 32(16), 4611–4639.
<https://doi.org/10.1080/01431161.2010.489068>
 46. Groom, G., Stjernholm, M., Nielsen, R. D., Fleetwood, A., & Petersen, I. K. (2013). Remote sensing image data and automated analysis to describe marine Vogel distributions and abundances. *Ecological Informatics*, 14, 2–8. <https://doi.org/10.1016/j.ecoinf.2012.12.001>
 47. Israël M. (2016). *Entwicklung eines UAV-basierten Systems zur Rehkitzsuche und Methoden zur Detektion und Georeferenzierung von Rehkitzen in Thermalbildern*.
https://elib.dlr.de/108446/1/thesis_israel.pdf
 48. Jones, H. G., & Vaughan, R. A. (2010). *Remote Sensing of Vegetation: Principles, Techniques and Applications*. Oxford University Press.
 49. Pauly, K. (2020, 28th of November). *OpsDrone: Technical workshop – Data acquisition* [Powerpoint-slides]. Remotesensing.vito.be. Consultant on 6th of February, 2023. Internal document, available upon request:
<https://forms.office.com/Pages/ResponsePage.aspx?id=m3f8PDj19kCE2FWM650avWwnL6RdgLhFrGdVdBXyfJdUQU81Rlk5MEIJUU8zREhHSU03RDcxRk1JNC4u>
 50. Kellenberger, B., Marcos, D., & Tuia, D. (2018). Detecting mammals in UAV images: Best practices to address a substantially imbalanced dataset with deep learning. *Remote Sensing of Environment*, 216, 139–153. <https://doi.org/10.1016/j.rse.2018.06.028>
 51. Kucharczyk, M., Hay, G. J., Ghaffarian, S., & Hugenholtz, C. H. (2020). Geographic object-based image analysis: A primer and future directions. In *Remote Sensing* (Vol. 12, Issue 12). MDPI AG. <https://doi.org/10.3390/rs12122012>
 52. Kumar, V., Pandey, S., Pal, A., & Sharma, S. (n.d.). (PDF) *Edge Detection Based Shape Identification*. Retrieved January 6, 2023, from https://www.researchgate.net/publication/301926246_Edge_Detection_Based_Shape_Identification
 53. Laliberte, A. S., & Ripple, W. J. (2003). Automated Wildlife Counts from Remotely Sensed Imagery. *Wildlife Society Bulletin*, 31(2), 362–371.
<http://www.jstor.org/stable/3784314>
http://www.jstor.org/stable/3784314?seq=1&cid=pdf-reference#references_tab_contents
 54. Prosekov, A., Kuznetsov, A., Rada, A., & Ivanova, S. (2020). Methods for Monitoring Large Terrestrial Animals in the Wild. *Forests*, 11(8), 808–819. <https://doi.org/10.3390/f11080808>
 55. Steen, K. A., Villa-Henriksen, A., Therkildsen, O. R., & Green, O. (2012). Automatic detection of animals in mowing operations using thermal cameras. *Sensors (Switzerland)*, 12(6), 7587–7597. <https://doi.org/10.3390/s120607587>

56. Su, J., Zhu, X., Li, S., & Chen, W.-H. (2023). AI meets UAVs: A survey on AI empowered UAV perception systems for precision agriculture. *Neurocomputing*, *518*, 242–270.
<https://doi.org/10.1016/j.neucom.2022.11.020>
57. Trathan, P. N. (2004). Image Analysis of Color Aerial Photography to Estimate Penguin Population Size. In *Source* (Vol. 32, Issue 2). Wildlife Society Bulletin.
58. Tuia, D., Kellenberger, B., Beery, S., Costelloe, B. R., Zuffi, S., Risse, B., Mathis, A., Mathis, M. W., van Langevelde, F., Burghardt, T., Kays, R., Klinck, H., Wikelski, M., Couzin, I. D., van Horn, G., Crofoot, M. C., Stewart, C. v., & Berger-Wolf, T. (2022). Perspectives in machine learning for wildlife conservation. *Nature Communications* *2022 13:1*, *13*(1), 1–15.
<https://doi.org/10.1038/s41467-022-27980-y>
59. Wang, D., Shao, Q., & Yue, H. (2019). Surveying wild animals from satellites, manned aircraft and unmanned aerial systems (UASs): A review. In *Remote Sensing* (Vol. 11, Issue 11). MDPI AG. <https://doi.org/10.3390/rs11111308>