



Schweizerische Eidgenossenschaft
Confédération suisse
Confederazione Svizzera
Confederaziun svizra

Eidgenössisches Departement für Umwelt, Verkehr, Energie und Kommunikation UVEK
Département fédéral de l'environnement, des transports, de l'énergie et de la communication DETEC
Dipartimento federale dell'ambiente, dei trasporti, dell'energia e delle comunicazioni DATEC

Bundesamt für Strassen
Office fédéral des routes
Ufficio federale delle Strade

Automatisierte Erfassung invasiver Neophyten an Autobahnen

**Détection automatisée de néophytes envahissantes le long
d'autoroutes**

**Automated detection of invasive alien plants along
highways**

Eidg. Forschungsanstalt WSL, Birmensdorf
Michael Nobis, Dr. rer. nat., Dipl. Biologe
Christian Ginzler, Mag. rer. nat.

ETH Zürich, Computer Vision Laboratory (CVL)
Radu Timofte, Dr. Ing., Dipl. Ing., Msc
Christoph Mayer, Msc ETH

**Forschungsauftrag VSS 2016/224 auf Antrag des Schweizerischen
Verbandes der Strassen- und Verkehrsfachleute (VSS)**

Oktober 2020

1690

Der Inhalt dieses Berichtes verpflichtet nur den (die) vom Bundesamt für Strassen unterstützten Autor(en). Dies gilt nicht für das Formular 3 "Projektabschluss", welches die Meinung der Begleitkommission darstellt und deshalb nur diese verpflichtet.

Bezug: Schweizerischer Verband der Strassen- und Verkehrsfachleute (VSS)

Le contenu de ce rapport n'engage que les auteurs ayant obtenu l'appui de l'Office fédéral des routes. Cela ne s'applique pas au formulaire 3 « Clôture du projet », qui représente l'avis de la commission de suivi et qui n'engage que cette dernière.

Diffusion : Association suisse des professionnels de la route et des transports (VSS)

La responsabilità per il contenuto di questo rapporto spetta unicamente agli autori sostenuti dall'Ufficio federale delle strade. Tale indicazione non si applica al modulo 3 "conclusione del progetto", che esprime l'opinione della commissione d'accompagnamento e di cui risponde solo quest'ultima.

Ordinazione: Associazione svizzera dei professionisti della strada e dei trasporti (VSS)

The content of this report engages only the author(s) supported by the Federal Roads Office. This does not apply to Form 3 'Project Conclusion' which presents the view of the monitoring committee.

Distribution: Swiss Association of Road and Transportation Experts (VSS)



Schweizerische Eidgenossenschaft
Confédération suisse
Confederazione Svizzera
Confederaziun svizra

Eidgenössisches Departement für Umwelt, Verkehr, Energie und Kommunikation UVEK
Département fédéral de l'environnement, des transports, de l'énergie et de la communication DETEC
Dipartimento federale dell'ambiente, dei trasporti, dell'energia e delle comunicazioni DATEC

Bundesamt für Strassen
Office fédéral des routes
Ufficio federale delle Strade

Automatisierte Erfassung invasiver Neophyten an Autobahnen

**Détection automatisée de néophytes envahissantes le long
d'autoroutes**

**Automated detection of invasive alien plants along
highways**

Eidg. Forschungsanstalt WSL, Birmensdorf
Michael Nobis, Dr. rer. nat., Dipl. Biologe
Christian Ginzler, Mag. rer. nat.

ETH Zürich, Computer Vision Laboratory (CVL)
Radu Timofte, Dr. Ing., Dipl. Ing., Msc
Christoph Mayer, Msc ETH

**Forschungsauftrag VSS 2016/224 auf Antrag des Schweizerischen
Verbandes der Strassen- und Verkehrsfachleute (VSS)**

Oktober 2020

1690

Impressum

Forschungsstelle und Projektteam

Projektleitung

Michael Nobis, WSL, Birmensdorf

Mitglieder

Radu Timofte, ETH Zürich

Christoph Mayer, ETH Zürich & WSL, Birmensdorf

Christian Ginzler, WSL, Birmensdorf

Federführende Fachkommission

Fachkommission 2: Projektierung

Begleitkommission

Präsidentin

Sibyl Rometsch, Info Flora, Bern

Mitglieder

Emmanuel Baltsavias, ETH Zürich, Institut für Geodäsie und Photogrammetrie

Roger Beer, Genève

Jsabelle Buckelmüller, Kanton Zürich, AWEL, Sektion Biosicherheit

Erwin Egger, DGMR, SIERA

Karin Hilfiker, SBB, Bern

Urs Landergott, FORNAT AG, Zürich

Beat Städler, Kanton Zürich, Baudirektion, Strasseninspektorat

Peter Steinauer, SKK, Wettingen

Marguerite Trocmé-Maillard, ASTRA, Bern

Laurence von Fellenberg, BAFU, Bern

Gian-Reto Walther, BAFU, Bern

KO-Finanzierung des Forschungsprojekts

Bundesamt für Umwelt (BAFU), Bern

Bezugsquelle

Das Dokument kann kostenlos von <http://www.mobilityplatform.ch> heruntergeladen werden.

Inhaltsverzeichnis

	Impressum	4
	Zusammenfassung	7
	Résumé	9
	Summary	11
1	Einführung	13
1.1	Ziel der Studie	13
1.2	Invasive Neophyten an Strassen	13
1.3	Künstliche Intelligenz und maschinelles Sehen	14
2	Untersuchungsgebiet und Auswahl der Arten	15
2.1	Untersuchungsgebiet	15
2.2	Auswahl der Arten	15
2.2.1	Götterbaum (<i>Ailanthus altissima</i>)	16
2.2.2	Schmalblättriges Greiskraut (<i>Senecio inaequidens</i>)	16
3	Methoden	19
3.1	Übersicht	19
3.2	Befahrungen und Aufnahmetechnik.....	19
3.3	Markieren der Trainingsbilder für Deep Learning	21
3.4	Deep-Learning-Modelle.....	23
3.4.1	Architektur, Design und Training der Deep-Learning-Modelle.....	23
3.5	Processing-Pipeline	24
3.5.1	Laufzeit, Speicherbedarf und andere Kennzahlen	26
4	Evaluierung der trainierten Modelle	27
4.1	Statistische Kennzahlen	27
4.2	Trainingsbilder, Validierungsbilder und Testbilder	29
4.3	CNNs mit Trainingsbildern aus drei Befahrungen.....	29
4.4	CNNs mit Trainingsbildern aus nur einer Befahrung	31
4.5	Evaluierung einer Frame-basierten Arterkennung.....	33
4.6	Visuelle Überprüfung der CNN Resultate	35
5	Verbreitungskarten	39
5.1	Verarbeitung der georeferenzierten CNN Resultate	39
5.2	Kartendarstellung	40
5.3	Verbreitungskarte des Götterbaums	41
5.4	Verbreitungskarte des Schmalblättrigen Greiskrauts.....	41
6	Karteninterpretation und Auswertungen	45
6.1	Reproduzierbarkeit des Kartieransatzes	45
6.2	Einfluss baulicher Unterschiede	47
6.3	Veränderungen zwischen den Befahrungen.....	49
6.3.1	Einfluss der Siedlungsfläche	51
7	Folgerungen und Anwendung der Ergebnisse	55
	Anhänge	57
	Glossar	63
	Literaturverzeichnis	64
	Projektabschluss	69
	Verzeichnis der Berichte der Forschung im Strassenwesen	72

Zusammenfassung

Verkehrsträger wie Autobahnen und Eisenbahnlinien sind Ausbreitungskorridore für invasive Neophyten. Diese können erhöhte Unterhaltskosten verursachen und sich ausgehend von den Verkehrswegen in angrenzende Landschaften und Siedlungsgebiete ausbreiten. Wegen ihrer hohen Ausbreitungsdynamik und aufwendigen Experten-Kartierungen ist die aktuelle Verbreitung invasiver Arten an Autobahnen und Eisenbahnlinien meist nicht näher bekannt. Angesichts der rasanten Entwicklung in den Bereichen digitaler Kameratechnik und künstlicher Intelligenz wurde in der vorliegenden Arbeit daher eine auf KI (Deep Learning) und maschinellem Sehen basierende, automatisierte Kartierung von zwei invasiven Neophyten an Autobahnen im Schweizer Mittelland entwickelt und angewendet.

Als Testarten dienten das aus Südafrika stammende Schmalblättrige Greiskraut (*Senecio inaequidens*) sowie der ursprünglich in China beheimatete Götterbaum (*Ailanthus altissima*). Während der Götterbaum durch sein rasches Wachstum zu erhöhtem Unterhaltsaufwand führen und die Verkehrssicherheit beeinträchtigen kann, ist das Schmalblättrige Greiskraut besonders für die Landwirtschaft problematisch, sollte die Art von den Verkehrsträgern auf Kulturen, Wiesen und Weiden übergehen. Inhaltsstoffe des Greiskraut können als Lebergifte Nutztiere und den Menschen schädigen.

Für die automatisierte Erfassung der beiden Arten wurde zunächst vom fließenden Verkehr aus mit zwei Kameras bei durchschnittlich 82 km/h die Vegetation der Seiten- und Mittelstreifen aus einem Fahrzeug heraus gefilmt. Zusammen mit GPS-Koordinaten wurde so die fahrbahnahe Vegetation entlang der Autobahnen auf einer Gesamtlänge von 690 km in beiden Fahrtrichtungen und während drei Befahrungen (Mai, August, Oktober) erfasst. Die befahrenen Autobahnabschnitte entsprechen rund der Hälfte des gesamten Schweizer Autobahnnetzes. Für das Trainieren und Testen der neuronalen Netze markierten anschliessend Experten in Bildern, die aus den Filmen extrahiert wurden, das Vorkommen oder Fehlen der beiden invasiven Neophyten. Beim Schmalblättrigen Greiskraut erfolgte zusätzlich die Unterscheidung blühender und nicht-blühender Vorkommen. Das Markieren der Arten erfolgte je Bild in jeweils 15 gleich grossen Bildkacheln (Teilbildern). Für das Trainieren und Testen der neuronalen Netze standen für den Götterbaum so insgesamt 972, für blühendes Greiskraut 2'096 und für nicht-blühendes Greiskraut 2'471 markierte Bildkacheln mit Artvorkommen zur Verfügung, während in über 100'000 Bildkacheln keine der beiden Arten von den Experten erkannt wurden. Von den verwendeten neuronalen Netzen (ResNet, Wide-ResNet, DenseNet, Resnext – jeweils auf ImageNet vortrainiert) und ihren Varianten erwies sich ResNet152 für die Arterkennung am besten geeignet. Die erkannten Vorkommen des Götterbaums stimmten in 97.5% der Fälle mit den Angaben der Experten überein, wobei 88.6% der markierten Bildkacheln gefunden wurden. Beim Schmalblättrigen Greiskraut waren dies 97.7% korrekt erkannte und 87.5% gefundene Bildkacheln. Die bereits hohe Rate korrekt erkannter Vorkommen erhöhte sich weiter, wenn nur Bilder mit mehrfach erkannten Bildkacheln als Vorkommen gewertet wurden.

Für die automatisierte Kartierung wurden Bilder im Abstand von fünf Metern verwendet und die beiden invasiven Neophyten mit dem trainierten neuronalen Netz automatisiert erkannt. Nach Ausschluss von Doppelbefahrungen und Tunnelpassagen entspricht dies für sämtliche erfasste Mittel- und Seitenstreifen sowie die drei Termine einer automatisierten Arterkennung in rund 1.35 Millionen georeferenzierten Bildern beziehungsweise über 20 Millionen Bildkacheln. Die daraus erstellten detailreichen Verbreitungskarten stehen webbasiert als interaktive Karten zur Verfügung. Für die automatisierte Kartierung konnte eine hohe Reproduzierbarkeit durch den Vergleich mehrfach befahrener Streckenabschnitte, den Vergleich zwischen der Mai-, August- und Oktoberbefahrung, sowie den Vergleich mit kurzen, von Experten kartierten Streckenabschnitten bestätigt werden.

Die beiden invasiven Neophyten wachsen an Autobahnen momentan häufiger auf Mittelstreifen als auf Seitenstreifen. Für den Götterbaum zeigen die Karten, dass die Art im Mittelland an Autobahnen noch sehr unterschiedlich verbreitet ist. Neben grossen

Vorkommen wie am Genfer See – insbesondere bei Lausanne – existieren noch lange Streckenabschnitte, in denen die Art nur in wenigen Teilbildern erkannt wurde. Da der Götterbaum an Autobahnen durch Mahd und Gehölzschnitt nur ausnahmsweise Samen bildet, kommt dem Sameneintrag ausgehend von Zier- und Strassenbäumen in Siedlungs- und Gewerbegebieten eine grosse Bedeutung zu. Dies konnte durch eine positive Beziehung zwischen den erfassten Vorkommen des Götterbaums an Autobahnen und angrenzenden Flächen mit hoher Bodenversiegelung bestätigt werden. Das Schmalblättrige Greiskraut ist im Gegensatz zum Götterbaum deutlich weiter verbreitet, und längere nicht oder nur spärlich besiedelte Autobahnabschnitte sind die Ausnahme. Die Vorkommen dieser Art zeigen an Autobahnen im Gegensatz zum Götterbaum keine positive Beziehung zu benachbarten Siedlungs- und Gewerbegebieten, was auf eine unabhängige, selbständige Ausbreitung entlang der Autobahnen schliessen lässt.

Die erkannten Vorkommen der beiden invasiven Arten weisen deutliche Unterschiede zwischen den für den Unterhalt zuständigen Gebietseinheiten auf. Dies beruht zum einen auf der unterschiedlichen Ausbreitungsdynamik der Arten. So tritt der Götterbaum besonders in der Nähe von Agglomerationen auf. Die Unterschiede beim weit verbreiteten Greiskraut weisen dagegen auf eine abweichende Praxis bei der Grünpflege und beim Neophyten-Management hin. So zeichnet sich eine Gebietseinheit, in der schon seit Jahren Massnahmen gegen das Schmalblättrige Greiskraut ergriffen wurden, durch besonders wenige erkannte Vorkommen aus. In dieser Gebietseinheit war auch die geringste Anzahl der im Herbst noch blühenden Greiskraut-Bestände festzustellen, die als Mass für den Ausbreitungsdruck durch Samen in die umgebende Landschaft gewertet werden können. Umgekehrt waren blühende Greiskraut-Bestände im Herbst in einer anderen Gebietseinheit mit Abstand am häufigsten, in der wegen einer Kartierung von Biodiversitätsflächen ausnahmsweise erst sehr spät gemäht wurde. Diese Resultate zeigen, dass die Methode neben detaillierten Verbreitungskarten auch für eine Erfolgskontrolle oder ein Monitoring beim Umgang mit invasiven Neophyten an Autobahnen eingesetzt werden kann.

Da weitere invasive Neophyten im Bildmaterial zu erkennen sind – unter anderem die melde- und bekämpfungspflichtige Ambrosie (*Ambrosia artemisiifolia*) – kann der entwickelte Ansatz auch für eine automatisierte Kartierung zusätzlicher Arten weiterentwickelt werden. Für eine Kartierung weiterer Arten müssten lediglich die neuronalen Netze mit diesen Arten trainiert werden, ohne dass eine erneute Befahrung notwendig würde. Dies gilt auch für zukünftig vom Bund oder den Kantonen gegebenenfalls neu regulierte Arten. Mit Filmmaterial aus mehreren Jahren könnte ferner die Dynamik der Arten erfasst werden und ein Monitoring des Neophyten-Managements an Verkehrsinfrastrukturen erfolgen.

Zusammenfassend ist festzuhalten, dass sich der auf Deep Learning basierende Kartieransatz bewährt hat. Er liefert gut reproduzierbare, räumlich hoch aufgelöste Verbreitungskarten, die mit einer klassischen Experten-Kartierung nicht mit vertretbarem Aufwand erstellt werden können. Es ist davon auszugehen, dass angesichts der aktuellen Entwicklung in den Bereichen künstlicher Intelligenz und Kameratechnik entsprechende Anwendungen der automatisierten Kartierung von Arten oder anderer Objekte rasch an Bedeutung gewinnen werden.

Résumé

Les infrastructures de transport, comme les autoroutes et les lignes de chemin de fer, sont des couloirs de propagation pour les néophytes envahissantes. Ces dernières peuvent entraîner une augmentation des coûts d'entretien et se propager depuis les voies de communication vers les zones rurales et résidentielles adjacentes. En raison de leur forte dynamique de dispersion et des coûts élevés de la cartographie classique faites par des experts, la répartition actuelle des espèces envahissantes le long des autoroutes et des lignes de chemin de fer n'est généralement pas connue en détail. Compte tenu du développement rapide dans les domaines de la technologie des caméras numériques et de l'intelligence artificielle (IA), cette étude a donc développé et appliqué une cartographie automatisée de deux néophytes envahissantes le long des autoroutes du plateau suisse, basée sur l'IA (Deep Learning) et la vision industrielle (Machine Vision).

Le séneçon sud-africain (*Senecio inaequidens*) et l'ailante (*Ailanthus altissima*) originaire de Chine ont servi d'espèces tests. Alors que l'ailante, en raison de sa croissance rapide en hauteur, peut entraîner une augmentation des coûts d'entretien et nuire à la sécurité routière, le séneçon sud-africain est particulièrement problématique pour l'agriculture si l'espèce se propage vers les champs, les prairies et les pâturages. Le séneçon contient des substances toxiques pour le bétail et l'homme et peut les empoisonner.

Pour le relevé automatisé de ces deux espèces, la végétation des accotements latéraux et bermes centrales a d'abord été filmée avec deux caméras à partir d'un véhicule circulant à une vitesse moyenne de 82 km/h. La végétation le long des autoroutes a ainsi été documentée avec les coordonnées GPS sur une longueur totale de 690 km dans les deux sens et au cours de trois passages (mai, août, octobre). Les tronçons d'autoroute recensés correspondent à environ la moitié du réseau autoroutier suisse. Pour la reconnaissance automatisée des espèces et l'entraînement des réseaux neuronaux, des experts ont ensuite marqué la présence ou l'absence des deux néophytes envahissantes dans les images extraites des films. Dans le cas du séneçon sud-africain, la différenciation entre les occurrences en floraison et celles sans fleur a également été effectuée. Chaque image a été divisée en 15 carreaux de taille égale (image partielle) et la présence des espèces a été marquée dans chacun d'eux. Pour entraîner et tester les réseaux neuronaux, 972 carreaux ont été marqués avec présence de l'ailante, 2'096 avec le séneçon en floraison et 2'471 avec le séneçon sans fleur, tandis que dans plus de 100'000 carreaux, aucune espèce n'a été reconnue par les experts. Parmi les réseaux neuronaux utilisés (ResNet, Wide-ResNet, DenseNet, Resnext - chacun étant entraîné au préalable sur ImageNet) et leurs variantes, ResNet152 s'est avéré être le plus adapté à la détection des espèces. La présence de l'ailante a été reconnue dans 97.5 % des cas, conformément aux indications des experts, et 88.6 % des carreaux marqués par les experts ont été trouvés. Dans le cas du séneçon sud-africain, 97.7 % des cas ont été correctement reconnus et 87.5 % des carreaux marqués par les experts ont été identifiés. Le taux déjà élevé d'occurrence correctement détectée augmenterait encore davantage si seules les images comportant plusieurs carreaux avec une présence détectée des espèces étaient considérées.

Pour la cartographie automatisée, des images à une distance de cinq mètres ont été extraites des films et les deux néophytes envahissantes ont été automatiquement reconnues grâce au réseau neuronal entraîné. En excluant les doubles passages et les tunnels, cela correspond à une reconnaissance automatique des espèces sur environ 1.35 million d'images géoréférencées ou plus de 20 millions de carreaux d'images pour toutes les bermes centrales et accotements latéraux lors des trois dates. Les cartes de distribution détaillées qui en résultent sont disponibles sous forme de cartes interactives sur le web. Pour la cartographie automatisée, un haut degré de reproductibilité a été confirmé en comparant les tronçons de route parcourus plusieurs fois, ainsi que les relevés de mai, août et octobre. De courts tronçons de la carte ont également été comparés à ceux cartographiés par des experts.

Les deux néophytes envahissantes poussent actuellement plus fréquemment sur les bermes centrales que sur les accotements latéraux. Pour l'ailante, les cartes montrent que

l'espèce est encore répartie de manière très différente sur le plateau suisse. En dehors de la présence fréquente le long de l'arc lémanique - particulièrement près de Lausanne - il existe encore de longues étendues où l'espèce n'a été identifiée que sur quelques carreaux d'image. Étant donné que l'ailante ne produit des semences que dans des cas exceptionnels du fait de la fauche et de l'élagage annuelle sur les autoroutes, les semences provenant des arbres d'ornement et de ceux poussant le long des routes dans les zones résidentielles et industrielles jouent apparemment un rôle important dans la propagation. Cela a pu être confirmé par une relation positive entre les occurrences enregistrées de l'ailante le long des autoroutes et la proximité des zones à forte imperméabilisation des sols - comme on peut en trouver dans les zones d'habitat et les zones industrielles. Contrairement à l'ailante, le séneçon sud-africain est beaucoup plus répandu, et les longs tronçons d'autoroute qui ne sont pas ou peu peuplés par cette espèce sont des exceptions. Contrairement à l'ailante, les occurrences de cette espèce sur les autoroutes ne montrent pas de relation positive avec les zones résidentielles et industrielles, ce qui suggère une propagation indépendante et autonome le long des autoroutes.

La présence détectée des deux espèces envahissantes montre de nettes différences entre les unités territoriales responsables de l'entretien. Cela provient d'une part de la dynamique de propagation de l'espèce, l'ailante, par exemple, se trouve surtout à proximité des agglomérations et d'autre part, les différences de distribution du séneçon sud-africain montrent une pratique différente dans l'entretien des espaces verts et la gestion des néophytes. Par exemple, une unité territoriale dans laquelle des mesures contre le séneçon sud-africain ont été prises pendant des années se caractérise par un nombre particulièrement faible d'occurrences reconnues. Dans cette unité territoriale, on a également trouvé la plus petite population de séneçon encore en floraison en automne, ce qui peut être considéré comme une mesure contre la pression de la dispersion des graines dans le paysage environnant. À l'inverse, l'occurrence du séneçon en floraison durant l'automne était de loin la plus fréquente dans une unité où, exceptionnellement, la fauche avait eu lieu très tard. Ces résultats montrent que la méthode peut être utilisée non seulement pour des cartes de distribution détaillées, mais aussi pour le contrôle des mesures et la surveillance dans le cadre de la gestion des néophytes envahissantes le long des autoroutes.

Compte tenu que d'autres néophytes envahissantes peuvent être identifiées sur les images – notamment l'ambrosie (*Ambrosia artemisiifolia*) qui est soumise à des obligations de signalement et d'éradication – l'approche développée peut également être perfectionnée pour la cartographie automatisée à d'autres espèces. Pour ce faire, les réseaux neuronaux devraient être entraînés avec ces espèces supplémentaires avec les mêmes images filmées sur l'autoroute. À l'avenir, cela peut s'appliquer également aux espèces qui pourraient être nouvellement réglementées par la Confédération ou les cantons. De plus, des films sur plusieurs années pourraient être utilisés pour enregistrer la dynamique des espèces et pour surveiller la gestion des néophytes sur les autoroutes et également sur d'autres routes.

En résumé, l'approche cartographique basée sur le Deep Learning s'est avérée efficace. Il fournit des cartes de distribution reproductibles et à haute résolution spatiale qui peuvent être produites à de moindres coûts par rapport à ceux occasionnés par une cartographie classique, effectuée par des experts sur le terrain. On peut supposer qu'au vu des développements actuels dans les domaines de l'intelligence artificielle et de la technologie des caméras, des applications de cartographie automatisée d'espèces ou d'autres objets gagneront rapidement en importance.

Summary

Transportation networks such as highways and railroad lines are dispersal corridors for the spread of invasive neophytes. These species can cause increased maintenance costs and spread from the transport routes into adjacent landscapes and settlement areas. Due to their high distribution dynamics and difficult expert mapping, the current distribution of invasive species along roads and railroad lines is usually not known in detail. In view of the rapid development in the fields of digital camera technology and artificial intelligence (AI), this study developed and applied an automated mapping of two invasive neophytes along highways in the Swiss Central Plateau based on AI (Deep Learning) and machine vision.

The narrow-leaved ragwort (*Senecio inaequidens*) from South Africa and the tree of heaven (*Ailanthus altissima*), which is native to China, served as test species. While the tree of heaven, due to its rapid growth, can lead to increased maintenance costs and impair road safety, the narrow-leaved ragwort is particularly problematic for agriculture, should the species spread from the transport routes to crops, meadows and pastures. Ingredients of the narrow-leaved ragwort can harm livestock and humans as liver poisons.

For the automated mapping of the two species, the vegetation of the side and central strips was first filmed from a car from the moving traffic with two cameras at an average speed of 82 km/h. Together with GPS coordinates, the vegetation along the highways was thus recorded over a total length of 690 km in both directions and during three periods (May, August, October). The sections of highway covered correspond to about half of the entire Swiss highway network. To train and test the neural networks, experts then marked the presence or absence of the two invasive neophytes in images extracted from the films. In the case of the narrow-leaved ragwort, the distinction between flowering and non-flowering occurrences was also made. The species were marked in 15 image tiles of the same size for each image. For the training and testing of the neural networks, 972 marked image tiles with species occurrence were available for the tree of heaven, 2'096 for flowering ragwort and 2'471 for non-blooming ragwort, while in over 100,000 image tiles neither of the two species was recognized by the experts. Of the neural networks used (ResNet, Wide-ResNet, DenseNet, Resnext - each pre-trained on ImageNet) and their variants, ResNet152 proved to be the most suitable for species detection. The detected occurrences of the tree of heaven were in 97.5% of the cases consistent with the experts' data, with 88.6% of the marked image tiles being found. In the case of the narrow-leaved ragwort these were 97.7% correctly recognized and 87.5% found image tiles. The already high rate of correctly detected occurrences was further increased if only images with multiple detected image tiles were considered as occurrences.

For the automated mapping, images at a distance of five meters were used and the two invasive neophytes were automatically recognized with the trained neural network. After excluding double driving and tunnel passages, this corresponds to an automated species recognition in approximately 1.35 million georeferenced images or more than 20 million image tiles for all central and side strips and the three periods. The resulting detailed distribution maps are available as web-based interactive maps. For the automated mapping, high reproducibility was confirmed by comparing route sections that had been mapped multiple times during a single period, by comparing the May, August and October periods, and by comparing them with short route sections mapped by experts.

The two invasive neophytes currently grow more frequently on central than on side strips. For the tree of heaven, the maps show that the species is still very heterogeneously distributed along highways of the Central Plateau. Besides large populations like at Lake Geneva - especially near Lausanne - there are still long sections where the species has only been recognized in a few image tiles. Since the tree of heaven only exceptionally produces seeds on highways due to mowing and wood-cutting, the seed dispersal from ornamental and street trees in settlement and industrial areas is of great importance. This was confirmed by a positive relationship between the recorded occurrences of the tree of heaven on highways and adjacent areas with high soil sealing. In contrast to the tree of heaven, the narrow-leaved ragwort is much more widespread, and longer sections of

highways that are not or only sparsely populated are the exception. In contrast to the tree of heaven, the occurrences of this species do not show a positive relationship to neighboring settlement and industrial areas on highways, which suggests an independent, self-supporting spread along the highways.

The detected occurrences of the two invasive species show clear differences between the territorial units (Gebietseinheiten) responsible for maintenance. On the one hand, this is due to the different dynamics of propagation of the species. Thus, the tree of heaven occurs particularly in the vicinity of agglomerations. On the other hand, the differences in the occurrences of the widespread narrow-leaved ragwort indicate a different practice in green maintenance and neophyte management. For example, a territorial unit in which measures against the narrow-leaved grey-weed have been taken for years is characterized by particularly few recognized populations. In this unit, the lowest number of ragwort stands still flowering in autumn was also found, which can be taken as a measure of the seed pressure into the surrounding landscape. On the other hand, autumn blooming stands were by far the most common in another unit, where mowing was exceptionally late due to mapping of biodiversity areas. These results show that the method can be used not only for detailed mapping, but also for control and monitoring the management of invasive neophytes along highways.

As further invasive neophytes can be recognized in the images – among others the ragweed (*Ambrosia artemisiifolia*), which is subject to mandatory reporting and control – the mapping approach can also be further developed for an automated mapping of additional species. For this purpose, only the neuronal networks would have to be trained again with these new species, without the need to drive on the highways again. This also applies to species that may be newly regulated by the federal authorities or the cantons in the near future. Furthermore, with film material from multiple years, the dynamics of the species could be measured and the neophyte management on highways could be monitored.

In summary, the deep learning-based mapping method has proven to be a very useful approach. It provides well reproducible, spatially high-resolution distribution maps that cannot be produced with reasonable effort using classical expert mapping. It can be assumed that in view of current developments in the fields of artificial intelligence and camera technology, corresponding applications of automated mapping of species or other objects will rapidly gain in importance.

1 Einführung

1.1 Ziel der Studie

Invasive Arten, die in einem Gebiet neu auftreten und sich rasch ausbreiten, können die Gesundheit von Menschen gefährden, erhöhte Kosten verursachen – beispielsweise in der Land- und Forstwirtschaft – oder sich negativ auf die Biodiversität auswirken. Für einige dieser Arten sind Verkehrsträger wie Autobahnen oder Eisenbahnlinien Ausbreitungskorridore, doch ist bei ihrer hohen Ausbreitungsdynamik über die aktuelle Verbreitung der Arten oft nur wenig bekannt. Da eine Kartierung über grössere Gebiete aufwendig ist, wird in der vorliegenden Studie mit neuronalen Netzen und maschinellem Sehen eine bildgestützte Methode zur automatisierten Erfassung zweier ausgewählter invasiver Neophyten an Schweizer Mittelland-Autobahnen entwickelt und angewendet. Die Studie hat zum Ziel, (1) die Möglichkeiten und Grenzen neuronaler Netze zur automatisierten Kartierung von Neophyten zu evaluieren, (2) detaillierte Karten zur aktuellen Verbreitung von zwei invasiven Neophyten an Mittelland-Autobahnen zu erstellen und (3) einfache Auswertungen zu Faktoren durchzuführen, welche das Auftreten der Arten beeinflussen.

1.2 Invasive Neophyten an Strassen

Der Mensch verursacht weltweit nicht nur den Rückgang und das Aussterben von Arten, sondern fördert auch Arten, indem diese sich mit seiner Hilfe über ihre natürlichen Verbreitungsgrenzen hinaus ausbreiten können. Dies gilt besonders seit der Entdeckung Amerikas im Jahr 1492 und dem anschliessend rasant zunehmenden Welthandel [1]. Daher werden Arten, die seither in einem bestimmten Gebiet neu auftreten als Neobiota bezeichnet – oder im Fall von Pflanzenarten auch als Neophyten. Verursachen diese Arten gesundheitliche, ökonomische oder ökologische Schäden, so ist von invasiven Neobiota die Rede. In den letzten Jahrzehnten hat die Häufigkeit mit der Neobiota aus unterschiedlichen Organismengruppen fernab ihrer ursprünglichen Verbreitung beobachtet wurden noch einmal deutlich zugenommen [2].

Die Schweiz besitzt ein gut ausgebautes Autobahnnetz mit einer Gesamtlänge von 1462 km (Stand 2018, [3]). Auf ihm bewegen sich nicht nur Menschen und werden Waren transportiert, sondern breiten sich auch gebietsfremde Arten aus. Diese werden zum Teil mit Fahrzeugen unbewusst verschleppt oder nutzen die gut vernetzten Lebensräume entlang von Autobahnen als Ausbreitungskorridore. So wurden in einer belgischen Studie an verschmutzten Fahrzeugen Samen von 33 Pflanzenarten festgestellt [4], und in einem Autobahntunnel in Deutschland konnten mit Samenfallen über 200 Pflanzenarten nachgewiesen werden, deren Samen mit dem Verkehr ausgebreitet wurden [5]. Dabei werden Samen nicht nur an Fahrzeugen, sondern auch durch den Fahrtwind entlang von Strassen ausgebreitet [6]. In der Schweiz werden unter anderem erste grössere Vorkommen der Ambrosie (*Ambrosia artemisiifolia*), die starke Pollenallergien auslösen kann, bei Genf wie auch im Tessin auf unabsichtliche Verschleppungen entlang von Autobahnen und Eisenbahnlinien aus Frankreich beziehungsweise Norditalien zurückgeführt [7]. Gegenüber kleineren Strassen sind Autobahnen von besonderer Bedeutung, da die Ausbreitung der Arten durch ein hohes Verkehrsaufkommen und Fahrten über grössere Distanzen gefördert wird [8,9].

Bedeutende invasive Neophyten der Schweiz werden seit 2001 in der «Schwarzen Liste» aufgeführt [10] und seit 2012 von Info Flora, dem nationalen Daten- und Informationszentrum der Schweizer Flora, fortlaufend aktualisiert [11]. Neben der allgemeinen Sorgfaltspflicht besteht für den Umgang mit bestimmten invasiven Neobiota seit 2008 durch die revidierte Freisetzungsverordnung eine gesetzliche Grundlage auf Bundesebene [12]. Im Rahmen der Umsetzung der «Strategie der Schweiz zu invasiven gebietsfremden Arten» [13] ist derzeit ein «Stufenkonzept» für den differenzierten Umgang mit invasiven Neobiota in Vorbereitung.

Für Unterhalt und Pflege der Grünräume entlang von Nationalstrassen einschliesslich Autobahnen ist das Bundesamt für Strassen (ASTRA) verantwortlich. Die Ausführung der Grünpflege ist in Gebietseinheiten organisiert und erfolgt in der Regel durch kantonale Tiefbauämter. Um die Nachhaltigkeit der Grünräume zu erhöhen und gesetzliche Rahmenbedingungen zu erfüllen, werden invasive Neophyten bei Gestaltung und betrieblichem Unterhalt berücksichtigt [14].

1.3 Künstliche Intelligenz und maschinelles Sehen

Künstliche Intelligenz (Artificial Intelligence) oder auch maschinelles Lernen (Machine Learning) bezeichnet Intelligenz durch Maschinen oder Computer. Die grössten Fortschritte der künstlichen Intelligenz sind in letzter Zeit im Bereich Deep Learning erfolgt. Deep Learning ermöglichte eine neue Kategorie von Algorithmen, die mit grossen Mengen klassifizierter Daten trainiert werden und deren Fähigkeiten in manchen Fällen, die des Menschen übertreffen. Der Name «Deep Learning» kommt daher, dass die Algorithmen aus einer sehr grossen Anzahl miteinander verketteter Ebenen bestehen, was als «tiefe» Modelle bezeichnet wird. Dabei werden die Variablen, welche die verschiedenen Ebenen parametrisieren nicht manuell ausgewählt, sondern durch das Trainieren mit bereits klassifizierten Daten optimiert [15].

Besonders erfolgreich wurde Deep Learning in Bereich maschinelles Sehen (Computer Vision) angewendet [16,17]. Durch Kombination von verschiedenen Methoden ermöglicht Deep Learning beispielsweise beim autonomen Fahren Objekte zu erkennen [18], deren Abstand zu schätzen [19] und Fahrwege zu planen [20]. Ein weiteres Anwendungsgebiet ist die Sprachverarbeitung (Native Language Processing), um Text in Sprache umzuwandeln oder Sprache in Text [21,22]. Deep Learning erlaubt ferner, Texte in verschiedene Sprachen zu übersetzen [23] oder handschriftliche Notizen als Computertext einzulesen [24]. Eine weitere Errungenschaft stellt Reinforcement-Learning dar, bei dem ein Algorithmus nur durch Beobachten und Ausprobieren beispielsweise von Computer- oder Brettspielen bereits nach kürzester Zeit dem Weltmeister überlegen war [25,26]. Eine weitere Anwendung ist künstliche Bilderzeugung, die täuschend echt aussehende Bilder generiert [27]. Der Ansatz wird unter anderem zur Aufbereitung von bereits aufgenommenen Bildern genutzt [28], um Rauschen oder Unschärfe zu entfernen [29] oder um die Bildauflösung künstlich zu erhöhen [30]. Weiter kann Deep Learning auch dazu missbraucht werden, um zum Beispiel sogenannte Deep Fakes zu generieren, bei denen Videos oder Bilder beliebig verändert werden können, ohne dass dies sichtbar wäre [31].

Angesichts der grossen Fortschritte, die in den letzten Jahren durch Deep Learning im Bereich Künstliche Intelligenz und maschinellem Sehen erreicht wurden, soll im Rahmen der vorliegenden Arbeit Deep Learning getestet und angewendet werden, um invasive Pflanzenarten entlang von Autobahnen zu erkennen und zu kartieren. Durch Deep Learning kam es auch im Bereich der automatisierten Arterkennung in den letzten Jahren zu grossen Fortschritten [32]. So existieren inzwischen auch auf Deep Learning basierende Anwendungen für Smartphones, die anhand von Fotos tausende unterschiedliche Arten automatisiert erkennen (u.a. iNaturalist, www.inaturalist.org; PI@ntNet, www.plantnet.org; FloralIncognita, <https://floraincognita.com>). Bisher gibt es jedoch keine Anwendung, die direkt für eine umfangreiche Kartierung einzelner Arten genutzt werden könnte.

2 Untersuchungsgebiet und Auswahl der Arten

2.1 Untersuchungsgebiet

Das Untersuchungsgebiet umfasst das Schweizer Mittelland mit den Autobahnabschnitten Genf-St. Margrethen (Autobahn A1), Basel-Weesen (A3), Basel-Luzern (A2) und Biel-Thun (A6) (Abb.1). Die Gesamtlänge der befahrenen Autobahnabschnitte beträgt ca. 690 km. Dies entspricht rund der Hälfte des gesamten Autobahnnetzes der Schweiz, das eine Gesamtlänge von 1462 km aufweist (Stand 2018, [3]).

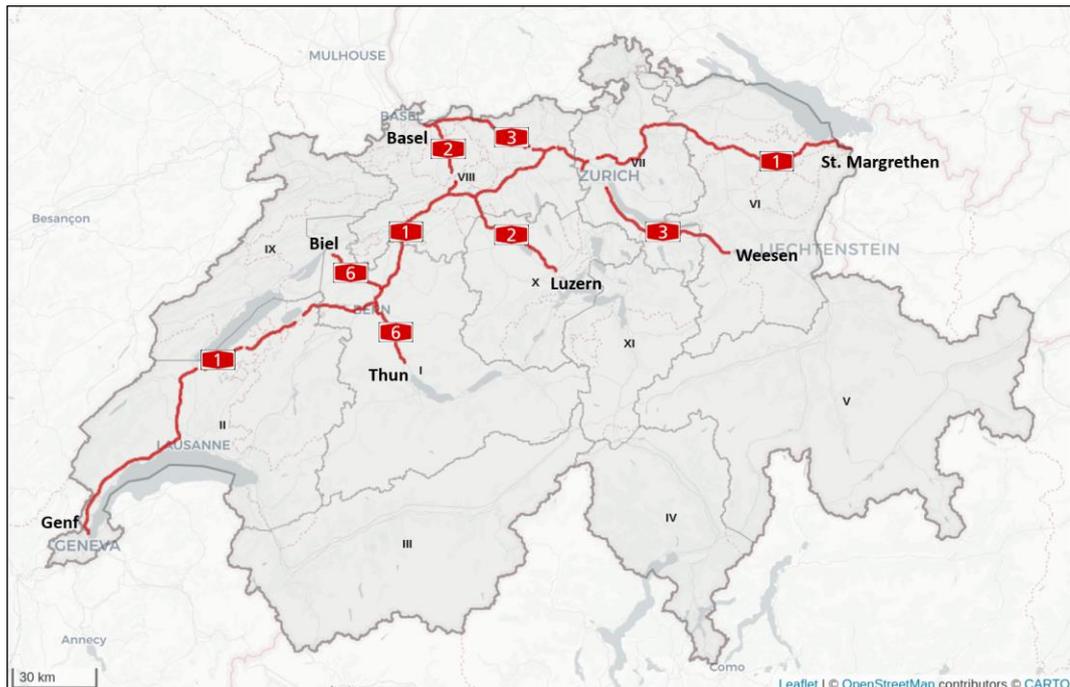


Abb.1 Karte der berücksichtigten Autobahnen. Für die Darstellung wurden die Bild-Koordinaten der Befahrungen verwendet. Polygone mit römischen Zahlen zeigen die Gebietseinheiten der Nationalstrassen.

2.2 Auswahl der Arten

Die Auswahl der Neophyten erfolgte anhand folgender Kriterien: Die Arten sollten zum einen als invasive Neophyten eingestuft sein. Als Basis diente hierfür die Schwarze Liste invasiver Neophyten der Schweiz [11]. Ferner sollten die Arten an Autobahnen im Schweizer Mittelland vorkommen, sich dort aktuell in Ausbreitung befinden und bereits so häufig sein, dass genügend Bildmaterial für den Kartieransatz zu erwarten war. Die Bestimmung der Art musste zudem für einen Experten anhand des Bildmaterials möglich sein. Für eine bessere Bewertung des methodischen Ansatzes sollten die beiden Arten schliesslich möglichst unterschiedliche Wuchsformen und Blattstrukturen aufweisen.

Nachdem invasive Neophyten wie die Ambrosie (*Ambrosia artemisiifolia*; s. Anhang II.1) anhand der Kriterien ausgeschlossen wurden, fiel die Wahl auf den Götterbaum (*Ailanthus altissima*) und das Schmalblättrige Greiskraut (*Senecio inaequidens*).

2.2.1 Götterbaum (*Ailanthus altissima*)

Der Götterbaum stammt ursprünglich aus China und wurde bereits in den 1740er Jahren nach Europa eingeführt [33]. Er ist salz- und trockenheits-tolerant und fand in der Schweiz lange Zeit als Zier- und Strassenbaum vor allem in Städten Verwendung. Die Art wächst sehr schnell, bis zu drei Meter pro Jahr, und erreicht unter günstigen Wuchsbedingungen eine Höhe von rund 30 Metern [33]. Der Blattaustrieb erfolgt spät erst im Mai, die Art blüht von Juni bis Juli, ihre Samen reifen zwischen September und Oktober und der Laubfall erfolgt ohne Herbstfärbung (im Gegensatz zum ähnlichen Essigbaum) Anfang bis Mitte November. Der Götterbaum ist zweihäusig, d.h. Samen und Pollen werden von unterschiedlichen Pflanzen gebildet. Unter günstigen Bedingungen produzieren Jungpflanzen bereits nach vier Jahren Samen, und ausgewachsene Einzelbäume können deutlich über eine Million Samen bilden [34]. Die Samen werden primär durch den Wind ausgebreitet, können aber auch mit Wasser über grössere Strecken transportiert [35] und offenkundig auch mit Fahrzeugen verschleppt werden. Für die Nahausbreitung ist zusätzlich Wurzelbrut bedeutend. Ein einzelnes Individuum kann so noch vor der Samenbildung und trotz mehrfachen Zurückschneidens durch Stockausschläge und Wurzelsprosse zur Besiedlung grösserer Flächen führen. Wurzelbrut wurde noch in einem Abstand von 27 Metern von der Ausgangspflanze beobachtet [36]. Entlang von Strassen konnte eine Besiedlung durch Wurzelbrut auf einer Länge von 120 Metern Länge beobachtet werden [37].

Die Art befindet sich derzeit im Schweizer Mittelland entlang von Autobahnen in Ausbreitung. Ihr starkes Wachstum kann zu einem Mehraufwand beim Strassenunterhalt führen und die Verkehrssicherheit beeinträchtigen [38] – beispielsweise durch Verdecken von Verkehrsschildern. Da die Art sich ausser durch Samen auch vegetativ durch Wurzelsprosse ausbreitet und mit Stockausschlägen gut regeneriert, ist ihr Zurückdrängen aufwendig. Der Götterbaum kann Bauwerke schädigen und dringt ausserhalb von Siedlungen und Verkehrsinfrastruktur auch in Wälder ein. Letzteres konnte seit längerem im Tessin beobachtet werden [39] und tritt neuerdings auch in der Nordschweiz auf [40]. Der Götterbaum steht seit 2001 auf der Schwarzen Liste invasiver Neophyten der Schweiz [10,11] und ist eine prioritäre Art beim Management invasiver Neophyten in verschiedenen Kantonen (z.B. Kt. Zürich, [41]). In der Europäischen Union steht der Götterbaum seit 2019 auf der «Liste invasiver gebietsfremder Arten von unionsweiter Bedeutung» (Unionsliste) [42].

2.2.2 Schmalblättriges Greiskraut (*Senecio inaequidens*)

Das Schmalblättrige Greiskraut stammt ursprünglich aus Südafrika und wurde Ende des 19. Jahrhunderts mehrfach mit Rohwolle nach Europa eingeschleppt [43]. Es handelt sich um einen mehrjährigen, 40-60 cm hohen (an Zäunen oder Gehölzen auch höher), basal verholzenden Halbstrauch. Die Art kann bei Störung wie regelmässiger Mahd ähnlich einer Staude auch nur mit krautigen Trieben wachsen. Das Schmalblättrige Greiskraut zeichnet sich durch eine lange Blütezeit von Juni bis Dezember aus, wobei ältere Triebe aus den Vorjahren bereits Anfang Mai erste Blüten bilden [44]. Für ältere Pflanzen wird eine Samenproduktion von 18'000 bis 29'000 Samen angegeben [43]. Jungpflanzen können bereits im ersten Jahr Samen bilden [45], und selbst Keimlinge aus Samen derselben Vegetationsperiode, die ab Juli-August austreiben, können noch im selben Jahr zur Blüte und Samenreife gelangen [44]. Es wird angenommen, dass die Art eine langlebige Samenbank aufbaut (30-40 Jahre in [46]).

In der Schweiz wurde das Schmalblättrige Greiskraut erstmals 1921 nachgewiesen und kam damals eventuell nur vorübergehend vor [47]. So wurde die Art beispielsweise in der Umgebung von Basel erst seit Mitte der 1980er Jahre festgestellt [48], nachdem sich die Art in Deutschland Richtung Süden ausgebreitet hatte [49]. Im Stadtgebiet von Zürich wurde sie erstmal 1995 auf Bahnarealen [50,51] und kurze Zeit später auch an Autobahnen beobachtet [52]. Die Art hat sich seither im Schweizer Mittelland besonders entlang von Autobahnen rasant ausgebreitet. Die Besiedlung von Siedlungsgebieten erfolgte dagegen offenbar meist sekundär.

Das Schmalblättrige Greiskraut enthält für den Menschen und Nutztiere schädliche Pyrrolizidinalkaloide, die in der Leber zu hochtoxischen Metaboliten abgebaut werden, sich

anreichern (Akkumulationsgift) und akute und chronische Leberschäden verursachen können. Dies ist besonders für die Landwirtschaft problematisch, sollte die Art von Strassenrändern auf Kulturen, Wiesen oder Weiden übergehen. Im Ursprungsland Südafrika sind tödlichen Vergiftungen bei Kühen bekannt [53], und aus Frankreich wurde mit der Ausbreitung des Schmalblättrigen Greiskrauts eine Zunahme von Vergiftungsfällen bei Pferden berichtet [54]. Im Gegensatz zu frischen Pflanzen, die von Weidetieren gemieden werden, trifft dies für Heu oder Silage nicht zu. Pyrrolizidinalkaloide können über Honig, Milch und Milchprodukte auch vom Menschen aufgenommen werden. Kontaminierte Lebensmittel müssen aus dem Verkehr gezogen werden [55].

An Autobahnen besiedelt das Schmalblättrige Greiskraut vor allem offene oder lückige Vegetation der intensiven Unterhaltszone (Definition gemäss [14]). Die Art kann nach Mahd bereits innerhalb von 6-8 Wochen wieder blühen und wird so gegenüber schlechter regenerierenden Konkurrenzarten gegebenenfalls durch Mahd indirekt gefördert [56,57]. Das Schmalblättrige Greiskraut zeichnet sich durch eine hohe Herbizidresistenz aus [57], wodurch das Zurückdrängen der Art weiter erschwert wird.

Das Schmalblättrige Greiskraut steht seit 2001 auf der Schwarzen Liste invasiver Neophyten der Schweiz [10,11] und gehört zu den verbotenen Arten gemäss Anhang 2 der Freisetzungsverordnung [12]. Im Kanton Zürich besteht eine Melde- und Bekämpfungspflicht für Grundstückseigentümer und Bewirtschafter [58]. Die Art wird vom ASTRA bei der Bekämpfung invasiver Neophyten an Nationalstrassen als eine der vier wichtigsten Arten genannt [59].



Abb. 2 Mittelstreifen der A1 bei Lausanne mit Schmalblättrigem Greiskraut (Vordergrund) und einem dichten Bestand des Götterbaums.

3 Methoden

Das Kapitel gibt zunächst eine Übersicht zum allgemeinen methodischen Vorgehen, gefolgt von Angaben zur Aufnahmetechnik und den verschiedenen Komponenten des verwendeten Deep-Learning-Ansatzes. Am Ende des Kapitels wird die Processing-Pipeline von den Videoaufnahmen bis zu den georeferenzierten Vorkommen der beiden invasiven Neophyten vorgestellt und der Zeit- und Ressourcenbedarf des Ansatzes beschrieben.

3.1 Übersicht

Für die automatisierte Kartierung der beiden Zielarten wurde die fahrbahnahe Vegetation von Mittel- und Seitenstreifen an drei Terminen während der Vegetationsperiode gefilmt und parallel GPS-Koordinaten aufgezeichnet. Aus den Filmen wurden anschliessend im Abstand von fünf Metern Bilder (Frames) extrahiert und anhand der Aufnahmezeit mit den GPS-Koordinaten georeferenziert. Für Training und Verarbeitung durch ein Convolutional Neural Network (CNN) wurden die Bilder in 15 kleinere Kacheln (Tiles) aufgeteilt. Das trainierte CNN liefert Schätzungen (Wahrscheinlichkeiten) für das Auftreten der Zielarten in den Bildkacheln, die als Verbreitungskarten dargestellt werden (Abb. 3).

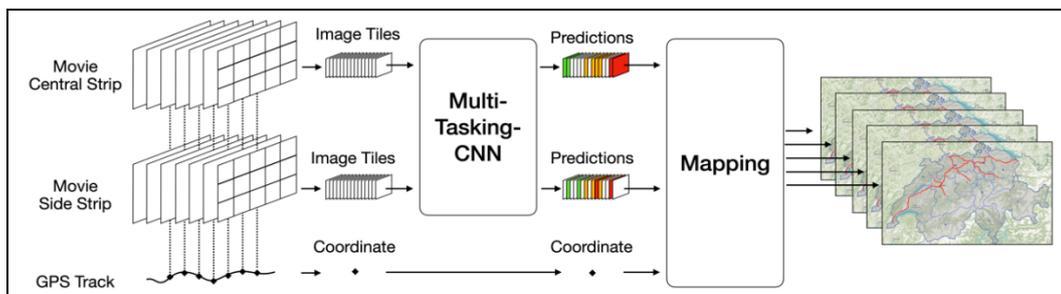


Abb. 3 Übersicht zum methodischen Vorgehen der automatisierten Kartierung.

3.2 Befahrungen und Aufnahmetechnik

Die Aufnahme des Filmmaterials entlang der Autobahnen erfolgte an drei Terminen während der Vegetationsperiode und richtete sich nach der Phänologie der beiden Zielarten. Die erste Befahrung fand Ende Mai statt (27.-30.05.2019). Zu diesem Zeitpunkt hatte der Götterbaum nach einer vorhergehenden Kältephase den Blattaustrieb weitgehend abgeschlossen. Eine zweite Befahrung wurde im August durchgeführt (13.-15.08.2019) und die abschliessenden Aufnahmen erfolgten Ende Oktober (22.-30.10.2019). Die dritte Befahrung wurde möglichst spät aber noch vor dem Laubfall des Götterbaums gewählt, da das Schmalblättrige Greiskraut noch weit in den Herbst hinein blüht. Eine Befahrung dauerte drei Tage, wobei die Gesamtstrecke von ca. 1380 km (beide Fahrtrichtungen) in Teilstrecken von ca. 180 km unterteilt wurde, um bei einem Zwischenhalt die Speichermedien der Kameras auszutauschen.

Die Befahrung der Autobahnen erfolgte mit einem PKW (Skoda Octavia). Dabei filmten zwei Video-Kameras von der rechten Fahrspur aus Mittel- und Seitenstreifen orthogonal zur Fahrtrichtung (Abb. 4). Die Kameras wurden an der halb geöffneten Innenscheibe mit einer Saughalterung (Delkin Saugstativ Fat Gecko) befestigt. Dabei muss darauf geachtet werden, dass der vorgesehene Aufnahmebereich sichtbar ist, das Objektiv nicht auf der geöffneten Scheibe aufschlagen kann und das Objektiv nur soweit wie nötig dem Fahrtwind ausgesetzt wird. Schwankende Abstände des Mittel- und Seitenstreifens wurden durch manuelles Nachführen des Zoom-Objektivs ausgeglichen.

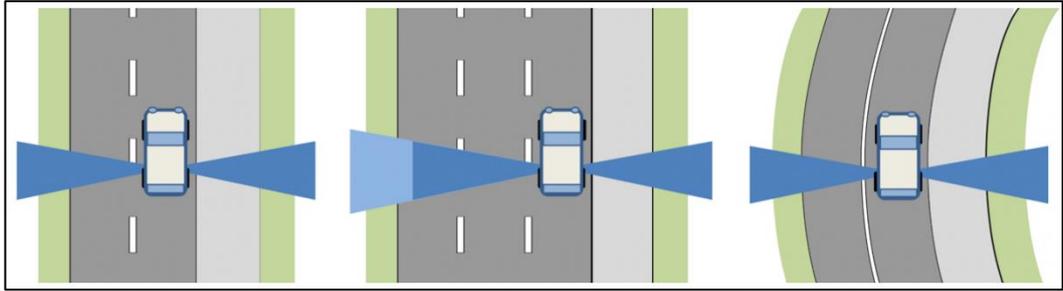


Abb. 4 Schematische Darstellung zur Ausrichtung der Kameras und Abdeckung der Aufnahmebereiche auf Mittel- und Seitenstreifen für verschiedene Strassensituationen.

Abbildung 5 zeigt die Befestigung der Kamera, die den Mittelstreifen filmt, sowie zwei Beispielbilder mit typischen Situationen für Seiten- und Mittelstreifen. Die aus den Filmen extrahierten Bilder weisen bei Fahrgeschwindigkeiten von durchschnittlich über 80 km/h einen deutlichen *Rolling-Shutter-Effekt* auf. Dieser entsteht bei sich im Bildausschnitt rasch bewegenden Objekten durch das zeilenweise Auslesen des Kamerasensors und lässt vertikale Objekte (z.B. Streckenpfosten) in der Nähe der Kamera schief erscheinen.



Abb. 5 Kameraposition und Bildbeispiele mit *Rolling-Shutter-Effekt* bei ca. 85 km/h.

Um in den Bildern Bewegungsunschärfe (Motion Blur) gering zu halten, wurden die Befahrungen nach Möglichkeit nahe der minimal zulässigen Geschwindigkeit von 80 km/h durchgeführt. Die Auswertung der GPS-Signale ergab einen Median der Geschwindigkeit von 82.3km/h. Die Geschwindigkeitsverteilungen für die einzelnen Befahrungen zeigt Abbildung 6. Bei zähfließendem Verkehr oder Stau traten geringer Geschwindigkeiten auf. Oft musste aber auch schneller gefahren werden, um sich dem fließenden Verkehr der rechten Fahrspur anzupassen und diesen nicht unnötig auszubremsten. So wurde auch das Abdecken des Mittelstreifens durch überholende LKWs vermieden.

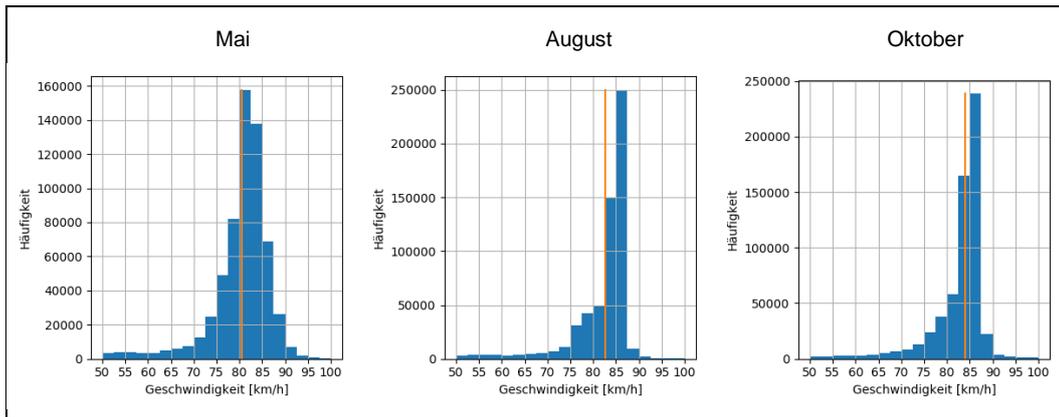


Abb. 6 Verteilung der Fahrgeschwindigkeit der drei Aufnahmetermine. Die vertikale orange Linie zeigt den Median.

Für die Filmaufnahmen wurden zwei Kameras vom Typ Sony Alpha 7s II mit dem Zoom-Objektiv FE 3.5-5.6/28-70 OSS verwendet. Alle Filme entstanden nach verschiedenen Tests zur Bildoptimierung mit der Verschlusszeit von 1/8000s, Zonen-Auto-Fokus mit Fokussierung auf die unteren zwei Drittel des Bildes, einer 4k-Auflösung und dem Video-Kompressionsformat XAVC S 4K: 3840 x 2160 (25p/100 Mbps). Dieses liefert eine relative tiefe Kompression von 3.858 bit/pixel, die noch Details im Bild erkennen lässt, die bei höherer Komprimierung nicht sichtbar wären. Zur Speicherung der Filme dienten Karten vom Typ SDXC U3 Extreme Pro Class 10, 128 GB. Als GPS-Logger kam das Modell QSTARZ BL-1000 GT zum Einsatz, das zehn Koordinaten pro Sekunde (10 Hz) aufzeichnet (genauer genommen handelt es sich um einen GNSS-Logger, da neben GPS- auch GLONASS-Satelliten für die Positionsbestimmung genutzt werden).

3.3 Markieren der Trainingsbilder für Deep Learning

Um ein Deep-Learning-Model erfolgreich trainieren und testen zu können, wird eine grosse Anzahl von Bildern benötigt, in denen die gesuchten Bildinhalte (Kategorien) bereits markiert sind. Für das Markieren der Trainingsbilder wird daher eine Benutzeroberfläche benötigt – ein sogenanntes Annotation-Tool. Für das Projekt wurde ein webbasiertes Annotation-Tool entwickelt, welches zunächst jedes 4k-Bild in 15 Bildkacheln aufteilt. Diese Kacheln können dann individuell aufgrund der vorhandenen Pflanzenarten vom Experten markiert werden. Abbildung 7 zeigt die Benutzeroberfläche mit einem Beispielbild und manuell vorgenommenen Markierungen.

Die Kategorien beim Markieren der Bildkacheln waren: AILANTHUS, SENECIO BLÜHEND, SENECIO NICHT-BLÜHEND, UNSICHER und KEINE. Sie wurden wie folgt vergeben: Enthält die Kachel keine der beiden berücksichtigten Neophyten, wird die Kachel mit KEINE markiert. Enthält sie den Götterbaum wird sie vom Experten mit AILANTHUS gekennzeichnet. Enthält die Bildkachel keinen Götterbaum aber blühendes Schmalblättriges Greiskraut, dann wird das Teilbild mit SENECIO BLÜHEND markiert, bei ausschliesslich nicht-blühendem Greiskraut mit SENECIO NICHT-BLÜHEND. Falls der Experte sich bei einer der beiden Zielarten unsicher ist, wird die Kachel mit UNSICHER markiert. Dieser Schritt verhindert falsche Markierungen, die das Trainieren der Netze erschweren. Der Experte war angehalten, wie später das zu trainierende Netz nur den Bildinhalt der Kachel zu interpretieren und nicht aus Nachbar-kacheln auf das Vorkommen einer Art zu schliessen.

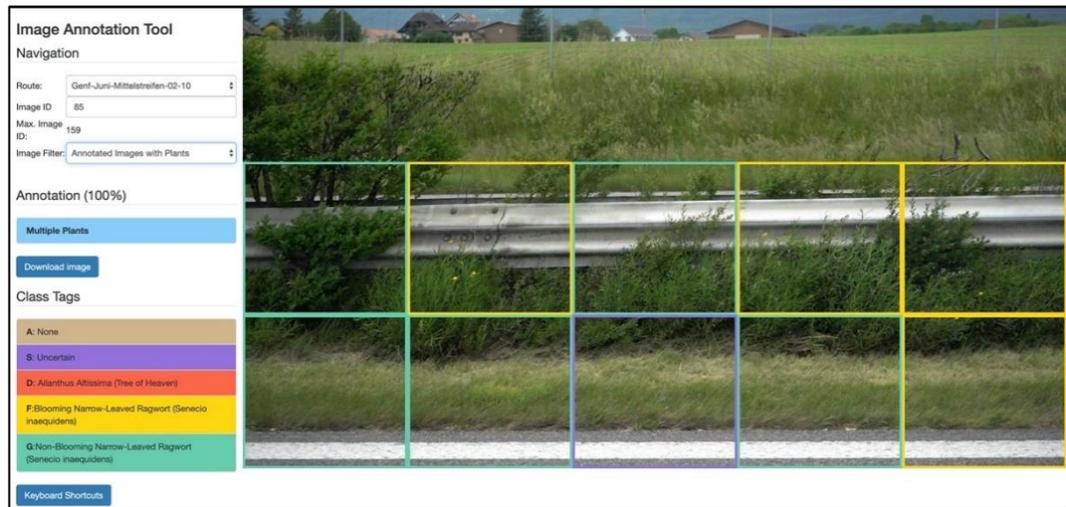


Abb. 7 Web-basiertes Annotation-Tool mit Beispielbild und markierten Bildkacheln.

Anstatt für das Markieren zufällige Einzelbilder aus den Filmen zu verwenden, wurde systematisch mittels des aufgezeichneten GPS-Signals zunächst alle 1000 Meter ein Bild extrahiert. Diese Strategie erfolgte mit sämtlichen Filmen von Mittel- und Seitenstreifen und für alle drei Befahrungen. Allerdings enthielten die so markierten Bilder nur 108 Bildkacheln mit Götterbaum – zu wenige, um ein zuverlässiges Deep-Learning-Model zu trainieren. Daher schaute der Experte zusätzlich weitere Bilder in Abständen von 100 Meter an und markierte darauf nur Vorkommen des Götterbaums, da für das Greiskraut bereits genügend markierte Bildkacheln vorlagen. Dies ergab 864 zusätzlichen Bildkacheln mit Götterbaum, womit 972 markierte Bildkacheln für diese Art zur Verfügung standen.

Tabelle 1 gibt eine Übersicht zur Anzahl der markierten Bildkacheln. Insgesamt wurden 109'307 Kacheln markiert, wobei in den weitaus meisten Fällen keine der beiden Arten vom Experten erkannt wurde. Mit mehr als 900 bzw. 2000 markierten Kacheln für den Götterbaum beziehungsweise für blühendes und nicht-blühendes Greiskraut waren genügend Trainings- und Testbilder für den Deep-Learning-Ansatz vorhanden. Dabei fällt auf, dass das Vorkommen sowohl des Götterbaums wie auch des Schmalblättrigen Greiskrauts auf Mittelstreifen häufiger markiert wurden als auf Seitenstreifen. Bildkacheln mit blühendem Greiskraut waren im Mai noch kaum vorhanden, im August bereits ähnlich häufig wie Kacheln mit ausschliesslich nicht-blühende Pflanzen und im Herbst am zahlreichsten. Die Spalte AILANTHUS zeigt neben der Summe der markierten Kacheln als Summanden die Werte für die Bildextraktion alle 1000 Meter und die nachträgliche Verdichtung mit Abständen von 100 Meter.

Tab. 1 Anzahl markierter Bildkacheln für Deep Learning.

Bereich	Befahrung	KEINE	AILANTHUS	SENECIO BLÜHEND	SENECIO NICHT BLÜHEND
Mittelstreifen	Mai	18028	12 + 201 = 213	14	609
	August	16384	60 + 419 = 479	581	1159
	Oktober	15870	19 + 144 = 163	701	219
Seitenstreifen	Mai	19032	0 + 13 = 13	10	91
	August	17541	17 + 61 = 78	402	312
	Oktober	16913	0 + 26 = 26	388	81
Mittel- und Seitenstreifen	Mai	37060	12 + 214 = 226	24	700
	August	33925	77 + 480 = 557	983	1471
	Oktober	32783	19 + 170 = 189	1089	300
Mittelstreifen	alle	50282	91 + 764 = 855	1296	1987
Seitenstreifen	alle	53486	17 + 100 = 117	800	484
Mittel- und Seitenstreifen	alle	103768	108 + 864 = 972	2096	2471

3.4 Deep-Learning-Modelle

Tiefe CNNs für alltägliche Szenen benötigen normalerweise Millionen von markierten Trainingsbildern, um zuverlässig zu funktionieren. Glücklicherweise ermöglicht Transfer-Learning, dass ein CNN auch mit deutlich weniger markierten Bildern ohne signifikante Qualitätsverluste trainiert werden kann. Die Idee von Transfer-Learning besteht darin, das CNN auf Bildern zu trainieren, die für andere Kategorien bereits markiert wurden. Je ähnlicher diese Trainingsbilder zum eigenen Bildmaterial sind desto besser. Üblicherweise genügt es jedoch, wenn beide Bildquellen alltägliche Szenen zeigen (Natural Images).

Ein CNN, das mittels Transfer-Learning vortrainiert wurde, kann bereits informative Merkmale (Features) erkennen und extrahieren. Diese Merkmale sind typisch um alltägliche Bilder, die zu unterschiedlichen Kategorien gehören, zu unterscheiden. Da sich die Kategorien der Transfer-Learning-Bilder oft von den eigentlichen Zielkategorien unterscheiden, wird das vortrainierte CNN abschliessend mit den eigentlichen Bildern und Markierungen trainiert (Fine-Tuning). Daher müssen die Parameter, die das CNN definieren, nur noch leicht angepasst und nicht von Grund auf neu gelernt werden. Mit Transfer-Learning sind daher für neue Kategorien oft bereits hunderte oder tausende neuer Bilder für das Trainieren der Deep-Learning-Modelle ausreichend.

Wir testeten verschiedene CNN-Architekturen und -Varianten von ResNet [17], Wide-ResNet [60], DenseNet [61] und Resnext [62] und benützen ImageNet [16] zum Vortrainieren der CNNs. Nach ersten Experimenten zeigten ResNet und DenseNet für die markierten Bilder das grösste Potential.

Das folgende Unterkapitel enthält genauere Angaben und Erklärungen zu den verwendeten Deep-Learning-Modellen, ihrer Architektur und der Trainings-Strategie.

3.4.1 Architektur, Design und Training der Deep-Learning-Modelle

Die Architektur und die Loss-Funktion, die zum Trainieren des CNNs benötigt wird, werden durch die Art der Markierungen und deren Anzahl beeinflusst. Im Gegensatz zu den Bildern dieses Projekts, die nur mit fünf Kategorien markiert wurden, wobei für die spätere Klassifikation mehrere Kategorien (Arten) pro Bildkachel vorkommen können, enthält ImageNet Bilder mit Markierungen aus 1000 Kategorien, wobei stets nur eine Kategorie pro Bild erlaubt ist. Das bedeutet, dass sowohl die Architektur als auch die Loss-Funktion zwischen dem Vortrainieren und dem eigentlichen Training mit den eigenen Bildern verändert werden müssen.

Da die Bildkacheln im Projekt mehrere Pflanzenarten enthalten können, wäre es auch möglich, mehrere CNNs zu trainieren, die jeweils nur die Wahrscheinlichkeit für das Auftreten einer einzelnen Pflanzenart berechnen. Diese Lösung hat den unerwünschten Nachteil, dass die Anzahl CNNs und damit der Rechenaufwand mit der Anzahl der Arten und Kategorien deutlich ansteigt.

Besser eignet sich ein CNN mit Multi-Task-Learning (MTL), das mehrere CNNs zu einem vereint. Somit steigt der Rechenaufwand nur gering, auch wenn die Anzahl Kategorien zunimmt. Das verwendete Multi-Task-CNN schätzt im vorliegenden Projekt das Vorkommen von Götterbaum und Schmalblättrigen Greiskraut und stellt zusätzlich fest, ob Vorkommen des Greiskrauts blühende Pflanzen aufweisen. Der dritte Ausgang zu blühenden Pflanzen ist nur relevant, sofern Greiskraut erkannt wurde. Dieses CNN benötigt nur drei Ausgänge. Somit kann nach dem Vortrainieren auf ImageNet die Anzahl Ausgänge stark reduziert werden, um das CNN mit den markierten Bildkacheln und der neuen Loss-Funktion zu trainieren.

Liefern die ersten beiden Ausgänge nur niedrige Werte, dann enthält das Bild keine der beiden Zielarten. Dies gilt auch dann, wenn nur der dritte Ausgang für die Entscheidung blühend oder nicht-blühend ausschlägt. Das Design des Multi-Task-CNN ist in Abbildung 8 schematisch dargestellt, wobei die farbigen Blöcke die aus den Bildkacheln extrahierten

Features darstellen. Als Feature-Extractors werden wie bereits erwähnt verschiedene gängige Architekturen wie ResNet und DenseNet verwendet. Die extrahierten Features werden dann zu den drei Ausgängen zusammengefasst und mittels der Sigmoid-Funktion auf das Einheitsintervall $[0,1]$ abgebildet, sodass die Werte p_i an den Ausgängen als Wahrscheinlichkeiten interpretiert werden können.

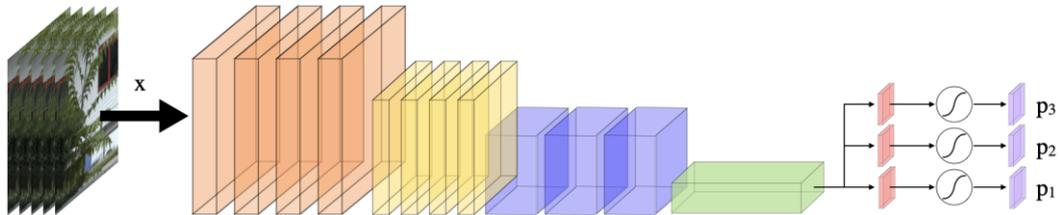


Abb. 8 Design des verwendeten Convolutional Neural Network (CNN).

Die folgende Gleichung zeigt die Loss-Funktion, die für das Trainieren mit den markieren Bildkacheln verwendet wurde. Entsprechend den drei Ausgängen ist sie die Summe von drei binary Crossentropy Loss-Funktionen:

$$LOSS(y, p(x)) = l(y_1, p_1(x)) + [y_1 \neq 1]l(y_2, p_2(x)) + [y_2 = 1]l(y_3, p_3(x))$$

In der Gleichung bezeichnet p die Wahrscheinlichkeitsschätzung des CNNs für das Eingangsbild x , wobei y die Werte mit den tatsächlichen Markierungen des Experten enthält. Der Index «1» entspricht der Kategorie AILANTHUS, «2» und «3» den Kategorien SENEICIO und SENEICIO BLÜHEND. Die Kategorie SENEICIO umfasst dabei sämtliche Bildkacheln, die im Annotation-Tool als SENEICIO BLÜHEND oder SENEICIO NICHT-BLÜHEND markiert wurden. Ferner enthält y_i den Wert Eins, falls die jeweilige Kategorie in der Bildkachel vorkommt, und Null falls sie vom Experten nicht markiert wurde. Da das häufigere Schmalblättrige Greiskraut nicht markiert wurde sobald der seltenere Götterbaum vorhanden war, wurden die Ausgänge zwei und drei nur mit Bildkacheln trainiert, die keinen Götterbaum enthalten.

Alternative ist auch ein CNN möglich, bei dem identisch mit den Markierungen des Annotation-Tools der zweite Ausgang nur für nicht-blühendes Greiskraut und der dritte Ausgang nur für blühendes Greiskraut trainiert wird. Allerdings funktionierte dieser Ansatz in der Praxis nur bedingt, da beide Kategorien sehr ähnlich sind und Bilder mit blühendem Greiskraut immer auch (Blatt-)Merkmale von nicht-blühendem Greiskraut enthalten. Zudem lag das Hauptaugenmerk auf der Erkennung des Schmalblättrigen Greiskrauts und nicht auf dessen Blühphänologie. Der alternative Ansatz würde jedoch das Erkennen der Art erschweren, da während des Trainings eine Verwechslung der ähnlichen Kategorien «bestraft» wird. Dieses Verhalten wurde in anfänglichen Testläufen beobachtet und der Ansatz daher nicht weiterverfolgt.

Das Trainieren des beschriebenen Multi-Task-CNNs dauerte auf einer TITAN Xp GPU von Nvidia ca. 45 Stunden. Dabei wurde ein auf ImageNet vortrainiertes ResNet152 benutzt und für 18 Epochen weitertrainiert, das heisst die Trainingsbilder wurden 18-mal verwendet.

3.5 Processing-Pipeline

Für die Anwendung des trainierten CNNs und das Erfassen der beiden Zielarten im gesamten Filmmaterial wurde eine Processing Pipeline entwickelt. Der Prozessor (CPU) diente dabei vor allem dazu, die Bilder aus den Filmen für das CNN bereitzustellen,

während ein GPU Cluster (Server mit mehreren Grafikkarten) die Bilder in die Bildkacheln aufteilt und die Wahrscheinlichkeiten für das Vorkommen der Pflanzenarten bestimmte (Abb. 9).

Neben CPUs und GPUs wird genügend Speicherplatz benötigt. Zum einen müssen sämtliche Filme, GPS-Daten sowie Meta-Informationen vorgehalten werden. Die Meta-Informationen beschreiben welche Filme zusammengehören (Mittel- und Seitenstreifen), wie die GPS-Daten den Filmen zugeordnet sind und wie diese aufeinander abgestimmt werden (Time Shift), sodass extrahierten Bildern von Mittel- und Seitenstreifen die korrekte GPS-Koordinate zugewiesen werden kann. Von diesem Speicher wird auch das trainierte CNN geladen. Ferner wird ein Zwischenspeicher benötigt, um die extrahierten Bilder, die vom CNN verarbeitet werden sollen, zu speichern bis sie nicht mehr benötigt werden. Schliesslich müssen noch die Ergebnisse gespeichert werden.

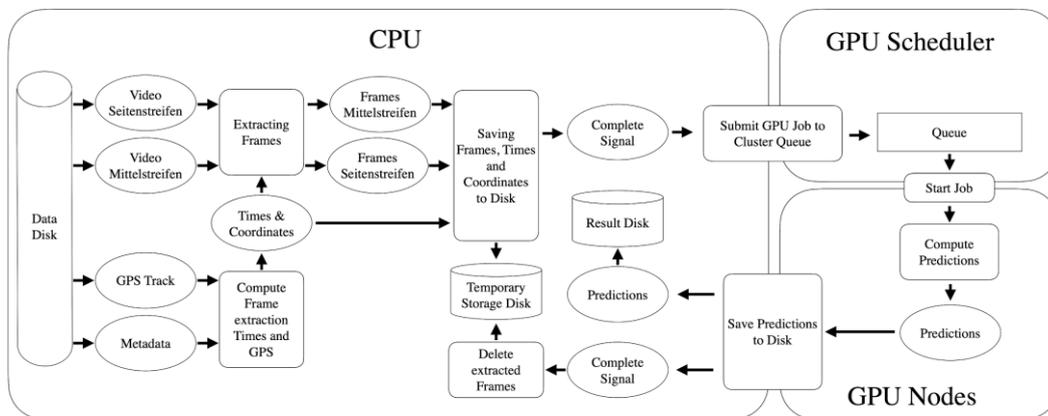


Abb. 9 Flussdiagramm der Processing Pipeline.

Das Vorgehen im Detail: Für jede Teilstrecke werden die Meta-Informationen und die dazugehörigen GPS-Daten geladen. Danach werden die Koordinaten berechnet, an denen die Bilder aus beiden Filmen von Seiten- und Mittelstreifen extrahiert werden sollen und diese als Video-Laufzeiten zwischengespeichert. Im nächsten Schritt werden die beiden Filme geladen, die Einzelbilder mittels *FFMPEG* anhand der zuvor berechneten Laufzeiten extrahiert und im Zwischenspeicher abgelegt. Danach wird ein Job mit der Aufgabe, das Vorkommen der verschiedenen Pflanzenarten auf den extrahierten Frames zu schätzen, an den GPU Scheduler gesendet. Sobald eine GPU-Einheit frei ist, wird das trainierte CNN geladen, die extrahierten Bilder verarbeitet und die Ergebnisse gespeichert. Nachdem der GPU-Auftrag für eine Teilstrecke abgeschlossen ist, werden die extrahierten Bilder vom Zwischenspeicher gelöscht und der benötigte Speicherplatz wird freigegeben.

Jedes extrahierte Bild mit 4k Auflösung ist ca. 16 MB gross. Somit wird für die Bilder eines Films (ca. 180 km) bei einem Abstand von fünf Metern zwischen zwei Bildern rund 570 GB Speicherplatz benötigt. Die Filme wurden daher in kleinere Abschnitte mit maximal 10'000 Bilder unterteilt. Dies reduzierte den maximalen Speicherbedarf, da bereits Bilder wieder gelöscht werden können bevor alle Bilder der Teilstrecke extrahiert wurden. Ausserdem können so mehrere Grafikkarten parallel die gleiche Teilstrecke bearbeiten. Dies verringert die Latenz und erhöht den Durchsatz, da das Extrahieren der Bilder weniger Zeit beansprucht als die Arterkennung durch das CNN.

3.5.1 Laufzeit, Speicherbedarf und andere Kennzahlen

In diesem Abschnitt werden die Laufzeiten der einzelnen Komponenten der Processing Pipeline aufgeführt sowie Durchsatz und Speicherbedarf beschrieben. Die Verarbeitung basierte auf *Python*-Skripten, wobei als Deep-Learning-Framework *PyTorch* verwendet wurde. Ferner stand folgende Hardware zur Verfügung: Intel Core i7-8700 CPU @ 3.20GHz CPU und GeForce GTX TITAN X, GeForce RTX 2080 Ti oder TITAN Xp GPUs von Nvidia je nach Verfügbarkeit sowie 8 TB Festplattenspeicher.

Bei einem Abstand von fünf Metern zwischen zwei Bildern wurden aus sämtlichen Filmen insgesamt 1'634'206 Einzelbilder extrahiert. Dies entspricht 24'513'090 Bildkacheln, die mittels CNN verarbeitet wurden. Pro Sekunde konnten bei einem Abstand von fünf Metern 4.73 Frames mit der Software *FFMPEG* extrahiert und gespeichert werden. Daher benötigt die erwähnte Hardware ca. vier Tage (95h 58min), um alle Einzelbilder zu extrahieren und zu speichern.

Die verwendeten Graphikkarten ermöglichen eine Verarbeitung von 27.15 Bildkacheln pro Sekunde durch das CNN – beziehungsweise 1.81 Einzelbilder pro Sekunde à 15 Bildkacheln. Dies entspricht einer Gesamtlaufzeit von ca. 11 Tagen (250h 47min), falls die Bilder mit nur einer Graphikkarte verarbeitet werden. Daher würde eine rein serielle Verarbeitung der Videos ca. 15 Tage dauern.

Da das Extrahieren von der CPU (Desktop Prozessor) durchgeführt wird und das CNN auf der GPU (Graphikkarte) läuft, können beiden Aufgaben parallel ausgeführt werden. Sind mehrere GPUs vorhanden, kann die Laufzeit durch Parallelisierung weiter reduziert werden. Sobald die Einzelbilder einer Teilstrecke extrahiert und gespeichert sind, kann ein neuer GPU Job gestartet werden, der die extrahierten Bilder mittels CNN verarbeitet. Da das Speichern der aus sämtlichen Filmen im Abstand von fünf Metern extrahierten Bilder ca. 25 Terabyte Speicherkapazität benötigt, ist es wichtig, die extrahierten Bilder wieder zu löschen, sobald die Verarbeitung durch das CNN abgeschlossen ist. Daher müssen nur die Einzelbilder der verschiedenen Teilstrecken, die momentan von den GPUs verarbeitet werden, gleichzeitig im Speicher vorliegen. Die verwendete Pipeline benötigte so maximal ein Terabyte Speicher, da maximal fünf GPUs parallel arbeiteten und die Filme wie oben beschrieben in Abschnitte mit je 10'000 Einzelbildern aufgeteilt wurden.

Durch diese Optimierungen dauerte die Verarbeitung sämtlicher Filme mit fünf Meter Abstand zwischen den extrahierten Bildern ca. fünf Tage (127 h 25 min), benötigte maximal ein Terabyte Speicherkapazität und nutzte gleichzeitig maximal fünf GPUs. Diese Zeit ist im Gegensatz zu den vorher erwähnten Angaben keine Hochrechnung, sondern die tatsächlich gemessene Dauer. Eine CPU genügte für das Extrahieren der Bilder aus den Filmen, um die fünf GPUs ausreichend schnell zu versorgen. Sobald allerdings zusätzliche GPUs zur Verfügung stehen, kann die Laufzeit durch Parallelisierung von CPUs beim Extrahieren der Bilder weiter reduziert werden.

4 Evaluierung der trainierten Modelle

4.1 Statistische Kennzahlen

Für die Beurteilung der Qualität eines Klassifikationsverfahrens dient der Vergleich der Resultate mit den tatsächlichen Eigenschaften der klassifizierten Objekte. Im Projekt ist dies der Vergleich der automatisierten Arterkennung durch das CNN mit den Angaben des Experten beim Markieren der Bildkacheln. Für diese Beurteilung haben sich mehrere Kennzahlen etabliert. Zunächst müssen allerdings noch die Werte der verschiedenen Ausgänge des CNNs in eine Schätzung für das Vorkommen oder Nicht-Vorkommen der verschiedenen Kategorien überführt werden.

Die Ausgänge des CNNs entsprechen zunächst Wahrscheinlichkeiten, deren Werte zwischen Null und Eins liegen. Die Schätzung des CNNs bedeutet beim Wert Eins, dass die entsprechende Kategorie gemäss CNN sicher vorkommt, und beim Wert Null, dass die Kategorie sicher nicht enthalten ist. Bei allen Werten dazwischen ist das Vorkommen oder Fehlen der Kategorie mit unterschiedlichen Wahrscheinlichkeiten verbunden. Es gilt daher zu klären, ab welchem Wahrscheinlichkeitswert (Schwellenwert) die Schätzung als Vorkommen der Kategorie gewertet werden soll. Hierzu wird zunächst für eine Vielzahl von Schwellenwerten eine Kennzahl für die Güte des CNN berechnet und anschliessend der Schwellenwert ermittelt, der diese Kennzahl optimiert.

Eine wichtige Voraussetzung für die Berechnung üblicher Kennzahlen ist die Übersicht der Ergebnisse der Klassifikation in einer sogenannten Wahrheits-Matrix (Confusion Matrix), die vier Fälle unterscheidet.

- True Positive (TP): Die Kategorie ist im Bild markiert und wurde vom CNN erkannt.
- True Negative (TN): Die Kategorie ist nicht markiert und wurde nicht erkannt.
- False Positive (FP): Die Kategorie ist nicht markiert, wurde aber vom CNN erkannt.
- False Negative (FN): Die Kategorie ist markiert, wurde aber vom CNN nicht erkannt.

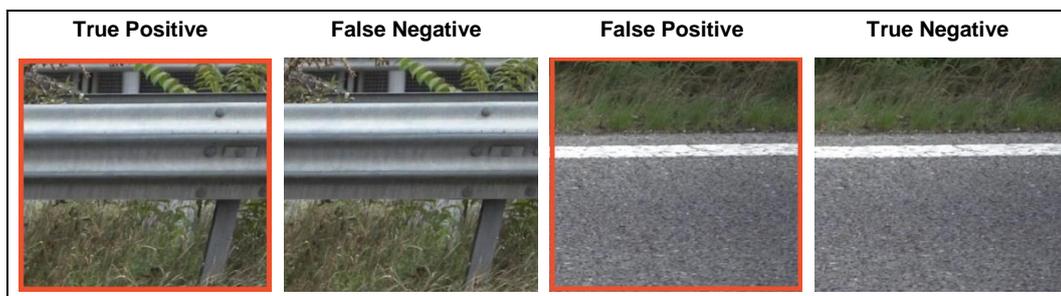


Abb. 10 Beispielbilder für die verschiedenen Fälle, die in einer Wahrheits-Matrix zusammengefasst werden. Der rote Rahmen gibt an, dass das Netz die Kategorie AILANTHUS im Bild erkannt hat. Allerdings kommt der Götterbaum nur in den ersten beiden Bildern tatsächlich vor.

Accuracy

Eine der am häufigsten verwendeten Kennzahlen für Klassifikationsverfahren ist *Accuracy*. Sie berechnet sich als Verhältnis der korrekt klassifizierten Bilder zur Gesamtzahl der Bilder.

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}$$

Accuracy ist jedoch ungeeignet für Kategorien, die wie im vorliegenden Projekt stark ungleich verteilt sind (siehe Tabelle 1). Würde das CNN zum Beispiel nie die Kategorie AILANTHUS erkennen, so würde es für den Götterbaum trotzdem eine Accuracy von 99.1% erzielen.

Precision und Recall

Daher existieren weitere Kennzahlen wie *Recall* und *Precision*, die für solche Verteilungen besser geeignet sind. Beide Kennzahlen hängen nicht von den True Negatives ab.

$$REC = \frac{TP}{TP + FN}$$

$$PRE = \frac{TP}{TP + FP}$$

Recall misst dabei die Trefferquote des Verfahrens, also wie viele der Bilder, auf denen die Art vom Experten markiert wurde, das CNN erkennt. Komplementär hierzu beschreibt Precision die Genauigkeit der Klassifikation, das heisst wie viele der erkannten Bilder tatsächlich auch mit der jeweiligen Kategorie markiert wurden. Beide Kennzahlen können nicht unabhängig voneinander maximiert werden. Typischerweise ist der Recall hoch, wenn die Precision tief ist, und umgekehrt. Erkennt das Verfahren zum Beispiel auf jedem Bild die Art, obwohl sie nur selten markiert wurde, so ist der Recall hoch aber die Precision tief. Umgekehrt ist die Precision hoch und der Recall tief, sollte das Verfahren nur in wenigen eindeutigen Fällen die Pflanzenart erkennt und diese ansonsten übersehen. Für die Bestimmung des Schwellenwerts ergibt sich so das Problem, dass zwei gegenläufige Kennzahlen je Schwellenwert existieren.

F1-Score

Der *F1-Score* kombiniert die beiden Kennzahlen Precision und Recall. Dabei bedeutet ein hoher Wert des F1-Scores ein guter Kompromiss zwischen Recall und Precision.

$$F1 = 2 \cdot \frac{PRE \cdot REC}{PRE + REC} = \frac{2 \cdot TP}{2 \cdot TP + FP + FN}$$

Da unterschiedliche Schwellenwerte in der Regel unterschiedliche F1-Scores aufweisen, wird häufig der höchste F1-Score angegeben und dieser auch für den Vergleich verschiedener Klassifikationsverfahren verwendet.

Area Under the Curve

Eine Alternative zum F1-Score stellt *Area Under the Curve* (AUC) dar. AUC ist hierbei definiert durch die Fläche unter der Precision-Recall-Kurve (Beispiele im folgenden Kapitel). Die Werte von AUC liegen zwischen Eins (beste Klassifikation) und Null (schlechteste Klassifikation). Der Vorteil von AUC liegt darin, dass diese Kennzahl Precision und Recall unabhängig von der Wahl eines Schwellenwerts kombiniert. Gleichzeitig ist dies aber auch ein Nachteil, da AUC nicht zur Bestimmung des Schwellenwerts verwendet werden kann.

4.2 Trainingsbilder, Validierungsbilder und Testbilder

Für das Trainieren der CNNs wurde ein Teil der vom Experten markierten Bildkacheln als Trainingsbilder verwendet (Training Set). Die Bestimmung der Schwellenwerte für die Klassifikation erfolgte mit einem weiteren Teil der markierten Bilder, der nicht zum Trainieren verwendet wurde – den sogenannten Validierungsbildern (Validation Set). In den folgenden Abschnitten wurde der Schwellenwert so gewählt, dass der F1-Score auf den Validierungsbildern maximiert wird. Dies lässt allerdings keine direkten Schlüsse für den erreichbaren F1-Score für neue Bilder zu, die weder zum Trainieren noch zur Bestimmung des Schwellenwerts verwendet wurden. Um die Fähigkeit zur Generalisierung eines Netzes dennoch bestimmen zu können, wird der F1-Score mittels weiterer bisher ungenutzter markierter Bildkacheln berechnet, ohne den Schwellenwert erneut zu optimieren. Der auf diesen Testbildern (Test Set) erzielte Wert erlaubt so Prognosen zur Güte des Netzes, wenn dieses auf neuen Bildern angewendet wird. Im vorliegenden Projekt wurden 80% der markierten Bildkacheln als Trainingsbilder, 10% als Validierungsbilder und 10% als Testbilder zufällig ausgewählt. Training und Evaluierung des CNN wurde ferner viermal mit den unterschiedlichen Feature-Extractors ResNet101, ResNet152, DenseNet169 und DenseNet201 wiederholt.

4.3 CNNs mit Trainingsbildern aus drei Befahrungen

In diesem Abschnitt wird die Evaluierung der CNNs mit Trainingsbildern aus sämtlichen Filmen der drei Befahrungen beschreiben. Als Kennzahlen für die Güte der Klassifikation werden Precision, Recall, F1-Score und AUC angegeben. Abbildung 11 zeigt für die Kategorie AILANTHUS die Precision-Recall-Kurven, wobei die verschiedenen Wertepaare der Kurven unterschiedlichen Schwellenwerten entsprechen, welche die Wahrscheinlichkeiten des jeweiligen CNN in eine Schätzung zu Vorkommen oder Nichtvorkommen der Kategorie umwandeln. Der optimale Schwellenwert maximiert gleichzeitig Precision und Recall (Werte oben rechts im Diagramm) und ist hier gleichbedeutend mit einem maximalen F1-Score. Dieser Schwellenwert definiert den für die Klassifikation gewählten Arbeitspunkt (Operating Point) des CNN (ausgefüllte Kreise).

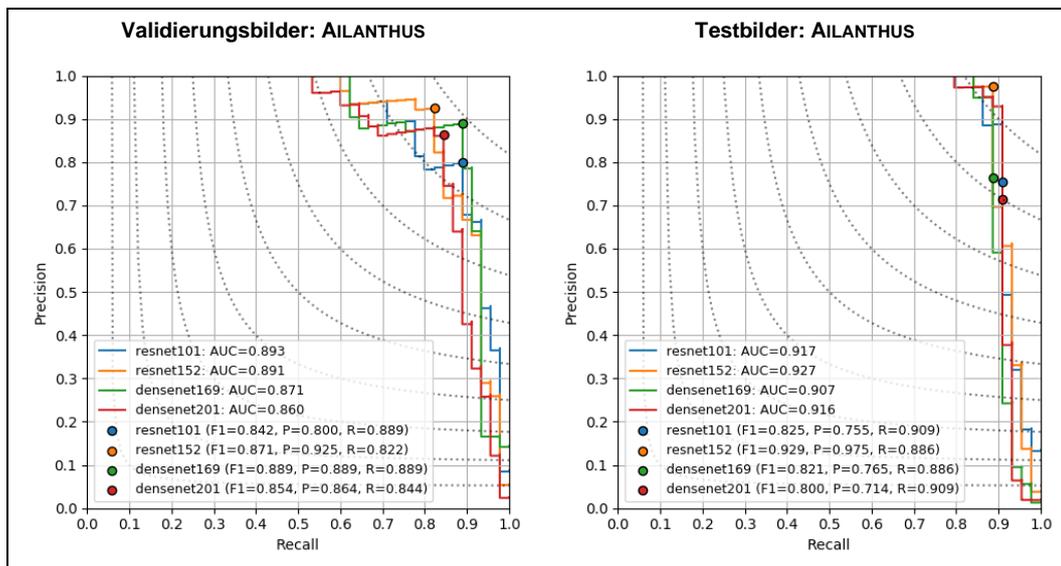


Abb. 11 Precision-Recall-Kurven der trainierten CNNs für die Kategorie AILANTHUS mit Trainingsbildern aus allen drei Befahrungen. Die Validierungsbilder dienen der Bestimmung des Schwellenwerts durch Maximierung des F1-Scores, deren Güte auf den Testbildern überprüft wird (rechte Grafik). Die grau gepunkteten Linien sind Isolinie auf denen der F1-Score identisch ist (von 0.1 unten links bis 0.9 oben rechts). In der Legende beziehen sich die Werte zu F1-Score, Precision und Recall auf den Arbeitspunkt des CNN.

Die Evaluierung der CNNs für die Kategorie AILANTHUS zeigt, dass für ResNet152 der F1-Score am Arbeitspunkt auf den Testbildern sogar höher ausfällt, während die Arbeitspunkte für alle anderen CNNs einen geringeren F1-Score aufweisen. Gleichzeitig erzielt ResNet152 den höchsten AUC-Wert auf den Testbildern. ResNet152 schneidet daher für die Kategorie AILANTHUS sowohl auf den Validierungs- als auch auf den Testbildern sehr gut ab.

Abbildung 12 zeigt die entsprechenden Precision-Recall-Kurven für die Kategorien SENECIO und SENECIO BLÜHEND. Es fällt auf, dass für SENECIO bis auf ResNet101 die drei übrigen CNNs ähnlich gut abschneiden. Dies gilt sowohl auf den Validierungsbildern wie auch auf den Testbildern und sowohl für F1-Score wie auch für AUC. Für die Kategorie SENECIO BLÜHEND erreicht wiederum ResNet152 den höchsten F1-Score auf den Validierungsbildern, doch schneidet der erhaltene Arbeitspunkt diesmal nicht so gut auf den Testbildern ab, obwohl ResNet152 den höchsten AUC-Wert aufweist. Den besten Arbeitspunkt auf den Testbildern erreicht hier DenseNet201.

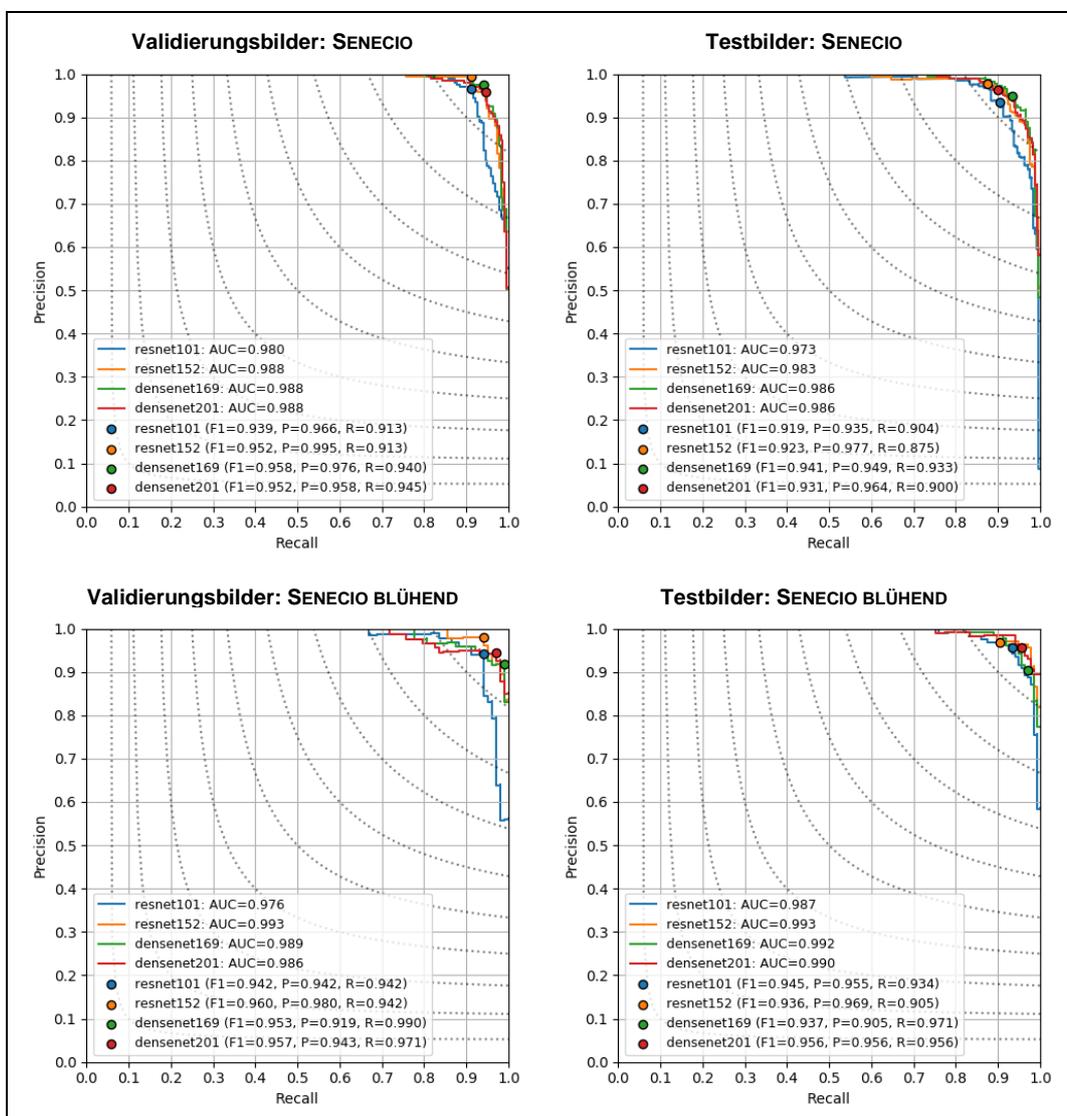


Abb. 12 Precision-Recall-Kurven der trainierten CNNs für die Kategorien SENECIO und SENECIO BLÜHEND mit Trainingsbildern aus allen drei Befahrungen. Für weitere Angaben zur Darstellung siehe Abb. 11.

Da abhängig von den Kategorien CNNs mit unterschiedlichen Feature-Extractors am besten abschneiden, werden die Ergebnisse für alle auf den Testbildern getesteten Modellen in den Tabellen 2 und 3 zusammengefasst. Es fällt auf, dass sowohl für F1-Score als auch für AUC ResNet152 durchschnittlich die besten Werte liefert. Daher wurde im Projekt für die automatisierte Kartierung ResNet152 als Feature-Extractor verwendet.

Tab. 2 F1-Scores für unterschiedliche CNNs und Kategorien (mit Testbildern berechnet)

CNN	AILANTHUS	SENECIO	SENECIO BLÜHEND	Durchschnitt
ResNet101	0.825	0.919	0.945	0.896
ResNet152	0.929	0.923	0.936	0.929
DenseNet169	0.821	0.941	0.937	0.900
DenseNet201	0.800	0.931	0.956	0.896

Tab. 3 AUC-Werte für unterschiedliche CNNs und Kategorien (mit Testbildern berechnet)

CNN	AILANTHUS	SENECIO	SENECIO BLÜHEND	Durchschnitt
ResNet101	0.917	0.973	0.987	0.959
ResNet152	0.927	0.983	0.993	0.968
DenseNet169	0.907	0.986	0.992	0.962
DenseNet201	0.916	0.986	0.990	0.964

4.4 CNNs mit Trainingsbildern aus nur einer Befahrung

Anstatt die CNNs mit Bildern aus allen drei Befahrungen zu trainieren, ist es auch möglich, nur Bilder einer bestimmten Befahrung (Jahreszeit) zu verwenden. Wir untersuchen daher im Folgenden die Frage, wie gut die Arterkennung für die Kategorien SENECIO und AILANTHUS ist, wenn Trainingsbilder nur aus einer Befahrung verwendet werden.

Abbildung 13 zeigt die Precision-Recall-Kurven mit Trainings- und Validierungsbildern aus nur einer Befahrung und Testbildern aus allen drei Befahrungen. Die Ergebnisse verdeutlichen, dass das Trainieren mit nur einer Befahrung grundsätzlich funktioniert. Dabei zeigen die mit den August-Bildern trainierten CNNs für beide Arten die höchsten AUC-Werte. Gleichzeitig ist aber eine deutliche Abnahme der Güte der Modelle gegenüber den ursprünglichen CNNs zu erkennen. Für beide Arten korrelieren dabei die AUC-Werte mit der Anzahl der verfügbaren Trainingsbilder, die für die August-Befahrung am grössten ist. Beim Greiskraut kommt hinzu, dass die Trainingsbilder der Mai- und Oktober-Befahrung grösstenteils nicht-blühende bzw. blühende Vorkommen enthalten. Nur in den August-Bildern sind beide Blühzustände ähnlich häufig vorhanden. Da die Testbilder der drei Befahrungen blühende und nicht-blühende Pflanzen enthalten, sind die Bilder der August-Befahrung offenbar am besten als Trainingsbilder geeignet.

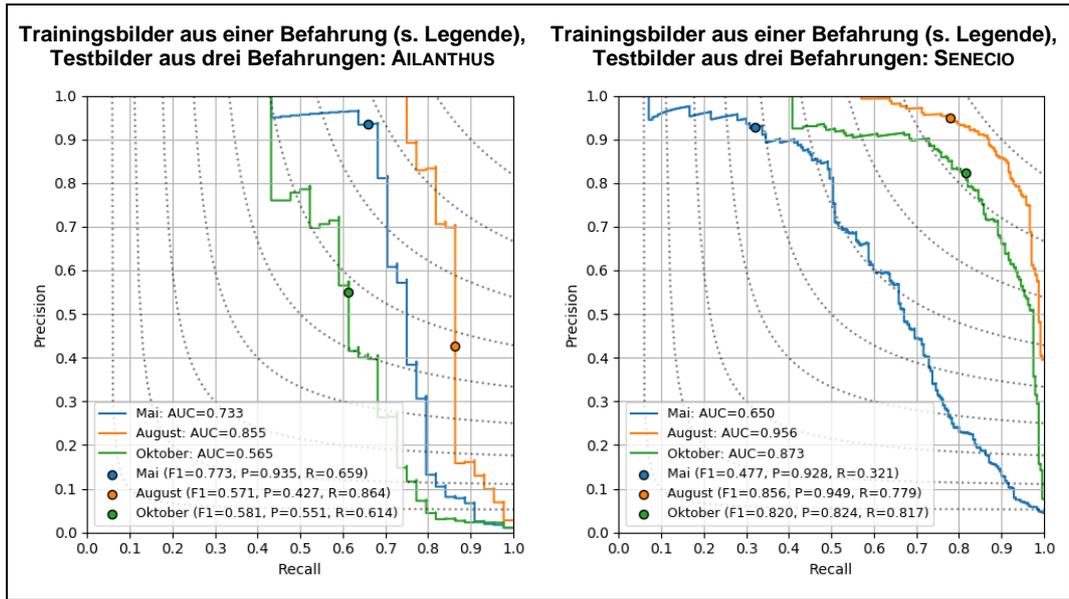


Abb. 13 Precision-Recall-Kurven der Kategorien AILANTHUS und SENECIO, wenn die CNNs mit Bildern aus nur Befahrungen (s. Legende) trainiert und mit Testbildern aus allen drei Befahrungen getestet werden. Für weitere Angaben zur Darstellung siehe Abb. 11.

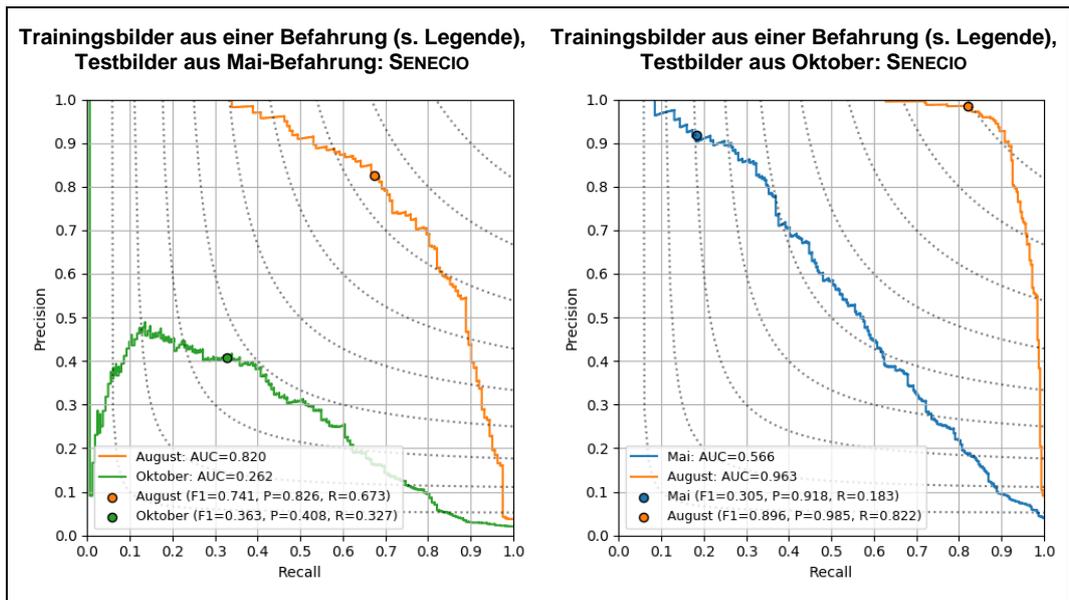


Abb. 14 Precision-Recall-Kurven der Kategorie Senecio, wenn die CNNs nur mit Bildern einer Jahreszeit trainiert wurden und auf sämtlichen Trainings- und Validierungsbildern von Mai oder Oktober getestet wurden. Die Punkte zeigen den Arbeitspunkt ausgewählt mittels den Validierungsbildern der in der Legende genannten Befahrung. Für weitere Angaben zur Darstellung siehe Abb. 11.

Für das Greiskraut wird der Einfluss der unterschiedlichen Blühphänologie noch deutlicher, wenn die mit nur einer Befahrung trainierten CNNs nicht mit Bildern aus allen drei Befahrungen, sondern nur mit Bildern einer jeweils anderen Befahrung getestet werden (Abb. 14). Es zeigt sich, dass das CNN mit Trainingsbildern der Oktober-Befahrung trotz rund doppelt so vieler Trainingsbilder schlechter beim Testen mit Bildern der Mai-Befahrung abschneidet (grüne Kurve) als umgekehrt (blaue Kurve). Dies dürfte daran liegen, dass wie bereits erwähnt die Trainingsbilder vom Oktober mehrheitlich blühendes

Greiskraut enthalten und die gelben Korbblüten für das trainierte CNN wahrscheinlich ein wichtiges Merkmal bei der Arterkennung darstellen. Allerdings fehlt dieses Blütenmerkmal in den Bildern der Mai-Befahrung weitgehend, da diese fast ausschliesslich nicht-blühendes Greiskraut enthalten. Umgekehrt, scheint es weniger problematisch, das CNN nur mit nicht-blühendem Greiskraut zu trainieren, da die charakteristischen Merkmale der Blattstruktur auch bei blühenden Pflanzen auftreten.

Eine Übersicht zu den erzielten F1-Scores und AUC-Werten einschliesslich der Kategorie SENECIO BLÜHEND liefern die Tabellen 4 und 5. Der Vergleich zeigt, dass die besten Resultate erreicht werden, wenn mit Bildern aus allen drei Befahrungen trainiert wird. Dies bestätigt die gewählte Strategie bei der Auswahl der Trainingsbilder. Falls es allerdings nur möglich ist, mit Bildern aus einer Jahreszeit zu trainieren, dann sollten diese Bilder besonders für das Schmalblättrige Greiskraut im Sommer aufgenommen werden.

Tab. 4 F1-Scores mit Trainingsbilder aus einzelnen und allen Befahrungen.

Trainingsbilder	AILANTHUS	SENECIO	SENECIO BLÜHEND
Mai	0.773	0.477	0.625
August	0.571	0.856	0.714
Oktober	0.581	0.820	0.701
alle	0.929	0.923	0.926

Tab. 5 AUC-Werte mit Trainingsbilder aus einzelnen und allen Befahrungen.

Trainingsbilder	AILANTHUS	SENECIO	SENECIO BLÜHEND
Mai	0.733	0.650	0.692
August	0.855	0.956	0.906
Oktober	0.565	0.873	0.719
alle	0.927	0.983	0.955

4.5 Evaluierung einer Frame-basierten Arterkennung

Die bisherige Evaluierung der CNNs bezog sich stets auf die Bildkacheln (Tiles) und nicht auf die extrahierten Bilder (Frames). Bisher wurde daher nicht berücksichtigt, ob eine Art nur einmal oder mehrfach je Frame erkannt wurde. Abbildung 15 zeigt den Zusammenhang zwischen den vorhergesagten Wahrscheinlichkeiten für das Auftreten der Arten in den Bildkacheln und der Anzahl erkannter Bildkacheln je Bild. Je mehr Bildkacheln mit Artvorkommen in einem Bild erkannt werden, desto höher sind in der Regel auch die Wahrscheinlichkeiten für das Auftreten der Arten in den einzelnen Bildkacheln. Die Darstellung verdeutlicht, dass die Schwellenwertbestimmung besonders durch Bilder beeinflusst wird, in denen die Arten in nur wenigen Kacheln erkannt werden. Hier besteht eine grössere Unsicherheit bei der Arterkennung als für Bildkacheln aus Bildern mit zahlreichen erkannten Kacheln.

Es wurden daher auch Precision-Recall-Kurven auf Ebene der Bilder (Frames) berechnet (Abb. 16). Dabei wurden erkannte Artvorkommen erst als solche gewertet, wenn mindestens eine, zwei oder drei Kacheln markiert waren beziehungsweise mindestens ein, zwei oder drei Kacheln vom CNN erkannt wurden. Es fällt auf, dass je mehr erkannte Kacheln pro Bild zur Arterkennung benötigt werden, die Precision bei gleichbleibendem Recall ansteigt. So wird auf den Testbildern des Götterbaums ein perfekter Arbeitspunkt mit Precision und Recall von 100% erreicht, falls nur Frames mit mindestens drei markierten Kacheln betrachtet werden. Auch für das Greiskraut erhöht sich die Precision je mehr erkannte Kacheln benötigt werden bei gleichbleibendem Recall. So wird eine Precision von 100% bis zu einem Recall von 82% erreicht.

Diese Resultate sind wichtig, da die Anzahl der False Positives reduziert werden kann, falls nur Bilder mit mehreren vom CNN erkannten Kacheln als Artvorkommen gewertet werden. Der Ansatz ermöglicht so Verbreitungskarten mit Frame-basierten Vorkommen mit hoher Precision. Er wurde daher auch für die Weitergabe der automatisiert erfassten Verbreitungsdaten an das nationale Daten- und Informationszentrum der Schweizer Flora (Info Flora) verwendet, um auch hier die Rate der False Positives möglichst gering zu halten.

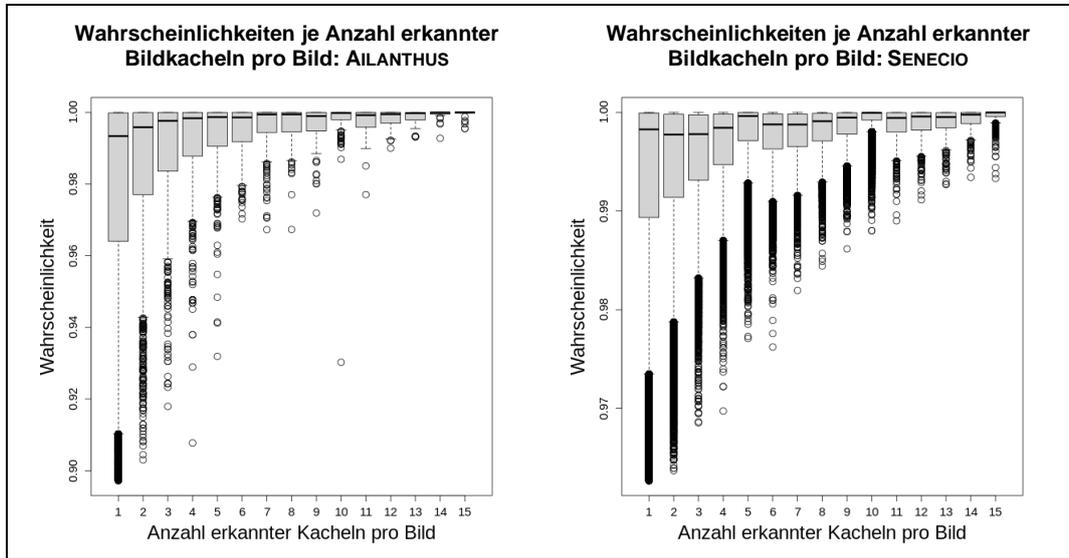


Abb. 15 Verteilungen der Wahrscheinlichkeiten für das Vorkommen der Kategorien AILANTHUS und SENECIO in Abhängigkeit von der Anzahl erkannter Kacheln pro Bild. Dargestellt sind nur die Wahrscheinlichkeiten, die über dem Schwellenwert der F1-Optimierung liegen, also als Vorkommen gewertet wurden. Die Verteilungen sind als Box- and-whisker-plots dargestellt. Die mittlere Querlinie repräsentieren den Median, die grauen Rechtecke die beiden mittleren Quartile, die gestrichelte Linien als «Whiskers» haben hier die 1.5-fache Höhe der angrenzenden Quartile und die Kreissymbole zeigen die ausserhalb davon liegende Werte.

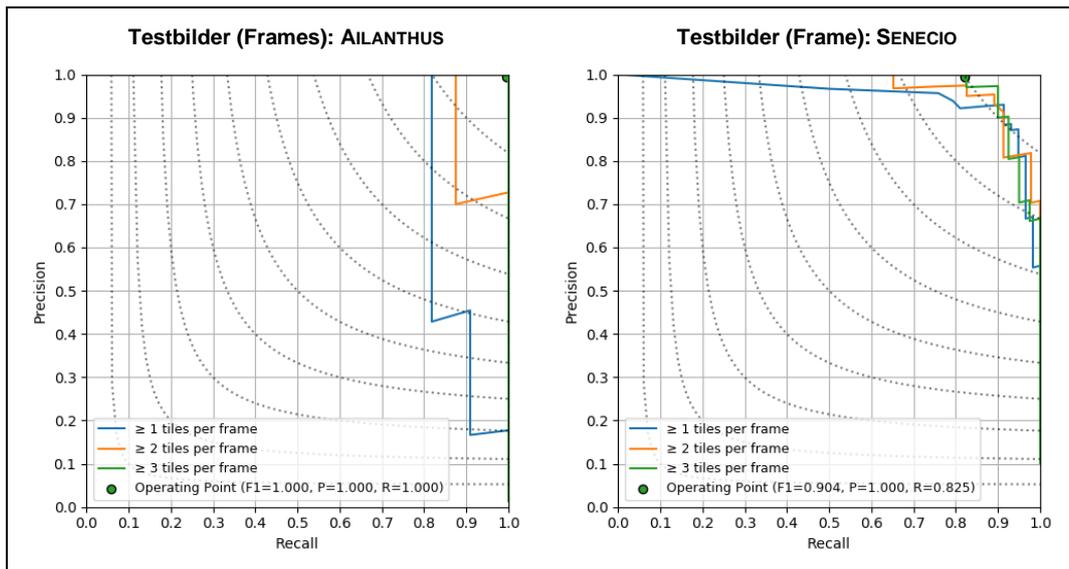


Abb. 16 Frame-basierte Precision-Recall-Kurven des CNN mit ResNet152 für die Kategorien AILANTHUS und SENECIO. Bei dieser Evaluierung wurden nur Bilder mit mindestens einer, zwei oder drei markierten Kacheln als Vorkommen gewertet. Dasselbe galt für die Vorhersagen des CNN.

4.6 Visuelle Überprüfung der CNN Resultate

Die bisherige Evaluierung liefert statistische Aussagen zur Güte der CNNs, lässt jedoch keine Rückschlüsse zu, wie gut Arterkennung in unterschiedlichen Aufnahme- und Wuchssituationen funktioniert. Die Resultate der Klassifikation wurden daher vom Experten im Bildmaterial visuell überprüft. Dabei wurden die durch Optimierung des F1-Scores erkannten Bildkacheln wie im Annotation-Tool durch farbige Umrandungen gekennzeichnet. Abbildung 17 zeigt zwei Beispielbilder mit erkannten Bildkacheln des Götterbaums. Das obere Bild lässt erkennen, dass neben älteren Pflanzen mit ihrer typischen Blattstruktur auch Jungpflanzen oder Wurzelbrut vom CNN erkannt werden. Immer wieder traten auch Bildkacheln auf, die zunächst wie Klassifikationsfehler aussahen (False Positives), bei genauerer Betrachtung jedoch den Götterbaum enthielten (unteres Bild). Ein besonders eindrückliches Beispiel für die hohe Sensitivität der Arterkennung zeigt Abbildung 18. Hier wurde der Götterbaum hinter den abgetönten Scheiben eines vorbeifahrenden Fahrzeugs erkannt. Typische Situationen für die automatisierte Arterkennung des Schmalblättrigen Greiskrauts zeigt Abbildung 19.

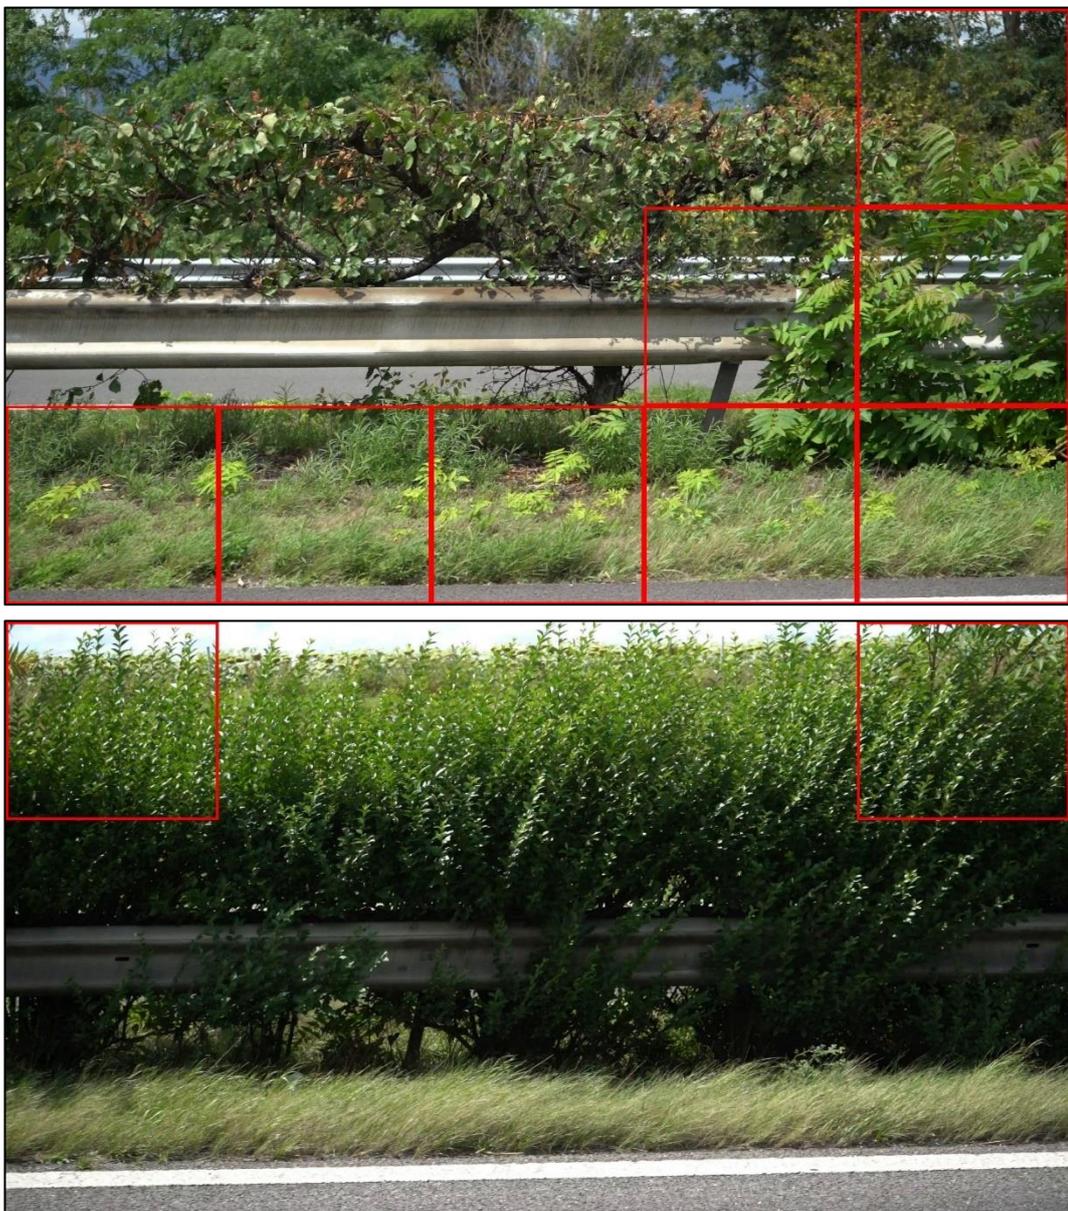


Abb. 17 Zwei Beispielbilder mit automatisiert korrekt erkannten Vorkommen des Götterbaums (rote umrandete Bildkacheln).



Abb. 18 Beispielbild, in dem der Götterbaum hinter den abgedunkelten Scheiben eines vorbeifahrenden Fahrzeugs vom CNN erkannt wurde (rote umrandete Bildkachel). Rechts ist ein vergrößerter Ausschnitt des linken Bilds dargestellt.



Abb. 19 Drei Beispielbilder für die korrekte automatisierte Erkennung des Schmalblättrigen Greiskrauts (gelb umrandete Bildkacheln).

Auch die automatisierte Erkennung des Schmalblättrigen Greiskrauts lieferte überzeugende Resultate sowohl für dichte Bestände (oberes Bild) als auch bei lückigen Vorkommen in grasreichen Abschnitten (mittlerer Bildstreifen) oder bei kleinen Einzelpflanzen (unterer Bildstreifen). Bei Letzteren wurde vom Experten oft erst bei genauerer Betrachtung der extrahierten Originalbilder das Vorkommen der Art festgestellt.

Es gibt aber auch Fehlklassifikationen. Dies gilt insbesondere bei der automatisierten Arterkennung auf Basis des optimierten F1-Scores, der einen Kompromiss zwischen Recall und Precision darstellt. So traten bei der visuellen Überprüfung unter anderem Fehlklassifikationen bei ähnlichen Arten auf. Dies ist jedoch eher die Ausnahme, da beispielsweise im Fall des Götterbaums teilweise viel häufigere Arten mit ähnlichen Blattstrukturen wie Esche, Robinie, Walnuss oder Holunder gut vom Götterbaum unterschieden wurden. Eine Verwechslung mit dem sehr ähnlichen, aber selteneren Essigbaum kann nicht ausgeschlossen werden, wurde bei der visuellen Überprüfung jedoch bei einem grösseren Essigbaumbestand nicht festgestellt. Neben der Verwechslung mit ähnlichen Arten traten auch Fehlklassifikationen auf, die einem Experten nicht unterlaufen würden. Abbildung 20 zeigt beispielsweise ein Graffiti und ein Muster auf einer LKW-Plane, die vom CNN irrtümlich als Götterbaum erkannt wurden. So überraschend diese Fehlklassifikationen bei der ansonsten hohen Übereinstimmung mit dem Experten erscheinen, so verständlich sind sie aus Sicht des Deep-Learning-Ansatzes. Die falsch erkannten Bildinhalte sind nicht oder kaum in den Trainingsbildern enthalten, so dass das CNN nicht ausreichend gut auf diese trainiert werden konnte.

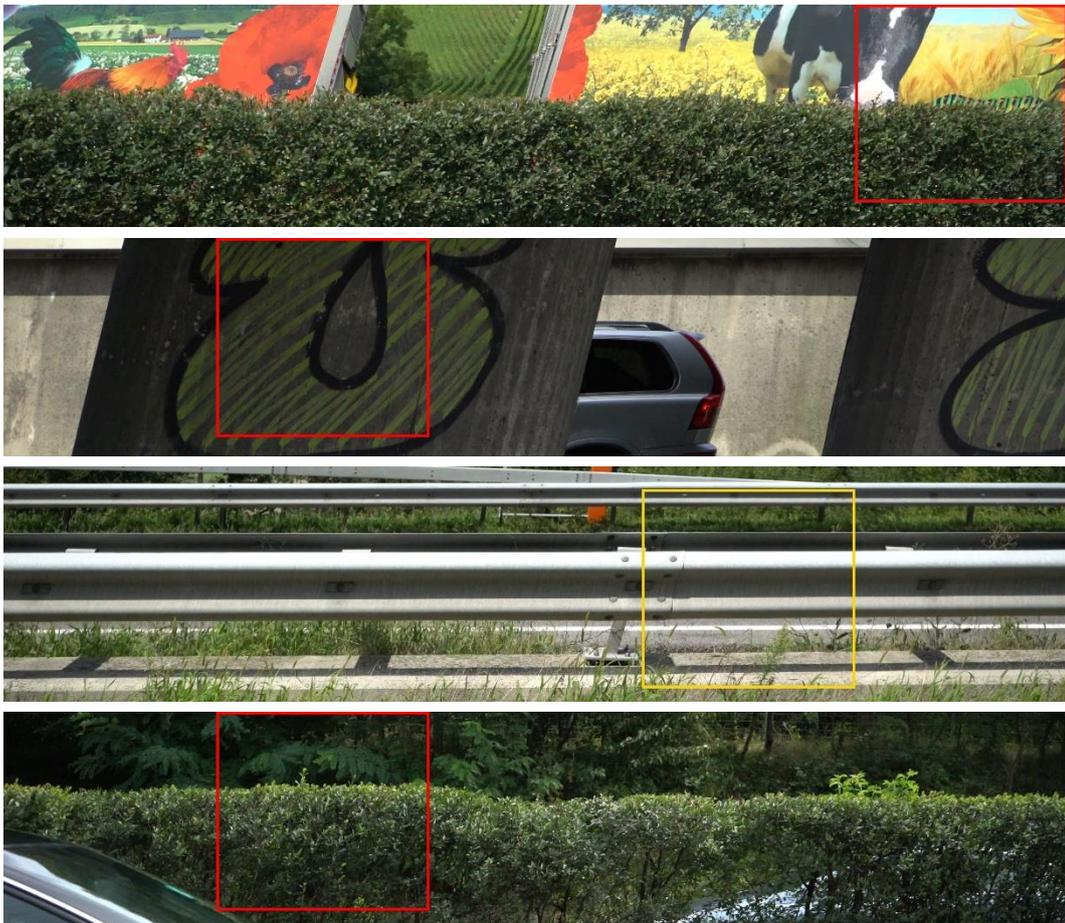


Abb. 20 Beispielbilder für Fehlklassifikationen (False Positives) der automatisierten Arterkennung. Von oben nach unten: Fehlerkennung des Götterbaums auf einer LKW-Plane und einem Graffiti; irrtümliche Erkennung des Greiskrauts (vermutlich wegen Kanadischem Berufkraut, *Conyza canadensis*); Fehlerkennung des Götterbaums bei Robinie.

5 Verbreitungskarten

Im folgenden Kapitel werden die Arbeitsschritte von den georeferenzierten Resultaten des CNN bis zur Kartendarstellung beschrieben. Die Interpretation und Auswertung der Karteninhalte erfolgen anschliessend.

5.1 Verarbeitung der georeferenzierten CNN Resultate

Für die automatisierte Kartierung wurden aus sämtlichen Filmen der drei Befahrungen Bilder im Abstand von fünf Metern extrahiert und das Auftreten der Kategorien *AILANTHUS*, *SENECIO* und *SENECIO BLÜHEND* durch das CNN in den jeweils 15 Bildkacheln vorhergesagt. Dies ergab Wahrscheinlichkeiten für das Auftreten der drei Kategorien in über 1.6 Millionen georeferenzierten Bildern beziehungsweise rund 24.5 Millionen Bildkacheln.

Nicht alle Daten konnten für die Kartendarstellung verwendet werden. Neben Doppelbefahrungen einzelner Autobahnabschnitte mussten Tunnelpassagen, Zwischenhalte für das Austauschen der Speichermedien, Wendebereiche am Ende der Teilstrecken sowie Zufahrten zu und Abfahrten von den Autobahnen für die Kartendarstellung und Analysen ausgeschlossen werden. Das Bildmaterial zeigt hier entweder nicht die Vegetation von Mittel- und Seitenstreifen an Autobahnen oder enthält nach Tunnelausfahrten für eine gewisse Strecke keine oder nicht zuverlässige GPS-Koordinaten. Für diesen Arbeitsschritt wurden daher 37 Ausschlusspolygone bestimmt (Abb. 21) und die Bild-Koordinaten innerhalb dieser Flächen nicht weiterverwendet. Nach Tunnelausfahrten wurden Koordinaten erst wieder berücksichtigt, sobald diese für sämtliche drei Befahrungen zuverlässig vorlagen. Für die Kartendarstellung wurden die CNN-Resultate so auf rund 1.35 Millionen Bilder beziehungsweise rund 20.24 Millionen Bildkacheln eingengt.



Abb. 21 Beispiele für Ausschlusspolygone im Bereich einer Tunnelpassage (oben) sowie eines Zwischenhalts an einer Autobahnraststätte (unten). Weisse Kreissymbole stellen ausgeschlossene Bild-Koordinaten dar, während die grünen, roten und blauen Koordinaten weiterverwendet wurden und der Mai-, August- und Oktober-Befahrung entsprechen.

Die Verarbeitung der räumlichen Daten und spätere Kartendarstellung erfolgte in *R* [63] und *RStudio* [64] mit den *R*-Packages *leafem* [65], *leafgl* [66], *leaflet* [67], *leaflet.extras* [68], *mapview* [69], *raster* [70], *shiny* [71] und dem *leaflet*-Plugin *hotline* (<https://github.com/iosphere/Leaflet.hotline>).

5.2 Kartendarstellung

Für die räumliche Darstellung der automatisch klassifizierten rund 1.35 Millionen Bilder wurden zwei unterschiedliche Ansätze verwendet. Zum einen wurde die Anzahl der erkannten Bildkacheln an den Bild-Koordinaten (Fahrzeugpositionen) durch unterschiedlich grosse und gefärbte Kreissymbole angezeigt. Dies eignet sich besonders für kleinräumige Darstellungen und gibt direkt die Resultate der Klassifikation wieder. Die Darstellung erschwert jedoch die Interpretation grösserer Übersichtskarten, da einzelne Symbole grössere Flächen abdecken oder kaum sichtbar wären. Als zweiter Ansatz wurde daher für Übersichtskarten die Information aus benachbarten Bildern zusammengefasst, um so den durchschnittlichen Zustand von Autobahnabschnitten besser abzubilden. Wegen der grossen Anzahl an Bildern wurde hierfür die maximale Anzahl erkannter Bildkacheln zunächst in einer Auflösung von 100 Metern gerastert und anschliessend mit einem Gauss-Filter ($\sigma = 2000$ m) geglättet. Einen Vergleich der beiden Kartendarstellungen bei unterschiedlicher Auflösung zeigt Abbildung 22. In der linken Karte mit der höchsten Auflösung sind für beide Fahrtrichtungen die Fahrzeugpositionen als Bild-Koordinaten der drei Befahrungen zu erkennen. Da der Götterbaum hier auf dem Mittelstreifen vorkommt, wurde das Vorkommen in beiden Fahrtrichtungen mit ähnlichem Verbreitungsmuster erfasst.

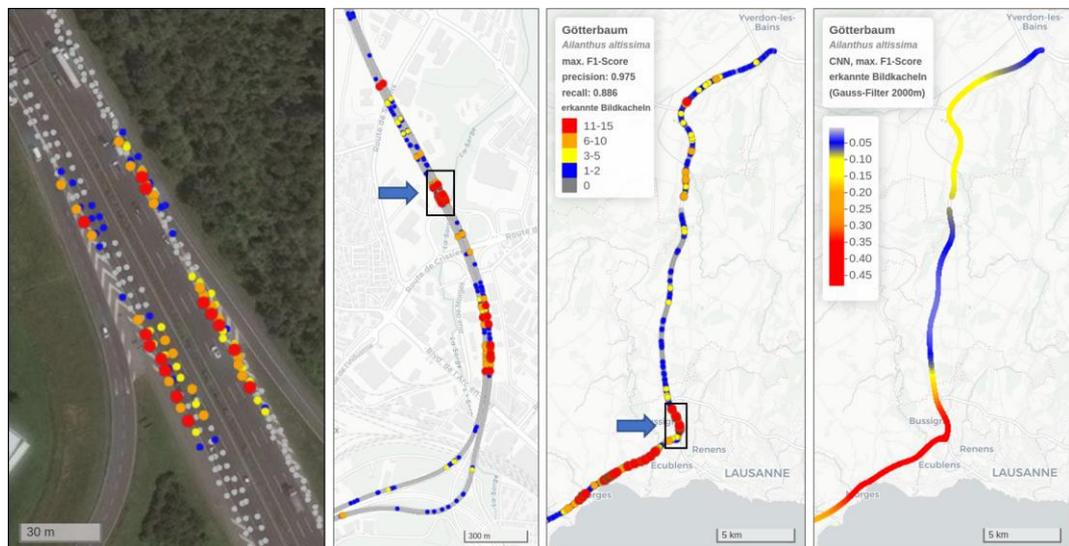


Abb. 22 Beispiele für die zwei unterschiedlichen Kartendarstellungen anhand erkannter Bildkacheln des Götterbaums zwischen Lausanne und Yverdon. Die linke Karte zeigt Vorkommen auf dem Mittelstreifen aus drei Befahrungen, die übereinstimmend aus beiden Fahrtrichtungen erfasst wurden. Die ersten drei Karten zeigen die Anzahl erkannter Bildkacheln koordinatengenau (Fahrzeugpositionen), wobei kleine Rechtecke den Ausschnitt der jeweils vorhergehenden Karte markieren. Die vierte Karte zeigt die mit einem Gauss-Filter geglättete Anzahl erkannter Bildkacheln.

Die folgenden Verbreitungskarten beruhen auf der Maximierung des F1-Scores für die Überführung der CNN-Wahrscheinlichkeiten in Vorkommen und Nicht-Vorkommen der Arten. Da dies einen Kompromiss zwischen Precision und Recall darstellt, muss berücksichtigt werden, dass die Karten auch Fehlklassifikationen enthalten. Dies gilt insbesondere für Bilder mit nur wenigen erkannten Bildkacheln (vgl. Kap. 4.5). In Anhang I stehen daher auch Karten mit Frame-basiertem Schwellenwert und der Arterkennung ab drei erkannten Bildkacheln zur Verfügung. Die Rate irrtümlich erkannter Artvorkommen ist in diesen Karten geringer, die Rate übersehener Vorkommen jedoch höher.

Durch die gewählte technische Umsetzung können die Karten in einem Web-Browser als einzelne (self-contained) HTML-Dateien geöffnet und interaktiv betrachtet werden. Entsprechende Download-Links sind im Text und in den Bildunterschriften zu den koordinatengenauen Karten des Götterbaums und des Schmalblättrigen Greiskrauts angegeben. Weitere Karten-Downloads stehen in Anhang I zur Verfügung. Im Browser können die Karten in unterschiedlichen Zoomstufen, mit unterschiedlichen Kartenhintergründen und getrennt für Vorkommen auf Mittel- oder Seitenstreifen angezeigt werden.

5.3 Verbreitungskarte des Götterbaums

Abbildung 23 zeigt die koordinatengenaue Darstellung der erkannten Bildkacheln des Götterbaums ([Link](#) zum Download der interaktiven Karte). Es fällt auf, dass die Art inzwischen an Autobahnen des gesamten Mittellands anzutreffen ist. Der Schwerpunkt der Vorkommen liegt jedoch an der A1 zwischen Lausanne und Genf. Dies wird noch deutlicher, wenn die durchschnittliche Anzahl erkannter Bildkacheln für längere Autobahnabschnitte betrachtet wird (Abb. 24). Ausserhalb der Region Genfersee kommen hohe Werte nur noch in der Umgebung von Zürich vor. An den übrigen Autobahnen des Mittellands tritt der Götterbaum dagegen noch lückig mit kleinräumigen Vorkommen auf.

Basierend auf der Maximierung des F1-Scores, beträgt die Precision des verwendeten CNNs 0.975, d.h. 97.5% der auf den Testbildern erkannten Bildkacheln stimmten mit den Angaben des Experten überein. Dabei wurden 89% der auf den Textbildern vom Experten als Vorkommen markierten Kacheln vom CNN erkannt (Recall 0.886). Die Verbreitungskarte in Anhang I mit einer konservativeren Arterkennung stimmt gut mit den Karten der Abbildungen 23 und 24 überein.

5.4 Verbreitungskarte des Schmalblättrigen Greiskrauts

Die Karte der erkannten Bildkacheln des Schmalblättrigen Greiskrauts ist in Abbildung 25 wiedergegeben ([Link](#) zum Download der interaktiven Karte). Im Vergleich zum Götterbaum ist das Greiskraut deutlich häufiger anzutreffen. Grosse und zusammenhängende Bestände kommen entlang aller untersuchten Autobahnen vor. Die Art wurde wiederum besonders häufig zwischen Lausanne und Genf erkannt (Abb. 26).

Das CNN weist eine ähnliche Güte wie beim Götterbaum auf – mit einer Precision von 0.977 und einem Recall von 0.875. Auch hier bestätigt die konservative Kartendarstellung in Anhang I die erfassten Verbreitungsmuster.

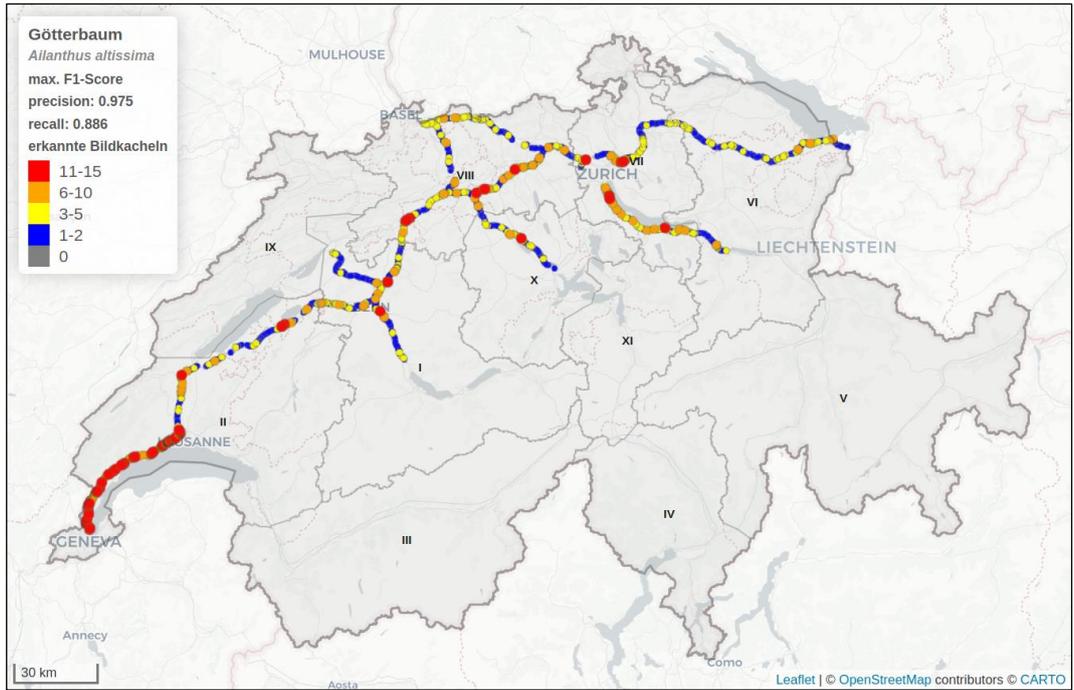


Abb. 23 Verbreitungskarte des Götterbaums mit der Anzahl der vom CNN erkannten Bildkacheln je Bild-Koordinate ([Link](#) zum Karten-Download für die interaktive Darstellung im Web-Browser). Der Schwellenwert für die Arterkennung basiert auf der Maximierung des F1-Scores. Römische Zahlen bezeichnen die Gebietseinheiten der Nationalstrassen.

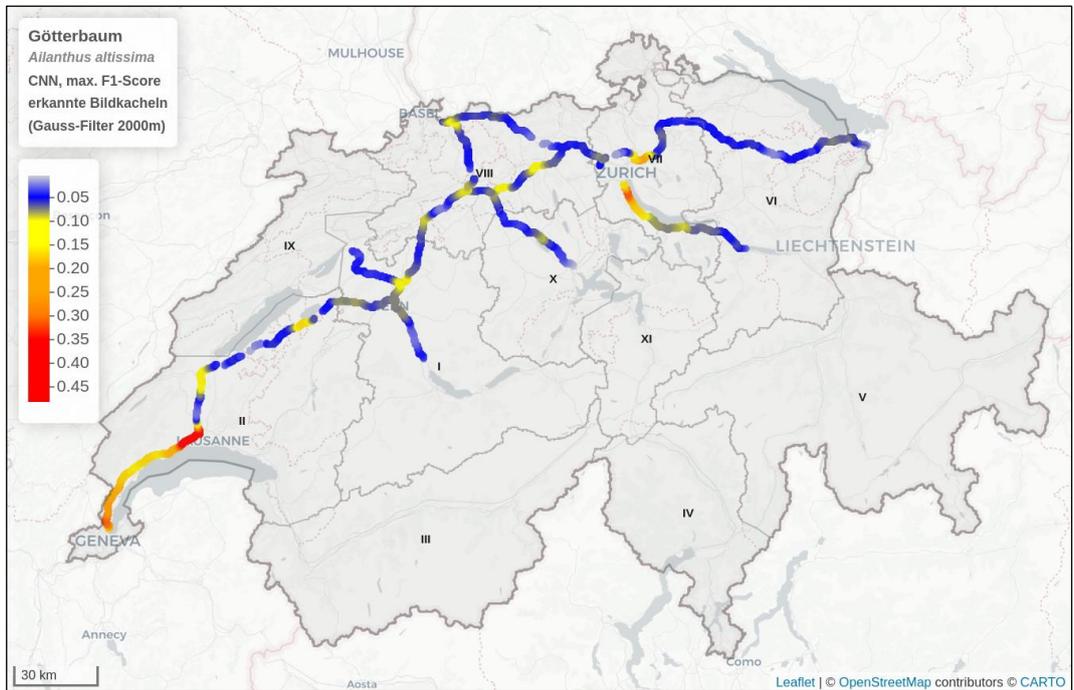


Abb. 24 Verbreitungskarte des Götterbaums mit der durchschnittlichen Anzahl erkannter Bildkacheln nach Anwendung eines Gauss-Filters ($\sigma = 2000$ m). Römische Zahlen bezeichnen die Gebietseinheiten der Nationalstrassen.

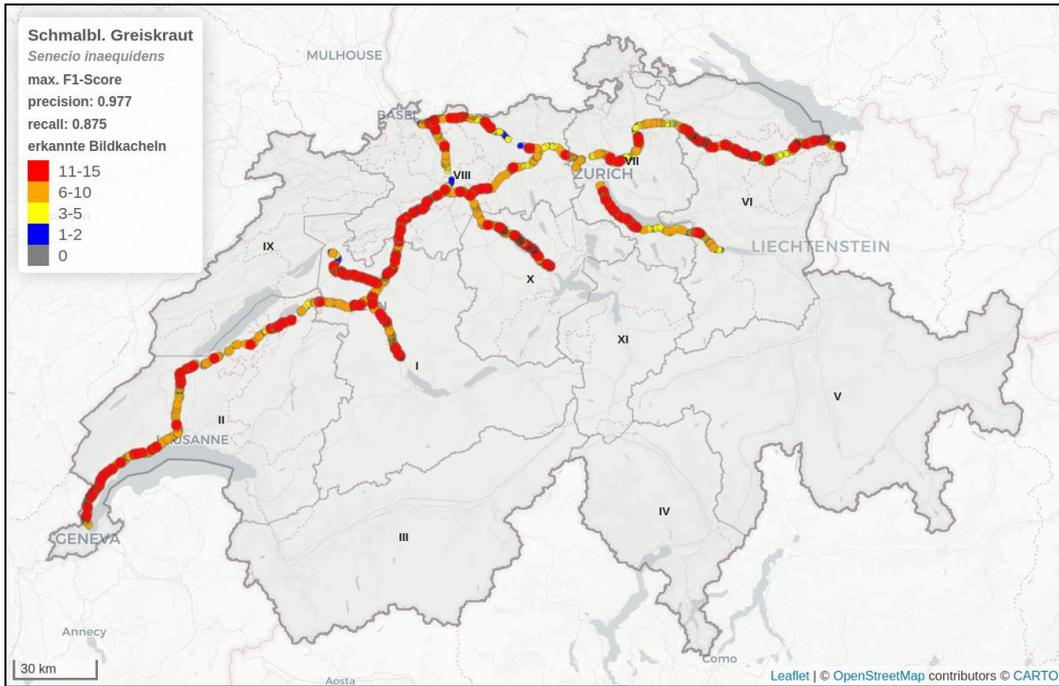


Abb. 25 Verbreitungskarte des Schmalblättrigen Greiskrauts mit der Anzahl der vom CNN erkannten Bildkacheln je Bild-Koordinate ([Link](#) zum Karten-Download für die interaktive Darstellung im Web-Browser). Der Schwellenwert für Vorkommen basiert auf der Maximierung des F1-Scores. Römische Zahlen bezeichnen die Gebietseinheiten der Nationalstrassen.

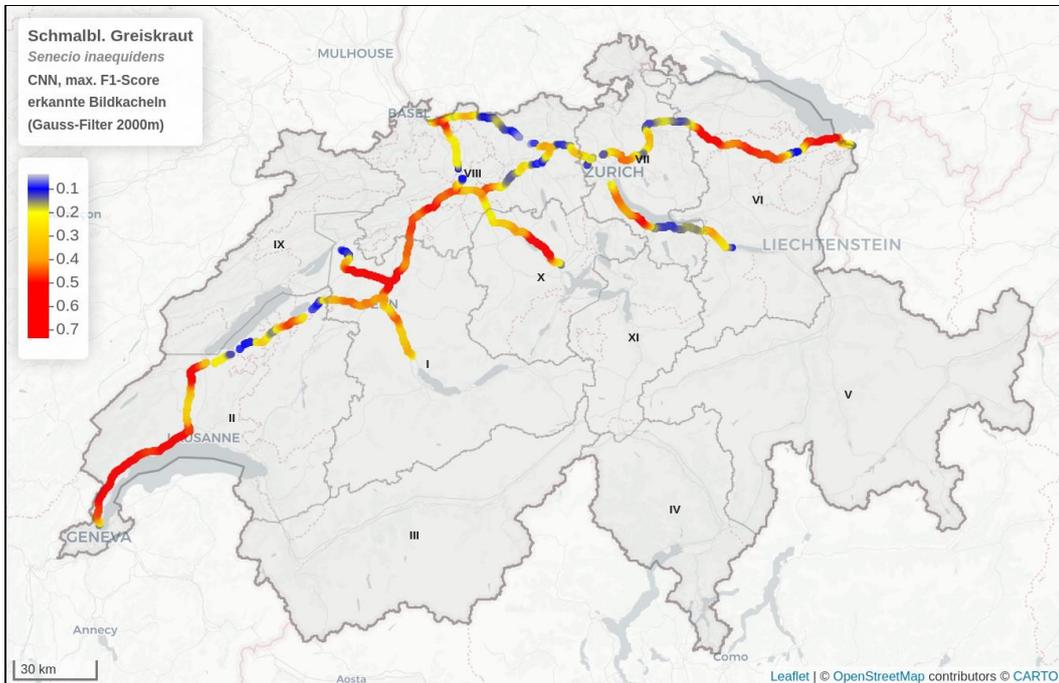


Abb. 26 Verbreitungskarte des Schmalblättrigen Greiskrauts mit der durchschnittlichen Anzahl erkannter Bildkacheln nach Anwendung eines Gauss-Filters ($\sigma = 2000$ m). Römische Zahlen bezeichnen die Gebietseinheiten der Nationalstrassen.

6 Karteninterpretation und Auswertungen

Im folgenden Kapitel wird die Reproduzierbarkeit des automatisierten Kartieransatzes hinterfragt und verschiedene Faktoren untersucht, welche das Vorkommen der beiden invasiven Arten entlang der Autobahnen beeinflussen.

6.1 Reproduzierbarkeit des Kartieransatzes

Die statistische Evaluierung der CNN-Ergebnisse zeigte gute Resultate für die Art-erkennung auf den Bildkacheln beziehungsweise extrahierten Bildern. Dies ist eine notwendige Voraussetzung für eine zuverlässige und reproduzierbare Kartierung, die jedoch noch von anderen Faktoren wie der Aufnahmetechnik beeinflusst wird. Da im Projekt keine zusätzlichen Experten-Kartierung durchgeführt wurde, die als unabhängige Vergleichsdaten dienen könnte, wird im Folgenden die Reproduzierbarkeit des automatisierten Ansatzes anhand von Plausibilitätskriterien und einer extern verfügbaren Verbreitungskarte überprüft.

Bei guter Reproduzierbarkeit ist zu erwarten, dass die erfassten Vorkommen einer Art bei wiederholten Befahrungen desselben Autobahnabschnitts weitgehend übereinstimmen. Da im Projekt Doppelbefahrungen nicht vollständig vermieden werden konnten, standen entsprechende Autobahnabschnitte für den Vergleich zur Verfügung. Abbildung 27 zeigt das lokale Verbreitungsmuster des Schmalblättrigen Greiskrauts auf einem Mittelstreifen der A1 bei Egerkingen. Die Strecke wurde während der Mai-Befahrung im Abstand von einem Tag zweimal befahren. Der Vergleich der erkannten Bildkacheln ergibt eine gute Übereinstimmung der kartierten Vorkommen. Dies gilt besonders für Bilder mit zahlreich erkannten Bildkacheln. Dabei ist die gute Reproduzierbarkeit der Vorkommen auf Mittelstreifen ferner unabhängig von der Fahrtrichtung. Dieser Befund konnte im Projekt genutzt werden, um die Georeferenzierung der Bilder zu überprüfen, da bei korrektem Abgleich zwischen GPS-Signal und Aufnahmezeit für beide Fahrtrichtungen die Lage der Verbreitungsmuster gut übereinstimmen (vgl. linke Karten in Abb. 22).

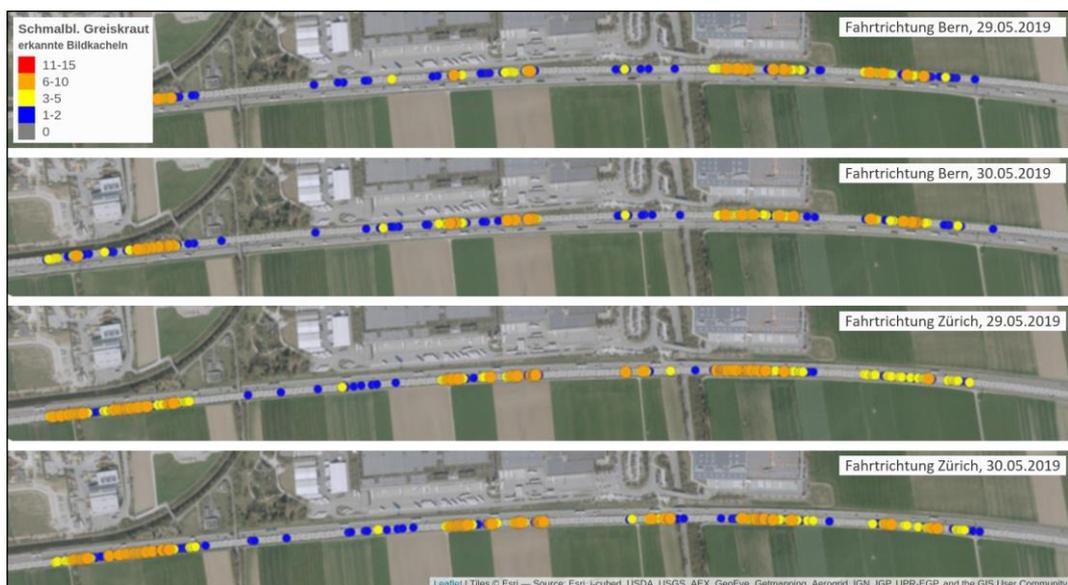


Abb. 27 Erkannte Vorkommen des Schmalblättrigen Greiskrauts auf einem Mittelstreifen der A1 nahe Egerkingen an unterschiedlichen Aufnahmetagen sowie bei Erfassung aus unterschiedlichen Fahrtrichtungen.



Abb. 28 Erkannte Vorkommen des Götterbaums auf einem Mittelstreifen der A3 bei Kilchberg während der Mai-, August- und Oktober-Befahrung.

Wie bei Doppelbefahrungen können für die Bewertung der Reproduzierbarkeit auch die Kartierergebnisse der Mai-, August- und Oktober-Befahrung verglichen werden. Abbildung 28 zeigt dies für den Götterbaum auf einem Mittelstreifen der A3 bei Kilchberg nahe Zürich. Auch hier ist eine gute Übereinstimmung festzustellen, die erwartungsgemäss jedoch geringer ist als bei einer zeitnahen Doppelbefahrung. Die Abnahme der erkannten Bildkacheln im Jahresverlauf ist hier durch Grünpflege bedingt. Der Vergleich zeigt zudem, dass Bilder mit nur wenigen erkannten Bildkacheln neben wahrscheinlichen Fehlklassifikationen, die isoliert nur bei einer Befahrung erkannt wurden, offensichtlich auch korrekt erfasste Vorkommen zeigen, da in ihrem Bereich während anderen Befahrungen Bilder mit zahlreich erkannten Bildkacheln auftraten.

Abbildung 29 zeigt schliesslich einen direkten Vergleich der automatisierten Kartierung mit einer unabhängigen Verbreitungskarte. Im Auftrag des ASTRA (Abteilung Strasseninfrastruktur Ost) wurden 2014 von der FORNAT AG das Schmalblättrige Greiskraut auf verschiedenen Autobahnabschnitten um Zürich kartiert [72]. Der Vergleich mit den automatisiert erkannten Bildkacheln ergibt erneut eine gute Übereinstimmung, auch wenn hier zwischen den Kartierungen fünf Jahre liegen. Zwischenzeitlich scheint sich die Art weiter ausgebreitet zu haben und besiedelt auch eine grössere Lücke aus dem Jahr 2014. Allerdings ist unklar, ob bei Bildern mit nur einer oder zwei erkannten Bildkacheln Fehlklassifikationen vorliegen. Das räumliche Muster der Bilder mit drei oder mehr erkannten Bildkacheln stimmt dagegen gut mit der unabhängigen Vergleichskarten überein.

Insgesamt belegen die Vergleiche eine gute Reproduzierbarkeit des automatisierten Kartieransatzes. Dies gilt besonders für Bilder mit mehreren erkannten Bildkacheln.

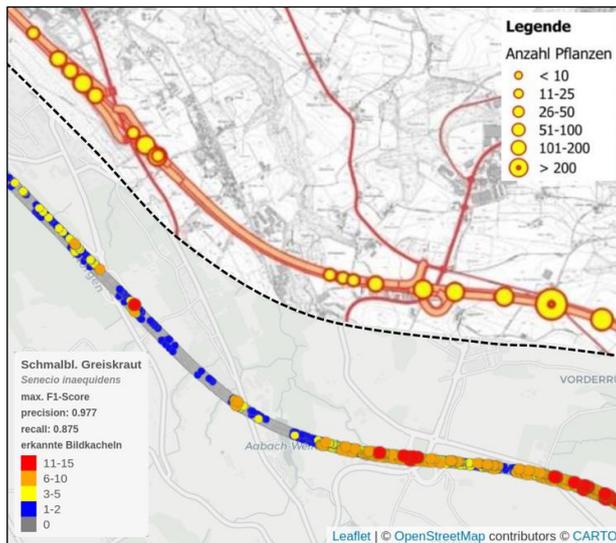


Abb. 29 Vergleich der automatisierten Kartierung des Schmalblättrigen Greiskrauts auf einem Mittelstreifen der A3 bei Horgen (untere Darstellung; Ergebnisse aus drei Befahrungen) mit einer klassischen Kartierung durch die FORNAT AG aus dem Jahr 2014 (oberer Kartenausschnitt).

6.2 Einfluss baulicher Unterschiede

Bei der Sichtung der Verbreitungsmuster fielen immer wieder scharfe Grenzen zwischen Autobahnabschnitten mit zahlreich erkannten Vorkommen und solchen mit weitgehendem Fehlen der Arten auf. Diese Muster konnten meist direkt mit baulichen Unterschieden erklärt werden.

Abbildung 30 zeigt als Beispiel ein deutlich abgegrenztes Vorkommen des Schmalblättrigen Greiskrauts auf einem Mittelstreifen an der A6 bei Heimberg nahe Thun. Im Luftbild wird deutlich, dass dieses Muster mit dem Vorhandensein eines grünen Mittelstreifens zusammenfällt. Der direkte Zusammenhang scheint sich hier auch auf die Vorkommen auf dem Seitenstreifen auszuwirken, da die Art dort nur im Bereich des grünen Mittelstreifens zahlreich erkannt wurde (nicht dargestellt; vgl. interaktive Karte, [Link](#)).



Abb. 30 Ein scharf abgegrenztes Vorkommen des Schmalblättrigen Greiskrauts auf dem Mittelstreifen der A6 nahe Thun, das mit dem Vorhandensein eines grünen Mittelstreifens zusammenfällt (rechte Darstellung).

Ein weiteres Beispiel für den Einfluss des grünen Mittelstreifens zeigt Abbildung 31 für die A1 an der Grenze zwischen den Gebietseinheiten VI und VII. Auch hier zeichnet sich für das Schmalblättrige Greiskraut ein deutliches Muster ab, indem zahlreiche erkannte Vorkommen des Mittelstreifens abrupt zusammen mit dem grünen Mittelstreifen enden (untere Karte). Allerdings ergibt sich zwischen den Gebietseinheiten auch ein klarer Unterschied für Vorkommen des Greiskrauts auf den Seitenstreifen (obere Karte). Dies ist als Resultat der Kombination von geringerem Samendruck dank fehlendem grünen Mittelstreifen und regelmässiger Bekämpfung durch Ausreissen zusätzlich zum Mähen durch die GE VII [73] zu werten.

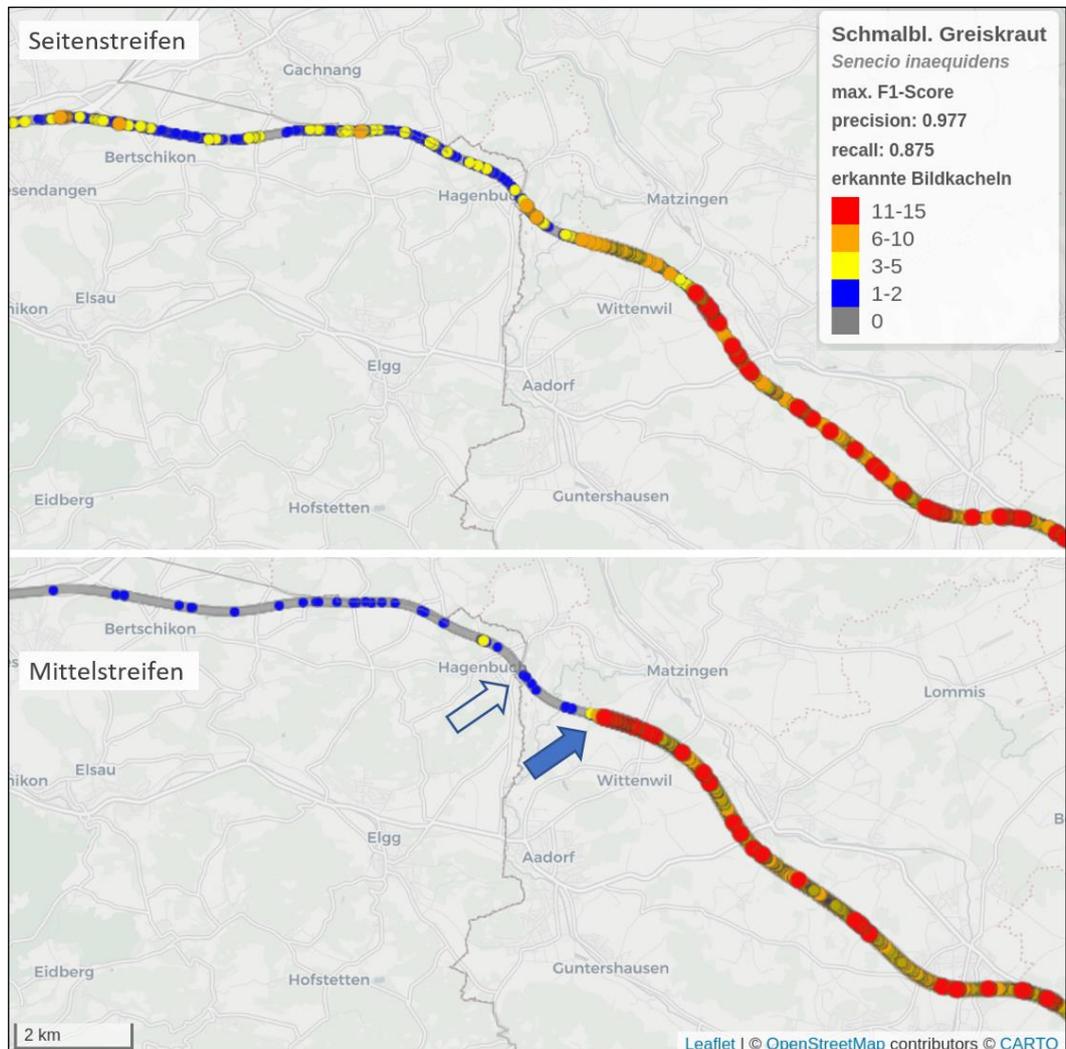


Abb. 31 Vorkommen des Schmalblättrigen Greiskrauts auf der A1 an der Grenze der Gebietseinheiten VI und VII (nicht ausgefüllter Pfeil), das mit dem Vorhandensein eines grünen Mittelstreifens zusammenfällt (endet aus Richtung St. Gallen beim ausgefüllten Pfeil). Dargestellt sind die Resultate aus allen drei Befahrungen getrennt für Seitenstreifen (oben) und Mittelstreifen (unten).

Räumlich deutlich abgegrenzte Verbreitungsmuster waren auch auf Seitenstreifen festzustellen. Abbildung 32 zeigt die Verbreitung des Schmalblättrigen Greiskrauts auf einem Seitenstreifen der A1 bei St. Margrethen. Das Vorkommen fällt hier mit einer Grünböschung zusammen, die von Schallschutzwänden flankiert wird. Ältere Aufnahmen in Google Street View zeigen, dass Schutzwände und Leitplanke in diesem Bereich in jüngerer Zeit erneuert wurden. Durch diese Störung wurde das Greiskraut offenbar gefördert, da es nach Überprüfung des Filmmaterials in der noch lückigen Vegetation zahlreich vorkam. Die Zunahme des Schmalblättrigen Greiskraut an Autobahnen im Bereich von Baustellen wird durch Untersuchungen der FORNAT AG bestätigt [73].

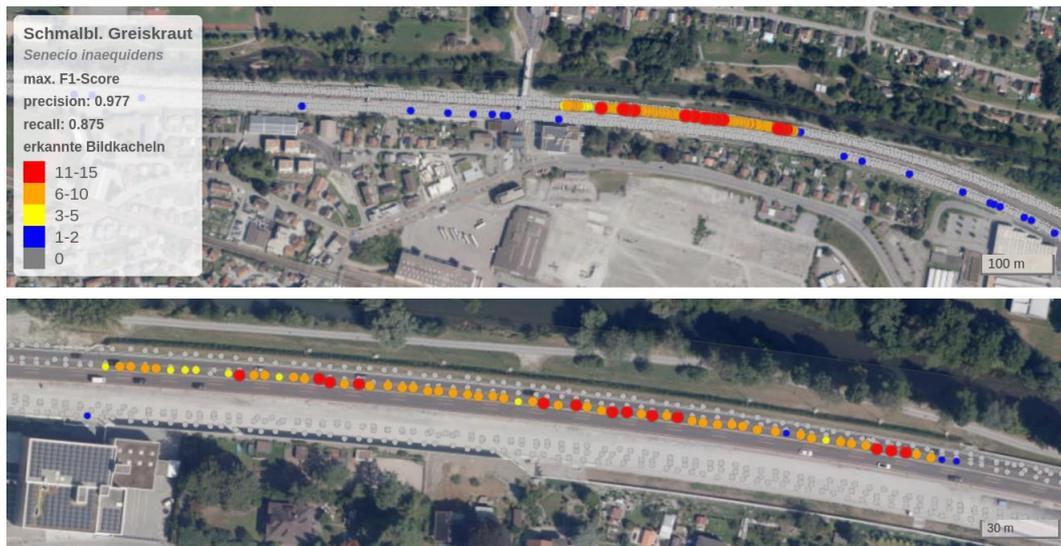


Abb. 32 Ein grösseres Vorkommen des Schmalblättrigen Greiskrauts während der August-Befahrung an einem Seitenstreifen der A1 bei St. Margrethen in Fahrtrichtung St. Gallen.

6.3 Veränderungen zwischen den Befahrungen

Neben baulichen Gegebenheiten gibt es weitere Faktoren, welche die Häufigkeit der erkannten Vorkommen beeinflussen. Für Unterschiede zwischen den Befahrungen sind vor allem Veränderungen in der Entwicklung der Arten (Phänologie) und die Grünpflege durch Mahd und Gehölzschnitt zu nennen. Abbildung 33 zeigt die Unterschiede in der relativen Häufigkeit der erkannten Bildkacheln für Götterbaum und Greiskraut getrennt nach Gebietseinheiten und Befahrungen. Zunächst fällt auf, dass beide Arten in den Gebietseinheiten unterschiedlich häufig auftreten. Der Götterbaum wurde mit Abstand am häufigsten in der Gebietseinheit II erkannt, gefolgt von der Gebietseinheit VII, während er in den übrigen Einheiten deutlich seltener erfasst wurde. Auch das Schmalblättrige Greiskraut zeigt in der Gebietseinheit II über das gesamte Jahre betrachtet die höchste relative Häufigkeit erkannter Bildkacheln, während es in den Gebietseinheiten VII und VIII in deutlich geringerer Dichte erfasst wurde.

Bei Betrachtung der Unterschiede zwischen den Befahrungen nimmt die Anzahl erkannter Bildkacheln zwischen der Mai- und August-Befahrung für beide Arten in sämtlichen Gebietseinheiten zunächst zu. Dies kann mit der Entwicklung und dem Wachstum der Arten bei nicht überall zeitnah erfolgter Grünpflege erklärt werden. Beim Götterbaum fällt jedoch die geringe Zunahme in der Gebietseinheit VII auf. Sie deckt sich mit der Beobachtung, dass hier das grösste Vorkommen auf einem Mittelstreifen der A3 südlich von Zürich bereits durch Unterhaltsmassnahmen während der August-Befahrung deutlich reduziert war. Zwischen der August- und Oktober-Befahrung ist beim Götterbaum in allen Gebietseinheiten dann ein deutlicher Rückgang der erkannten Bildkacheln festzustellen, was durch fortgesetzte Grünpflege bei reduziertem Wachstum der Art erklärt werden kann.

Die Veränderungen beim Schmalblättrigen Greiskraut sind zunächst ähnlich. Auch hier steigt die relative Häufigkeit erkannter Bildkacheln zwischen der Mai- und August-Befahrung zunächst deutlich an und ist mit dem Aufwachsen der Art in Verbindung zu bringen. Stärker als diese Zunahme der Arterkennungen ist noch die Zunahme bei der Häufigkeit der Bildkacheln mit blühenden Exemplaren, da das Greiskraut im Mai zunächst nur vereinzelt blühte. Wie beim Götterbaum nimmt die Häufigkeit erkannter Vorkommen des Greiskraut zur Oktober-Befahrung hin wieder ab und dürfte auch hier die durchgeführte Grünpflege widerspiegeln. Es gibt jedoch eine Ausnahme: In der Gebietseinheit II nimmt

die Häufigkeit des Greiskraut im Gegensatz zu allen anderen Gebietseinheiten leicht zu. Ein noch stärkerer Anstieg ist für den Anteil blühender Pflanzen festzustellen. Dies lässt darauf schliessen, dass die Bestände des Schmalblättrigen Greiskrauts hier zwischen August und Oktober im Vergleich zu den anderen Gebietseinheiten weniger von Grünpflegemassnahmen betroffen waren und so in der Gebietseinheit II über grössere Strecken ungestört zur Blüte gelangen konnten.

Tatsächlich erklärt sich die hohe Zahl blühende Pflanzen im Oktober in der Gebietseinheit II aus der Tatsache, dass es in 2019 in dieser Gebietseinheit ein Mahd-Moratorium wegen der Kartierung von Biodiversitäts-Schwerpunkten gab. Daher ist die Situation nicht typisch, und die Mahd erfolgte erst im November nach der letzten Befahrung. Das Beispiel zeigt eindrücklich, welche Auswirkungen Unterschiede in der Grünpflege auf die Blüte und damit auf die potentielle Samenproduktion sowie weitere Ausbreitung dieser invasiven Art in die umliegende Landschaft haben können.

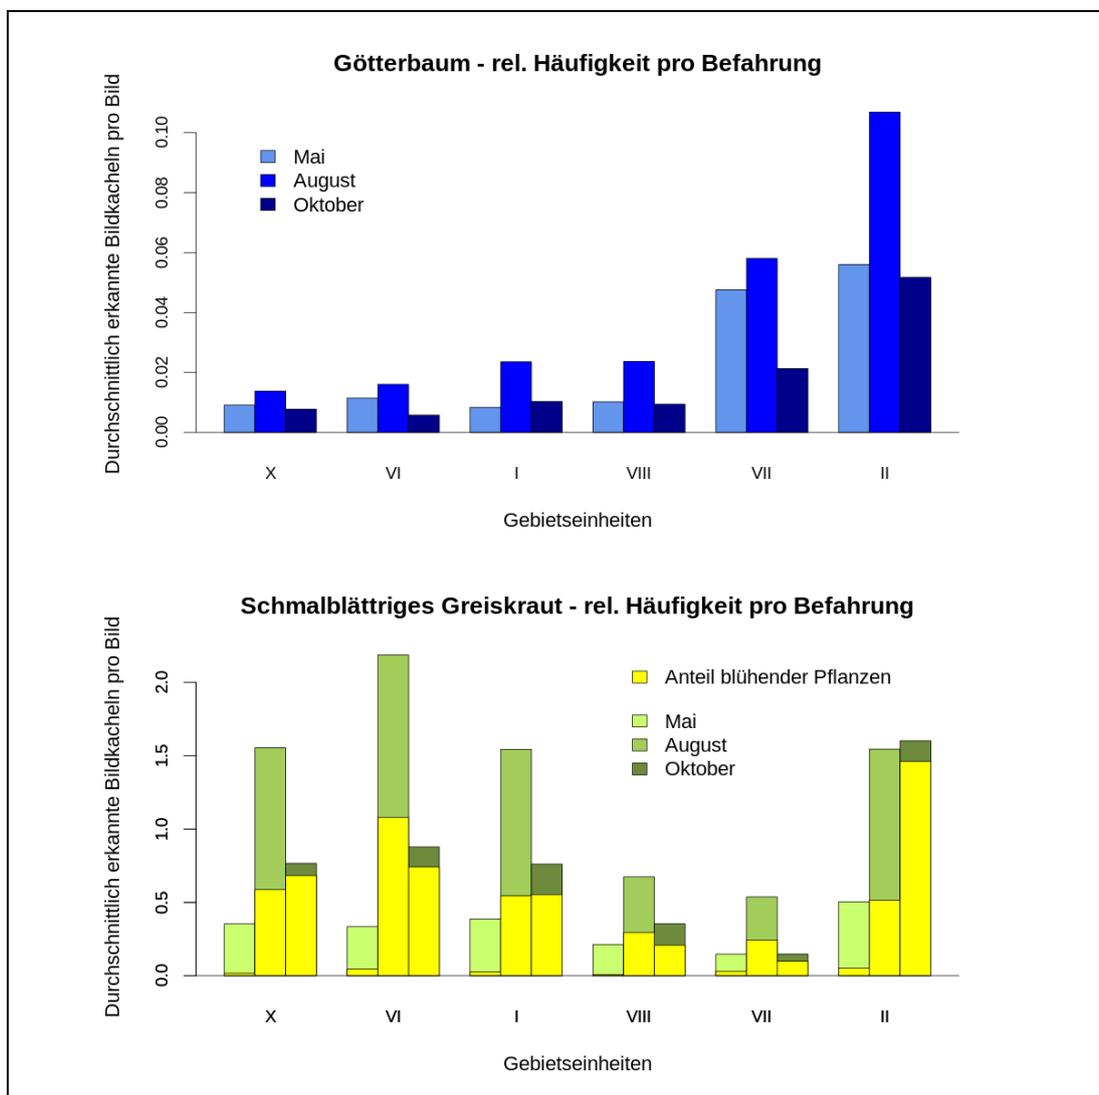


Abb. 33 Relative Häufigkeit erkannter Bildkacheln des Götterbaums und Schmalblättrigen Greiskrauts getrennt nach Gebietseinheiten und Befahrungen. Für das Greiskraut ist ferner der Anteil blühender Vorkommen dargestellt. Die Gebietseinheiten sind in beiden Darstellungen nach zunehmender Häufigkeit des Götterbaums sortiert.

Umgekehrt stimmt auch die allgemein besonders niedrige Häufigkeit des Greiskrauts in der Gebietseinheit VII mit besonderen Massnahmen überein [73]. In der Gebietseinheit erfolgt seit 2015 ein speziell auf das Schmalblättrige Greiskraut abgestimmter dritter «Neophytenchnitt». Die zunächst für Mittelstreifen vorgesehene Massnahme wurde seither auch auf belastete Böschungen ausgeweitet. Zusätzlich wird die Art durch Ausreissen in Abschnitten ohne grünen Mittelstreifen oder in neu angelegten Flächen bei Baustellen bekämpft.

Die räumliche Verteilung der Zu- und Abnahmen in der Häufigkeit blühender Vorkommen des Schmalblättrigen Greiskrauts zwischen der August- und Oktober-Befahrung ist in Abbildung 34 dargestellt. Sie zeigt die deutliche Zunahme blühende Exemplare im Gebiet des Genfersees, während im Zentralen und Östlichen Mittelland die Abnahme blühender Greiskraut-Vorkommen überwiegt. Die in der Karte zu erkennenden Unterschieden dürften direkte mit Häufigkeit und Zeitpunkt der letzten Grünpflege in Verbindung stehen.

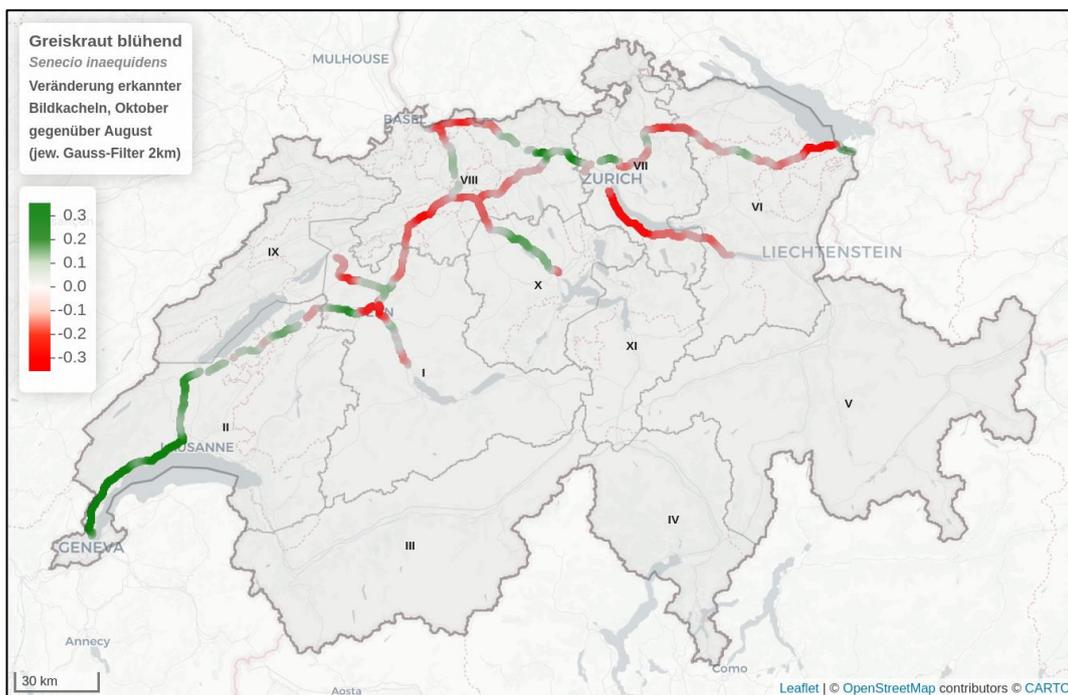


Abb. 34 Zu- und Abnahmen in der Häufigkeit erkannter Bildkacheln mit blühendem Schmalblättrigem Greiskraut zwischen der August- und Oktober-Befahrung. Die Darstellung beruht auf den Veränderungen der durchschnittlichen Häufigkeit, wie sie in Kapitel 5.4 beschrieben wurde (Rasterung der maximalen Werte in einer Auflösung von 100 Metern mit anschliessender Anwendung eines Gauss-Filters mit $\sigma = 2000$ m).

6.3.1 Einfluss der Siedlungsfläche

Siedlungsflächen begünstigen allgemein das Auftreten von Neophyten [74,75]. Das trifft auch für Neophyten entlang von Strassen zu [9]. Im Folgenden wird daher der Einfluss der Siedlungsfläche auf die erkannten Vorkommen von Götterbaum und Schmalblättrigem Greiskraut untersucht. Abbildung 35 zeigt eine Karte der verwendeten Umweltdaten. Es handelt sich um Angaben zur Bodenversiegelung, die landesweit in einer Auflösung von 20 Metern vorliegen (Pan-European Copernicus Land Monitoring Services, www.copernicus.eu, 2009). Für die Beschreibung der Umgebung der ausgewerteten Bilder wurde den Bild-Koordinaten der durchschnittliche Versiegelungsgrad im Umkreis von

einem Kilometer zugeordnet. Dabei sind niedrige Versiegelungsgrade des ländlichen Raums viel häufiger anzutreffen als hohe Werte im industriell-urbanen Umfeld (Histogramm in Abb. 35).

Die Bodenversiegelung in der Umgebung der automatisch erkannten Artvorkommen ist in Abbildung 36 in Abhängigkeit von der Anzahl erkannter Bildkacheln dargestellt. Die beiden untersuchten Arten zeigen dabei unterschiedliche Muster. Während beim Schmalblättrigen Greiskraut die Bodenversiegelung bei zunehmender Anzahl erkannter Bildkacheln eher abnimmt, treten beim Götterbaum Bilder mit zahlreich erkannten Bildkacheln in Gebieten mit deutlich erhöhter Bodenversiegelung auf. Der unterschiedliche Befund lässt Rückschlüsse auf die Besiedlung der Autobahnen im Schweizer Mittelland zu. Beim Schmalblättrige Greiskraut ist davon auszugehen, dass die Art sich selbständig über grössere Strecken und auch über die Landesgrenzen hinweg im Mittelland ausgebreitet hat. Eine engere Beziehung zu Ballungsräumen und Siedlungsflächen im Mittelland als Ursprungsgebiet scheint nicht zu bestehen. Für die Stadt Zürich ist dies auch widerlegt, da das Schmalblättrige Greiskraut zunächst auf Eisenbahnarealen und an Autobahnen auftrat und sich erst später in der Stadt ausbreitete [51,52]. Ganz anders beim Götterbaum, der als Strassen- und Stadtbaum seit langem im industriell-urbanen Umfeld gepflanzt wurde. In Städten und Siedlungsflächen des Mittellands existieren daher zahlreiche Altbäume als Samenquellen. An Autobahnen zeigen daher grössere Vorkommen mit zahlreich erkannten Bildkacheln eine auffällige Nähe zu Siedlungsflächen, von denen die Besiedlung der Autobahnen ausgegangen sein dürfte. Die eigenständige Vermehrung und Ausbreitung entlang der Autobahnen dürfte beim Götterbaum im Gegensatz zum Greiskraut nur gering ausgeprägt sein, da Autobahnvorkommen wegen des regelmässigen Gehölzschnitts kaum oder keine Samen produzieren. Das gilt besonders für die zahlreicheren Bestände auf Mittelstreifen.

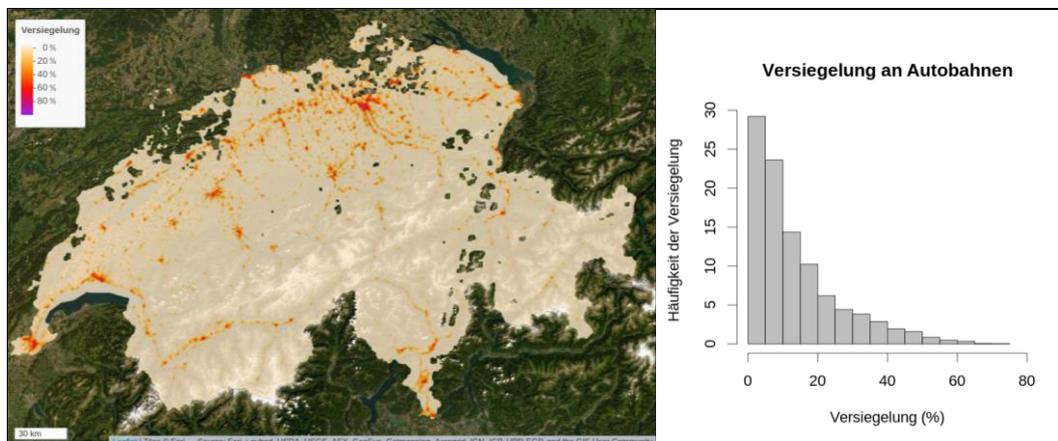


Abb. 35 Daten zur landesweiten Bodenversiegelung, die zur Auswertung der erkannten Artvorkommen verwendet wurden. Rechts ist die Häufigkeitsverteilung der Bodenversiegelung in der 1-Kilometer-Umgebung der Bild-Koordinaten dargestellt. Für Lücken in der Karte fehlen Angaben, da dort wegen Wolkenabdeckung keine Werte durch Fernerkundung ermittelt werden konnten. Datenquelle: European Copernicus Land Monitoring Services, www.copernicus.eu, 2009.

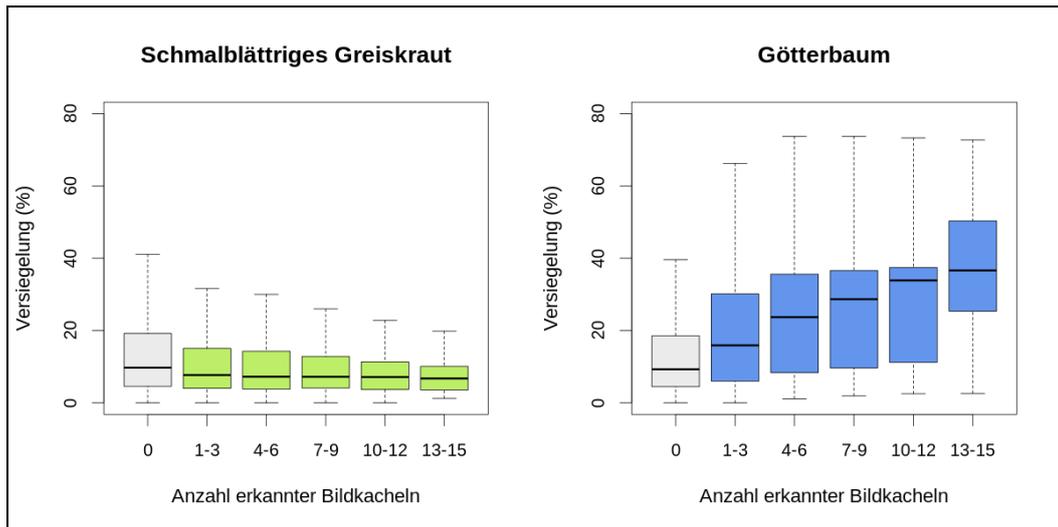


Abb. 36 Verteilung der Bodenversiegelung in der 1-Kilometer-Umgebung der Bild-Koordinaten in Abhängigkeit von der Anzahl erkannter Bildkacheln für Greiskraut und Götterbaum. Darstellung als Box-and-whisker-plots (vgl. Abb. 15, ohne Extremwerte).

7 Folgerungen und Anwendung der Ergebnisse

Die Bewertung des verwendeten Kartieransatzes hängt in erster Linie von der Güte des trainierten neuronalen Netzes bei der Arterkennung ab. Diese ist mit einer Precision von 97.5% für den Götterbaum beziehungsweise 97.7% für das Schmalblättrige Greiskraut bei einem Recall von jeweils knapp 90% hoch. Die Werte liegen im Bereich oder übertreffen aktuell publizierte Angaben zur automatisierten Arterkennung bei Gefässpflanzen [32]. Dabei ist zu berücksichtigen, dass die verwendeten Bilder hinsichtlich Aufnahmetechnik und Bildinhalten stärker standardisiert sind als dies bei Anwendungen wie iNaturalist oder Methodenvergleichen wie PlantCLEF (www.imageclef.org) der Fall ist. Die bereits hohe Genauigkeit der Arterkennung konnte im Projekt noch erhöht werden, wenn nur Bilder mit mehrfach erkannten Bildkacheln als Vorkommen gewertet wurden (Kapitel 4.5 und Anhang I), wodurch der Anteil irrtümlich erkannter Vorkommen (False Positives) reduziert wird. Der Effekt ist jedoch nicht in jedem Fall erwünscht, da dabei auch die Wahrscheinlichkeit steigt, vorhandene Vorkommen zu übersehen (False Negatives). Dies kann bei der Früherkennung invasiver Arten problematisch sein. Je nach Anwendung und Fragestellung können daher mit dem Ansatz für Precision oder Recall optimierte Karten erstellt werden.

Die detaillierten Verbreitungskarten des Projekts stehen den Gebietseinheiten als Entscheidungshilfen beim Umgang mit invasiven Neophyten zur Verfügung. Für den Götterbaum können sie verwendet werden, um die weitere Ausbreitung der Art in Streckenabschnitten mit bisher nur kleineren Vorkommen durch gezielte Gegenmassnahmen zu verhindern. Für eine differenzierte Grünpflege liefern die Karten zudem die Lage besonders stark betroffener Streckenabschnitte und Angaben zu grösseren Beständen – beispielsweise im Bereich von Signalisationen. Da der Götterbaum an Autobahnen durch den regelmässigen Gehölzschnitt praktisch keine Samen bildet und sich meist nur lokal durch Wurzelbrut ausbreitet, ist davon auszugehen, dass neue Vorkommen an Autobahnen vom Sameneintrag aus der umgebenden Landschaft abhängen. Dabei kommt Samenbäumen im Siedlungsbereich als Eintragsquelle und dem Verschleppen der Samen durch Fahrzeuge offenbar eine grosse Bedeutung zu.

Beim Schmalblättrigen Greiskraut hat die Kartierung gezeigt, dass die Art im Gegensatz zum Götterbaum bereits weit verbreitet ist. Es gibt jedoch Unterschiede in der Häufigkeit, und lokal können stark betroffene mit kaum besiedelten Abschnitten abwechseln. Die Kartierung liefert den Gebietseinheiten so Informationen zu aktuell besonders grossen Vorkommen, bei denen durch eine angepasste Grünpflege – beispielsweise durch zusätzliche Mahd [76] – der Samendruck in die Landschaft und die Ausbreitung auf angrenzende Flächen (Abb. 37) wirkungsvoll vermindert werden kann. Der Vergleich der Mai-, August- und Oktober-Befahrungen lieferte ferner Anhaltspunkte, dass bereits heute eine unterschiedliche Grünpflege der Gebietseinheiten das Vorkommen des Schmalblättrigen Greiskrauts beeinflusst. Dies gilt besonders für den Anteil blühender Pflanzen, der als Mass für den potenziellen Samendruck in die angrenzende Landschaft dienen kann. Der Kartieransatz mit der Unterscheidung von nicht-blühendem und blühendes Greiskraut kann daher auch für eine Erfolgskontrolle angepasster Unterhaltmassnahmen verwendet werden.

Im Projekt wurden lediglich zwei invasive Neophyten erfasst, doch lässt sich der Ansatz auf zahlreiche weitere Arten, die im Bildmaterial vom Experten gut erkannt werden konnten, ausdehnen (z.B. Staudenköcherich, *Reynoutria japonica* aggr.; Nordamerikanische Goldruten, *Solidago canadensis* aggr.; Sommerlieder, *Buddleja davidii*). Dies ist aber nicht für sämtliche Arten möglich, da das Verfahren bei unscheinbaren oder schwierig zu unterscheidenden Arten an seine Grenzen stösst. Auch können gut erkennbare Arten zu selten sein, um eine ausreichende Anzahl an Trainingsbildern generieren zu können. Ein Beispiel ist die Ambrosie (*Ambrosia artemisiifolia*), die im Bildmaterial zwar erkannt wurde, für die jedoch wegen ihrer Seltenheit weitere Bildquellen für Trainingsbilder genutzt werden müssten (s. Anhang II.1). Die bereits trainierten Netze können auch als Ausgangspunkt für weitere Erhebungen dienen – sei es für eine erneute Kartierung derselben Streckenabschnitte im Sinne eines Monitorings oder für die Erfassung entlang neuer Strassen. Dabei sollten jedoch erneut Testbilder vom Experten markiert werden, um die Güte der

Netze für das neue Bildmaterial zu überprüfen und bei Bedarf durch weitere Trainingsbilder die Arterkennung zu verbessern.

Zusammenfassend kann festgehalten werden, dass sich der auf Deep Learning basierende Kartieransatz bewährt hat. Er lieferte durch die automatisierte Arterkennung in ca. 1.35 Millionen georeferenzierten Bildern und rund 20.24 Millionen Bildkacheln gut reproduzierbare, detailreiche Verbreitungskarten. Diese hätten durch klassische Kartierung nicht mit vertretbarem Aufwand erstellt werden können. Es ist davon auszugehen, dass angesichts der rasanten Entwicklung in den Bereichen künstliche Intelligenz und Kamertechnik entsprechende Ansätze der automatisierten Arterkennung und Kartierung auch in der Praxis rasch an Bedeutung gewinnen werden.



Abb. 37 Vorkommen des Schmalblättrigen Greiskrauts (*Senecio inaequidens*) auf einem Seitenstreifen in Nachbarschaft zu einer Weide.

Anhänge

I	Frame-basierte Verbreitungskarten	59
II	Beobachtungen zu weiteren Arten	61
II.1	Ambrosie (<i>Ambrosia artemisiifolia</i>)	61
II.2	Gefleckter Schierling (<i>Conium maculatum</i>)	61
II.3	<i>Cuscuta</i> -Art auf Schmalblättrigem Greiskraut.....	62

I Frame-basierte Verbreitungskarten

Im Gegensatz zu den Karten in den Kapitel 5.3 und 5.4, die auf der Maximierung des F1-Scores für die Arterkennung in den Bildkacheln basieren und so einen Kompromiss zwischen Precision und Recall darstellen, wurde für die folgenden Karten nur Bilder mit mindestens drei erkannten Bildkacheln als Artvorkommen gewertet und der Schwellenwert dabei für maximale Precision optimiert. Die Karten zeigen daher weniger irrtümlich erkannte Artvorkommen, erfassen jedoch auch nur einen geringeren Anteil der Vorkommen. Die koordinatengenauen Darstellungen stehen wie in den Kapiteln 5.3 und 5.4 als interaktive Karten zur Verfügung (s. Link in der Abbildungsunterschriften).

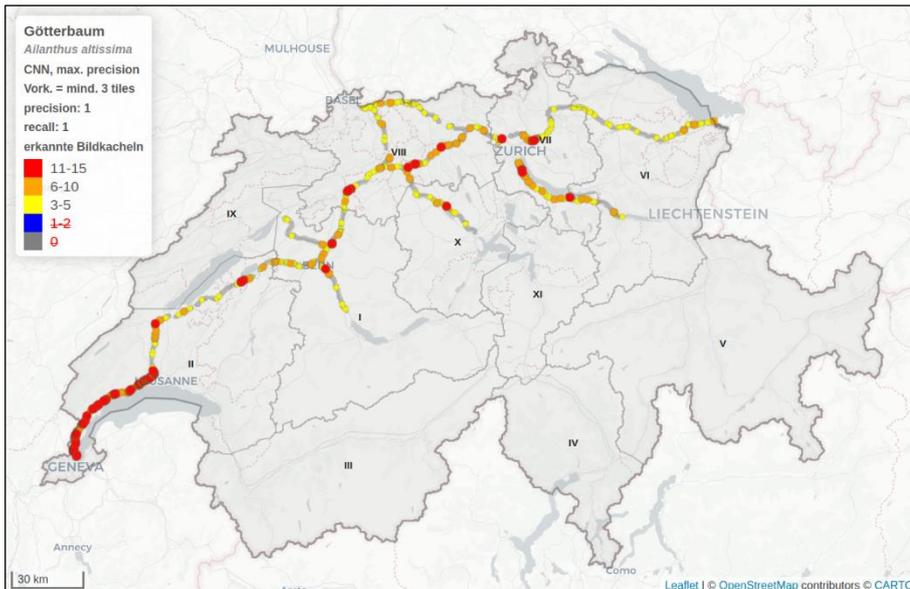


Abb. 38 Verbreitungskarte des Götterbaums mit Frame-basierter Arterkennung ab drei erkannten Bildkacheln und einem für maximale Precision optimierten Schwellenwert. Dargestellt ist die Anzahl erkannter Bildkacheln je Bild-Koordinate ([Link](#) zum Karten-Download für die interaktive Darstellung im Web-Browser).

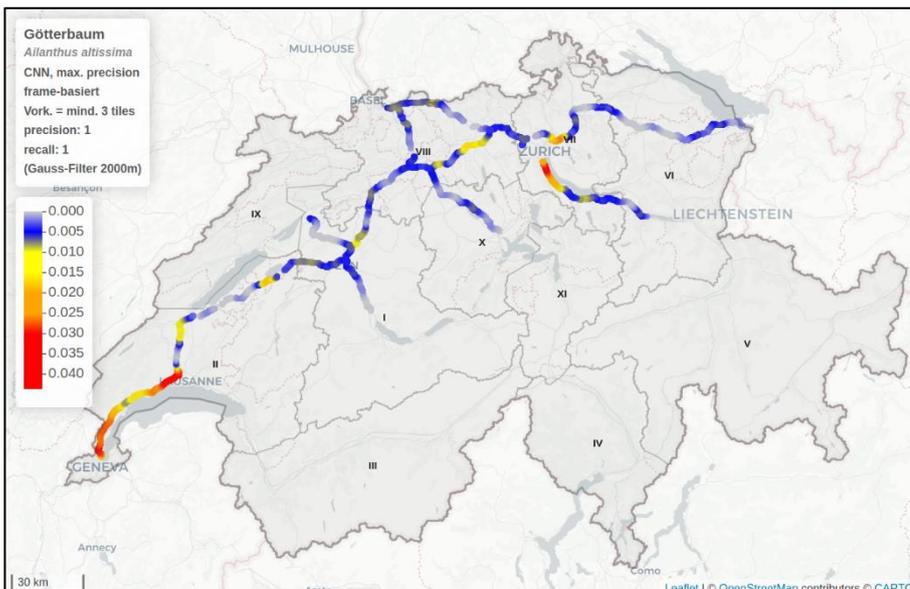


Abb. 39 Verbreitungskarte des Götterbaums mit der durchschnittlichen Anzahl erkannter Bildkacheln aus Abbildung 38 nach Anwendung eines Gauss-Filters ($\sigma = 2000$ m).

II Beobachtungen zu weiteren Arten

Bei der Durchführung des Projekts wurden neben den beiden invasiven Neophyten zahlreiche weitere Pflanzenarten beobachtet, von denen im Folgenden ausgewählte Funde beschrieben werden.

II.1 Ambrosie (*Ambrosia artemisiifolia*)

Die Ambrosie ist ein prioritärer invasiver Neophyt der Schweiz [11,12], der starke Pollenallergien auslösen kann. Die Art wurde im Projekt nicht für die Erfassung ausgewählt, da zunächst unklar war, ob sie im Bildmaterial erkannt werden kann und genügend Vorkommen für Trainings- und Testbilder existieren. Während der Befahrung und beim Markieren der Bilder wurde die Art dann an drei Lokalitäten festgestellt und sicher erkannt. Ein grösserer Bestand im Kanton Zürich wurde der zuständigen kantonalen Stelle (Strickhof) gemeldet. Es ist davon auszugehen, dass ein gut trainiertes CNN die Art im Filmmaterial erkennen kann. Für eine ausreichende Zahl an Trainingsbildern müssten jedoch im Gegensatz zu Schmalblättrigem Greiskraut und Götterbaum andere Bildquellen genutzt werden, da die Art im Filmmaterial des Projekts offenbar zu selten vorkommt. Genauere Angaben zur Häufigkeit der Art sind durch die zufälligen Beobachtungen nicht möglich.



Abb. 42 Ambrosie an einem Seitenstreifen (links) und Mittelstreifen (rechts) der A1.

II.2 Gefleckter Schierling (*Conium maculatum*)

Der Gefleckte Schierling gilt in der Schweiz als Archäophyt, der im Unterschied zu Neophyten bereits früh mit dem Menschen ins Gebiet gelangte. Er wird gemäss aktueller Roter Liste landesweit als «potenziell gefährdet» eingestuft [77] und besitzt grössere Vorkommen auf Mittelstreifen der Autobahnen im Schweizer Mittelland. Diese stellen einen bedeutenden Anteil des Gesamtbestandes der Schweiz dar. Der Gefleckte Schierling ist kulturhistorisch interessant, da mit ihm in der Antike der sogenannte «Schierlingsbecher» zubereitet wurde, der auch bei der Hinrichtung von Sokrates im Jahr 399 v. Chr. genannt wird.



Abb. 43 Der Gefleckte Schierling besitzt landesweit bedeutende Vorkommen auf Mittelstreifen der Autobahnen im Schweizer Mittelland. Die linke Aufnahme zeigt die Art zusammen mit Götterbaum und Schmalblättrigem Greiskraut.

II.3 *Cuscuta*-Art auf Schmalblättrigem Greiskraut

Beim Markieren der Bilder fiel bei einem Bestand des Schmalblättrigen Greiskrauts gelbe «Fäden» auf, die zunächst wie Kunststofffäden wirken. Tatsächlich handelt es sich mit hoher Wahrscheinlichkeit um eine *Cuscuta*-Art, die hier als Schmarotzer ohne eigene grüne Blätter auf dem Schmalblättrigen Greiskraut wächst und Wasser sowie Nährstoffe von diesem bezieht. Bei der Art könnte es sich um *Cuscuta campestris* aus Nordamerika handeln, die schon mehrfach in Europa mit Schmalblättrigen Greiskraut beobachtet wurde (www.waarneming.nl, Brandes, 1999). Gemäss aktueller Verbreitungskarte von Info Flora (www.infoflora.ch) existieren für *Cuscuta campestris* nur wenige und meist nicht verifizierte Funde in der Schweiz. Diese Fundmeldungen haben in den letzten Jahren jedoch zugenommen.



Abb. 44 Schmalblättriges Greiskraut mit einer *Cuscuta*-Art als Schmarotzer.

Glossar

Begriff	Bedeutung
CNN	Convolutional Neural Network. Ein Klasse von Deep-Learning-Netzen, die üblicherweise zur Mustererkennung in Bildern eingesetzt und mit Beispielbildern trainiert werden.
Confusion-Matrix	Wahrheits-Matrix, die zur Berechnung statistische Kennzahlen wie Precision und Recall verwendet wird. Die Einträge entsprechen True Positives, False Positives, False Negatives und True Negatives.
Epochen	Gibt an, wie oft jedes Trainingsbild zum Optimieren der CNN-Parameter beim Trainieren verwendet wird.
Feature-Extractor	Teil eines CNNs, der dafür zuständig ist, nützliche Merkmale in den Bildern zu extrahieren, die zur Lösung der eigentlichen Aufgabe des CNNs benötigt werden.
FFMPEG	Eine Programmbibliothek zur Aufnahme und Verarbeitung von digitalem Video- und Audiodateien.
Frame	Extrahiertes Einzelbild aus einem Video
(Bild-)Kachel	Ausschnitt der aus den Filmen extrahierten Bilder, der vom CNN verarbeitet wird.
Loss-Funktion	Mathematische Funktion, die das Fehlverhalten des CNNs während des Trainings quantitative misst, sodass das CNN verändert werden kann, um diese Fehler zu minimieren.
Motion Blur	Bewegungsunschärfe. Entsteht, wenn sich die Kamera oder das Objekt während der Belichtungszeit bewegt und der gleiche Bildpunkt auf mehreren Pixel abgebildet wird.
Multi-Task-Model	Deep-Learning Modell, das mehrere Aufgaben erfüllen kann. Meist besteht es aus einem gemeinsamen Feature-Extractor, der für alle Aufgaben verwendet wird.
Rolling Shutter	Strategie beim Auslesen des Kamerasensors. Da beim Filmen das Einfrieren aller Pixel und anschließendes Auslesen zu viel Zeit beansprucht, wird der Sensor zeilen- oder spaltenweise ausgelesen und ausgelesene Bereiche bereits wieder belichtet.
Transfer-Learning	Erlaubt es, CNNs mit anderen ähnlichen Trainingsbildern vorzutrainieren, um die benötigte Anzahl markierter Trainingsbilder zu reduzieren.

Literaturverzeichnis

-
- [1] Kowarik, I., Boye, P. (2003). **Biologische Invasionen: Neophyten und Neozoen in Mitteleuropa**. Ulmer.
-
- [2] Seebens, H., Blackburn, T.M., Dyer, E.E., Genovesi, P., Hulme, P.E., Jeschke, J.M., Pagad, S., Pyšek, P., Winter, M., Arianoutsou, M., Bacher, S., Blasius, B., Brundu, G., Capinha, C., Celesti-Grappo, L., Dawson, W., Dullinger, S., Fuentes, N., Jäger, H., Kartesz, J., Kenis, M., Kreft, H., Kühn, I., Lenzner, B., Liebhold, A., Mosena, A., Moser, D., Nishino, M., Pearman, D., Pergl, J., Rabitsch, W., Rojas-Sandoval, J., Roques, A., Rorke, S., Rossinelli, S., Roy, H.E., Scalera, R., Schindler, S., Štajerová, K., Tokarska-Guzik, B., van Kleunen, M., Walker, K., Weigelt, P., Yamanaka, T., Essl, F. (2017). **No saturation in the accumulation of alien species worldwide**, *Nature Communications* 8, 14435.
-
- [3] Bundesamt für Statistik BFS (2020). **Infrastruktur und Streckenlänge**, <https://www.bfs.admin.ch/bfs/de/home/statistiken/mobilitaet-verkehr/verkehrsinfrastruktur-fahrzeuge/streckenlaenge.html> (aufgerufen am 11.6.2020).
-
- [4] Zwaenepoel, A., Roovers, P., Hemy, M. (2006). **Motor vehicles as vectors of plant species from road verges in a suburban environment**, *Basic and Applied Ecology* 7, 83–93.
-
- [5] von der Lippe, M., Kowarik, I. (2007). **Long-Distance Dispersal of Plants by Vehicles as a Driver of Plant Invasions**, *Conservation Biology* 21, 986–996.
-
- [6] von der Lippe, M., Bullock, J.M., Kowarik, I., Knopp, T., Wichmann, M. (2013). **Human-Mediated Dispersal of Seeds by the Airflow of Vehicles**, *PLoS One* 8, e52733.
-
- [7] Taramarcas, P., Lambelet, C., Clot, B., Keimer, C., Hauser, C. (2005). **Ragweed (Ambrosia) progression and its health risks: will Switzerland resist this invasion?** *Swiss Medical Weekly* 135, 538–548.
-
- [8] Lemke, A., Kowarik, I., von der Lippe, M. (2019). **How traffic facilitates population expansion of invasive species along roads: The case of common ragweed in Germany**, *Journal of Applied Ecology* 56, 413–422
-
- [9] Vakhlamova, T., Rusterholz, H.-P., Kanibolotskaya, Y., Baur, B. (2016). **Effects of road type and urbanization on the diversity and abundance of alien species in roadside verges in Western Siberia**, *Plant Ecology* 217, 1–12.
-
- [10] SKEW (2001). **Schwarze Liste besonders aggressiver invasiver Neophyten**, Schweizerische Kommission für die Erhaltung von Wildpflanzen, <http://www.cps-skew.ch/deutsch/empfehlungen/saatgut.htm> (Artenliste IVa; Stand 1.5.2001; aufgerufen via www.archive.org am 14.6.2020).
-
- [11] Buholzer, S., Nobis, M., Schoenenberger, N., Rometsch, S. (2014). **Liste der gebietsfremden invasiven Pflanzen der Schweiz**, Info Flora, Bern.
-
- [12] Schweizerische Eidgenossenschaft (2008), **Verordnung über den Umgang mit Organismen in der Umwelt, Freisetzungsverordnung (FrSV)**, SR 814.911, www.admin.ch.
-
- [13] Bundesamt für Umwelt BAFU (2016). **Strategie der Schweiz zu invasiven gebietsfremden Arten**. Beilage zum Bericht des Bundesrates in Erfüllung des Postulates 13.3636 «Stopp der Ausbreitung von invasiven gebietsfremden Arten» von Nationalrat Karl Vogler vom 21.06.2013, Bundesamt für Umwelt, Bern.
-
- [14] Bundesamt für Strassen ASTRA (2015). **Betrieb NS – Teilprodukt Grünpflege – Standards und Indikatoren**. Richtlinie ASTRA16230, V3.10, www.astra.admin.ch
-
- [15] Goodfellow, I., Bengio, Y., Courville, A. (2016). **Deep Learning**, MIT Press.
-
- [16] Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., Fei-Fei, L. (2009). **ImageNet: A large-scale hierarchical image database**, *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
-
- [17] He, K. Zhang, X., Ren, S., Sun, J. (2016). **Deep Residual Learning for Image Recognition**, *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
-
- [18] S. Ren, K. He, R. Girshick, J. Sun (2015). **Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks**, *Advances in Neural Information Processing Systems* 28, 91–99.
-
- [19] Liu, M., Salzmann, M., He, X. (2014). **Discrete-Continuous Depth Estimation from a Single Image**, *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
-

-
- [20] Hecker, S., Dai, D., Van Gool, L. (2018). **End-to-End Learning of Driving Models with Surround-View Cameras and Route Planners**, *The European Conference on Computer Vision (ECCV)*.
-
- [21] van den Oord, A., Dieleman, S., Zen, H., Simonyan, K., Vinyals, O., Graves, A., Kalchbrenner, N., Senior, A., Kavukcuoglu, K. (2016). **Wavenet: A generative model for raw audio**, *ArXiv*, 1609.03499v2.
-
- [22] Turc, I. Chang, M.-W., Lee, K., Toutanova, K. (2019). **Well-Read Students Learn Better: On the Importance of Pre-training Compact Models**, *ArXiv*, 1908.08962v2.
-
- [23] Bahdanau, D., Cho, K., Bengio, Y. (2014). **Neural machine translation by jointly learning to align and translate**, *ArXiv*, 1409.0473.
-
- [24] LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). **Gradient-based learning applied to document recognition**, *Proceedings of the IEEE* 86, 2278–2324.
-
- [25] Silver, D., Huang, A., Maddison, C.J., Guez, A., Sifre, L., van den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., Dieleman, S., Grewe, D., Nham, J., Kalchbrenner, N., Sutskever, I., Lillicrap, T., Leach, M., Kavukcuoglu, K., Graepel, T., Hassabis, D. (2016). **Mastering the game of Go with deep neural networks and tree search**, *Nature* 529, 484–503.
-
- [26] Vinyals, O., Babuschkin, I., Czarnecki, W.M., Mathieu, M., Dudzik, A., Chung, J., Choi, D.H., Powell, R., Ewalds, T., Georgiev, P., Oh, J., Horgan, D., Kroiss, M., Danihelka, I., Huang, A., Sifre, L., Cai, T., Agapiou, J.P., Jaderberg, M., Vezhnevets, A.S., Leblond, R., Pohlen, T., Dalibard, V., Budden, D., Sulsky, Y., Molloy, J., Paine, T.L., Gulcehre, C., Wang, Z., Pfaff, T., Wu, Y., Ring, R., Yogatama, D., Wünsch, D., McKinney, K., Smith, O., Schaul, T., Lillicrap, T., Kavukcuoglu, K., Hassabis, D., Apps, C., Silver, D. (2019). **Grandmaster level in StarCraft II using multi-agent reinforcement learning**, *Nature* 575, 350–354.
-
- [27] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y. (2014). **Generative Adversarial Nets**, *Advances in Neural Information Processing Systems* 27, 2672–2680.
-
- [28] Ignatov, A., Kobyshev, N., Timofte, R., Vanhoey, K., Van Gool, L. (2017). **DSLR-Quality Photos on Mobile Devices with Deep Convolutional Networks**, *The IEEE International Conference on Computer Vision (ICCV)*, 2017.
-
- [29] Zhang, K., Zuo, W., Chen, Y., Meng, D., Zhang, L. (2017). **Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising**, *IEEE Transactions on Image Processing* 26, 3142–3155.
-
- [30] Timofte, R., Rothe, R., Van Gool, L. (2016) **Seven Ways to Improve Example-Based Single Image Super Resolution**, *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
-
- [31] Thies, J., Zollhofer, M., Stamminger, M., Theobalt, C., Niessner, M. (2016). **Face2Face: Real-Time Face Capture and Reenactment of RGB Videos**, *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
-
- [32] Wäldchen, J., Mäder, P. (2018). **Machine learning for image based species identification**, *Methods in Ecology and Evolution* 9, 2216–2225.
-
- [33] Kowarik, I., Säumel, I. (2007). **Biological flora of Central Europe: *Ailanthus altissima* (Mill.) Swingle**, *Perspectives in Plant Ecology, Evolution and Systematics*. 8 (2007) 207–237.
-
- [34] Martin, P.H., Canham, C.D. (2010). **Dispersal and recruitment limitation in native versus exotic tree species: life-history strategies and Janzen-Connell effects**, *Oikos*. 119 (2010) 807–824.
-
- [35] Kowarik, I., Säumel, I. (2008). **Water dispersal as an additional pathway to invasions by the primarily wind-dispersed tree *Ailanthus altissima***, *Plant Ecology* 198 241–252.
-
- [36] J.L. Fryer (2010). ***Ailanthus altissima***. In: Fire Effects Information System [Webseite]. U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station, Fire Sciences Laboratory, <https://www.fs.fed.us/database/feis/plants/tree/ailalt/all.html> (aufgerufen 14.6.2020).
-
- [37] Kowarik, I. (1983). **The distribution of the Tree of Heaven (*Ailanthus altissima* (Mill.) Swingle) in the French Mediterranean area (Bas-Languedoc)**, *Phytocoenologia* 11, 389–405.
-
- [38] Burch, P.L., Zedaker, S.M. (2003). **Removing the invasive tree *Ailanthus altissima* and restoring natural cover**. *Journal of Arboriculture* 29, 18-24.
-

-
- [39] Wunder, J., Knüsel, S., Dorren, L., Schwarz, M., Bourrier, F., Conedera, M. (2018). **Götterbaum und Paulownie: die «neuen Wilden» im Schweizer Wald?** *Schweizerische Zeitschrift für Forstwesen* 169, 69–76.
-
- [40] Gurtner, D., Conedera, M., Rigling, A., Wunder, J. (2015). Der Götterbaum dringt in die Wälder nördlich der Alpen vor, *Wald und Holz* 7, 22–24.
-
- [41] Kanton Zürich (2018). **Massnahmenplan invasive gebietsfremde Organismen 2018-2021**. Baudirektion, AWEL, 12 S.
-
- [42] Europäische Kommission (2019), **List of Invasive Alien Species of Union concern**, https://ec.europa.eu/environment/nature/invasivealien/list/index_en.htm (aufgerufen 14.6.2020).
-
- [43] Ernst, W.H.O. (1998). **Invasion, dispersal and ecology of the South African neophyte *Senecio inaequidens* in The Netherlands: from wool alien to railway and road alien**. *Acta Botanica Neerlandica*. 47, 131–151.
-
- [44] Werner, D.J., Rockenbach, T., Hölscher, M.-L. (1991). **Herkunft, Ausbreitung, Vergesellschaftung und Ökologie von *Senecio inaequidens* DC. unter besonderer Berücksichtigung des Köln-Aachener Raumes**. *Tuexenia* 11, 73-107.
-
- [45] López-García, M.C., Maillat, J. (2005). **Biological characteristics of an invasive south African species**, *Biological Invasions* 7, 181–194.
-
- [46] T. Heger, H.J. Böhmer (2006). **NOBANIS – Invasive Alien Species Fact Sheet – *Senecio inaequidens***. *Online Database of the European Network on Invasive Alien Species – NOBANIS*. www.nobanis.org (aufgerufen 14.6.2020).
-
- [47] Lenzin, H., Huck, C., Gross, A., Nagel, P. (2009). **Verbreitung und Standorte des Schmalblättrigen Kreuzkrauts (*Senecio inaequidens*) und anderer Neophyten in der Stadt Basel (Schweiz)**, *Bauhinia* 21, 17–24.
-
- [48] Brodtbeck, T., Zemp, M., Frei, M., Kienzle, U., Knecht, D. (1999). **Flora von Basel und Umgebung 1980-1996, Teil II**. Mitteilungen der Naturforschenden Gesellschaften beider Basel, Volume 3.
-
- [49] Heger, T., Böhmer, H.J. (2005). **The invasion of Central Europe by *Senecio inaequidens* DC. - a complex biogeographical problem**. *Erdkunde*. 59, 34–49.
-
- [50] Landolt, E. (2013). **Flora des Sihltals - von der Stadt Zürich bis zum Höhrönen**. *Fachstelle Naturschutz Kanton Zürich*, <http://www.naturschutz.zh.ch>.
-
- [51] Landolt, E. (2001). **Flora der Stadt Zürich (1984-1998)**, Birkhäuser, Basel.
-
- [52] Federer, C. (2015). **Distribution of *Senecio inaequidens* in Zurich from 1985 to 2015**, Master-Arbeit, ETH Zürich.
-
- [53] Dimande, A.F.P., Botha, C.J., Prozesky, L., Bekker, L., Rosemann, G.M., Labuschagne, L., Retief, E. (2007). **The toxicity of *Senecio inaequidens* DC.** *Journal of the South African Veterinary Association* 78, 121–129.
-
- [54] Passemar, B., Priymenko, N. (2007). **L'intoxication des chevaux par les séneçons, une réalité en France**. *Revue de Médecine Vétérinaire* 158, 425-430.
-
- [55] Bundesamt für Bevölkerungsschutz BABS (2015). **Nationale Gefährdungsanalyse – Gefährdungsdossier Massenausbreitung invasiver Arten**. Bundesamt für Bevölkerungsschutz, www.babs.admin.ch.
-
- [56] Böhmer, H.J. (2001). **Das Schmalblättrige Greiskraut (*Senecio inaequidens* DC. 1837) in Deutschland - eine aktuelle Bestandesaufnahme**. *Floristische Rundbriefe* 35, 47–54.
-
- [57] Feichtinger, G. (2012). **Erfahrungsbericht zur Bekämpfung des Schmalblättrigen Kreuzkrauts (*Senecio inaequidens*) im Kanton Zürich**. Strickhof: Fachstelle Pflanzenschutz des Kanton Zürich.
-
- [58] Fischer, K., Landergott, U. (2014). **Schmalblättriges Greiskraut: Bekämpfungspflicht**. *Zürcher UmweltPraxis (ZUP)* 77, 35–36.
-
- [59] Bundesamt für Strassen ASTRA (2014). **Bekämpfung Neophyten**. Merkblatt ASTRA 26010-03020, www.astra.admin.ch.
-

-
- [60] Zagoruyko, S., Komodakis, N. (2016). **Wide Residual Networks**. *The British Machine Vision Conference (BMVC)*.
-
- [61] Huang, G., Liu, Z., van der Maaten, L., Weinberger, K.Q. (2017). **Densely Connected Convolutional Networks**. *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
-
- [62] Xie, S., Girshick, R., Dollár, P., Tu, Z., He, K. (2017). **Aggregated Residual Transformations for Deep Neural Networks**. *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
-
- [63] R Core Team (2020). **R: A Language and Environment for Statistical Computing**. R Foundation for Statistical Computing, Vienna, <https://www.R-project.org>.
-
- [64] RStudio Team (2020). **RStudio: Integrated Development Environment for R**, RStudio Inc., Boston, <http://www.rstudio.com>.
-
- [65] Appelhans, T. (2019). **leafem: leaflet Extensions for mapview**, <https://CRAN.R-project.org/package=leafem>.
-
- [66] Appelhans, T., Fay, C. (2020). **leafgl: Bindings for Leaflet.glify**. R package version 0.1.1.
-
- [67] Cheng, J., Karambelkar, B., Xie, Y. (2019). **leaflet: Create Interactive Web Maps with the JavaScript Leaflet Library**. <https://CRAN.R-project.org/package=leaflet>.
-
- [68] Karambelkar, B., Schloerke, B. (2018). **leaflet.extras: Extra Functionality for "leaflet" Package**. <https://CRAN.R-project.org/package=leaflet.extras>.
-
- [69] T. Appelhans, F. Detsch, C. Reudenbach, S. Woellauer (2019). **mapview: Interactive Viewing of Spatial Data in R**. <https://CRAN.R-project.org/package=mapview>.
-
- [70] Hijmans, R.J. (2020). **raster: Geographic Data Analysis and Modeling**. <https://CRAN.R-project.org/package=raster>.
-
- [71] Chang, W., Cheng, J., Allaire, J.J., Xie, Y., McPherson, J. (2019). **shiny: Web Application Framework for R**. <https://CRAN.R-project.org/package=shiny>.
-
- [72] Landergott, U. (2015). **Schmalblättriges Greiskraut: Monitoring und Bekämpfung im Kanton Zürich - Zwischenbericht 2014**. FORNAT AG, Zürich
-
- [73] Landergott, U. (2020). **Schmalblättriges Greiskraut: Monitoring und Bekämpfung im Kanton Zürich - Bericht 2015-2018**. FORNAT AG, Zürich.
-
- [74] Concepción, E.D., Obrist, M.K., Moretti, M., Altermatt, F., Baur, B., Nobis, M.P. (2016). **Impacts of urban sprawl on species richness of plants, butterflies, gastropods and birds: not only built-up area matters**. *Urban Ecosystems* 19, 225–242.
-
- [75] Nobis, M.P., Jaeger, J.A.G., Zimmermann, N.E. (2009). **Neophyte species richness at the landscape scale under urban sprawl and climate warming**, *Diversity and Distributions* 15, 928–939
-
- [76] Feichtinger, G., Ammann, L. (2015). **Effekt eines dritten Schnitts im Vergleich zu zwei Schnitten auf die Samenproduktion von *Senecio inaequidens***. *Strickhof: Fachstelle Pflanzenschutz des Kantons Zürich*.
-
- [77] Bornand, C., Gyax, A., Juillerat, P., Jutzi, M., Möhl, A., Rometsch, S., Sager, L., Santiago, H., Eggenberg, S. (2016). **Rote Liste Gefäßpflanzen. Gefährdete Arten der Schweiz.**, Bundesamt für Umwelt, Bern und Info Flora, Genf, *Umwelt-Vollzug* 1621, 178 S.
-
- [78] D. Brandes, D. (1999). ***Senecio inaequidens* am Monte Baldo**, *Abhandlungen des Naturwissenschaftlichen Vereins zu Bremen* 44/2–3, 245–256.
-

Projektabschluss



Schweizerische Eidgenossenschaft
Confédération suisse
Confederazione Svizzera
Confederaziun svizra

Eidgenössisches Departement für
Umwelt, Verkehr, Energie und Kommunikation UVEK
Bundesamt für Strassen ASTRA

FORSCHUNG IM STRASSENWESEN DES UVEK

Version vom 09.10.2013

Formular Nr. 3: Projektabschluss

erstellt / geändert am: 16.10.2020

Grunddaten

Projekt-Nr.: VSS 2016/224
 Projekttitel: Automatisierte Erfassung invasiver Neophyten an Autobahnen
 Enddatum: 31.7.2020

Texte

Zusammenfassung der Projektergebnisse:

Im Projekt wurde eine auf künstlicher Intelligenz (KI) und maschinellem Sehen (Deep Learning) basierende, automatisierte Kartierung von zwei invasiven Neophyten an Autobahnen im Schweizer Mittelland entwickelt und angewendet. Als Testarten dienten das aus Südafrika stammende Schmalblättrige Greiskraut (*Senecio inaequidens*) sowie der ursprünglich in China beheimatete Götterbaum (*Ailanthus altissima*). Vom fließenden Verkehr aus wurden mit zwei Kameras aus einem Fahrzeug heraus Seiten- und Mittelstreifen gefilmt. So konnte die fahrbahnahe Vegetation auf einer Gesamtlänge von 690 km in beiden Fahrrichtungen und während drei Befahrungen (Mai, August, Oktober) erfasst werden, was rund der Hälfte des Schweizer Autobahnnetzes entspricht. Für das Trainieren und Testen der neuronalen Netze markierten Experten in Bildern der Filme das Vorkommen oder Fehlen der Testarten in jeweils 15 gleich grossen Teilbildern (Bildkacheln). Beim Schmalblättrigen Greiskraut wurden zusätzlich blühende und nicht-blühende Vorkommen unterschieden. Für den Götterbaum standen so 972, für blühendes Greiskraut 2'096 und für nicht-blühendes Greiskraut 2'471 markierte Artvorkommen zur Verfügung. Von den getesteten neuronalen Netzen erwies sich RasNet152 für die Arterkennung am besten geeignet. Die erkannten Vorkommen des Götterbaums stimmten in 97.5% der Fälle mit Angaben der Experten überein, wobei 88.6% der markierten Bildkacheln gefunden wurden. Beim Schmalblättrigen Greiskraut waren dies 97.7% korrekt erkannte und 87.5% gefundene Bildkacheln.

Die automatisierte Kartierung im Schweizer Mittelland wurde im Anschluss mit Bildern im Abstand von fünf Metern durchgeführt und berücksichtigte rund 1.35 Millionen Bilder beziehungsweise über 20 Millionen Bildkacheln. Detailreiche, interaktive Verbreitungskarten stehen web-basiert zur Verfügung. Eine hohe Reproduzierbarkeit der Kartierung wurde durch den Vergleich mehrfach erfasster Streckenabschnitte bestätigt.

Die beiden Testarten wachsen an Autobahnen momentan häufiger auf Mittelstreifen als auf Seitenstreifen. Der Götterbaum weist neben grösseren Vorkommen wie am Genfer See noch lange, kaum oder nicht besiedelte Streckenabschnitte auf. Das Schmalblättrige Greiskraut ist dagegen nahezu durchgehend vorhanden. Da der Götterbaum an Autobahnen wegen Mahd und Gehölzschnitt nur ausnahmsweise Samen bildet, ist für seine weitere Ausbreitung an Autobahnen der Sameneintrag aus Siedlungsgebieten wichtiger Faktor. Dies konnte durch eine Korrelation der Autobahnvorkommen mit Gebieten mit erhöhter Bodenversiegelung bestätigt werden. Das Schmalblättrige Greiskraut zeigt keine solche Beziehung, was auf eine unabhängige, selbständige Ausbreitung schliessen lässt. Die erkannten Vorkommen der beiden invasiven Arten zeigen deutliche Unterschiede zwischen den Gebietseinheiten, was zum Teil durch eine abweichende Praxis bei der Grünpflege und beim Neophyten-Management erklärt werden kann.



Schweizerische Eidgenossenschaft
Confédération suisse
Confederazione Svizzera
Confederaziun svizra

Eidgenössisches Departement für
Umwelt, Verkehr, Energie und Kommunikation UVEK
Bundesamt für Strassen ASTRA

Zielerreichung:

Der auf Deep Learning basierende Kartieransatz konnte erfolgreich entwickelt werden und hat sich bei mehrfacher Anwendung auf rund der Hälfte des Schweiz Autobahnnetzes bewährt. Er liefert gut reproduzierbare, räumlich hoch aufgelöste Verbreitungskarten, die mit einer klassischen Experten-Kartierung nicht mit vertretbarem Aufwand erstellt werden können. Als Einflussfaktoren für das Auftreten der beiden invasiven Neophyten an Autobahnen im Schweizer Mittelland konnten Siedlungsnähe und unterschiedliche Grünpflege identifiziert werden.

Folgerungen und Empfehlungen:

Der entwickelte Ansatz hat sich bewährt und kann zur Erfassung weiterer invasiver Neophyten weiterentwickelt werden - beispielsweise für die im Bildmaterial zu erkennende melde- und bekämpfungspflichtige Ambrosie (*Ambrosia artemisiifolia*). Hierfür müssten die neuronalen Netze erweitert und neu trainiert werden, ohne dass zwingend das Autobahnnetz neu befahren werden muss. Dies gilt auch für gegebenenfalls zukünftig von Bund oder Kantonen neu regulierte Arten. Mit Filmmaterial aus mehreren Jahren könnte die Ausbreitungs-Dynamik der Arten erfasst werden (bei neuen Arten auch nachträglich) und ein Monitoring des Neophyten-Managements erfolgen. Es ist davon auszugehen, dass angesichts der aktuellen Entwicklung in den Bereichen künstlicher Intelligenz und Kamertechnik entsprechende Anwendungen der automatisierten Kartierung von Arten oder auch anderen Objekten rasch an Bedeutung gewinnen werden. Das Projekt hat dabei einen Ansatz entwickelt, dessen Anwendung und Anpassung an neue Arten oder Techniken weiter verfolgt werden sollte.

Publikationen:

Das Projekt wurde 2019 im WSL-Magazin DIAGONAL vorgestellt, worüber auch in den Medien berichtet wurde (SRF, 20min). Neben dem Abschlussbericht werden internationale Publikationen vorbereitet.

Der Projektleiter/die Projektleiterin:

Name: Nobis

Vorname: Michael

Amt, Firma, Institut: Eidg. Forschungsanstalt WSL

Unterschrift des Projektleiters/der Projektleiterin:



Schweizerische Eidgenossenschaft
Confédération suisse
Confederazione Svizzera
Confederaziun svizra

Eidgenössisches Departement für
Umwelt, Verkehr, Energie und Kommunikation UVEK
Bundesamt für Strassen ASTRA

FORSCHUNG IM STRASSENWESEN DES UVEK

Formular Nr. 3: Projektabschluss

Beurteilung der Begleitkommission:

Beurteilung:

Das Forschungsprojekt beantwortet die beiden folgenden Fragen und erfüllt oder überschreitet dabei sogar die erhofften Ziele: (1) Kann man mit einer vergleichsweise einfachen Kamertechnik mit Hilfe von KI (Deep Learning) Pflanzen beim Vorbeifahren erkennen, inventarisieren und mit grosser Genauigkeit lokalisieren? (2) Ist es möglich, diese Technik für die automatische Erfassung von invasiven Neophyten zu nutzen? Diese beiden Fragen konnten positiv beantwortet werden. Somit bringt uns das Forschungsprojekt eine innovative und vielversprechende Grundlage für die Kartierung und das Monitoring invasiver Neophyten, was wiederum entscheidend für ein effizientes und gezieltes Management dieser Arten ist. Die Resultate sind auch von internationaler Bedeutung.

Umsetzung:

Die Technik kann schon jetzt für die Praxis verwendet werden. Es besteht auch ein starkes Interesse, die Methode auf weitere Arten auszudehnen. Das Monitoring der invasiven Neophyten ist ein wichtiger Aspekt im Umgang mit diesen Arten. Es ist Teil der Bekämpfungsstrategien und hilft zu entscheiden, wann, wo und wie die Arten bekämpft werden sollen.

weitergehender Forschungsbedarf:

Die Anpassung auf weitere Arten ist nicht nur erwünscht, sie ist notwendig. Die Anzahl invasiver Neophyten in der Schweiz wird weiter zunehmen, ein relativ hoher Anteil ist in Siedlungsgebieten und an/entlang von Verkehrsinfrastruktur zu finden, andere in der Land- und Forstwirtschaft und in natürlichen Lebensräumen. Die Kosten der Bekämpfung steigen, und das Monitoring wird immer wichtiger, um rechtzeitig eingreifen zu können. Es ist Teil der Bekämpfungsstrategie auf nationaler Ebene.

Einfluss auf Normenwerk:

kein

Der Präsident/die Präsidentin der Begleitkommission:

Name: Rometsch

Vorname: Sibyl

Amt, Firma, Institut: Info Flora

Unterschrift des Präsidenten/der Präsidentin der Begleitkommission:

Verzeichnis der Berichte der Forschung im Strassenwesen

Das Verzeichnis der in der letzten Zeit publizierten Schlussberichte kann unter www.astra.admin.ch (Forschung im Strassenwesen --> Arbeitshilfen, Formulare, Merkblätter --> Formulare) heruntergeladen werden.