

JUNGE

wissenschaft

JungforscherInnen publizieren
online | *peer reviewed* | original

Verlag:
Physikalisch-
Technische
Bundesanstalt



Mathematik &
Informatik

KI-Pflege für Orchideen

Dateneffiziente Analyse von Bilddaten komplexer biologischer Systeme mit Künstlicher Intelligenz (KI)

In dieser Arbeit wurde eine App entwickelt, die den Gesundheitszustand von Orchideen mithilfe einer App beurteilt und Pflegetipps gibt. Grundlage hierfür ist eine KI, die sowohl mit einer geringen Anzahl an Trainings- als auch Eingabedaten auskommt. Grundlage für diese dateneffiziente Analyse ist der Zusammenschluss verschiedener neuronaler Netze.

DIE JUNGFORSCHER*INNEN



© Stiftung Jugend forscht e.V.

Elora Marx (2005) und
Canisius-Kolleg, Berlin

Alois Bachmann (2007)
Humboldt-Gymnasium, Berlin

Eingang der Arbeit:

6.9.2023

Arbeit angenommen:

15.11.2023



KI-Pflege für Orchideen

Dateneffiziente Analyse von Bilddaten komplexer biologischer Systeme mit Künstlicher Intelligenz (KI)

1. Einleitung

Künstliche Intelligenz (KI) hat im Bereich der Bildanalyse bereits ein sehr hohes Niveau erreicht. Doch statt, wie in der Bioinformatik oft üblich, große, mit festgelegten Standards und Methoden erstellte Datenbestände und Bilder computergestützt zu analysieren (Machine Learning), wird in dieser Arbeit der Fokus auf von Privatpersonen erstellte Bilder gelegt, die sich zum Beispiel in Bezug auf Bildqualität, Lichtverhältnisse und Hintergrund stark unterscheiden können.

1.1 Vorhandene Apps

Es existieren bereits Apps, die ähnliche Funktionen abdecken wie die hier vorgestellte App *orch_ai_d*, beispielsweise Plantix [16] und Agrio [2]. Diese beiden Systeme sind allerdings in erster

Linie auf Agrikultur spezialisiert und erkennen in diesem Bereich die häufigsten Pflanzen und Pflanzenkrankheiten und dienen in der professionellen Landwirtschaft zur Erkennung und Eindämmung von Schädlingen. Die eher auf Zimmerpflanzen anwendbare App PictureThis [15] verlangt, dass konkret kranke Pflanzenteile fotografiert werden. Das setzt allerdings voraus, dass die Nutzenden überhaupt erkennen, dass es sich um eine Krankheit handelt. Die App Flora Incognita [5] fordert die nutzende Person adaptiv zur Aufnahme verschiedener Pflanzenteile auf und setzt dabei ähnlich wie ein Bestimmungsbuch zumindest ein botanisches Grundwissen voraus. Die App Pflanzendoktor [26] dagegen funktioniert wie ein strukturiertes Lexikon ohne jegliche künstliche Intelligenz.

1.2 Ziele für *orch_ai_d*

Die hier vorgestellte App *orch_ai_d* ist für Menschen ohne fachlichen Bezug und Vorwissen ausgelegt und soll ihnen die Unsicherheit bei der Behandlung ihrer Pflanzen nehmen. Daher wird der Fokus nicht nur auf Krankheiten, sondern vor allem auf Pflegefehler gelegt. Da Zimmerpflanzen meist mehr morphologisch distinkte Teile aufweisen als landwirtschaftlich genutzte Pflanzen, führt dies zu höheren Anforderungen an das System. Als Beispieldpflanzen wurden fünf Orchideengattungen gewählt, da Orchideen mit 32 Prozent in Deutschland den größten Marktanteil an Zimmerpflanzen haben (Stand 2021) [21]. Da die untersuchten Gattungen in Deutschland nicht endemisch sind, erweist sich die korrekte Pflege und Zustandseinschätzung für Laien oft als schwierig.

Beraten von Pflanzenmarktangestellten wurden die Gattungen und Krankheitszustände festgelegt, die von der App, die mit einer KI arbeitet, erkannt werden sollen [1]. Auf Basis der erhaltenen Informationen und weiterer Recherchen wurde eine Tabelle mit biologischen Fakten über die gewählten Orchideengattungen erstellt. Dabei wurden vor allem die Bedürfnisse der Pflanzen in Bezug auf die abiotischen Faktoren Licht, Wasser und Raumklima und die Bedrohungen durch parasitäre biotische Faktoren berücksichtigt. Die gewählten Krankheitszustände waren Fäule durch Überwässerung, Vertrocknung, Sonnenbrand und Befall durch Wollläuse. Diese treten mit ähnlichen Symptomen bei allen fünf Gattungen auf.

Die App *orch_ai_d* funktioniert so, dass nach Eingabe eines Orchideenbildes einerseits eine möglichst korrekte Diagnose und andererseits passende Pflegehinweise ausgegeben werden.

Grundlage hierfür ist eine funktionsfähige Architektur aus künstlichen neuronalen Netzen, die auf der Basis eines

eventuell nicht allzu guten Bildes eine verlässliche Aussage trifft.

2. Architektur und Training der künstlichen Intelligenz

2.1 Grundbegriffe aus der KI

2.1.1 Object-Detectors

Object-Detector-KIs sind auf Convolutional Neural Networks (CNN) basierende überwachende lernende Systeme, die verschiedene Aspekte eines Bildes anhand visueller Merkmale identifizieren. Dafür werden Rechtecke, sogenannte Bounding-Boxen, genutzt, die möglichst eng um die erkannten Objekte gezogen werden und bestimmten Klassen zugeordnet sind. Die hier verwendete vortrainierte KI *YOLOv7* funktioniert hierbei einstufig, braucht also keine Vorfilterung des Bildes nach Regionen, was zu einer starken Verbesserung der Laufzeit führt. [13]

2.1.2 Klassifizierer

Klassifizierer sind neuronale Netzwerke, die darauf trainiert werden, Objekte oder ganze Bilder bestimmten vordefinierten Klassen zuzuordnen. Dafür benötigen sie einen annotierten Datensatz mit Beispielen, auf dessen Basis sie lernen, anhand bestimmter, nicht vordefinierter Muster Vorhersagen über die Klassenzugehörigkeit eines Objekts zu treffen. [7]

2.1.3 Reinforcement Learning

Reinforcement Learning (RL) ist ein Bereich des maschinellen Lernens, bei dem ein Agent im Trial-and-error-Verfahren darauf trainiert wird, eine bestimmte Zielfunktion zu maximieren. Dies wird erreicht, indem der Agent infolge seiner Entscheidungen Belohnungen oder Strafen erhält und sein Verhalten daraufhin anpasst, um kumulativ maximale Belohnungen zu erhalten. [6]

2.1.4 Ergebnisdarstellung durch Konfusionsmatrizen

Konfusionsmatrizen dienen der Visualisierung der Leistung einer überwachenden KI. Im Optimalfall zeigen diese Matrizen eine diagonal absteigende Linie mit dem Wert 1 und alle anderen Werte sind 0. [20]

2.2 Beschreibung der Netzwerk-Architektur

Als Input dient das Bild einer Orchidee. Dieses wird zur Präprozessierung an die ersten zwei Teil-KIs weitergeleitet. Der Gattungsklassifizierer *CL-orchid_type* erkennt anhand des gesamten Bildes die Orchideengattung (siehe [Abb. 1](#)) und gibt dabei für die einzelnen Gattungen Wahrscheinlichkeitswerte an, die in Summe 1 ergeben.

Als Teileklassifizierer wurde die Object-Detector-KI *YOLOv7* [24] verwendet, die auf die Auswertung von Bildern spezialisiert und im Bereich der Bounding Boxen eines der aktuellsten und meistgenutzten Systeme ist. Der Teileklassifizierer zieht Bounding Boxen, um nach den einzelnen Pflanzenteilen Blüten, Blätter, Stängel und Wurzeln zu suchen (siehe [Abb. 1](#)). Um die Daten in ein für *YOLOv7* auslesbares Datenformat zu konvertieren, wurden sie auf die Plattform *Roboflow* [17] hochgeladen, die außerdem die Augmentierung (siehe Kap. 3.4) der Daten für die Bounding Boxen durchführt.

Werden Pflanzenteile erkannt, werden diese an die Zustandsklassifizierer *CL-flower*, *CL-leaf*, *CL-stem* und *CL-root* weitergegeben. Die Klassifizierer sind mit gelabelten Bildern aus den fünf Datensätzen für die Krankheitszustände trainiert, sodass sie Stressfaktoren jeweils anhand eines Pflanzenorgans erkennen und pro Krankheit einen Wahrscheinlichkeitswert zwischen 0 und 100 Prozent angeben. Bei mehreren Bounding Boxen pro Pflanzenorgan wird ein gewichteter Durchschnitt der Scores gebildet.

Die Zahl der Boxen, ab der eine Gruppierung vorgenommen wird, wurde mittels Reinforcement Learning dahingehend optimiert, auf dem Gesamtdatensatz eine maximale Genauigkeit zu erreichen. Dieses Vorgehen verbessert die Genauigkeit des Gesamtsystems, also den Anteil der Bilder, die vollständig korrekt klassifiziert werden, um 2,5 Prozent.

Die Scores der Zustandsklassifizierer werden in der Postprozessierung *CL-sickness* zusammengefasst und gewichtet. Die Gewichtung erfolgt mittels eines hartkodierten und durch Reinforcement Learning (RL) modifizierten Algorithmus, der die Wahrscheinlichkeit mit einbezieht, dass der jeweilige Zustand korrekt anhand der einzelnen Pflanzenorgane (Boxenarten) erkannt wird. Dabei ist das Ergebnis von *CL-orchid_type* aktuell irrelevant.

Anhand der Kombination der Ergebnisse der verschiedenen Klassifizierer wird der passende Eintrag aus einer von uns erstellten Datenbank abgerufen. In dieser existieren für jede Gattung zwei Ausgaben pro Zustand, jeweils für Wahrscheinlichkeitswerte unter 70 Prozent und über 70 Prozent. Dies basiert auf der Annahme, dass die KI bei stärker ausgeprägten Zuständen einen höheren Wahrscheinlichkeitswert angibt. Die Ausgaben beinhalten nicht nur die Ergebnisse der KI-Analyse, sondern auch gattungsspezifische Pflegehinweise. Der Text für die Gattung *Vanda* und ‚trocken‘ < 70 Prozent lautet beispielsweise: „Deine *Vanda*-Orchidee ist etwas trocken. Besonders im Sommer benötigt sie viel Wasser, aber auch in der Winterruhe solltest du sie etwa in der Woche 30 Minuten lang tränken oder gießen. Achte in der Wachstumsperiode darauf, dass das Substrat immer leicht feucht, aber nicht nass ist. Halte die Luftfeuchtigkeit über 60 Prozent und besprühe sie im Sommer täglich mit Wasser.“

Zur Programmierung der KIs nutzten wir als Programmiersprache Python und als KI-Framework PyTorch [14].

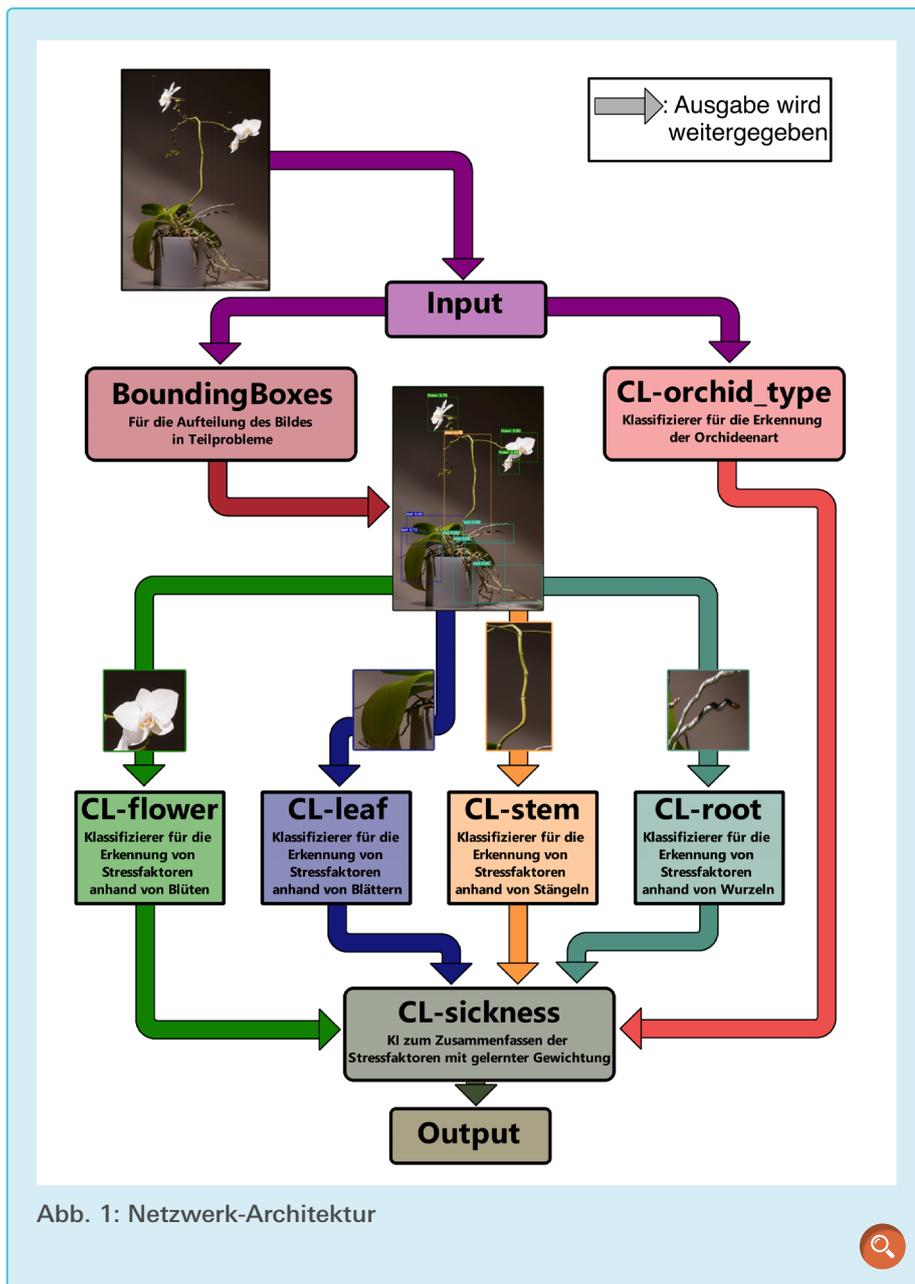


Abb. 1: Netzwerk-Architektur

2.3 Problembehandlung bei der Klassifizierung

In der Boxenerkennung von *orch_ai_d* kommt es bei unsauberen Hintergründen vor, dass zusätzliche Boxen gezogen werden, die in die Klassifizierung eingehen würden. Auch wenn mehrere Pflanzen auf dem Bild zu sehen sind, kann die Genauigkeit beeinflusst werden. Daher werden die gezogenen Boxen jeder Klasse anhand von Vektor- und Positionsdaten gruppiert. Von jeder Klasse wird jeweils die am zentralsten liegende Gruppe berücksichtigt, da davon ausgegangen wird, dass sich das Objekt des Interesses im Zentrum des Bildes befindet.

Bei den Zustandsklassifizierern für die Pflanzenteile können Fehlklassifizierungen verhindert werden, indem botanisches Hintergrundwissen berücksichtigt wird. Beispielsweise können trockene Wurzeln eine optische Ähnlichkeit zu Wollausbefall aufweisen. Der Klassifizierer für die Wurzeln gibt daher bei Trockenheit meist neben einer erhöhten Wahrscheinlichkeit für Trockenheit auch einen hohen Wert für Wollläuse an. Da aber Wollläuse nur äußerst selten die Wurzeln von Orchideen befallen, sind die Wurzeln hier nicht aussagekräftig. Indem der Score für Wollläuse in der Wurzel-KI auf 0 gesetzt wurde, konnte diese Fehlklassifizierung eliminiert werden.

den. Neben der Beseitigung von Fehlerquellen zielt die Gewichtung vor allem darauf ab, die wirklich aussagekräftigen Werte durch Multiplikation mit im teilweise durch Reinforcement Learning automatisierten Trial-and-Error-Verfahren erarbeiteten Faktoren >1 hervorzuheben.

Der Teileklassifizierer hatte immer wieder Probleme, Pflanzenteile, die durch eine Fehlbehandlung verändert waren, zuverlässig zu erkennen. Durch forciertes Training auf einem Datensatz, in dem zu gleichen Teilen auch gelabelte Bilder kranker Orchideen enthalten waren, konnte dieses Problem gelöst werden.

2.4 Trainingsdaten

KI- und Machine-Learning-Systeme erlangen ihre Fähigkeiten über die Arbeit mit Trainingsdaten. Bilderkennende, 'intelligente' neuronale Netzwerke lernen die Kategorisierung verschiedener abgebildeter Objekte oft anhand Tausender oder Millionen von Bilddateien. Im Unterschied zu einem hartkodierten Algorithmus ist das neuronale Netzwerk einer KI eine Blackbox. Es ist schwierig, abzuschätzen, nach welchen Kriterien eine KI eine Klassifizierung oder Diskriminierung vornimmt [9]. Daher hängt ihre Funktionsfähigkeit zu großen Teilen von der Qualität der Trainingsdaten ab [18].

Während des Trainings wird der reale Trainingsfortschritt mit nicht im Trainingsdatensatz enthaltenen Validierungsdaten überprüft, was den Datenbedarf noch einmal erhöht.

Für die zwei Hauptklassifizierungssysteme von *orch_ai_d*, Gattungsklassifizierer und Zustandsklassifizierer, werden Trainingsdaten benötigt, in diesem Fall Bilddateien. Alle anderen Teile des Systems arbeiten mit Metadaten auf Basis der aufbereiteten und kategorisierten Bilddateien. Die Trainingsdaten für den Gattungsklassifizierer entnehmen wir einem Datensatz aus [20], das 1513 Bilder von Orchideen der fünf gewählten

Tab. 1: Anzahl der Trainingsbilder pro Gattung

Gattung	Bildanzahl
<i>Cymbidium</i>	286
<i>Dendrobium</i>	270
<i>Oncidium</i>	236
<i>Phalaenopsis</i>	464
<i>Vanda</i>	259



Gattungen (*Phalaenopsis*, *Oncidium*, *Dendrobium*, *Cymbidium* und *Vanda*) enthielt (siehe [Tab. 1](#)).

Anders als für die Klassifizierung der Gattungen konnten wir für die Zustände (gesund, Sonnenbrand, feucht, trocken, Wollläuse) nur für den Zustand ‚gesund‘ auf einen fertigen Datensatz zurückgreifen, nämlich den Datensatz für die Gattungen. Die Trainingsdaten für die anderen Zustände stellten wir selbst zusammen. Über Bildersuche im Internet suchten wir den entsprechenden Zustand und sammelten alle Bilder, die nach unserer recherchebasierten Einschätzung tatsächlich das Krankheitsbild zeigten. Die Anzahl der nutzbaren Ergebnisse war bei der begrenzten Suchanfrage entsprechend klein, etwa 100 bis 150 Bilder pro Zustand (siehe [Tab. 2](#)).

Um die Zustandsklassifizierer *CL-flower*, *CL-leaf*, *CL-stem* und *CL-root* auf die Heterogenität vorzubereiten, die ihnen in der praktischen Nutzung begegnen, und eine Überanpassung an den Datensatz zu verhindern, setzten wir die Bilder verschiedenen Augmentierungen aus. Dies waren:

- Änderung der Bildgröße (Blüte: 64 × 64, Blatt: 128 × 128, Stängel: 32 × 64, Wurzel: 64 × 64, Gattung: 224 × 224),
- zwei zufällige Arten der Perspektivänderung,
- zufällige Spiegelung (horizontal und vertikal),
- zufällige Rotation um -45° bis +45° und
- Ersetzung zufälliger Vierecke durch schwarze Flächen.

Für den Teilklassifizierer, dessen Funktionalität unabhängig von der Qualität des Fotos gewährleistet sein muss, nahmen wir folgende Augmentierungen vor:

- Veränderung der Bildergröße auf 640 × 640,
- zufällige Spiegelung (horizontal und vertikal),
- zufällige Rotation um -15° bis +15°,
- zufällige Perspektivänderung um +/-15° horizontal und +/-15° vertikal,
- zufällige Helligkeitsänderung um -25 Prozent bis +25 Prozent,
- Hinzufügen zufälliger Verschwommenheit von bis zu 10 Pixeln sowie von 5 Prozent Noise und Erstellung von ‚Mosaiken‘, bei denen mehrere Bilder zu einem Bild zusammengesetzt werden.

Diese Schritte sind in der Arbeit mit Bildverarbeitungs-Modellen üblich. Durch die Augmentierung wurde die Anzahl der Bilder für das Training des Teilklassifizierers von 477 auf 1335 erhöht.

Die Bildanzahl nach der Augmentierung ist für die Klassifizierer nicht eindeutig, da in jeder Epoche die Bilder neu manipuliert werden.

Für das Training des Teilklassifizierers wurden zunächst Boxen per Hand gezogen, anhand derer die KI die Erkennung der einzelnen Pflanzenteile lernen sollte.

Die Systeme, auf denen die Modelle trainiert wurden, sind in [Tab. 3](#) aufgelistet.

3. Genauigkeiten der KIs

Bei allen Klassifizierern wurde das Training manuell gestoppt, sobald über mehrere Epochen weder der Loss noch die Accuracy eine Verbesserung zeigten.

3.1 Gattungsklassifizierer

Die aktuelle Genauigkeit des Gattungsklassifizierers *CL-orchid_type* liegt nach

Tab. 2: Trainings- und Validierungsdaten für die verschiedenen Zustände

Zustand	Bildanzahl Training	Bildanzahl Validierung
Trocken	131	26
Gesund	260	37
Wollläuse	174	32
Sonnenbrand	83	11
Feucht	137	28



Tab. 3: Genutzte Trainingssysteme und deren Parameter

Spezifikation	System 1	System 2
GPU	RTX 2080 TI	RTX 2060
CPU	Ryzen 5 1600X	Intel i5-11400f
RAM	16 GB 2400 MHz DDR4	16 GB 3000 MHz DDR4
Speicherkapazität	1.500 GB (M.2); 2.200 GB (SATA)	500 GB (M.2)



Abb. 2: Konfusionsmatrix des Gattungsklassifizierers *CL-orchid_type*

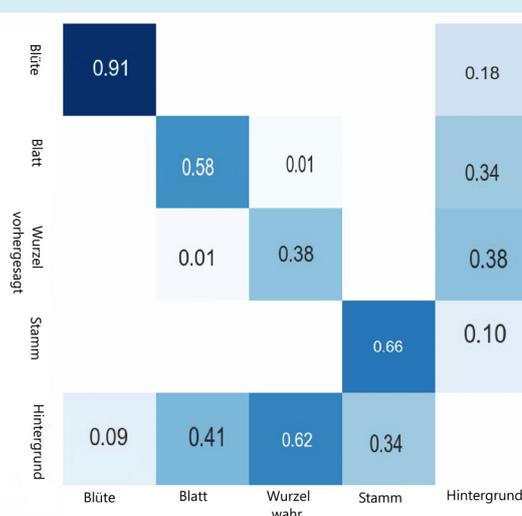


Abb. 3: Konfusionsmatrix der Object-Detector-KI *YOLOv7*, verwendet als Teileklassifizierer

etwa 13,5 Stunden Training auf System 1 bei 79 Prozent. Die Erkennung funktioniert vor allem dann gut, wenn Blü-

ten im Bild sind, da diese die größten gattungsspezifischen Unterschiede aufweisen.

Abb. 2 zeigt die Genauigkeit des Klassifizierers für die einzelnen Gattungen, wobei deutlich erkennbar ist, dass *Oncidium* als seltenste Gattung im Datenset am ungenauesten klassifiziert wird, zwischen *Phalaenopsis* und den anderen Gattungen allerdings kaum Unterschiede bestehen, obwohl für *Phalaenopsis* deutlich mehr Daten vorliegen. Die Ungenauigkeit in Bezug auf *Oncidium* kann also entweder darin begründet sein, dass es eine distinkte Schwelle für die Anzahl an Trainingsbildern gibt, oder das *Oncidium* wenig Merkmale aufweist, die für eine genaue Klassifizierung herangezogen werden können.

3.2 Teileklassifizierer

Nach 73 Stunden Training auf System 1 kann die KI *YOLOv7* die verschiedenen Pflanzenorgane zutreffend detektieren. Dies wird an der Konfusionsmatrix (siehe Abb. 3) und einem Beispielbild (siehe Abb. 4) deutlich. Die Farben der Boxenrahmen stehen im Beispiel für die verschiedenen Teile der Pflanze (grün – Wurzel; rot – Blatt; violett – Stängel).

3.3 Zustandsklassifizierer

Die Blüte (siehe Abb. 5a) ist nur für die Klassifizierung trockener und gesunder Orchideen hilfreich. Die Blätter (siehe Abb. 5b) gehören dagegen zu den aussagekräftigsten Pflanzenteilen, vor allem für die Klassifizierung von Sonnenbrand und Wollläusen sind sie relevant.

Da die Genauigkeit im Validierungsdatensatz beim *CL-root* (siehe Abb. 5c) bereits nach etwa 2,5 Stunden abfiel, was auf Overfitting hindeutet, verzichteten wir auf weiteres Training. Die Wurzeln, die bei den meist epiphytischen Orchideen relativ frei vorliegen, liefern aber wie die Blätter viele Daten über die Gesundheit der Orchidee.

Die Sprossachse (siehe Abb. 5d) ist der am wenigsten relevante Teil für die Klassifizierung des Zustandes und wird in der aktuellen Version des Systems nicht mehr berücksichtigt.

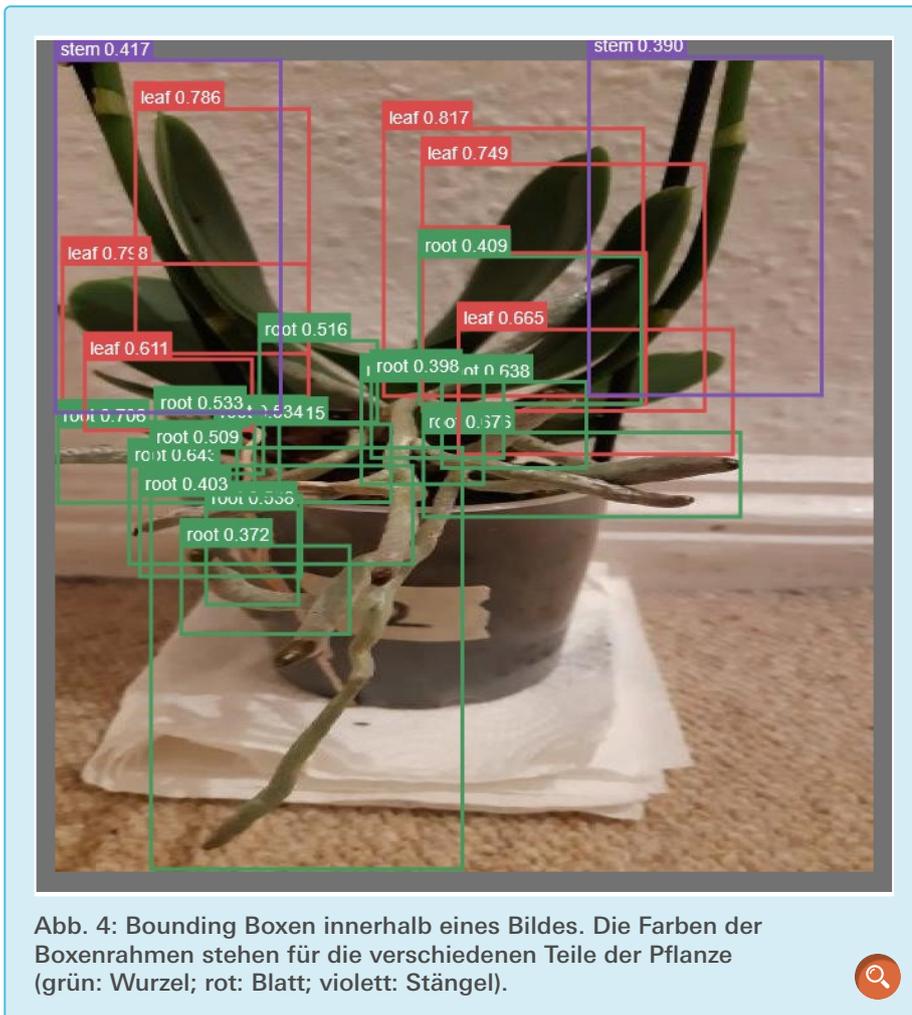


Abb. 4: Bounding Boxes innerhalb eines Bildes. Die Farben der Boxenrahmen stehen für die verschiedenen Teile der Pflanze (grün: Wurzel; rot: Blatt; violett: Stängel).



3.4 Gesamtsystem

Die Scores der Zustandsklassifizierer werden in der Postprozessierung *CL-sickness* zusammengefasst und gewichtet. Die Gewichtung wurde durch biologisch fundiertes Schlussfolgern, Auswertung der Matrizen, Trial-and-Error-Verfahren und RL angepasst. Trotz aller Anpassung der Gewichtung kann die Gesamtgenauigkeit jedoch nur auf den Leistungen der einzelnen Zustandsklassifizierer aufbauen. Deren Konfusionsmatrizen (siehe [Abb. 5](#)) verdeutlichen auch noch einmal die Notwendigkeit der Gewichtung, denn manche Zustandsklassifizierer weisen aus den in 2.3 erklärten Gründen an Stellen charakteristische Fehler auf, an denen die KIs für andere Organe eine hohe Genauigkeit zeigen. Aus den [Abb. 5](#) wird außerdem die unterschiedliche Aussagekraft der einzelnen Pflanzenteile gut erkennbar. Während die Zu-

standsklassifizierer anhand der Blüten und der Sprossachse wenig diagnostizieren können, erscheinen die Blätter und Wurzeln als Hauptaussageträger. Das deckt sich auch mit der allgemei-

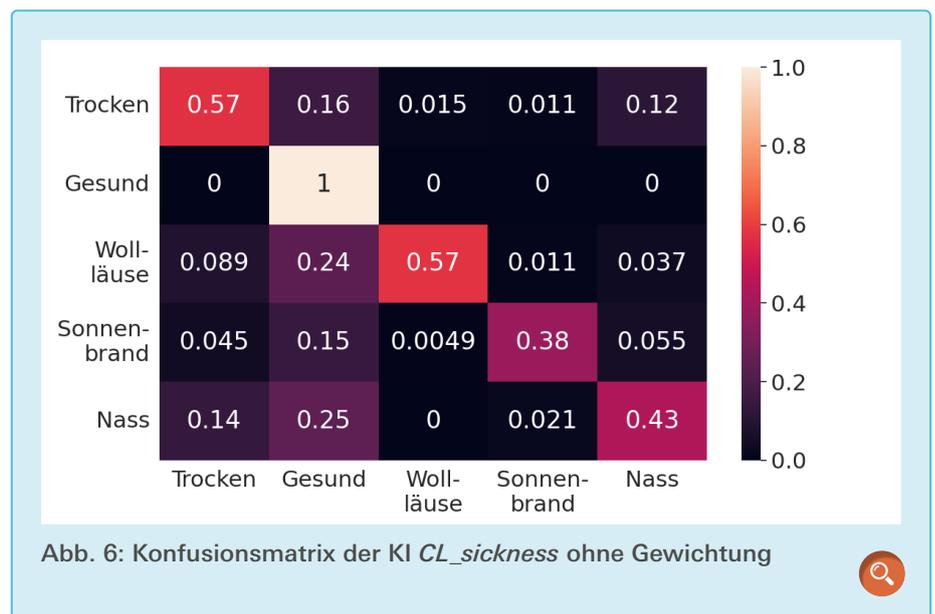
nen Erfahrung bei der Beschäftigung mit Pflanzen.

Das Gesamtsystem von *orch_ai_d* erkennt den Zustand einer Orchidee aktuell mit einer Genauigkeit von 77 Prozent (siehe [Abb. 7](#)). Das ist einerseits auf das Training der Teil-KIs, andererseits auf den RL-optimierten Gewichtungsalgorithmus zurückzuführen. Ohne Einsatz der Gewichtung liegt unsere Genauigkeit bei 66 Prozent (siehe [Abb. 6](#)).

3.5 Vergleichendes Training

Eine der Zielsetzungen von *orch_ai_d* ist ein möglichst geringer Datenbedarf. Inwiefern das System dieser entspricht, wurde durch vergleichende Trainings der vier Teileklassifizierer untersucht. Die Teileklassifizierer wurden mehrmals über je 256 Epochen auf zufällig zusammengestellten Datensätzen trainiert, die jeweils 100, 75, 50, 25 und 15 Prozent des Gesamtdatensatzes enthielten. Nach jedem Durchlauf wurde die Validierungsgenauigkeit ermittelt (siehe [Abb. 8](#)).

Dabei konnten wir nur für den Teileklassifizierer *Cl-root* bei 15 Prozent eine deutliche Verschlechterung der Validierungsgenauigkeit feststellen. Werte von über 100 Prozent weisen auf ein beginnendes Overfitting bei *Cl-leaf* und



CL-root hin. Allgemein setzt eine deutliche Verschlechterung der Validierungsgenauigkeit ein, wenn nur noch 25 Prozent des Gesamtdatensatzes genutzt wurde. Daraus schlussfolgern wir, dass das System auch mit weniger als der Hälfte der Daten gleichermaßen leistungsfähig wäre.

4. Versuchsreihe

In einer Versuchsreihe testeten wir die Hypothese, dass die Wahrscheinlichkeit, die eine KI für einen Zustand annimmt, proportional zur Ausprägung dieses Zustands steigt.

4.1 Versuchsdurchführung

Vier möglichst ähnliche, anfänglich ge-

sunde Orchideen wurden so behandelt, dass sich die Krankheitszustände Fäule durch Überwässerung, Vertrocknung, Wollläuse und Sonnenbrand ausbildeten. Täglich wurden die Pflanzen aus fünf verschiedenen Perspektiven fotografiert. Die Pflanzen standen dabei immer am selben Ort (siehe Tab. 4).

4.2 Versuchsergebnisse

Die Erzeugung der verschiedenen Krankheitszustände an den vier Versuchsorten funktionierte unterschiedlich gut. Die im Wasser aufbewahrte Orchidee P1 entwickelte statt Fäule zunächst Schimmel. Für den Wollausbefall (P3) stand nur Sekret der Tiere zur Verfügung, wodurch wir in erster Linie den visuellen Effekt nach-

bilden konnten. Die nicht gegossene Pflanze (P2) zeigte klare Symptome von zunehmender Trockenheit, und auf der Pflanze P4 bildeten sich nach zweimaliger Bestrahlung mit künstlichem Licht die für einen Sonnenbrand typischen Flecken aus.

Da sich bei der trockenen Orchidee die Entwicklung am kontinuierlichsten vollzog, entschlossen wir uns, die Hypothese anhand der Klassifizierung dieser Pflanze zu überprüfen.

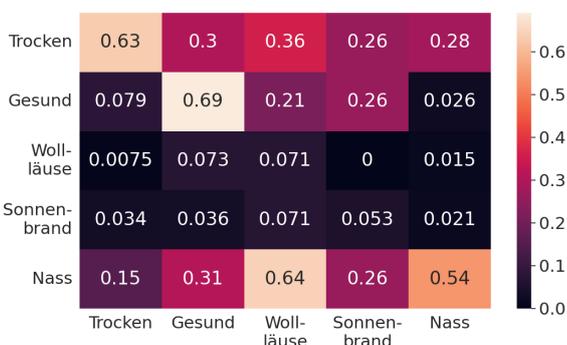
Der Zustand der Orchidee wird immer korrekt als trocken klassifiziert, auch wenn teilweise andere Zustände höhere Wahrscheinlichkeitswerte erhalten (siehe Abb. 9). Das ist allgemein positiv zu bewerten, da sonst eine falsche Be-



a) Matrix Zustandsklassifizierer Teilsystem Blüte (CL-flower), Training auf System 2



b) Matrix Zustandsklassifizierer Teilsystem Blatt (CL-leaf), Training auf System 1



c) Matrix Zustandsklassifizierer Teilsystem Wurzeln (CL-root), Training auf System 1



d) Matrix Zustandsklassifizierer Teilsystem Sprossachse (CL-stem), Training auf System 2

Abb 5: Konfusionsmatrizen der Zustandsklassifizierer



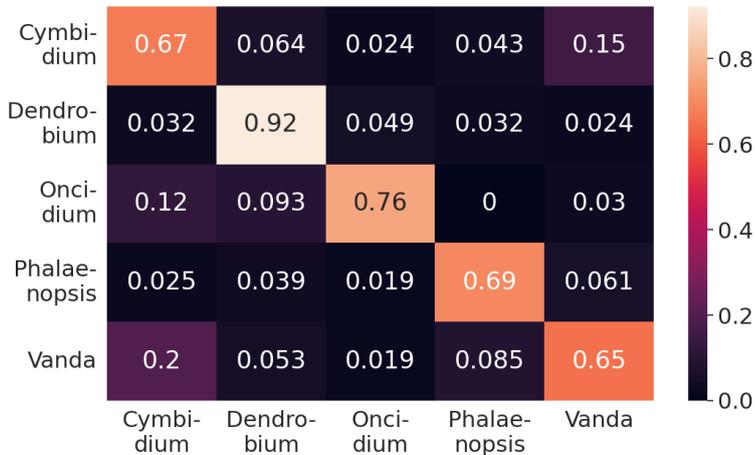


Abb. 7: Konfusionsmatrix der KI *CL_sickness* mit Gewichtung



handlung empfohlen werden könnte. Die Gattung (nicht abgebildet) wird an 24 von 26 Tagen richtig als *Phalaenopsis* angegeben.

Allerdings weist der Verlauf keine monotone Zunahme über den gesamten Zeitraum auf. Das könnte mehrere Gründe haben. Einerseits könnte es daran liegen, dass keine Verbindung zwischen der Ausprägung des Zustandes und der Sicherheit der Klassifizierung liegt. Andererseits könnte auch die Entwicklung des Zustands nicht so sein, so dass eine stetig bessere Klassifizierung möglich wird. Allerdings zeichnen sich in der [Abb. 9](#) zwei Bereiche mit monotoner Tendenz ab, bei denen klare Veränderungen in der Morphologie der Pflanze vorliegen: Von Tag 0 bis 9 trocknete die Pflanze sichtbar aus und die Wurzeln wurden silbrig. Ab Tag 20 erschlafften die Blätter zunehmend.

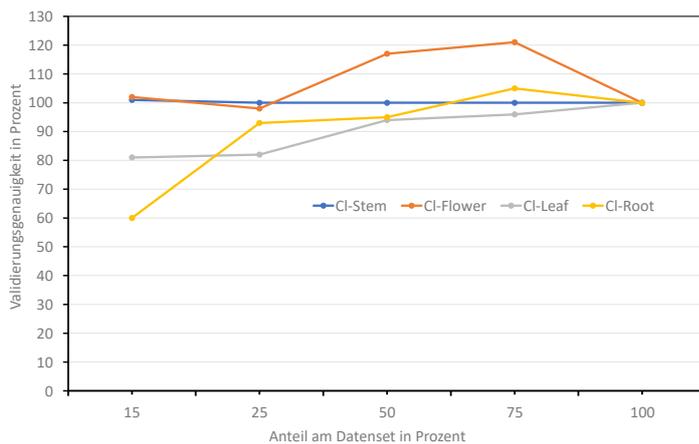


Abb. 8: Validierungsgenauigkeit in Abhängigkeit von der Größe des Trainingsdatensatzes



5. Die App *orch_ai_d*

Um die App *orch_ai_d* final nutzbar zu machen, programmierten wir eine serverbasierte Android-Applikation (ca. 1,5 MB) sowie den dazugehörigen Server. Mit der App können Nutzende Bilder ihrer Orchideen an unseren Server schicken, wo das KI-System die Klassifizierung durchführt und den entsprechenden Output sowie im Falle einer ge-

Tab. 4: Bedingungen der Versuchsreihe



Exemplar und Ausgangszustand	Zieldiagnose	Variable: Wasser	Variable: Lichtverhältnisse	Sonstige Variablen
P1 (<i>Phalaenopsis</i> , weiß), gesund	Fäule durch Überwässerung	Stehen in Wasserbehälter	Fenster nah, Südfenster	–
P2 (<i>Phalaenopsis</i> , weiß), leicht trocken	Vertrocknung	Kein Gießen	Fenster nah, Südfenster	–
P3 (<i>Phalaenopsis</i> , weiß), gesund	Wollläuse	Bedarfsgerechtes Gießen	Fenster nah, Ostfenster	Auftragen von Wollläusen
P4 (<i>Phalaenopsis</i> , weiß), leicht trocken	Sonnenbrand	Bedarfsgerechtes Gießen	Fenster nah, Südfenster	2 × 3 h unter hitzebildender Lampe

ringen Differenz der Sicherheiten auch die anderen möglichen Ergebnisse an das Endgerät zurücksendet. Damit sollen Fehler, die bei der aktuellen Genauigkeit des Gesamtsystems statistisch gesehen in etwa einem Fünftel der Fälle vorkommen, ausgeglichen werden. Zur statistischen Wahrscheinlichkeit der Fehler ist allerdings anzumerken, dass für die Ermittlung dieses Wertes von der gleichen Häufigkeit aller Zustände ausgegangen wurde. Die tatsächliche Fehlerhäufigkeit sollte also, da vor allem die seltenen Zustände schlechter klassifiziert werden, um Einiges geringer sein.

In der App sind sowohl ein Kamera- als auch ein Galeriemodus verfügbar, um Fotos einzuspeisen.

Die App ist im Google Play Store verfügbar [4], wurde allerdings erst relativ selten (etwa zehnmal) heruntergeladen, weshalb noch keine wirkliche Auswertung der eingespeisten Daten möglich ist.

6. Zusammenfassung und Ausblick

Das Ziel dieser Arbeit war es, mit wenigen Daten im Training und einer hohen Variabilität des Inputs höchstmögliche Genauigkeit zu erlangen. Durch Training und Anpassung der Gewichtung ist es gelungen, eine hohe Genauigkeit der KI zu erreichen. Die getroffenen Klassifizierungen sowohl der Gattung als auch des Krankheitszustands sind in etwa vier Fünfteln aller Fälle (79 Prozent für die Gattung und 77 Prozent für den Krankheitszustand) korrekt.

Grundlage hierfür ist die automatisierte Einordnung der Pflanzenteile in Bounding Boxen. Diese Aufteilung des Bildes zur Lösung eines Gesamtproblems stellt einen deutlichen Fortschritt gegenüber der Klassifizierung am Gesamtbild dar. Die Nutzung der Bounding Boxen ist dabei einer der einfachsten Wege, einer künstlichen Intelligenz eine Hilfestellung in der Auswertung von Daten zu bieten, vor allem, wenn mehr als ein Objekt sichtbar ist [22]. Sie erhöht einerseits die Sicherheit, dass die KI nur die relevanten Dinge beachtet, andererseits liefert sie die Metadaten für die Klassifizierung anhand der einzelnen Pflanzenorgane.

Als Ergebnis dieses Projekts steht die

serverbasierte App *orch_ai_d* zur Verfügung. Für Personen, die sich mit den Befindlichkeiten von Orchideen nicht auskennen, kann das eine bedeutende Hilfe bei der Pflege ihrer Pflanzen darstellen.

Zukünftige Arbeiten lassen sich von folgenden Überlegungen leiten: Allgemein ist die Architektur der KI durch ihren kleinteiligen, baukastenartigen Aufbau leicht um mehr Faktoren wie die Lebensphase oder zusätzliche Pflanzenteile erweiterbar. Auch innerhalb der Klassifizierer könnten zusätzliche Optionen (wie Blattläuse oder die Gattung *Orchis*) hinzugefügt werden. So könnten schrittweise der Funktionsbereich der KI vergrößert und weitere Krankheiten, Arten und damit einhergehend auch Anwendungsbereiche, beispielsweise die industrielle Pflanzenzüchtung, erschlossen werden.

Es ist wahrscheinlich, dass ein Teil des Trainings, unter anderem zur Bestim-

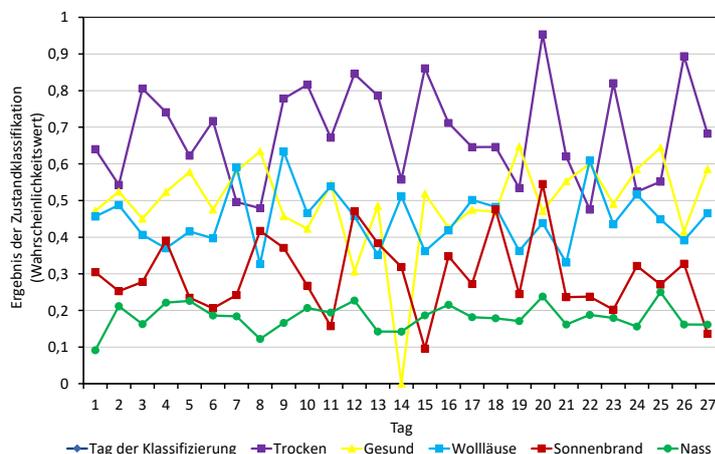


Abb. 9: Zeitlicher Verlauf der klassifizierten Wahrscheinlichkeitswerte der einzelnen Zustände für die behandelten Orchideen



Abb. 10: Der Hauptbildschirm der App *orch_ai_d*

mung der Bounding Boxen, direkt auf Gattungen derselben Familie übertragbar ist und vor allem die Bestimmung makroskopischer Pflanzenschädlinge nahezu unabhängig von der Pflanzenart funktioniert. Das Training für neue Gattungen würde sich dann nur auf die Aspekte fokussieren, die sie von den bereits bekannten unterscheiden, was mit einer großen Zeit- und Datensparnis einhergeht.

Die Gattungsklassifizierung könnte um Klassifizierer für die einzelnen taxonomischen Stufen erweitert werden, um eine schrittweise Annäherung zu erhalten und Fehler abzuschwächen. Das Ergebnis höherer Klassifizierer, beispielsweise der Familie, könnte eingesetzt werden, um das Ergebnis der Zustandsklassifizierer zu filtern und eine passende Gewichtung zu nutzen. Diese würden für alle Klassen des Datensatzes eine Sicherheit angeben, sodass pro erkanntem Pflanzenteil ein Klassifizierer genügen würde. Nur die Ergebnisse der Klassen für die erkannte Familie aber würden in der Zusammenfassung berücksichtigt. Eine untere taxonomische Ebene (Gattung oder Art) würde den genauen Output bestimmen, um weiterhin möglichst spezifische Hinweise zu geben.

Danksagung

Friedrich Koch (Schüler am Humboldt-Gymnasium) hat uns bei der Erstellung der Grafiken, der Formatierung unseres Plakats und durch alle Nervenzusammenbrüche und Panikanfälle geholfen und uns außerdem seinen PC für etwa 25 Stunden Training zur Verfügung gestellt.

Friedrich Koch, Robert Koch, Jonathan Wentzek, Tanrek Groepl, Kilian Danke und Milan Jaenicke (Schüler am Humboldt-Gymnasium) haben uns durch das Ziehen von Boxen auf den Bildern unterstützt, die zum Training des Teilklassifizierers genutzt wurden.

Thanh Thuy Grabowski-Le (Geschäfts-

führerin von Le Orchid UG, Joachimsthaler Straße 14) hat uns umfangreich zur Pflege von Orchideen beraten und uns eine mit Wollläusen befallene Orchidee geschenkt.

Eduard Nord (Verkäufer bei Blume 2000, Tauentzienstraße 1) hat uns zu Orchideengattungen im Verkauf beraten und uns mit unverkäuflichen Orchideen unterstützt.

Dipl. Ing. Y. Olad (Geschäftsführung von Kant Floristik, Kantstraße 154) hat uns Auskunft zur Pflege und Lebensdauer von Orchideen gegeben.

Katja Grimm, Dennis Kobert, Viktoria Bachmann und Raul Heimann haben uns durch wertvolle Tipps und Verbesserungsvorschläge sehr geholfen.

Vielen Dank an alle, die uns bei unserer Forschung unterstützt oder beraten haben!

Literaturverzeichnis

- [1] Advanco GmbH, Hrsg. Orchideenarten im Lexikon von A–Z – Orchideen nach Bildern bestimmen. url: <https://www.plantopedia.de/orchideenarten/> (besucht am 15.01.2023).
- [2] Agrio. url: <https://agrio.app/> (besucht am 18.02.2023).
- [3] Dagmar Dittfeld. Wollläuse auf Orchideen bekämpfen – Hausmittel und andere Tricks. url: <https://www.gartentipps.com/wolllaeuse-auf-orchideen-bekaempfen.html> (besucht am 20.01.2023).
- [4] Alois Bachmann und Elora Marx. orch_ai_d. url: <https://play.google.com/store/apps/details?id=ai.tobitoyota.orchaid> (besucht am 26.02.2024).
- [5] Flora Incognita. url: <https://floraincognita.de/die-flora-incognita-app/> (besucht am 18.02.2023).
- [6] Vincent Francois-Lavet u. a. „An Introduction to Deep Reinforcement Learning“. In: arXiv:1811.12560 (2018). url: <https://arxiv.org/abs/1811.12560> (besucht am 25.06.2024).

- [7] Patrick Helmig. Machine Learningverfahren zur Klassifizierung von Daten. url: <https://rocketloop.de/de/blog/klassifizierungsverfahren/> (besucht am 09.03.2024).
- [8] HG Insights. Companies currently using Pytorch. url: <https://discovery.hgdata.com/product/pytorch> (besucht am 20.01.2023).
- [9] Institut für Lernen und Innovation in Netzwerken, Hrsg. Nachvollziehbare KI-Entscheidungen. url: <https://kompetenzzentrum-karlsruhe.de/themen/nachvollziehbare-ki-entscheidungen/> (besucht am 16.01.2023).
- [10] Hendrik Kehres. Sonnenbrand bei deiner Orchidee – Symptome und Sonnenschutzmaßnahmen. url: <https://www.pflanzen.schule/orchideen/orchidee-sonnenbrand/> (besucht am 20.01.2023).
- [11] Marcel Klitzsch. Orchideen Wurzeln und Blätter faulen ab – Was tun? url: <https://www.gartenlexikon.de/orchideen-faulen/#gegenmassnahmen> (besucht am 20.01.2023).
- [12] Labelbox. url: <https://labelbox.com/> (besucht am 20.01.2023).
- [13] Luise Weickmann und Maximilian Otten. Object Detection: Wie Maschinen Objekte erkennen. url: <https://lamarr-institute.org/de/blog/object-detection/> (besucht am 08.03.2024).
- [14] Meta, Hrsg. PyTorch. url: <https://ai.facebook.com/tools/pytorch/> (besucht am 20.01.2023).
- [15] PictureThis. url: <https://www.picturethisai.com/de/app> (besucht am 18.02.2023).
- [16] Plantix. url: <https://plantix.net/en/> (besucht am 18.02.2023).
- [17] Roboflow. url: <https://roboflow.com/> (besucht am 20.01.2023).
- [18] Christian Rozsenich. Arten und Bedeutung von KI-Trainingsdaten. url: <https://www.clickworker.de/kunden-blog/arten-bedeutung-ki-trainingsdaten/> (besucht am 16.01.2023).
- [19] Matthias Rudolf und Wiltrud Kuhlisch. Biostatistik. Eine Einführung für Bio- und Umweltwissenschaftler. München: Pearson, 2021.
- [20] W. Sarachai u. a. „Orchids Classification Using Spatial Transformer Network with Adaptive Scaling“. In: Intelligent Data Engineering and Automated Learning – IDEAL 2019. Hrsg. von H. Yin u. a. Bd. 11871. Lecture Notes in Computer Science. Springer, Cham., 2019. url: https://doi.org/10.1007/978-3-030-33607-3_1.

- [21] Statista GmbH, Hrsg. Beliebteste blühende Zimmerpflanzen in Deutschland nach Marktanteil in den Jahren 2020 und 2021. url: <https://de.statista.com/statistik/daten/studie/206577/umfrage/beliebteste-bluehende-zimmer5c-pflanzen-nach-marktanteil/> (besucht am 20.01.2023).
- [22] Inc. Superb AI, Hrsg. An Introduction to Bounding Boxes [+ Best Practices]. url: <https://www.superb-ai.com/blog/an-introduction-to-bounding-boxes-best-practices> (besucht am 17.01.2023).
- [23] Jon Vanzile. The Spruce. url: <https://www.the-spruce.com/> (besucht am 01.09.2022).
- [24] Chien-Yao Wang, Alexey Bochkovskiy und Hong-Yuan Mark Liao. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. Cornell University. url: <https://arxiv.org/abs/2207.02696> (besucht am 06.07.2022).
- [25] Wikimedia Inc., Hrsg. Confusion matrix. url: https://en.wikipedia.org/wiki/Confusion_matrix (besucht am 18.02.2023).
- [26] Pflanzendoktor. url: <https://www.neudorff.de/rat-hilfe/apps.html> (besucht am 21.03.2024)

Publiziere auch Du hier!

Forschungsarbeiten von Schüler/Inne/n und Student/Inn/en

In der Jungen Wissenschaft werden Forschungsarbeiten von SchülerInnen, die selbstständig, z. B. in einer Schule oder einem Schülerforschungszentrum, durchgeführt wurden, veröffentlicht. Die Arbeiten können auf Deutsch oder Englisch geschrieben sein.

Wer kann einreichen?

SchülerInnen, AbiturientInnen und Studierende ohne Abschluss, die nicht älter als 23 Jahre sind.

Was musst Du beim Einreichen beachten?

Lies die [Richtlinien für Beiträge](#). Sie enthalten Hinweise, wie Deine Arbeit aufgebaut sein soll, wie lang sie sein darf, wie die Bilder einzureichen sind und welche weiteren Informationen wir benötigen. Solltest Du Fragen haben, dann wende Dich gern schon vor dem Einreichen an die Chefredakteurin Sabine Walter.

Lade die [Erstveröffentlichungserklärung](#) herunter, drucke und fülle sie aus und unterschreibe sie.

Dann sende Deine Arbeit und die Erstveröffentlichungserklärung per Post an:

Chefredaktion Junge Wissenschaft

Dr.-Ing. Sabine Walter
Paul-Ducros-Straße 7
30952 Ronnenberg
Tel: 05109 / 561508
Mail: sabine.walter@verlag-jungewissenschaft.de

Wie geht es nach dem Einreichen weiter?

Die Chefredakteurin sucht einen geeigneten Fachgutachter, der die inhaltliche Richtigkeit der eingereichten Arbeit überprüft und eine Empfehlung ausspricht, ob sie veröffentlicht werden kann (Peer-Review-Verfahren). Das Gutachten wird den Euch, den AutorInnen zugeschickt und Du erhältst gegebenenfalls die Möglichkeit, Hinweise des Fachgutachters einzuarbeiten.

Die Erfahrung zeigt, dass Arbeiten, die z. B. im Rahmen eines Wettbewerbs wie **Jugend forscht** die Endrunde erreicht haben, die besten Chancen haben, dieses Peer-Review-Verfahren zu bestehen.

Schließlich kommt die Arbeit in die Redaktion, wird für das Layout vorbereitet und als Open-Access-Beitrag veröffentlicht.

Was ist Dein Benefit?

Deine Forschungsarbeit ist nun in einer Gutachterzeitschrift (Peer-Review-Journal) veröffentlicht worden, d. h. Du kannst die Veröffentlichung in Deine wissenschaftliche Literaturliste aufnehmen. Deine Arbeit erhält als Open-Access-Veröffentlichung einen DOI (Data Object Identifier) und kann von entsprechenden Suchmaschinen (z. B. BASE) gefunden werden.

Die Junge Wissenschaft wird zusätzlich in wissenschaftlichen Datenbanken gelistet, d. h. Deine Arbeit kann von Experten gefunden und sogar zitiert werden. Die Junge Wissenschaft wird Dich durch den Gesamtprozess des Erstellens einer wissenschaftlichen Arbeit begleiten – als gute Vorbereitung auf das, was Du im Studium benötigst.

Richtlinien für Beiträge

Für die meisten Autor/Inn/en ist dies die erste wissenschaftliche Veröffentlichung. Die Einhaltung der folgenden Richtlinien hilft allen – den Autor/innen/en und dem Redaktionsteam

Die Junge Wissenschaft veröffentlicht Originalbeiträge junger AutorInnen bis zum Alter von 23 Jahren.

- Die Beiträge können auf Deutsch oder Englisch verfasst sein und sollten nicht länger als 15 Seiten mit je 35 Zeilen sein. Hierbei sind Bilder, Grafiken und Tabellen mitgezählt. Anhänge werden nicht veröffentlicht. Deckblatt und Inhaltsverzeichnis zählen nicht mit.
- Formulieren Sie eine eingängige Überschrift, um bei der Leserschaft Interesse für Ihre Arbeit zu wecken, sowie eine wissenschaftliche Überschrift.
- Formulieren Sie eine kurze, leicht verständliche Zusammenfassung (maximal 400 Zeichen).
- Die Beiträge sollen in der üblichen Form gegliedert sein, d. h. Einleitung, Erläuterungen zur Durchführung der Arbeit sowie evtl. Überwindung von Schwierigkeiten, Ergebnisse, Schlussfolgerungen, Diskussion, Liste der zitierten Literatur. In der Einleitung sollte die Idee zu der Arbeit beschrieben und die Aufgabenstellung definiert werden. Außerdem sollte sie eine kurze Darstellung schon bekannter, ähnlicher Lösungsversuche enthalten (Stand der Literatur). Am Schluss des Beitrages kann ein Dank an Förderer der Arbeit, z. B. Lehrer und

Sponsoren, mit vollständigem Namen angefügt werden. Für die Leser kann ein Glossar mit den wichtigsten Fachausdrücken hilfreich sein.

- Bitte reichen Sie alle Bilder, Grafiken und Tabellen nummeriert und zusätzlich als eigene Dateien ein. Bitte geben Sie bei nicht selbst erstellten Bildern, Tabellen, Zeichnungen, Grafiken etc. die genauen und korrekten Quellenangaben an (siehe auch [Erstveröffentlichungserklärung](#)). Senden Sie Ihre Bilder als Originaldateien oder mit einer Auflösung von mindestens 300 dpi bei einer Größe von 10 · 15 cm! Bei Grafiken, die mit Excel erstellt wurden, reichen Sie bitte ebenfalls die Originaldatei mit ein.
- Vermeiden Sie aufwendige und lange Zahlentabellen.
- Formelzeichen nach DIN, ggf. IUPAC oder IUPAP verwenden. Gleichungen sind stets als Größengleichungen zu schreiben.
- Die Literaturliste steht am Ende der Arbeit. Alle Stellen erhalten eine Nummer und werden in eckigen Klammern zitiert (Beispiel: Wie in [12] dargestellt ...). Fußnoten sieht das Layout nicht vor.
- Reichen Sie Ihren Beitrag sowohl in ausgedruckter Form als auch als PDF

ein. Für die weitere Bearbeitung und die Umsetzung in das Layout der Jungen Wissenschaft ist ein Word-Dokument mit möglichst wenig Formatierung erforderlich. (Sollte dies Schwierigkeiten bereiten, setzen Sie sich bitte mit uns in Verbindung, damit wir gemeinsam eine Lösung finden können.)

- Senden Sie mit dem Beitrag die [Erstveröffentlichungserklärung](#) ein. Diese beinhaltet im Wesentlichen, dass der Beitrag von dem/der angegebenen AutorIn stammt, keine Rechte Dritter verletzt werden und noch nicht an anderer Stelle veröffentlicht wurde (außer im Zusammenhang mit **Jugend forscht** oder einem vergleichbaren Wettbewerb). Ebenfalls ist zu versichern, dass alle von Ihnen verwendeten Bilder, Tabellen, Zeichnungen, Grafiken etc. von Ihnen veröffentlicht werden dürfen, also keine Rechte Dritter durch die Verwendung und Veröffentlichung verletzt werden. Entsprechendes [Formular](#) ist von der Homepage www.junge-wissenschaft.ptb.de herunterzuladen, auszudrucken, auszufüllen und dem gedruckten Beitrag unterschrieben beizulegen.
- Schließlich sind die genauen Anschriften der AutorInnen mit Telefonnummer und E-Mail-Adresse sowie Geburtsdaten und Fotografien (Auflösung 300 dpi bei einer Bildgröße von mindestens 10 · 15 cm) erforderlich.
- Neulingen im Publizieren werden als Vorbilder andere Publikationen, z. B. hier in der Jungen Wissenschaft, empfohlen.

Impressum

[JUNGE]
wissenschaft



Junge Wissenschaft

c/o Physikalisch-Technische
Bundesanstalt (PTB)
www.junge-wissenschaft.ptb.de

Redaktion

Dr. Sabine Walter, Chefredaktion
Junge Wissenschaft
Paul-Ducros-Str. 7
30952 Ronnenberg
E-Mail: sabine.walter@verlag-jungewissenschaft.de
Tel.: 05109 / 561 508

Verlag

Dr. Dr. Jens Simon,
Pressesprecher der PTB
Bundesallee 100
38116 Braunschweig
E-Mail: jens.simon@ptb.de
Tel.: 0531 / 592 3006
(Sekretariat der PTB-Pressestelle)

Design & Satz

Sebastian Baumeister
STILSICHER – Grafik & Werbung
E-Mail: baumeister@stilsicher.design
Tel.: 05142 / 98 77 89



Physikalisch-Technische Bundesanstalt
Bundesallee 100