

Schlussbericht

zum Vorhaben

Thema: Entwicklung von automatisierten (digitalen) Bilderkennungssystemen zur **Holzartenbestimmung mittels künstlicher Intelligenz**

Zuwendungsempfänger:

Teilvorhaben 1:

Thünen-Institut für Holzforschung (TI), Hamburg Thünen-Kompetenzzentrum Holzherkünfte

Teilvorhaben 2:

Fraunhofer-Institut für Techno- und Wirtschaftsmathematik (ITWM), Kaiserslautern

Förderkennzeichen:

Teilvorhaben 1:

TI: 2220HV063A

Teilvorhaben 2:

ITWM: 2220HV063B

Laufzeit:

01.06.2021 bis 30.09.2024

Monat der Erstellung:

11/2024

Gefördert durch:



Bundesministerium
für Ernährung
und Landwirtschaft

aufgrund eines Beschlusses
des Deutschen Bundestages

Das diesem Bericht zugrundeliegende Vorhaben wurde aufgrund eines Beschlusses des Deutschen Bundestages mit Mitteln des Bundesministeriums für Ernährung und Landwirtschaft (BMEL) über die Fachagentur Nachwachsende Rohstoffe e.V. (FNR) als Projektträger des BMEL für das Förderprogramm Nachwachsende Rohstoffe unterstützt. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei der Autorenschaft.

Inhaltsverzeichnis

I.	Kurzbericht.....	1
1.	Aufgabenstellung	1
2.	Planung und Ablauf des Vorhabens.....	1
3.	Resümee der wesentlichen Ergebnisse	1
a)	Arbeitspakete und Meilensteine	1
b)	Zusammenfassung.....	3
II.	Ausführliche Darstellung der Ergebnisse.....	5
1.	Erzielte Ergebnisse	5
	Arbeitspaket 1: Auswahl der Hölzer (TI und ITWM).....	5
	Arbeitspaket 2: Beschaffung der Ausgangsstoffe (TI)	6
	Arbeitspaket 3: Generation des Bildmaterials (TI)	6
	Arbeitspaket 4: Reduktion der Bilddaten auf wesentliche Zelltypen und -strukturen (ITWM)	7
	Arbeitspaket 5: Implementierung einer Bilddatenbank (TI)	10
	Arbeitspaket 6: Implementierung und Optimierung der Algorithmen (ITWM)	11
	Erklärbarkeit ¹⁴	
	Nadelhölzer ¹⁶	
	Arbeitspaket 7: Implementierung von Systemsoftware und Benutzerschnittstelle (ITWM).....	18
	Systemsteuerung	21
	Arbeitspaket 8: Analyse von Mischproben (TI und ITWM).....	22
	Arbeitspaket 9: Blindtest (TI und ITWM)	23
	Arbeitspaket 10: Entwicklungstransfer für eine digitale Bestimmung von Massivhölzern (TI und ITWM) 25	
	Arbeitspaket 11: Abschlussbericht (TI und ITWM)	25
2.	Verwertung.....	26
a)	Erfindungen/Schutzrechtsanmeldungen.....	26
b)	Wirtschaftliche Erfolgsaussichten nach Projektende.....	26
c)	Wissenschaftliche und/oder technische Erfolgsaussichten nach Projektende	26
d)	Wissenschaftliche und wirtschaftliche Anschlussfähigkeit	26
3.	Erkenntnisse von Dritten	26
4.	Veröffentlichungen	27

I. Kurzbericht

Die erreichten Ergebnisse der engen Kooperation der Projektpartner werden, wie auch schon in den Zwischenberichten von 2022-2024, in diesem Dokument gemeinsam dargestellt. Die Kompetenzbereiche der Projektpartner sind klar umgrenzt und im Text ist immer gekennzeichnet, welche Arbeitspakete vom TI und/oder ITWM bearbeitet wurden. Gesonderte Anhänge der einzelnen Teilprojekte wurden nicht angefertigt.

1. Aufgabenstellung

Ziel des Projekts war die Entwicklung einer Software zur vollautomatisierten Erkennung von Holzarten in Faserstoffen (Zellstoff, Papier/-produkte) mit Hilfe von Machine Learning / KI. Diese Software soll die Kontrolle der Deklarationen bezüglich des Artnachweises gemäß der Europäischen Holzhandelsverordnung (EUTR) durch die Bundesanstalt für Ernährung und Landwirtschaft (BLE) unterstützen und eine großflächigere Überprüfung ermöglichen. (Die EUTR wird aktuell ersetzt durch die EUDR = EU-Verordnung zu entwaldungsfreien Lieferketten.)

2. Planung und Ablauf des Vorhabens

Das Projekt wurde mit verschiedenen Arbeitspaketen geplant, die entweder vom Thünen-Institut (TI) für Holzforschung, vom Fraunhofer Institut ITWM oder von beiden Instituten gemeinsam bearbeitet wurden.

Am TI wurde dabei ein großer Bilddatensatz von Referenzen aufgebaut und annotiert. Mit diesem wurde am ITWM das KI-System zur Auswertung entwickelt. Dies waren keine nacheinander und getrennt voneinander stattfindenden Teilprojekte, sondern in Diskussion und Zuarbeit durch die Holzanatomie (TI) mussten die Algorithmen durch die IT-Spezialist*innen (ITWM) angepasst werden. Die Bearbeitung des Projektes erfolgte eng verzahnt im ständigen Austausch. Jedes Teilergebnis wurde zwischen den Projektpartnern gespiegelt, d.h. Datenqualität (TI) und Entwicklung (ITWM) waren immer auf dem gleichen Stand

Die webbasierte Benutzeroberfläche (GUI) wurde am ITWM programmiert, vom TI getestet und fortwährend aktualisiert.

3. Resümee der wesentlichen Ergebnisse

a) Arbeitspakete und Meilensteine

Arbeitspakete (AP) (lt. Planung im Antrag)	Bearbeitungszeitraum (lt. Balkenplan im Antrag)	Zielerreichung
AP 1 Auswahl der Hölzer (TI und ITWM)	07/2021 bis 10/2021	Die Auswahl der Hölzer erfolgte im genannten Zeitraum, aber auch noch darüber hinaus, sofern sich die Hinzunahme weiterer Gattungen als sinnvoll herausstellte, z.B. die Hinzunahme von Verwechslungspartnern schon vorhandener Gattungen (Tabelle 1). Insgesamt wurden 21 Gattungen bearbeitet.
AP 2 Beschaffung der Ausgangsstoffe (TI)	08/2021 bis 01/2022	Hölzer aus der Sammlung des Thünen-Instituts waren leicht zu beschaffen. Darüber hinaus wurden verschiedene Personen für Plantagenhölzer aus realen Plantagen angefragt. Dies reichte über den Zeitraum hinaus, da es viel Zeit erforderte, Personen zu finden, die Hölzer mit sicherer Herkunft und korrekter Bezeichnung beschaffen konnten.
AP 3 Generation des Bildmaterials (TI)	08/2021 bis 06/2023	Der Hauptanteil der Bilder entstand in dem Zeitraum. Darüber hinaus wurde das Bildmaterial aber in Absprache mit allen Projektpartnern kontinuierlich ergänzt. Datengetriebene Verfahren kann man durch gezielte Verbesserung der Datenbasis gezielt verbessern (s. AP 2).
AP 4 Reduktion der Bilddaten auf wesentliche Zelltypen und -strukturen (ITWM)	09/2021 bis 06/2022	Das Bildmaterial besteht aus großen Bildern (1GB pro Bild). Für effiziente Klassifikation der Bildinhalte ist ein zweischrittiges Verfahren notwendig, was zunächst nach den für Laubholz charakteristischen Gefäßen sucht und diese dann zur Klassifikation heranzieht. Hier wurde iterativ versucht, die Annotation der Gefäße weitestgehend zu automatisieren und mit Reinproben zu arbeiten, damit eine Annotierung der Gefäßklassen nur in Ausnahmefällen

Arbeitspakete (AP) (lt. Planung im Antrag)	Bearbeitungszeitraum (lt. Balkenplan im Antrag)	Zielerreichung
		notwendig ist.
AP 5 Implementierung einer Bilddatenbank (ITWM und TI)	01/2023 bis 07/2023	Es wurde eine Datenbank für die Verwaltung der Bilder entwickelt. Notwendige Anpassungen wurden auch über den Zeitraum hinaus vorgenommen (bspw. das Hinzufügen weiterer Spalten).
AP 6 Implementierung und Optimierung der Algorithmen (TI und ITWM)	12/2021 bis 04/2024	In enger Abstimmung zwischen den Projektpartnern wurden hier Algorithmen zur Bilderkennung, zur Nachvollziehbarkeit und zur Beurteilung der Ergebnisse entwickelt. Dies wurde kontinuierlich während der gesamten Projektlaufzeit durchgeführt. Auf den gelernten Laubhölzern konnte eine Erkennungsrate von 84,8 Prozent der Gefäße und 78,3 Prozent der Klassifikation erreicht werden.
AP 7 Implementierung von Systemsoftware und Benutzerschnittstelle (ITWM)	09/2021 bis 04/2022	Das übergeordnete Ziel dieses Forschungsprojektes ist, dass Gutachten zur Feststellung der vorhandenen Holzarten einfacher erstellt werden können. Um dies auch Nicht-KI-Experten zu ermöglichen, wurde vom Fraunhofer ITWM eine Benutzeroberfläche (GUI) implementiert. Diese ist webbasiert, um eine universelle Nutzbarkeit sicherzustellen und außerdem in ihren einzelnen Schritten interaktiv und parametrisierbar gestaltet. Desweiteren ist es möglich, auch zu einem späteren Zeitpunkt noch Nadelhölzer in die GUI einzufügen.
AP 8 Analyse von Mischproben (TI und ITWM)	01/2023 bis 02/2024	Aus verschiedenen Kombinationen von Laub- und Nadelhölzern wurden Mischproben hergestellt, um erste Ansätze zum Training eines KI-Modells zu erhalten, das Laub- und Nadelholz differenzieren kann.
AP 9 Blindtest (TI und ITWM)	01/2024 bis 04/2024	Mischproben aus 9 Laubhölzern und 5 Nadelhölzern wurden zu 12 Blindproben verarbeitet, die von 6 Wissenschaftler*innen und von den KI-Modellen analysiert wurden.
AP 10 Entwicklungstransfer für eine digitale Bestimmung von Massivhölzern (TI und ITWM)	07/2022 bis 06/2024	Dieses Arbeitspaket konnte im Projekt nicht bearbeitet werden. Weitere Details dazu unter „Arbeitspaket 10: Entwicklungstransfer für eine digitale Bestimmung von Massivhölzern (TI und ITWM)“.
AP 11: Abschlussbericht (TI und ITWM)	09/2024 bis 10/2024	Der Abschlussbericht liegt hiermit vor.

Meilensteine (M) (lt. Planung im Antrag)	Fälligkeit (lt. Balkenplan im Antrag)	Zielerreichung
M 1 Nach 6 Monaten Projektlaufzeit sollte die Auswahl der wesentlichen Hölzer (AP 1) und deren Beschaffung (AP 2) abgeschlossen sein.	01/2022	Die Probenauswahl, -beschaffung und -präparation wurde abgeschlossen und das Ziel somit erreicht.
M 2 Nach 12 Monaten Projektlaufzeit sollte eine Bilddatenbank für die Bilddatenerhebung des Projekts implementiert sein (AP 5). Die automatisierte Digitalisierung der mikroskopischen Präparate sollte etabliert sein (AP 3). Eine erste Softwarelösung zur Reduktion der Bilddaten auf wesentliche Zelltypen und -strukturen sollte entwickelt sein (AP 4).	07/2022	Das neu beschaffte Mikroskop Zeiss Axioscan 7 war erfolgreich im Einsatz. Damit wurde ein erster Bilddatensatz von Laub- und Nadelhölzern erhoben (AP3). Die Bilddaten wurden in einer PostgreSQL-Datenbank eingebunden (AP5). Ein großer Teil der Laubholz-Bilddaten wurde annotiert und damit ein Detektionsmodul für die Gefäßelement-Erkennung entwickelt (AP4). Für Nadelhölzer ist das Modell nicht anwendbar. Hier muss ein anderes KI-Modell entwickelt werden (Ziel des bereits begonnenen Folgeprojekts). Erste Versuche sind vielversprechend.
M 3 Nach 18 Monaten Projektlaufzeit sollte ein Prototyp	01/2024	Der Prototyp der Systemsoftware wurde entwickelt und die aktuellen Algorithmen zur Detektion und Klassifikation

Meilensteine (M) (lt. Planung im Antrag)	Fälligkeit (lt. Balkenplan im Antrag)	Zielerreichung
einer Systemsoftware mit Benutzerschnittstelle entworfen sein (AP 7). Erste Algorithmen sollten implementiert sein und fortwährend optimiert worden sein (AP 6). Parallel sollte nach 12 Monaten Projektlaufzeit mit dem Entwicklungstransfer für eine digitale Bestimmung von Massivhölzern begonnen worden sein (AP 10).		eingebunden (AP 7). Die Laubholzerkennung liefert sehr gute Ergebnisse (AP 6). Sobald die Nadelholzerkennung erfolgreich ist, kann das dazugehörige entwickelte KI-Modell eingebunden werden. AP 10 konnte nicht mehr realisiert werden.

b) Zusammenfassung

Das Projekt KI_Wood-ID konnte im Förderzeitraum sehr gute Erfolge erzielen. In diesem Zeitraum haben wir es geschafft, die Bilddatensatzerhebung zu etablieren, zwei Künstliche Intelligenz (KI)-Modelle auf die automatisierte Erkennung der für die Papierherstellung wichtigsten Laubhölzer zu optimieren und die Anwendung in eine Benutzeroberfläche zu integrieren. Für die Erkennung von Nadelhölzern liegen ebenfalls erste Ansätze vor.

Von Laub- und Nadelhölzern wurden 113 Holzproben von 21 Gattungen mazeriert. Je Mazerat wurden mindestens 20 Objektträger präpariert und davon 20 mikroskopische Großaufnahmen erstellt (ca. 8 cm² mit der Auflösung von ca. 53818 x 31282 Pixeln aus 406 Einzelaufnahmen in fünf Fokusebenen zusammengesetzt). Der Dateiname der Bilder enthält alle wichtigen Informationen.

Die aufgenommenen Bilder wurden in einer Bilddatenbank organisiert. Die Datenbank speichert nur Verweise auf die Bilddaten und ergänzt diese mit Metadaten. Siehe auch AP 7.

Um die maschinell lernenden Systeme geleitet trainieren zu können, musste zunächst für die Laubhölzer der Zelltyp mit den meisten Erkennungsmerkmalen – die Gefäßelemente - annotiert werden. Mit den annotierten Bildern einer größeren Auswahl von Laubhölzern wurde die Erkennung unterschiedlicher Gefäßelemente trainiert (Detektionsschritt) und an den fortlaufend neu aufgenommenen Bildern die automatisierte Erkennung erprobt. Die Detektion von Gefäßelementen funktioniert sehr gut. Die Vorhersagen der Gefäßpositionen (predictions) wurden am TI gecheckt und flossen dann als Trainingsdaten für eine neue Version der Detektion ein (ITWM). Zum Ende des Projekts arbeiteten wir mit Version 8.

Für ca. 1000 Laubholzbilder wurden diese automatisch erzeugten Annotationsdateien (in der Datenbank markiert als *predictions*) durch das TI kontrolliert (*predictions checked*). Im Vergleich zu der manuell erstellten Annotation war die Kontrolle der am ITWM erstellten Annotationen bereits eine erhebliche Arbeits- und Zeitersparnis.

Die Erkennung der Holzarten (Klassifikationsschritt) innerhalb der verwendeten Laubhölzer war für die meisten Gattungen sehr gut, bei einigen wenigen kam es noch zu mehrdeutigen Klassifikationen. In Abbildung 10 ist die Confusion Matrix zu sehen, welche beschreibt, wie gut und eindeutig Klassen bestimmt werden können. So kann man gut erkennen, dass die KI die Gefäßelemente der Gattung *Populus* zu 95 % richtig erkannt hat und wenige fälschlicherweise als *Salix*, *Betula* oder *Fagus* klassifiziert hat (2, 1 und 1 %). Dabei ist zu bedenken, dass auch Holzanatom*innen nicht jedes Gefäßelement (oder auch Fragment davon) eindeutig zuordnen können, sondern immer die gesamten Gefäßelemente von zwei Präparaten eingruppiert. Besonders vor dem Hintergrund, dass die Gattung *Salix* der gleichen Familie wie *Populus* angehört und die beiden sich auch in ihrer Anatomie sehr stark ähneln, ist dieses Ergebnis beachtlich. Die Erkennung von *Salix* ist im Vergleich zu anderen sehr schlecht. Da jedoch nicht jedes Gefäßelement der Gattung *Salix* das entscheidende Strukturmerkmal aufweist, das es eindeutig zur Gattung *Populus* abgrenzt, ist dieses Ergebnis nachvollziehbar. Mit der steigenden Datengrundlage konnte hier das Ergebnis auf 57 % gesteigert werden (im Vergleich zum Ergebnis von 19 % - Stand: März 2023). Das gilt auch für die beiden Gattungen *Liquidambar* und *Schima*, die zwar nicht zur gleichen Familie gehören, aber ebenfalls in der Morphologie der Einzelzellen kaum zu unterscheiden sind. Mit der Aufnahme der Gattung *Alnus* in das Klassifikationstraining nahmen wir, aus Sicht der Holzanatomie, zusammen mit der Gattung *Betula* ein weiteres Verwechslungspaar ins Projekt. Die Confusion Matrix zeigt bemerkenswerterweise keine Verwechslung der beiden Gattungen durch die KI. Insgesamt gehen wir davon aus, dass mit steigender Datengrundlage zu jeder Gattung die Klassifikation immer besser werden wird (Umsetzung im bereits begonnenen Folgeprojekt WoodFiberID).

Nadelhölzer bilden im Gegensatz zu Laubhölzern keine Gefäßelemente aus. Der vorrangige Zelltyp der Nadelhölzer ist die Tracheide. Holzanatomen können in Fasermaterialien die Gattungen oder Gruppen von Gattungen an den auf deren Zellwänden sichtbaren Kreuzungsfeldtöpfeln unterscheiden. Die Annotation dieser Strukturen erweist sich als kompliziert und aufwendig, da diese zum Teil nur in einer Fokusebene sichtbar sind. Deshalb wurde zunächst versucht, die Nadelholzerkennung mit einem ungeleiteten Training umzusetzen. Dies führte jedoch auch mit steigender Datengrundlage nicht zu befriedigenden Ergebnissen. Der im jetzt begonnenen Folgeprojekt verfolgte Lösungsansatz ist deshalb, zunächst eine Detektion der Nadelholz-Tracheiden zu entwickeln, auf die dann in einer zweiten Stufe die eigentliche Nadelholzbestimmung aufgebaut werden soll.

Der zum Ende des Projekts durchgeführte Blindtest zeigte auf, wo die KI-Modelle erfolgreich sind und an welcher Stelle Verbesserungsbedarf besteht. Die Erkennung der Laubhölzer war größtenteils sehr gut und nachvollziehbar. Nadelhölzer konnten an dieser Stelle noch nicht identifiziert werden. Die bisher entwickelten Nadelholz-Modelle ermöglichen bisher lediglich in Ansätzen die Differenzierung zwischen Laub- und Nadelholz, aber keine Unterscheidung der Nadelhölzer. Daher müssen für ihre Erkennung eigene Nadelholz-spezifischen KI-Modelle im Folgeprojekt entwickelt werden. Eine wissenschaftliche Veröffentlichung zu den Ergebnissen des Blindtests befindet sich momentan in Vorbereitung.

Neben den algorithmischen Entwicklungen zur Lösung des Erkennungs- und Klassifikationsproblems ist ein Ziel des Projektes auch gewesen, eine grafische Benutzeroberfläche (GUI) zu entwickeln, die die Bedarfe der Anwender - beispielhaft vertreten durch das Thünen Institut – aufnimmt und bedient. In diesem Rahmen hat das ITWM eine GUI entwickelt, die sowohl die Erkennung/Detektion der Gefäßelemente als auch deren Klassifikation in die gelernten Arten grafisch darstellt. Diese GUI ist interaktiv angelegt worden und kann entsprechend gesteuert werden. Daher ist es möglich, sowohl die Detektionsqualität durch einen Schwellwert anzupassen als auch die Klassifikationsqualität. Dadurch wird ein interaktives Arbeiten mit der Software möglich, was eine Anpassung an die jeweilige Erkennungs-Situation erlaubt und auch den Nutzern ein Gefühl für die KI-Lösung und damit eine gewisse Nachvollziehbarkeit gewährt. Die grafische Benutzeroberfläche wurde webbasiert implementiert, um systemunabhängig zu funktionieren und kann direkt auf die Datenbank zugreifen.

II. Ausführliche Darstellung der Ergebnisse

1. Erzielte Ergebnisse

Arbeitspaket 1: Auswahl der Hölzer (TI und ITWM)

Im Projekt wurden zunächst die in Tabelle 1 genannten Holzarten zur Untersuchung ausgewählt. Durch eine kontinuierliche Diskussion der Funktion von KI-Systemen und der biologischen, morphologischen Eigenschaften der Daten wurde im Verlauf des Projektes vom Projektteam die Bedeutung verschiedener Aspekte für die Auswahl der Gattungen herausgearbeitet und entsprechend nach diesen Aspekten ausgewählt.

Die Hauptgesichtspunkte, die beachtet wurden, sind die wirtschaftliche Relevanz – also das Vorkommen im Realfall – einerseits. Andererseits spielen morphologische Gesichtspunkte eine Rolle, um ein Verfahren zu trainieren, das möglichst gut auf weitere mögliche Arten generalisierbar ist.

Aus wirtschaftlichen Gesichtspunkten wurden zunächst Arten ausgewählt, die weltweit in großem Maßstab in Plantagen angebaut werden und/oder häufig in Papier- und Faserplatten am Thünen-Institut identifiziert werden. Diese mussten daher in der Liste der zu erkennenden Holzarten vorhanden sein.

Andererseits musste die Auswahl der Hölzer auch auf das datengetriebene KI-Erkennungsverfahren angepasst sein: Das im Projekt entwickelte spezifische Verfahren basiert auf der Art, wie Holzanatom:innen Laubhölzer identifizieren (siehe AP6): Die KI-basierte Laubholzklassifikation besteht aus einem ersten Schritt, in dem die Gefäßelemente innerhalb des Präparates detektiert werden, um in einem nächsten Schritt klassifiziert zu werden. Um eine möglichst stabile Lösung zu schaffen, wurden die Arten so ausgewählt, dass sowohl der Detektionsschritt als auch der Klassifikationsschritt stabil funktionieren und die Stärken und Schwächen des Systems am Ende des Projekts gut überprüft werden können. Dafür wurden besonders für das Training der Gefäßelement-Detektion eine größere Anzahl Arten/Gattungen danach ausgewählt, dass sie eine besonders hohe Varianz in der Gefäßform oder –morphologie aufweisen. Damit soll verhindert werden, dass das System später in der Anwendung Gattungen, auf deren Klassifizierung sie nicht trainiert wurde, schon bei der Gefäßdetektion "übersieht". Zusätzlich wurden Gattungen mit erheblichem Verwechslungspotenzial in die Untersuchung aufgenommen. Damit können die Grenzen des Systems gut überprüft werden. Im Einzelnen bedeutete dies, dass auch Arten bearbeitet wurden, die klassischerweise in der Papier- oder Faserplattenindustrie nicht verwendet werden, aber in der Auswahl der Hölzer das Spektrum der möglichen Ausprägungsformen der Gefäßelemente vervollständigten.

Alle genannten Gattungen (21) wurden mazeriert und zu Präparaten weiterverarbeitet. Dabei handelte es sich um 16 Laub- und die 5 wichtigsten Nadelhölzer. Die Mazeration, Präparation und Bilddatenerhebung der ausgewählten Gattungen waren damit abgeschlossen (Tabelle 1).

Tabelle 1 Auswahl der untersuchten Gattungen

	Gattung	Familie	Anzahl der mazerierten Proben	Anzahl der Bilder
Laubholz	<i>Acacia</i>	FABACEAE-MIMOSOIDEAE	12	220
	<i>Acer</i>	SAPINDACEAE	5	100
	<i>Alnus</i>	BETULACEAE	3	70
	<i>Betula</i>	BETULACEAE	8	180
	<i>Casuarina</i>	CASUARINACEAE	2	40
	<i>Diospyros</i>	EBENACEAE	2	40
	<i>Eucalyptus</i>	MYRTACEAE	16	353
	<i>Fagus</i>	FAGACEAE	5	100
	<i>Hevea</i>	EUPHORBIACEAE	7	210
	<i>Liquidambar</i>	ALTINGIACEAE	7	100
	<i>Melaleuca</i>	MYRTACEAE	1	20
	<i>Populus</i>	SALICACEAE	8	160
	<i>Quercus</i>	FAGACEAE	1	20
	<i>Robinia</i>	FABACEAE	2	40
	<i>Salix</i>	SALICACEAE	3	60
<i>Schima</i>	THEACEAE	5	100	
Nadelholz	<i>Abies</i>	PINACEAE	3	60
	<i>Cunninghamia</i>	CUPRESSACEAE	3	60
	<i>Picea</i>	PINACEAE	3	60
	<i>Pinus</i>	PINACEAE	14	280
	<i>Pseudotsuga</i>	PINACEAE	3	60

Arbeitspaket 2: Beschaffung der Ausgangsstoffe (TI)

Alle in Tabelle 1 genannten Hölzer ließen sich für die Mazeration aus der wissenschaftlichen Holzsammlung und der Dublettensammlung des Thünen-Instituts schnell und unkompliziert beschaffen. Jeweils mehrere Proben der gleichen Gattung wurden einbezogen, um die natürliche Variabilität innerhalb der Gattungen und Arten abzubilden. Dabei wurden zusätzlich zu den Sammlungshölzern auch Hölzer aus realen Plantagen beschafft. Mit steigendem Datenumfang beruhend auf möglichst vielen individuellen Proben, können die maschinell lernenden Systeme stabiler Gefäßelemente unterschiedlichster Gattungen detektieren und alle Arten und Individuen innerhalb der Gattungen sicherer klassifizieren.

Für die Materialergänzung durch Plantagenholz wurden Personen in Südamerika, Südafrika und Asien kontaktiert, die vor Ort Proben beschaffen. Aus Südamerika und Südafrika waren Proben in Form von Zellstoffen, Hackschnitzeln und Massivholz eingegangen. Vom Thünen-Institut für Forstgenetik wurden ebenfalls Holzproben zur Mazeration zur Verfügung gestellt. Grundsätzlich stellte sich die Materialbeschaffung von Hölzern, die über die Sammlungshölzer hinausgehen, jedoch als schwierig dar und wurde daher über den geplanten Zeitraum hinaus weiter fortgeführt. Somit wurde die Datenbank konstant mit Referenzen erweitert.

Arbeitspaket 3: Generation des Bildmaterials (TI)

Von 21 Gattungen wurden 113 Holzproben mazeriert und angefärbt. Da Papier und Faserplatten in der Praxis mit zwei verschiedenen Färbungen angefärbt werden, wurden diese auch beide im Projekt eingesetzt (Alexander-Herzberg-Lösung und Nigrosin (1%)). Um realistische Proben abzubilden, wie sie später von

unterschiedlichen Prüflaboren zu erwarten sind, wurden die Präparate von fünf unterschiedlichen Personen angefertigt und dabei gezielt unterschiedliche Färbungsintensitäten erzeugt. Hierdurch sollte vermieden werden, dass die KI auf eine bestimmte Farbe einzelner Proben trainiert wird. Auch die Anzahl der Fasern/Zellen auf den Objektträgern wurde variiert, damit das System in der späteren Anwendung möglichst stabil mikroskopische Bilder der in anderen Laboren präparierten Proben verarbeiten kann.

Für die automatisierte und reproduzierbare Digitalisierung einer großen Anzahl von Objektträgern in sehr guter Auflösung wurde im Rahmen des Projekts das Zeiss Axioscan 7 angeschafft und seit Ende Mai 2022 erfolgreich eingesetzt. Im individuell an das Projekt angepassten ScanProfil wurden die Mazeratpräparate auf einer Fläche von 8 cm² mit der Auflösung 53818 x 31282 Pixeln aus 406 Einzelbildaufnahmen zusammengesetzt. Um ein Präparat in der vollen Tiefenschärfe zu erfassen, wurden Aufnahmen in 5 Fokusebenen mit definiertem Abstand erstellt. Pro Objektträger entstand so eine circa 1 GB große Bilddatei. Durch einen am Anfang des Projekts bestehenden Fehler der Zeiss-Software beim Komprimieren der Dateien war der Speicherbedarf zuvor größer (ca. 4 GB/Datei). Durch eine Konvertierung aller im Projekt erhobenen Bilder konnte der erforderliche Speicherplatz für die Bilddaten bei Erweiterung der Anzahl gesenkt werden.

So konnten insgesamt 2291 Übersichtsaufnahmen von 113 unterschiedlichen Mazeraten (= individuelle Holzproben) erstellt werden. Dies ergibt einen Gesamtspeicherbedarf von ca. 2,4 TB für alle erstellten Aufnahmen. In ca. 1000 dieser Bilder wurden dann mehr als 118.000 Gefäßelemente händisch annotiert oder automatisch erstellte Vorhersagen für Gefäßelemente (Predictions) überprüft (siehe AP 4). Diese dienen als sichere Datengrundlage für den machine learning-Prozess.

Es wurden hauptsächlich Reinpräparate, aber auch Mischpräparate digitalisiert. Siehe hierzu AP 8 und 9.

Arbeitspaket 4: Reduktion der Bilddaten auf wesentliche Zelltypen und -strukturen (ITWM)

Wie bereits oben beschrieben werden die Laubholz-Gattungen von Holzanatomen anhand ihrer Gefäße erkannt. Es ist prinzipiell möglich, mit Übersichtsaufnahmen von Reinproben zu trainieren und lediglich die Information, um welche Reinprobe es sich handelt, als Information mit hineinzugeben. Dies wurde zu Beginn der Projektlaufzeit probiert. Die Hoffnung war, dass eine KI von „alleine“ lernt, auf welche Charakteristika sie innerhalb der Bilder schauen soll. Wie erwartet führte dieser Ansatz mit der geringen Menge von vorhandenen Daten nicht zum Erfolg. Um auf diese Art generalisierbar zu sein, sind vermutlich Millionen Bilder von sehr unterschiedlicher Genese notwendig. Denn ein solcher generalisierter Ansatz weiß nicht, worauf er achten soll, weswegen er anfällig dafür ist, „das Falsche“ zu lernen – z.B. die Präparationsmethode, die Kochung usw. – also anfällig ist für sogenanntes Overfitting.

Aus diesem Grund ist eine Annotation der Daten in ähnlicher Art wie bei der menschlichen Bestimmung der Gattungen angewendet worden – da in der menschlichen Methodik das Vorwissen liegt. Das macht die Erkennung effizienter, weniger Daten werden benötigt und der Algorithmus wird in die richtige Richtung gelenkt.

Bei Laubhölzern nutzen Holzanatomen fast ausschließlich die Gefäßelemente zur Bestimmung, weil dieser Zelltyp die meisten Strukturmerkmale aufweist. Deshalb wurde auch das erste maschinell lernende System auf die Detektion dieser Zellen trainiert. Für die Annotation wurde die Zeiss-Software verwendet, da es keinen forschungstechnischen Erkenntnisgewinn für dieses Projekt hat, eine solche Software zu schreiben, gleichzeitig aber Expertise und Aufwand dafür nötig ist. Damit der Annotationsaufwand möglichst gering ist, wurden zunächst nur Reinproben erzeugt. Auf diese Art müssen lediglich die Gefäße markiert werden, d.h. eine Annotation der Klassen ist nicht notwendig, da alle Gefäße eines Bildes zur gleichen Klasse gehören. In Abbildung 1 ist der iterative Prozess der Annotation dargestellt. In einem ersten Schritt müssen jeweils wenige Proben „voll manuell annotiert“ werden. Mit Hilfe dieser Annotationen wird dann ein „Rechteckdetektor“ trainiert, der Vorschläge für zukünftige Annotationen macht. Auf diese Art müssen zu einem späteren Zeitpunkt die Vorhersagen (predictions) „nur“ noch „nachannotiert“, das heißt bestätigt oder ergänzt werden (predictions checked). Auf diese Art lässt sich wesentlich schneller als mit voll manueller Annotation eine große Datenbasis von annotierten Gefäßen erzeugen.

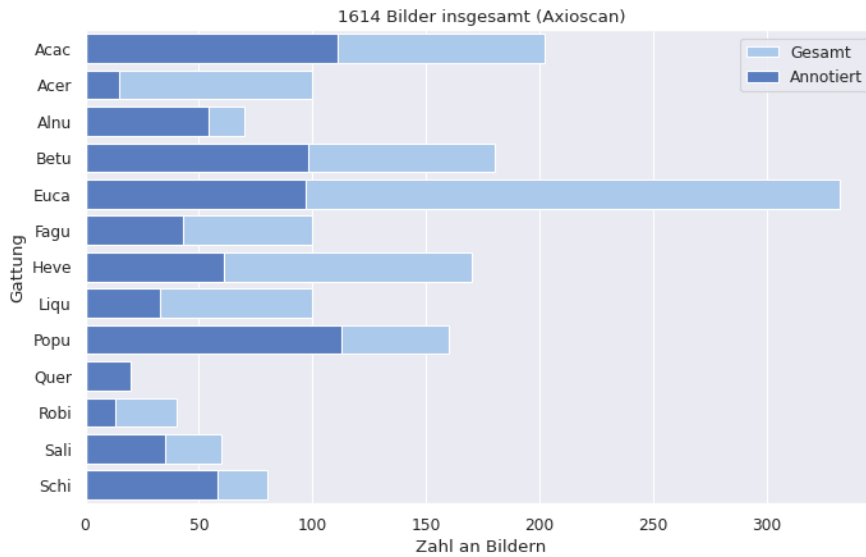


Abbildung 3 Die Anzahl der annotierten Laubholz-Bilddateien zu Projektende, die in die Entwicklung des Systems eingeflossen sind.

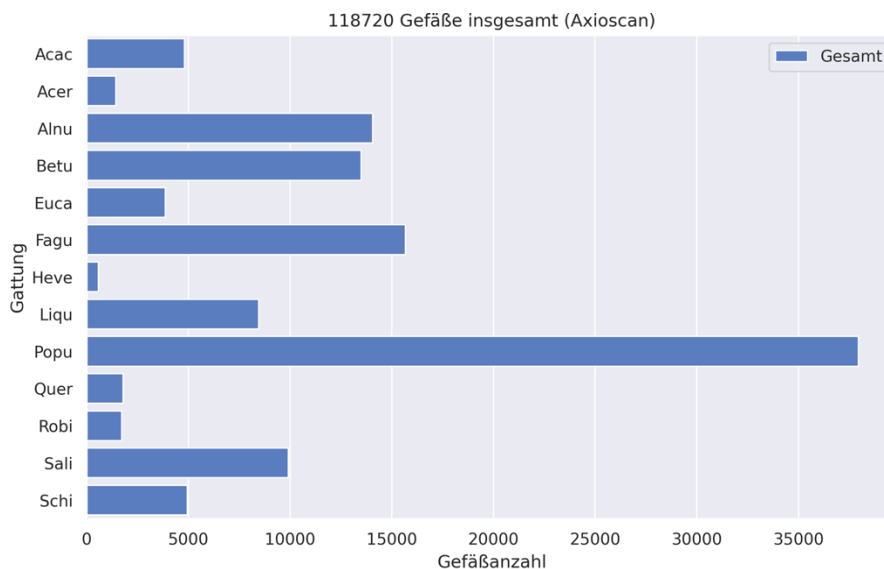


Abbildung 4 Die Anzahl der insgesamt annotierten Laubholzgefäße

In Abbildung 4 ist die Anzahl der insgesamt annotierten Laubholzgefäße zu sehen. Insgesamt sind es mehr als 118 000 Gefäße, die der Datensatz zu Projektende enthält und die zu einer guten Klassifikation und Detektion führen.

Beim Nadelholz war ursprünglich geplant, diesen Annotationsaufwand der Bilddaten durch ein ungeleitetes Training zu umgehen. Dies wird eingehender unter AP 6 erläutert.

Für die Erstellung einer großen Klassifikationsbasis können die beschriebenen Reinprobengefäße ohne weiteren Aufwand übernommen werden. Allerdings ist es sinnvoll, die Menge der Klassifikationsdaten so weit wie möglich zu erweitern. Insbesondere auch, um bestimmte vorhersehbare Änderungen – wie etwa jede beliebige Rotation oder bestimmte Färbungen – in die Datengrundlage mit aufzunehmen, wurden sogenannte Augmentierungsverfahren implementiert. Die Parameter wurden gemeinsam unter Berücksichtigung des Erhalts holzanatomischer Merkmale abgestimmt. Diese Verfahren sind implementiert und in die Machine-Learning-Software integriert (AP 6).

Die eingesetzten Augmentierungsalgorithmen sind in der folgenden Tabelle 2 aufgelistet:

Tabelle 2 Eingesetzte Augmentierungsalgorithmen

Augmentierung	Parameterbereich
Rotation	[-5,5]
Elastische Verzerrung	[0,100]
Strecken/Stauchen	[0.5, 2.0]
Gamma-Korrektur	[0.9, 1.1]
Multiplikativer Histogramausgleich	[0.0,1.0]
Kontrast	[0.8,1.2]
Helligkeit	[-.2, 0.2]
Gauss-Glättung	[0.001,1.0]
Gaußsches Rauschen	[0.0, 0.025]

Die durch Augmentierung generierten Daten wurden zu den Trainingsdatensätzen für Detektion und Klassifikation hinzugefügt.

Arbeitspaket 5: Implementierung einer Bilddatenbank (TI)

Es wurde eine Bilddatenbank auf Basis der Datenbanksoftware PostgreSQL implementiert. In der Datenbank wurden zusätzlich zu den Bildern auch für das Projekt generell relevante Informationen gespeichert. Hierzu gehörten die verwendeten Färbungen, Gattungen, Spezies, Mazeratnummern und Mikroskoptypen. Da große Dateien, wie zum Beispiel Bilder, üblicherweise nicht direkt in einer Datenbank gespeichert werden, wurde nur der Dateipfad für das jeweilige Bild hinterlegt. Zusätzlich kann der Datenbank entnommen werden, ob ein Bild zu den Trainingsdaten, den Mischproben oder den unbekanntenen Proben gehört.

Beim Ablegen der Bilder in der Datenbank wurde das zuvor entwickelte Dateinamenschema verwendet, um die wichtigsten Informationen zu einem Bild sofort in der Datenbank hinterlegen zu können. Beispielsweise ist die Mazeratnummer im Dateinamen enthalten, sodass in der Datenbank eine direkte Verknüpfung zu dieser erfolgen kann. Die restlichen Daten wurden anhand von csv-Dateien eingelesen. Hierzu gehörten beispielsweise die Mazeratnummern mit den zugehörigen Daten wie Gattung, Spezies, Probentyp und Herkunft.

Weiterhin musste hierzu eine eindeutige Identifikationsnummer für Bilder eingeführt werden. Wie geplant war dabei das Ziel, dass diese Identifikationsnummer auch für den Menschen lesbar sein sollte. Konkret wurde folgendes Namensschema für die Identifikation umgesetzt:

[4-Buchstabenkürzel für die Gattung]_[4-Buchstabenkürzel für die Art]_[1-Buchstabenkürzel für die Art der Präparation]_[Sammlungsnummer des Mazerats]_[1-Buchstabenkürzel für das verwendete Mikroskop]_[Vergrößerungsfaktor]_[1-Buchstabenkürzel der verwendeten Färbung]_[fortlaufende Bild-Nr.] . [Bildkennung]

Ein Beispiel wäre dann z.B. „Casu_equi_M_MZ0181_Zx005_Ni_17.jpg“

Dieser Dateiname steht für ein am Zeiss Axioscan 7 mit dem 5-fach Objektiv aufgenommenes Mazerat der Gattung *Casuarina* der Art *Casuarina equisetifolia*. Das Mazerat ist in der wissenschaftlichen Mazerat-/Zellstoff-Sammlung am Thünen-Institut unter der Nummer MZ0181 aufgenommen. Hier ist somit der genaue Bezug zu dem Holzstück, aus dem die Probe mazeriert wurde, hinterlegt. Das Präparat wurde mit Nigrosin gefärbt und das Bild trägt die fortlaufende Nummer 17.

Die Partitionierung in Trainings-, Validierungs- und Testdaten kann durch dieses Namensschema vollautomatisch durch die KI-Software vorgenommen werden.

Aufgrund des derzeit sehr hohen Speicherbedarfs der Mikroskopbilder wurde für die Bildablage ein Bildformat gewählt, welches den Speicherbedarf reduziert. Dazu bietet sich (nach einem Update der Zeiss-Software) das Zeiss-eigene Bildformat .dzi an. Da die Bilder auch für die Verwendung der KI in JPG-Dateien umgewandelt werden, bietet es sich an, die Bilder direkt in diesem zu hinterlegen. Dies hat den zusätzlichen Vorteil, dass die Umwandlung nur an einer zentralen Stelle stattfindet und nicht bei Bedarf an mehreren Stellen ausgeführt werden muss. Bei der Umwandlung ist zu beachten, dass für jede Fokusebene eine einzelne JPG-Datei entsteht. Eine Aufnahme ergibt also fünf JPG-Dateien. Trotz der erhöhten Dateianzahl wird der Speicherbedarf so deutlich reduziert. Zum Ende dieses Projektes konnten dann beide Formate (Zeiss und JPeg) verwendet werden.

Alle erstellten Bilder wurden in die Datenbank eingepflegt. Für das Speichern der Daten wurde eine Ordnerstruktur basierend auf den Gattungen, den Spezies und den Mazeratnummern erarbeitet, sodass es auch ohne die Datenbank möglich wäre, ein gesuchtes Bild zu finden.

Des Weiteren wurde eine Benutzeroberfläche für die Datenbankverwaltung entwickelt. Diese ermöglicht eine einfache Handhabung der Datenbank, indem hier Bilder hochgeladen oder spezifische Abfragen gestellt werden können. Derzeit ist es möglich, neue Trainingsdaten in die Datenbank zu importieren. Ebenso ist ein Import der in den csv-Dateien enthaltenen Daten möglich. Es wurden bereits mehrere Abfragen eingearbeitet, sodass zum Beispiel die Ausgabe aller Bilder und Mazerate zu einer vorgegebenen Gattung möglich ist. Die Webanwendung läuft – wie die Benutzeroberfläche des bisher entwickelten Bilderkennungssystems - auf dem für das Projekt angeschafften Server und ist nur für die interne Verwendung gedacht.

Arbeitspaket 6: Implementierung und Optimierung der Algorithmen (ITWM)

Das Arbeitspaket AP 6 umfasst die Implementierung diverser Algorithmen über einen längeren Zeitraum.

Forschungsschwerpunkt hier war die Entwicklung von KI-Algorithmen, insbesondere durch den Einsatz von tiefen neuronalen Netzen.

Da die genannten Methoden auf Daten basieren, war es unerlässlich, die Prozesse der Erkennung durch menschliche Experten (TI) zu verstehen. Dies war von entscheidender Bedeutung, um zu ermitteln, wie die Daten zu annotieren sind, damit die Lernverfahren zu äquivalenten Resultaten gelangen. Bei Erkennung der Holzarten durch die Experten (TI) zeigte sich bei Laubhölzern eine besondere Fokussierung auf die Gefäße. In Abbildung 5 ist dargestellt, wie das Problem, das im Projekt zu lösen war, zunächst anhand der derzeitigen best practice modelliert wurde.

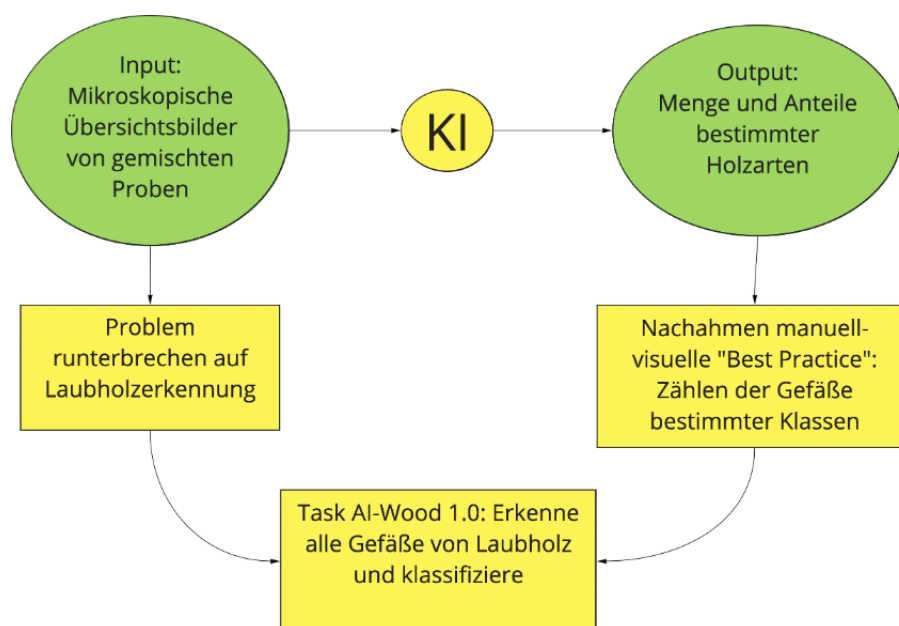


Abbildung 5 Algorithmus

Da die Holzanatominnen vom TI über die Klassifikation der Gefäße die entsprechenden Laubhölzer bestimmen, wurde ein analoger zweistufiger Ansatz gewählt, der in der folgenden Abbildung 6 in grün dargestellt ist:

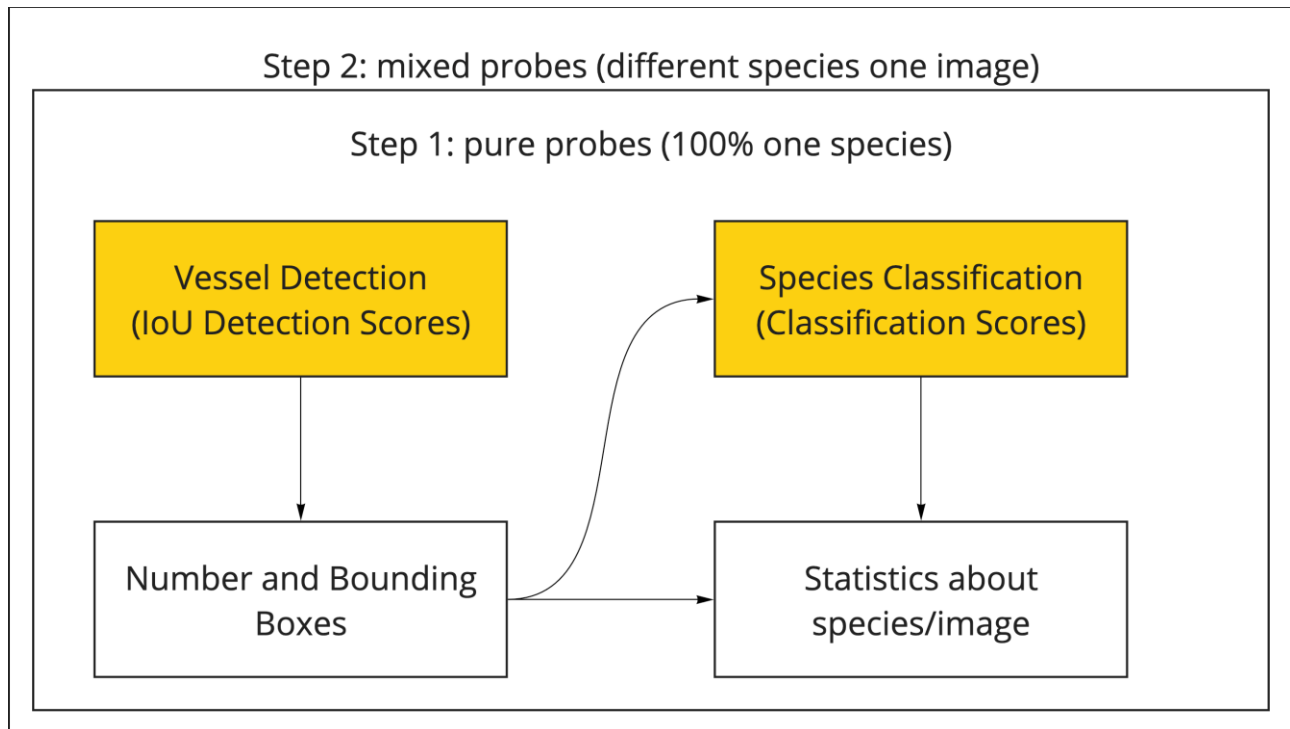


Abbildung 6 Zweistufiges Vorgehen in orange: Zunächst wird der Detektor trainiert und dann der Klassifikator. Zunächst nur mit reinen Proben, dann auch mit gemischten.

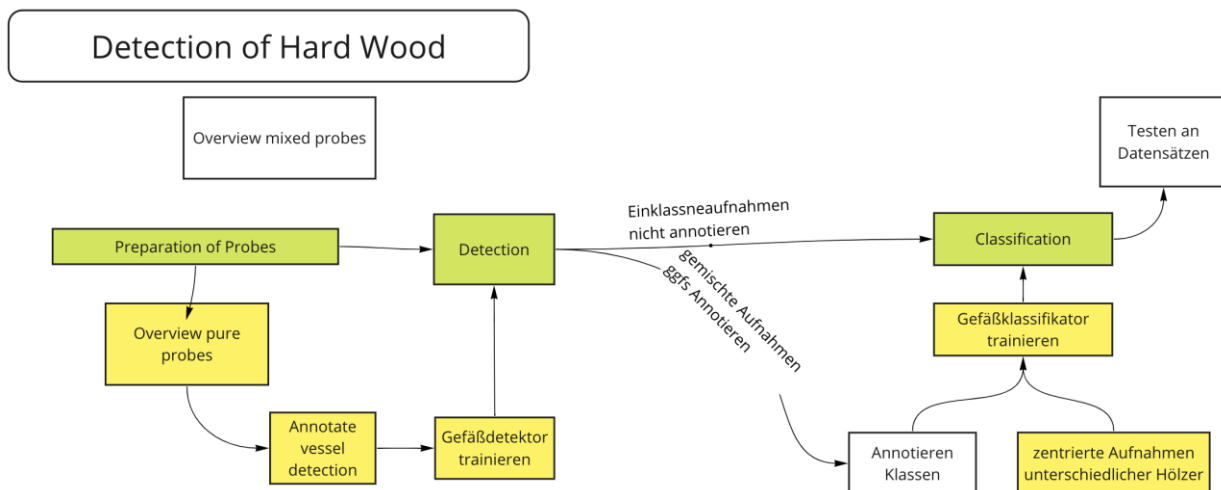


Abbildung 7: Vorgehen bei der Erkennung der Laubhölzer. In grün die Schritte, die beim Auftreten jeder Probe geschehen (automatisiert), in gelb die Trainings- und Annotationsschritte

1. Im ersten Schritt erfolgt die Erkennung der Gefäße (Detektion). Dies impliziert, dass unabhängig von der jeweiligen Holzart ein Algorithmus entwickelt wurde, der alle im Bild vorhandenen Gefäße auffindet und lokalisiert.
2. Im zweiten Schritt erfolgt die Klassifikation der Gefäße, wodurch die jeweilige Art identifiziert wird.

Der zweischrittige Ansatz gewährleistet zudem, dass auch gemischte Proben verschiedenen Arten zugeordnet werden können, entsprechend dem derzeitigen manuellen Vorgehen. Ein typisches Ausgabebild ist in Abbildung 12 zu sehen.

Detektion

Für die Detektion wurde ein neuronales Netz verwendet, das dem aktuellen Stand der Technik entspricht (YOLOV7). Für die Evaluierung findet die sogenannte "Mean Average Precision" (mAP) Anwendung. Die Kennzahl bezeichnet eine Mischung aus der Detektionsgenauigkeit (Precision) und dem Detektionsumfang (Recall). Die erzielten Werte liegen hierbei über 70 %. Die Korrekturen durch die Holzanatomen beziehen sich häufig auf mehrfache Markierung einer Zelle. Deshalb sind die einzelnen Boxen nicht immer im eigentlichen Sinne falsch, sondern erfassen ein Gefäßelement vielleicht in zwei Boxen jeweils zur Hälfte und in einer weiteren als Ganzes.

Klassifikation

Weiterhin wurden verschiedene State-of-the-Art-neuronale Netze eingesetzt, um ein möglichst gutes Klassifikationsergebnis zu erzielen. Die verwendeten Netzwerke sind EfficientNets unterschiedlicher Tiefe, DenseNet-121, ResNet sowie ConvNeXt-tiny. Die Darstellung der Klassifikationsergebnisse erfolgt durch eine sogenannte Confusion Matrix (Abbildung 10). Diese verdeutlicht, welche Gattungen wie gut erkannt werden (Diagonale) und welche Gattungen verwechselt werden. Die Resultate sind als außerordentlich zufriedenstellend zu bewerten. Gattungen, die bei den KI-Methoden eine geringe Differenzierung aufweisen, sind solche, die sich anatomisch so ähnlich sind, dass eine Differenzierung anhand der Holzanatomie auch nur eingeschränkt möglich ist. Zudem muss beachtet werden, dass auch Holzanatomen eine Holzgattung als in einer Probe enthalten einstufen, wenn sie mehrere Gefäßelemente dieser Gattung in einer Probe erkennen, da nicht jedes Gefäßelement alle erforderlichen Strukturmerkmale aufweist. Dass es lediglich zwischen den auch von den Holzanatomen als ähnlich eingestuften Gattungen zu Verwechslungen kommt, bestätigt, dass die KI-Entscheidungen auf den klassischen Strukturmerkmalen basieren und nicht auf unbeabsichtigten Unterschieden in den Datensätzen der einzelnen Klassen (Leakage-Effekt).

Optimierungen und Implementierungsdetails

Im Bereich der Detektion wurde zunächst insbesondere die notwendige Auflösung für eine gute Detektion evaluiert. Da die Detektion immer auf den gesamten Übersichtsaufnahmen ausgeführt wird (Bildgröße bis zu 20T Pixel), spielt die Auflösung eine entscheidende Rolle in der Performanz. In Abbildung 8 sind die evaluierten Auflösungen aufgezeigt mit Ihrem F2 Score (Ein Maß, das dem Recall ein größeres Gewicht gibt). Wir sehen, dass zunächst mit einer steigenden Auflösung die Detektionsqualität zunimmt, dann aber stagniert. Daher macht es keinen Sinn, mehr Rechenleistung zu nutzen als notwendig.

Image Size	F2 Score
1024	0.7863
2048	0.8316
4096	0.8243

Abbildung 8 Unterschiedliche Auflösungen führen zu unterschiedlichem F2 Score . Man sieht einen starken Anstieg der Qualität bis zu 2048 Pixel, danach sinkt die Qualität wieder langsam.

Architecture	F2 Score
YOLOv10-S	0.691
YOLOv10-M	0.719
YOLOv7-W6	0.783
YOLOv7-tiny	0.723
Ours	0.848

Weiterhin wurden Änderungen an der Implementierung von der State-of-the-art-Lösung YOLOv7 implementiert. Zwar wurden bereits gute Ergebnisse mit YOLOv7 erzielt (78%), aber es gab immer noch Fälle, in welchen die Erkennung fehlgeschlagen ist. Da wir bei der Detektion insbesondere an Recall

interessiert sind, haben wir eine neue YOLO-Variante namens WoodYOLO entwickelt. Bei YOLOV7 wird mAP optimiert, sodass Precision und Recall gleich wichtig sind. Mit WoodYOLO haben wir einen Algorithmus geschrieben, der darauf optimiert ist, den Recall zu maximieren. Hintergrund ist, dass wir false positives in einem Nachverarbeitungsschritt aussortieren können. Mit der neuen Herangehensweise nutzen wir das Evaluationsmaß "F2 Score". Hier konnten wir gegenüber YOLOv7 und YOLOv10 bis zu 12.9% höhere Werte erzielen. In unserer Arbeit WoodYOLO erreichen wir einen F2 Score von 84.8%, während YOLOV7-tiny lediglich 72.3% erreicht, die Arbeit wurde im Journal Forests (siehe unten) veröffentlicht.

Zur Optimierung der Algorithmik wurden im Laufe des Projektes zwei Maßnahmen ergriffen:

1. Eine Erhöhung der Datenmenge wurde vorgenommen
2. Der Klassifikator wurde um eine "Hintergrundklasse" erweitert. Dies impliziert, dass der Klassifikator nicht zwangsläufig eine Entscheidung für eine der Gattungen treffen muss, sondern auch die Möglichkeit besteht, dass er ein Gefäßelement als solches nicht anerkennt. Dies ist insbesondere von Relevanz, da der erste Schritt der Detektion bei einer wesentlich niedrigeren Auflösung erfolgt und von uns so konfiguriert wurde, dass falsch positive Ergebnisse toleriert werden, während weniger richtige positive Ergebnisse übersehen werden. Die als falsch positiv identifizierten Fälle können nun im Klassifikator, der die kleinen, vom Detektor ausgewählten Bildausschnitte in voller Bildqualität analysiert, mit höherer Zuverlässigkeit herausgefiltert werden.

Die Resultate der aktuellen Klassifikation, welche auf einem Training mit elf Laubholzgattungen basiert, sind in Abbildung 9 in Form einer sogenannten Confusion Matrix dargestellt. Für die Detektion wurde unser Verfahren WoodYolo verwendet. Desweiteren wurden verschiedene Experimente hinsichtlich der Nutzung der sogenannten Hyperparameter gemacht.

Erklärbarkeit

Bei der Entwicklung eines Klassifikators mit datenbasierten Methoden muss genau darauf geachtet werden, dass das Verfahren die „richtigen“ Eigenschaften lernt. Insbesondere bei Daten, die durch Präparationsart, -dichte, -färbung usw. beeinflusst sein können, ist es daher wichtig, eine möglichst unabhängige Trainings-Validierungs- und Testdatenbasis zu haben. In diesem Sinne wurde für alle relevanten Arten bei der Erstellung des Datensatzes darauf geachtet, mindestens drei Mazerate pro Gattung zur Verfügung zu stellen. Dies ist in Abbildung 9 dargestellt. Hier sieht man, dass der Datensatz im letzten Projektjahr gezielt vergrößert wurde.

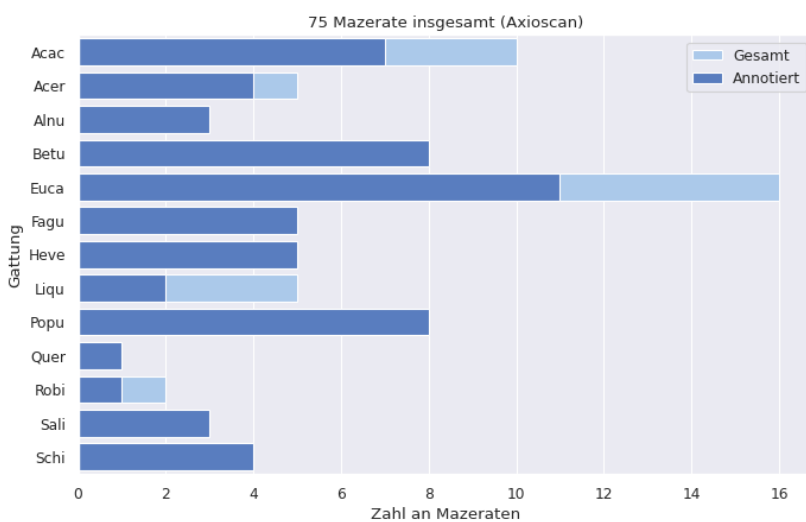


Abbildung 9 Jede Gattung wird durch mindestens drei unabhängige Mazerate repräsentiert, um in Ansätzen die Varianz innerhalb der Gattungen abzubilden. Annotiert bedeutet hier, dass von dem jeweiligen Mazerat mindestens vier Bilder annotiert sind.




Abbildung 10 Confusion Matrix der Klassifikation von 11 Gattungen (im Vergleich zu vorher 9). Die korrekten Vorhersagen sind in der Diagonalen ablesbar und proportional zum Resultat in der Intensität der Blautöne kodiert

Die Ergebnisse sind bereits in einer Journal-Veröffentlichung enthalten (DOI: 10.1093/mam/ozae038).

Da wir zur Erkennung der Holzarten KI-Verfahren einsetzen, ist es wichtig, die Erklärbarkeit kritisch zu hinterfragen. Da in KI-Verfahren in der Regel tausende bis Millionen Parameter optimiert werden, kann eine menschlich verstehbare Kausalität oft nur schwer hergestellt werden. Aus diesem Grund haben wir mit sogenannten „Attribution Maps“ gearbeitet (ITWM). Diese sollen bei der genutzten KI-Methode den neuronalen Netzen die Regionen aufzeigen, die für Klassifikationsentscheidungen besonders wichtig sind. Hier wurden Vergleiche verschiedener Methoden angestellt. Am TI wurden zudem in ausgewählten Bildern die Bildregionen, die besonders relevant für die menschliche Klassifikation sind, markiert. Diese dienten als sogenannte Ground Truth zum Abgleich der verschiedenen Verfahren. In Abbildung 11 sieht man drei unterschiedliche Verfahren (oben und unten links) zur Darstellung dieser wichtigen Regionen in einem Laubholzgefäß. Die Karte zeigt zwar, dass ähnliche Regionen wie von menschlichen Experten zur Klassifikation betrachtet zu werden scheinen, allerdings zeigen sie doch große Unterschiede auf. Aus diesem Grund wurde hier eine Veröffentlichung zum Vergleich dieser Methoden realisiert (VISIGRAPP 2024, DOI:10.5220/0012363400003660).




Abbildung 11 Darstellung von 3 "Attribution Maps" anhand eines Gefäßes zur Darstellung der wichtigen Klassifikationsregionen, sowie einer menschlichen Annotation (unten rechts)



Abbildung 12 Ein typisches Ergebnisbild der KI-Verfahren. Jedes gefundene Gefäß wird umrandet. Die Klassifikation jedes Gefäßes wird über den Rechtecken in Kurzform angezeigt. Optional kann noch die Klassifikationswahrscheinlichkeit dargestellt werden.

Nadelhölzer

In den letzten Monaten des Projektes wurde auch mit der Erkennung von Nadelhölzern begonnen. Diese ist algorithmisch schwieriger, da Nadelhölzer nicht anhand der Gefäße, sondern anhand bestimmter Merkmale auf den Tracheiden (Kreuzungsfelder) erkannt werden. Jede einzelne Zelle dieses in Nadelhölzern am häufigsten vorkommenden Zelltyps kann diese Merkmale aufweisen. Allerdings enthalten viele der Zellen diese Merkmale auch nicht. Aus diesem Grund sind eine Markierung und Annotation der Daten sehr aufwendig. Der Suchraum ist wegen dieser undefinierten Eigenschaften kaum einschränkbar. Aus diesem Grund wurde zunächst erprobt (ähnlich wie auch am Anfang bei den Laubhölzern) mit Reinproben ohne Annotation zu arbeiten. Das bedeutet, die Bilder werden in kleine Abschnitte geteilt und dann Nadelholzreinproben und Laubholzreinproben als Trainingsmaterial (in kleinen Abschnitten) genutzt und dann Laub- und Nadelholz zur Testung voneinander getrennt. Der Klassifikator unterteilt dann das Bild in kleine Teile.

Das Bild wird dann mit einer Art Schiebefenster mit Überlappung abgetastet (Abbildung 13). An den Rändern jedes Feldes ist manchmal nur die Hälfte der Objekte sichtbar, während sich der zweite Teil in einem anderen Feld befindet. Daher entfernen wir bei der Vorhersage Objekte in der Nähe des Randes. Dann ist jedes Feld für genau eine disjunkte Menge von Objekten verantwortlich.




Abbildung 13 Beispiel für die Aufteilung eines Bildes in vier Teile mit fünf zusätzlichen Feldern (patches) zur Bearbeitung von Objekten, d.h. Gefäßen an den Rändern

Dieser erste sehr generische Ansatz hat auf Trainings- und Testbildern zu zufriedenstellenden Ergebnissen geführt, allerdings konnte dieser Ansatz nicht ausreichend generalisieren. In Abbildung 14 ist zu sehen, dass ein großer Teil nicht klassifizierbar ist (also Hintergrund). Das entspricht zwar der Realität, allerdings handelt es sich hier um ein reines Laubholzbild und dennoch sind substantielle Bildteile grün, also als Nadelholz klassifiziert.




Abbildung 14: Fensterbasierte Klassifikation der einzelnen Bildteile in einem mikroskopischen Bild von Laubholzzellen. In rot Hintergrund, in grün Nadelholz, in blau Laubholz

Obwohl der Ansatz, das Bild im Ganzen zu klassifizieren, vielversprechend scheint, ist er doch für diesen Anwendungsfall zu instabil.




Abbildung 15 Nadelhölzer aufgeteilt nach Trainingsdaten (grün), Validierungsdaten (rot), und Testdaten (hellgrün)




Abbildung 16 Aufteilung der Bilder nach Gattung und Art. Die meisten Arten sind nur durch ein Mazerat repräsentiert

Der Versuch ohne Annotation, nur mit Hilfe von reinen Stichproben, eine ausreichend gute Klassifikationsleistung zu erreichen, erwies sich bei der vorliegenden Datenlage als zu wenig stabil. Dies liegt vor allem daran, dass die gesuchte Information sehr dünn im Bild verteilt ist. Im Falle der Laubhölzer ist die Information zwar auch dünn gestreut, aber durch den zweistufigen Ansatz bekommt die KI schon einen Hinweis, wo sie genau hinschauen soll. Sie konzentriert sich nicht auf das gesamte Bild, sondern nur auf die Gefäße. Bei Nadelhölzern ist diese Lokalisierung noch wesentlich schwieriger, da nur ein Teil der Tracheiden in nur einem Teil der Fokusebenen diskriminierende Informationen enthält. Wenn der Suchraum so klein ist, sind enorme Datenmengen erforderlich, um zufriedenstellende Ergebnisse zu erzielen.

In einem solchen Fall ist es sinnvoll, die KI mit Hilfe der Annotation auch bei Nadelhölzern auf bestimmte charakteristische Stellen hinzuweisen. Hier wurden begonnen für die ersten ausgewählten Regionen insbesondere Kreuzungsfelder und Hoftüpfel für die KI zu markieren, d.h. in einem Teil der in Abbildung 16 dargestellten Bilder wurden diese besonderen Merkmale klassifiziert. In Abbildung 15 sind die markierten Regionen einzeln aufgeführt. Mit diesem Trainings-/Testdatensatz wurden verschiedene Experimente durchgeführt. Wie in Abbildung 15 zu sehen ist, wurde er in Trainings- und Validierungsdaten aufgeteilt und eine KI mit dieser Aufteilung trainiert.

Es konnten z.T. vielversprechende Ergebnisse erzielt werden. Allerdings konnten diese noch nicht ausreichend validiert werden. Um sicherzustellen, dass die KI die richtigen Merkmale lernt (und nicht Hintergrundigenschaften wie Färbung, Präparationsmerkmale usw.), haben wir auch Experimente durchgeführt, bei denen die Trainings- und Validierungsdaten bei der Klassifikation nach Gattung komplett nach Mazeraten aufgeteilt wurden. Hier konnten wir eine sehr schlechte Generalisierung beobachten. Das bedeutet, dass die KI aus dem Trainingsdatensatz nicht gelernt hat, wie sie den Validierungsdatensatz aufteilen soll.

Bei genauer Betrachtung fällt allerdings auf, dass die Mazerate der Gattungen zum Teil unterschiedliche Arten repräsentieren. Das bedeutet, die Generalisierung funktioniert eventuell einfach bei so geringen Daten nicht über Art-Grenzen hinweg. Bei der Nadelholzklassifikation sind also bereits vielversprechende Ergebnisse vorhanden, allerdings müssen hier weitere Methoden entwickelt werden, um eine gute Generalisierung einer KI für Nadelhölzer erreichen zu können. Dies wird in dem bereits begonnenen Anschlussprojekt erfolgen.

Arbeitspaket 7: Implementierung von Systemsoftware und Benutzerschnittstelle (ITWM)

Für die Entwicklung der Trainingssoftware wurden zu Beginn sogenannte jupyter notebooks (Abbildung 17) verwendet, anhand derer sehr flexibel und interaktiv entwickelt werden kann.

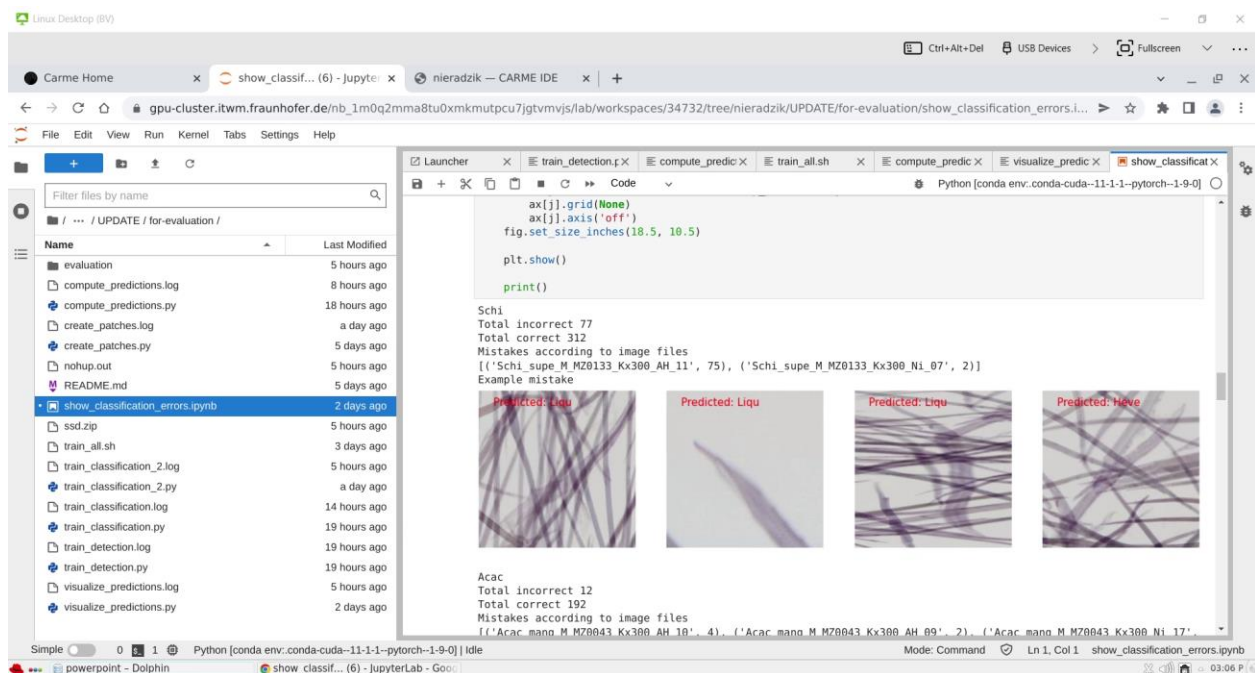


Abbildung 17 Screenshot der Entwicklungsumgebung (jupyter notebooks)

Außerdem können state-of-the-art Methoden problemlos über python eingebunden werden. Für Annotationen und die Überprüfung der Ergebnisse kam die Benutzeroberfläche von Zeiss zum Einsatz:

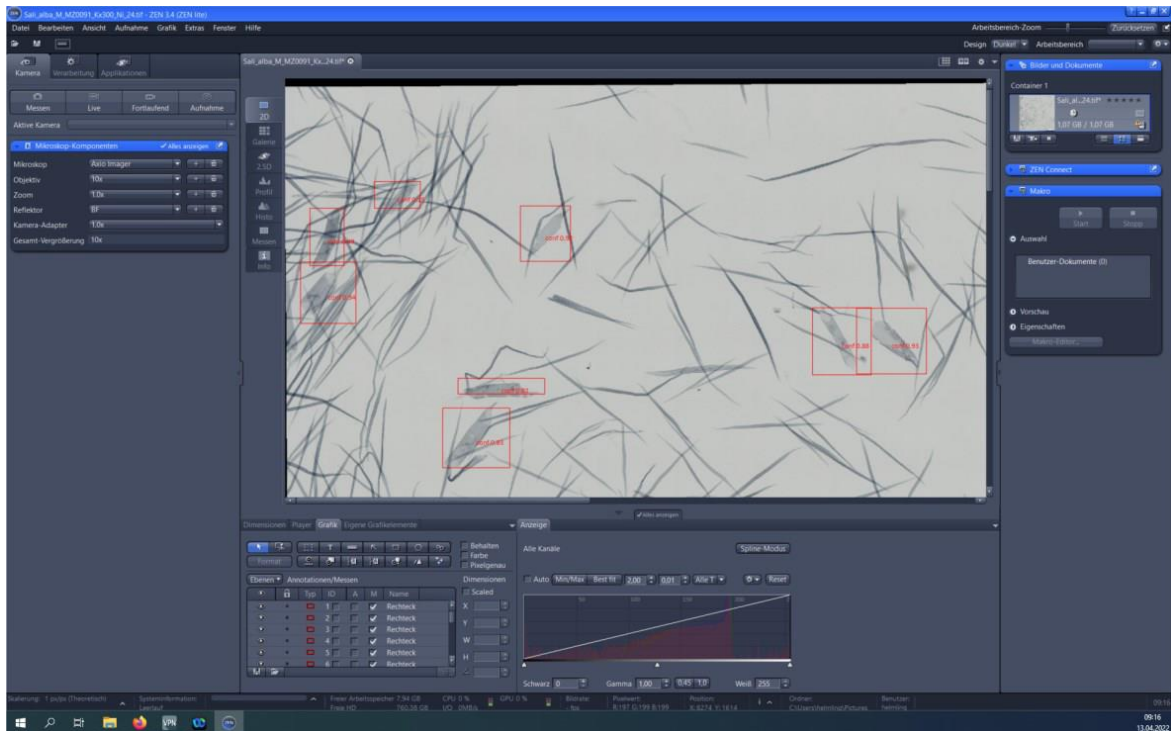


Abbildung 18 Die Zeiss-eigene GUI wurde zur Annotation eingesetzt.

Für die letztendliche Nutzung wurde eine graphische Benutzeroberfläche (GUI) entwickelt, die in Abbildung 20 dargestellt ist. Diese GUI ist interaktiv gestaltet, so ist es z.B. möglich, sowohl die Erkennungsqualität über einen Schwellwert als auch die Klassifizierungsqualität anzupassen. Für diese Schwellwerte werden die direkten Wahrscheinlichkeiten der KI-Verfahren verwendet, d.h. Detektion und Klassifikation liefern Werte, die eine gewisse Sicherheit in der Erkennung oder Klassifikation widerspiegeln (Abbildung 19). So kann der Nutzer nachträglich in beide Verfahren eingreifen.




Abbildung 19 Das Bild zeigt die von der KI zurückgelieferten Wahrscheinlichkeiten zur Klassifikation der Gefäße. Diese Werte können das Ergebnis durch Schwellen verändern. Hier ist die Schwelle 0,95 (95%). D.h. alle Klassifikationen mit einer Wahrscheinlichkeit > 0,95 werden als **sichere** Klassifikation definiert. Alle Werte darunter als **unsicher**.

Dadurch wird ein interaktives Arbeiten mit der Software ermöglicht, was eine Anpassung an die jeweilige Erkennungssituation erlaubt und auch dem Anwender ein Gefühl für die KI-Lösung und damit eine gewisse Nachvollziehbarkeit gibt.

Auf der linken Seite sind die Dateinamen der hochgeladenen Übersichtsaufnahmen zu sehen, die interaktiv ausgewählt werden können. In der Mitte ist die Aufnahme selbst zu sehen, zunächst ohne detektierte und markierte Gefäße. Sobald darunter „Detect“ angeklickt wird, analysiert das erste KI-Modell, in welchen Regionen die für die Laubholzerkennung wichtigen Gefäße sichtbar sind und markiert diese. Wird anschließend der Button „Classify“ angeklickt, identifiziert das zweite KI-Modell, welcher Holzart diese zugeordnet werden kann und wie hoch die Konfidenz (= Wahrscheinlichkeit der Übereinstimmung) ist. Die aktuellen Versionen der Benutzeroberfläche werden prototypisch auf dem TI-Server implementiert und im Vor-Ort-Einsatz am Thünen-Institut getestet. Das daraus resultierende Feedback fließt direkt in die Weiterentwicklung der Benutzeroberfläche am ITWM ein.

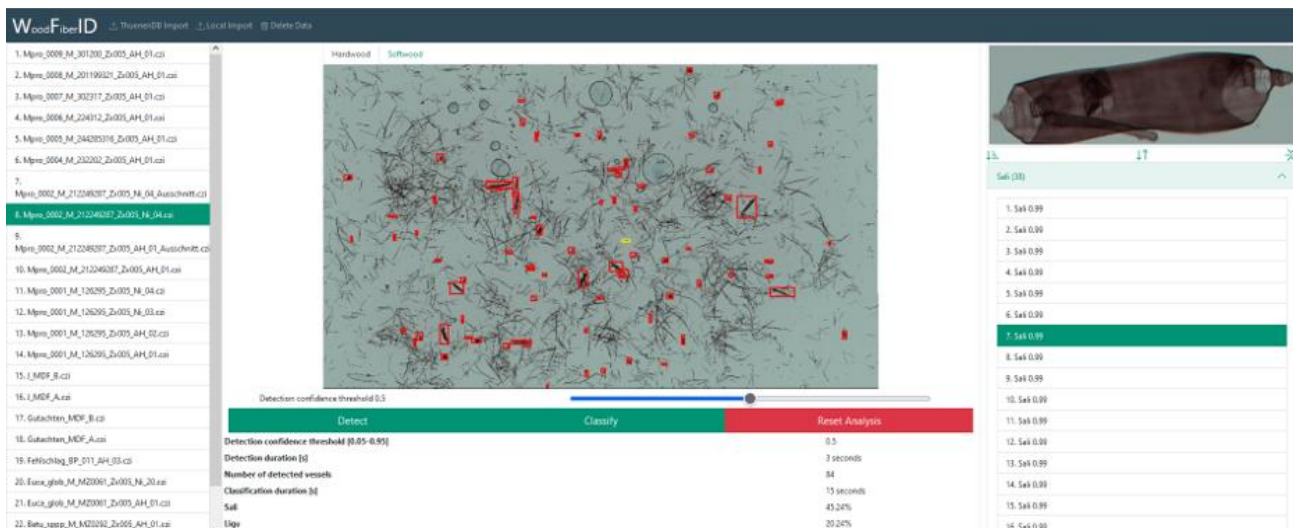


Abbildung 20 Graphische Benutzeroberfläche (GUI) für die Klassifikation von Holzgattungen in Übersichtsaufnahmen

Für die Bilddatenbank wird PostgreSQL verwendet, wobei die Bilddaten selbst nicht in der Datenbank liegen, sondern nur Verweise auf diese. Dies macht es besonders einfach, sich die Bilddaten mit externen Tools anzuschauen. In Abbildung 21 ist der Aufbau der Datenbank mit Metadaten und Kommunikationswegen beschrieben. Aktuell spiegelt die WoodFiberID-Datenbank die spätere Thünen-Datenbank, um Änderungen während der Entwicklung testen zu können, ohne die Datenbank am Thünen-Institut zu gefährden. Neben den Bilddaten werden auch die Analyseergebnisse in der Datenbank abgelegt.

Data Flow

Goal

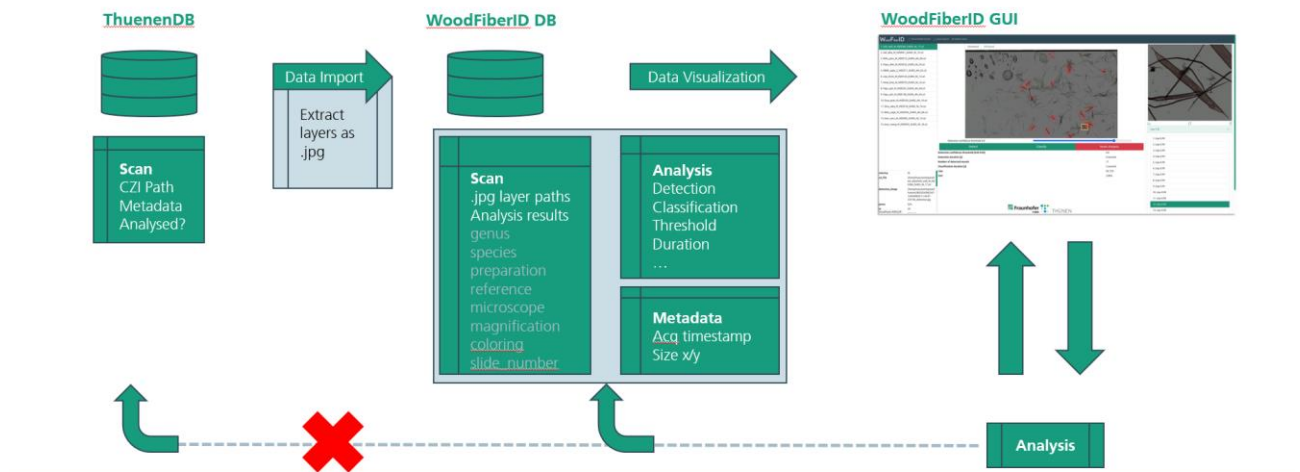


Abbildung 21 Aufbau der Datenbank und Kommunikation mit Nutzeroberfläche

Systemsteuerung

Die Systemsteuerung wurde in Form eines einfachen Webservice implementiert. Sie ist für das Zusammenspiel zwischen Algorithmik und Benutzerschnittstelle zuständig.

Es wurde deshalb ein Service implementiert, der über einen eigenen Webserver verfügt, der für die Kommunikation mit dem Benutzer und die Ausführung der Algorithmen verantwortlich ist.

Die Kommunikation zwischen Web-GUI und Service erfolgt über die REST-API (Representational State Transfer). Im Prinzip ist der Ablauf wie folgt (Abbildung 22):

1. Die GUI speichert alle vom Benutzer definierten Parameter in der SQL-Datenbank sowie eine Referenz auf die Eingabedaten und generiert einen eindeutigen Schlüssel für den Zugriff auf die Datenbank (UUID). Technisch wird dies durch einen Aufruf von der GUI im Webserver durchgeführt. Dieser überträgt dann die Parameter an den Client der wiederum die Analyse durchführt.
2. Wenn der Benutzer die Analyse startet, sendet die Benutzerschnittstelle eine http-Anfrage über REST an den Webserver des Dienstes. Die UUID wird als Parameter übergeben. Der Service liest mittels SQL alle Parameter und Eingabedaten ein und führt die Analyse durch. Die Analyseparameter werden durch ein Kommunikationsmodul übertragen.
3. Die Ergebnisse werden vom Service über die eindeutige Kennung in die Datenbank zurückgeschrieben (SQL).
4. Die Benutzerschnittstelle erhält vom Service über REST eine http-Response und kann nun die Ergebnisse über SQL lesen und anzeigen.

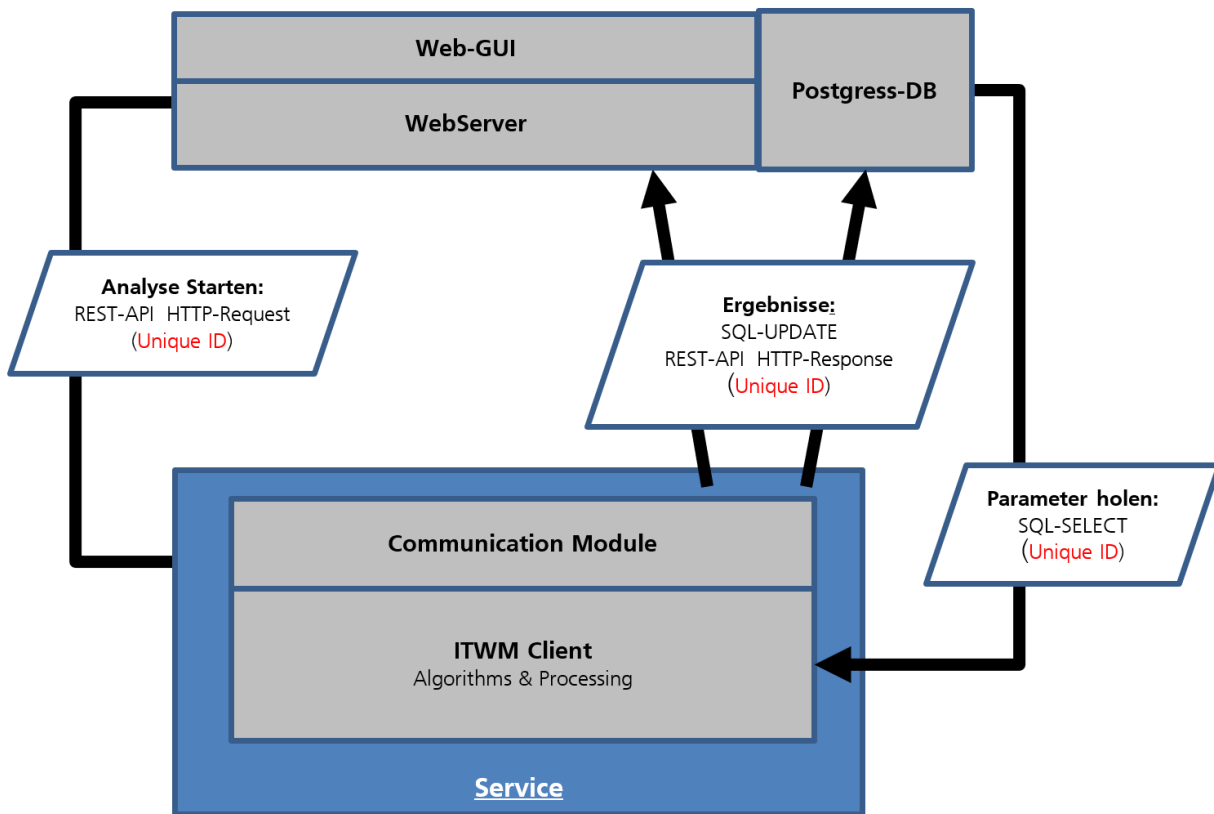


Abbildung 22 Aufbau von Systemsoftware und GUI

Arbeitspaket 8: Analyse von Mischproben (TI und ITWM)

In einem ersten Ansatz wurden 4 Bilder mit Mischproben erzeugt: (1) *Eucalyptus-Acacia* und (2) *Acacia-Fagus*, (3) *Liquidambar-Schima* und (4) *Salix-Populus*. Jede der vier Proben enthielt zwei unterschiedliche Gattungen, die für die Holzanatom*innen entweder sehr leicht (1 und 2) oder kaum bis gar nicht (3 und 4) zu unterscheiden sind. Die KI erzielte bei der Identifizierung gute Ergebnisse bzw. hatte bei der Unterscheidung sehr ähnlich aussehender Gattungen (Verwechslungspartner) die gleichen Schwierigkeiten wie die Holzanatom*innen. Eine Kontrolle der Klassifizierungen einzelner Gefäßelemente war bei den ähnlich aussehenden Gattungen nicht möglich.

Darüber hinaus wurde ein kompletter Satz von 9 Mischproben in verschiedenen Kombinationen von Laubholz und Nadelholz vorbereitet. Die unterschiedlichen Kombinationen können der Tabelle 3 entnommen werden. In diesen Mischungen waren jeweils 8 unterschiedliche Laubhölzer und 5 unterschiedliche Nadelhölzer enthalten. Die o.g. Verwechslungspartner wurden in diesem Fall nicht zusammengemischt. An den gescannten Bildern der Präparate wurden sowohl Laubholzgefäße als auch erste diagnostisch wichtige Regionen (Tüpfel) der Nadelholzzellen annotiert. Somit konnten auch erste Ansätze zum Training eines KI-Modells zur Differenzierung von Laub- und Nadelholz in den Bildern der Mischpräparate erprobt werden. Die Beurteilung des Erfolges der Klassifikation einer Mischprobe ist nicht trivial, da keine großflächige Annotation vorhanden ist. Insbesondere können keine Evaluationszahlen erzeugt werden. Die Mischproben haben daher zu einer grundsätzlichen Validierung der Ansätze gedient. Die Methoden erzeugten in diesen Proben grundsätzlich sinnvolle Ergebnisse. Eine genauere Einschätzung erfolgte mit dem Blindtest (AP 9).

Tabelle 3 Kombination der Mischproben

Lfd. Nr.	Gattung/Art 1	Gattung/Art 2	Gattung/Art 3	LH/NH
MP_001	<i>Acacia</i>	<i>Hevea</i>		LH
MP_002	<i>Salix</i>	<i>Eucalyptus</i>	<i>Schima</i>	LH

MP_003	<i>Betula</i>	<i>Schima</i>	<i>Eucalyptus</i>	LH
MP_004	<i>Eucalyptus</i>	<i>Pinus radiata</i>		LH-NH
MP_005	<i>Populus</i>	<i>Hevea</i>	<i>Picea</i>	LH-NH
MP_006	<i>Fagus</i>	<i>Cunninghamia</i>		LH-NH
MP_007	<i>Pinus taedae</i>	<i>Picea</i>		NH
MP_008	<i>Pinus sylvestris</i>	<i>Picea</i>	<i>Pseudotsuga</i>	NH
MP_009	<i>Abies</i>	<i>Pseudotsuga</i>		NH

Arbeitspaket 9: Blindtest (TI und ITWM)

Für die Blindtestproben wurden die Mazerate von 9 Laubholzgattungen (*Acacia*, *Betula*, *Eucalyptus*, *Fagus*, *Hevea*, *Liquidambar*, *Populus*, *Salix*, *Schima*) und von 5 Nadelholzgattungen (*Abies*, *Cunninghamia*, *Picea*, *Pinus*, *Pseudotsuga*) in unterschiedlichen Zusammensetzungen zusammengemischt (Tabelle 4).

Tabelle 4 Zufällige Zusammensetzungen der unterschiedlichen Blindtestproben

	1	2	3	4	5	6	7	8	9	10	11	12
Abies			x				x			x		
Acacia			x					x	x			
Betula						x					x	
Cunninghamia			x	x						x		
Eucalyptus								x				x
Fagus		x			x							
Hevea				x	x				x			
Liquidambar	x	x									x	
Picea					x		x					
Pinus						x				x		
Populus	x	x						x			x	
Pseudotsuga					x		x			x		
Salix			x					x				
Schima	x			x		x						x

Insgesamt wurden 12 Blindproben hergestellt. Für die Blindtestproben wurden die Mazerate (= individuelle Proben) von 9 Laubholzgattungen und von 5 Nadelholzgattungen ausgewählt, die nicht für das Training der KI-Modelle eingesetzt worden waren. Die Zusammensetzungen der Blindproben wurden zufällig durch ein selbstgeschriebenes Skript geplant, in dem bestimmte Kriterien festgelegt waren. So wurden 6 reine Laubholz-, 2 reine Nadelholz- und 4 Laubholz-Nadelholz-Proben aus max. 4 unterschiedlichen Gattungen ermittelt. Alle Gattungen (Mazerate) sollten mindestens einmal in einer Blindprobe enthalten sein. Die Verwechslungspartnerpaare *Populus/Salix* und *Liquidambar/Schima* mussten mindestens einmal zusammen und einmal allein in einer Probe vorkommen.

Nach der ermittelten Zusammensetzung wurden die 12 Blindproben von technischen MitarbeiterInnen am Thünen Institut aus den Mazeraten gemischt und für jede Probe jeweils drei Objektträger mit den zwei unterschiedlichen Färbungen präpariert. Für die Analyse durch die KI-Modelle wurden alle Objektträger nach dem für die Erfassung der Trainingsdaten entwickelten Scanprotokoll eingescannt. Parallel haben sechs WissenschaftlerInnen des Thünen-Instituts, die die Zusammensetzung der Proben nicht kannten, unabhängig voneinander analysiert. Ihnen stand für die Untersuchung jeweils ein Objektträger der zwei Färbungen für jede Blindprobe zur Verfügung. Die Auswertung des Blindtests durch die WissenschaftlerInnen erfolgte somit über

die mikroskopische Untersuchung von zwei Objektträgern und der Erfassung einer Auflistung der insgesamt erkannten Gattungen. Dies entspricht der etablierten Praxis.

Laubholzauswertung

Die im Projekt entwickelten KI-Modelle zur Laubholzerkennung wurden auf alle Präparate angewandt. Die Ergebnisse wurden als tsv- und cz-Datei ausgegeben. In der tsv-Datei ist jede Struktur, die in den einzelnen Bilddateien als Gefäßelement erkannt wurde, durchnummeriert (Index) aufgelistet mit den Koordinaten im Bild, den Kennwerten der Detektion zur Objektwahrscheinlichkeit und den zu den einzelnen Gattungen errechneten Konfidenz-Werten. Zur visuellen Darstellung in der Zeiss-Software dient die cz-Datei. Damit können in der jeweiligen Bilddatei die Bounding Boxes um die als Gefäßelement erkannten Regionen mit den wichtigsten Informationen angezeigt werden (Index, Kürzel der Gattung mit höchstem Konfidenz-Wert = identifizierte Gattung und dessen Konfidenz-Wert).

Bei der Analyse der Bilder durch die Laubholz-KI-Modelle ist der erste entscheidende Schritt die Detektion der Gefäßelemente. Werden diese Zellen nicht korrekt erkannt, könnten selektiv Gattungen "übersehen" werden (falsch negativ). Werden Regionen detektiert, die keine Gefäßelemente enthalten, durchläuft der Bildausschnitt die Klassifikation. Da hier aber kein Gefäßelement enthalten ist, werden hier sprichwörtlich Äpfel mit Birnen verglichen und entsprechend schlechte Ergebnisse erzielt (Abbildung 23). Entsprechend wurde auf die Detektion aufbauend eine Objektwahrscheinlichkeit berechnet und ausschließlich Regionen ausgewertet, die mit höherer Wahrscheinlichkeit als 70% als Gefäßelement eingestuft wurden.

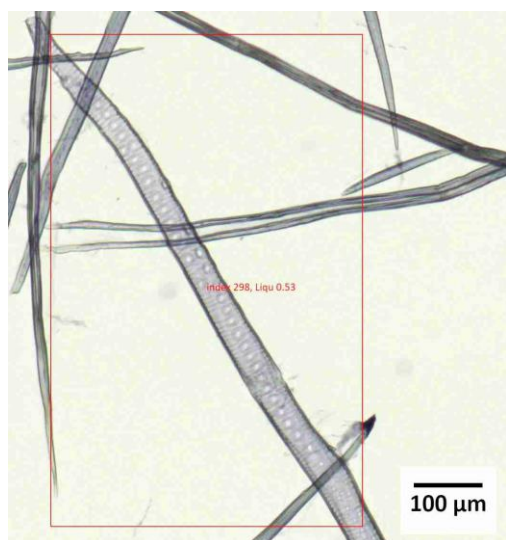


Abbildung 23 Nadelholz-Tracheide, die als Gefäßelement detektiert wurde und für die in der Klassifikation die höchste Konfidenz mit der Laubholzgattung Liquidambar berechnet wurde.

Von allen so detektierten Regionen wurden 79,3% einer Gattung zugeordnet, die in der jeweiligen Probe real enthalten war (Tabelle 5, links). Die gut 20% falsch positiver Ergebnisse für die einzelnen Bildregionen bewirken jedoch, dass in den einzelnen Blindproben zu viele Gattungen, die nicht enthalten waren, falschpositiv aufgelistet wurden (nur 61,1% richtig positiv und richtig negativ; Tabelle 5, rechts).

Tabelle 5 KI-Klassifikations-Ergebnis im Blindtest bezogen auf die einzelnen Bounding Boxes (links) und die Blindproben (rechts). Ausgewertet wurde jeweils die Laubholzgattung mit der höchsten Konfidenz unabhängig davon, wie gering sie im Einzelfall war.

KI-Ergebnis für Bounding Boxes			KI-Ergebnis je Blindprobe		
Konfidenz 0-1			Konfidenz 0-1		
	Richtig	Falsch		Richtig	Falsch
Positiv	5299	1380	Positiv	25	42
Negativ	-	-	Negativ	41	0
Prozent	79,34%		Prozent	61,11%	
Precision	-		Precision	37,31%	
Recall	-		Recall	100,00%	

Vergleicht man diese Ergebnisse mit der Auswertung durch Holzanatomen, muss man grundsätzliche methodische Unterschiede beachten. Bei der holzanatomischen Begutachtung, werden alle Gefäßelemente angeschaut, aber Gefäßelemente, die nicht alle entscheidenden Strukturmerkmale aufweisen, werden nicht einzeln ausgewertet. Stattdessen wird betrachtet, ob diese zu einer der schon eindeutig enthaltenen Gattungen passen. Diese Transferleistungen können nicht so einfach in das automatisierte System integriert werden. Jedoch wird dadurch ersichtlich, dass einzelne Gefäßelemente, die nicht alle Merkmale aufweisen oder zum Beispiel durch den Herstellungsprozess fragmentiert wurden, nicht in die Auswertung fließen dürfen, da sie das Ergebnis verfälschen. Deshalb ist es folgerichtig, analog zur Analyse durch Menschen, auch nur die Gefäßelemente in die Auswertung zu nehmen, die eine hohe Übereinstimmung mit einer Gattung aufweisen (Konfidenz > 0,95). Dadurch werden die Ergebnisse der KI wesentlich verbessert. Danach werden 98,5% der als Gefäßelement detektierten Regionen einer Gattung zugeordnet, die in der entsprechenden Blindprobe enthalten ist (Tabelle 6, links). Eine bemerkenswert gute Quote, wenn man vergleicht, dass von den Holzanatomen im Schnitt 96,5% der Entscheidungen richtig getroffen wurden (Tabelle 6, rechts). Jedoch wirken sich die falsch positiven Entscheidungen der KI-Modelle zu den einzelnen Regionen auch auf die in der gesamten Probe nachgewiesenen Gattungen aus. So waren insgesamt bei den KI-Modellen 85,2% der Entscheidungen, welche der neun Gattungen enthalten ist oder nicht, auf die Blindproben bezogen richtig (Tabelle 6, Mitte). Besonders hervorzuheben ist, dass alle in den Blindproben enthaltenen Gattungen erkannt wurden (100% Recall).

Tabelle 6 KI-Klassifikations-Ergebnis im Blindtest bezogen auf die einzelnen Bounding Boxen (links) und die Blindproben (rechts). Ausgewertet wurde jeweils die Laubholzgattung mit der höchsten Konfidenz, wenn diese mindestens einen Wert von 0,95 erreicht hat.

Ergebnis je Bounding Box			Ergebnis je Blindprobe					
KI - Konfidenz > 0,95			KI - Konfidenz > 0,95			Mensch		
	Richtig	Falsch		Richtig	Falsch		Richtig	Falsch
Positiv	3479	54	Positiv	25	16	Positiv	140	13
Negativ	-	-	Negativ	67	0	Negativ	485	10
Prozent	98,5%		Prozent	85,2%		Prozent	96,5%	
Precision	-		Precision	61,0%		Precision	91,5%	
Recall	-		Recall	100,0%		Recall	93,3%	

Eine wissenschaftliche Veröffentlichung der Ergebnisse befindet sich gerade in Vorbereitung. Zudem wurde am Thünen-Institut eine B.Sc.-Arbeit zu diesem Thema verfasst. Die Blindtest-Ergebnisse werden auf der KIDA-Fachtagung in Leipzig im Dezember 2024 mit einem Posterbeitrag vorgestellt.

Arbeitspaket 10: Entwicklungstransfer für eine digitale Bestimmung von Massivhölzern (TI und ITWM)

Dieses Arbeitspaket konnte im Projekt nicht bearbeitet werden. Stattdessen wurde am TI die PostgreSQL-Datenbank entwickelt und der Wissenstransfer zur Systemsoftware und Benutzerschnittstelle und dessen Implementierung bearbeitet.

Arbeitspaket 11: Abschlussbericht (TI und ITWM)

Der Abschlussbericht liegt hiermit vor.

2. Verwertung

a) Erfindungen/Schutzrechtsanmeldungen

Es wurden keine Schutzrechtsanmeldungen vorgenommen, Erfindungen wurden durch Publikationen veröffentlicht.

b) Wirtschaftliche Erfolgsaussichten nach Projektende

In dem Projekt wurde erstmals die Identifizierung der in Papier und Papierprodukten enthaltenen Hölzer mittels künstlicher Intelligenz automatisiert. Bisher muss diese Analyse zeitaufwendig von hochgradig spezialisierten Menschen durchgeführt werden.

Gelingt die vollständige Automatisierung und die Anwendung der Systeme auf im Handel befindliche Papierproben aus gemischten Hölzern, würden sowohl die freiwilligen Selbstkontrollen des Handels als auch die behördlichen Kontrollen der EUTR und der neu eingeführten EUDR (EU deforestation regulation – EU-Verordnung zu entwaldungsfreien Lieferketten) wesentlich vereinfacht werden. Damit war das Ziel dieses Projekts, einen entscheidenden Beitrag zu transparenten, legalen Handelsketten zu leisten. Da das entwickelte System zum Projektende nur für Laubhölzer bestimmter Gattungen verwendbar ist, werden in einem bereits begonnenen Folgeprojekt Modelle für die Erkennung von Nadelhölzern entwickelt und die Laubholzerkennung auf weitere Gattungen zu erweitert. Damit würde zukünftig ein anwendbares System zur Verfügung stehen, dass die Zahl der behördlichen Prüfungen erhöhen und Falschdeklarationen von Faserprodukten aufdecken kann.

c) Wissenschaftliche und/oder technische Erfolgsaussichten nach Projektende

Viele klassische, modellbasierte Verfahren, auch für die Industrie, werden nach und nach durch KI-Lösungen ersetzt oder ergänzt. Beispielsweise werden für die Gesichtserkennung Netzwerke wie ArcFace eingesetzt, die klassische Verfahren stark übertreffen. Erkenntnisse aus diesem Vorhaben werden zukünftig in anderen Projekten vor allem in der Produktion verwendet. Aktuell werden verschiedene Systeme zur Online-Inspektion von Oberflächen mit Hilfe von KI realisiert. Die Erkenntnisse aus KI_Wood-ID, insbesondere auch der Umgang mit großen Bildern der effizienten Annotation und dem Umgang mit zu kleinen Datenmengen, werden in diesen Projekten eingesetzt. Ebenso werden die Erklärbarkeitsmodelle für Neuronale Netze, die entwickelt worden sind, in Projekten zur Digitalisierung und mit erhöhten Sicherheits-/Nachvollziehbarkeitsansprüchen Einsatz finden. Der Einsatz von KI-Methoden für natürliche Materialien wie Holz, Leder etc. ist wissenschaftlich noch immer ein offenes Feld. Das Projektteam hat schon einige Veröffentlichungen in diesem Feld eingereicht und plant, auch den Datensatz (in Teilen) und sogenannte Benchmark-Ergebnisse zu veröffentlichen.

d) Wissenschaftliche und wirtschaftliche Anschlussfähigkeit

Die Ergebnisse des Forschungsprojektes sind breit veröffentlicht worden (Veröffentlichungen, S. 27). Insbesondere im nachfolgenden Projekt, in dem es um Nadelholzerkennung gehen soll, wird das Projekt ergänzt auf wissenschaftlicher und wirtschaftlicher Ebene. Sowohl das Thünen Institut als auch Fraunhofer ITWM sind wissenschaftlich gut vernetzt und können erlangte Erkenntnisse in weiteren wissenschaftlichen und wirtschaftlichen Tätigkeiten anschließen.

3. Erkenntnisse von Dritten

Eine wichtige Erkenntnis von Dritten ist die Weiterentwicklung der YOLO-Architektur. Seit der ursprünglichen Veröffentlichung von YOLO wurden zahlreiche Versionen von verschiedenen Institutionen und Unternehmen entwickelt und adaptiert auf spezifische Anwendungszwecke. Insbesondere in praktischen Anwendungen bleibt YOLO ein häufig genutzter Ansatz für die Objekterkennung. Ge et al. (2021) zeigen beispielsweise ähnlich wie in unserer WoodYOLO Publikation, dass anchor boxes nicht unbedingt bei der Detektion notwendig sind.

Abseits der Detektion entstehen auch in der Klassifikation ständig neue Architekturen, die weiter die Unterscheidung von Gefäßen verbessern kann. ConvNeXt, entwickelt durch Zhuang et al. (2022), kommt zum Ergebnis, dass Transformer-basierte Architekturen bei der Klassifikation nicht unbedingt einen Vorteil liefern. Basierend auf dieser Architektur haben auch wir die Klassifikation verbessern können.

Qamar et al. (2024) zeigen in ihrer Studie die Anwendung von YOLOv8 für die Analyse von mikroskopischen Holzfaserbildern. Ihre Arbeit verdeutlichte das Potenzial dieser Methode zur Segmentierung und Charakterisierung von mazerierten Fasern und Gefäßen.

Saqib Qamar, Abu Imran Baba, Stéphane Verger, and Magnus Andersson. Segmentation and characterization of macerated fibers and vessels using deep learning. *Plant Methods*, 20(1), August 2024. ISSN 1746-4811. doi:10.1186/s13007024-01244-w. URL <http://dx.doi.org/10.1186/s13007-024-01244-w>.

Zheng Ge, Songtao Liu, Feng Wang, Zeming Li, and Jian Sun. YOLOX: Exceeding yolo series in 2021, 2021a. URL <https://arxiv.org/abs/2107.08430>.

Zhuang Liu, Hanzi Mao, Chao-Yuan Wu, Christoph Feichtenhofer, Trevor Darrell, and Saining Xie. A convnet for the 2020s. In *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 11966–11976, 2022. doi: 10.1109/CVPR52688.2022.01167.

4. Veröffentlichungen

- **Nieradzik L, Stephani H, Sieburg-Rockel IJ, Helmling S, Olbrich A, Wrage S, Keuper J** (2024) WoodYOLO: A novel object detector for wood species detection in microscopic images. *Forests* 15(11):1910, DOI:10.3390/f15111910 https://literatur.thuenen.de/digbib_extern/dn069063.pdf (peer-reviewed)
- **Helmling S, Nieradzik L, Sieburg-Rockel IJ, Weibel T, Wrage S, Gospodnetic P, Keuper J, Stephani H, Rauhut M, Olbrich A** (2024) Automated wood species identification in microscopic images of fibrous materials using machine learning / AI. In: *Forests & society towards 2050 : 26th IUFRO World Congress, Stockholm, Sweden, 23-29 June 2024 ; Book of abstracts*. p 3523 https://literatur.thuenen.de/digbib_extern/dn068687.pdf
- **Nieradzik L, Sieburg-Rockel IJ, Helmling S, Keuper J, Weibel T, Olbrich A, Stephani H** (2024) Automating wood species detection and classification in microscopic images of fibrous materials with deep learning. *Microsc Microanal* 30(3):508-520, DOI:10.1093/mam/ozae038 (peer-reviewed)
- **Nieradzik L, Stephani H, Sieburg-Rockel IJ, Helmling S, Olbrich A, Keuper J** (2024) Challenging the black box: A comprehensive evaluation of attribution maps of CNN applications in agriculture and forestry. In: Radeva P, Furnari A, Bouatouch K, Sousa AA (eds) *Proceedings of the 19th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISIGRAPP 2024)*. Vol. 2. pp 483-492, DOI:10.5220/0012363400003660
- **Helmling S, Sieburg-Rockel IJ, Wrage S, Olbrich A, Nieradzik L, Stephani H, Weibel T, Gospodnetic P, Rauhut M** (2023) Automatisierte Holzartenidentifizierung in mikroskopischen Bildern von Fasermaterialien mit Hilfe von maschinellem Lernen / KI. In: *KIDA-Fachtagung, 27. - 28. September 2023, Quedlinburg : Abstractbuch*. Braunschweig: Geschäftsstelle Think Tank Digitalisierung, Johann Heinrich von Thünen-Institut, pp 21-22
- Fraunhofer Presseinformation, Automatisierte Bilderkennung für die Bestimmung von Holzarten, KI im Einsatz gegen globale Entwaldung, *Forschung Kompakt /* 02. September 2024
- Forschungsfelder, Magazin für Ernährung und Landwirtschaft, BMEL, 1/24, S.26
- **Heddier, Jonas**, Künstliche Intelligenz versus Mensch – Auswertung einer Blindstudie zur Holzartenbestimmung von mazerierten Mischproben, B.Sc.-Arbeit, Universität Hamburg, 2024
- Wachsame Augen auf Holz, Nordwissen, taz-nord, 03.11.2023

Vorträge

2024

- Webinar der Nederlandse Voedsel- en Warenautoriteit (NVWA)
- 6. Holzanatomisches Kolloquium, Dresden
- VISIGRAPP 2024 (siehe Paper), Rom
- IUFRO World Congress 2024, Stockholm
- 2nd International Seminar on Anatomical Plant Identification, Hamburg
- FNR Online-Seminarreihe „Digitalisierung Forst und Holz“, 7. Seminar: Baumstamm- und Holzartenidentifizierung mittels KI

2023

- KIDA Fachtagung, Quedlinburg
- Jahrestagung des VPM Nord/Zellcheming, Barsbüttel
- Exkursion der AG von Prof. Militz, Universität Göttingen nach Hamburg
- World Forest ID-Meeting, Malmö
- International Workshop on “Identification of CITES-protected timbers”, Hamburg

- Thünen-Kolloquium November 2023
- PTS Grundkurs - Qualitätskontrolle & -sicherung durch mikroskopische Prüfung von Fasern, Füllstoffen und Papier, Dresden
- Wood+ Erasmus Summer School: EDU-4, Hamburg
- Wood+ Erasmus Summer School: WO-3, Hamburg

2022

- BfN, Internationale Naturschutzakademie, Insel Vilm
- Asforclit – WG2 Workshop
- Peruvian-German Colloquium, CITEmadera, Thünen Institut, Universität Hamburg
- Holzanatomisches Seminar für Kriminalbiologen mit Schwerpunkt Holzartenidentifizierung, Hamburg

Messestände

Grüne Woche 2024, Berlin

Woche der Umwelt 2024, Schloss Bellevue, Berlin

Posterpräsentation auf der Curious 2024, Mainz

Ligna 2023, Hannover