

Université de Montréal

Influence de la phénologie foliaire automnale de forêts tempérées sur la segmentation d'espèces  
d'arbres à partir d'imagerie de drone et d'apprentissage profond

Par

Myriam Cloutier

Département de sciences biologiques, Faculté des arts et des sciences

Mémoire présenté en vue de l'obtention du grade de Maître ès sciences (M.Sc.) en sciences  
biologiques

Juillet 2023

© Myriam Cloutier, 2023

Université de Montréal

Département de sciences biologiques / Institut de recherche en biologie végétale,

Faculté des arts et des sciences

---

*Ce mémoire intitulé*

**Influence de la phénologie foliaire automnale de forêts tempérées sur la segmentation d'espèces d'arbres à partir d'imagerie de drone et d'apprentissage profond**

*Présenté par*

**Myriam Cloutier**

*A été évalué par un jury composé des personnes suivantes*

**Marie-Hélène Brice**  
Présidente-rapportrice

**Etienne Laliberté**  
Directeur de recherche

**Mickaël Germain**  
Codirecteur

**Margaret Kalacksa**  
Membre du jury

## Résumé

La télédétection des forêts est devenue de plus en plus accessible grâce à l'utilisation de véhicules aériens inoccupés (UAV) et à l'apprentissage profond, ce qui permet d'obtenir des images répétées à haute résolution et d'observer les changements phénologiques à des échelles spatiales et temporelles plus importantes. Dans les forêts tempérées, à l'automne, la sénescence des feuilles se produit lorsque les feuilles changent de couleur et tombent. Cependant, l'influence de la sénescence foliaire sur la segmentation des espèces d'arbres à l'aide d'un réseau neuronal convolutif (CNN) n'a pas encore été évaluée. Nous avons acquis de l'imagerie haute résolution par UAV au-dessus d'une forêt tempérée au Québec à sept reprises entre mai et octobre 2021. Nous avons segmenté et identifié 23 000 couronnes d'arbres de 14 classes différentes pour entraîner et valider un CNN pour chaque acquisition d'imagerie. La meilleure segmentation (F1-score le plus élevé) était au début de la coloration des feuilles (début septembre) et le F1-score le plus bas au pic de la coloration automnale (début octobre). La chronologie de la sénescence varie considérablement d'une espèce à l'autre et au sein d'une même espèce, ce qui entraîne une grande variabilité du signal télédéTECTé. Les espèces d'arbres à feuilles caduques et à feuilles persistantes qui présentaient des traits distinctifs et moins variables dans le temps entre les individus ont été mieux classées. Bien que la segmentation des arbres dans une forêt hétérogène demeure un défi, l'imagerie UAV et l'apprentissage profond démontrent un grand potentiel pour la cartographie des espèces d'arbres. Les résultats obtenus dans une forêt tempérée où la couleur des feuilles change fortement pendant la sénescence automnale montrent que la meilleure performance pour la segmentation des espèces d'arbres se produit au début de ce changement de couleur.

**Mots-clés :** Forêt tempérée; espèces d'arbres; phénologie foliaire; télédétection; véhicule aérien télépiloté; apprentissage profond; segmentation sémantique.

## Abstract

Remote sensing of forests has become increasingly accessible with the use of unoccupied aerial vehicles (UAV), along with deep learning, allowing for repeated high-resolution imagery and the capturing of phenological changes at larger spatial and temporal scales. In temperate forests during autumn, leaf senescence occurs when leaves change colour and drop. However, the influence of leaf senescence in temperate forests on tree species segmentation using a Convolutional Neural Network (CNN) has not yet been evaluated. Here, we acquired high-resolution UAV imagery over a temperate forest in Quebec, Canada on seven occasions between May and October 2021. We segmented and labelled 23,000 tree crowns from 14 different classes to train and validate a CNN for each imagery acquisition. The CNN-based segmentation showed the highest F1-score (0.72) at the start of leaf colouring in early September and the lowest F1-score (0.61) at peak fall colouring in early October. The timing of the events occurring during senescence, such as leaf colouring and leaf fall, varied substantially between and within species and according to environmental conditions, leading to higher variability in the remotely sensed signal. Deciduous and evergreen tree species that presented distinctive and less temporally-variable traits between individuals were better classified. While tree segmentation in a heterogenous forest remains challenging, UAV imagery and deep learning show high potential in mapping tree species. Our results from a temperate forest with strong leaf colour changes during autumn senescence show that the best performance for tree species segmentation occurs at the onset of this colour change.

**Keywords:** Temperate forest; Tree species; Leaf phenology; Remote sensing; Unoccupied aerial vehicle; Deep learning; Semantic Segmentation.

# Table des matières

Résumé .....	iii
Abstract .....	iv
Table des matières .....	v
Liste des tableaux .....	vii
Liste des figures .....	viii
Liste des sigles et abréviations .....	ix
Remerciements .....	x
Chapitre 1 – Mise en contexte .....	11
Problématique : Suivi de la biodiversité en forêt .....	11
La télédétection en milieu forestier .....	12
L'apprentissage profond .....	13
Réseaux neuronaux convolutifs .....	14
Les caractéristiques des arbres .....	17
La phénologie des arbres .....	17
L'architecture et la texture des couronnes .....	19
Caractère novateur du projet .....	20
Objectifs et hypothèses de recherche .....	20
Méthodologie .....	21
Chapitre 2 – Influence of Temperate Forest Autumn Leaf Phenology on Segmentation of Tree Species from UAV Imagery Using Deep Learning .....	23
Abstract .....	24
1. Introduction .....	24
2. Methods .....	28

2.1 Study site .....	28
2.2 Datasets .....	30
2.3 Deep learning model and training .....	35
2.4 Accuracy assessment.....	36
3. Results .....	36
3.1 Model results .....	36
3.2 Predictions errors in confusion matrices .....	39
4. Discussion .....	44
4.1 Lowest accuracy for October imagery .....	44
4.2 Challenges related to the variability of senescence.....	46
4.3 Tree segmentation in a complex canopy.....	48
4.4 Other features from the imagery .....	50
4.5 Species-specific traits.....	51
5. Conclusion.....	54
Chapitre 3 – Discussion générale .....	56
Retour sur les objectifs et les hypothèses de recherche .....	56
Perspectives .....	61
La recherche en phénologie.....	61
L’importance des jeux de données .....	62
Le potentiel de la télédétection.....	64
Références bibliographiques .....	65
Annexes.....	82

## **Liste des tableaux**

Table 1	F1-score for the models for each class at each date.....	38
---------	--	----

## Liste des figures

Figure 1	Les principales approches lors de l'utilisation d'un CNN .....	16
Figure 2	Map of the study site in St-Hippolyte, Quebec, Canada .....	29
Figure 3	Image of the annotations from the dataset .....	32
Figure 4	Example of the fourteen classes from the seven orthomosaics (May to October).....	34
Figure 5	Confusion matrices for early September and October .....	40
Figure 6	Classes with higher and lower performances in the predictions .....	42
Figure 7	Classes that showed the highest proportions of misclassifications .....	43
Supplementary Figure S1	Illumination conditions for each date of acquisition .....	82
Supplementary Figure S2	Example of annotated tree crowns .....	83
Supplementary Figure S3	Example of tiles and masks from the early September imagery .....	84
Supplementary Figure S4	Variation of the F1-scores for each class for the seven dates .....	85
Supplementary Figure S5	Confusion matrices for each class for the remaining five dates.....	90

## Liste des sigles et abréviations

CNN	Convolutional neural network ; réseau convolutif neuronal
DEM	Digital elevation model ; Modèle numérique d'élévation
EPSG	European Petroleum Survey Group
GCP	Ground control point ; Point de contrôle
GNSS	Global navigation satellite systems ; Système de positionnement par satellite
GPU	Graphical Processing Unit
GSD	Ground sampling distance ; Résolution au sol
IA	Intelligence artificielle
IMU	Inertial measurement unit ; Unité de mesure de l'inertie
IVADO	Institut de valorisation des données
LEFO	Laboratoire d'écologie fonctionnelle végétale
IRBV	Institut de recherche en biologie végétale
LiDAR	Light Detection and Ranging ; Détection et télémétrie par lumière
RGB	Rouge-vert-bleu ; Red-green-blue
RTK	Real-time kinematic ; Cinématique temps réel
SAM	Segment Anything Model
SIG	Système d'information géographique
SBL	Station de biologie des Laurentides de l'Université de Montréal
Sp.	Espèce
Spp.	Espèces
UAV	Unoccupied Aerial Vehicle ; Véhicule aérien télépiloté
UTM	Universal Transverse Mercator
WGS	World Geodetic System

## Remerciements

Pour commencer, j'aimerais remercier mon directeur, Etienne Laliberté, et mon co-directeur Mickaël Germain de m'avoir donné l'opportunité ainsi que les outils pour faire cette maîtrise. J'apprécie que vous m'ayez fait confiance avec ce projet ambitieux qui sortait de mes attentes, tout en étant le projet idéal pour moi pour commencer mon parcours en recherche. J'ai pu découvrir deux domaines connexes qui me passionnent, la télédétection et l'apprentissage profond. J'apprécie aussi l'opportunité d'avoir pu travailler dans le cadre d'un projet en lien avec IVADO, et d'ainsi collaborer avec des chercheurs de ce milieu. Je vous remercie pour votre disponibilité, votre aide et pour votre grande écoute tout au long de ma maîtrise. Je veux aussi remercier les membres de mon comité-conseil, Anne Bruneau et Margaret Kalacska, pour leur support et leurs recommandations.

J'aimerais souligner l'immense aide et tout le travail de ceux et celles qui m'ont aidé à générer le jeu de données : Noémie Lacombe pour le travail sur le terrain et au labo avec plusieurs milliers d'annotations; Ariane Roberge pour l'aide avec les orthomosaïques et le travail sur le terrain et avec les annotations; Antoine Caron-Guay pour le travail sur le terrain et Étienne Morissette pour le travail sur les annotations. Sans vous, je ne serais pas venu à bout de finir les 23 000 polygones (je serais probablement encore en train d'annoter des arbres...)!

Je veux remercier les membres de LEFO, passés et présents, pour leur support, leur aide, leur compagnie et leur conseil. J'ai appris de vous et j'ai apprécié partager mon parcours avec vous tous et toutes! J'aimerais aussi remercier le personnel de la Station de biologie des Laurentides qui était présent à la station durant mon été de terrain. Je veux aussi remercier les personnes de la *gang* des poissons (et compagnie) qui ont contribué à ce que cet été soit aussi agréable et mémorable.

Merci à mes amies, qui m'ont encouragé durant mon parcours et qui étaient là quand j'avais besoin d'elles. Finalement, un merci tout particulier à mes parents qui m'ont soutenu et encouragé depuis le début dans ce mystérieux cheminement qu'est la recherche, qui m'ont aidé à traverser plusieurs épreuves et sans qui je ne serais pas où je suis.

# **Chapitre 1 – Mise en contexte**

## **Problématique : Suivi de la biodiversité en forêt**

Dans le contexte actuel de changements climatiques et de déclin de la biodiversité, il devient impératif d'assurer la surveillance et la détection de changements de biodiversité afin d'en comprendre les effets sur la santé des écosystèmes et la distribution des espèces (He et al., 2011; Nagendra et al., 2013; Onishi et al., 2022). Cependant, davantage de connaissance et de données sur les dynamiques des milieux forestiers sont nécessaires afin d'arriver à une surveillance et une gestion efficaces de ces écosystèmes (Fassnacht et al., 2016; Goodbody et al., 2019; Lausch et al., 2017). La cartographie des espèces d'arbres en forêt est essentielle à leur bonne gestion et à leur protection (Hill et al., 2010). Ceci implique l'acquisition de données spatiales sur la biodiversité des forêts d'une manière périodique et rigoureuse (Korpela & Tokola, 2006; Natesan et al., 2020). De plus, ces informations devraient idéalement être à l'échelle d'arbres individuels, incluant l'espèce, la taille de la couronne ainsi que le nombre d'arbres par espèce afin d'avoir des données à une échelle spatiale plus fine et une cartographie des espèces plus détaillée (Zhang et al., 2022).

Selon la diversité et la complexité d'une forêt, l'identification de couronnes individuelles d'arbres peut être une tâche ardue (Fassnacht et al., 2016; Zhang et al., 2022). Ceci peut être entre autres dû à une variabilité dans les traits des espèces d'intérêt (Natesan et al., 2020). De plus, les méthodes traditionnellement utilisées pour les inventaires forestiers nécessitent beaucoup de temps et de main-d'œuvre et tendent à être de plus en plus dispendieuses, ce qui limite le nombre de campagnes de terrain pouvant être réalisées. Ces méthodes sont aussi limitées en termes d'étendue spatiale pouvant être couverte en plus de ne pas inclure des endroits plus difficiles d'accès (Goodbody et al., 2019; Komárek, 2020; Veras et al., 2022). Ces facteurs rendent difficile la collecte de données au niveau de l'arbre individuel sur une grande échelle spatiale, limitant la résolution temporelle qu'il est possible d'obtenir (Beloiu et al., 2023). Il est donc nécessaire d'introduire d'autres méthodes qui rendront possible la récolte de données sur la végétation en milieu forestier de façon plus rapide et précise et qui permettront de couvrir un territoire plus grand.

## La télédétection en milieu forestier

La télédétection, lorsqu'intégrée aux méthodes actuelles de recherche en foresterie et en écologie, représente un outil qui peut nous aider à adresser les défis quant au suivi de la biodiversité (Beloiu et al., 2023; Cavender-Bares et al., 2022; de Lima et al., 2022; Lechner et al., 2020). En effet, la télédétection peut permettre la cartographie et la caractérisation de la végétation, ce qui aide à la gestion des écosystèmes (Nagendra et al., 2013). L'utilisation de plateformes de télédétection pour l'acquisition de données permet d'avoir une vision aérienne de la végétation (Kattenborn et al., 2021). Différents types de plateforme existent en télédétection, chacun pouvant répondre à différents objectifs de recherche. Les plateformes terrestres, par exemple des phénocams (*The PhenoCam Network*, (n.d.)), acquièrent de l'imagerie à une très haute résolution temporelle avec plusieurs prises d'image par jour, mais elles sont limitées en termes de couverture spatiale (Klosterman et al., 2018). Les imageries prises par satellites offrent une très grande couverture spatiale et une résolution temporelle plutôt grande, mais la résolution spatiale est trop faible pour les besoins de ce projet (Coops et al., 2023). Afin de cartographier et de faire un suivi de la végétation de la canopée d'une forêt à l'échelle d'arbres individuels, il est nécessaire d'avoir une plateforme permettant de couvrir de larges superficies avec une résolution spatiale suffisamment grande pour permettre de voir les détails présents dans les couronnes d'arbres (Fassnacht et al., 2016).

Les véhicules aériens télépilotés (UAV), communément appelés des drones, offrent un intermédiaire entre les deux plateformes précédentes, c'est-à-dire une couverture spatiale adéquate et une très haute résolution spatiale (Kattenborn et al., 2021), répondant donc aux besoins de cette étude. Les UAVs sont un outil de plus en plus accessible et abordable (Komárek, 2020; Lopatin et al., 2019), particulièrement pour l'acquisition d'imagerie rouge-vert-bleu (RGB) qui nécessite les capteurs les moins coûteux (Kattenborn et al., 2020). La plupart des UAVs peuvent aussi géoréférencer l'imagerie directement lors de l'acquisition, ce qui assure une précision lors de la prise répétée d'imagerie à un même endroit (Kattenborn et al., 2021; Park et al., 2019). La flexibilité des UAVs et leur capacité de faire du géoréférencement automatisé, comparativement aux inventaires de terrain conventionnels, permettent d'acquérir facilement des données à plusieurs reprises sur un même site, ce qui favorise la création d'un jeu de données multitemporel (Klosterman & Richardson, 2017; Veras et al., 2022). L'imagerie RGB avec une très haute résolution spatiale permet de voir la forme des couronnes, les motifs de ramifications des branches

et la forme et la couleur des feuilles (Fassnacht et al., 2016; Kattenborn et al., 2019). Ces détails caractérisant les couronnes des arbres sont souvent nécessaires afin d'identifier l'espèce de l'arbre (Natesan et al., 2020; Schiefer et al., 2020). Pour ces raisons, nous avons choisi les UAVs pour faire l'acquisition d'imagerie RGB pour ce projet. Il est à noter que l'utilisation croissante des UAVs en écologie amène une augmentation de la quantité de données qu'il est possible de produire pour caractériser la végétation, avec une diversité de résolutions spatiales, temporelles et spectrales (Katal et al., 2022; Kattenborn et al., 2021). Ces imageries à très haute résolution contiennent une quantité importante d'information présente dans les motifs complexes de formes, de couleurs et de textures de la végétation qui peuvent être utilisés pour identifier les espèces d'arbres et qui pourraient bénéficier des approches récentes de vision par ordinateur (Schiefer et al., 2020).

## L'apprentissage profond

Afin d'extraire un maximum de données à partir de l'imagerie aérienne, il est possible de combiner cette technologie aux méthodes d'intelligence artificielle (IA). L'IA peut être définie comme étant un système capable d'interpréter des données, d'apprendre de celles-ci et d'utiliser ces apprentissages afin d'accomplir des tâches qui lui sont définies par l'utilisateur (Haenlein & Kaplan, 2019). L'IA représente un groupe de types d'apprentissage qui inclut entre autres le *shallow learning*, aussi appelé l'apprentissage par machine (*machine learning*) et l'apprentissage profond (*deep learning*; (Hoeser & Kuenzer, 2020; Zhong et al., 2019)). Le *shallow learning* a un potentiel plus limité dû au fait qu'il est nécessaire d'appliquer l'ingénierie des caractéristiques (*feature engineering*), c'est-à-dire que l'utilisateur doit préciser au modèle les variables les plus importantes à extraire dans les données et les combinaisons de paramètres et de transformations à utiliser (Kattenborn et al., 2021; Kaul et al., 2020). L'apprentissage profond est caractérisé par un nombre important de couches neuronales successives permettant au modèle d'apprendre par lui-même les transformations et les caractéristiques propres aux données dont il a besoin et ainsi extraire de l'information plus riche de l'imagerie (Hoeser & Kuenzer, 2020; Kattenborn et al., 2021; Zhong et al., 2019). L'apprentissage profond est donc plus performant que les modèles d'apprentissage par machine classique (Hoeser & Kuenzer, 2020; Katal et al., 2022), surtout lorsqu'on cherche à extraire des informations contextuelles dans une imagerie complexe, comme une canopée de forêt. Un nombre grandissant de recherches allient la télédétection de la végétation

à l'apprentissage profond afin de cartographier la végétation avec une grande précision en extrayant les caractéristiques de la canopée présentes dans l'imagerie (Brodrick et al., 2019; Katal et al., 2022; Kattenborn et al., 2021; Veras et al., 2022). Parmi les différents modèles d'apprentissage profond qui ont été développés, les réseaux neuronaux convolutifs (CNNs) ont été choisis pour ce projet, car ils sont particulièrement bien adaptés à des problèmes de vision par ordinateur (Brodrick et al., 2019; Kattenborn et al., 2021; Schiefer et al., 2020). Récemment, une nouvelle méthode a émergée dans le domaine de l'apprentissage profond, les « *transformers* ». Ceux-ci demandent en général moins de ressources computationnelles lors de l'entraînement tout en ayant des performances similaires ou supérieures aux CNNs les plus récents dans des contextes de vision par ordinateur (Dosovitskiy et al., 2021; Vaswani et al., 2023). Pour ce projet, malgré ces avantages, il a été décidé d'utiliser les CNNs, puisque ces algorithmes ont davantage été utilisés dans des études similaires et que l'objectif de l'étude n'était pas d'atteindre les plus hautes performances prédictives.

## Réseaux neuronaux convolutifs

Les CNNs sont un type d'algorithme d'apprentissage profond capable d'extraire l'information spatiale complexe caractérisant les objets d'intérêt dans l'imagerie et le contexte spatial autour de ces objets d'intérêt (Kattenborn et al., 2021; Korznikov et al., 2021). Ils sont composés de couches hiérarchiques de neurones artificiels qui cherchent à simuler le fonctionnement des neurones d'un cerveau humain et qui extraient de l'information de plus en plus complexe et abstraite plus les couches sont profondes (Ferreira et al., 2020; James & Bradshaw, 2020; Kaul et al., 2020). Parmi ces couches, la première correspond aux données d'imagerie et la dernière couche correspond aux prédictions faites par le modèle (Kattenborn et al., 2021). Pour l'entraînement d'un CNN, la récolte des données d'entraînement doit être faite en s'assurant de remplir certains critères qui maximiseront la qualité des prédictions produites par le CNN. D'abord, la quantité de données de référence est critique pour le succès du modèle (Kattenborn et al., 2021). Les données doivent idéalement avoir une grande hétérogénéité, c'est-à-dire inclure entre autres différents types de conditions d'acquisition d'imagerie, différents types de conditions environnementales et une variété de structure d'âge, afin de s'assurer d'avoir des modèles robustes et généraux (Schiefer et al., 2020; Weinstein et al., 2020). Il est aussi recommandé que les classes d'intérêt, qui correspondent aux différents groupes représentés dans le jeu de données et qui seront identifiés par

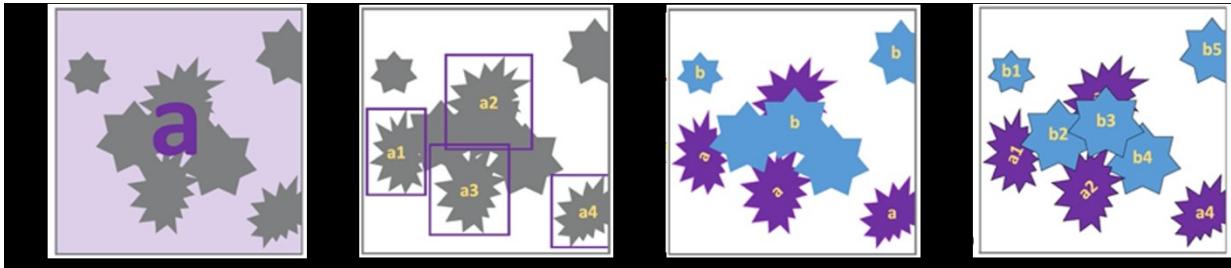
le modèle, aient des abondances plutôt équilibrées puisque les classes les moins abondantes dans le jeu de données risquent d'être moins bien classifiées par le modèle (Schiefer et al., 2020).

Plusieurs types d'apprentissages existent pour utiliser des CNNs selon la structure et la nature des données utilisées pour l'entraînement (Figure 1). La plus générale est la classification d'image (Figure 1a) pour laquelle une image entière est associée à une classe si l'objet d'intérêts s'y trouve (Kattenborn et al., 2021; Schiefer et al., 2020). Ensuite, la détection d'objet (Figure 1b) dessine une boîte autour des objets d'intérêt détectés dans l'image. Cette approche est moins fréquemment appliquée en contexte naturel où les entités ne sont pas toujours facilement comptables (Kattenborn et al., 2021). Par contre, une étude récente a démontré le potentiel de la détection de couronnes d'arbres individuels en milieu forestier, soulignant que le modèle performerait bien pour des inventaires forestiers en fournissant l'espèce, le nombre de couronnes et l'emplacement des couronnes d'arbres (Beloiu et al., 2023).

La segmentation sémantique (Figure 1c), quant à elle, est une approche qui combine la segmentation d'objets et la classification de pixels (Schiefer et al., 2020). L'entraînement d'un CNN en utilisant la segmentation sémantique est basé sur des masques correspondant à chaque classe d'intérêt qui identifient de manière spatialement explicite les pixels des objets, où tous les pixels de l'image doivent être assignés à une classe (Ferreira et al., 2020; Kattenborn et al., 2021; Long et al., 2015). Une architecture spécifique de CNN qui fait de la segmentation sémantique, un U-Net (Ronneberger et al., 2015), a été utilisée par Schiefer et al. (2020) pour la cartographie d'arbres individuels dans une canopée donnant des résultats concluants. Une caractéristique intéressante de l'application de U-Net dans un environnement naturel est le fait que ce modèle est capable de reconnaître les couronnes d'arbres comme des entités ayant une géométrie spécifique. Cependant, les couronnes d'une même classe qui se chevauchent ne sont pas reconnues comme des objets différents, mais plutôt comme un seul objet (Korznikov et al., 2021).

La dernière approche présentée est la segmentation d'instance (Figure 1d) qui est une combinaison de la détection d'objet et de la segmentation sémantique. Ce type de segmentation classifie les pixels de chaque objet, comme pour la segmentation sémantique, en plus de déterminer la forme exacte de chaque objet individuel (Ferreira et al., 2020). Cependant, ceci requiert que les individus soient discernables sur l'imagerie puisque la classification par individu se fait plus difficilement si les couronnes d'arbres se chevauchent (Kattenborn et al., 2020; Schiefer et al.,

2020). La segmentation d’instance est appliquée lorsque l’objectif est d’identifier des individus et d’en faire la délinéation spatiale (Kattenborn et al., 2021). Les méthodes avec lesquelles les données seront récoltées pour cette étude permettront d’utiliser la segmentation d’instance, mais puisque nous ne cherchons pas à détecter les objets individuels et seulement de classifier les pixels de l’imagerie, nous allons utiliser la segmentation sémantique.



**Figure 1** Les principales approches lors de l’utilisation d’un CNN

Les approches présentées sont (a) la classification d’images, (b) la détection d’objets, (c) la segmentation sémantique et (d) la segmentation d’instance. Les lettres dans les encadrés (a et b) correspondent aux différentes classes d’intérêt et les couleurs (bleu et mauve) correspondent aux différents objets (indiqué par un chiffre après la lettre). Figure tirée de Kattenborn et al. (2021).

Les CNNs offrent plusieurs avantages, surtout lorsque l’objectif est de classifier des imageries plus complexes telles que des canopées de forêts naturelles. Ils sont spécifiquement développés pour analyser les patrons spatiaux dans l’imagerie, les rendant très efficaces lorsqu’ils sont utilisés pour prédire des objets spatiaux dans des imageries aériennes haute résolution en exploitant les détails importants dans l’imagerie (Fricker et al., 2019; Kattenborn et al., 2019). Ils se basent sur le contexte spatial entourant les objets d’intérêt et extrait une grande quantité d’information par rapport aux propriétés des végétaux, telles que la couleur, la texture, les formes et l’architecture (Kattenborn et al., 2021; Schiefer et al., 2020). De plus, les CNNs peuvent produire des prédictions très précises qui peuvent être similaires ou supérieures à la vision humaine, mais qui peuvent être appliquées de manière automatisée sur une grande étendue spatiale (Brodrick et al., 2019). Ceci permet de cartographier rapidement des arbres au niveau de l’espèce sur un grand site d’étude, à la condition d’avoir des données d’entraînement de qualité et en quantité suffisante (Kattenborn et al., 2019; Weinstein et al., 2019).

Malgré ces avantages ainsi que les avancées dans les domaines de la télédétection et de l'apprentissage profond, certains défis sont associés à l'utilisation de ces deux outils. Dans une forêt mixte et complexe, il peut être plus difficile de segmenter les couronnes d'arbres afin de créer des données pour l'entraînement du modèle dû entre autres à des couronnes qui se chevauchent, rendant aussi les prédictions par le modèle moins précises (Fassnacht et al., 2016; Zhang et al., 2022). Ainsi, la complexité d'une forêt hétérogène peut jouer sur la faciliter d'acquérir un jeu de donnée et sur le succès de prédiction des classes par le CNN (Beloiu et al., 2023).

## **Les caractéristiques des arbres**

Lorsque des traits distinctifs caractérisent les espèces et augmentent les différences quant à leur apparence, les CNNs seraient plus aptes à classifier l'imagerie en différentes espèces. Ceci pourrait même contribuer à diminuer la taille du jeu de données nécessaire afin d'obtenir une bonne segmentation, malgré les défis mentionnés précédemment (Kattenborn et al., 2021). Certaines caractéristiques des couronnes d'arbres contribuent à augmenter la différence entre les espèces, telles que l'intensité de la couleur des feuilles, la structure de la couronne et la forme des feuilles (Nezami et al., 2020). Plusieurs traits sont visibles dans l'imagerie générée pour cette étude, entre autres les patrons de couleurs qui changent selon les espèces au cours de la saison et la variété d'architecture et de texture des couronnes d'arbres.

## **La phénologie des arbres**

La phénologie est définie comme étant la variation des phénomènes périodiques en fonction des saisons et se manifeste tout au long de l'année (Gallinat et al., 2015). La phénologie des végétaux reçoit de plus en plus d'intérêt dû au fait que les moments où les phénomènes liés à la phénologie se manifestent dépendent en grande partie des conditions environnementales et des microclimats où se trouve la végétation (Katal et al., 2022; Lisein et al., 2015). En effet, la prise en compte de la phénologie lors de l'acquisition de données peut grandement contribuer à l'entraînement et au succès de modèles d'apprentissage profond (Korznikov et al., 2021). De l'imagerie aérienne acquise de manière répétée afin de représenter différents stades phénologiques peut permettre à un CNN d'apprendre et d'utiliser les patrons phénologiques spécifiques aux espèces (Veras et al., 2022). L'utilisation de patrons qui changent selon les espèces aide à la reconnaissance entre les

espèces (He et al., 2019; Hill et al., 2010; Korznikov et al., 2021). Les processus phénologiques des feuilles en particulier peuvent être très utiles pour différencier entre des espèces d'arbres et contribuer à une meilleure classification (Fassnacht et al., 2016; Nagendra et al., 2013), puisque les feuilles constituent la partie la plus visible de l'arbre sur de l'imagerie aérienne. Certains exemples de patrons phénologiques au niveau des feuilles dans les forêts tempérées sont l'émergence des feuilles au printemps, la maturation des feuilles au cours de l'été et la coloration suivie de la chute des feuilles à l'automne durant le processus de sénescence (Korznikov et al., 2021; Lisein et al., 2015; Nagendra et al., 2013).

Parmi ces étapes dans la phénologie foliaire en milieu tempéré, la coloration des feuilles à l'automne a été mentionnée par plusieurs comme étant le moment optimal pour l'acquisition d'imagerie lorsque l'objectif est de classifier les couronnes d'arbres (Grybas & Congalton, 2021; Hill et al., 2010; Key et al., 2001; Weil et al., 2017). Le processus qui englobe la coloration et la chute des feuilles à l'automne est la sénescence et est particulièrement apparent chez les arbres décidus. Ce phénomène se produit lorsque les feuilles approchent la fin de leur cycle de vie, ce qui déclenche une réponse systémique dans la plante et un déclin des fonctions dans la feuille, se manifestant par un changement de couleur avant l'abscission complète de la feuille (Gallinat et al., 2015; Zani et al., 2020). Selon les espèces, certaines feuilles deviennent rouges dû à une production d'anthocyanines alors que d'autres feuilles deviennent jaunes ou oranges lorsque la chlorophylle se dégrade et dévoile les pigments caroténoïdes qui étaient présents (Matile, 2000). L'accumulation d'anthocyanines protège les chloroplastes de la feuille d'un excès de radiation solaire lorsque les chlorophylles sont dégradées afin de retirer un maximum de nutriments à la fin de la saison de croissance. La stratégie de sénescence est spécifique à chaque espèce (Hill et al., 2010), résultant en une mosaïque de couleurs sur les imageries aériennes. Cependant, les études portant sur la phénologie automnale sont beaucoup moins nombreuses que celles portant sur la phénologie printanière (Zani et al., 2020). Ce manquement dans la littérature est attribué à la complexité des facteurs déclenchant la sénescence et l'imprédictibilité quant au moment de la coloration et de la chute des feuilles d'une année à l'autre (Gallinat et al., 2015; Katal et al., 2022). De plus, la sénescence des feuilles démontre une variabilité interspécifique bien plus importante que pour la phénologie printanière (Budianti et al., 2021). Ces facteurs compliquent la sélection d'une date adéquate pour l'acquisition d'imagerie aérienne afin de capturer la sénescence, en particulier la coloration des feuilles.

## L'architecture et la texture des couronnes

Certains traits des arbres, tels que la forme de la couronne et l'allocation de la biomasse dans la couronne (i.e. l'emplacement des feuilles) varient en fonction de l'espèce (Ørka et al., 2009), ce qui peut permettre de différencier entre les classes. Un des principaux traits par rapport à l'architecture de la couronne visible depuis les aires est la différence entre les feuillus et les conifères. Notamment, les conifères ont des couronnes plutôt coniques ainsi qu'une relation importante entre la hauteur et la taille de la couronne alors que les feuillus ont des couronnes de forme plutôt large et plate et une structure plus complexe (He et al., 2019; Nuijten et al., 2019). Au niveau des conifères, les pins tendent à avoir des structures de couronnes moins coniques que d'autres espèces, telles que les épinettes, un aspect qui pourrait être détecté par le CNN et contribuer à une meilleure classification (Nezami et al., 2020).

Pour ce qui est des espèces de feuillus, les différences sont plutôt au niveau de la texture de la couronne due à une irrégularité plus importante quant à leur forme. L'angle des feuilles et la densité de la couronne ainsi que la différence entre les espèces de fin de succession et début de succession amènent des différences quant à l'apparence des couronnes sur l'imagerie (Hagemeier & Leuschner, 2019). Plus spécifiquement, les espèces de début de succession ont des feuilles qui sont plutôt orientées vers la verticale et la couronne est moins dense afin de favoriser le passage de la lumière à travers la couronne. Au contraire, les espèces de fin de succession ont des feuilles avec un angle plutôt horizontal ainsi que des feuilles plus larges afin de capter davantage de lumière (Hagemeier & Leuschner, 2019). En plus de ces traits qui peuvent se répéter entre des espèces du même stade de succession, des arbres appartenant au même groupe fonctionnel et poussant dans le même environnement affichent des textures similaires, ce qui est parfois dû à des feuilles ayant des formes similaires (Onishi et al., 2022).

Dans tous les cas, il est tout de même nécessaire d'avoir une résolution spatiale suffisamment grande pour pouvoir distinguer ces traits et pour que le CNN puisse les utiliser (Schiefer et al., 2020). De l'imagerie ayant une résolution assez grande est d'autant plus importante pour les aspects liés à la géométrie et l'architecture des couronnes, puisque ceux-ci impliquent l'orientation et la taille des feuilles ainsi que d'autres aspects plus subtils qui pourraient être captés par le CNN. Ce type d'information aide le CNN à distinguer entre certaines espèces de feuillus grâce à des couronnes ayant un aspect différent dû aux stratégies spécifiques des arbres. Les

différences dans la performance du modèle entre les classes peuvent être attribuées aux formes distinctives de la couronne propre à chaque espèce (Gan et al., 2023; Hastings et al., 2020).

## **Caractère novateur du projet**

Ces dernières années, de plus en plus de recherche en écologie est faite en alliant la télédétection par UAV et l'apprentissage profond pour cartographier des espèces d'arbres (Katal et al., 2022; Kattenborn et al., 2021). Parmi les chercheurs qui incluent des données phénologiques dans leur imagerie, peu se sont penchés à déterminer les aspects de la végétation qui pourrait influencer la précision de leur modèle (Kattenborn et al., 2021; Yang et al., 2019; Zhang et al., 2018). En effet, parmi des études récentes utilisant les UAVs et les CNNs pour cartographier des espèces d'arbres dans les forêts de milieux tempérés, plusieurs ont mentionné un besoin pour des études qui regardent les effets de la phénologie végétale sur ce type de méthodes (Beloiu et al., 2023; Gan et al., 2023; Korznikov et al., 2021; Nuijten et al., 2019). De manière plus générale, il manque d'études qui examinent et essaient de comprendre quelles caractéristiques de la végétation pourraient mener à des erreurs de classification avec des modèles d'IA (Fassnacht et al., 2016). La phénologie automnale d'une forêt tempérée occupe une partie importante des données de cette étude, contribuant ainsi à répondre aux besoins dans la littérature présentée ici. Cette étude offre aussi une méthodologie pour l'étude de la sénescence dont notre compréhension est limitée par l'accès à des données précises sur une grande échelle temporelle et spatiale (Katal et al., 2022).

## **Objectifs et hypothèses de recherche**

Dans le cadre de ce projet, l'objectif principal est d'évaluer l'effet que pourraient avoir les changements phénologiques dans une forêt tempérée sur la performance d'un modèle d'apprentissage profond. Plus spécifiquement, une comparaison sera effectuée sur la capacité d'un CNN à segmenter 14 classes composant la canopée d'une forêt (11 espèces d'arbres, deux genres et les arbres morts) en fonction du moment durant la saison de croissance. Pour ce faire, plusieurs modèles d'apprentissage profond seront entraînés à partir d'imagerie de la fin du printemps (fin mai) jusqu'au pic des couleurs à l'automne (début octobre). Pour pouvoir entraîner ces modèles, un grand jeu de données sera généré à partir d'imageries où plusieurs milliers de couronnes d'arbres

seront segmentés individuellement. En ayant des données sur le potentiel de segmenter des couronnes d'arbres au niveau de l'espèce, il sera possible de déterminer les caractéristiques morphologiques et écologiques des espèces qui pourraient influencer la performance des modèles. Certains des traits qui pourraient expliquer les résultats des prédictions à une date, tels que la couleur, la forme et la texture, ainsi que la variation de la performance liée aux changements phénologiques au cours de la saison de croissance, particulièrement lors de la sénescence des feuilles à l'automne seront ensuite identifiés.

Plusieurs auteurs ont indiqué que le pic des couleurs à l'automne était le moment de l'année avec le plus de succès pour la classification de couronnes d'arbres dans des forêts tempérées (Grybas & Congalton, 2021; Hill et al., 2010; Key et al., 2001; Weil et al., 2017). Ainsi, il est prévu que plus l'imagerie avance dans la saison, jusqu'au pic des couleurs en début octobre, mieux la performance du modèle sera à identifier et à segmenter les couronnes d'arbres. Il est aussi attendu que le changement des couleurs lors de la sénescence des feuilles à l'automne aide à différencier entre les espèces et aide à définir le contour des couronnes, améliorant ainsi la performance du modèle. De plus, puisque les classes qui sont proches au niveau phylogénétique tendent à avoir des traits similaires sur l'imagerie (Onishi et al., 2022), il est attendu que les classes du même genre soient plus souvent confondues entre elles. En d'autres mots, les modèles auraient davantage de difficulté à les différencier due à des apparences similaires sur l'imagerie.

## Méthodologie

Afin de répondre à mes hypothèses et réaliser mes objectifs, nous avons choisi comme site d'étude une partie de la Station de biologie des Laurentides de l'Université de Montréal (SBL), à Saint-Hippolyte. Ce site est caractérisé par une topographie variée, ainsi que plusieurs types de sols (Courchesne & Hendershot, 1989; Savage, 2001). La canopée de cette forêt est composée de plus d'une quinzaine d'espèces d'arbres dont nous avons sélectionné les plus fréquentes pour ensuite les diviser en 14 classes (11 espèces, deux genres et les arbres morts). Le site d'étude, totalisant environ 44 ha, a été divisé en deux sections, une correspondant au jeu de données pour l'entraînement et la validation des modèles et l'autre pour l'inférence des modèles. L'imagerie a été acquise à l'aide d'un drone à sept reprises entre la fin mai et début octobre 2021. Cette résolution temporelle de l'imagerie nous a permis d'avoir des données allant de la fin du printemps (fin mai)

jusqu'au pic des couleurs à l'automne (début octobre). De plus, les images ont une très haute résolution spatiale (entre 1.8 et 2 cm/pixel), permettant de distinguer les détails des couronnes d'arbres. Avec ces images, nous avons créé des orthomosaïques pour chacune des dates à l'aide d'un logiciel de photogrammétrie, ce qui permet d'avoir une vue d'ensemble sur le site d'étude. En utilisant ces orthomosaïques et un récepteur GNSS avec une précision submétrique, nous avons parcouru la totalité du site d'étude et nous avons annoté 23 000 couronnes d'arbres à l'espèce sous forme de points sur un logiciel SIG. Ces points nous ont permis ensuite de délimiter la forme des couronnes, créant ainsi une couche de polygones qui peut être utilisée aux sept dates. Ceci nous a permis d'avoir la position précise des couronnes d'arbres ainsi que leur espèce et leur étendue spatiale, formant le jeu de données pour l'entraînement des modèles. Après avoir fait le tuilage des orthomosaïques et des annotations, nous avons entraîné sept modèles différents (un par date d'acquisition de l'imagerie) de type U-Net, des architectures faisant partie de la classe des CNNs. Afin d'évaluer la performance des modèles, nous avons utilisé la métrique F1-score et nous avons aussi représenté la précision des modèles avec des matrices de confusion. En comparant les F1-score et les valeurs dans les matrices de confusion pour chaque classe et chaque date, nous avons été en mesure de déterminer l'effet de la phénologie de ces espèces d'arbres de milieux tempérés sur la performance d'un modèle d'apprentissage profond.

Les résultats obtenus suite à la complétion de ce projet de maîtrise sont présentés dans le deuxième chapitre de ce mémoire sous forme d'article qui est disponible en format pre-print à Biorxiv (Cloutier et al., 2023a) et qui sera soumis à la revue *Remote Sensing of Environment*. Les autrices.eurs qui ont participé à l'élaboration du projet et du manuscrit sont Myriam Cloutier, Etienne Laliberté et Mickaël Germain. La première autrice a effectué le travail de terrain, l'analyse des données, l'entraînement des modèles et la rédaction du manuscrit. Etienne Laliberté et Mickaël Germain ont supervisé le projet et commenté et corrigé le manuscrit.

# **Chapitre 2 – Influence of Temperate Forest Autumn Leaf Phenology on Segmentation of Tree Species from UAV Imagery Using Deep Learning**

Myriam Cloutier<sup>1\*</sup>, Mickaël Germain<sup>2</sup>, Etienne Laliberté<sup>1</sup>

<sup>1</sup> Institut de recherche en biologie végétale, Département de sciences biologiques, Université de Montréal, Université de Montréal, 4101 Sherbrooke Est, Montréal, Québec, Canada H1X 2B2

<sup>2</sup> Centre d'applications et de recherches en télédétection (CARTEL), Département de géomatique appliquée, Université de Sherbrooke. 2500, boulevard de l'Université, Sherbrooke, QC, J1K 2R1, Canada

\*Corresponding author: contact [myriam.cloutier.4@umontreal.ca](mailto:myriam.cloutier.4@umontreal.ca)

## **Avant-propos**

Le jeu de données généré et utilisé dans cet article est disponible en ligne, sur Zenodo (Cloutier et al., 2023b). L'article est disponible en ligne sur Biorxiv (Cloutier et al., 2023a) et sera soumis à la revue *Remote Sensing of Environment*.

## **Abstract**

Remote sensing of forests has become increasingly accessible with the use of unoccupied aerial vehicles (UAV), along with deep learning, allowing for repeated high-resolution imagery and the capturing of phenological changes at larger spatial and temporal scales. In temperate forests during autumn, leaf senescence occurs when leaves change colour and drop. However, the influence of leaf senescence in temperate forests on tree species segmentation using a Convolutional Neural Network (CNN) has not yet been evaluated. Here, we acquired high-resolution UAV imagery over a temperate forest in Quebec, Canada on seven occasions between May and October 2021. We segmented and labelled 23,000 tree crowns from 14 different classes to train and validate a CNN for each imagery acquisition. The CNN-based segmentation showed the highest F1-score (0.72) at the start of leaf colouring in early September and the lowest F1-score (0.61) at peak fall colouring in early October. The timing of the events occurring during senescence, such as leaf colouring and leaf fall, varied substantially between and within species and according to environmental conditions, leading to higher variability in the remotely sensed signal. Deciduous and evergreen tree species that presented distinctive and less temporally-variable traits between individuals were better classified. While tree segmentation in a heterogenous forest remains challenging, UAV imagery and deep learning show high potential in mapping tree species. Our results from a temperate forest with strong leaf colour changes during autumn senescence show that the best performance for tree species segmentation occurs at the onset of this colour change.

## **1. Introduction**

Monitoring vegetation and detecting changes in biodiversity is critical for understanding the effects of climate change on plant species distribution and ecosystem health (He et al., 2011; Nagendra et al., 2013; Onishi et al., 2022). Improved knowledge and data on forest dynamics are needed for efficient and sustainable management of these ecosystems (Fassnacht et al., 2016; Goodbody et al., 2019; Lausch et al., 2017). To acquire these data, spatially explicit data on forest stands need to be produced periodically and ideally at the individual tree level (Korpela & Tokola, 2006; Natesan et

al., 2020). However, identifying individual tree species can be difficult depending on the complexity of the forest and the variability of the traits of the target species (Fassnacht et al., 2016; Natesan et al., 2020; Zhang et al., 2022). Moreover, traditional methods used for field surveys in forests are limited to small spatial extents, are time-consuming and labour-intensive, and can be very expensive, especially in remote regions. These factors make it challenging to conduct repeated forest surveys (Beloiu et al., 2023; Goodbody et al., 2019; Veras et al., 2022).

Remote sensing, specifically from unoccupied aerial vehicles (UAVs), has been identified in recent years as a tool capable of addressing these challenges and benefiting research in plant ecology and forestry (Cavender-Bares et al., 2022; de Lima et al., 2022; Lechner et al., 2020). Forests that require monitoring and management will increasingly benefit from remote sensing with UAVs (Dainelli et al., 2021). The many advantages of UAVs compared to on-the-ground field surveys have led to an increase in their use in ecology, resulting in an increase in available data, as well as higher diversity of these data (e.g. spatial, temporal and spectral; Kattenborn et al., 2021). UAVs are flexible, increasingly accessible, and inexpensive, enabling the acquisition of multi-temporal data for tree species in heterogeneous forests (Klosterman & Richardson, 2017; Komárek, 2020; Veras et al., 2022). UAVs also have the potential to acquire very high spatial resolution RGB imagery, making it possible to see detailed characteristics in the tree crowns, such as leaf and canopy shape and branching patterns (Fassnacht et al., 2016; Kattenborn et al., 2019; Natesan et al., 2020). High spatial resolution is necessary for these patterns to be visible in the imagery and can thus help to identify tree species using recent computer vision approaches (Schiefer et al., 2020).

High-resolution UAV data require methods that can extract the complex features present in the imagery. Recently developed deep learning algorithms have been used to process the imagery by efficiently extracting the features present in forest canopies to map vegetation with high accuracy (Brodrick et al., 2019; Katal et al., 2022; Veras et al., 2022). Convolutional Neural Networks (CNN), a type of deep learning algorithms, are capable of extracting complex spatial information about objects of interest from the imagery (Kattenborn et al., 2021), as well as the spatial context surrounding object of interest (Korznikov et al., 2021). When acquired repeatedly across a growing season, UAV imagery data combined with deep learning can also leverage species-specific phenological patterns (Veras et al., 2022). CNNs were specifically developed to analyze spatial

patterns, making them highly effective when using high spatial resolution remote sensing data for spatial prediction problems by leveraging higher detail in the imagery (Fricker et al., 2019; Kattenborn et al., 2019; Schiefer et al., 2020). Other advantages of using CNNs on remote sensing RGB imagery is the high classification accuracy, which can approach and even surpass human vision in certain situations, but that can be rapidly applied to a large extent in an automatic fashion (Brodrick et al., 2019). This can allow for rapid mapping of trees at the species-level over large extents, provided that sufficient spatially explicit reference data is available (Kattenborn et al., 2019; Weinstein et al., 2019).

Despite the increasing accessibility of UAVs and deep learning methods, identifying tree species from UAV imagery remains a challenge in natural, heterogeneous forests (Fassnacht et al., 2016; Zhang et al., 2022). Some studies have successfully mapped tree species in heterogeneous forests in temperate regions (Beloiu et al., 2023; Gan et al., 2023; Schiefer et al., 2020) and tropical regions (Braga et al., 2020; Veras et al., 2022) using a combination of high-resolution RGB imagery from UAVs with deep learning. However, challenges remain in complex mixed-species forest canopies due to overlapping crowns and diverse crown structure, especially when it comes to individual tree crown segmentation (Zhang et al., 2022). To potentially overcome this challenge, many researchers have suggested the use of multi-temporal imagery (Hill et al., 2010; Veras et al., 2022; Yang et al., 2017). However, these studies include different phenological events in the training dataset without knowing which aspects of the vegetation may influence the accuracy (Kattenborn et al., 2021; Yang et al., 2019; Zhang et al., 2018), limiting our efficiency in leveraging phenological information to classify tree species.

Phenology is defined as the timing of seasonal events. Foliar phenology in particular can be used to differentiate between tree species and increase classification accuracy (Fassnacht et al., 2016; Nagendra et al., 2013), as leaves are the most prominent organs that are captured in aerial imagery. Consequently, foliar phenological characteristics of tree species can be particularly useful for tree species classification in complex tree canopies. When training a CNN, the amount of reference data needed can be reduced by harnessing these species-specific phenological patterns that increase the contrast between classes of interest (Kattenborn et al., 2021; Veras et al., 2022). Specifically, in autumn, leaf senescence is the phenological event during which leaves age due to a decline in function which is triggered by a systemic response in the plant, causing leaves to change colours

before falling (Gallinat et al., 2015; Zani et al., 2020). However, when compared to research focusing on spring phenology, autumn phenology has received significantly less attention (Zani et al., 2020). This can be attributed to the higher complexity regarding the drivers of senescence and its unpredictable timing year-to-year (Gallinat et al., 2015; Katal et al., 2022). Additionally, leaf senescence exhibits a greater interspecies variation than for spring phenology, such as for leaf budding and leaf unfolding (Budianti et al., 2021). This makes it challenging to select an appropriate date for acquiring UAV imagery to capture leaf senescence across many tree species.

More broadly, further research is needed at a high resolution on large scales on tree autumn coloration, an important phenomenon found in temperate forests Northeastern North America, Europe and Asia (Renner & Zohner, 2019). This bright display of red, orange and yellow autumn leaf colours in these temperate regions could be affected by changing global temperatures and should be included in climate change models (Norby et al., 2003). In fact, many authors who have investigated the use of UAV and deep learning for mapping tree species in temperate forests mention a need for studies examining the effects of phenology on these methods (Beloiu et al., 2023; Gan et al., 2023; Korznikov et al., 2021; Nuijten et al., 2019). Generally, there is a need for additional research aimed at identifying tree species traits that could help or hinder classification accuracy of a CNN model (Fassnacht et al., 2021; Onishi & Ise, 2021).

In this study, we assessed the influence of autumn phenology on the task of segmenting tree species from high-resolution UAV RGB imagery in a temperate mixed forest in Eastern Canada, using deep learning. To do so, we trained seven separate CNNs using imagery from seven UAV acquisitions over the same forest during the 2021 growing season, using a large reference dataset in which 23,000 individual tree crowns were segmented and annotated to species at the tree level. We evaluated the performance of the different CNN models for each species and each date. We hypothesized that the model trained with the imagery taken during peak autumn colour (i.e. early October) would perform the best out of the entire growing season. We expected the colour change to help differentiate between species and to highlight the contours of the crowns. We also hypothesized that tree classes that were closer to one another phylogenetically (i.e. tree species within the same genus) would show a higher degree of confusion in the predictions because of similar foliar traits. Overall, our aim was to evaluate the change in performance of a CNN in segmenting 14 classes (11 tree species, two genera and dead trees) according to the timing in the

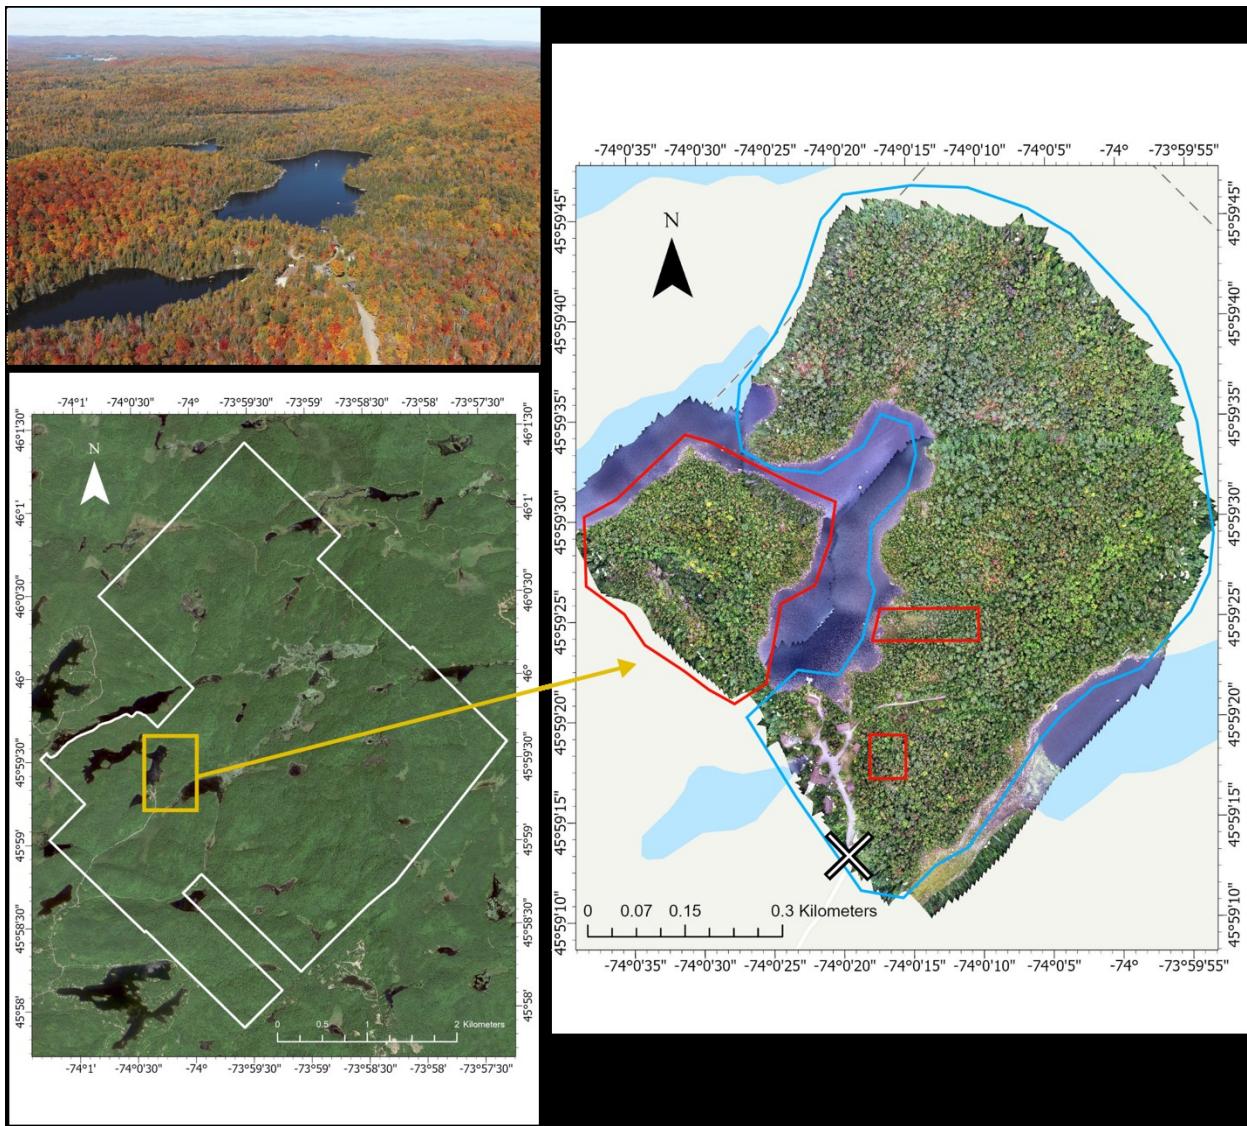
growing season, and to determine some of the characteristics of the tree species that would explain the differences in performance, specifically leaf senescence and other species-specific traits, such as colour, texture, and shape.

## 2. Methods

### 2.1 Study site

The study was conducted in a mixed temperate forest in Quebec, Canada. The study site is located within the research station of Université de Montréal in Saint-Hippolyte ( $45^{\circ}59'17.34''$  N /  $74^{\circ}0'20.75''$  W, Figure 2). The site has a diverse topography, with hills, cliffs, and valleys, bringing a range of different forest types and environmental conditions within the study area. The study area is mostly covered by unmanaged mixed temperate forest, which includes a variety of deciduous and evergreen tree species, as well as a small bog and many lakes. The area has been affected by disturbances in the last century, such as logging and medium to low intensity fires, before becoming a research station in 1965 (Savage, 2001). The most common tree species that form the canopy are *Betula papyrifera* Marshall, *Acer rubrum* L., *Populus grandidentata* Michaux and *Acer saccharum* Marshall (Savage, 2001).

The study area was divided into a training and validation site and a test site, totalling about 44 ha. The imagery for the training and validation site was acquired using two different flights due to the drone's maximum flight time and a third flight was done for the imagery for the test site. The three flights were taken near the middle of the day, before and after noon, to minimize changes in light conditions. Regarding the division of the area, we selected the largest area as the training site because it contained most of the tree crowns in our dataset. The test site was chosen because it was physically separated from the training site with a lake while containing enough tree crowns for inference and model performance evaluation. This separation of the training site and the test site was done to minimize spatial autocorrelation between the two datasets (Kattenborn et al., 2022).



**Figure 2 Map of the study site in Saint-Hippolyte, Quebec, Canada**

The biological research station is delineated in white. The study site used for training and validation is delineated in blue and the test site is in red. The two sections used for the test dataset (smaller polygons in red within the blue polygon) were excluded from the training and validation dataset and served to assure all classes were present in both datasets. The photography at the top was taken from the position marked with an X and shows the study site. Projection: WGS84 UTM Zone 18N (EPSG:32618). Satellite imagery from Google Earth (2019).

## 2.2 Datasets

### 2.2.1 Drone imagery

The imagery was acquired using a UAV, a DJI Phantom 4 RTK aircraft (DJI Science and Technology Co. Ltd., Shenzhen, China). This UAV is equipped with a Real Time Kinematic (RTK) GNSS receiver which is synchronized with the inertial measurement unit (IMU) and the camera, allowing for direct georeferencing of each photo (Kalacska et al., 2020; Taddia et al., 2019). The imagery was acquired 60 meters above the canopy. To maintain a constant distance between the UAV and the canopy across the study area, we used DJI's Terrain Follow Mode using a 1-m LiDAR-derived digital surface model as our reference (Gouvernement du Québec, 2021).

The imagery was acquired seven times in 2021, at a rate of one acquisition per month from May to August 2021, and three acquisitions for September and October during the period of leaf senescence. We selected these dates to have a temporal resolution that allowed us to see the changes in foliage during the growing season, as well as the faster rate of change in leaf colour in autumn. We acquired the imagery on days during which the acquisition would not be affected by strong wind or rain. However, the light conditions varied from one imagery to the other, ranging from overcast conditions, to passing clouds, to full sun (Supplementary Figure S1). The imagery with poorer light conditions (i.e., lower cloud coverage) were of good quality, so we did not adjust the images to homogenize the light conditions. To ensure the imagery was well georeferenced, we positioned 25 ground control points (GCPs) throughout the area. The coordinates of the ground control points were then measured using two Emlid Reach RS2 RTK GNSS receivers, one as a base on a geodetic marker and one as a rover.

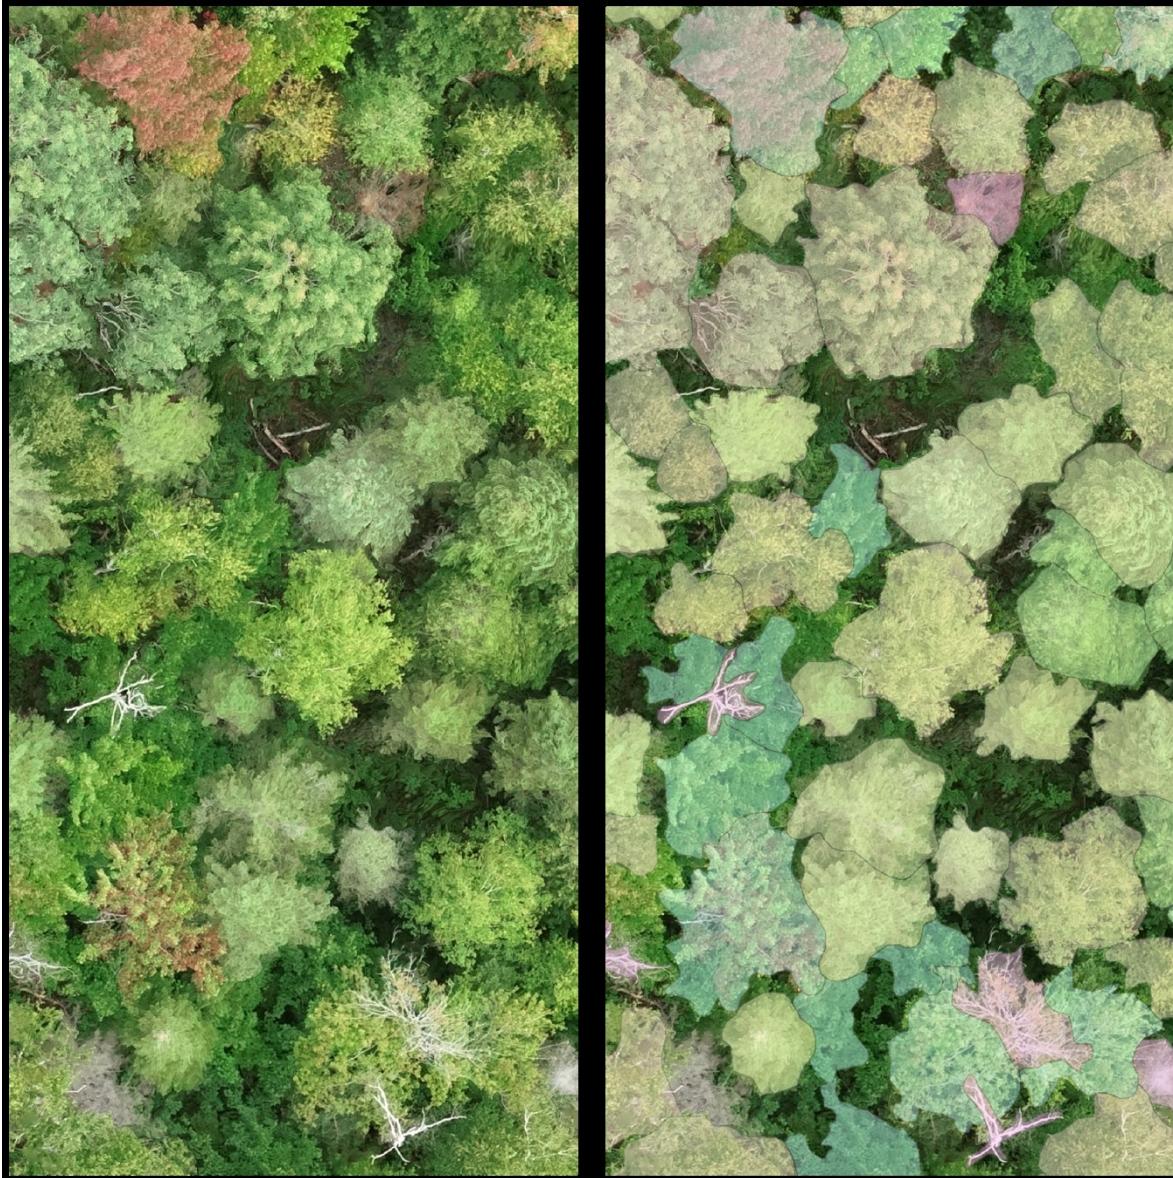
The aerial imagery was processed using Agisoft Metashape Professional v.1.7.5 (Agisoft, 2021) to generate orthomosaics using Structure from motion photogrammetry. Three orthomosaics were made for each of the dates, according to the drone flights (two for training site and one for testing site), totalling 21 orthomosaics. These orthomosaics had a ground sampling distance between 1.81 and 2.02 cm. The protocol used to generate the orthomosaics was adapted from Over et al. (2021). We started by importing and aligning the drone photos and importing the GCPs coordinates into Metashape to precisely georeference the images. We then created a dense point cloud using the tie points created during the image alignment. We set our parameters to aggressive filtering and medium density to create the dense point cloud. This approach made it smoother and helped avoid

local artefacts and noise when using the dense point cloud to build the digital elevation models (DEM), which were then used to build the orthomosaics by projecting the images onto the DEM.

### 2.2.2 Annotations

We conducted a field survey the same summer the imagery was taken, in 2021. Using an Arrow 100 submeter GNSS receiver (EOS Positioning Systems, Inc. Terrebonne, Canada) and a Windows Surface Pro tablet, we generated a label for each tree crown on the orthomosaics in the form of a point directly in the field. This was done using ArcGIS Pro (ESRI Inc., 2021) from which we could visualize an orthomosaic and assign the labels using a point layer. The Arrow 100, connected to the tablet, allowed us to locate ourselves on the orthomosaic to minimize labelling errors. In ArcGIS Pro, the points were then used to create polygons delineating the tree crowns individually according to the class assigned during the field survey (Figure 3). In total, we delineated 23,000 tree crowns. The parts of the imagery we did not annotate were classified as background, mainly forest floor, herbaceous vegetation, rocks, water, and buildings. This also includes trees from the classes we were interested in, but for which the crowns were not clear enough to delineate due to overlapping crowns or blurriness in the orthomosaic or that have not been annotated during the field survey.

The polygons delineating the tree crowns were only drawn using the orthomosaic that was the clearest (i.e diffuse light conditions, minimal artefacts, leaves still on), which was the imagery taken on September 2<sup>nd</sup>, 2021. We decided to create a single layer of polygons instead of one layer per imagery due to the very long time it took to complete the annotations. Since the orthomosaics were very accurately georeferenced (generally <3 cm error), the polygons could be applied to the other dates with minimal shifts (Supplementary Figure S2). We did not adjust the polygons for the different dates to account for fallen trees or other major changes as we considered such changes to be relatively rare and would thus not affect the overall quality of our dataset.

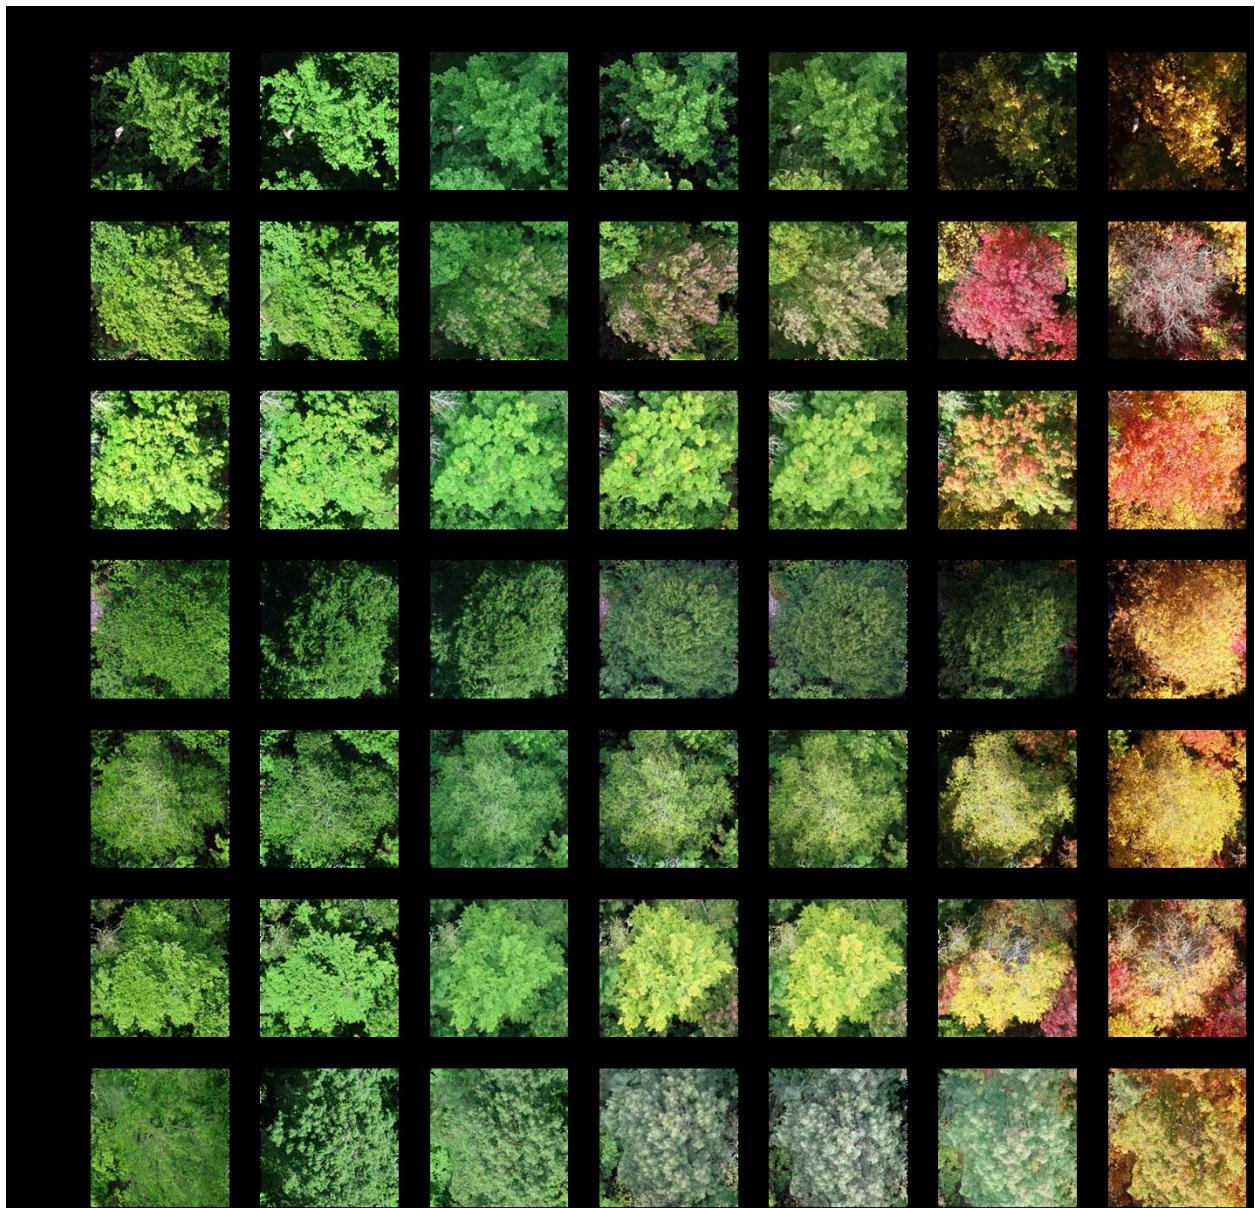


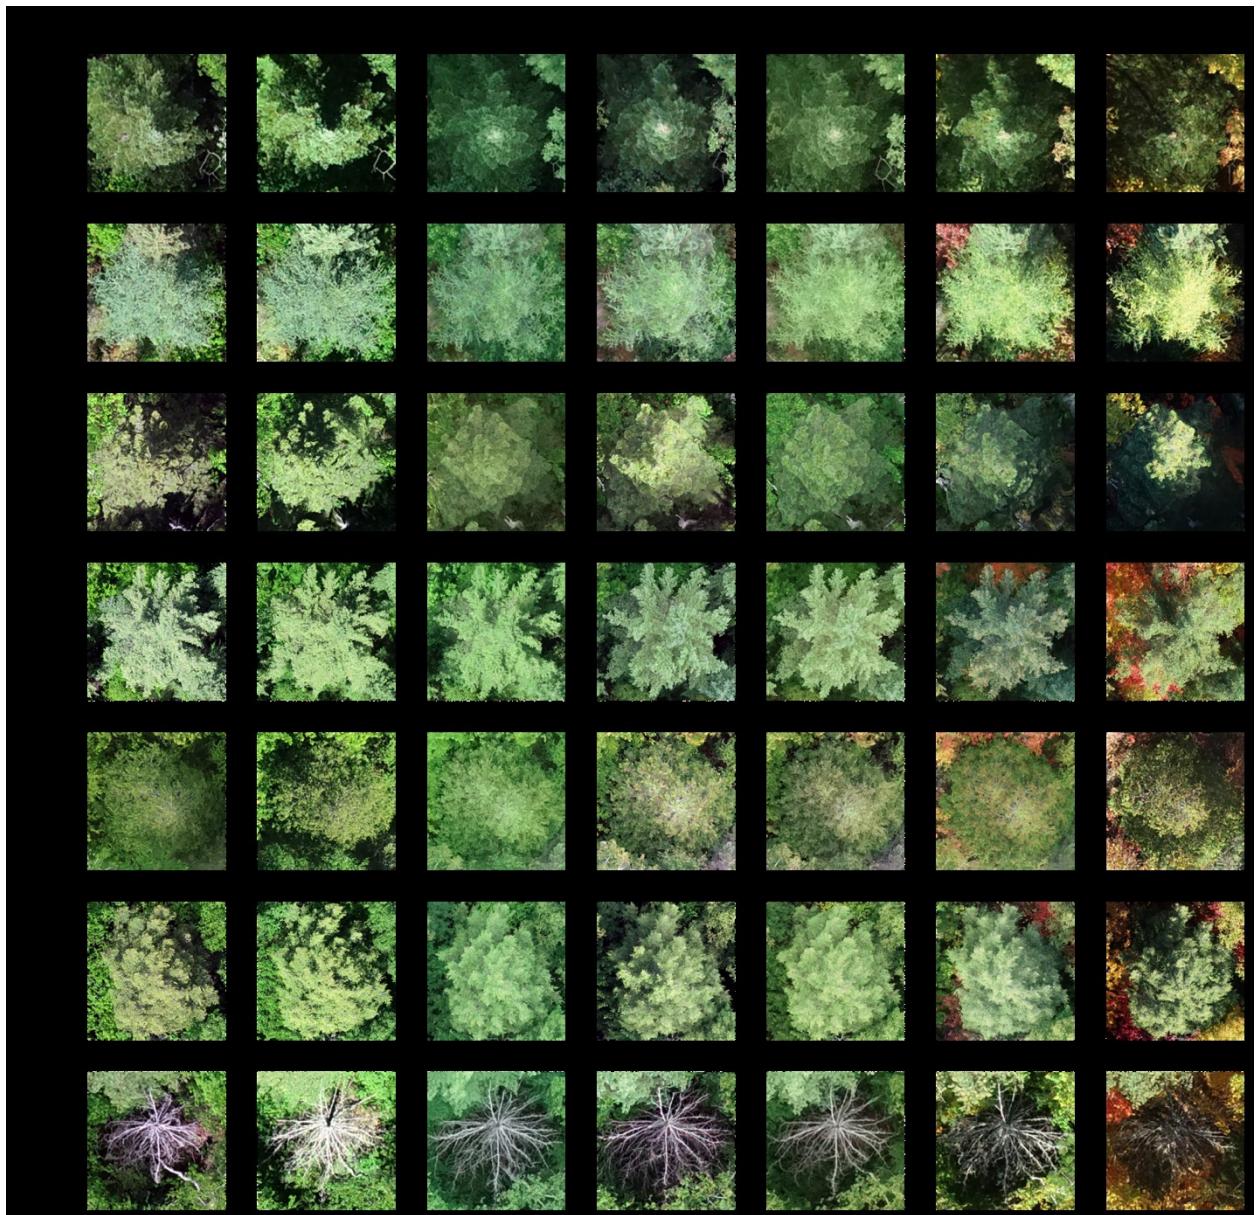
**Figure 3 Image of the annotations from the dataset**

On the left is a section of the orthomosaic representing the canopy of the forest on the 2<sup>nd</sup> of September. On the right are the annotations segmenting the tree crowns on the orthomosaic.

The classes used are presented in Figure 4. These 14 classes represent the crowns that were the most abundant at the top of the canopy. The proportion of the area covered by each species for the training and test sites is shown in Table 1. Most of the classes (11) are at the tree species level, two of them are at the genus level and there is also one class for dead trees. The dataset includes six

classes representing conifers and seven classes representing deciduous broadleaf species. In the analyses and the discussion, *Larix laricina* (Du Roi) K. Koch, a deciduous conifer, has been included with the evergreen conifers as the imagery stops before the senescence starts for this species.





**Figure 4 Example of the fourteen classes from the seven orthomosaics (May to October)**  
The first half represents the seven broadleaf species, and the second half represents the six conifers and the dead trees. The same crown is shown for each species from May to October.

#### 2.2.3 Data splitting and tiling

To train a semantic segmentation model, the orthomosaics and the polygons need to be separated into regular tiles and masks. The tiles correspond to a section of the orthomosaic and the mask to the related annotations. We ran the tiling of the orthomosaics and the annotations in R (R Core

Team, 2021) where we created a grid covering the entire area and selected tiles where at least 25% of the surface was covered by annotations. This avoided including in the dataset regions where the orthomosaic was not clear enough to annotate. To train our models, we chose non-overlapping tiles of 256 x 256 pixels based on the results from Schiefer et al. (2020), which corresponds to approximately 5 x 5 m on the ground. Examples of such tiles and associated masks are shown in Supplementary Figure S3.

The tiles in the training site were randomly divided between training data (80%) and validation data (20%). The tiles in the test dataset (approximately 20% of the entire dataset) contained the annotations from the test site as well as some annotations from the training site (which were excluded from the training data) to balance the classes (Figure 2). This was done because some of the less abundant species were all present in the training site, but not in the test site. The data used is available online.

### 2.3 Deep learning model and training

The type of model used for training is a CNN, specifically a U-Net (Ronneberger et al., 2015), which is a semantic segmentation algorithm. We chose U-Net as our architecture because of its success in other individual tree classification problems (James & Bradshaw, 2020; Korznikov et al., 2021; Schiefer et al., 2020; Wagner et al., 2019). We trained one model for each date and evaluated the performance of this model on the test data from the same date, data that was not used for training. We did not apply models trained on one date to other dates as this was out of the scope of the study. The parameters used for training were the same for all models {batch: 14, learning rate: 0.001, epochs: 60, optimizer: Adam}. We utilized data augmentation techniques, which increases the number of tiles used to train the model, to enhance the robustness of our dataset and to account for the high heterogeneity. Specifically, we applied random rotations with a probability of 0.5, along with horizontal and vertical flips with a probability of 0.75, directly on the batch dataset.

All the code for the training and the testing was written in Python (Python Software Foundation) using the fast.ai library (Howard & Gugger, 2020a). The fast.ai library is a high-level library for deep learning models based on PyTorch. While it limited us regarding certain parameters, it

allowed us to train the models using a more accessible workflow (Howard & Gugger, 2020b). We ran the code on Google Colab Pro+ which gave us access to NVIDIA A100 Tensor Core GPUs.

## 2.4 Accuracy assessment

To assess the performance of the models, we used the F1-score. This metric is calculated by taking the harmonic mean of the precision and recall (Equation 1). The recall represents the proportion of actual presences that were correctly classified, and the precision represents the proportion of predicted presences that were classified correctly. When applied to the test dataset, we extracted the F1-score for each of the classes and calculated the average per date and per class.

$$F1 = \frac{2 \times precision \times recall}{precision + recall} \quad (1)$$

We then represented the accuracy of the predictions using confusion matrices by calculating the overlap between the annotations and the predictions from the model and calculating the percentage. The confusion matrices allowed us to see which pixels were misclassified and between which classes for the different dates. By comparing the confusion matrices and the F1-scores, we could determine how the phenology of each species during the growing season can affect the performance of the models.

# 3. Results

## 3.1 Model results

The model that showed the highest overall average F1-score (0.72) was trained on imagery from early September. The second-best model was trained with imagery from August, with an F1-score of 0.66. The other models showed an average F1-score between 0.65 and 0.61. The model trained on the October imagery had the lowest F1-score, with 0.61.

The classes with the highest F1-scores are *L. laricina*, *P. strobus*, and *Populus* spp. *Pinus strobus* had the highest average F1-score for all the dates. The F1-scores for *P. strobus* range between 0.77 and 0.87, where the lowest scores were from the models trained with the imagery taken in late

September and October. The classes with the lowest F1-scores were *A. pensylvanicum*, *F. grandifolia* and *Betula alleghaniensis*. *Acer pensylvanicum* had the lowest overall average F1-score for all dates. The F1-scores for *A. pensylvanicum* ranged between 0.36 and 0.61.

When comparing the deciduous broadleaf species and the evergreen species (including *L. laricina*, which we grouped with the evergreen trees), general trends regarding the variation of the F1-score throughout the growing season can be seen between the classes from each group (Table 1, Supplementary Figure S4). The evergreen trees showed less variability in their F1-score through time, and they all showed similar trends, except for *P. strobus* and *L. laricina* which had higher F1-scores overall. *Tsuga canadensis* had a lower score for the imagery from late September and October. As for the deciduous broadleaf classes, *Populus* spp. and *B. papyrifera*, the first and second best predicted deciduous classes, have trends very similar to the ones seen in the evergreen classes. *Acer pensylvanicum* and *F. grandifolia*, the two worst predicted deciduous classes, along with *B. alleghaniensis* have more variability in their score and different trends from any other class. *Betula alleghaniensis* is the only deciduous class with an increase in its F1-score in October. Three of the deciduous classes, *Populus* spp., *B. papyrifera* and *A. rubrum*, have higher scores in September (early and late) compared to the rest of the dates. *Acer pensylvanicum*, *A. rubrum*, *A. saccharum* and *F. grandifolia* showed a decline in their F1-score from the predictions done on the imagery from late September and October.

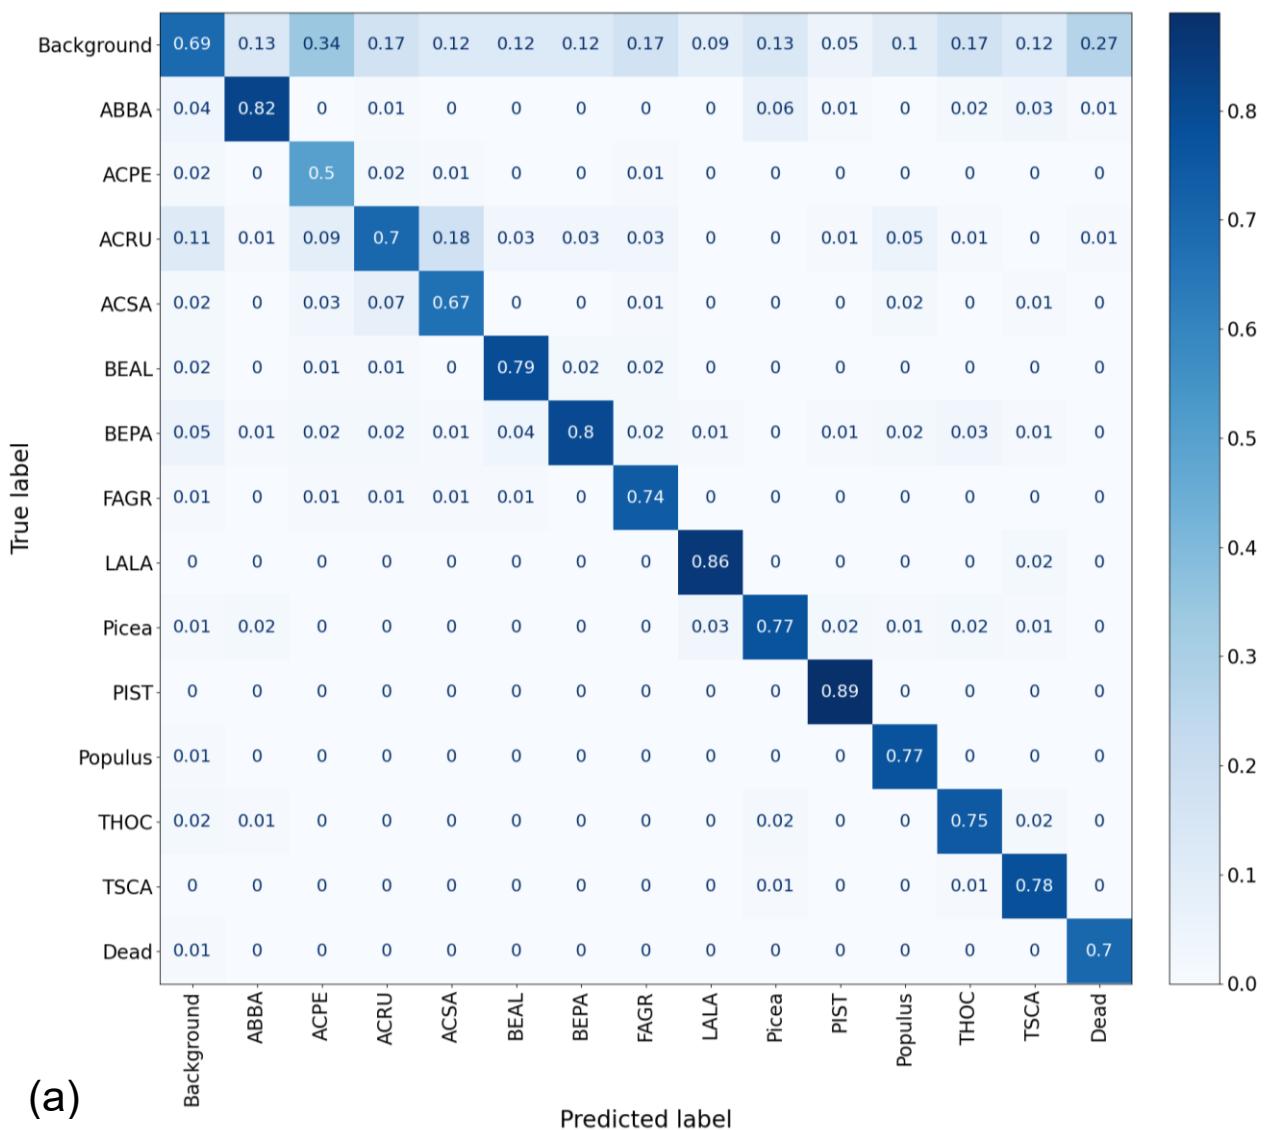
**Table 1** F1-score for the models for each class at each date.

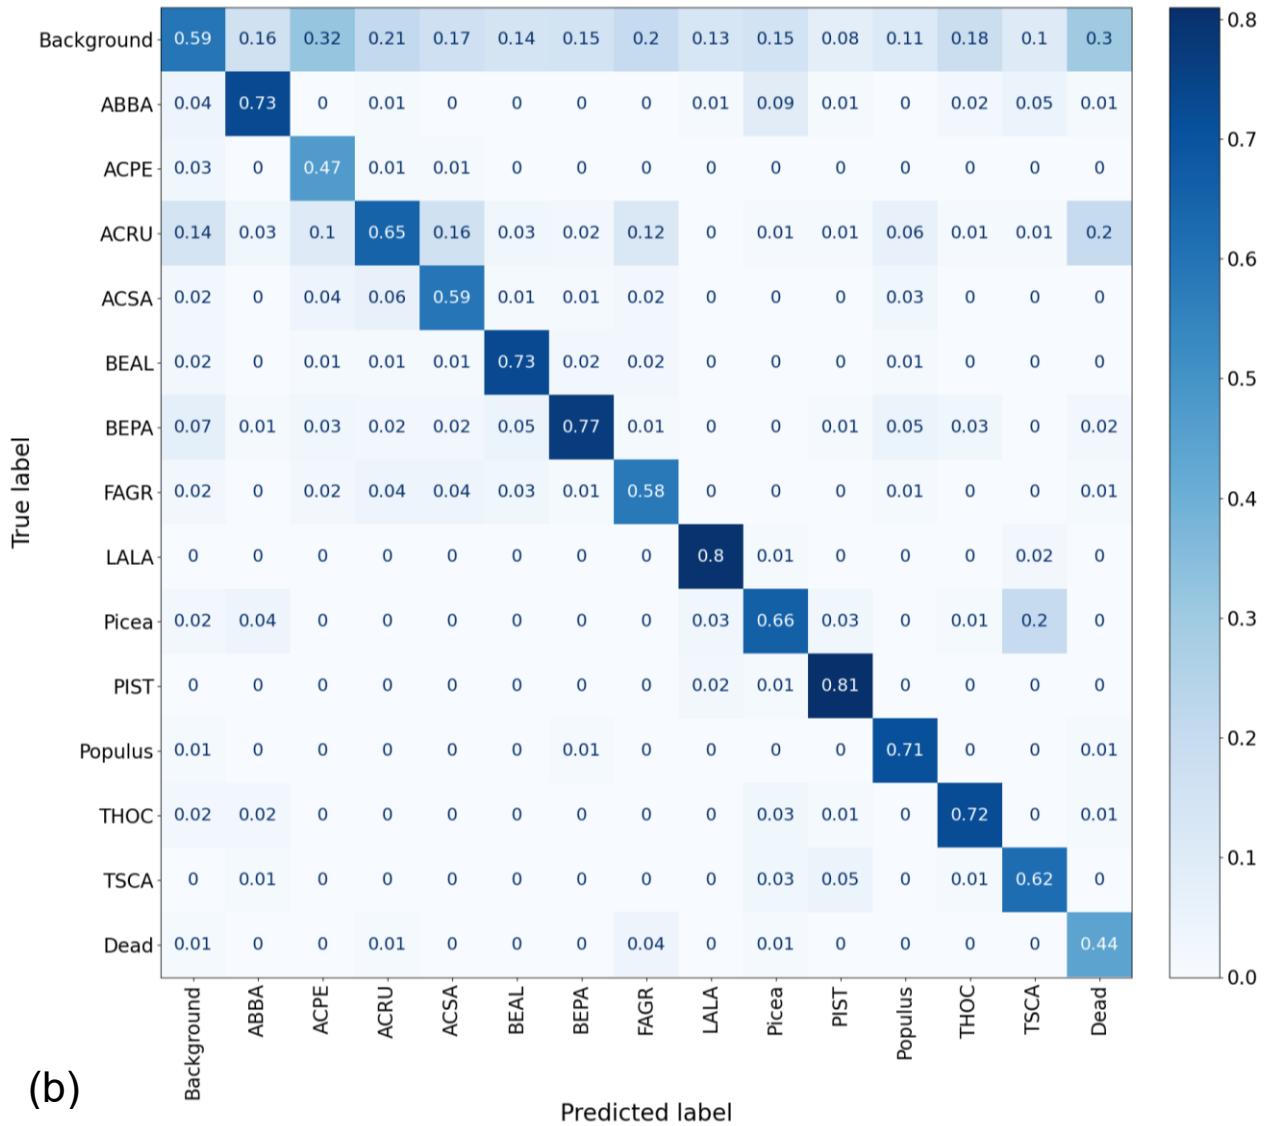
This represents the performance of the trained model after applying it to new independent imagery (test dataset). The highest F1-score for each date is in bold. The highest average F1-score for the dates and classes is also in bold.

F1-score	Proportion of pixels (%)	Date							Average F1-score
		2021-05-28	2021-06-17	2021-07-21	2021-08-18	2021-09-02	2021-09-28	2021-10-07	
<i>Abies balsamea</i>	5.1	0.69	0.68	0.64	0.69	0.74	0.66	0.63	0.68
<i>Acer pensylvanicum</i>	1.8	0.61	0.55	0.52	0.41	0.54	0.45	0.36	0.49
<i>Acer rubrum</i>	23.1	0.61	0.61	0.57	0.62	0.64	0.63	0.55	0.60
<i>Acer saccharum</i>	7.2	0.60	0.59	0.57	0.61	0.60	0.64	0.54	0.59
<i>Betula alleghaniensis</i>	2.6	0.53	0.65	0.62	0.69	0.74	0.63	0.66	0.65
<i>Betula papyrifera</i>	31.1	0.69	0.70	0.68	0.71	0.79	0.73	0.72	0.72
<i>Fagus grandifolia</i>	1.3	0.59	0.52	0.56	0.60	0.71	0.43	0.39	0.54
<i>Larix laricina</i>	0.5	<b>0.80</b>	<b>0.81</b>	0.75	<b>0.80</b>	0.79	0.73	0.75	0.77
<i>Picea spp.</i>	2.2	0.69	0.67	0.61	0.67	0.73	0.69	0.65	0.67
<i>Pinus strobus</i>	6.3	0.76	0.79	<b>0.79</b>	0.75	<b>0.87</b>	<b>0.77</b>	<b>0.77</b>	<b>0.79</b>
<i>Populus spp.</i>	13.5	0.72	0.76	0.72	0.75	0.83	<b>0.77</b>	<b>0.77</b>	0.76
<i>Thuja occidentalis</i>	3.2	0.66	0.66	0.65	0.66	0.72	0.68	0.64	0.67
<i>Tsuga canadensis</i>	0.3	0.65	0.63	0.61	0.66	0.75	0.61	0.53	0.63
Dead tree	1.6	0.54	0.57	0.54	0.61	0.62	0.54	0.52	0.56
Average F1-score		0.65	0.65	0.63	0.66	<b>0.72</b>	0.64	0.61	

### 3.2 Predictions errors in confusion matrices

The diagonal in the confusion matrices (Figure 5) corresponds to the true positive for each class. These values were high, meaning the label for most of the predicted pixels corresponds to the label of the annotated pixels. This is the case for the matrices comparing the predictions to the annotations for each of the seven dates (Supplementary Figure S5).





**Figure 5 Confusion matrices for early September and October**

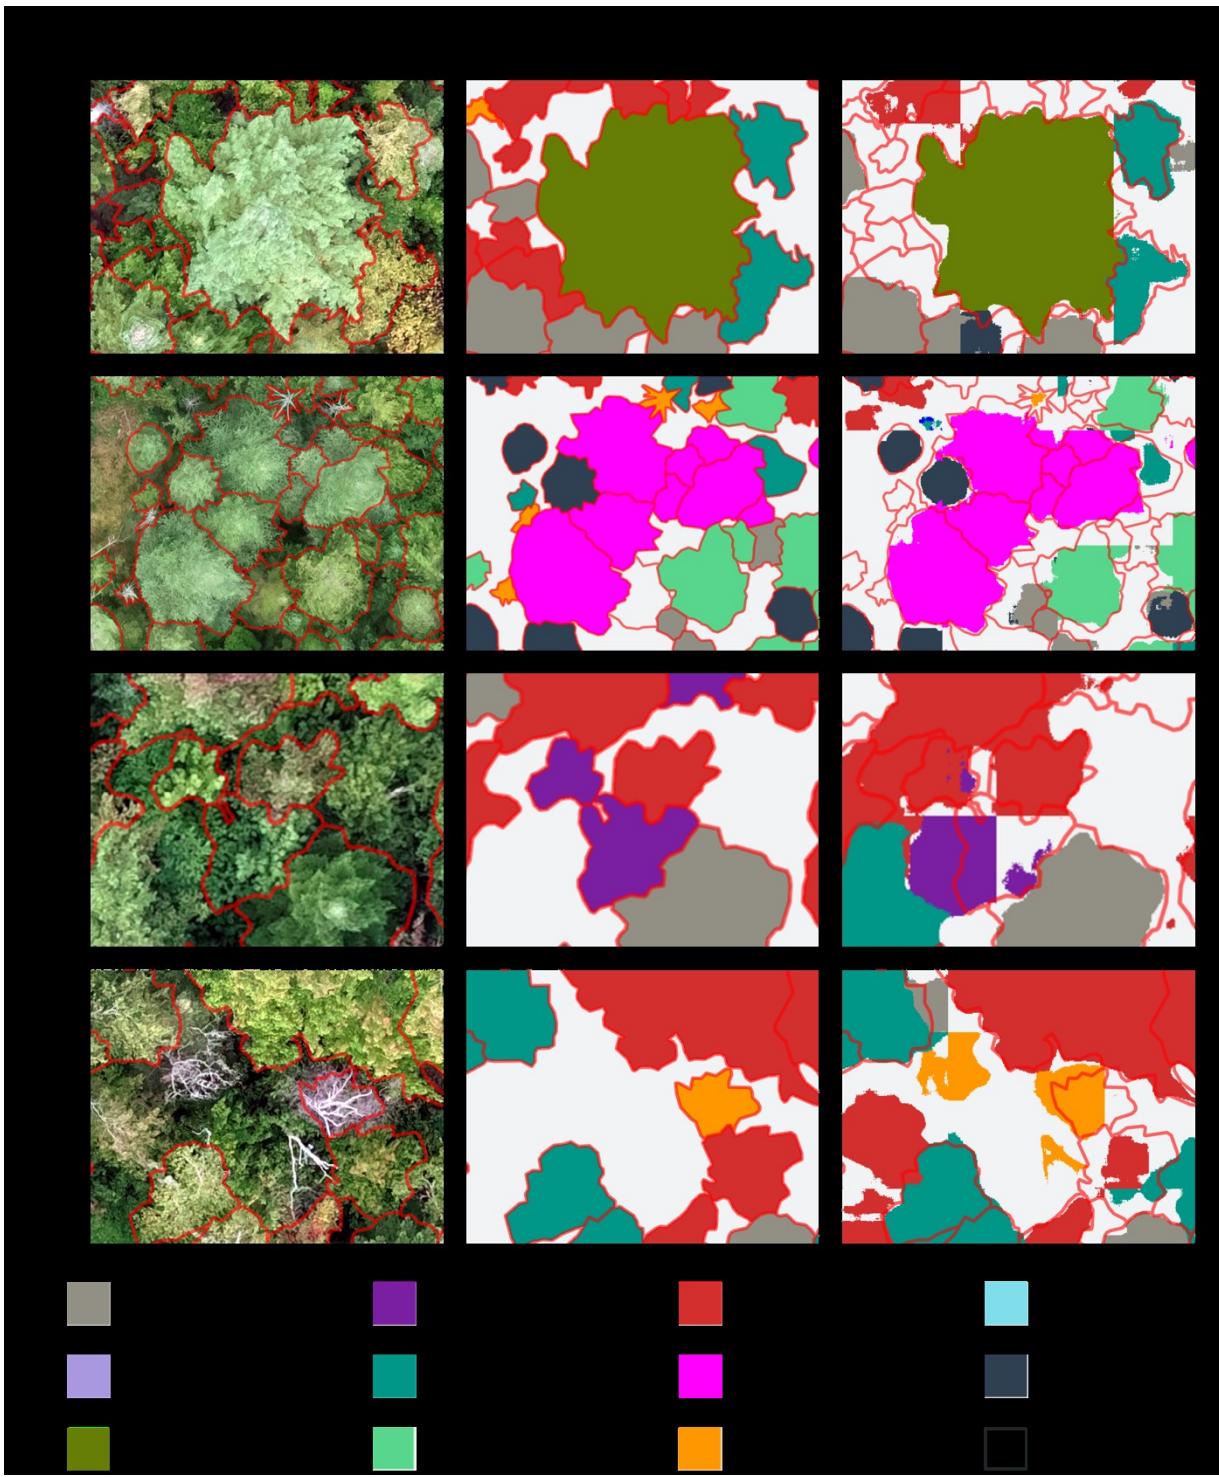
The values represent the overlap (from 0-1) between the annotations (true label) and the predictions (predicted label) done by the model on unseen imagery from (a) September 2<sup>nd</sup>, 2021, and (b) October 10<sup>th</sup>, 2021. ABBA: *Abies balsamea*, ACPE: *Acer pensylvanicum*, ACRU: *Acer rubrum*, ACSA: *Acer saccharum*, BEAL: *Betula alleghaniensis*, BEPA: *Betula papyrifera*, FAGR: *Fagus grandifolia*, LALA: *Larix laricina*, Picea : *Picea spp.*, PIST: *Pinus strobus*, Populus: *Populus spp.*, THOC: *Thuja occidentalis*, TSCA: *Tsuga canadensis*.

The classes with the highest performances in the matrices were mostly consistent with what was seen with the F1-score in Table 1. *Pinus strobus* (Figure 6a) and *L. laricina* (Figure 6b) had the highest values in the matrices overall, followed by *B. papyrifera* and *A. balsamea*. On the other

hand, *A. pensylvanicum*, dead trees and *F. grandifolia* were the classes with the lowest values in the matrices overall.

In general, the models overestimated the number of pixels for each class, in that predictions for each class included what was labelled as background. This is illustrated in the confusion matrices by larger values in the top row. This overestimation of the number of pixels representing each class can be seen throughout the season.

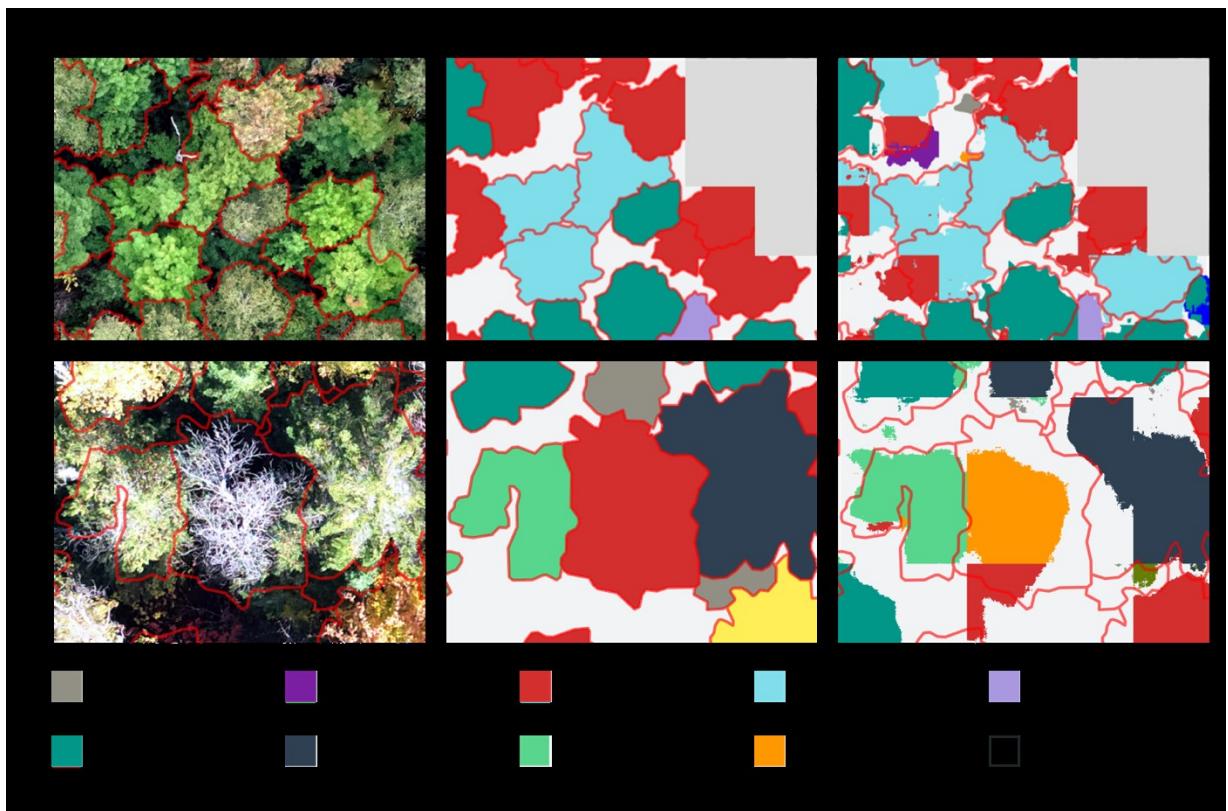
Some classes had consistently lower values of pixels misclassified with background, such as *P. strobus*. Other classes had consistently higher proportions ( $> 27\%$ ), mainly *A. pensylvanicum* and dead trees. As mentioned earlier, *A. pensylvanicum* showed the lowest performance of all the classes. The predictions were less accurate when crowns are surrounded by other vegetation than when the crown is more isolated and distinct from its surroundings (Figure 6c). Dead trees also had a low performance when looking at the values in the confusion matrices. The imagery contained a lot of dead branches along with full crowns and many of the predictions for this class included these single, isolated branches as well as partially dead crowns (Figure 6d).



**Figure 6 Classes with higher and lower performances in the predictions**

The classes with the highest performance in the predictions were (a) *Pinus strobus* and (b) *Larix laricina*. Two of the classes with the lowest performance in the predictions were (c) *Acer pensylvanicum* and (d) dead trees. These predictions were generated by the model trained with the imagery from September 2<sup>nd</sup>, 2021.

The main classes that were misclassified were the maple species, *A. pensylvanicum*, *A. rubrum* and *A. saccharum*. Specifically, pixels labeled as *A. rubrum* in the annotations were often predicted as being *A. saccharum* (Figure 7a) and, to a lesser extent, *A. pensylvanicum*. This difference in the annotations and the predictions is present in similar proportions for all the dates, with only the model trained with the July imagery having a higher proportion of misclassifications between the maples. In a smaller proportion than for the maples, the two birch species were also misclassified where *B. papyrifera* pixels are being predicted as *B. alleghaniensis*. In some cases, classes from different genera were confused by the models as well. *Acer rubrum* was mistaken for *F. grandifolia* for all the dates, but especially in the early-mid part of the summer (June and July) and in the fall (end of September and October). From May to early September, a very small proportion (1-2%) of pixels labelled as *A. rubrum* were predicted as being dead trees. This proportion increased to 10% for the end of September and 20% for October (Figure 7b).



**Figure 7 Classes that showed the highest proportions of misclassifications**

Some classes had high proportions of misclassification with a class other than the background such as (a) the maples, specifically *Acer rubrum* and *Acer saccharum* all throughout the season (example from 2<sup>nd</sup> of September), and (b) *Acer rubrum* often identified as a dead tree in October. The parts in grey in (a) were not included in the training or the testing of the model as the annotations covered less than 25% of the area of those tiles.

## 4. Discussion

Our results showed that semantic segmentation on UAV imagery can accurately classify tree species in a temperate forest, as was previously highlighted in other studies (James & Bradshaw, 2020; Kattenborn et al., 2019; Schiefer et al., 2020). However, our results offer new insights about the temporal variation in tree species classification driven by leaf phenological changes. Contrary to our hypothesis, tree species classification was not more accurate during peak autumn colours (i.e. early October) in this temperate forest. Instead, classification accuracy was highest at the start of the senescence process in early autumn, when autumn foliage colours started to appear (i.e. early September), and was in fact lowest for most species at peak autumn colours in early October. Still, classification accuracy remained relatively high throughout the growing season, even in early summer where tree foliage appeared more uniformly green, among and within tree species. Together, our results provide further evidence of the power of high-resolution UAV imagery and deep learning to classify tree species in temperate forests, but shows how the development of leaf colour during senescence can influence the performance of such classification models.

### 4.1 Lowest accuracy for October imagery

The model trained and tested with the October imagery showed the lowest F1-score out of all the dates. This went against our initial hypothesis, since we expected that imagery at peak autumn leaf colours would give the best predictions. Our results differ from those of previous studies seeking to determine the optimal timing for aerial imagery to differentiate tree species, which concluded that imagery acquired in autumn, when species display the largest colour differences, gave the highest accuracy (Grybas & Congalton, 2021; Hill et al., 2010; Key et al., 2001; Weil et al., 2017). However, in the early and late September models, when leaf colouring had started but was not at its peak, the F1-scores were higher than for the October model. This suggests other aspects of senescence beyond colour change, such as leaf abscission and drop, can also influence tree species classification from UAV imagery. On the imagery from October, it was possible to see the forest floor and vegetation below the canopy through the tree crowns that had lost most of their leaves. This can affect the appearance of the imagery and increase the influence of the background (forest floor, sub-canopy vegetation) within the imagery (Cho et al., 2012). It could also change the crown structure by exposing primary and lateral branches on the imagery (Veras et al., 2022). Together, our results suggest that peak autumn foliage colour does not lead to the highest tree species

classification accuracy from UAV imagery in a temperate forest. Instead, the highest performance was obtained at the start of the senescence process when leaves were just starting to change colour.

We attribute a large part of the drop in accuracy for the October model to the leaf fall that happens during senescence. Deciduous tree species classification accuracy decreased from September to October, particularly for tree species that had then lost most of their leaves, such as *A. rubrum* and *F. grandifolia*. Similarly, this was observed in the Amazonian forest during the dry season, where there was a drop in the CNN accuracy relative to other phenological periods (Veras et al., 2022). The authors associated this decrease in performance with significant leaf drop during the dry season. However, it is important to note that in that Amazonian study as well as ours, species classification accuracies remain high for most deciduous tree species, despite such variation in crown appearance caused by leaf drop.

While some authors have recommended to avoid acquiring imagery when most of the leaves have fallen (Wolter et al., 1995), recent studies using CNNs to map tree crowns suggest that including more leafless trees during training could help the model to generalize to images taken throughout the year (Braga et al., 2020). For instance, our October model seems to have been able to learn features of leaf-on and leaf-off crowns of *A. rubrum*, one of the most abundant species in our dataset and one of the species with significant leaf fall in the October imagery. Some *A. rubrum* leafless crowns were correctly identified at least in part, but more leafless crowns would be necessary to adequately generalize the features for the CNN to identify both leaf-on and leafless crowns. Another species with significant leaf fall in October was *F. grandifolia*. However, because of its low abundance in the dataset, many *F. grandifolia* crowns have not been detected or were misclassified with the background or other deciduous species. To avoid a decrease in prediction accuracy in autumn, more leafless crowns may be needed to train the model to learn species-specific branching patterns. Additionally, the branching structure may have less distinguishable features due to less contrast with the surroundings making it more difficult to distinguish from the background, and as such may require more training data for the model to correctly classify them (Cho et al., 2012; Kattenborn et al., 2020). So, while senescence and leaf colouring in autumn in temperate forest can add contrast in terms of colour among tree species and can be a useful trait to differentiate them (Fassnacht et al., 2016), the timing of leaf fall also differs within species.

Intraspecific variability in the timing of leaf fall can lead to a decrease in the accuracy of the model since it increases within-class heterogeneity.

## 4.2 Challenges related to the variability of senescence

Our initial hypothesis was that tree species classification accuracy from UAV imagery would be highest at peak autumn colours when the contrast in foliage colour among species was expected to be highest. We defined the 7<sup>th</sup> of October as the peak date for colouring from our field observations and based on previous phenocam observations at that site (see Laurentides site at <http://phenocam.unh.edu>). However, this decision was subjective and based on visual interpretation of the level of colouring and leaf fall in the overall landscape, while there can be significant spatial and temporal variability in senescence even within landscapes.

The definition of senescence is broad, ranging from the start of leaf colour change to leaf abscission, which includes multiple events that should not be assigned to a single date and that should be treated as a multiple-day event (Denny et al., 2014; Gallinat et al., 2015). Due to differences in species composition and environmental conditions in different studies, it is difficult to compare the timing and the dates chosen to acquire the imagery. In fact, the beginning of leaf fall varies between species (Veras et al., 2022), which we observed in the target species. This can be due to environmental conditions, especially considering the variable topography and the variety of soil types and conditions in our study site (Courchesne & Hendershot, 1989; Savage, 2001). While we did not measure soil conditions, these topo-edaphic conditions could have influenced the timing of senescence. Temperature variations associated with microclimate from the topography can also affect phenology on smaller scales (Lechowicz, 1984; Lisein et al., 2015; Richardson & O'Keefe, 2009). Moreover, abundant soil moisture can delay leaf colouring and leaf drop while drought and low moisture levels could advance senescence (Gallinat et al., 2015; Leuzinger et al., 2005). Early frost and high winds can also advance tree senescence depending on topographical position (Chmielewski et al., 2005; Norby et al., 2003). This combination of conditions affect the trees and their leaves throughout the growing season, causing leaf senescence to be an asynchronous event between and within species in heterogeneous areas (Gallinat et al., 2015). Therefore, classifying deciduous species in a temperate forest during senescence can be made difficult due to challenges related to predicting the timing of leaf colouring and leaf fall (Onishi et al., 2022).

Some tree species, such as *A. rubrum*, can tolerate a wide range of environmental conditions (Abrams, 1994; Fowells et al., 1965), which might influence its phenological response in autumn (Klosterman et al., 2018). The occurrence of *A. rubrum* in a wide range of conditions may explain the decline in the F1-score of that species in October. This could have led to different timing for the colouring and falling of leaves depending on the specific environmental conditions, causing more variability in the appearances of crowns. Indeed, an important factor that can negatively affect tree species classification performance is the colour variation of the leaves within a species, which tends to be greater in mixed forests (Lisein et al., 2015). Therefore, in a region with a variable topography and a diverse tree species composition such as ours, the timing of phenological events may vary significantly both among and within species in response to these conditions, which can influence tree species accuracy from UAV imagery.

Compared to autumn phenology and leaf senescence, spring leaf phenology is more homogeneous in terms of colour response than autumn leaf phenology. Indeed, spring phenological events tend to be more synchronized within species and the different species are distinct enough to differentiate between them (Lisein et al., 2015). We acquired imagery at the end of May, during late leaf flushing, and the accuracy of that spring model was higher than those from late September and October. Tree species such as *A. rubrum* and *F. grandifolia* were better classified in May than in October, pointing to higher homogeneity in spring leaf phenology for these species compared to autumn phenology. However, the opposite pattern was found for species where leaf colouring happened later in the season, such as *B. alleghaniensis*, which had better predictions in September and October than in May. While the objective of this study was not to determine an ideal date for imagery to map autumn phenology, our results highlight the fact that because of the many factors influencing the timing of senescence, especially regarding leaf fall, a single date cannot be chosen to capture peak colouring for multiple species in a mixed heterogenous forest. The use of multitemporal imagery with higher temporal resolution (e.g. every few days) during senescence would take advantage of the capacity deep learning models have to learn generalized features from imagery and make the models more adapted to variability within the imagery (Natesan et al., 2020), such as the timing of senescence or light conditions.

### 4.3 Tree segmentation in a complex canopy

Field observations combined with visual interpretation of the orthomosaic are necessary to build an extensive, accurate and precise segmentation dataset in a complex forest canopy to train CNN models (Kattenborn et al., 2021). In our study, having visual interpreters allowed us to segment tree crowns with irregular shapes, others that were partially covered by other crowns or that were overlapping other trees from the same or different species. Other studies that used visual interpretation to build a dataset of tree crowns also highlighted the value of this approach, even if there can be some misinterpretation of the imagery (Beloiu et al., 2023; Schiefer et al., 2020). Additionally, when annotating the imagery directly with this method, it ensures an accurate georeferencing of the annotations aligned with the imagery (Schiefer et al., 2020), which is especially important when working with multitemporal imagery.

The quality of the labelling and the delineation of the tree crowns has a direct influence on the quality of the species classification (Fassnacht et al., 2016). Some CNNs have been able to compensate for mislabelled crowns by correcting the classes in the predictions, but only to some extent (Hamdi et al., 2019; Kattenborn et al., 2020). Moreover, these corrections would also affect the metric of the model as they would not correspond to the training data. Therefore, it is best to avoid faulty labels and inaccurate segmentations, but certain characteristics of the target species can lead to mistakes. For many species, including most broadleaf species and some conifer species such as *T. occidentalis*, the borders of the crowns are not clearly identifiable on the imagery which may affect the accuracy of the annotations and the predictions (Gan et al., 2023). While delineating the crowns, the border of the crowns may vary slightly depending on whether this is done by a visual interpreter or the CNN, leading to differences in the labelling of the pixels on the borders of the crowns. Additionally, closed and overlapping canopies are more difficult for delineating tree crowns than for isolated trees or uniformly and distributed planted trees (Nevalainen et al., 2017; Yang et al., 2022). Tree detection algorithms are also known to be less accurate in forest with complex crown structures (Nuijten et al., 2019) or heterogenous conditions such as a higher diversity of species and shapes (Berra, 2020; Hastings et al., 2020), which is the case for most of our study site and makes the segmentation of tree crowns a laborious task.

We chose to annotate only one of our multiple dates, an approach that was also followed by Veras et al. (2022). This was done to reduce the time required to annotate all the imagery while still

ensuring that the annotations were of high quality by ensuring that annotations and imagery were aligned for all dates (Supplementary Figure S2). The cm-level alignment of all imagery among dates was made possible by using a UAV equipped with an RTK GNSS receiver in combination with GCPs. It is unclear whether the use of a single date for our annotations might explain the higher performance of the early September imagery or if other attributes of the imagery, such as light conditions or the phenology of the species, had a stronger influence on the performance. While additional data would be needed to test for this, we can see that the proportion of background pixels that have been classified as each target class, corresponding to the false positives, is relatively high for all the dates. This leads us to believe the models are less accurate in predicting the pixels on the border of the polygons. The accuracy of the predictions can be affected by the edges of the tree crowns which are often not well defined or clear (Gan et al., 2023). This could also be because the models are correcting for some missing labels in the imagery. On the other hand, the models made relatively few mistakes between the classes. If the predictions from the early September model would have been influenced by the alignment of the annotation, we would expect a significant decrease in false positives, which was not the case. More tests would be necessary to explore this, but we believe that the higher F1-score from early September is not only attributed to the fact that the annotations were made from this date.

Recent computer vision foundational algorithms such as the Segment Anything Model (SAM, Kirillov et al., 2023) may help to reduce the time necessary to build such extensive segmentation training datasets. However, it is still unknown how well such algorithms would perform on complex forest canopies, with overlapping crowns and fuzzy contours. In medical imagery, the performance of SAM was tested and gave variable results depending on the imagery and the parameters used, which led to the conclusion that some fine-tuning may be necessary for different applications (Huang et al., 2023). More research would need to be done to assess the capabilities of SAM in this context and to determine if this model were a promising tool in remote sensing of forest canopies.

The dataset created here (23,000 segmented individual tree crowns) includes 13 species and genera, which have an environmental and an economic importance in Northeastern North America. Moreover, these trees are segmented on seven different dates, totalling almost 161,000 annotated tree crowns. Due to the nature of the annotations, other deep learning approaches may be used such

as instance segmentation, which detects the individual object segments them (Kattenborn et al., 2021). This dataset is available online for use by others. The workflow presented here could be applied to other types of forests to assess the effects of the phenology specific to the region. With recent advances in segmentation tools, such as SAM (Kirillov et al., 2023), building a dataset for this type of method may become increasingly accessible depending on the complexity of the forest and the capacity of these types of models. More high temporal resolution segmented imagery of forest canopies can significantly improve our ability to accurately map and monitor these ecosystems.

#### **4.4 Other features from the imagery**

Different characteristics of the imagery, such as illumination conditions, spatial resolution, and texture, can influence the performance of the model (Flood et al., 2019; Kattenborn et al., 2019). Light conditions can influence the quality of the predictions of the CNNs, especially when comparing the F1-score for dates with diffuse light conditions (e.g., early September and August) and dates with full sun conditions (e.g., July and October). This may be combined with other features of the imagery, such as the effects of phenology discussed earlier. Since we did not test directly for the effect of different illumination conditions, we cannot say whether the light conditions or the phenology had a stronger impact on the F1-score. Some authors have stated that the changing tree phenology has as a greater impact on the quality of their imagery than illumination conditions (Lisein et al., 2015). Other studies using a CNN to detect tree crowns have reported a minor influence of illumination conditions on the classification (Beloiu et al., 2023), while others have reported an important decrease in accuracy due to shaded areas in the imagery when using a maximum-entropy classifier (Lopatin et al., 2019). This seems to indicate that CNNs are more robust to changes in illumination conditions and are still able to extract the relevant information, despite shaded areas. If the crown is distinguishable on the imagery, meaning it is not completely dark, the model is likely to identify it since the conditions were the same in the datasets used for training and testing. In fact, deep learning algorithms may be better at coping with shadows in the imagery, using them as an additional source of species-specific information, especially regarding the structure of the canopy (Kattenborn et al., 2020; Lopatin et al., 2019). Despite this, when possible, it might be best to avoid strong cast shadows in the imagery, especially in a forest with trees of variable heights, which could exacerbate the effects of shadows and make the segmentation task more difficult.

The spatial resolution of the imagery can influence the model's ability to classify tree species. When a CNN is trained with high-resolution imagery, it increases the accuracy as it can extract more contextual details in the imagery such as leaf form or branching patterns, which may be necessary to differentiate between species (Kattenborn et al., 2019). Higher spatial resolution also increases the contrast in texture that is visible on the imagery (Park et al., 2019). Low-contrast regions could lead to less accurate predictions from a CNN, showing the importance of texture in the imagery (Flood et al., 2019). When comparing the importance of texture and colour for a classification problem, the model that used texture features outperformed the model that was based only on colour. It was concluded that texture should be used when colour features do not perform well enough since they can be more robust to different light conditions than colour (Park et al., 2019).

In high-resolution imagery, for a given pixel in a tree crown, its neighbouring pixels are likely to be in the same crown and have similar information and therefore be classified as the same class (Woodcock & Strahler, 1987). However, this was not always the case. An edge effect, where the edges of the tiles result in artefacts in the predictions, can often appear when the CNN cannot determine with high confidence the label of a crown. This results in some crowns being assigned different classes depending on the tile, affecting the accuracy of the predictions (Flood et al., 2019). This was especially true for classes that were close phylogenetically with similar features such as *A. rubrum* and *A. saccharum*. For these species, some crowns were identified as both classes, often separated by a line representing the tile edge. While higher spatial resolution brings more information to the imagery, it also increases within-class variability due to increased spatial detail, canopy structure and shadows (Hay et al., 1996; Lopatin et al., 2019). This could lead to misclassifications especially in classes with overlapping features. Finally, higher-resolution imagery also entails higher computational costs.

## 4.5 Species-specific traits

Distinctive traits as well as constant traits within a class can play an important role in the performance of a tree species classification model. Some of these traits may be associated with the species, the functional traits or type, in particular deciduous broadleaf tree species and conifers. While autumn leaf colouring can help to distinguish between deciduous trees and evergreen trees (Onishi et al., 2022), our results show that deciduous broadleaf species consistently show a lower

average F1-score than conifer species, regardless of the date. Other studies have also reported a higher performance for conifers than broadleaf species for segmentation and tree counting (Onishi et al., 2022; Zhang et al., 2022). The difference in crown structure between broadleaf species and conifers and the variability from one individual to the other could explain this. Deciduous trees tend to have a more complex and plastic crown structure, while conifers have a more conical crown and a stronger relationship between height and crown size, leading to more of a constant crown structure (Nuijten et al., 2019). This was the case with the conifers in our dataset, which did not vary as much as broadleaf trees during senescence. As such, conifer species with homogeneous characteristics throughout the growing season are more likely to be better detected by the model (Veras et al., 2022), and they are not affected by the asynchronous timing of senescence from one individual to another. Two broadleaf classes stood out from the rest in that they showed a higher F1-score, *Populus spp.* and *B. papyrifera*. Both tree species are intolerant to shade and are therefore always at the top of the canopy with their crowns completely visible and not affected by the shade of neighbouring trees. *Populus spp.* has more constant features from one crown to another, while *B. papyrifera* showed more variability in crown shape and timing of leaf colouring and drop which may have been compensated by the large number of annotations for this species.

Some classes may be easier to classify by the model due to distinctive traits and require fewer annotations to reach a higher performance. The contrast between target classes and their surroundings contribute greatly to accurate CNN-based mapping (Kattenborn et al., 2020). According to our models' predictions, distinctive traits could be even more important than the number of annotations for species with constant traits between individuals. Indeed, the abundance of each tree species did not have a major impact on the accuracy of the model despite being strongly unbalanced. The most abundant species, *B. papyrifera*, was not the best classified species, although its classification accuracy was still above average. This species' features were not particularly distinctive, and they somewhat varied between individuals regarding crown shape and structure and timing of senescence throughout the study site. On the other hand, one of the least abundant species, *L. laricina*, was the second best identified class in the dataset. This species has very distinct features, especially regarding colour and texture. Also, the *L. laricina* crowns were grouped together in a bog, rarely isolated or surrounded by other species. This species often covered most of the surface of the tiles used to train the CNN when it was present. In some cases, underrepresented classes could get crowded by more frequent species in tiles during training

(Schiefer et al., 2020). *Larix laricina* was not affected in this way by the unbalanced dataset. A possible reason that less abundant species may have been misclassified could be because they share features with more abundant species (Schiefer et al., 2020). However, the species present in our dataset had few features that overlapped, and the CNN was able to differentiate the less abundant species.

*Pinus strobus* was the class with the highest average F1-score, which is similar to other studies reporting the highest performance for the *Pinus* genus for tree count (Zhang et al., 2022) and crown segmentation and detection (Beloiu et al., 2023; Fricker et al., 2019; Schiefer et al., 2020). A previous study using leaf spectroscopy found that needles of *P. strobus* have a spectral signature that distinguishes this species from other species with high accuracy (Blanchard, 2022). On the imagery, we noticed that *P. strobus* had a distinctive blue-grey colour, similar only to the colour of *L. laricina*, but with a very distinct crown texture. Overall, most of the identification errors for *P. strobus* and other species were between the classes and the background, due to false positives from the model identifying parts of the imagery that have not been annotated or from overestimating the size of the crowns. This indicates that the classes in our dataset have enough distinct features for the CNN to differentiate between each class, especially for classes in different genera.

The major source of misidentification between classes was between species that were closer phylogenetically. Species in the same genus may share features and have a similar appearance in the imagery (Onishi et al., 2022), making them more prone to misclassifications by the CNN. This was especially true for the three maple species, *A. pensylvanicum*, *A. rubrum* and *A. saccharum*, which were often misclassified among each other throughout the growing season. Also, trees of the same functional groups and growing in similar environments may have a similar texture and light acquisition performance (Onishi et al., 2022). Due to *A. rubrum*'s plasticity (Royer et al., 2008, 2009), its functional traits such as leaf shape vary depending on the conditions in which it grows, making it resemble *A. saccharum* and sometimes *A. pensylvanicum*. Along with its variability during senescence, this variability in *A. rubrum*'s appearance would explain the lower F1-score despite the high abundance of annotations for this class. While the variability of *A. rubrum*'s features increased the proportion of misclassification, its high abundance within the dataset seems to mitigate these effects since it was overall well identified.

Our study shows the effect of phenology, specifically autumn leaf senescence, on the performance of a CNN in identifying and segmenting tree crowns in a temperate forest. Contrary to our hypothesis, in October, when almost all leaves of tree species at the top of the canopy had changed colours, the CNN produced the least accurate predictions. We attribute this to the important leaf fall and the intra and interspecific variability of the timing of the different events within senescence. Nevertheless, our results show that the predictions produced by a CNN remained relatively accurate all throughout the growing season, from the end of spring to autumn, when compared to different studies (Kattenborn et al., 2019; Natesan et al., 2020; Schiefer et al., 2020). While this offers an insight into the way leaf senescence may influence a CNN, imagery with a higher temporal resolution would provide more detailed information on the senescence process in this temperate forest, especially for species with highly asynchronous timing. This can be important when it comes to monitoring temperate forest using a UAV and deep learning, for phenology monitoring or tree mapping.

## 5. Conclusion

Understanding the influence of leaf phenology on the capacity of a CNN to accurately identify and segment tree crowns is crucial to improving and optimizing our use of UAVs and remote sensing in forests. High spatial and temporal resolution imagery can help to understand and map these ecosystems, and by leveraging the phenological traits associated with temperate forests, it may help to understand these complex processes. In this study, we show how autumn phenology, specifically leaf senescence in a temperate mixed forest, can affect the performance of a CNN in segmenting individual tree crowns and identifying them to the species level. While peak colouring can be beneficial for some deciduous species, for most species, it is detrimental due to asynchronous leaf fall, especially in a heterogenous forest. Earlier in the season, at the start of leaf colouring, our models gave the best predictions overall. This further highlights the importance of the timing of imagery acquisition for optimized conditions for species mapping, a factor mentioned by others (Hill et al., 2010). The models presented in this study could be optimized by acquiring imagery at a higher temporal resolution, especially during leaf senescence, and to include earlier spring phenology to create a more complete representation of the growing season. To account for the

variability of the field site, integrating topo-edaphic variables could allow for a better understanding of the classification. More recent deep learning models could also give better predictions, but the objective of the study was to compare the performance of the models to one another, not to achieve the best predictions.

## Acknowledgments

The authors thank Noémie Lacombe, Ariane Roberge, Antoine Caron-Guay and Étienne Morissette whose contribution to the field work and the annotations were essential to building the dataset used in this study. The authors also thank the staff at the Station de biologie des Laurentides for the lodgings during the field work and access to the field site and equipment.

## Chapitre 3 – Discussion générale

### Retour sur les objectifs et les hypothèses de recherche

Des données sur la distribution des espèces d’arbres sont cruciales pour une bonne gestion des forêts et pour la recherche sur les milieux naturels (Hermosilla et al., 2022). La télédétection à partir de différentes plateformes peut permettre de cartographier les espèces d’arbres à grande échelle, mais l’utilisation des UAVs en particulier peut permettre de faire des acquisitions d’imagerie répétée, aux moments et aux endroits nécessaires (Coops et al., 2023). Les UAVs rendent aussi possible la caractérisation de la biodiversité à l’échelle d’arbres individuels pour de la gestion à un niveau précis, en particulier à des endroits touchés par une perturbation causant des changements au niveau de la biodiversité (Coops et al., 2023; Goodbody et al., 2017; Igihaut et al., 2019). De plus, lorsque la télédétection est utilisée conjointement avec l’apprentissage profond, ces méthodes sont d’autant plus efficaces pour gérer l’influx de données de plus en plus grand puisque les modèles d’apprentissage profond peuvent traiter de grande quantité de données rapidement (Katal et al., 2022). L’avancée de ces technologies dans les dernières années en plus de leur intégration dans le domaine de l’écologie ouvre la porte à de nouvelles avenues pour l’étude de la biodiversité. Un nombre croissant de recherches est fait en utilisant ces méthodes interdisciplinaires, mais il reste encore plusieurs questions à explorer, particulièrement par rapport à l’influence de la biodiversité végétale sur le succès des modèles d’apprentissage profond (Kattenborn et al., 2021; Yang et al., 2019; Zhang et al., 2018). C’est pourquoi, lors de ce projet, nous cherchions à améliorer nos connaissances par rapport à l’utilisation des UAVs et des CNNs sur la biodiversité des forêts de milieux tempérés qui sont sujettes à des changements phénologiques importants influençant l’apparence des espèces d’arbres.

En particulier, ce projet visait à évaluer l’effet que pourraient avoir les changements phénologiques dans une forêt tempérée mixte dans les Laurentides sur la performance d’un modèle d’apprentissage profond, spécifiquement un CNN. Nous cherchions aussi à déterminer les caractéristiques morphologiques et écologiques des espèces qui auraient potentiellement influencé la performance des modèles. Pour répondre à ces objectifs, nous avons créé un jeu de données où 23 000 couronnes d’arbres de 14 classes ont été identifiées et segmentées à partir d’imagerie prise par UAV d’une forêt tempérée à sept dates différentes. Ces données ont servi à entraîner et à tester

sept CNNs, soit un par date. À partir des prédictions générées par ces modèles, nous avons ensuite comparé la performance et la précision selon le moment dans la saison de croissance. En regardant la précision des prédictions par espèce pour chaque acquisition, il a été possible d'expliquer certains des résultats en les liant aux caractéristiques spécifiques des espèces.

Les résultats obtenus ont permis de répondre aux objectifs, et ainsi contribué à comprendre le fonctionnement des CNNs lorsqu'utilisé en écologie végétale. Nos résultats démontrent que la phénologie foliaire des espèces d'arbres en milieu tempéré, particulièrement à l'automne, a une influence sur la performance d'un modèle d'apprentissage profond, mais que cette influence n'arrive pas au même moment pour toutes les espèces, ni avec la même intensité. Ces résultats sont discutés dans l'article du chapitre 2, mais je vais ajouter à cette discussion en mentionnant certaines limitations et défis rencontrés lors du projet.

Tout d'abord, le modèle entraîné avec l'imagerie prise en octobre, lors du pic des couleurs, a donné les prédictions les moins précises, c'est-à-dire celles qui correspondaient le moins avec les annotations que nous avions faites. Ceci va contre l'hypothèse que nous avions émise initialement selon laquelle l'imagerie qui se rapproche le plus du pic des couleurs à l'automne donnera les meilleures prédictions. Cette hypothèse était basée sur des conclusions d'études précédentes qui indiquaient que ce moment dans le processus de la sénescence correspondait au meilleur moment pour différencier entre les espèces (Grybas & Congalton, 2021; Hill et al., 2010; Key et al., 2001; Weil et al., 2017), ce qui n'était pas le cas dans notre site d'étude. Ceci démontre que le fait d'indiquer un moment spécifique à l'intérieur d'un phénomène aussi complexe que la sénescence des feuilles ne peut pas être applicable à toutes les forêts tempérées. Ce genre de conclusion, ainsi que celles obtenues dans cette étude, doit plutôt être vue comme des éléments à considérer lors de la planification de l'acquisition d'imagerie. Selon les espèces qui voient leur performance diminuer en octobre et en se basant sur ce que nous voyons sur l'imagerie, ceci serait principalement dû à la chute des feuilles à la fin de la sénescence. Cette chute tend à causer beaucoup de variabilité intra-espèces pour certaines des espèces, puisque certaines des couronnes sont pleines de feuilles et d'autres n'ont plus de feuilles sur une même imagerie. Afin d'éviter les défis associés avec les couronnes ayant perdu leurs feuilles lors de l'identification d'espèces d'arbres par télédétection, une option serait d'éviter ce genre d'imagerie (Wolter et al., 1995). Cependant, quoique ceci permettrait probablement d'améliorer les prédictions du modèle, ces méthodes excluraient une

partie du processus de la sénescence. Au contraire, il serait plus pertinent d'inclure plus de couronnes sans feuilles lors de l'entraînement de modèle (Braga et al., 2020). Certaines des couronnes sans feuilles de l'érable rouge, une des espèces les plus abondantes et ayant une forte proportion de chutes de feuilles, ont correctement été identifiées par le modèle. Ceci démontre que les CNNs ont le potentiel d'apprendre les caractéristiques des motifs d'embranchement et de structure de couronnes des espèces, si ce type de couronne est présent en quantité suffisante dans le jeu de données d'entraînement.

Le modèle avec le plus haut taux d'erreur a été entraîné avec l'imagerie acquise lors du pic des couleurs, alors que la meilleure performance a été obtenue avec l'imagerie un mois plus tôt, en début septembre, lorsque la sénescence débutait et que les couleurs des feuilles commençaient à changer. Ceci pourrait être expliqué par plusieurs caractéristiques des imageries. Tout comme les conclusions des études précédentes, l'imagerie qui capture une partie de la sénescence pourrait donner la meilleure classification de couronnes d'arbres, puisque le processus phénologique du changement de couleur des feuilles est très évident sur l'imagerie (Fassnacht et al., 2016). De plus, il aurait pu y avoir un effet des conditions de luminosité sur cette baisse de performance, puisque l'imagerie de septembre a été acquise avec des conditions de luminosité diffuses alors que l'imagerie d'octobre a été prise lors d'une journée ensoleillée. En regardant les conifères, dont leur apparence ne change pas dû à la sénescence dans l'imagerie, il est possible de voir une diminution de leur F1-score entre le modèle de début septembre et celui d'octobre. Ceci est aussi le cas pour les autres imageries avec des conditions plus lumineuses (Figure supplémentaires S1 et S4). Nous n'avons pas évalué l'impact des conditions de luminosité sur les résultats, mais il est tout de même certain que la phénologie a un impact significatif pour certaines des espèces pour lesquelles la sénescence affecte fortement leur apparence. Une imagerie avec une plus grande résolution temporelle aurait probablement permis de mieux voir ces changements et identifier plus précisément le moment où la performance des modèles augmente et décline pour chaque espèce avec l'avancée de la sénescence.

Un autre aspect de la sénescence qui aurait causé une baisse de performance dans le modèle entraîné avec l'imagerie d'octobre est la variabilité dans le moment du début de la sénescence dans une même espèce. La sénescence des feuilles n'est pas un processus synchrone entre les espèces et dans une même espèce (Gallinat et al., 2015). Ainsi, classifier des espèces d'arbres de manière

détaillée peut être difficile due à une instabilité quant à la quantité de feuilles et de couleurs (Onishi et al., 2022). Comme mentionné précédemment, la chute des feuilles a un impact assez significatif. En effet, lorsque les feuilles des arbres d'une même espèce changent de couleur à différents moments, la couronne garde tout de même une forme et une texture similaire. Cependant, lorsque la chute des feuilles arrive à des moments différents, ceci affecte à la fois la couleur, la texture et la forme des couronnes. Cette variabilité peut être importante à considérer selon les besoins de l'imagerie et elle dépend principalement des espèces présentes et des conditions environnementales du site d'étude. Dans un site plus hétérogène, la variabilité de la phénologie dans une même espèce est plus grande que dans une monoculture ou une forêt avec une structure d'âge homogène (Lisein et al., 2015). Des variations de température associées au microclimat dû à des différences topographique peuvent avoir un effet sur la phénologie à petite échelle, en plus de différence au niveau de la disponibilité de l'eau dans les sols (Gallinat et al., 2015; Lechowicz, 1984; Leuzinger et al., 2005; Lisein et al., 2015; Richardson & O'Keefe, 2009). Dans mon site d'étude, certaines espèces étaient très abondantes et présentes sur une large gamme de conditions environnementales et topo-édaphique comme l'érythrine (Abrams, 1994; Fowells et al., 1965), alors que d'autres étaient beaucoup moins abondantes et poussent dans une gamme de conditions moins larges, comme le bouleau jaune. Nous n'avons pas récolté de données sur les sols ou comparé la distribution des espèces et leur patron de sénescence aux données topographiques afin de voir les effets des différents types de conditions (édaphique, humide, xérique), mais ces analyses pourraient être pertinentes pour des projets futurs. Puisque les conditions environnementales peuvent avoir une influence sur la réponse phénologique à l'automne (Klosterman et al., 2018), une espèce telle que l'érythrine pourrait permettre de voir l'effet de ces différentes conditions environnementales sur la variabilité de la sénescence au sein d'une même espèce.

Afin d'entraîner un modèle d'apprentissage profond pour segmenter et identifier des couronnes d'arbres de manière précise, un jeu de données doit être construit à partir de segmentations de qualité (Kattenborn et al., 2021). Pour réussir à créer un jeu de donnée de qualité à partir de notre imagerie, il a été nécessaire d'utiliser de l'interprétation visuelle pour faire la segmentation, puisque la canopée était complexe, les couronnes d'arbres se chevauchaient et les formes des couronnes de certaines espèces avaient des formes très variables et des contours difficiles à distinguer. Toutes ces caractéristiques rendent difficile la délimitation des couronnes (Nevalainen et al., 2017; Yang et al., 2022). Malgré le fait que cette étape prend beaucoup de temps

dans le cadre d'un projet, l'interprétation visuelle a permis de s'assurer que les annotations prenaient en compte tous les aspects particuliers et les formes irrégulières des couronnes. De plus, grâce à l'imagerie multi-temporelle, il était possible d'utiliser ces différentes imageries pour aider à la tâche en utilisant les changements de couleur et de luminosité qui faisait ressortir les contours des arbres. Les couronnes d'espèces feuillues en particulier ont des contours plutôt flous, et souvent difficiles à définir. Nous avions considéré appliquer une zone tampon sur la bordure interne des polygones dans le but de retirer cet effet, mais nous étions confiants de la qualité des annotations et que cet effet pourrait être semblable à la différence entre les différents annotateurs. De plus, il est à noter que la campagne de terrain durant laquelle nous avons identifié les couronnes d'arbres sur les orthomosaïques était cruciale pour avoir des annotations justes. Il aurait été impossible d'annoter l'imagerie à l'espèce sans formation préalable pour l'interprétation visuelle de cette canopée.

La résolution spatiale des imageries peut être importante pour distinguer les détails présents dans les couronnes (Kattenborn et al., 2019), particulièrement lorsque l'objectif est de classer plusieurs espèces différentes. Entre autres, une résolution spatiale élevée permet de voir la texture dans les couronnes (Park et al., 2019). Par contre, une haute résolution spatiale entraîne aussi davantage de variabilité intra-espèce dû à l'augmentation des détails qui sont visibles dans l'imagerie (Hay et al., 1996; Lopatin et al., 2019). Ceci pourrait être une des causes des problèmes de classification entre les espèces d'érable, en particulier l'érable rouge et l'érable à sucre. La variabilité amenée par la très haute résolution spatiale de l'imagerie pourrait causer un chevauchement des traits entre les deux espèces. Ceci pourrait même être exacerbé par la plasticité de l'érable rouge, particulièrement au niveau des feuilles (Royer et al., 2008, 2009).

Les imageries utilisées dans ce projet ont toutes une résolution spatiale similaire (entre 1,8 et 2 cm), mais il aurait été intéressant d'évaluer la performance des modèles avec une résolution moins grande. En diminuant la résolution, certains des détails ne seront plus visibles, ce qui pourrait diminuer la variabilité intraspécifique. Ceci pourrait être avantageux dans le cas de l'érable rouge et l'érable à sucre, diminuant peut-être les erreurs de classification entre les deux espèces. Selon les résultats de Schiefer et al. (2020), où ils ont évalué le potentiel de différentes résolutions spatiales pour la segmentation d'arbres avec un U-Net, une meilleure résolution donnera de meilleurs résultats pour la segmentation d'espèces dans une canopée de forêt mixte. Puisque nous

utilisions le même type de modèle, nous avons opté pour une très haute résolution spatiale pour identifier et segmenter un maximum d'espèces. Avec des modèles de vision par ordinateur plus récents, il serait intéressant de revoir le potentiel de différentes résolutions spatiales pour la segmentation des couronnes d'arbres.

Finalement, des caractéristiques constantes dans une espèce contribuent à de meilleures prédictions par un modèle d'apprentissage profond (Veras et al., 2022). Les résultats obtenus pour certaines des espèces démontrent exactement ça, que des traits distinctifs et constants à travers les individus peuvent jouer un rôle important dans la qualité des prédictions faites par le modèle, parfois plus importants que le nombre d'annotations. Ceci est particulièrement visible chez le mélèze laricin. Bien que cette espèce soit une des moins abondantes dans le jeu de données, elle est l'espèce la mieux prédite en moyenne. Son apparence particulière, c'est-à-dire une couleur presque bleue et une texture particulière à cause de ses aiguilles minces en faisceaux denses, permet à cette espèce de ressortir sur l'imagerie et d'être plus facilement reconnue par le modèle. En général, les conifères performent mieux que les feuillus (Figure supplémentaire S4), ce qui a été observé par d'autres auteurs précédemment (Onishi et al., 2022; Zhang et al., 2022). Ceci peut aider à la construction du jeu de données, en considérant si certaines espèces nécessiteraient plus de représentation dans les données, que ce soit en échantillonnant plus d'individus de cette espèce ou en faisant de l'augmentation de données au moment de l'entraînement.

## Perspectives

### La recherche en phénologie

Les méthodes utilisées et développées lors de ce projet nous ont permis de générer un grand jeu de données de 23 000 couronnes d'arbres individuels sur une saison de croissance, de la sortie des feuilles jusqu'au pic des couleurs. Dans le cadre de la recherche en phénologie, ce genre de méthodes peut être utilisé pour mieux comprendre la phénologie, autant dans les milieux tempérés que dans les milieux tropicaux et boréaux. Jusqu'à récemment, notre compréhension des patrons phénologiques a été limitée par notre capacité à les cartographier et les documenter sur de grandes échelles spatiales et temporelles (Katal et al., 2022). Maintenant qu'il est de plus en plus accessible de capturer la phénologie des forêts à l'aide de la télédétection, des outils et des méthodes doivent

être développés pour pouvoir analyser toutes ces données afin de pouvoir faire le suivi de la phénologie (Correia et al., 2020). Ceci est particulièrement important à l'ère des changements climatiques, surtout considérant que le suivi des patrons phénologiques peut permettre de comprendre l'influence des changements climatiques sur la végétation (Katal et al., 2022). En effet, la phénologie au niveau des espèces peut être utilisée comme indicateurs de changement dans les forêts mixtes tempérées (Calinger & Curtis, 2023). Ceci démontre de l'importance de développer des techniques pour acquérir des données à grande échelle au niveau de l'espèce, lorsque possible. Cependant, cette tâche sera difficile dû à la panoplie de facteurs qui influence la phénologie. Ceci nécessitera beaucoup de collaboration pour la prise de données et la création de modèles d'apprentissage profond dans différents types d'écosystèmes, puisque les modèles ne peuvent pas être appliqués de manière globale (Gill et al., 2015). De plus, même à une petite échelle comme dans une forêt tempérée, les phénophases ne changeront pas de manière uniforme (Archetti et al., 2013), ce qui augmente l'importance d'avoir des données avec une bonne résolution temporelle.

## L'importance des jeux de données

Pour l'entraînement de modèles d'apprentissage profond, il est nécessaire d'avoir un jeu de données large et de qualité, tout en étant adéquat pour répondre aux questions de recherche. Pour la phénologie, il est nécessaire de générer plus de données, plus fréquemment et en incluant des suivis à long terme (Budianti et al., 2021). En effet, pour comprendre les facteurs qui font varier la phénologie, il faut des données au niveau de l'arbre individuel et au niveau de l'espèce, avec une haute résolution spatiale et temporelle (Park et al., 2019). C'est ce que nous avons accompli dans le cadre de ce projet, spécifiquement pour la forêt de la Station de biologie des Laurentides de l'Université de Montréal. Dans ce projet, nous avons déterminé l'influence de la phénologie sur la performance d'un CNN et les caractéristiques des arbres qui expliqueraient ces résultats, mais ce jeu de données a le potentiel de répondre à beaucoup d'autres questions de recherche. La façon dont les données ont été prises, en segmentant individuellement les couronnes d'arbres, permettrait de les utiliser pour entraîner un modèle de segmentation d'instance où les prédictions segmentent et identifient les couronnes tout en considérant chaque couronne comme un objet individuel. Par contre, dû à la complexité de la canopée dans une forêt naturelle, il serait plus difficile d'obtenir de bonne prédiction avec les modèles présentement disponibles (Schiefer et al., 2020), ce qui

pourrait changer avec les avancés en apprentissage profond. Avec le jeu de données, il sera également possible de pousser plus loin notre compréhension de ce qui peut influencer les CNNs lorsqu'utilisés en écologie forestière, en plus de regarder cet effet pour différente architecture pour la détection d'objet, la segmentation sémantique et la segmentation d'instance. Les données permettent aussi l'extraction de métriques de phénologie, ce qui est un défi présentement puisqu'il manque de données donnant accès au même individu pour plusieurs stades phénologiques dans une même année (Katal et al., 2022). D'autres sources de données qui n'ont pas été utilisées dans le projet, mais qui sont disponibles dans le jeu de données, sont des nuages de points générés lors de la création des orthomosaïques par photogrammétrie. Ceux-ci pourraient permettre entre autres de comparer la forme des couronnes à travers la saison de croissance pour les différentes phénophases (Nuijten et al., 2019).

Ce jeu de données, incluant les annotations, les orthomosaïques et les nuages de points, sera bientôt mis disponible en ligne pour que d'autres puissent profiter du travail qui a été mis pour le générer. Ceci sera avantageux pour les autres groupes de recherche intéressés à l'utiliser, ainsi que pour des groupes qui n'ont pas les équipements, les outils ou les opportunités d'acquérir ce type de données. Il pourra être intégré avec d'autre jeu de données de ce type et faire partie d'étude comparative sur la classification d'espèces d'arbres (Fassnacht et al., 2016). Les projets de recherche cherchant à générer ou utiliser des données de télédétection de la végétation pour entraîner et développer des modèles d'apprentissage profond encouragent la collaboration entre des chercheurs et des chercheuses de différents milieux, tels que l'écologie et l'intelligence artificielle, afin de créer des équipes multidisciplinaires. Des groupes avec une expertise en écologie et en télédétection et qui connaissent les besoins liés à ces domaines peuvent nécessiter l'aide de groupes ayant une expertise en apprentissage profond et les avancés dans le domaine, et vice-versa. Un exemple d'un tel projet, où s'insère mon projet de maîtrise, est un projet sur la biodiversité et les changements climatiques financé par l'Institut de valorisation des données (IVADO) regroupant des biologistes et des géographes de l'Université de Montréal et des chercheurs au Mila, un institut d'intelligence artificielle. Avec les avancés rapides dans le domaine de l'apprentissage profond, particulièrement avec le développement de nouveaux modèles et de nouvelles techniques, ce genre de collaboration va être de plus en plus avantageux pour tous.

## **Le potentiel de la télédétection**

Depuis les dernières années, l'utilisation de la télédétection a augmenté grâce aux avancées technologiques dans ce domaine, la rendant très fréquemment utilisée dans la recherche en foresterie (Fassnacht et al., 2023). Grâce à ça, il y a une croissance de la capacité d'acquisition de données de télédétection à différents niveaux, ce qui amène énormément de nouvelles opportunités pour l'étude des forêts (Dainelli et al., 2021). Certains groupes de recherche explorent la combinaison de différentes plateformes de télédétection, spécifiquement l'imagerie satellitaire et l'imagerie par UAV. Coops et al. (2023) suggèrent un cadre conceptuel pour les inventaires forestiers où l'imagerie satellitaire est utilisée pour détecter des changements de biodiversité à grande échelle, puis d'utiliser des UAVs afin d'obtenir des informations sur la perturbation à une échelle plus fine. À l'opposé, Schiefer et al. (2023) explorent l'utilisation de données générées à l'aide d'un CNN à partir d'imagerie par UAV qui sont ensuite appliquées sur de l'imagerie satellitaire pour la détection d'arbres morts à grande échelle. Ces articles, publiés très récemment, témoignent des avancées rapides en télédétection, au niveau technologique, mais aussi au niveau méthodologique en explorant différentes manières d'utiliser les données à différentes échelles.

Dans ce mémoire, j'ai démontré l'importance de la phénologie d'une forêt tempérée mixte sur la cartographie d'arbres individuels au niveau de l'espèce en utilisant un modèle d'apprentissage profond, et j'ai exploré les traits morphologiques et écologiques de ces espèces qui pourraient expliquer des différences dans la performance des modèles. En parallèle, j'ai généré un grand jeu de données multi-temporel, qui s'ajoute aux quelques jeux de données déjà existant segmentant des arbres individuels, et qui est déjà utilisé dans le cadre d'autres projets de recherche. En écologie, la compréhension de ce qui peut nuire ou aider un CNN nécessite plus d'attention afin d'optimiser notre utilisation de la télédétection afin qu'elle devienne un outil encore plus indispensable pour la recherche dans l'ère des changements climatiques.

## Références bibliographiques

- Abrams, M. D. (1994). Genotypic and phenotypic variation as stress adaptations in temperate tree species: A review of several case studies. *Tree Physiology*, 14(7-8-9), 833–842. <https://doi.org/10.1093/treephys/14.7-8-9.833>
- Agisoft. (2021). *Agisoft Metashape User Manual Professional Edition* (1.7.5) [Computer software]. Agisoft LLC.
- Archetti, M., Richardson, A. D., O'Keefe, J., & Delpierre, N. (2013). Predicting Climate Change Impacts on the Amount and Duration of Autumn Colors in a New England Forest. *PLOS ONE*, 8(3), e57373. <https://doi.org/10.1371/journal.pone.0057373>
- Beloiu, M., Heinzmann, L., Rehush, N., Gessler, A., & Griess, V. C. (2023). Individual Tree-Crown Detection and Species Identification in Heterogeneous Forests Using Aerial RGB Imagery and Deep Learning. *Remote Sensing*, 15(5), Article 5. <https://doi.org/10.3390/rs15051463>
- Berra, E. F. (2020). Individual tree crown detection and delineation across a woodland using leaf-on and leaf-off imagery from a UAV consumer-grade camera. *Journal of Applied Remote Sensing*, 14(3), 034501. <https://doi.org/10.1117/1.JRS.14.034501>
- Blanchard, F. (2022). *Identifier les arbres du Québec grâce à la spectroscopie foliaire: Différenciation fonctionnelle et phylogénétique des espèces* [Université de Montréal]. <https://papyrus.bib.umontreal.ca/xmlui/handle/1866/27520>
- Braga, J. R., Peripato, V., Dalagnol, R., P. Ferreira, M., Tarabalka, Y., O. C. Aragão, L. E., F. de Campos Velho, H., Shiguemori, E. H., & Wagner, F. H. (2020). Tree Crown Delineation

Algorithm Based on a Convolutional Neural Network. *Remote Sensing*, 12(8), Article 8.

<https://doi.org/10.3390/rs12081288>

Brodrick, P. G., Davies, A. B., & Asner, G. P. (2019). Uncovering Ecological Patterns with Convolutional Neural Networks. *Trends in Ecology & Evolution*, 34(8), 734–745.

<https://doi.org/10.1016/j.tree.2019.03.006>

Budianti, N., Mizunaga, H., & Iio, A. (2021). Crown Structure Explains the Discrepancy in Leaf Phenology Metrics Derived from Ground- and UAV-Based Observations in a Japanese Cool Temperate Deciduous Forest. *Forests*, 12(4), Article 4.

<https://doi.org/10.3390/f12040425>

Calinger, K., & Curtis, P. (2023). A century of climate warming results in growing season extension: Delayed autumn leaf phenology in north central North America. *PLoS One*, 18(3), e0282635. <https://doi.org/10.1371/journal.pone.0282635>

Cavender-Bares, J., Schneider, F. D., Santos, M. J., Armstrong, A., Carnaval, A., Dahlin, K. M., Fatoyinbo, L., Hurt, G. C., Schimel, D., Townsend, P. A., Ustin, S. L., Wang, Z., & Wilson, A. M. (2022). Integrating remote sensing with ecology and evolution to advance biodiversity conservation. *Nature Ecology & Evolution*, 6(5), Article 5.

<https://doi.org/10.1038/s41559-022-01702-5>

Chmielewski, F. M., Müller, A., & Küchler, W. (2005). Possible impacts of climate change on natural vegetation in Saxony (Germany). *International Journal of Biometeorology*, 50(2), 96–104. <https://doi.org/10.1007/s00484-005-0275-1>

Cho, M. A., Mathieu, R., Asner, G. P., Naidoo, L., van Aardt, J., Ramoelo, A., Debba, P., Wessels, K., Main, R., Smit, I. P. J., & Erasmus, B. (2012). Mapping tree species composition in South African savannas using an integrated airborne spectral and LiDAR system. *Remote Sensing of Environment*, 125, 214–226. <https://doi.org/10.1016/j.rse.2012.07.010>

Cloutier, M., Germain, M., & Laliberté, E. (2023a). *Influence of Temperate Forest Autumn Leaf Phenology on Segmentation of Tree Species from UAV Imagery Using Deep Learning* (p. 2023.08.03.548604). bioRxiv. <https://doi.org/10.1101/2023.08.03.548604>

Cloutier, M., Germain, M., & Laliberté, E. (2023b). *Quebec Trees Dataset* [dataset]. Zenodo. <https://doi.org/10.5281/zenodo.8148479>

Coops, N. C., Tompalski, P., Goodbody, T. R. H., Achim, A., & Mulverhill, C. (2023). Framework for near real-time forest inventory using multi source remote sensing data. *Forestry: An International Journal of Forest Research*, 96(1), 1–19. <https://doi.org/10.1093/forestry/cpac015>

Correia, D. L. P., Bouachir, W., Gervais, D., Pureswaran, D., Kneeshaw, D. D., & De Grandpré, L. (2020). Leveraging Artificial Intelligence for Large-Scale Plant Phenology Studies From Noisy Time-Lapse Images. *IEEE Access*, 8, 13151–13160. <https://doi.org/10.1109/ACCESS.2020.2965462>

Courchesne, F., & Hendershot, W. H. (1989). Sulfate retention in some podzolic soils of the southern laurentians, quebec. *Canadian Journal of Soil Science*, 69(2), 337–350. <https://doi.org/10.4141/cjss89-034>

Dainelli, R., Toscano, P., Di Gennaro, S. F., & Matese, A. (2021). Recent Advances in Unmanned Aerial Vehicle Forest Remote Sensing—A Systematic Review. Part I: A General Framework. *Forests*, 12(3), Article 3. <https://doi.org/10.3390/f12030327>

de Lima, R. A. F., Phillips, O. L., Duque, A., Tello, J. S., Davies, S. J., de Oliveira, A. A., Muller, S., Honorio Coronado, E. N., Vilanova, E., Cuni-Sanchez, A., Baker, T. R., Ryan, C. M., Malizia, A., Lewis, S. L., ter Steege, H., Ferreira, J., Marimon, B. S., Luu, H. T., Imani, G., ... Vásquez, R. (2022). Making forest data fair and open. *Nature Ecology & Evolution*, 6(6), Article 6. <https://doi.org/10.1038/s41559-022-01738-7>

- Denny, E. G., Gerst, K. L., Miller-Rushing, A. J., Tierney, G. L., Crimmins, T. M., Enquist, C. A. F., Guertin, P., Rosemartin, A. H., Schwartz, M. D., Thomas, K. A., & Weltzin, J. F. (2014). Standardized phenology monitoring methods to track plant and animal activity for science and resource management applications. *International Journal of Biometeorology*, 58(4), 591–601. <https://doi.org/10.1007/s00484-014-0789-5>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2021). *An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale* (arXiv:2010.11929). arXiv. <http://arxiv.org/abs/2010.11929>
- ESRI Inc. (2021). *ArcGIS Pro* (2.9) [Computer software].
- Fassnacht, F. E., Latifi, H., Stereńczak, K., Modzelewska, A., Lefsky, M., Waser, L. T., Straub, C., & Ghosh, A. (2016). Review of studies on tree species classification from remotely sensed data. *Remote Sensing of Environment*, 186, 64–87. <https://doi.org/10.1016/j.rse.2016.08.013>
- Fassnacht, F. E., Schmidt-Riese, E., Kattenborn, T., & Hernández, J. (2021). Explaining Sentinel 2-based dNBR and RdNBR variability with reference data from the bird's eye (UAS) perspective. *International Journal of Applied Earth Observation and Geoinformation*, 95, 102262. <https://doi.org/10.1016/j.jag.2020.102262>
- Fassnacht, F. E., White, J. C., Wulder, M. A., & Næsset, E. (2023). Remote sensing in forestry: Current challenges, considerations and directions. *Forestry: An International Journal of Forest Research*, cpad024. <https://doi.org/10.1093/forestry/cpad024>
- Ferreira, M. P., Almeida, D. R. A. de, Papa, D. de A., Minervino, J. B. S., Veras, H. F. P., Formighieri, A., Santos, C. A. N., Ferreira, M. A. D., Figueiredo, E. O., & Ferreira, E. J. L. (2020). Individual tree detection and species classification of Amazonian palms using UAV

images and deep learning. *Forest Ecology and Management*, 475, 118397.

<https://doi.org/10.1016/j.foreco.2020.118397>

Flood, N., Watson, F., & Collett, L. (2019). Using a U-net convolutional neural network to map woody vegetation extent from high resolution satellite imagery across Queensland, Australia. *International Journal of Applied Earth Observation and Geoinformation*, 82, 101897. <https://doi.org/10.1016/j.jag.2019.101897>

Fowells, H. A., United States, Forest Service, & Timber Management Research. (1965). *Silvics of forest trees of the United States*. vi, 762.

Frickr, G. A., Ventura, J. D., Wolf, J. A., North, M. P., Davis, F. W., & Franklin, J. (2019). A Convolutional Neural Network Classifier Identifies Tree Species in Mixed-Conifer Forest from Hyperspectral Imagery. *Remote Sensing*, 11(19), Article 19. <https://doi.org/10.3390/rs11192326>

Gallinat, A. S., Primack, R. B., & Wagner, D. L. (2015). Autumn, the neglected season in climate change research. *Trends in Ecology & Evolution*, 30(3), 169–176. <https://doi.org/10.1016/j.tree.2015.01.004>

Gan, Y., Wang, Q., & Iio, A. (2023). Tree Crown Detection and Delineation in a Temperate Deciduous Forest from UAV RGB Imagery Using Deep Learning Approaches: Effects of Spatial Resolution and Species Characteristics. *Remote Sensing*, 15(3), Article 3. <https://doi.org/10.3390/rs15030778>

Gill, A. L., Gallinat, A. S., Sanders-DeMott, R., Rigden, A. J., Short Gianotti, D. J., Mantooth, J. A., & Templer, P. H. (2015). Changes in autumn senescence in northern hemisphere deciduous trees: A meta-analysis of autumn phenology studies. *Annals of Botany*, 116(6), 875–888. <https://doi.org/10.1093/aob/mcv055>

- Goodbody, T. R. H., Coops, N. C., Marshall, P. L., Tompalski, P., & Crawford, P. (2017). Unmanned aerial systems for precision forest inventory purposes: A review and case study. *The Forestry Chronicle*, 93(01), 71–81. <https://doi.org/10.5558/tfc2017-012>
- Goodbody, T. R. H., Coops, N. C., & White, J. C. (2019). Digital Aerial Photogrammetry for Updating Area-Based Forest Inventories: A Review of Opportunities, Challenges, and Future Directions. *Current Forestry Reports*, 5(2), 55–75. <https://doi.org/10.1007/s40725-019-00087-2>
- Google Earth V 7.3.6.9345. (June 7, 2019). St-Hippolyte, Quebec, Canada. 45° 59' 33.01" N, -74° 0' 18.35" W. Eye alt 10.2 km. <https://www.earth.google.com> [Accessed June 9 2023].
- Gouvernement du Québec. (2021). *LiDAR - Modèles numériques (terrain, canopée, pente) – Données Québec*. <https://www.donneesquebec.ca/recherche/dataset/produits-derives-de-base-du-lidar>
- Grybas, H., & Congalton, R. G. (2021). A Comparison of Multi-Temporal RGB and Multispectral UAS Imagery for Tree Species Classification in Heterogeneous New Hampshire Forests. *Remote Sensing*, 13(13), Article 13. <https://doi.org/10.3390/rs13132631>
- Haenlein, M., & Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, 61(4), 5–14. <https://doi.org/10.1177/0008125619864925>
- Hagemeier, M., & Leuschner, C. (2019). Functional Crown Architecture of Five Temperate Broadleaf Tree Species: Vertical Gradients in Leaf Morphology, Leaf Angle, and Leaf Area Density. *Forests*, 10(3), Article 3. <https://doi.org/10.3390/f10030265>
- Hamdi, Z. M., Brandmeier, M., & Straub, C. (2019). Forest Damage Assessment Using Deep Learning on High Resolution Remote Sensing Data. *Remote Sensing*, 11(17), Article 17. <https://doi.org/10.3390/rs11171976>

- Hastings, J. H., Ollinger, S. V., Ouimette, A. P., Sanders-DeMott, R., Palace, M. W., Ducey, M. J., Sullivan, F. B., Basler, D., & Orwig, D. A. (2020). Tree Species Traits Determine the Success of LiDAR-Based Crown Mapping in a Mixed Temperate Forest. *Remote Sensing*, 12(2), Article 2. <https://doi.org/10.3390/rs12020309>
- Hay, G. J., Niemann, K. O., & McLean, G. F. (1996). An object-specific image-texture analysis of H-resolution forest imagery. *Remote Sensing of Environment*, 55(2), 108–122. [https://doi.org/10.1016/0034-4257\(95\)00189-1](https://doi.org/10.1016/0034-4257(95)00189-1)
- He, K. S., Rocchini, D., Neteler, M., & Nagendra, H. (2011). Benefits of hyperspectral remote sensing for tracking plant invasions. *Diversity and Distributions*, 17(3), 381–392. <https://doi.org/10.1111/j.1472-4642.2011.00761.x>
- He, Y., Yang, J., Caspersen, J., & Jones, T. (2019). An Operational Workflow of Deciduous-Dominated Forest Species Classification: Crown Delineation, Gap Elimination, and Object-Based Classification. *Remote Sensing*, 11(18), Article 18. <https://doi.org/10.3390/rs11182078>
- Hermosilla, T., Bastyr, A., Coops, N. C., White, J. C., & Wulder, M. A. (2022). Mapping the presence and distribution of tree species in Canada's forested ecosystems. *Remote Sensing of Environment*, 282, 113276. <https://doi.org/10.1016/j.rse.2022.113276>
- Hill, R. A., Wilson, A. K., George, M., & Hinsley, S. A. (2010). Mapping tree species in temperate deciduous woodland using time-series multi-spectral data. *Applied Vegetation Science*, 13(1), 86–99. <https://doi.org/10.1111/j.1654-109X.2009.01053.x>
- Hoeser, T., & Kuenzer, C. (2020). Object Detection and Image Segmentation with Deep Learning on Earth Observation Data: A Review-Part I: Evolution and Recent Trends. *Remote Sensing*, 12(10), Article 10. <https://doi.org/10.3390/rs12101667>

Howard, J., & Gugger, S. (2020a). *Deep Learning for Coders with fastai and PyTorch*. O'Reilly Media, Inc.

Howard, J., & Gugger, S. (2020b). fastai: A Layered API for Deep Learning. *Information*, 11(2), 108. <https://doi.org/10.3390/info11020108>

Huang, Y., Yang, X., Liu, L., Zhou, H., Chang, A., Zhou, X., Chen, R., Yu, J., Chen, J., Chen, C., Chi, H., Hu, X., Fan, D.-P., Dong, F., & Ni, D. (2023). Segment Anything Model for Medical Images? (arXiv:2304.14660). arXiv. <https://doi.org/10.48550/arXiv.2304.14660>

Ighaut, J., Cabo, C., Puliti, S., Piermattei, L., O'Connor, J., & Rosette, J. (2019). Structure from Motion Photogrammetry in Forestry: A Review. *Current Forestry Reports*, 5(3), 155–168. <https://doi.org/10.1007/s40725-019-00094-3>

James, K., & Bradshaw, K. (2020). Detecting plant species in the field with deep learning and drone technology. *Methods in Ecology and Evolution*, 11(11), 1509–1519. <https://doi.org/10.1111/2041-210X.13473>

Kalacska, M., Lucanus, O., Arroyo-Mora, J. P., Laliberté, É., Elmer, K., Leblanc, G., & Groves, A. (2020). Accuracy of 3D Landscape Reconstruction without Ground Control Points Using Different UAS Platforms. *Drones*, 4(2), Article 2. <https://doi.org/10.3390/drones4020013>

Katal, N., Rzanny, M., Mäder, P., & Wäldchen, J. (2022). Deep Learning in Plant Phenological Research: A Systematic Literature Review. *Frontiers in Plant Science*, 13. <https://www.frontiersin.org/articles/10.3389/fpls.2022.805738>

Kattenborn, T., Eichel, J., & Fassnacht, F. E. (2019). Convolutional Neural Networks enable efficient, accurate and fine-grained segmentation of plant species and communities from high-resolution UAV imagery. *Scientific Reports*, 9(1), Article 1. <https://doi.org/10.1038/s41598-019-53797-9>

- Kattenborn, T., Eichel, J., Wiser, S., Burrows, L., Fassnacht, F. E., & Schmidlein, S. (2020). Convolutional Neural Networks accurately predict cover fractions of plant species and communities in Unmanned Aerial Vehicle imagery. *Remote Sensing in Ecology and Conservation*, 6(4), 472–486. <https://doi.org/10.1002/rse2.146>
- Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in Vegetation Remote Sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24–49. <https://doi.org/10.1016/j.isprsjprs.2020.12.010>
- Kattenborn, T., Schiefer, F., Frey, J., Feilhauer, H., Mahecha, M. D., & Dormann, C. F. (2022). Spatially autocorrelated training and validation samples inflate performance assessment of convolutional neural networks. *ISPRS Open Journal of Photogrammetry and Remote Sensing*, 5, 100018. <https://doi.org/10.1016/j.photo.2022.100018>
- Kaul, V., Enslin, S., & Gross, S. A. (2020). History of artificial intelligence in medicine. *Gastrointestinal Endoscopy*, 92(4), 807–812. <https://doi.org/10.1016/j.gie.2020.06.040>
- Key, T., Warner, T. A., McGraw, J. B., & Fajvan, M. A. (2001). A Comparison of Multispectral and Multitemporal Information in High Spatial Resolution Imagery for Classification of Individual Tree Species in a Temperate Hardwood Forest. *Remote Sensing of Environment*, 75(1), 100–112. [https://doi.org/10.1016/S0034-4257\(00\)00159-0](https://doi.org/10.1016/S0034-4257(00)00159-0)
- Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., Xiao, T., Whitehead, S., Berg, A. C., Lo, W.-Y., Dollár, P., & Girshick, R. (2023). *Segment Anything* (arXiv:2304.02643). arXiv. <https://doi.org/10.48550/arXiv.2304.02643>
- Klosterman, S., Melaas, E., Wang, J. A., Martinez, A., Frederick, S., O’Keefe, J., Orwig, D. A., Wang, Z., Sun, Q., Schaaf, C., Friedl, M., & Richardson, A. D. (2018). Fine-scale perspectives on landscape phenology from unmanned aerial vehicle (UAV) photography.

*Agricultural and Forest Meteorology*, 248, 397–407.

<https://doi.org/10.1016/j.agrformet.2017.10.015>

Klosterman, S., & Richardson, A. D. (2017). Observing Spring and Fall Phenology in a Deciduous Forest with Aerial Drone Imagery. *Sensors*, 17(12), Article 12.  
<https://doi.org/10.3390/s17122852>

Komárek, J. (2020). The perspective of unmanned aerial systems in forest management: Do we really need such details? *Applied Vegetation Science*, 23(4), 718–721.  
<https://doi.org/10.1111/avsc.12503>

Korpela, I., & Tokola, T. (2006). Potential of Aerial Image-Based Monoscopic and Multiview Single-Tree Forest Inventory: A Simulation Approach. *Forest Science*, 52, 136–147.

Korznikov, K. A., Kislov, D. E., Altman, J., Doležal, J., Vozmishcheva, A. S., & Krestov, P. V. (2021). Using U-Net-Like Deep Convolutional Neural Networks for Precise Tree Recognition in Very High Resolution RGB (Red, Green, Blue) Satellite Images. *Forests*, 12(1), Article 1. <https://doi.org/10.3390/f12010066>

Lausch, A., Erasmi, S., King, D. J., Magdon, P., & Heurich, M. (2017). Understanding Forest Health with Remote Sensing—Part II—A Review of Approaches and Data Models. *Remote Sensing*, 9(2), Article 2. <https://doi.org/10.3390/rs9020129>

Lechner, A. M., Foody, G. M., & Boyd, D. S. (2020). Applications in Remote Sensing to Forest Ecology and Management. *One Earth*, 2(5), 405–412.  
<https://doi.org/10.1016/j.oneear.2020.05.001>

Lechowicz, M. J. (1984). Why Do Temperate Deciduous Trees Leaf Out at Different Times? Adaptation and Ecology of Forest Communities. *The American Naturalist*, 124(6), 821–842. <https://doi.org/10.1086/284319>

Leuzinger, S., Zotz, G., Asshoff, R., & Körner, C. (2005). Responses of deciduous forest trees to severe drought in Central Europe. *Tree Physiology*, 25(6), 641–650. <https://doi.org/10.1093/treephys/25.6.641>

Lisein, J., Michez, A., Claessens, H., & Lejeune, P. (2015). Discrimination of Deciduous Tree Species from Time Series of Unmanned Aerial System Imagery. *PLOS ONE*, 10(11), e0141006. <https://doi.org/10.1371/journal.pone.0141006>

Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3431–3440. <https://doi.org/10.1109/CVPR.2015.7298965>

Lopatin, J., Dolos, K., Kattenborn, T., & Fassnacht, F. E. (2019). How canopy shadow affects invasive plant species classification in high spatial resolution remote sensing. *Remote Sensing in Ecology and Conservation*, 5(4), 302–317. <https://doi.org/10.1002/rse2.109>

Matile, P. (2000). Biochemistry of Indian summer: Physiology of autumnal leaf coloration. *Experimental Gerontology*, 35, 145–158. [https://doi.org/10.1016/S0531-5565\(00\)00081-4](https://doi.org/10.1016/S0531-5565(00)00081-4)

Nagendra, H., Lucas, R., Honrado, J. P., Jongman, R. H. G., Tarantino, C., Adamo, M., & Mairota, P. (2013). Remote sensing for conservation monitoring: Assessing protected areas, habitat extent, habitat condition, species diversity, and threats. *Ecological Indicators*, 33, 45–59. <https://doi.org/10.1016/j.ecolind.2012.09.014>

Natesan, S., Armenakis, C., & Vepakomma, U. (2020). Individual tree species identification using Dense Convolutional Network (DenseNet) on multitemporal RGB images from UAV. *Journal of Unmanned Vehicle Systems*, 8(4), 310–333. <https://doi.org/10.1139/juvs-2020-0014>

Nevalainen, O., Honkavaara, E., Tuominen, S., Viljanen, N., Hakala, T., Yu, X., Hyppä, J., Saari, H., Pölönen, I., Imai, N. N., & Tommaselli, A. M. G. (2017). Individual Tree Detection and

- Classification with UAV-Based Photogrammetric Point Clouds and Hyperspectral Imaging. *Remote Sensing*, 9(3), Article 3. <https://doi.org/10.3390/rs9030185>
- Nezami, S., Khoramshahi, E., Nevalainen, O., Pölönen, I., & Honkavaara, E. (2020). Tree Species Classification of Drone Hyperspectral and RGB Imagery with Deep Learning Convolutional Neural Networks. *Remote Sensing*, 12(7), Article 7. <https://doi.org/10.3390/rs12071070>
- Norby, R. J., Hartz-Rubin, J. S., & Verbrugge, M. J. (2003). Phenological responses in maple to experimental atmospheric warming and CO<sub>2</sub> enrichment. *Global Change Biology*, 9(12), 1792–1801. <https://doi.org/10.1111/j.1365-2486.2003.00714.x>
- Nuijten, R. J. G., Coops, N. C., Goodbody, T. R. H., & Pelletier, G. (2019). Examining the Multi-Seasonal Consistency of Individual Tree Segmentation on Deciduous Stands Using Digital Aerial Photogrammetry (DAP) and Unmanned Aerial Systems (UAS). *Remote Sensing*, 11(7), Article 7. <https://doi.org/10.3390/rs11070739>
- Onishi, M., & Ise, T. (2021). Explainable identification and mapping of trees using UAV RGB image and deep learning. *Scientific Reports*, 11(1), 903. <https://doi.org/10.1038/s41598-020-79653-9>
- Onishi, M., Watanabe, S., Nakashima, T., & Ise, T. (2022). Practicality and Robustness of Tree Species Identification Using UAV RGB Image and Deep Learning in Temperate Forest in Japan. *Remote Sensing*, 14(7), Article 7. <https://doi.org/10.3390/rs14071710>
- Ørka, H. O., Næsset, E., & Bollandsås, O. M. (2009). Classifying species of individual trees by intensity and structure features derived from airborne laser scanner data. *Remote Sensing of Environment*, 113(6), 1163–1174. <https://doi.org/10.1016/j.rse.2009.02.002>
- Over, J.-S. R., Ritchie, A. C., Kranenburg, C. J., Brown, J. A., Buscombe, D. D., Noble, T., Sherwood, C. R., Warrick, J. A., & Wernette, P. A. (2021). Processing coastal imagery with

Agisoft Metashape Professional Edition, version 1.6—Structure from motion workflow documentation. In *Processing coastal imagery with Agisoft Metashape Professional Edition, version 1.6—Structure from motion workflow documentation* (USGS Numbered Series 2021–1039; Open-File Report, Vols. 2021–1039, p. 46). U.S. Geological Survey.  
<https://doi.org/10.3133/ofr20211039>

Park, J. Y., Muller-Landau, H. C., Lichstein, J. W., Rifai, S. W., Dandois, J. P., & Bohlman, S. A. (2019). Quantifying Leaf Phenology of Individual Trees and Species in a Tropical Forest Using Unmanned Aerial Vehicle (UAV) Images. *Remote Sensing*, 11(13), Article 13.  
<https://doi.org/10.3390/rs11131534>

Python Software Foundation. (n.d.). *Python Language Reference* (2.7) [Computer software].  
<http://www.python.org>

R Core Team. (2021). *R: A language and environment for statistical computing* (4.1.1) [Computer software]. R Foundation for Statistical Computing. <https://www.R-project.org/>  
Renner, S. S., & Zohner, C. M. (2019). The occurrence of red and yellow autumn leaves explained by regional differences in insolation and temperature. *New Phytologist*, 224(4), 1464–1471.  
<https://doi.org/10.1111/nph.15900>

Richardson, A. D., & O’Keefe, J. (2009). Phenological Differences Between Understory and Overstory. In A. Noormets (Ed.), *Phenology of Ecosystem Processes* (pp. 87–117). Springer New York. [https://doi.org/10.1007/978-1-4419-0026-5\\_4](https://doi.org/10.1007/978-1-4419-0026-5_4)

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *arXiv:1505.04597 [Cs]*. <http://arxiv.org/abs/1505.04597>

Royer, D. L., McElwain, J. C., Adams, J. M., & Wilf, P. (2008). Sensitivity of leaf size and shape to climate within Acer rubrum and Quercus kelloggii. *New Phytologist*, 179(3), 808–817.  
<https://doi.org/10.1111/j.1469-8137.2008.02496.x>

Royer, D. L., Meyerson, L. A., Robertson, K. M., & Adams, J. M. (2009). Phenotypic Plasticity of Leaf Shape along a Temperature Gradient in *Acer rubrum*. *PLOS ONE*, 4(10), e7653. <https://doi.org/10.1371/journal.pone.0007653>

Savage, C. (2001). *Recolonisation forestière dans les Basses Laurentides au sud du domaine climacique de l’érablière à bouleau jaune* [Université de Montréal]. [https://sbl.umontreal.ca/public/FAS/sbl/Documents/4-Territoire/Biodiversite/memoire\\_Caroline\\_Savage.pdf](https://sbl.umontreal.ca/public/FAS/sbl/Documents/4-Territoire/Biodiversite/memoire_Caroline_Savage.pdf)

Schiefer, F., Kattenborn, T., Frick, A., Frey, J., Schall, P., Koch, B., & Schmidlein, S. (2020). Mapping forest tree species in high resolution UAV-based RGB-imagery by means of convolutional neural networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 170, 205–215. <https://doi.org/10.1016/j.isprsjprs.2020.10.015>

Schiefer, F., Schmidlein, S., Frick, A., Frey, J., Klinke, R., Zielewska-Büttner, K., Junttila, S., Uhl, A., & Kattenborn, T. (2023). UAV-based reference data for the prediction of fractional cover of standing deadwood from Sentinel time series. *ISPRS Open Journal of Photogrammetry and Remote Sensing*, 8, 100034. <https://doi.org/10.1016/j.ophoto.2023.100034>

Taddia, Y., Stecchi, F., & Pellegrinelli, A. (2019). Using Dji Phantom 4 Rtk Drone for Topographic Mapping of Coastal Areas. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W13, 625–630. <https://doi.org/10.5194/isprs-archives-XLII-2-W13-625-2019>

*The PhenoCam Network.* (n.d.). Retrieved September 28, 2023, from <https://phenocam.nau.edu/webcam/sites/laurentides/>

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2023). *Attention Is All You Need* (arXiv:1706.03762). arXiv.  
<http://arxiv.org/abs/1706.03762>

Veras, H. F. P., Ferreira, M. P., da Cunha Neto, E. M., Figueiredo, E. O., Corte, A. P. D., & Sanquetta, C. R. (2022). Fusing multi-season UAS images with convolutional neural networks to map tree species in Amazonian forests. *Ecological Informatics*, 71, 101815.  
<https://doi.org/10.1016/j.ecoinf.2022.101815>

Wagner, F. H., Sanchez, A., Tarabalka, Y., Lotte, R. G., Ferreira, M. P., Aidar, M. P. M., Gloor, E., Phillips, O. L., & Aragão, L. E. O. C. (2019). Using the U-net convolutional network to map forest types and disturbance in the Atlantic rainforest with very high resolution images. *Remote Sensing in Ecology and Conservation*, 5(4), 360–375.  
<https://doi.org/10.1002/rse2.111>

Weil, G., Lensky, I. M., Resheff, Y. S., & Levin, N. (2017). Optimizing the Timing of Unmanned Aerial Vehicle Image Acquisition for Applied Mapping of Woody Vegetation Species Using Feature Selection. *Remote Sensing*, 9(11), Article 11.  
<https://doi.org/10.3390/rs9111130>

Weinstein, B. G., Marconi, S., Bohlman, S. A., Zare, A., & White, E. P. (2020). Cross-site learning in deep learning RGB tree crown detection. *Ecological Informatics*, 56, 101061.  
<https://doi.org/10.1016/j.ecoinf.2020.101061>

Weinstein, B. G., Marconi, S., Bohlman, S., Zare, A., & White, E. (2019). Individual Tree-Crown Detection in RGB Imagery Using Semi-Supervised Deep Learning Neural Networks. *Remote Sensing*, 11(11), Article 11. <https://doi.org/10.3390/rs11111309>

Wolter, P., Mladenoff, D., Host, G., & Crow, T. (1995). Improved Forest Classification in the Northern Lake States Using Multi-Temporal Landsat Imagery. *Photogrammetric Engineering and Remote Sensing*, 61.

Woodcock, C. E., & Strahler, A. H. (1987). The factor of scale in remote sensing. *Remote Sensing of Environment*, 21(3), 311–332. [https://doi.org/10.1016/0034-4257\(87\)90015-0](https://doi.org/10.1016/0034-4257(87)90015-0)

Yang, J., He, Y., & Caspersen, J. (2017). Individual tree-based species classification for uneven-aged, mixed-deciduous forests using multi-seasonal WorldView-3 images. *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 827–830. <https://doi.org/10.1109/IGARSS.2017.8127080>

Yang, L., Chen, W., Bi, P., Tang, H., Zhang, F., & Wang, Z. (2022). Improving vegetation segmentation with shadow effects based on double input networks using polarization images. *Computers and Electronics in Agriculture*, 199, 107123. <https://doi.org/10.1016/j.compag.2022.107123>

Yang, Q., Shi, L., Han, J., Zha, Y., & Zhu, P. (2019). Deep convolutional neural networks for rice grain yield estimation at the ripening stage using UAV-based remotely sensed images. *Field Crops Research*, 235, 142–153. <https://doi.org/10.1016/j.fcr.2019.02.022>

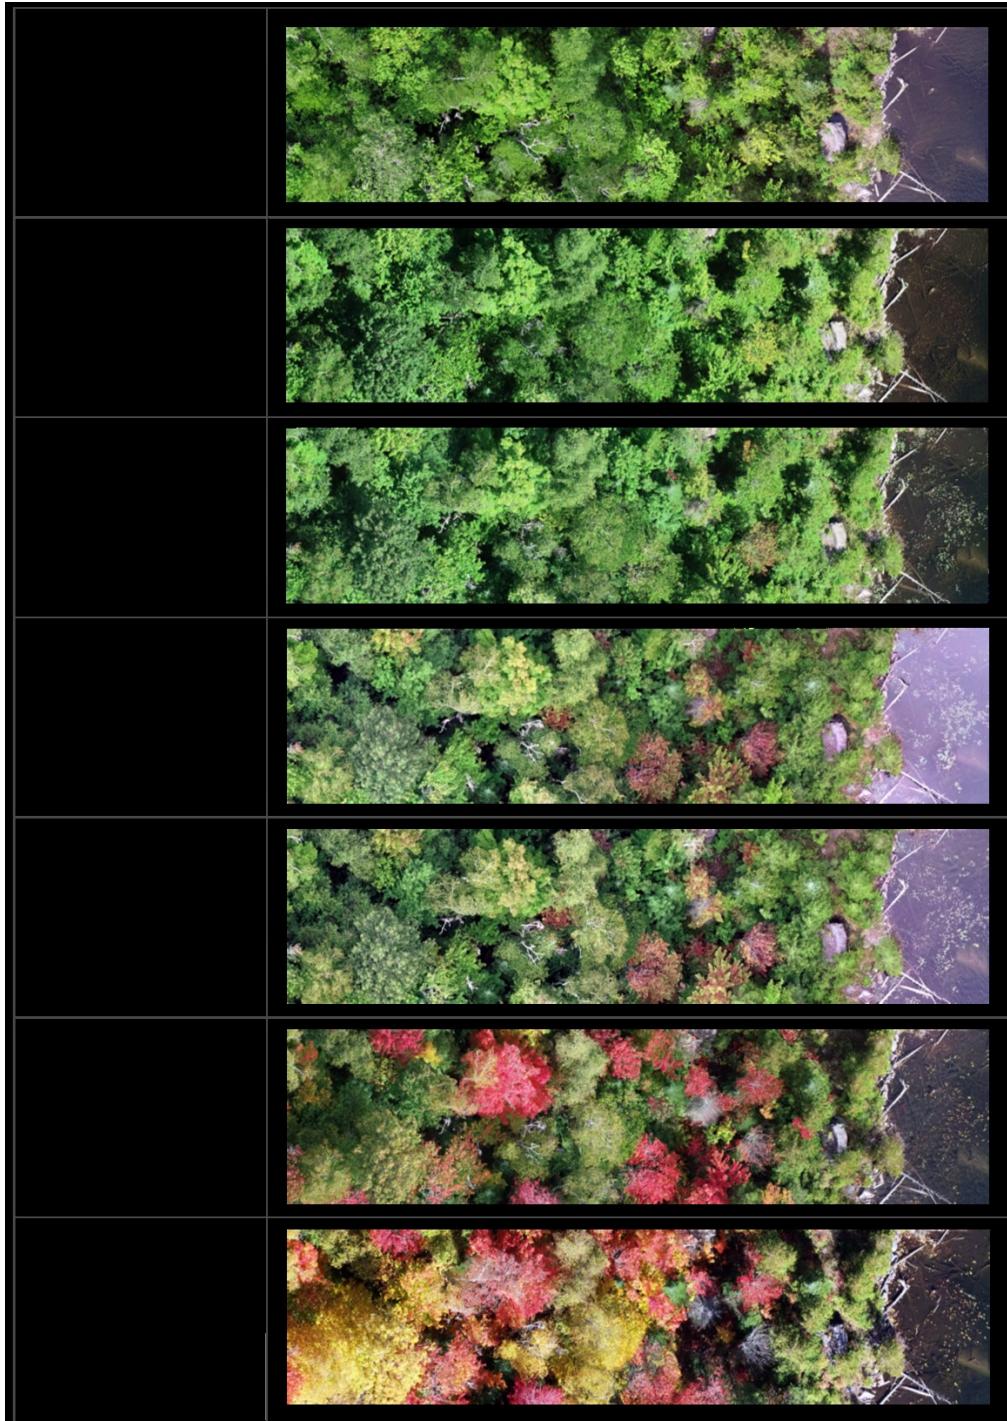
Zani, D., Crowther, T. W., Mo, L., Renner, S. S., & Zohner, C. M. (2020). Increased growing-season productivity drives earlier autumn leaf senescence in temperate trees. *Science*, 370(6520), 1066–1071. <https://doi.org/10.1126/science.abd8911>

Zhang, C., Zhou, J., Wang, H., Tan, T., Cui, M., Huang, Z., Wang, P., & Zhang, L. (2022). Multi-Species Individual Tree Segmentation and Identification Based on Improved Mask R-CNN and UAV Imagery in Mixed Forests. *Remote Sensing*, 14(4), Article 4. <https://doi.org/10.3390/rs14040874>

Zhang, M., Lin, H., Wang, G., Sun, H., & Fu, J. (2018). Mapping Paddy Rice Using a Convolutional Neural Network (CNN) with Landsat 8 Datasets in the Dongting Lake Area, China. *Remote Sensing*, 10(11), Article 11. <https://doi.org/10.3390/rs10111840>

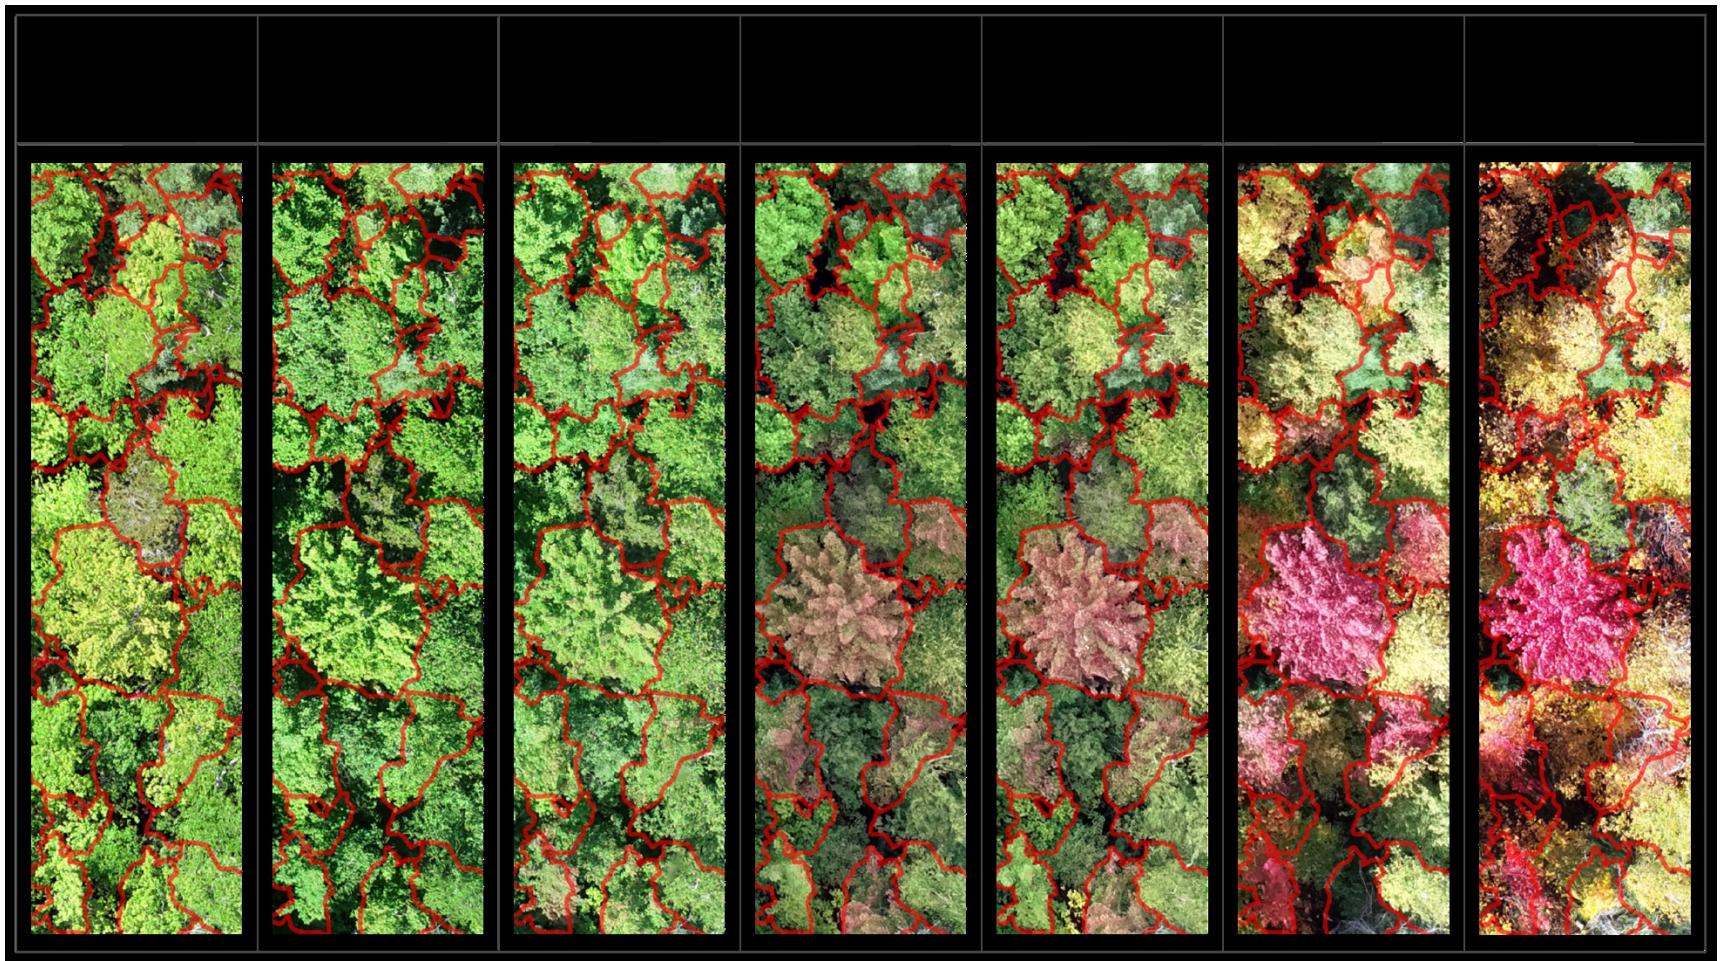
Zhong, G., Ling, X., & Wang, L.-N. (2019). From shallow feature learning to deep learning: Benefits from the width and depth of deep architectures. *WIREs Data Mining and Knowledge Discovery*, 9(1), e1255. <https://doi.org/10.1002/widm.1255>

## Annexes



**Supplementary Figure S1** Illumination conditions for each date of acquisition

The imagery with more diffuse light conditions are from August and early September, and the imagery with more sunny light conditions are from June, July, and October. May and late September have intermediate light conditions.

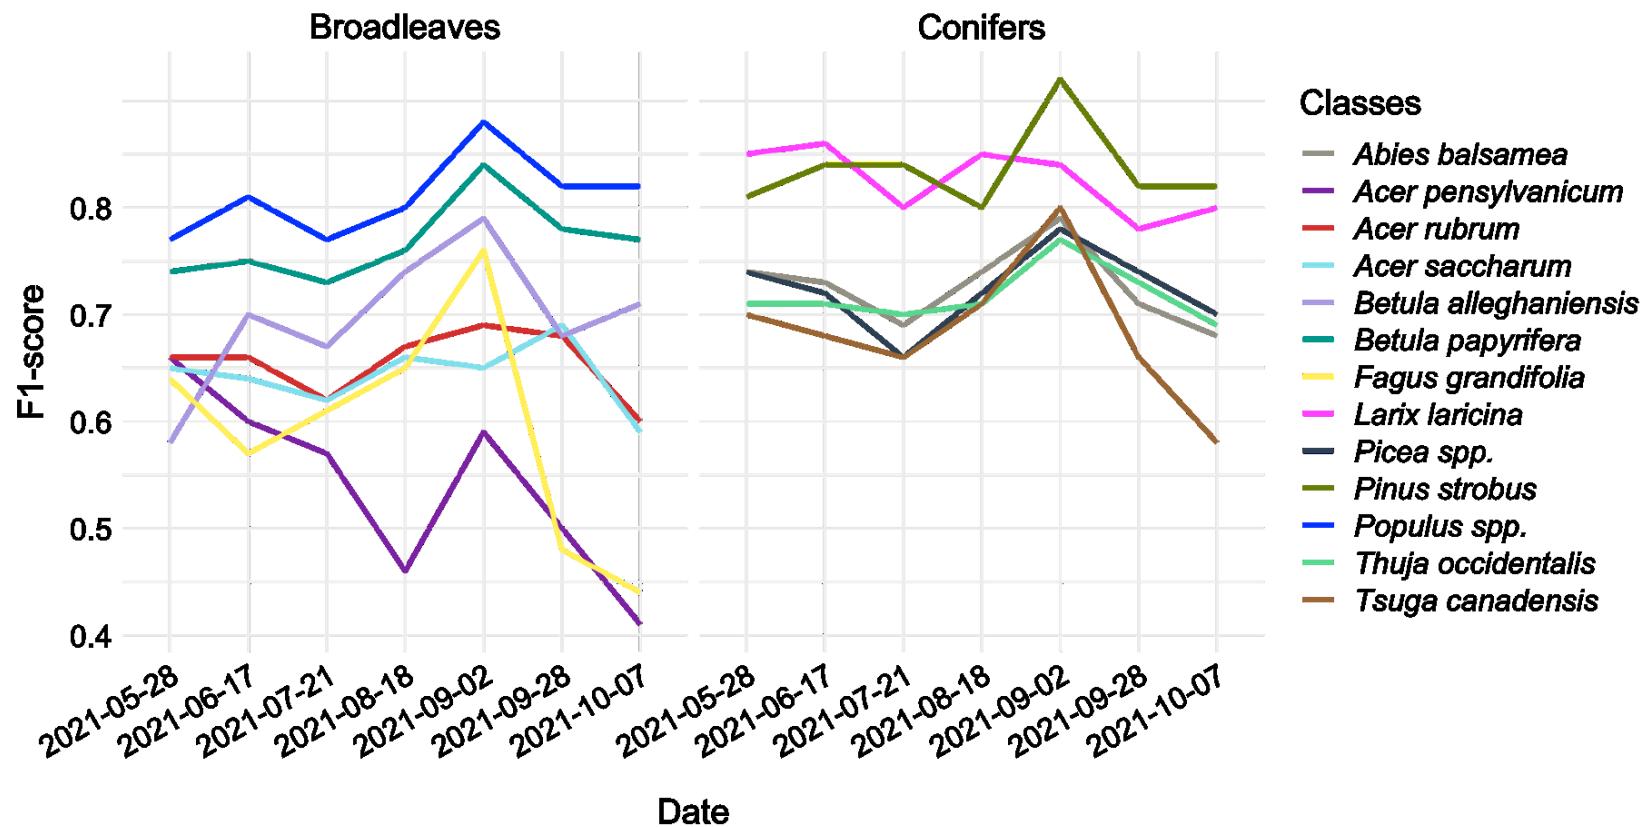


**Supplementary Figure S2 Example of annotated tree crowns**

It is possible to see that the annotations (contour of the polygons in red) are well aligned with the orthomosaic for each date, making it possible to apply the segmentation done on the imagery of early September onto the orthomosaics from other dates.

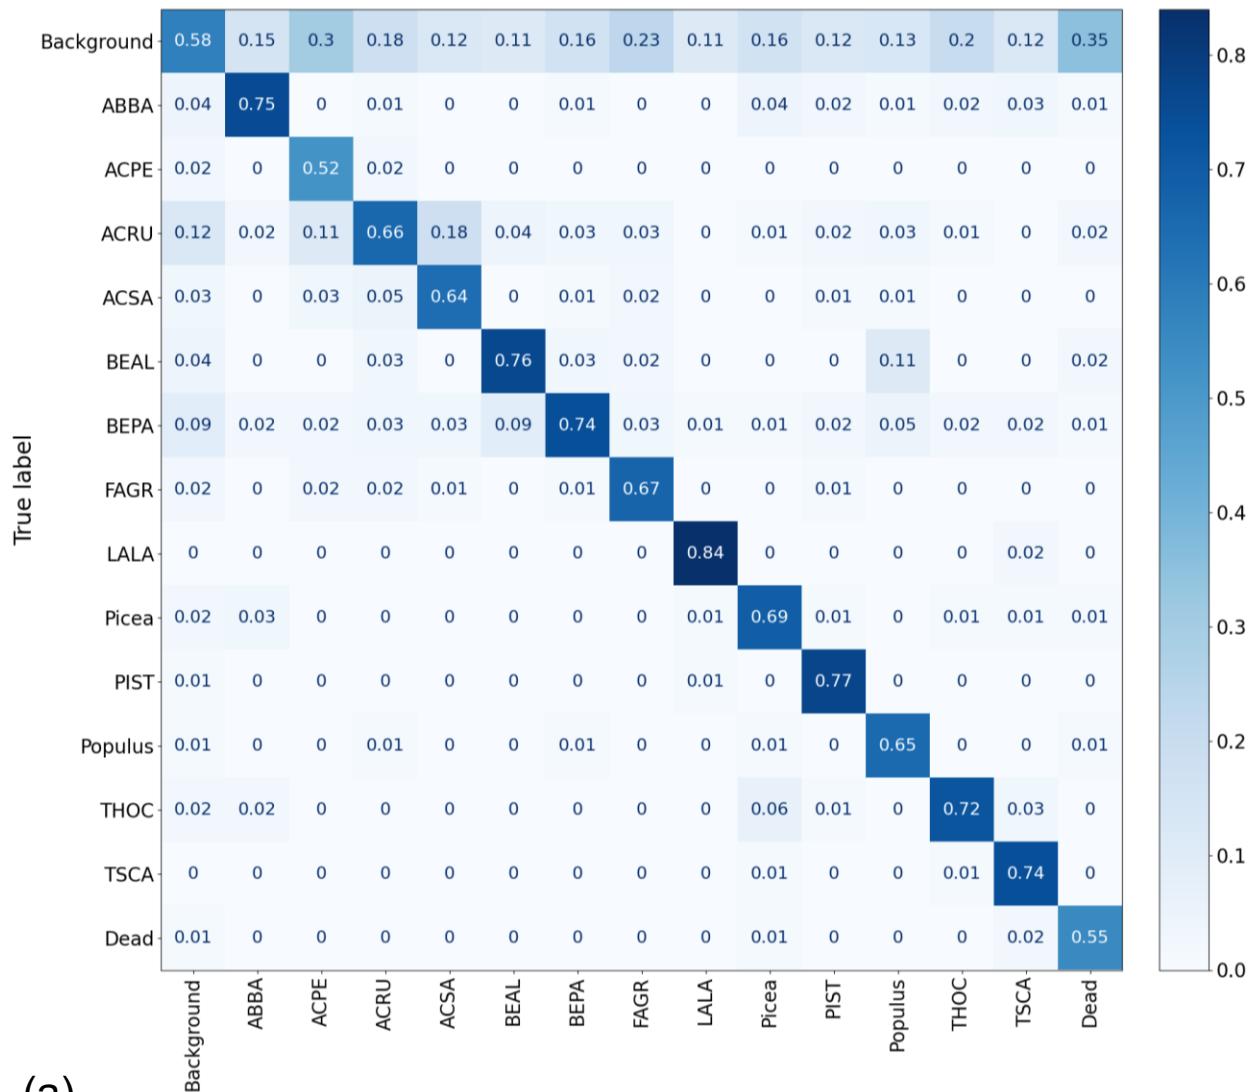


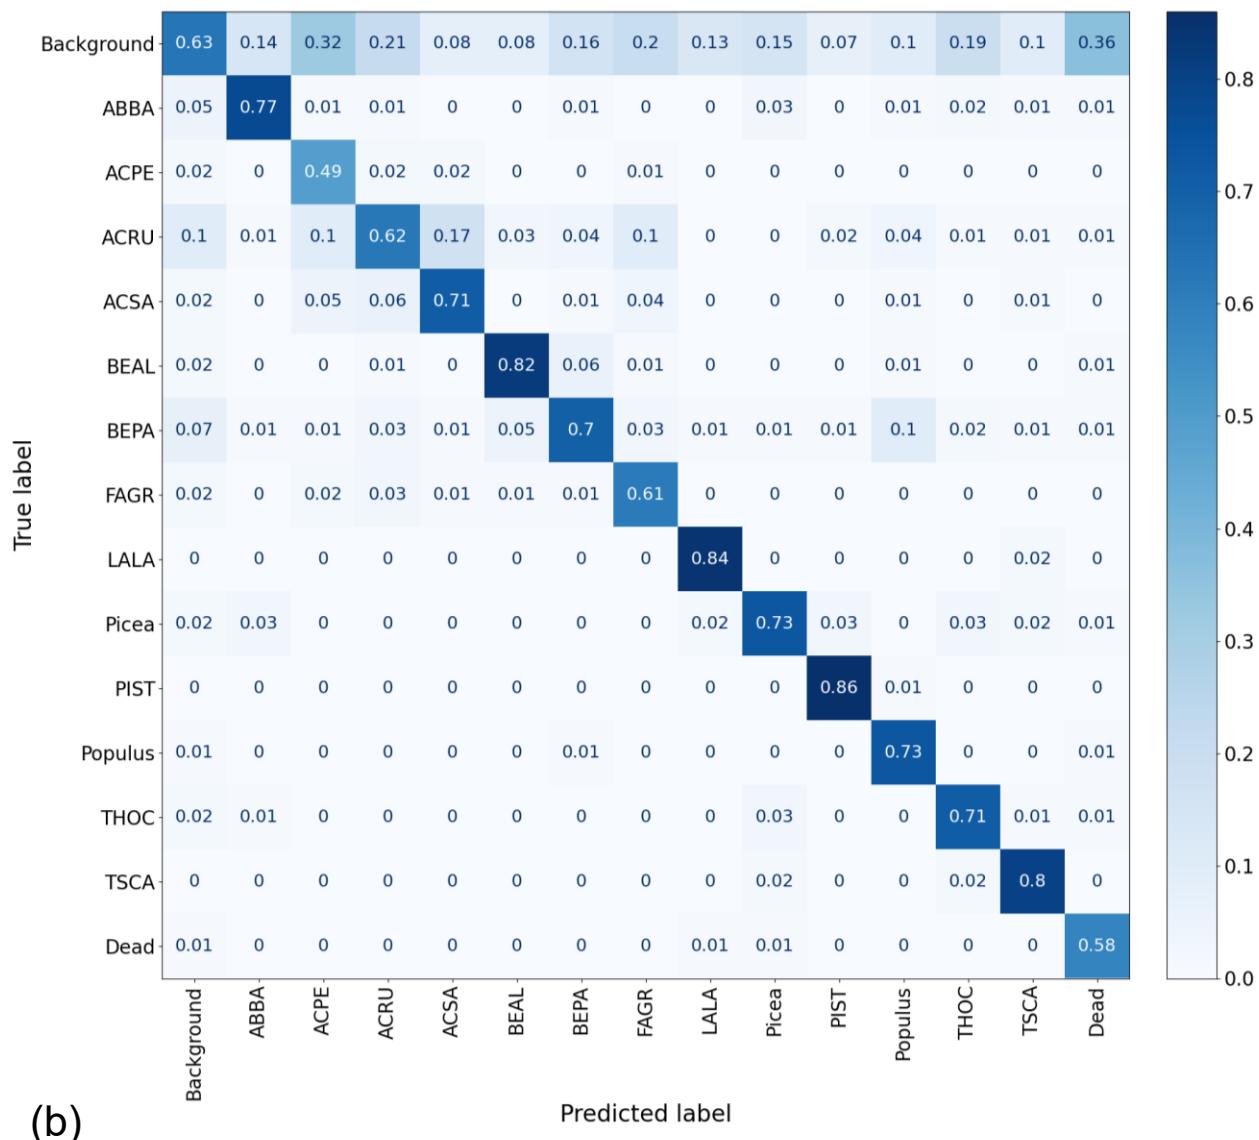
**Supplementary Figure S3 Example of tiles and masks from the early September imagery**  
The tiles represent a section of the orthomosaic of 256 x 256 pixels and the masks represent the annotations for that section in raster format. The different colours in the masks correspond to different classes.



**Supplementary Figure S4 Variation of the F1-scores for each class for the seven dates**

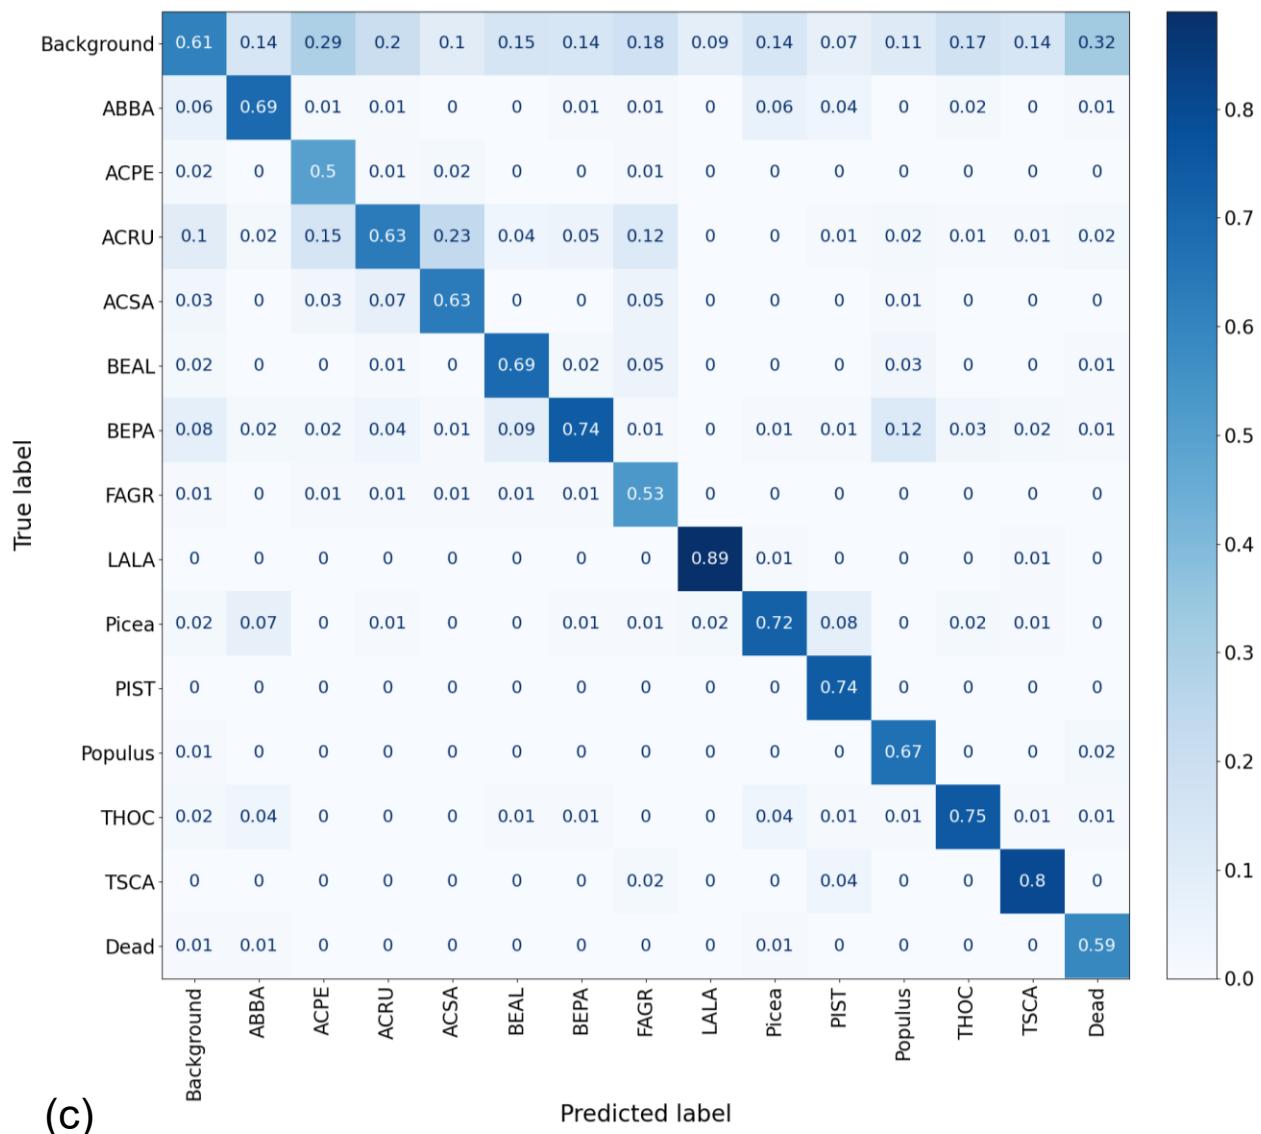
The temporal variation of the F1-score throughout the growing season is more variable for deciduous broadleaf species (left) than it is for conifers (right). Most species show a peak in their F1-score for the September 2<sup>nd</sup> model, and often a decrease in the F1-score for the October 7<sup>th</sup> model.

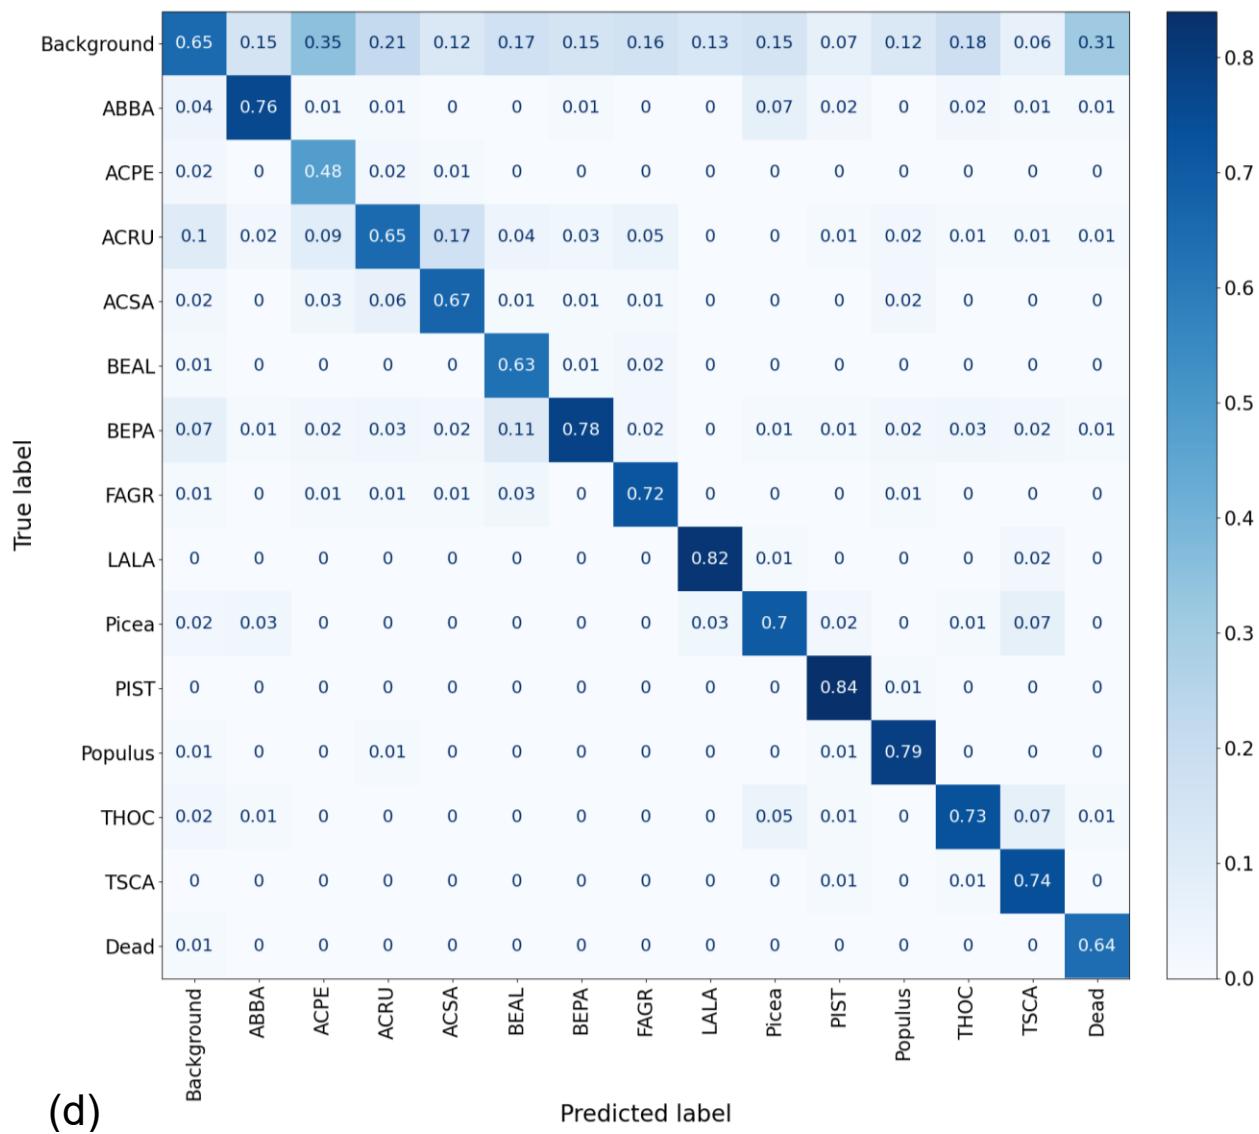


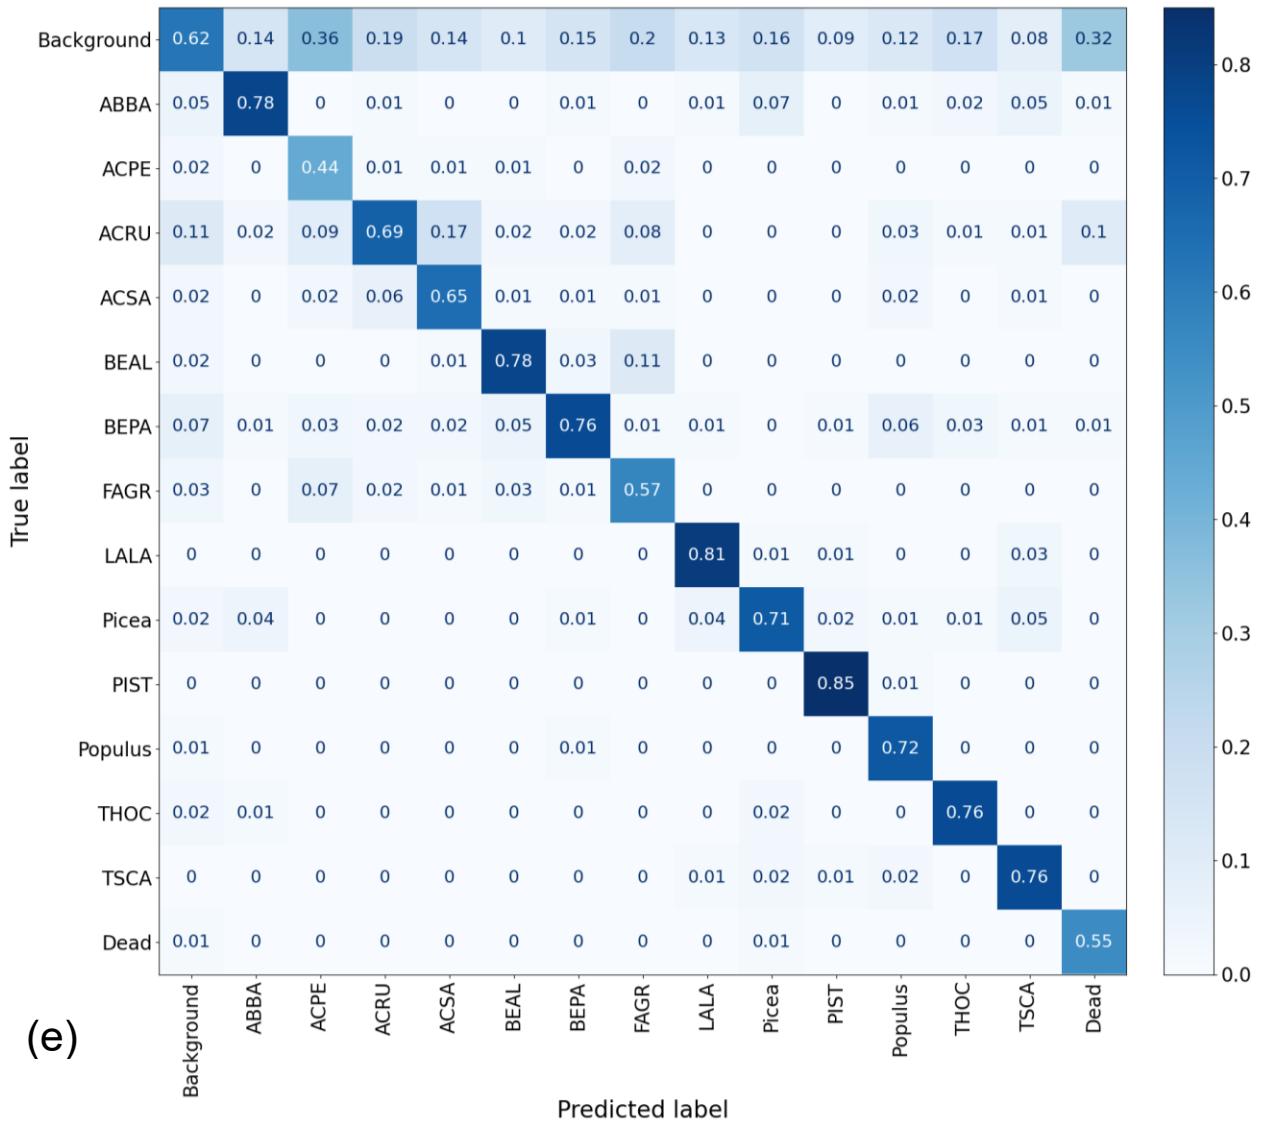


(b)

Predicted label







**Supplementary Figure S5 Confusion matrices for each class for the remaining five dates**  
The values represent the overlap (from 0-1) between the annotations (true label) and the predictions (predicted label) done by the model on unseen imagery from (a) May 28th, 2021, (b) June 17th, 2021, (c) July 21st, 2021, (d) August 18th, 2021, (e) September 28th, 2021. ABBA: *Abies balsamea*, ACPE: *Acer pensylvanicum*, ACRU: *Acer rubrum*, ACSA: *Acer saccharum*, BEAL: *Betula alleghaniensis*, BEPA: *Betula papyrifera*, FAGR: *Fagus grandifolia*, LALA: *Larix laricina*, Picea: *Picea spp.*, PIST: *Pinus strobus*, Populus: *Populus spp.*, THOC: *Thuja occidentalis*, TSCA: *Tsuga canadensis*.