

Abschlussbericht

Entwicklung eines künstlich-intelligenten zerstörungsfreien Ultraschall-Messsystems zur portablen und kontaminierungsfreien Reife- und Haltbarkeitsprüfung von Lebensmitteln (KI-UltraHaltbarkeit)

13FH566IX6

Motivation

Das Kaufverhalten in Lebensmittelgeschäften wird normalerweise von der Qualität, dem Aussehen, der Frische und dem Geruch der Produkte bestimmt. Produkte, die diese Kriterien nicht erfüllen, werden jedoch nicht gekauft und landen im Abfall. Diese organischen Abfälle können sich weltweit auf bis zu 1,3 Milliarden Tonnen pro Jahr summieren und haben enorme negative Auswirkungen auf die Umwelt. Nach Angaben des Bundesministeriums für Ernährung und Landwirtschaft (BMEL) werden in Deutschland im Jahr 2020 11 Millionen Tonnen Bioabfälle in den Mülltonnen landen, die aufgrund der freigesetzten Gigatonnen CO2-Emissionen zwischen 20 und 30 % der Umweltbelastung in der EU ausmachen [1]. Erschwerend kommt hinzu, dass Untersuchungen zeigen, dass jede Sekunde etwa 313 kg essbare Lebensmittel im Müll landen [2].

Es wird jedoch erwähnt, dass mindestens 50 % der entsorgten Lebensmittel durch bessere Planung und Lagerungsstrategien eingespart werden könnten [1]. Dies gilt vor allem für Produkte, deren Qualität durch bloße visuelle Inspektion nicht leicht zu erkennen ist, z. B. bei dickschaligen Früchten (Wassermelone, Melone, Avocado usw.), da Reifegrad und Haltbarkeit nur schwer zu erkennen sind. Daher ist es in den meisten Fällen notwendig, die Früchte aufzuschneiden, um die Qualität von Obst und Gemüse zu prüfen, was zu einem höheren Abfallaufkommen führt.

Das Ziel des FH-IngenieurNachwuchs BMBF-Projekts KI-UltraHaltbarkeit ist es, die Qualität von dickschaligem Obst zu bestimmen, ohne dabei organischen Abfall zu erzeugen. Unser Ziel ist es, einen Beitrag zum Umweltschutz zu leisten, indem wir eine zerstörungsfreie Methode entwickeln, die akustische Resonanz und künstliche Intelligenz kombiniert, um die Haltbarkeit von Obst und Gemüse zu bestimmen und den Beteiligten in der Lieferkette eine Entscheidungshilfe bei der Lagerplanung zu geben. Das Projekt findet in enger Zusammenarbeit zwischen der HTW Saar, EDEKA, Globus und dem Fraunhofer IZFP statt.

Um eine solche Lösung zu entwickeln, wurden verschiedene zerstörungsfreie Methoden wie gepulste Thermografie, Farbbildanalyse, Ultraschall, akustische Resonanz, Aroma- und Geschmacksvorhersage sowie zusätzliche Methoden zur Bewältigung spezifischer Situationen in Betracht gezogen und getestet. Nachfolgend wird eine kurze Beschreibung der einzelnen Methoden mit den entsprechenden Ergebnissen gegeben.

Blitzthermografie

Um nicht sichtbare Defekte in bestimmten Materialien zu erkennen, ist die Thermografie ein wertvolles nicht-invasives Bildgebungsverfahren mit zwei beliebten Ansätzen: aktiv und passiv [3]. Unter den aktiven Methoden sticht die Blitzthermografie als eine weit verbreitete Technik hervor, die darauf abzielt, Temperaturmuster des Bauteils als Reaktion auf eine erzeugte Wärmequelle zu analysieren, die von hochenergetischen oder blinkenden Lampen stammen kann und von Millisekunden bis Mikrosekunden dauert [3]. Die Impulsthermografie eignet sich besonders gut für die Erkennung von Defekten in industriellen Materialien wie Metall, Stahl und Verbundwerkstoffen [7]. Die schnelle und kontrollierte Anwendung von Wärme ermöglicht die Identifizierung von Anomalien unter der Oberfläche, Delaminationen, Rissen und Hohlräumen, was sie zu einer bevorzugten Methode für die industrielle Qualitätskontrolle macht.

In Anlehnung an die erfolgreichen Ergebnisse früherer Veröffentlichungen über verschiedene Früchte [4] haben wir das Potenzial der Impulsthermografie als alternative Methode zur Bewertung des äußeren und inneren Zustands landwirtschaftlicher Erzeugnisse untersucht. Ziel war es, nicht sichtbare Mängel und Qualitätsschwankungen bei verschiedenen landwirtschaftlichen Produkten aufzudecken.

In unserer Studie wurde die Impulsthermografie als Sichtprüfungstechnik für Galiamelonen (750), Wassermelonen (365) und Äpfel (2.000) eingesetzt. Zusätzlich wurden Umgebungsdaten wie Luftfeuchtigkeit, Raumtemperatur und Gewicht der Früchte für eine erste Analyse erfasst und alle 3 bis 4 Tage Fotos aufgenommen, um Veränderungen und Entwicklungen im Laufe der Zeit zu beobachten. Während des Experiments wurde eine Thermosensorik QWIP Dualband 384 mit einer Dualband-Kamera eingesetzt, die, wie in [23] erwähnt, gleichzeitig mit 4,4 - 5,2 μm (MW) und 7,8 - 8,8 μm (LW) arbeitet und eine Wärmeimpulsvariation zwischen 10 und 143 fps aufweist.

Um verborgene Muster in Wärmebildern aufzudecken, haben wir eine Modellarchitektur für ein neuronales Faltungsnetzwerk (Convolutional Neural Network, CNN) entwickelt, die ein Wärmebild als Eingabe nimmt und die Haltbarkeit der Frucht als Ergebnis mit drei Klassen (0, 1 und 2) vorhersagt. Jede Klasse steht für eine Alter Klasse 0: <7 Tage, Klasse 1: 8-15 Tage und Klasse 3: >15 Tage. Abbildung 1 zeigt das Architekturdiagramm des Modells und veranschaulicht den Fluss von den Eingangsbildern auf der linken Seite durch die inneren Schichten des Netzwerks bis zum Ausgang auf der rechten Seite.

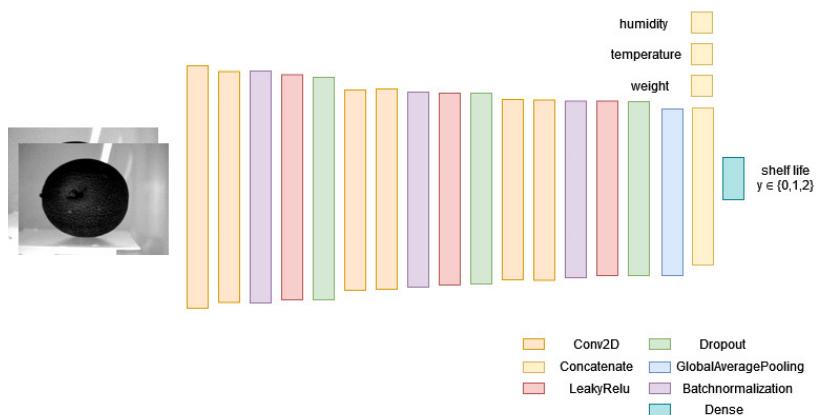


Abbildung 1. CNN-Architektur für Wärmebilder. Interne Schichten sind dafür verantwortlich, Details aus dem Bild zu extrahieren und die entsprechenden Umgebungsvariablen zu kombinieren, um das Vorhersageergebnis zu verbessern.

Die Datenerweiterung spielt eine entscheidende Rolle bei der Abschwächung von Problemen wie Overfitting beim Deep Learning [5]. Wir haben Methoden zur Datenerweiterung implementiert, darunter Mixup (Kombination mehrerer Bilder), Flipping, Zufallszoom und Puzzle, die über die empirische Risikominimierung hinausgehen, indem sie die Minimierung des Umgebungsrisikos berücksichtigen [6]. Beispiele für diese Transformationen sind in Abbildung 2 zu sehen.

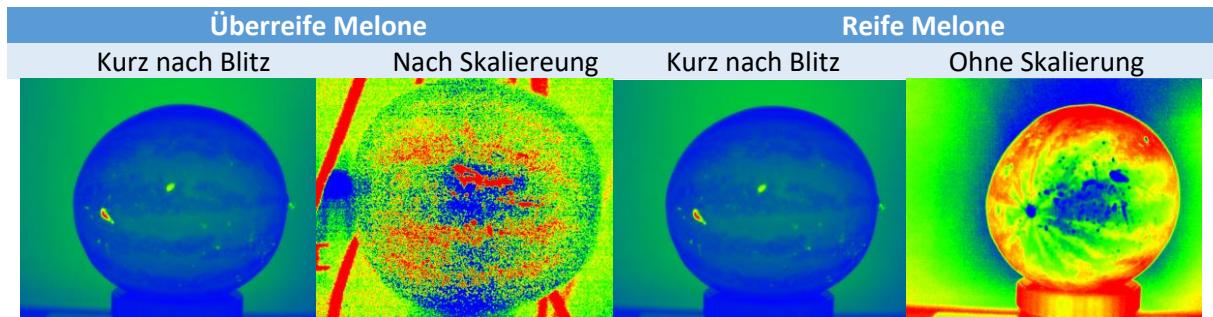


Abbildung 2. Wärmebildvergleich zwischen reifen und überreifen Melonen. Die Tabelle über den Bildern beschreibt die Zeitpunkte nach der Stimulation und Skalierung der Frucht, um eine bessere interne Analyse zu ermöglichen.

Wir stellten jedoch fest, dass eine Erhöhung des Umfangs der Datenerweiterung nicht zu einer signifikanten Verbesserung des Trainingsprozesses führte. Stattdessen beobachteten wir günstigere Ergebnisse, wenn wir zufällige Datentransformationen anwendeten, anstatt uns nur auf eine einzige Datentransformationstechnik zu verlassen.

Um die Leistung verschiedener 3-Klassen-KI-Klassifizierungsmethoden zu bewerten, haben wir mehrere Ansätze verglichen und denjenigen mit der höchsten Genauigkeit ausgewählt (siehe Tabelle 1).

Frucht	KI Methode	Accuracy		Recall		Precision	
		Training	Testing	Training	Testing	Training	Testing
Galia	CNN (3 Klassen)	80.80 %	80.27 %	89 %	85 %	49 %	48 %

Tabelle 1. Zusammenfassung des Leistungsvergleichs zwischen den traditionellen Klassifizierungsmethoden und einem CNN für Galia-Melonen, der zeigt, dass der letztere Ansatz genaue Ergebnisse liefert.

Die grafischen Ergebnisse der Genauigkeit und der Verlustfunktion für den CNN-Ansatz nach 100 Epochen sind in Abbildung 3 dargestellt:

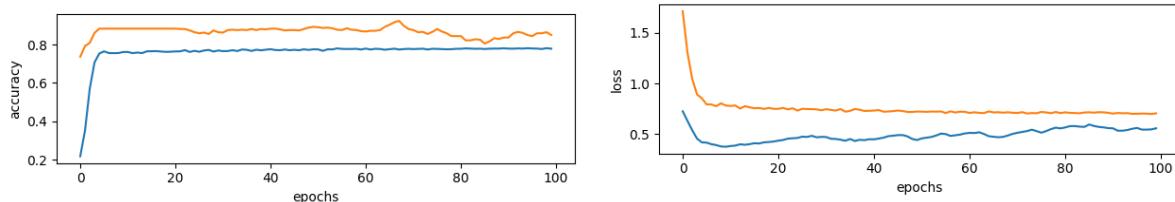


Abbildung 3. CNN-Genauigkeit (links) und Verlust (rechts) mit Wärmebildern für Trainings- (orange) und Testdatensätze (blau).

Das Modell erreichte eine endgültige Genauigkeit von ca. 80,27 % auf dem Testdatensatz. Dieses Ergebnis ist zwar lobenswert, blieb aber etwas hinter unseren Erwartungen zurück und entsprach nicht dem von uns angestrebten Leistungsniveau.

Farbbildanalyse

Im Gegensatz zu dickschaligen Früchten weisen bestimmte Produkte wie Tomaten und Bananen Reifemarkale auf, die sich durch die Bewertung der Qualität ihrer Oberfläche bestimmen lassen. Die Farbe der Oberfläche von Äpfeln beispielsweise ist ein entscheidender Reifegradindikator. Aufbauend auf diesem Prinzip haben wir ein Deep-Learning-Modell (Abbildung 4) entwickelt, das sich auf Farbbilder mit einer Kombination von Umweltfaktoren wie Gewicht, Temperatur und Feuchtigkeit konzentriert, um Fotos von Wassermelonen (500), Galia-Melonen (1495) und Äpfeln (7428) zu analysieren. Die Bilder wurden in einer Dunkelkammer mit einer Canon EOS 450D (4272 x 2848 Pixel) aufgenommen, wie in einer Masterarbeit im Rahmen des Projekts [23] beschrieben ist. Die Architektur des Modells ist wie folgt:

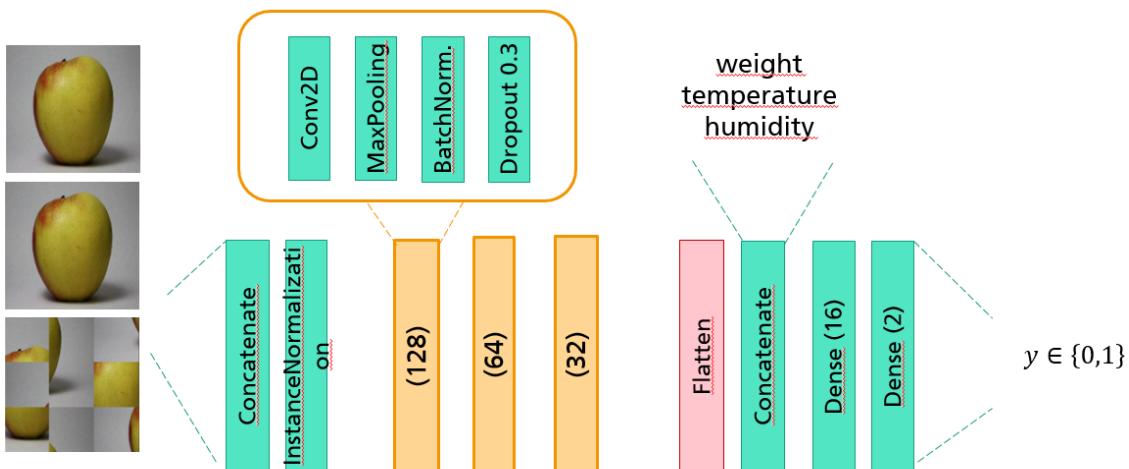
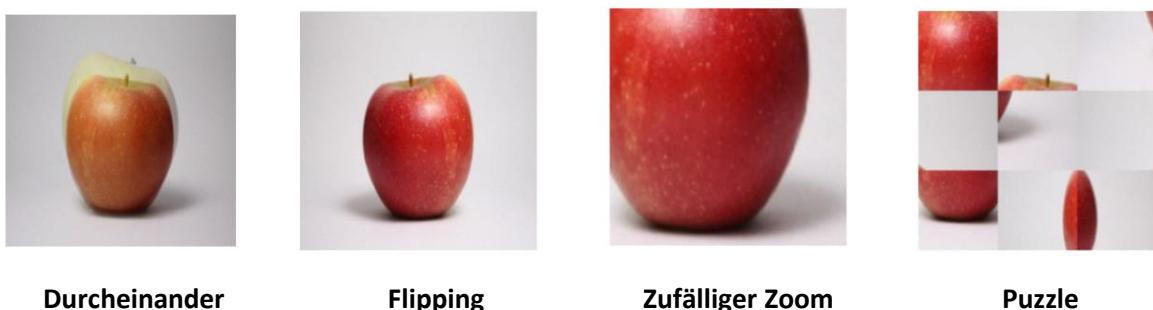


Abbildung 4. CNN-Netzwerkarchitektur, die RGB-Bilder für die Reife- und Haltbarkeitsvorhersage verarbeitet [23].

In diesem Ansatz schlagen wir eine CNN-Modellarchitektur zur Verarbeitung von Farbbildern von Früchten vor. Der Input des Modells ist ein Bild, das bereits mit verschiedenen Datenanreicherungstechniken transformiert wurde (Abbildung 5), wodurch seine Vielfalt und Robustheit erhöht wird. Um den zeitlichen Kontext des Reifungsprozesses von Früchten zu erfassen, werden mehrere Bilder zu einem einzigen Element kombiniert. Das Netzwerk besteht aus einer Reihe von Schichten, die einzelne Faltungen verwenden und mit hilfreichen Zusatzinformationen, den so genannten Hilfsvariablen, verknüpft sind, um mehr Details in der binären Klassifizierungsausgabe (1 oder 0) zu erfassen, die angibt, ob die Frucht reif ist oder nicht.



Durcheinander

Flipping

Zufälliger Zoom

Puzzle

Abbildung 5. Verschiedene Datenerweiterungsbeispiele von Äpfeln für unser CNN-Modell.

Das Modell wies eine hohe Genauigkeit von 90,60 % im Testdatensatz auf (siehe Tabelle 2).

KI Methode	Frucht	Accuracy	
		Training	Testing
CNN (3 Klasse)	Apfel	90.32 %	90.60 %

Tabelle 2. Gesamtleistung des farbbasierten CNN-Modells.

Obwohl diese hohe Genauigkeit auf den ersten Blick ermutigend erscheint, müssen wir vorsichtig sein, da das Modell während des Trainingsprozesses Anzeichen einer Überanpassung zeigte (siehe Abbildung 6). Um dieses Problem zu lösen, müssen wir das Modell weiter analysieren und feinabstimmen. Dieser Prozess umfasst die Anpassung der Parameter und der Architektur des Modells, um eine bessere Verallgemeinerung und eine bessere Leistung bei neuen, ungesiehenen Daten zu gewährleisten. Durch die Feinabstimmung des Modells wollen wir die Überanpassung reduzieren und ein robusteres und zuverlässigeres Ergebnis erzielen, das in der Lage ist, den Reifegrad von Äpfeln in verschiedenen Szenarien genau vorherzusagen.

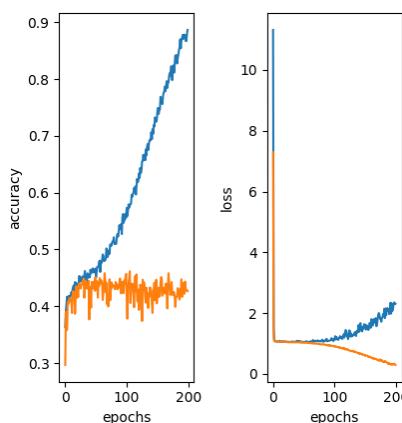


Abbildung 6. Genauigkeit und Verlust für Trainings- (blau) und Testdatensatz (Test), wobei die Überanpassung in unseren Ergebnissen hervorgehoben wird.

Ultraschall

Ultraschall, eine zerstörungsfreie Methode, nutzt Hochfrequenzwellen, um ein inneres Bild der Frucht zu erzeugen. Unser Ziel war es, die Genauigkeit des Ultraschalls bei der Bestimmung des Reifegrads von Wassermelonen zu bewerten. Es wurden mehrere Versuchsaufbauten für diese Technik untersucht, wobei man sich auf frühere Forschungsarbeiten stützte, die die Möglichkeit der Gewinnung von Messwerten mittels Ultraschall aufzeigten [24]. Auf der Grundlage der bisherigen Literatur wurden verschiedene Ansätze ausprobiert, einschließlich unterschiedlicher Frequenzbereiche. Anfänglich wurden Phased-Array-Anordnungen verwendet, die nach und nach zu niedrigeren Frequenzbereichen (1-3 MHz) übergingen und schließlich Einzelarray-Anordnungen (unter 500 kHz) einsetzten, wie in früheren Forschungsarbeiten beschrieben.

Während unserer Messkampagne gingen wir davon aus, dass Wassermelonen überwiegend aus Wasser bestehen. Unsere Experimente ergaben jedoch, dass Wassermelonen auf der Mikroebene auch Luft enthalten und eine andere Mikrostruktur aufweisen als Fleisch oder Fisch. Dieser Faktor trug zur Herausforderung der Ultraschallpenetration bei, da die Energie schnell von der Frucht absorbiert wird, die wie ein stark absorbierendes Material wirkt. Wir führten Tests durch, indem wir das Fruchtfleisch der Wassermelone zerdrückten, um die Energieabsorption zu untersuchen. Während wir beim Zerquetschen des Fruchtfleisches kein Echo erhielten, erzielten wir ein einziges Ergebnis, als wir

das Fruchtfleisch durch eine Maschine führten, die Gas entfernte. Dies zeigt, dass Ultraschall für unsere Zwecke nicht die am besten geeignete Technik ist und eine viel niedrigere Durchdringungsfrequenz erfordert.



Abbildung 7. Beispiel für den Aufbau der Ultraschalluntersuchung mit Wassermelonen

Mehrere Faktoren tragen dazu bei, dass Ultraschall als Untersuchungsmethode seine Grenzen hat. Mit abnehmendem Frequenzbereich werden die Ultraschall-Arrays immer größer. Außerdem haben Ultraschall-Arrays in der Regel ebene Oberflächen, die gekoppelt werden müssen. Da Früchte runde Oberflächen haben, erwies sich die Übertragung eines Signals auf die gesamte Oberfläche als schwierig. Das Vorhandensein von Luft dämpfte das Signal, das überwiegend über die Oberfläche geleitet wurde. Um das Kopplungsproblem zu entschärfen, verwendeten wir ein Wasserbad, was jedoch keinen nennenswerten Erfolg brachte. Außerdem deutete die auf der Wasseroberfläche schwimmende Wassermelone auf das Vorhandensein von Gas hin, was das Experiment zusätzlich erschwerte.

Um Erkenntnisse aus früheren Untersuchungen zu gewinnen, führten wir Experimente mit einem Array durch, das an der Vorderseite eine Verengung aufwies, wie in [25] beschrieben. Der größte Teil der Energie wurde jedoch nach wie vor über die Oberfläche übertragen, und nur ein kleiner Teil konnte aufgrund der begrenzten Kontaktfläche der Array-Front in die Frucht eindringen.

Außerdem haben wir eine Arbeit untersucht, in der hohe Frequenzen und ein Wasserbad verwendet wurden [26]. Obwohl dies in der Arbeit nicht ausdrücklich erwähnt wird, wurde angenommen, dass die Früchte in das Wasserbad getaucht wurden, um die Signalerfassung zu verbessern. Bei allen Messungen wurden sowohl Transmissions- als auch Reflexionsmethoden verwendet. Die Wassermelonen ließen jedoch keine vollständige Transmission durch ihre Oberfläche zu. Um diesem Umstand Rechnung zu tragen, haben wir eine am Fraunhofer-Institut IZFP eingeführte Methode der "Rückreflexion" in Betracht gezogen. Diese Methode zielt darauf ab, die Reflexion zu analysieren, wenn zwei Materialien mit unterschiedlichen Eigenschaften vorhanden sind. Die Hypothese war, dass die Schale andere Eigenschaften als das Fruchtfleisch haben könnte. Leider war dieser Ansatz aufgrund der hohen Absorptionsfähigkeit von Früchten nicht erfolgreich. Diese Versuche wurden sowohl mit ganzen Früchten als auch mit Fruchtstücken durchgeführt. Während sich Ultraschall als unvollkommene Methode zur Beurteilung des Reifegrads von Früchten erwies, ist sie für die Untersuchung von Flüssigkeiten wie Fruchtsäften vielversprechend.

Akustische Resonanz

Das typische Verfahren zur Qualitätsprüfung von dickschaligen Früchten umfasst manuelle akustische Tests, bei denen eine Person auf die Oberfläche der Frucht klopft, um den Reifegrad anhand des entstehenden Geräusches zu beurteilen. Diese Methode hat jedoch mehrere Nachteile, da sie ausschließlich auf subjektiven Einschätzungen beruht und oft zu widersprüchlichen und ungenauen Ergebnissen führt. Viele der Technologien, die auf diesem Prinzip beruhen, sind häufig auf eine bestimmte Obstsorte beschränkt, was die Innovation für den industriellen Einsatz unpraktisch macht [13, 14, 15, 16, 18].

Daher liegt der Hauptbeitrag unseres Projekts in der Nutzung der akustischen Resonanz in Kombination mit Techniken der künstlichen Intelligenz, um konsistente und zuverlässige Ergebnisse zu gewährleisten. Durch die Automatisierung des akustischen Prüfverfahrens schaffen wir einen robusteren und effizienteren Ansatz, der eine höhere Genauigkeit bei der Beurteilung des Reifegrads ermöglicht.

Dieses Verfahren beginnt mit der Signalanalyse, einem entscheidenden Schritt beim Training des neuronalen Netzes, das die Grundlage für diese Methode bildet. Trotz des potenziellen Rauschens im Eingangssignal, das die weitere Analyse behindern könnte, werden verschiedene Audioverarbeitungstechniken eingesetzt, um das Problem wirksam zu entschärfen. Zur Rauschunterdrückung wird ein einkanaliger Rauschunterdrückungsalgorithmus gewählt, der üblicherweise bei der Verarbeitung von Mono-Audio verwendet wird. Dieser Algorithmus schätzt die Signalenergie und das Grundrauschen für jeden Frequenzbereich des zerlegten Signals und reduziert oder dämpft das Rauschen effektiv.

Signalbeschneidung und Signalausrichtung sind wesentliche Schritte in der Signalverarbeitungsphase während des Trainings des neuronalen Netzes. Diese Schritte helfen dabei, das Rauschen aus dem Signal zu entfernen und es an einer vorbestimmten Stelle auszurichten, um die Konsistenz des Timings zu gewährleisten. Während der Inferenz werden nur die Signalbeschneidung und die Frequenzumwandlung durchgeführt, bevor das Ergebnis des Audios vorhergesagt wird.

Die Idee, die Leistungsfähigkeit von CNN-Architekturen für die Vorhersage des Reifegrads von Früchten zu nutzen, führt zu einem Deep-Learning-Modell, das den eingehenden Signalton, der nach dem Auftreffen der Frucht auf die Oberfläche aufgezeichnet wird, empfängt und verarbeitet, um ein binäres Klassifizierungsproblem zu lösen, bei dem das Ergebnis eine reife oder unreife Frucht ist. Während die erste Version aus einer Reihe von Schichten besteht, die die herkömmliche Konfiguration von Faltungsschichten, gefolgt von Max-Pooling und Dropout, verwenden, fügte die zweite Version einen Instanznormalisierungsschritt direkt nach dem Lesen der Eingangssignale hinzu und reduzierte die Tiefe des Netzwerks leicht, indem einige Schichten entfernt wurden. Abbildung 8 zeigt die beiden vorgeschlagenen CNN-Architekturmodelle für die Vorhersage der Haltbarkeit.

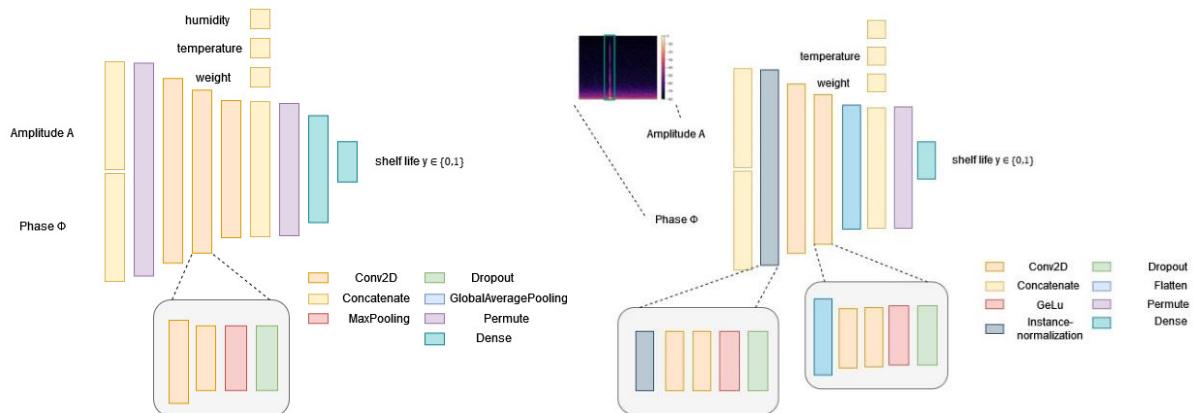


Abbildung 8. Vergleich der Architekturen für zwei verschiedene Modelle der binären Regalvorhersage. Während Version 1 (links) der konventionellen Schichtenarchitektur folgt, enthält Version 2 (rechts) Subschichten zur Extraktion weiterer Details und nicht standardisierte Pooling-Schichten.

Abbildung 9 veranschaulicht den Vergleich zwischen der Genauigkeit und den Verlusten jeder Architektur während der Trainings- und Testphase. Dieser Vergleich ermöglicht es uns, die Leistung der verschiedenen Architekturen bei der Vorhersage der Ergebnisse genau und effizient zu bewerten. Eine detailliertere Aufschlüsselung der Genauigkeits- und Verlustwerte für jede Architektur findet sich in Tabelle 3.

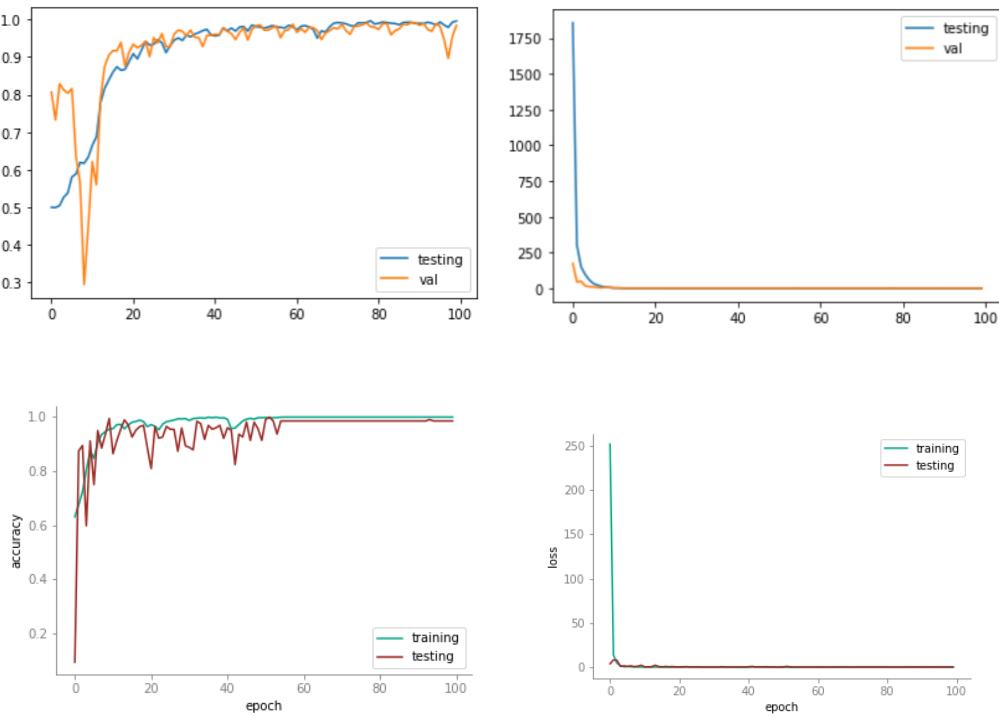


Abbildung 9. Genauigkeit (links) und Verlust (rechts) in Training und Test für beide CNN-Architekturen (I bzw. II).

Architektur	Frucht	Epochen	Spezifikationen	LR	Accuracy		Loss Function	
					Training	Testing	Training	Testing
Acoustic Testing I	Watermelon (2500)	100	$F_s = 200$ kHz	0.001	98.18 %	85.09 %	0.10	0.13
Acoustic Testing II	Watermelon / Galia (4.986)	100	$F_s = 44.1$ kHz	0.001	98.54 %	96.15 %	0.15	0.18

Tabelle 3. Leistungsvergleich zwischen den beiden CNN-Architekturen mit den jeweiligen Genauigkeits- und Verlustwerten in den Trainings- und Testdatensätzen. Zusätzliche Informationen zum Training werden hier als Referenz für die Einrichtung hinzugefügt.

Die Genauigkeit des Modells, das reife und überreife Wassermelonen klassifiziert, liegt im Testdatensatz bei 96 %. Die erfolgreichen Ergebnisse sind auch in unserer Veröffentlichung "Acoustic Ripeness Classification for Watermelon Fruits using Convolutional Neural Networks" [9] enthalten.

Es ist erwähnenswert, dass frühere Technologien, wie auch der vorgeschlagene Ansatz, üblicherweise Klopfvibrationen als Methode zur Messung des Resonanzverhaltens von Früchten verwendet haben [15, 16, 16, 17, 18, 19] (Resonanzvibration). Während sich die Klopfvibration in verschiedenen Studien als effektiv erwiesen hat, besteht eine bemerkenswerte Einschränkung darin, dass viele dieser Technologien oft auf eine bestimmte Obstsorte zugeschnitten sind. Diese Spezifität macht die Innovation für eine breite industrielle Nutzung unpraktisch, da verschiedene Obstsorten einzigartige Eigenschaften und Resonanzverhalten aufweisen können, die für eine genaue Bewertung spezifische Anpassungen erfordern.

Aktives Lernen

Die Erfassung hochwertiger und zuverlässiger Daten zum Reifegrad von Früchten ist ein zeit- und arbeitsintensiver Prozess. Um dieser Herausforderung zu begegnen, kann ein automatisierter Ansatz, der die Zusammenarbeit mit Nutzern oder anderen relevanten Informationsquellen einbezieht, um neue Datenpunkte zu kennzeichnen und das gewünschte Ergebnis zu erzielen, den Lernprozess erheblich beschleunigen. Dieser Ansatz fällt in den Bereich des aktiven Lernens, einer Unterart des maschinellen Lernens, die speziell auf dieses Ziel ausgerichtet ist [27].

Um diesen Ansatz weiter zu untersuchen, haben wir zusätzliche Experimente durchgeführt und die Ergebnisse in einem Forschungspapier mit dem Titel "Interactive Deep Learning for Shelf Life Prediction of Muskmelons Based on an Active Learning Approach" [10] veröffentlicht.

Aktives Lernen erweist sich als besonders vorteilhaft, wenn eine begrenzte Anzahl von Proben zur Verfügung steht, was bei zerstörungsfreien Prüfverfahren häufig der Fall ist. Während die Probenrate für die Erkennung von Eigenschaften im Allgemeinen hoch ist, kann die Erfassung ausreichender Daten zeitaufwändig sein. Um diese Datenbeschränkung zu überwinden, wird beim aktiven Lernen eine Abfragestrategie verwendet, die Proben auswählt, bei denen das Modell unsicher ist. Die Beschriftungen dieser Proben werden iterativ durch ein "Human-in-the-Loop"-Setup erfasst, so dass das Modell schrittweise aus den Eingaben von Fachleuten lernen kann.

Traditionell konzentrierte sich das aktive Lernen auf die Abfrage unsicherer Stichproben, die sich in der Nähe der Entscheidungsgrenze befinden [27]. Dieser Ansatz hat jedoch seine Grenzen, da er möglicherweise nicht die gesamte Datenverteilung effektiv untersucht. Um dieses Problem zu lösen, wurden umfangreiche Forschungsarbeiten zum Diversity Sampling [28] durchgeführt, eine Methode die darauf abzielt, den Stichprobenraum umfassender zu untersuchen.

In unserer Arbeit verwendeten wir die Diversität basierende Erfassungsfunktion k-Detimental Point Processes (k-DPP) und verglichen sie mit anderen Erfassungsfunktionen anhand von Metriken wie F-Score, Genauigkeit, Präzision und Recall. Unsere Ergebnisse zeigten, dass die k-Detimental Point Process-Methode eine vergleichbare Leistung wie andere Erfassungsfunktionen erbrachte, wie in Tabelle 4 dargestellt.

Acquisition Function	Accuracy	Loss	Precision	Recall
BALD	0.7098 (0.1290)	0.6935 (0.0228)	0.7361 (0.0132)	0.6667 (0.0131)
least confidence	0.7174 (0.0083)	0.6760 (0.0132)	0.7531 (0.0116)	0.6760 (0.0103)
k-DPP	0.7260 (0.0107)	0.6747 (0.0051)	0.7615 (0.0093)	0.6504 (0.0221)
margin sampling	0.7391 (0.0150)	0.7391 (0.0139)	0.7742 (0.0156)	0.6712 (0.014)
ratio of confidence	0.7283 (0.1827)	0.7283 (0.209)	0.7596 (0.0164)	0.6714 (0.0161)
random	0.7135 (0.0220)	0.7135 (0.0247)	0.7509 (0.0277)	0.6469 (0.0162)

Tabelle 4. Zusammenfassung des Vergleichs zwischen den Erfassungsfunktionen in Bezug auf die Bewertungsmetriken. Die Tabelle zeigt den Durchschnitt und die Standardabweichung der letzten Iteration, wobei die beste Metrik durch Fettdruck hervorgehoben ist [10].

Darüber hinaus konzentriert sich die laufende Forschung im Rahmen der Doktorarbeit von Dominique Albert-Weiß darauf, aktives Lernen auf Geräten mit geringer Rechenleistung zugänglich zu machen und mögliche Lösungen zur Reduzierung der erforderlichen Rechenzeit zu erforschen. Diese Bemühungen zielen darauf ab, die mit der Wanduhrzeit verbundenen Herausforderungen anzugehen und aktives Lernen zu einer praktischeren und effizienteren Lösung für die zerstörungsfreie Prüfung und andere verwandte Anwendungen zu machen.

Few-shot-lernen

Few-shot-lernen ist eine vielversprechende Technik, die sich bei Datensätzen mit einer begrenzten Anzahl von Stichproben als äußerst effektiv erweist. Dieser Ansatz lehnt sich an das menschliche Lernen an, bei dem Menschen auf der Grundlage einer kleinen Anzahl von Instanzen erfolgreich die richtige Klasse klassifizieren können, was die Fähigkeit zur Verallgemeinerung von begrenzten Daten unter Beweis stellt [29].

In unserer Studie haben wir den Fruit360-Datensatz [32] untersucht und geprüft, ob die Ergebnisse des "few-shot"-Lernens auf zukünftige Anwendungen anwendbar sind. Als Teil unseres Ansatzes haben wir ein Siamesisches Netzwerk verwendet. Da wir uns jedoch nur auf die Proben von Wassermelonenfrüchten und nicht auf andere Obstsorten konzentrierten, stellte dies eine Herausforderung für die effektive Anpassung der few-shot-Lernmethode dar (Overfitting).

Während des Zeitraums unserer Studie war das few-shot-lernen noch eine aufstrebende Technik im Bereich des Deep Learning und wurde noch nicht umfassend entwickelt. Dieser Mangel an Reife führte zu bemerkenswerten Overfitting-Problemen, bei denen die Leistung des Modells zu sehr auf die Trainingsdaten zugeschnitten war, was zu einer schlechten Generalisierung führte.

Allerdings hat sich die Landschaft des few-shot lernen in jüngster Zeit erheblich weiterentwickelt, insbesondere durch die Fortschritte beim meta-lernen [30]. Die Entwicklung von meta-learning-techniken hat die Fähigkeit des few-shot lernen verbessert, Szenarien mit begrenzten Daten effektiver zu handhaben. Infolgedessen birgt das few-shot lernen ein erhebliches Potenzial für den künftigen Einsatz in verschiedenen Anwendungen, einschließlich solcher, die mit begrenzten Datensätzen wie Wassermelonenfruchtproben arbeiten.

Die kontinuierlichen Fortschritte auf dem Gebiet des Deep Learning und die Verfeinerung der "few-shot"-Lerntechniken bieten spannende Perspektiven für die Verbesserung der Robustheit und Verallgemeinerung von Modellen im Umgang mit kleinen Datensätzen. In Anbetracht dieser Fortschritte könnten künftige Anwendungen stark von der Integration des "few-shot lernen" als leistungsfähiges Werkzeug für den Umgang mit begrenzten Datenmengen in einer Vielzahl von Domänen profitieren.

Multi-Task-Lernen & Multimodales Lernen

Multi-Task-Lernen bezieht sich auf den Ansatz, bei der Analyse von Eingabedaten mehrere Aufgaben gemeinsam zu berücksichtigen [31]. In unserem Fall haben wir Multi-Task-Lernen mit multimodalem Lernen kombiniert und verschiedene Datenquellen wie akustische Signale, Fotografie und Thermografie genutzt, um Früchte anhand verschiedener Merkmale zu klassifizieren. Das Multi-Task-Lernen macht sich den inneren induktiven Bias zunutze und geht davon aus, dass Aufgaben gleichzeitig gelernt werden können, was zu einer verbesserten Verallgemeinerung führt, indem Synergien zwischen den Aufgaben genutzt werden. Eine allgemeine Regel besagt, dass sich eng verwandte Aufgaben mehr Schichten in der Architektur des neuronalen Netzes teilen, während sich unähnliche Aufgaben weniger Schichten teilen.

In [23] wurden Fotografie und Thermografie eingesetzt, um die Haltbarkeit von Früchten zu klassifizieren, was ein Klassifikationsproblem darstellt, und gleichzeitig die Haltbarkeitsdauer vorherzusagen, was ein Regressionsproblem darstellt. Die Ergebnisse waren erfolgreich, was zum Teil auf die enge Verwandtschaft dieser Aufgaben zurückzuführen ist, die einen nützlichen Wissenstransfer zwischen ihnen ermöglicht. Unsere Experimente haben jedoch gezeigt, dass das gleichzeitige Lernen von nicht verwandten Aufgaben aufgrund des fehlenden Aufgabenbezugs nicht immer einfach ist. Der Versuch, die Haltbarkeit von Lebensmitteln zu klassifizieren und gleichzeitig den mit einem Refraktometer gemessenen Zuckergehalt vorherzusagen, führte beispielsweise aufgrund der grundlegenden Unähnlichkeit der Aufgaben zu keinen zufriedenstellenden Ergebnissen.

Um diese Herausforderung zu bewältigen, haben wir Optimierungstechniken in das Multitasking-Lernen integriert, um das Problem der widersprüchlichen Gradienten zu lösen, die bei der Optimierung für verschiedene Aufgaben auftreten können und dazu führen, dass sich der Gradient in die falsche Richtung bewegt oder in suboptimalen Tälern stecken bleibt. Ein bemerkenswerter Ansatz, den wir in Betracht zogen, war die PCGrad-Methode, die die Projektion des Gradientenvektors in die Normalebene ermöglicht. Während sich zahlreiche Ansätze auf die Richtung des Gradienten

konzentriert haben, wurde der Größe des Gradienten im Rahmen des Multi-Task-Lernens weniger Aufmerksamkeit geschenkt.

Die Dissertation von Dominique Albert-Weiß wird einen Beitrag zur Optimierung des Multitasking-Lernens leisten. Die Forschung wird Methoden erforschen, um eine Pareto-optimale Lösung zu erreichen, die Kompromisse zwischen den verschiedenen Aufgaben ausgleicht und dadurch die Gesamtleistung verbessert. Darüber hinaus wird sich die Arbeit mit der Generalisierung befassen und Methoden zur Analyse der Konvergenz zu einem flachen Minimum untersuchen, ein von Schmidhuber eingeführtes Konzept, das mit einer guten Generalisierung verbunden ist. Diese Bemühungen zielen darauf ab, Multitasking-Lerntechniken voranzutreiben und den Weg für effektivere und vielseitigere Anwendungen in verschiedenen Bereichen zu ebnen, einschließlich der Qualitätskontrolle und -bewertung von Obst.

Aroma- und Geschmacksvorhersage (Multi-Task Learning)

Aroma und Geschmack sind wichtige Komponenten bei der Qualitätskontrolle von Obst, da sie sich direkt auf die Zufriedenheit und die Vorlieben der Verbraucher auswirken. Um die Funktionalität unseres Prototyps für die Qualitätskontrolle von Obst zu verbessern, haben wir verschiedene Ansätze untersucht, darunter Multi-Task-Learning [31], um die Machbarkeit der gleichzeitigen Vorhersage von Haltbarkeitsdauer, Zuckergehalt und Aroma zu bewerten. Ziel ist es, ein umfassendes Modell zu entwickeln, das in der Lage ist, ganzheitliche Ergebnisse zu liefern, die diese verschiedenen Faktoren einbeziehen und eine gründliche Bewertung der Fruchtqualität gewährleisten. In der aktualisierten Version unseres Modells haben wir die Eingabedaten um Wärmebilder und aufgezeichnete Geräusche erweitert, die durch Klopfen auf die Fruchtoberfläche gewonnen wurden.

Diese zusätzlichen Modalitäten liefern wertvolle Informationen über die inneren Eigenschaften der Frucht und tragen zu einer detaillierteren Analyse ihrer Qualität bei. Um die Informationen aus diesen verschiedenen Datenquellen nutzbar zu machen, haben wir einen Prozess der Zerlegung und Kombination aller Elemente angewandt, wie in Abbildung 10 dargestellt.

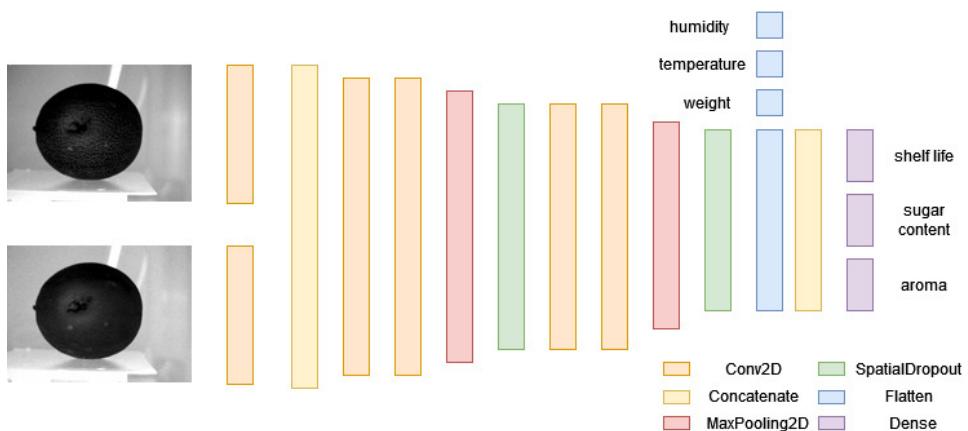


Abbildung 10. Modellarchitektur für Multitasking-Ansatz durch Lesen von Wärmebildern und Vorhersage mehrerer Aufgaben, wie Haltbarkeit, Zuckergehalt und Aroma.

Multi-Task-Learning erwies sich als vielversprechender Ansatz für die gleichzeitige Vorhersage mehrerer Faktoren, der es dem Modell ermöglicht, seine Leistung über verschiedene Aufgaben hinweg gemeinsam zu optimieren. Durch die Nutzung der Synergien zwischen Haltbarkeit, Zuckergehalt und

Aromavorhersage wollten wir ein robusteres und genaueres System zur Qualitätskontrolle von Obst schaffen.

Task	Accuracy	
	Training	Testing
Shelf-life (3 Klassen)	72.59 %	58.05 %
Aroma (3 Klassen)	67.70 %	34.75 %
Sugar (3 Klassen)	69.53 %	52.08 %

Tabelle 5. Zusammenfassung der Genauigkeit für die auf Multitasking basierende Modellarchitektur zur Vorhersage verschiedener Ergebnisse.

Die Integration von Wärmebildern und aufgezeichneten Geräuschen mit herkömmlichen Dateneingaben ermöglicht unserem Modell eine umfassende Bewertung der Fruchtqualität unter Berücksichtigung sowohl interner als auch externer Faktoren. Diese ganzheitliche Bewertung verbessert nicht nur die Genauigkeit der Vorhersage der Fruchtreife (Tabelle 5), sondern liefert auch wertvolle Einblicke in die Aroma- und Geschmackseigenschaften, was eine fundiertere Entscheidungsfindung in der Agrarindustrie ermöglicht und sicherstellt, dass nur die hochwertigsten Früchte den Verbraucher erreichen.

Um zusätzliche Daten für Galia-Melonen (1350) und Wassermelonen (660) zu sammeln, führten wir Messungen des Texturanalyse-Brix-Index (2 mm) durch, um den Zuckergehalt der Früchte zu bewerten. Diese Analyse liefert wertvolle Daten, die unseren Datensatz weiter ergänzen und bereichern und zu einem umfassenderen Verständnis der Fruchtqualität beitragen. Diese Skala liefert spezifische Informationen über die bei der Analyse angewandte Methodik und die damit verbundenen Parameter, die zur genauen Quantifizierung des Zuckergehalts der Früchte verwendet werden.

Durch die Einbeziehung der Brix-Index-Messungen in unseren Datensatz verbessern wir die Vielfalt und Tiefe der für jede Fruchtprobe verfügbaren Informationen. Der Zuckergehalt, ein wesentlicher Aspekt der Fruchtreife und des Geschmacks, dient als wichtiges Merkmal für den Vorhersageprozess unseres Modells.

Diese zusätzliche Datenquelle stärkt die Fähigkeit des Modells, genaue und zuverlässige Bewertungen der Fruchtqualität vorzunehmen, und stellt sicher, dass unser System zur Kontrolle der Fruchtqualität konsistente und verlässliche Ergebnisse liefert. Durch die Kombination von Daten aus verschiedenen Quellen, wie z. B. Wärmebildern, Tonaufnahmen und Brix-Index-Messungen, wird unser Modell zur Kontrolle der Fruchtqualität robuster und kann eine ganzheitliche Bewertung von Galia-Melonen und Wassermelonen vornehmen. Dieser Ansatz verbessert unsere Fähigkeit, die von den Verbrauchern geforderten hohen Qualitätsstandards zu erfüllen, und gewährleistet, dass nur die besten und reifsten Früchte auf den Markt kommen.

Erklärung der Ausgabe eines CNN zur Klassifizierung: LIME

Die Verwendung eines auf Deep Learning basierenden Modells für die Vorhersage des Reifegrads von Früchten ist zwar von entscheidender Bedeutung, aber ebenso wichtig ist es, Erklärungen für die Ergebnisse des Modells zu liefern. Durch das Anbieten von Erklärungen erhöhen wir die Vertrauenswürdigkeit der Ergebnisse des Modells, erhalten tiefere Einblicke in seinen Entscheidungsprozess und erleichtern die Entwicklung genauerer und zuverlässigerer zukünftiger Versionen. Eine wirksame Methode zur Bereitstellung von Erklärungen sind die lokal interpretierbaren modellagnostischen Erklärungen (LIME) [11].

LIME ist ein vielseitiger Ansatz, der auf jede Modellarchitektur des maschinellen Lernens angewendet werden kann. Im Zusammenhang mit einem bildbasierten Modell geht LIME von der Annahme aus, dass bestimmte Regionen des Bildes entscheidende Punkte (oder Pixel) enthalten, die die endgültige Entscheidung des Modells stark beeinflussen. Abbildung 11 veranschaulicht die Ergebnisse, die durch die Anwendung der LIME-Methode erzielt wurden.

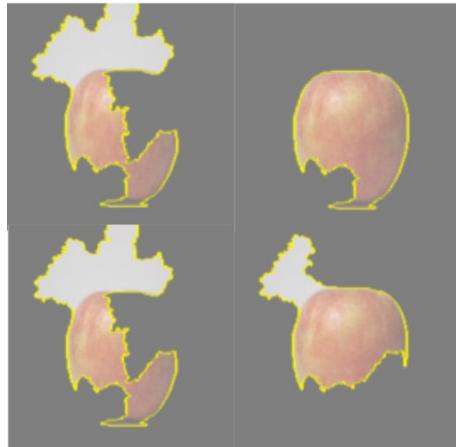


Abbildung 11. Ergebnis nach Anwendung von LIME für die AI-Erklärbarkeit des Modells. Diese Bereiche heben hervor, welche Merkmale des Bildes eine entscheidende Rolle bei der Bestimmung des Outputs des Netzwerks spielen.

Sie zeigen die hervorgehobenen Elemente des Bildes, die wesentlich zur Interpretation des Modells und zum anschließenden Entscheidungsprozess beitragen. Diese hervorgehobenen Regionen dienen als Erklärungen, die Aufschluss darüber geben, welche Teile des Bildes besonders einflussreich bei der Bestimmung des vorhergesagten Reifegrades der Frucht waren.

Durch die Einbeziehung von LIME-basierten Erklärungen ermöglichen wir Benutzern und Fachleuten ein tieferes Verständnis der Entscheidungsgrundlagen des Modells. Diese Transparenz ist von unschätzbarem Wert, um das Vertrauen in die Genauigkeit und Zuverlässigkeit des Modells zu stärken. Darüber hinaus erleichtern diese Erklärungen die Verbesserung des Modells und die weitere Forschung auf dem Gebiet der Vorhersage des Fruchtreifegrads, so dass wir das Modell verfeinern und seine Leistung in zukünftigen Iterationen steigern können. Letztendlich erhöht die Anwendung von LIME die Interpretierbarkeit und Vertrauenswürdigkeit unseres Deep-Learning-basierten Systems zur Vorhersage des Fruchtreifegrads.

Aktueller Prototyp

Version 1

Die Hardware des handgehaltenen Systems besteht aus einem rechteckigen Aluminiumgehäuse, in dem Sensoren zur Erfassung von Druck, Feuchtigkeit und Temperatur der Umgebung untergebracht sind. Außerdem befindet sich oben auf dem Gehäuse eine Waage, auf der die Früchte platziert und ihr Gewicht gemessen werden können. Das System umfasst auch ein Mikrofon, das mit dem Jetson Nano Developer Kit verbunden ist. Dieses Mikrofon zeichnet das Geräusch auf, das beim Klopfen auf die Frucht entsteht, und erleichtert die Durchführung von Vorhersagen mit Hilfe des eingebetteten AL-Modells.

Die grafische Benutzeroberfläche (GUI) wurde mit kivy entwickelt, einem robusten Python-basierten Framework zur Erstellung grafischer Komponenten. Das Designkonzept dreht sich um einen

Hauptbildschirm, der es dem Benutzer ermöglicht, die Frucht auszuwählen und mit einer schrittweisen Analyse fortzufahren. Dabei werden verschiedene Informationen über die Frucht aufgezeichnet, wie z. B. Druck, Gewicht, Temperatur und Feuchtigkeit.

Außerdem zeichnet das System das Signal auf, das durch das Klopfen auf die Frucht erzeugt wird. Schließlich führt das System eine Haltbarkeitsvorhersage durch. Jeder Verfahrensschritt entspricht einem individuellen Button, den der Nutzer anklicken kann, um die Ausführung zu starten.

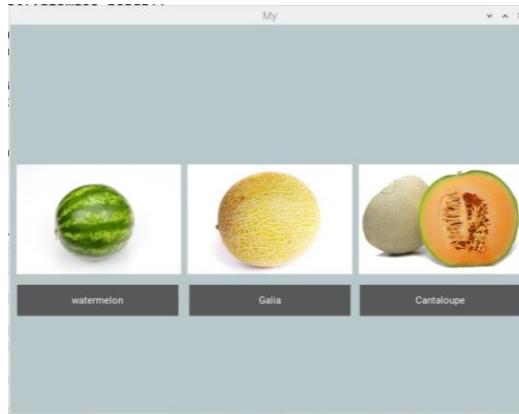


Abbildung 11. GUI erste Version.

Version 2

Der verbesserte Systemaufbau umfasst drei Hauptkomponenten, die in Abbildung 12 dargestellt sind. Erstens gibt es die mit Sensoren ausgestattete Waage, die dazu dient, das Gewicht der Früchte zu messen und gleichzeitig wichtige Umgebungsinformationen wie Druck, Feuchtigkeit und Temperatur aufzuzeichnen. Zweitens spielt das tragbare System eine wichtige Rolle bei der Automatisierung des Prozesses des Anzapfens der Frucht und der Erfassung des daraus resultierenden Signals. Schließlich stellt eine grafische Benutzeroberfläche alle gesammelten Informationen in einem benutzerfreundlichen Format dar.

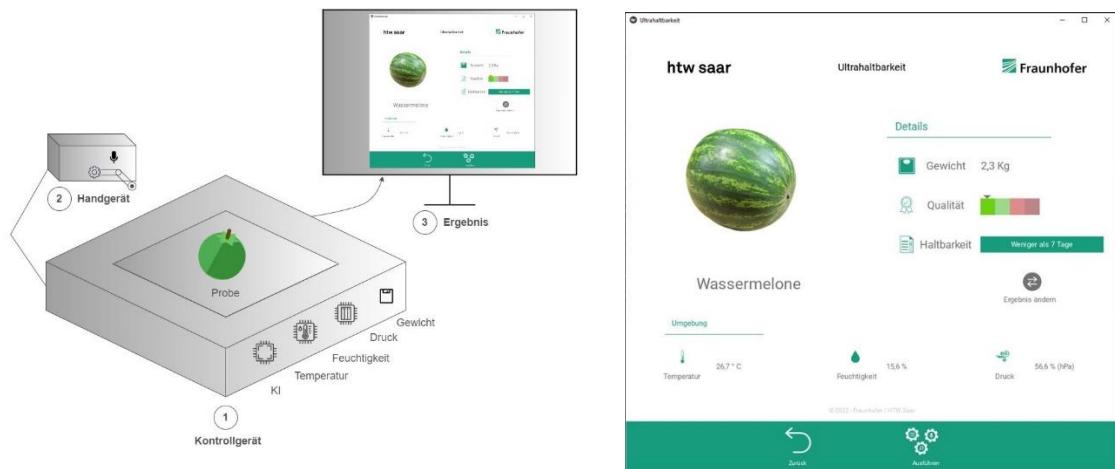


Abbildung 12. Vollständiger Aufbau zur Messung des Reifegrads der Früchte. Vollständiger Aufbau zur Messung des Reifegrads von Früchten.

Das Hardware-Design des Handheld-Systems wurde verbessert, um ein tragbareres Design zu erhalten, was eine der Anforderungen von Edeka nach unserem Besuch in Offenburg war, wo wir die Funktionalität des Systems demonstrierten. Diese erneuerte Version beinhaltet eine Größenoptimierung und ein anderes Design, das es widerstandsfähiger und bequemer macht, um die Früchte zu klopfen.

Die verbesserte GUI-Version (Abbildung 12) wurde weiterhin mit kivy entwickelt und an die Automatisierung der Funktionalität angepasst, die die Ausführung aller Aufgaben nach Drücken einer einzigen Taste am unteren Rand des Bildschirms umfasst, um die Informationen auf benutzerfreundliche Weise anzuzeigen.

Das Ergebnis ist ein Qualitätsindikator mit einer dreifarbig Skala, der den aktuellen Zustand des Obstes anzeigt und angibt, wie lange es gelagert wurde, um Handlungsmöglichkeiten zu bieten.

Während der Entwicklung des Projekts haben wir erfolgreich zwei Patente angemeldet. Die Informationen sind in der nachstehenden Tabelle aufgeführt.

Datum der letzten Änderung	Status	Name des Schutzrechtes
09.04.2021	Veröffentlicht	Inspektionssystem für die Sortierung von biologischen Lebensmitteln auf der Grundlage eines optischen VIS/IR-Bildsensors unter Verwendung eines Deep Learning-Multitasking-Ansatzes.
09.04.2021	Veröffentlicht	Tragbares System zur Qualitäts- und Reifeprüfung von landwirtschaftlichen Gütern auf der Grundlage eines multimodalen akustischen und optischen Bildsensors mit künstlicher Intelligenz.

Tabelle 6. List der Patente während des Projekts.

Referenzen

- [1] Food Waste - National Strategy for food waste reduction (2020) BMEL, <https://www.bmel.de/EN/topics/food-and-nutrition/food-waste/national-strategy-for-food-waste-reduction.html>.
- [2] Rasper, M. (2022) Organisation für natur- und Artenschutz | WWF - WWF Deutschland, WWF – Deutschland, <https://www.wwf.de/fileadmin/fm-wwf/Publikationen-PDF/Deutschland/WWF-Power-fuer-die-Isar.pdf>.
- [3] Dr. Aderhold, J. (2023) Pulse thermography, Fraunhofer, <https://www.vision.fraunhofer.de/en/technologies/heat-flow-thermography/pulse-thermography.html>.
- [4] Mohd Ali, M. et al. (2022) 'Quality prediction of different pineapple (ananas comosus) varieties during storage using infrared thermal imaging technique', Food Control, 138, p. 108988. doi:10.1016/j.foodcont.2022.108988.
- [5] Z. Ma, P. Duan, and W. Li (2019), "Improved Fruit Detection in Thermal Images through Convolutional Neural Network and Data Augmentation Techniques"
- [6] Zhang, H. et al. (2018) Mixup: Beyond empirical risk minimization, arXiv.org, <https://arxiv.org/abs/1710.09412>.
- [7] Fox, M., Goodhew, S., & De Wilde, P. (Directors). (2016). *Building defect detection: External versus internal thermography* [Film]. Pages 317-331.
- [8] Clark, M.R. et al. (2003) Application of infrared thermography to the non-destructive testing of concrete and masonry bridges, NDT & E International, <https://www.sciencedirect.com/science/article/pii/S0963869502000609>.
- [9] Albert-Weiβ, D. et al. (1970) Acoustic ripeness classification for watermelon fruits using convolutional neural networks, Fraunhofer, <https://publica.fraunhofer.de/entities/publication/75576cb6-07e8-4aaa-80fb-8831648a98e1/details>.
- [10] Albert-Weiss, D. and Osman, A. (1970) Interactive deep learning for shelf life prediction of Muskmelons based on an active learning approach, Fraunhofer, <https://publica.fraunhofer.de/entities/publication/e3aa92dd-c55d-4e5e-8249-2dfd8341cd3a/details>.
- [11] Ribeiro, M.T., Guestrin, C. and Singh, S. (2016) "Why should I trust you?" explaining the predictions of any classifier, <https://dl.acm.org/doi/pdf/10.1145/2939672.2939778>.
- [12] Kovács, P. et al. (2020) Deep learning approaches for thermographic imaging, AIP Publishing. <https://doi.org/10.1063/5.0020404>.
- [13] Zhejiang University ZJU, (2003), Hand detecting instrument for ripeness of watermelon, CN2554628Y <https://patents.google.com/patent/CN2554628Y/en?oq=CN2554628>
- [14] Shihezi University, 2016, "Hami" melon maturity acoustics non-destructive test device, CN205879875U, <https://patents.google.com/patent/CN205879875U/en?oq=CN205879875U>
- [15] Jiangxi Science and Technology Normal University, 2014, Handheld for safety detection device and method, CN104034665A <https://patents.google.com/patent/CN104034665A/en?oq=CN104034665A>
- [16] Zhejiang University ZJU, 2014, Multi-point synchronous measurement device for watermelon knocking vibration, CN104062357A <https://patents.google.com/patent/CN104062357A/en?oq=CN104062357+>

- [17] Nanjing University of Information Science and Technology, 2014, A kind of hand held watermelon is surveyed ripe instrument, CN203929790
<https://patents.google.com/patent/CN203929790U/en?oq=CNCN203929790>
- [18] Affeldt, Jr. Henry et al. (1992), Agricultural commodity condition measurement, 5152401,
<https://www.freepatentsonline.com/5152401.html>
- [19] Shoji, T. et al. (2001), Method of measuring ripeness and texture of vegetable or fruit and measuring instrument, 6276536, <https://www.freepatentsonline.com/6276536.html>
- [20] Clark, M.R. et al. (2003) Application of infrared thermography to the non-destructive testing of concrete and masonry bridges, NDT & E International,
<https://www.sciencedirect.com/science/article/pii/S0963869502000609> (Accessed: 21 July 2023).
- [21] Cawley, P. (2001), Method and apparatus for assessing the ripeness or firmness of fruit and vegetables, 6240766, <https://www.freepatentsonline.com/6240766.html>.
- [22] Crezee, L. (2003), Method and device for determining the hardness of products such as fruit, 6539781, <https://www.freepatentsonline.com/6539781.html>
- [23] Hajdini E., 2021, Multi-task learning for ripeness prediction of apple fruits [Master's thesis, Saarland University], (<http://bibliothek.izfp.fhg.de/publica/2021/21063.pdf>)
- [24] Awad, T.S. et al. (2012) Applications of ultrasound in analysis, processing and quality control of Food: A Review, Food Research International,
<https://www.sciencedirect.com/science/article/abs/pii/S096399691200141X>.
- [25] Mizrach, A., Schotte, S. and Verlinden, B.E. (2007) Nondestructive ultrasonic monitoring of tomato quality during shelf-life storage, Postharvest Biology and Technology, <https://www.sciencedirect.com/science/article/abs/pii/S0925521407001949>.
- [26] Fernandes, F.A.N. and Rodrigues, S. (2023) Ultrasound applications in drying of fruits from a sustainable development goals perspective, Ultrasonics Sonochemistry, <https://www.sciencedirect.com/science/article/pii/S1350417723001426>.
- [27] Hino H., (2020) Active Learning: Problem settings and recent developments, <https://arxiv.org/pdf/2012.04225.pdf>
- [28] Burr S., Active learning literature survey. University of Wisconsin, Madison, 52(55-66):11, 2010.
- [29] Parnami A., Lee M., Learning from few examples: A summary of approaches to few-shot learning, (2022), <https://arxiv.org/pdf/2203.04291.pdf>
- [30] Gharoun, H. et al. (2023) Meta-learning approaches for few-shot learning: A survey of recent advances, arXiv.org. Available at: <https://arxiv.org/abs/2303.07502>.
- [31] Crawshaw, M. (2020) Multi-task learning with Deep Neural Networks: A survey, arXiv.org. <https://arxiv.org/abs/2009.09796>.
- [32] Horea M., Mihai O., Fruit Recognition from images using Deep Learning, Acta Univ. Sapientiae, Informatica Vol. 10, Issue 1, pp. 26-42, 2018. <https://github.com/Horea94/Fruit-Images-Dataset>

Eines der Hauptziele des Projekts "KI-UltraHaltbarkeit" war es, ein Prototyp zu erstellen, der in der Lage ist, den Reifegrad von Wassermelonen zu erkennen. Das zugrunde liegende Messverfahren hierfür ist die akustische Klangprüfung. Zu diesem Zweck wurde ein Gerät entwickelt, das die Frucht durch Klopfen anregt und anschließend das akustische Signal mittels eines Mikrofons aufnimmt.

Während wir dieses Verfahren bereits im Vorjahr getestet haben, haben wir uns in diesem Jahr auf kostengünstigere Messtechniken verlassen, die zwar eine geringere Abtastrate des Mikrofons besitzen, aber dennoch ausreichende Auflösung besitzen. Das Vorgehen sieht folgendermaßen aus: Die Frucht wird auf einen stationären Aufbau gelegt, auf dem weitere Messgrößen wie das Gewicht und atmosphärische Parameter erfasst werden. Über eine grafische Benutzeroberfläche hat man nun die Möglichkeit, diese Parameter einzusehen und die Messung zu aktivieren. Eine Aussage über die Reife der Frucht ist in drei Reifegraden möglich und kann ebenfalls über die grafische Benutzeroberfläche (GUI) abgerufen werden.

Für die Erstellung des Prototyps wurde die Sensorik eigenständig ausgewählt und das Gehäuse sowie das Handgerät mithilfe von CAD-Software entworfen. Alle Komponenten wurden mit einem 3D-Drucker gedruckt und bestehen aus Aluminium- und primär Polymerteilen, um den Zusammenbau der einzelnen Elemente zu erleichtern. Ein Beispiel für die Gesamtstruktur ist in Abbildung 1.1 dargestellt.

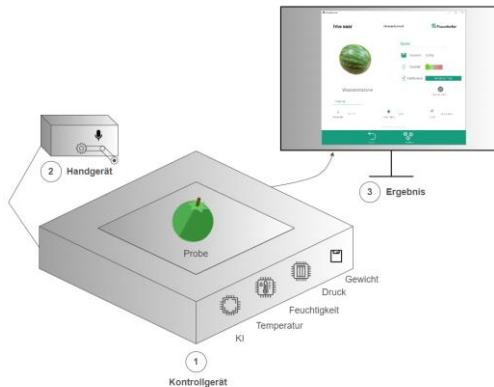


Abbildung 1.1 Aufbau des Prototyps.

Das Eingangssignal wird in der Fourier-Domäne transformiert. Diese Fourier-Daten dienen anschließend als Eingabe für ein speziell trainiertes neuronales Netzwerk (CNN), das vielversprechende Ergebnisse bei der Klassifizierung von Früchten liefert.

Zu diesem Zweck wurde eine GUI entwickelt, um die Ergebnisse des Modells darzustellen und die Interpretation durch den Benutzer zu erleichtern. Die GUI wurde mit Python erstellt und verwendet das Framework Kivy für grafische Elemente (siehe Abbildung 1.2). Die Benutzeroberfläche zeigt Informationen über die Frucht, die Umgebung und insbesondere das Ergebnis der Fruchtklassifizierung an.

Der Prototyp wurde dem Projektpartnern vorgestellt und an neuen Proben getestet. Die Effektivität und Genauigkeit des Geräts waren überzeugend, nachdem aus 10 Proben (9 frische Früchte und 1 verdorbenes Obst) alle Früchte korrekt klassifiziert wurden. Regelmäßige Diskussion mit den Projektpartnern ermöglichten Verbesserungsmaßnahmen und Ideen zum weiteren Ausbau des Prototyps zu erörtern, inklusiv Ideen um die Funktionalität des Systems zu erweitern.

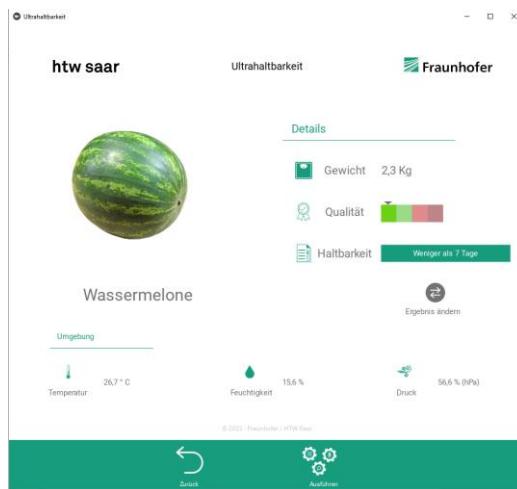


Abbildung 1.2 Aufbau des Prototyps.

Normalerweise Zusätzlich wurden Arbeiten zur Fusion von akustischer Resonanz und der Analyse von RGB-Bildern durchgeführt. Dieser Ansatz, auch als multimodale Fusion bezeichnet, ermöglicht es, die verschiedenen Arten von Informationen miteinander zu verknüpfen, um bessere Ergebnisse zu erzielen.

Im Computer-Vision-Ansatz wurden hochmoderne Deep-Learning-basierte Architekturen wie Transformer und Vision Transformers verwendet, die dann durch späte Fusion kombiniert wurden. Es hat sich gezeigt, dass dadurch sehr gute Ergebnisse erzielt werden können. Dieser Ansatz ist noch in Bearbeitung und wird noch in diesem Jahr veröffentlicht, da sie sich derzeit im Peer-Review-Verfahren befindet.

Ein weiterer Schwerpunkt lag in der weiteren Untersuchung von weiteren Daten (aktive und passive Thermografie, Computer Tomografie, Fotografie und Ultraschall), welche in der noch laufenden Doktorarbeit von Frau Dominique Albert-Weiß untersucht werden.

Darüber hinaus wird derzeit eine Exist-Forschungstransfer-Antrag auf der Grundlage unserer Arbeit vorbereitet. Ziel ist es, ein Start-up-Unternehmen zu gründen. Zurzeit sind zwei Anträge für geplante Patentanmeldungen angedacht. Die Titel sowie das Einreichungsdatum der Schutzrechte sind in der unten dargestellten Tabelle beschrieben:

Datum der letzten Änderung	Status	Name des Schutzrechtes
09.04.2021	Veröffentlicht	Inspektionssystem für die Sortierung von biologischen Lebensmitteln auf der Grundlage eines optischen VIS/IR-Bildsensors unter Verwendung eines Deep Learning-Multitasking-Ansatzes.
09.04.2021	Veröffentlicht	Tragbares System zur Qualitäts- und Reifeprüfung von landwirtschaftlichen Gütern auf der Grundlage eines multimodalen akustischen und optischen Bildsensors mit künstlicher Intelligenz.