

# Machine Learning-basierte mikroskopische Holzartenbestimmung

Sven Koch

sven.koch@haw-hamburg.de

Department Informatik  
der Fakultät Technik und Informatik  
der Hochschule für Angewandte Wissenschaften Hamburg

**Zusammenfassung** Der internationale Handel mit Holz und Holzprodukten erfordert effektive Methoden für eine genaue und zweifelsfreie Bestimmung der individuellen Hölzer. Durch Handelsverordnungen, CITES-Artenschutzmaßnahmen und zur Kontrolle des illegalen Handels, sind eindeutige Holzartenbestimmungen umso bedeutsamer. Die „klassische“ anatomische Holzartenbestimmung erfordert bislang eine große wissenschaftliche Expertise und den Zugang zu einer umfassenden Sammlung an Referenzmustern. Der Einsatz der digitalen Holzartenerkennung auf Grundlage von maschinellen Lernverfahren soll aufgrund dessen eine schnelle und zuverlässige Alternative zur Bestimmung von Holzarten bieten. Diese Arbeit beschreibt dazu erstmals eine Machine Learning-basierte Holzartenbestimmung auf der Basis von mikroskopischen Präparaten. Auf mikroskopischer Ebene ist es auch möglich, sehr feine Strukturmerkmale in die Identifikation miteinzubeziehen. Zur Erprobung des Verfahrens wurden sechs wichtige Wirtschaftsbaumarten aus der Familie der MELIACEAE ausgewählt, worunter sich auch die CITES-geschützten Arten *Swietenia* spp. befinden. Der erforderliche Bilddatensatz wurde mit wissenschaftlich belegtem Referenzmaterial des Thünen-Instituts für Holzforschung aufgebaut und umfasst ca. 7000 Aufnahmen. Das entwickelte neuronale Netz zur Holzartenbestimmung basiert auf einem Convolutional Neural Network und wurde nach dem Transfer Learning Lernverfahren trainiert. Die sechs ausgewählten Arten können durch das vorgestellte Modell mit einer Gesamtgenauigkeit von 97% klassifiziert werden. Fehlerhaft klassifizierte Arten sind optisch und anatomisch stark übereinstimmend und auch konventionell anspruchsvoll zu bestimmen. Diese Arbeit stellt einen wichtigen konzeptionellen Beweis zur Verwendung und Weiterentwicklung von Computer Vision Anwendungen auf dem Themengebiet der Holzartenbestimmung dar.

**Keywords:** Mikroskopische Holzartenbestimmung · Computer Vision · Machine Learning · Convolutional Neural Networks · Transfer Learning

## 1 Einleitung

Die globalen Entwicklungen im internationalen Handel mit Holz und Holzprodukten erfordern wichtige (Kontroll-)Maßnahmen und effektive Methoden für

eine genaue und zweifelsfreie Bestimmung der individuellen Hölzer (Gattungen bzw. Arten) und ihrer geographischen Herkünfte. Diese Maßnahmen sind umso wichtiger, da mit Inkrafttreten der EU-Holzhandelsverordnung (EUTR) das Inverkehrbringen von Holz oder Holzzeugnissen aus illegalem Einschlag verboten ist und in den letzten Jahren weitere wichtige Wirtschaftsbaumarten in die Liste der CITES-geschützten Hölzer aufgenommen wurden [5]. Eine eindeutige Bestimmung von Holzarten ist aber auch für den Verbraucherschutz im Bezug auf die Bewertung der Produkteigenschaften von zunehmend großer Bedeutung.

Für die „klassische“ anatomische Bestimmung der Hölzer werden Mikrotomschnitte in den drei anatomischen Richtungen (transversal, tangential und radial) mit Schnittstärken von ca. 10 bis 20  $\mu\text{m}$  von den zu untersuchenden Mustern hergestellt. Unter dem Lichtmikroskop können die Hölzer dann anhand von ca. 80 codierten Strukturmerkmalen verglichen und bestimmt werden.

Die zweifelsfreie Bestimmung der Hölzer erfordert eine fundierte wissenschaftliche Ausbildung und Expertise und insbesondere den Zugang zu belegten Referenzpräparaten. Diese Vergleichsmuster stehen international nur an wenigen Forschungseinrichtungen zur Verfügung [6].

Daher wurde im Rahmen dieser Arbeit ein digitales Bilderkennungssystem entwickelt, was auf Grundlage von mikroskopischen Präparaten eine möglichst akkurate Holzartenbestimmung ermöglicht. Besonders der Einsatz von Convolutional Neural Networks und das vereinfachte Training durch Transfer Learning, liefern in diesem Kontext die nötigen Werkzeuge, um ein entsprechendes Projekt zu realisieren.

Nach Erprobung der Technologie ist der Einsatz einer computergestützten Holzartenbestimmung beispielsweise für wissenschaftliche Kontrollbehörden denkbar, die den Handel mit insbesondere tropischen Hölzern gemäß den EUTR- und CITES-Richtlinien kontrollieren.

## 2 Verwandte Arbeiten

Der Einsatz von Computer Vision ist im Bereich der Holzartenbestimmung noch weitgehend unerprobt. Es existieren aber durchaus interessante Projekte und Ansätze auf diesem Themengebiet. Beispielsweise beschreiben XJ Tang et al. ein System zur Holzartenbestimmung auf makroskopischer Ebene mithilfe einer Smartphonekamera und Makro-Objektiv [10].

Diese Arbeit dokumentiert hingegen erstmals ein Erkennungsverfahren anhand mikroskopischer Strukturmerkmale des Holzgewebes. Mit mikroskopischer Vergrößerung kann eine sichere Unterscheidung der individuellen Arten bzw. Gattungen anhand feiner anatomischer Merkmale, z.B. Vorkommen von septierten Fasern, etc. erkannt und verwendet werden.

### 3 Datensatz der Holzarten

#### 3.1 Auswahl der Holzarten

Für die Erprobung der Machine Learning-gestützten Bestimmungsmethode wurden zunächst sechs wichtige Wirtschaftsbaumarten aus der Familie der MELIACEAE (Mahagonigewächse) ausgewählt [4]. Diese Hölzer sind im internationalen Handel stark nachgefragt und beinhalten unter anderem auch die Gruppe der CITES-geschützten Arten *Swietenia* spp. (Echtes Mahagoni).

Der Probenumfang umfasst die nachfolgend gelisteten Handelshölzer (botanische Gattungen / Arten):

1. *Entandrophragma angolense*, **Tiama**, Afrika
2. *Entandrophragma candollei*, **Kosipo**, Afrika
3. *Entandrophragma cylindricum*, **Sapeli**, Afrika
4. *Entandrophragma utile*, **Sipo**, Afrika
5. *Khaya* spp., **Khaya**, Afrika
6. *Swietenia macrophylla*, **Echtes Mahagoni**, Mittel- und Südamerika

#### 3.2 Aufnahme des Bilddatensatzes

Für die mikroskopische Bildgebung wurde wissenschaftlich belegtes Referenzmaterial des Thünen-Instituts für Holzforschung herangezogen. Da die wesentlichsten diagnostischen Strukturmerkmale auf den Querschnittsflächen vorkommen, wurde auf Präparate in transversaler Schnittrichtung zurückgegriffen.

Unter einem Durchlichtmikroskop (*ZEISS Primo Star*) wurden die Querschnittpräparate mit vierfacher Objektivvergrößerung aufgenommen. Zur Fotografie wurde eine Digitalkamera (*ZEISS AxioCam ERc 5s*) verwendet, mit der 8-Bit RGB Farbbilder mit einer Größe von 1280 px × 720 px gespeichert werden können. Aus einem individuellen Schnittpräparat konnten jeweils mehrere unterschiedliche Einzelaufnahmen (Bildausschnitte) dokumentiert werden.

Die Abbildungen 1 - 6 zeigen exemplarische Aufnahmen für jede Klasse aus dem erstellten Bilddatensatz.

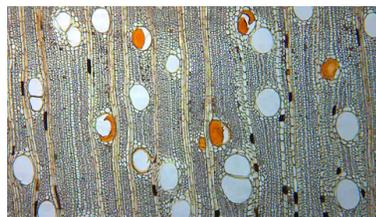


Abbildung 1: *Entandrophragma angolense* (Tiama), mikroskopischer Querschnitt



Abbildung 2: *Entandrophragma candollei* (Kosipo), mikroskopischer Querschnitt



Abbildung 3: *Entandrophragma cylindricum* (Sapeli), mikroskopischer Querschnitt



Abbildung 4: *Entandrophragma utile* (Sipo), mikroskopischer Querschnitt



Abbildung 5: *Khaya* spp. (Khaya), mikroskopischer Querschnitt



Abbildung 6: *Swietenia macrophylla* (Echtes Mahagoni), mikroskopischer Querschnitt

## 4 Machine Learning Methodiken

### 4.1 Ansatz

In den letzten Jahren haben Convolutional Neural Networks (CNNs) viele Fortschritte im Bereich der Bildklassifizierung erzielt und sich als Standard für Bildklassifikationsaufgaben etabliert [7]. Convolutional Neural Networks können im Gegensatz zu herkömmlichen neuronalen Netzen auch zweidimensionale Eingänge in Form einer Matrix verarbeiten. Dadurch bleiben Informationen zur Bildpunktposition und über Bildpunktnachbarschaften erhalten, was wesentlich für die Erkennung von lokalen Bildstrukturen ist. Eine verbreitete Möglichkeit, um Convolutional Neural Networks zu trainieren, ist die Technik des Transfer Learning.

Transfer Learning ist ein maschinelles Lernverfahren, um auch auf Grundlage von kleinen und mittelgroßen Trainingsdatensätzen einen leistungsfähigen Klassifikator zu entwickeln. Beim Transfer Learning werden die Ergebnisse eines bereits fertig trainierten neuronalen Netzes für eine neue Aufgabe genutzt. Dadurch entfällt das zeit- und rechenintensive Training eines tiefen neuronalen Netzes mit einem großen Datensatz [8]. Dazu werden die bereits trainierten Gewichte der unteren Schichten eines bestehenden neuronalen Netzes übernommen und lediglich die Ausgabeschicht für die spezifische Problemstellung ersetzt und trainiert.

## 4.2 Aufbau eines neuronalen Netzes zur Holzartenbestimmung

Das neuronale Netz zur Holzartenbestimmung nutzt die zuvor beschriebenen Konzepte der Convolutional Neural Networks und des Transfer Learning. Die genaue Architektur des entwickelten Modells ist in Listing 1.1 dargestellt.

Die Basis bilden die bereits trainierten Faltungsschichten des MobileNetV2-Netzes [9]. Dabei werden die vorinitialisierten Gewichte aus dem Training mit dem ImageNet-Datensatz [3] übernommen. Die oberste Klassifikationsschicht von MobileNetV2 wird aber gegen einen spezifischen Klassifikator ausgetauscht.

Der Klassifikator besteht aus einer weiteren Faltungsschicht mit einer Filtergröße von  $3\text{ px} \times 3\text{ px}$  mit ReLU Aktivierungsfunktion. Neben einer folgenden Schicht zur Batch Normalisierung, werden mittels Max Pooling die Größen der Featuremaps zur Informationskonzentration weiter reduziert. Anschließend können die zweidimensionalen Featuremaps in einen eindimensionalen Vektor umgeformt werden. Zur Ausgabe der Klassifikationsergebnisse wird dann eine klassische Schicht mit vollständig verbundenen Neuronen und Softmax Aktivierungsfunktion eingesetzt. Die Anzahl der Ausgangsneuronen beträgt sechs und korrespondiert mit der Anzahl an zu unterschiedenen Klassen.

Layer (type)	Output Shape	Param #
mobilenetv2_1.00_224 (Model)	(None, 7, 7, 1280)	2257984
conv2d (Conv2D)	(None, 5, 5, 32)	368672
batch_normalization (BatchNo	(None, 5, 5, 32)	128
max_pooling2d (MaxPooling2D)	(None, 1, 1, 32)	0
flatten (Flatten)	(None, 32)	0
dense (Dense)	(None, 6)	198
Total params: 2,626,982		
Trainable params: 368,934		
Non-trainable params: 2,258,048		

Listing 1.1: Architekturübersicht des entwickelten neuronalen Netzes. Die Basis bildet das vortrainierte MobileNetV2 Modell mit einem spezialisierten Klassifikator für die Holzartenbestimmung.

Die Definition der Netzarchitektur und das Training wurde mithilfe von Keras [2] auf dem TensorFlow-Back-End [1] implementiert.

## 4.3 Training des neuronalen Netzes

Für das Training des neuronalen Netzes wurde der vorhandenen Datensatz von 6964 Bildern in eine 80%/20% Trainings-/Validierungsaufteilung unterteilt. Die

Tabelle 1 enthält Informationen über die genaue Bildanzahl der einzelnen Klassen.

<b>Art</b>	<b>Training</b>	<b>Validierung</b>
<i>Entandrophragma angolense</i>	884	221
<i>Entandrophragma candollei</i>	939	235
<i>Entandrophragma cylindricum</i>	832	208
<i>Entandrophragma utile</i>	926	232
<i>Khaya</i> spp.	1011	253
<i>Swietenia macrophylla</i>	978	245
Gesamt	5570	1394

Tabelle 1: Übersicht der Trainings- und Validierungsdatensätze pro Holzart. Die Gesamtgröße des Datensatzes umfasst 6964 Bilder.

Trainiert wurde das neuronale Netz über 25 Epochen bei einer Batchgröße von 32. Als Optimierer wurde Adam mit der Lernrate  $10^{-3}$  verwendet. Dabei wurde das Fehlermaß mit der Categorical Crossentropy Fehlerfunktion berechnet. Die Eingangsgröße für die Featuremaps beträgt  $224 \text{ px} \times 224 \text{ px}$ . Die Bilder aus dem Trainings- und Validierungsdatensatz wurden vor Eingabe in das neuronale Netz entsprechend skaliert.

Bevor die Trainingsdaten dem neuronalen Netz präsentiert wurden, erfolgte für jeden Batch in Echtzeit eine Data Augmentation. Das Ziel von Data Augmentation ist, den bestehenden Trainingsdatensatz durch geringfügige Bildtransformationen zu manipulieren und damit zu erweitern. In diesem konkreten Anwendungsfall wurden die Trainingsbilder in zufälliger Weise leicht rotiert, skaliert oder an der horizontalen oder vertikalen Achse gespiegelt.

Neben der Vergrößerung des Trainingsdatensatzes konnte Data Augmentation zudem das bekannte Problem des Overfittings verhindern. Ein Overfitting liegt vor, wenn das neuronale Netz überangepasst ist. In dem Fall werden die Trainingseingaben sehr genau approximiert, aber unbekannte Eingaben können nicht wie gewünscht vom Modell abstrahiert werden. Durch die Aufnahme des gesamten Bilddatensatzes mit der gleichen Konfiguration (immer gleiches Lichtmikroskop und Digitalkamera), weist jedes Bild unvermeidlich identische Artefakte auf, die den Overfitting-Effekt weiter verstärken. Das neuronale Netz soll ausschließlich die anatomischen Strukturen und Merkmale der Holzpräparate abstrahieren, jedoch keine unerwünschten Artefakte. Durch die zufälligen Bildmanipulationen konnten diese Störungen entfernt bzw. unwirksam gemacht werden.

Die Kurven der Genauigkeit (Accuracy) und des Verlustes (Loss) des neuronalen Netzes werden über den Trainingsverlauf in Abbildung 7 grafisch aufgetragen. Nach dem Training über 25 Epochen wird eine Genauigkeit von 97,31% auf den Validierungsdaten erreicht. Der Verlust auf den Validierungsdaten wurde auf 9,16% reduziert. Ein Finetuning, also das anschließende Nachtrainieren

von Gewichten aus der MobileNetV2-Basis, hat die Leistung des Modells nicht weiter verbessern können.

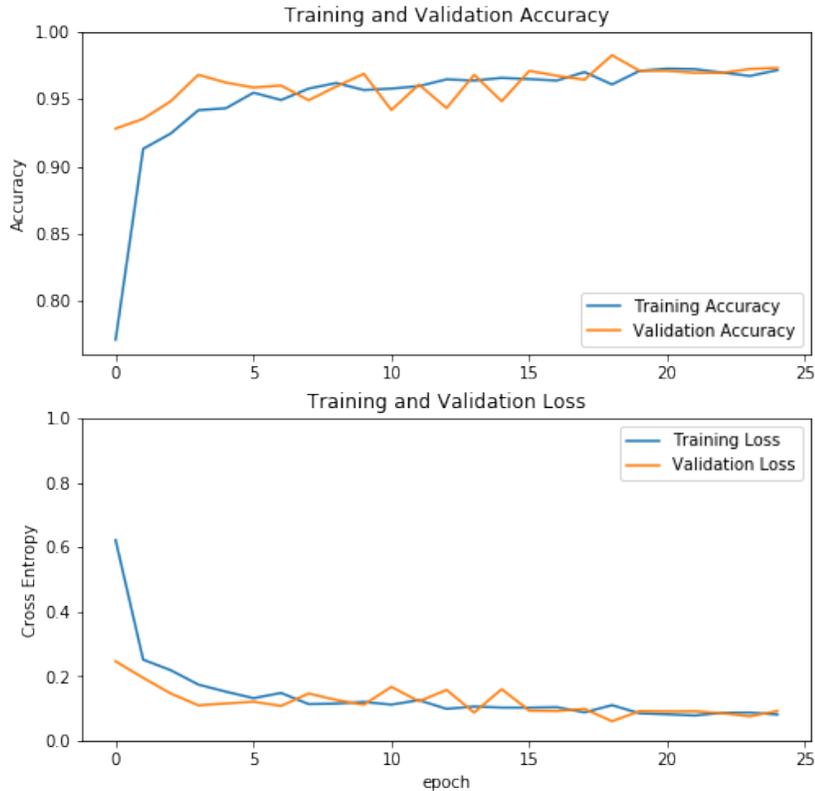


Abbildung 7: Darstellung der Genauigkeit (Accuracy) und des Fehlers (Loss) auf den Trainings- und Validierungsdaten pro Trainingsepoche.

## 5 Ergebnisse und Analysen

Die individuellen Sturkturmerkmale der einzelnen Gattungen bzw. Arten variieren charakteristisch, sodass einige Klassen besser voneinander unterschieden werden können als andere. Angesichts dieser Variationen sollte die Leistungsfähigkeit des Modells separat für die einzelnen Klassen bewertet werden. Die Abbildung 8 stellt dazu eine Konfusionsmatrix dar, die alle Kombinationen von tatsächlicher und vorhergesagter Klasse in Beziehung setzt.

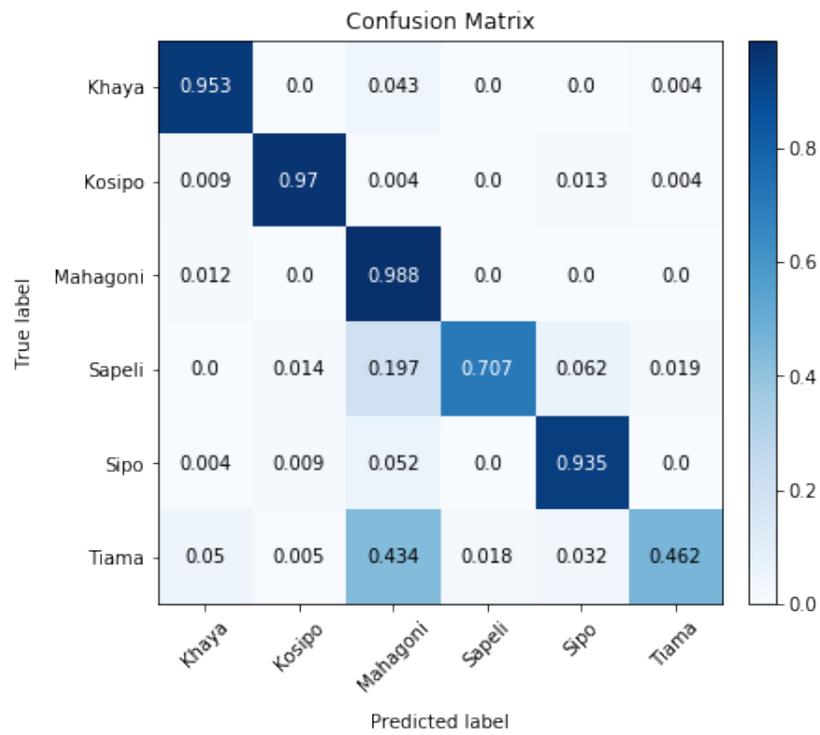


Abbildung 8: Konfusionsmatrix für die sechs Ausgänge des Klassifikators. Auf der Diagonalen sind die korrekten Klassifizierungen aufgetragen. Falsche Klassifizierungen liegen außerhalb der Diagonalen.

Insgesamt wurde ein sehr gutes Gesamtergebnis erzielt. Besonders die ermittelten Vorhersagen für *Entandrophragma candollei* (Kosipo) und *Swietenia macrophylla* (Echtes Mahagoni) sind nahezu fehlerfrei. Auch die Erkennungsgenauigkeit für die Klassen *Entandrophragma utile* (Sipo) und *Khaya* spp. (Khaya) liegt noch deutlich oberhalb von 90%.

Auch wenn das neuronale Netz sehr sicher *Swietenia macrophylla* (Echtes Mahagoni) identifizieren kann (hoher Recall = 99%), ist die Precision (= 60%) dieser Klasse nur gering. Der Klasse *Swietenia macrophylla* (Echtes Mahagoni) wurden auch einige fehlerhafte Holzarten zugeordnet. Dieses Ergebnis muss darauf zurückgeführt werden, dass das Modell eine vergleichsweise schlechte Leistung bei der Klassifizierung von Bildern von *Entandrophragma cylindricum* (Sapeli) und insbesondere *Entandrophragma angolense* (Tiama) aufweist. Der Vergleich der mikroskopischen Strukturmerkmale in den Abbildungen 1 (Tiama), 3 (Sapeli) und 6 (Echtes Mahagoni) zeigt, dass diese Hölzer aufgrund ihrer anatomischen Ähnlichkeiten insgesamt - auch von erfahrenen Holzanatomen - schwierig voneinander zu differenzieren sind [11].

In Bezug auf eine praktische Anwendung des Systems kann festgestellt werden, dass die erzielten Ergebnisse mit einer Sicherheit von größtenteils über 90% grundlegend geeignet sind. Es ist realistisch, dass computergestützte Systeme zur Holzartenbestimmung als effiziente und schnelle Verfahren zur Serienprüfung etabliert werden. Für eine Verifizierung der Ergebnisse kann im Zweifelsfall auf die konventionellen anatomischen Untersuchungen zurückgegriffen werden.

## 6 Fazit und weitere Ausblicke

Diese Arbeit stellt ein mit Transfer Learning trainiertes Convolutional Neural Network zur mikroskopischen Holzartenbestimmung vor. Das Modell kann anatomisch sehr ähnliche Hölzer aus der Familie der MELIACEAE mehrheitlich mit sehr zufriedenstellender Genauigkeit klassifizieren.

Es gibt einige Möglichkeiten zur Verbesserung oder Weiterentwicklung dieser Arbeit. Neben der Optimierung der Klassifizierungsgenauigkeit ist auch die Erweiterung des Datensatzes um weitere Holzarten eine gute Möglichkeit zur Fortentwicklung. Eine nützliche Erweiterung wäre außerdem die Integration des Machine Learning-basierten Klassifikators in ein Kamerasystem für die Lichtmikroskopie, sodass eine Holzartenbestimmung in Echtzeit unter dem Mikroskop erfolgen kann.

Auch wenn die Klassifikation einzelner Holzarten noch ungenau ist, sollen diese Ergebnisse einen wichtigen konzeptionellen Beweis zur Umsetzbarkeit, Verwendung und Weiterentwicklung von Computer Vision Anwendungen auf dem Themengebiet der Holzartenbestimmung liefern.

## **7 Danksagung**

Einem besonderen Dank gilt dem Thünen-Kompetenzzentrum Holzherkünfte, Hamburg für die Bereitstellung der mikroskopischen Präparate und mikroskopischen Ausstattung.

## Literaturverzeichnis

- [1] Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M., et al. (2016). Tensorflow: A system for large-scale machine learning. In *12th {USENIX} Symposium on Operating Systems Design and Implementation ({OSDI} 16)*, pages 265–283.
- [2] Chollet, F. et al. (2015). Keras.
- [3] Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., and Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database. In *2009 IEEE conference on computer vision and pattern recognition*, pages 248–255. Ieee.
- [4] Gasson, P., Baas, P., and Wheeler, E. (2011). Wood anatomy of cites-listed tree species. *IAWA journal*, 32(2):155–198.
- [5] Koch, G., Haag, V., Heinz, I., and Richter, H. (2015a). Die europäische holzhandelsverordnung (eutr)-anforderungen and die holzartenbestimmung in der praxis the european timber regulation (eutr)-requirements on wood identification in practice.
- [6] Koch, G., Haag, V., Heinz, I., Richter, H.-G., and Schmitt, U. (2015b). Control of internationally traded timber - the role of macroscopic and microscopic wood identification against illegal logging. *Journal of Forensic Research*, 6.
- [7] Krizhevsky, A., Sutskever, I., and Hinton, G. (2012). Imagenet classification with deep convolutional neural networks. *Neural Information Processing Systems*, 25.
- [8] Pan, S. J. and Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10):1345–1359.
- [9] Sandler, M., Howard, A. G., Zhu, M., Zhmoginov, A., and Chen, L.-C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 4510–4520.
- [10] Tang, X. J., Tay, Y. H., Siam, N. A., and Lim, S. C. (2017). Rapid and robust automated macroscopic wood identification system using smartphone with macro-lens. *CoRR*, abs/1709.08154.
- [11] Wheeler, E. A. (2011). Inside wood—a web resource for hardwood anatomy. *Iawa Journal*, 32(2):199–211.

### **Erklärung zur selbstständigen Bearbeitung der Arbeit**

Hiermit versichere ich, dass ich die vorliegende Arbeit ohne fremde Hilfe selbständig verfasst und nur die angegebenen Hilfsmittel benutzt habe. Wörtlich oder dem Sinn nach aus anderen Werken entnommene Stellen sind unter Angabe der Quellen kenntlich gemacht.

Reinbek	12.07.2020	
Ort	Datum	Unterschrift im Original