

Automatisierte Kitzrettung: Die Anwendung von künstlicher Intelligenz und Drohnentechnologie zur Verbesserung der Wildtiererkennung auf landwirtschaftlichen Flächen

Bachelorarbeit

eingereicht von: **Ing. Alexander Pichler**
Matrikelnummer: 11844563

im Fachhochschul-Bachelorstudiengang Wirtschaftsinformatik (0470)
der Ferdinand Porsche FernFH

zur Erlangung des akademischen Grades eines
Bachelor of Arts in Business

Betreuung und Beurteilung: DI Dr. Werner Toplak

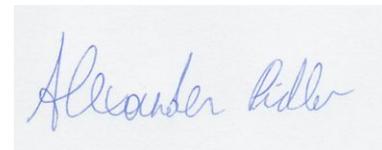
Wiener Neustadt, September 2024

Ehrenwörtliche Erklärung

Ich versichere hiermit,

1. dass ich die vorliegende Bachelorarbeit selbständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel benutzt habe. Alle Inhalte, die direkt oder indirekt aus fremden Quellen entnommen sind, sind durch entsprechende Quellenangaben gekennzeichnet.
2. dass ich diese Bachelorarbeit bisher weder im Inland noch im Ausland in irgendeiner Form als Prüfungsarbeit zur Beurteilung vorgelegt oder veröffentlicht habe.

Altenberg bei Linz, 26. September 2024



Unterschrift

Creative Commons Lizenz

Das Urheberrecht der vorliegenden Arbeit liegt bei Alexander Pichler. Sofern nicht anders angegeben, sind die Inhalte unter einer Creative Commons <„Alexander Pichler - Nicht-kommerziell - Weitergabe unter gleichen Bedingungen 4.0 International Lizenz“ (CC BY-NC-SA 4.0)> lizenziert.

Die Rechte an zitierten Abbildungen liegen bei den in der jeweiligen Quellenangabe genannten Urheber*innen.

Die Kapitel 1 bis 11 der vorliegenden Bachelorarbeit wurden im Rahmen der Lehrveranstaltung „Bachelor Seminar 1“ eingereicht und am 15. September 2024 als Bachelorarbeit 1 angenommen.

Kurzzusammenfassung: Automatisierte Kitzrettung: Die Anwendung von künstlicher Intelligenz und Drohnentechnologie zur Verbesserung der Wildtiererkennung auf landwirtschaftlichen Flächen

Die vorliegende Arbeit befasst sich mit dem Einsatz von künstlicher Intelligenz (KI) und Drohnentechnologie zur Rettung von Rehkitzen während der Mähseason. Rehkitze werden häufig von Mähmaschinen erfasst, da sie sich bei Gefahr regungslos im hohen Gras verstecken. In der Vergangenheit wurden bereits verschiedene Methoden entwickelt, um Rehkitze zu retten. Dazu zählen akustische und geruchliche Abschreckungsmaßnahmen, die traditionelle Suche sowie der Einsatz von Drohnen. Die Erfolgsaussichten, ein Kitz mit einer Drohne aufzuspüren, sind am größten. Allerdings ist diese Methode zeitintensiv und anfällig für Fehler, da die Wahrnehmung des Menschen limitiert ist.

Das Ziel dieser Arbeit ist die Entwicklung eines Prototypen, welcher mithilfe einer KI-basierten Auswertung von Drohnenaufnahmen die genauen geografischen Koordinaten von Rehkitzen berechnet. Im Anschluss erfolgt ein Vergleich der Zeitersparnis und der Genauigkeit gegenüber der manuellen Auswertung durch Menschen.

Die Ergebnisse legen dar, dass die KI-gestützte Methode die Zeit für das Auffinden der Kitze signifikant verkürzt, jedoch bei der Genauigkeit hinter der manuellen Auswertung zurückbleibt sowie eine höhere Rate an falsch-positiven Erkennungen aufweist. Die Detektionsrate könnte durch eine größere Menge an Trainingsdaten verbessert werden.

Schlagwörter:

Kitzrettung, Drohnentechnologie, Wildtiererkennung, Künstliche Intelligenz, YOLO, Bilderkennung, Darknet

Abstract: Automated fawn rescue: The application of artificial intelligence and drone technology to improve wildlife detection on agricultural land

The present thesis explores the use of artificial intelligence (AI) and drone technology for the rescue of fawns during the mowing season. Fawns are often struck by mowing machines as they remain motionless in tall grass when threatened. Various methods have been developed in the past to rescue fawns, including acoustic and scent deterrents, traditional searching methods, and the use of drones. The chances of successfully locating a fawn are highest with drones; however, this method is time-consuming and prone to errors due to human limitations in perception.

The aim of this thesis is to develop a prototype that utilizes AI-based analysis of drone footage to calculate the precise geographic coordinates of fawns. A comparison is then made between the time efficiency and accuracy of the AI method and manual human evaluation.

The results demonstrate that the AI-assisted method significantly reduces the time required to locate the fawns, but it lags behind manual evaluation in terms of accuracy and exhibits a higher rate of false positives. The detection rate could be improved with a larger set of training data.

Keywords:

Fawn rescue, Drone technology, Wildlife detection, Artificial intelligence, YOLO, Image detection, Darknet

Inhaltsverzeichnis

1. EINLEITUNG.....	1
2. ZIEL.....	2
2.1 Forschungsfrage.....	2
2.2 Hypothese.....	2
2.3 Methodische Vorgangsweise.....	2
3. AKTUELLER FORSCHUNGSSTAND UND BISHERIGE ARBEITEN.....	3
3.1 Bisherige Arbeiten zur Kitzrettung.....	3
3.2 Arbeiten zum Einsatz von Drohnentechnologie mit Wärmebildgeräten zur Kitzrettung.....	3
3.3 Arbeiten zum Einsatz von KI mit Drohnen.....	4
4. REHWILD.....	5
4.1 Einteilung.....	5
4.1.1 Säugetiere.....	5
4.1.2 Paarhufer.....	5
4.1.3 Wiederkäuer.....	6
4.1.4 Hirschartige.....	7
4.2 Europäisches Reh.....	8
4.2.1 Definition und Merkmale.....	8
4.2.2 Verbreitung und Lebensraum.....	11
4.2.3 Ernährung.....	11
4.2.4 Soziales Verhalten und Fortpflanzung.....	12
4.2.5 Geburtszeit.....	12
4.2.6 Verhalten der Jungtiere bei Gefahr.....	13
5. GENERELLES ZUR KITZRETTUNG.....	14
5.1 Auswirkungen der landwirtschaftlichen Intensivierung.....	15
5.2 Methoden zur Kitzrettung.....	15
5.2.1 Traditionelle Suche.....	15
5.2.2 Akustische Methoden.....	16
5.2.3 Geruchsmethoden.....	16
5.2.4 Optische Methoden.....	17
5.2.5 Kombination von Methoden.....	17

5.2.6	Drohnen mit Wärmebildkameras.....	18
5.2.7	Drohnen mit künstlicher Intelligenz.....	19
6.	ORTUNGSTECHNOLOGIEN.....	20
6.1	Geografisches Koordinatensystem.....	20
6.1.1	Längengrad.....	20
6.1.2	Breitengrad.....	21
6.2	Global Navigation Satellite System.....	21
6.2.1	Generelles.....	21
6.2.2	Technische Grundlagen von GNSS.....	21
6.2.3	GNSS-Systeme.....	21
6.3	Differential Global Positioning System.....	22
7.	DROHNEN.....	23
7.1	Multikopter.....	23
7.1.1	Funktionsweise.....	23
7.1.2	Anwendungen im privaten Bereich.....	23
7.1.3	Steuerung und Übertragung von Kamerabildern.....	23
7.2	DJI Mavic 3T.....	24
8.	WÄRMEBILDGERÄTE.....	25
9.	KÜNSTLICHE INTELLIGENZ.....	26
9.1	Grundbegriffe der Künstlichen Intelligenz.....	26
9.1.1	Maschinelles Lernen (ML).....	26
9.1.2	Labeling (Annotieren).....	27
9.1.3	Model.....	27
9.1.4	Foundation Model.....	27
9.1.5	Bounding Box.....	27
9.1.6	Neuronale Netze.....	28
9.1.7	Tiefe neuronale Netze (Deep Neural Networks, DNNs).....	28
9.2	Convolutional Neural Networks.....	28
9.2.1	Funktionsweise von CNNs.....	29
10.	OBJEKTERKENNUNG IN VIDEOS.....	30
10.1	You Only Look Once.....	30
10.1.1	Funktionsweise von YOLO.....	30

10.1.2	Darknet.....	31
10.1.3	DarkHelp.....	31
10.1.4	DarkMark.....	31
10.1.5	Vergleich mit anderen Modellen.....	31
11.	KONZEPTIONELLER VORGEHENS- UND LÖSUNGSANSATZ.....	33
11.1	Daten.....	33
11.2	Prototyp.....	33
11.2.1	Anforderungen an das YOLO-Modell.....	34
11.2.2	Anforderungen an die grafische Desktopanwendung.....	34
11.3	Experiment.....	34
11.3.1	Auswertung durch die Versuchspersonen.....	35
11.3.2	Auswertung durch den Prototypen.....	35
11.3.3	Signifikanztest für die Auffindungszeit.....	36
11.3.4	Vergleich der Detektionsrate.....	36
12.	AUFBAU DES PROTOYPEN.....	37
12.1	YOLO-Modell.....	37
12.1.1	Trainingsdaten.....	37
12.2	Trainieren mit DarkMark.....	39
12.3	Aufrufen von Darknet.....	44
12.4	Grafische Desktopanwendung.....	47
12.4.1	Aufbau der Anwendung.....	47
12.5	Berechnung der Koordinaten der erkannten Objekte.....	50
12.5.1	Objekt im Bild ermitteln.....	51
12.5.2	Berechnung wie viele Meter einem Pixel im Bild entsprechen.....	52
12.5.3	Rotation des Punktes.....	52
12.5.4	Berechnung der geografischen Koordinaten.....	53
12.5.5	Finaler Algorithmus in Java.....	54
13.	DURCHFÜHRUNG DES EXPERIMENTS.....	55
13.1	Ermittlung der Daten der künstlichen Intelligenz.....	55
13.2	Ermittlung der Daten der Versuchspersonen.....	55
13.2.1	Auswahl der Versuchspersonen und Einschulung.....	55
13.2.2	Verwendung der Webanwendung.....	56
13.2.3	Ergebnis der Webanwendung.....	58

14. AUSWERTUNG DER ERGEBNISSE.....	60
14.1 Ergebnis des Prototypen.....	60
14.2 Ergebnis der Versuchspersonen.....	61
14.3 Vergleich der Detektionsraten.....	63
14.4 Vergleich der Auffindungszeiten.....	63
15. BEANTWORTUNG DER FORSCHUNGSFRAGE.....	65
16. BEANTWORTUNG DER HYPOTHESE.....	66
17. AUSBLICK.....	67
ANHANG.....	68
LITERATURVERZEICHNIS.....	82
ABBILDUNGSVERZEICHNIS.....	87
TABELLENVERZEICHNIS.....	89

1. Einleitung

Im Mai und Juni findet die Mähseason statt, während der Landwirtinnen und Landwirte ihre Wiesen mähen. Doch zu dieser Zeit bringen auch die Rehe ihre Jungen, die sogenannten Kitze, zur Welt. Um ihre Nachkommen vor Feinden wie beispielsweise dem Fuchs zu schützen, platzieren sie die Kitze im hohen Gras. Die Jungtiere verhalten sich bei Gefahr anders als erwachsene Rehe: Anstatt zu flüchten, verstecken sie sich im hohen Gras. Dadurch bleiben sie oft unbemerkt und werden leider häufig von Mähmaschinen erfasst und getötet. Diese Situation ist sowohl für die Landwirtschaft als auch für die Jagd unvorteilhaft. Die Landwirtinnen und Landwirte können ihr Gras nicht zur Fütterung nutzen und der Jagd wird der Erhalt eines gesunden und vielfältigen Wildbestandes erschwert.

Um diesem Problem zu begegnen, kooperieren Personen aus dem landwirtschaftlichen- und jagdlichen Bereich und stimmen sich bezüglich der Mäharbeiten ab. Früher wurde das Feld manuell abgesucht, um nach Kitzen zu suchen. In den letzten Jahren hat sich jedoch der Einsatz von Drohnen, oft ausgestattet mit Wärmebildkameras, als effizientere Methode etabliert. Die Rettung von Kitzen mithilfe von Drohnen hat sich bewährt, da sie zuverlässiger als das manuelle Absuchen ist und weniger Kitze übersehen und getötet werden. Zudem ist sie zeitsparender.

Falls ein Kitz gefunden wird, wird es behutsam mit Handschuhen und einer Hand voll Gras gepackt, um den menschlichen Geruch zu vermeiden, und in einer Box untergebracht. Nach Abschluss der Mäharbeiten wird das Kitz wieder freigelassen. Es ruft sofort nach seiner Mutter, die sich in unmittelbarer Nähe befindet und das Kitz wieder aufnimmt.

Die Arbeit mit der Drohne erfordert konzentriertes Arbeiten, da das gesamte Gelände manuell abgeflogen werden muss, während gleichzeitig auf einem Bildschirm nach Anzeichen für die Anwesenheit von Kitzen gesucht wird. Diese Aufgabe kann besonders herausfordernd sein, weil über die gesamte Mähseason viele Wiesen abgeflogen werden müssen.

2. Ziel

Das Ziel dieser Arbeit ist herauszufinden, ob mithilfe eines durch künstliche Intelligenz (KI) unterstützten Verfahrens zur Bilderkennung die Zeit für das Auffinden von Rehkitzen signifikant verringert wird, während die Detektionsrate gleichbleibt.

2.1 Forschungsfrage

Die Forschungsfrage, die im Rahmen dieser Arbeit beantwortet werden soll, lautet: „Kommt es durch ein KI-unterstütztes Verfahren zur Bilderkennung zu einer signifikanten Verringerung der Zeit für das Auffinden von Rehkitzen bei gleichbleibender Detektionsrate gegenüber der herkömmlichen Methode?“

2.2 Hypothese

Die Hypothese zu dieser Forschungsfrage lautet: „Durch ein KI-unterstütztes Verfahren zur Bilderkennung kommt es bei gleichbleibender Detektionsrate gegenüber der herkömmlichen Methode zu einer signifikanten Verringerung der Zeit für das Auffinden von Rehkitzen.“

2.3 Methodische Vorgangsweise

Zur Beantwortung der Forschungsfrage wird ein Prototyp entwickelt, der eine KI-basierte Auswertung von Bilddaten durchführt. Das System analysiert Videoaufnahmen, identifiziert Zeitpunkte und Pixelkoordinaten, an denen Kitze sichtbar sind, und nutzt die Koordinaten der Drohne zur Positionsbestimmung der Jungtiere. Um die Effizienz der Methode zu prüfen, wird ein Drohnenvideo sowohl von der KI als auch von einer Versuchsgruppe ausgewertet. Anschließend wird die Genauigkeit der beiden Methoden verglichen. Im Anschluss erfolgt ein Vergleich der Genauigkeit der beiden Methoden. Mithilfe eines Signifikanztests wird untersucht, ob sich die Auffindungszeit signifikant verringert.

Mein persönliches Interesse an diesem Thema stammt aus meiner Leidenschaft für Naturschutz und Technologie. Die Möglichkeit, durch den Einsatz von KI und Drohnen einen Beitrag zum Schutz von Wildtieren zu leisten, motiviert mich, dieses Projekt umzusetzen.

3. Aktueller Forschungsstand und bisherige Arbeiten

3.1 Bisherige Arbeiten zur Kitzrettung

In der Studie von Cukor et al. (2019b) wurde die Effektivität verschiedener Präventionsmaßnahmen, um Rehkitze und ihre Mütter von Wiesen zu vertreiben, die für die Mahd vorgesehen sind, evaluiert. Zu den untersuchten Methoden gehörten akustische, optische und Geruchsabschreckung sowie traditionelle Suchmethoden mit freiwilligen Helfern und Jagdhunden. Die Untersuchungen basierten auf einer Kombination von Befragungen und Feldversuchen, die vor der Mahd durchgeführt wurden. Die Ergebnisse zeigten, dass keine der getesteten Vergrämungsmethoden vollständig wirksam war. (Cukor et al. 2019b).

2002 untersuchte Jarnemo den Einfluss der Mahd auf die Kitzsterblichkeit und bewertete verschiedene Gegenmaßnahmen. Eine von ihm getestete Methode zur Rettung von Rehkitzen war der Einsatz von Vergrämungsmitteln, wie beispielsweise das Anbringen von Plastiksäcken an Holzpfählen. Dabei konnte er nachweisen, dass durch diese Methode 82% der beobachteten Jungtiere von ihren Müttern aus den gefährdeten Gebieten entfernt wurden.

Diese Erkenntnisse legten den Grundstein für die Suche nach effektiveren Technologien zur Kitzrettung, wie den Einsatz von Drohnen und Wärmebildkameras.

3.2 Arbeiten zum Einsatz von Drohnentechnologie mit Wärmebildgeräten zur Kitzrettung

Cukor et al. untersuchten 2019 die Wirksamkeit von Drohnen in Kombination mit Wärmebildgeräten zur Rettung von Rehkitzen. Die Studie zeigte, dass mit Wärmebildgeräten ausgestattete Drohnen eine effiziente Methode sind, um Rehkitze auf Wiesen aufzuspüren. Diese Technologie ermöglicht es, schnell große Flächen abzufliegen und Rehkitze anhand der deutlichen Wärmeabstrahlung ihres Körpers im Vergleich zur Umgebung zu identifizieren. Die Ergebnisse zeigen, dass diese Methode vor allem bei geeigneten Wetterbedingungen zuverlässig ist und eine deutliche Verbesserung gegenüber herkömmlichen Suchmethoden darstellt. Dabei können unter optimalen Bedingungen Erkennungsraten von bis zu 100% erreicht werden (Cukor et al. 2019a).

In der Arbeit von Israel et al. (2011) wurde ein Drohnen-basiertes System zur Rettung von Rehkitzen vorgestellt. Das System nutzte eine Wärmebildkamera, die auf einem Oktokopter montiert war. Die Kamera nahm Wärmebilder auf, die in Echtzeit an eine Bodenstation übertragen wurden. Diese Methode ermöglichte die manuelle Erkennung

von Rehkitzen durch Beobachter, die die Live-Bilder auf Monitoren verfolgten. Die Studie unterstrich die Bedeutung einer schnellen Arbeitsweise und die Effizienz der Drohnentechnologie unter verschiedenen Licht- und Wetterbedingungen. Dank der hohen Auflösung der Wärmebilder konnte die Erkennungsrate signifikant gesteigert werden, was die Zuverlässigkeit und Praktikabilität der Methode bestätigt.

Meyer et al. (2019) untersuchten den Einsatz von Drohnen mit Wärmebildgeräten zur automatisierten Wildtiererkennung mit dem Fokus Wildtierpopulationen zu überwachen. Drohnenflüge verschiedener Gebiete im Südschwarzwald und in der Nordwestschweiz zeigten, dass Wärmebilddaten besonders geeignet sind, um die Körperwärme von Wildtieren zu erfassen.

3.3 Arbeiten zum Einsatz von KI mit Drohnen

Meyer et al. (2019) untersuchten den Einsatz von Drohnen und künstlicher Intelligenz zur automatisierten Wildtiererkennung. In ihrer Studie sammelten sie Wärmebilddaten von Wildgehegen im Südschwarzwald und in der Nordwestschweiz. Die kontrastreichen Wärmebilder erwiesen sich als ideal für die automatisierte Erkennung.

Für die Bildanalyse setzten die Forscher das Faster Region-based Convolutional Neural Network (Faster R-CNN) ein. Dieses KI-System erreichte eine Erkennungsrate von 92,8 % pro Tier und eine Klassifizierungsgenauigkeit von 88,6 % pro Tierart.

Die Ergebnisse zeigen, dass Drohnen mit KI-gesteuerten Wärmebildgeräten eine effiziente und präzise Methode zur Wildtierüberwachung darstellen. Diese Methode hat das Potenzial, die Effizienz und Genauigkeit der Kitzrettung weiter zu optimieren.

4. Rehwild

Das Rehwild umfasst zwei Hauptarten:

1. Europäische Reh (*Capreolus capreolus*)
2. Sibirische Reh (*Capreolus pygargus*)

Beide Arten gehören zur Familie der Hirsche (*Cervidae*). Das Europäische Reh ist in großen Teilen Europas heimisch, während das Sibirische Reh in Asien, insbesondere in Sibirien und den angrenzenden Regionen, beheimatet ist. Obwohl die beiden Arten eine hohe Ähnlichkeit aufweisen, unterscheiden sie sich in einigen körperlichen und ökologischen Merkmalen sowie in ihrer Verbreitung. (Fiala-Köck et al. 2019)

Im Folgenden wird daher der Fokus auf das Europäische Reh gelegt, da nur dieses für meine Region relevant ist.

4.1 Einteilung

4.1.1 Säugetiere

4.1.1.1 Definition und Merkmale

Säugetiere (*Mammalia*) sind eine Klasse der Wirbeltiere (*Vertebrata*) und zeichnen sich durch das Vorhandensein von Milchdrüsen aus, die zur Ernährung der Jungtiere dienen. Weitere charakteristische Merkmale sind das Vorhandensein von Haaren sowie ein differenziertes Gebiss. Säugetiere sind endotherm, was bedeutet, dass sie ihre Körpertemperatur unabhängig von der Umgebung regulieren können. (Armstrong et al. 2024)

4.1.2 Paarhufer

4.1.2.1 Definition und Merkmale

Paarhufer (*Artiodactyla*) sind eine Ordnung der Säugetiere, die sich durch das Vorhandensein von geraden Zehenzahlen an ihren Füßen auszeichnen, in der Regel zwei oder vier. Diese Tiere zeigen eine bemerkenswerte Anpassung an verschiedene Lebensräume und Ernährungstypen, was sie zu einer sehr vielfältigen Gruppe innerhalb der Säugetiere macht. Die Paarhufer sind ursprünglich in allen Regionen der Welt außer Australasien und den Polarregionen beheimatet. Im Laufe der Geschichte wurden jedoch viele Arten nach Australien und Neuseeland eingeführt. (Gentry, 2024) (Etnyre, 2011) (Fiala-Köck et al. 2019)

4.1.2.2 Anatomische Merkmale

Das Hauptmerkmal der Paarhufer ist ihre Zehenanordnung, bei der das Körpergewicht hauptsächlich auf den dritten und vierten Zehen ruht. Diese Anpassung ermöglicht ihnen eine effiziente Fortbewegung auf verschiedenen Untergründen. Die Zehen sind oft durch Hufe geschützt, was besonders bei Arten, die in offenen und harten Landschaften leben, von Vorteil ist (beispielsweise Rehe, Wildscheine und Gämse). (Gentry, 2024) (Etnyre, 2011)

Die Paarhufer besitzen ein komplexes Verdauungssystem, das in vielen Fällen einen mehrkammerigen Magen umfasst, um die Verdauung von Pflanzenmaterial zu optimieren. Dies ist besonders ausgeprägt bei den Wiederkäuern. (Gentry, 2024) (Etnyre, 2011) (Fiala-Köck et al. 2019)

4.1.2.3 Lebensweise und Ernährung

Die Ernährung der Paarhufer variiert stark und umfasst sowohl Pflanzenfresser als auch Allesfresser. Wiederkäuer wie Rehe, Rinder und Schafe sind ausschließlich Pflanzenfresser. Andere Paarhufer, wie Schweine, haben eine vielfältigere Ernährung und können sowohl pflanzliche als auch tierische Nahrung zu sich nehmen. (Fiala-Köck et al. 2019)

Paarhufer leben in einer Vielzahl von Lebensräumen, von den offenen Savannen und Steppen bis hin zu dichten Wäldern und sogar Feuchtgebieten. Diese ökologische Vielfalt spiegelt sich in ihrer Körpergröße und Lebensweise wider. Während einige Arten wie die Giraffen beeindruckend groß sind und hohe Bäume nach Nahrung absuchen, sind andere wie die Ziegen klein und wendig, um in felsigen und unwegsamen Gelände zu überleben. (Fiala-Köck et al. 2019)

4.1.3 Wiederkäuer

4.1.3.1 Definition und Merkmale

Wiederkäuer (Ruminantia) sind eine Unterordnung der Paarhufer und zeichnen sich durch ein spezialisiertes Verdauungssystem aus, das ihnen ermöglicht, pflanzliche Nahrung effizient zu verdauen. Das auffälligste Merkmal der Wiederkäuer ist ihr mehrteiliger Magen, der aus Pansen, Netzmagen, Blättermagen und Labmagen besteht. Diese Abschnitte arbeiten zusammen, um die Nahrung schrittweise abzubauen und die Nährstoffe optimal zu verwerten. Eine weitere charakteristische Eigenschaft ist der Vorgang des Wiederkäuens, bei dem die Nahrung zunächst grob zerkaut und geschluckt, dann wieder hochgewürgt, erneut gekaut und schließlich weiter verdaut wird. (Fiala-Köck et al. 2019)

Die Gruppe der Wiederkäuer umfasst eine Vielzahl von Arten, die sich hinsichtlich ihrer Ernährungsweise und Anpassung unterscheiden. Dabei kann zwischen drei Typen unterschieden werden:

1. **Raufutterverzehr:** Diese Tiere nehmen vorwiegend faserreiches Futter wie Gras auf.
2. **Intermediärtypus:** Diese Tiere nehmen eine Mischung aus Gras und energiereichen Pflanzen auf.
3. **Konzentratselektierer:** Diese Tiere nehmen energiedichte Nahrung wie junge Triebe und Früchte auf.

(Fiala-Köck et al. 2019)

4.1.3.2 Verdauungsprozess

Das sogenannte Vormagensystem der Wiederkäuer umfasst den Pansen, den Netzmagen und den Blättermagen. Der Labmagen stellt demgegenüber den eigentlichen Drüsenmagen dar und ähnelt in seiner Struktur dem Magen von Allesfressern.

Wiederkäuer verbringen etwa die Hälfte ihres Tages mit der Nahrungsaufnahme. Der Prozess erfolgt in mehreren Phasen. Zunächst erfolgt lediglich eine grobe Zerkleinerung und Schlucken der Nahrung, sodass diese in den Pansen gelangt. Im Anschluss erfolgt die Fermentation des Nahrungsbreis durch Milliarden von Mikroorganismen. Der teilweise verdaute Nahrungsbrei wird anschließend zurück in den Mund befördert, wo er einer weiteren Zerkleinerung und einer erneuten Benetzung mit Speichel unterzogen wird, bevor er wiederum hinuntergeschluckt wird.

Das Vormagensystem fungiert demnach als komplexe Gärkammer. Die darin enthaltenen Mikroorganismen unterstützen den Prozess der Zersetzung pflanzlicher Nahrung und Freisetzung von Nährstoffen. Dabei entstehen Säuren, die durch den basischen Speichel neutralisiert werden müssen, um das System im Gleichgewicht zu halten.

Der Gehalt an strukturwirksamen Rohfasern in der Nahrung stellt einen entscheidenden Faktor für die Gesundheit und Effizienz des Verdauungssystems von Wiederkäuern dar. Ein Rohfasergehalt von etwa 15 % wird hierfür als optimal erachtet. Eine unzureichende Zufuhr an Rohfasern, in Kombination mit einer energiereichen Nahrung, beispielsweise Krafffutter, kann den Wiederkäuungsprozess beeinträchtigen. Dies resultiert in einer unzureichenden Neutralisation der produzierten Säuren, was wiederum zu einer Übersäuerung des Pansens führen kann.

(Fiala-Köck et al. 2019)

4.1.4 Hirschartige

4.1.4.1 Definition und Merkmale

Die Hirschartigen (Cervidae) sind eine Familie der Paarhufer innerhalb der Unterordnung der Wiederkäuer. Diese Familie umfasst etwa 50 Arten, die auf fast allen

Kontinenten vorkommen, außer in Australien und der Antarktis. Ein zentrales Merkmal der Hirschartigen ist das Vorhandensein von Geweihen, die aus Knochen bestehen und von den Männchen jährlich abgeworfen und neu gebildet werden. Diese Geweihe dienen als sekundäre Geschlechtsmerkmale und sind bei innerartlichen Kämpfen um Weibchen und Reviere von großer Bedeutung. (Heckeberg, 2017) (Fiala-Köck et al. 2019)

4.1.4.2 Anatomische Merkmale

Hirschartige haben einen schlanken, anmutigen Körperbau mit langen Beinen, der sie zu schnellen und ausdauernden Läufern macht. Ihre Füße enden in gespaltenen Hufen, die den typischen Paarhufbau widerspiegeln. Der Kopf ist häufig durch große Augen und Ohren gekennzeichnet, was auf eine hohe Wachsamkeit und ein ausgeprägtes Hörvermögen hinweist.

(Fiala-Köck et al. 2019)

4.1.4.3 Lebensweise und Ernährung

Hirschartige sind hauptsächlich Pflanzenfresser und ernähren sich von einer Vielzahl von Pflanzenmaterialien wie Blättern, Knospen, Gräsern und Früchten. Ihre Nahrung variiert je nach Jahreszeit und Verfügbarkeit. In gemäßigten Zonen ernähren sie sich im Frühling und Sommer vor allem von frischem Grün, während sie im Herbst und Winter vermehrt auf holzige Pflanzen und trockene Vegetation zurückgreifen. (Fiala-Köck et al. 2019)

Die Lebensräume der Cervidae sind vielfältig und reichen von dichten Wäldern über offene Graslandschaften bis hin zu Hochgebirgsregionen. Ihre Anpassungsfähigkeit an unterschiedliche Umgebungen trägt zu ihrer weiten Verbreitung bei. Viele Arten zeigen eine starke Präferenz für Lebensräume, die sowohl Deckung als auch offene Flächen bieten, da dies Schutz vor Raubtieren und Zugang zu Nahrung ermöglicht. (Fiala-Köck et al. 2019)

4.2 Europäisches Reh

4.2.1 Definition und Merkmale

Das Europäische Reh (*Capreolus capreolus*) gehört zu den kleineren Hirscharten und zeichnet sich durch einen schlanken, grazilen Körperbau aus. Es zählt zu den Kulturfolgern, weshalb es sich an den vom Menschen geschaffenen Lebensräumen anpasst. Es ist daher eine der am weitesten verbreiteten Arten innerhalb der Familie der Hirsche (Cervidae). Ausgewachsene männliche Tiere (Böcke) erreichen eine Schulterhöhe von 65 bis 75 Zentimetern und ein Gewicht von 20 bis 30 Kilogramm. Weibchen (Geißen) haben eine geringere Schulterhöhe und ein geringeres Gewicht. Die Fellfärbung variiert je nach Jahreszeit. Im Sommer ist das Fell rotbraun, im Winter

graubraun. Die Jungtiere, die sogenannten Kitze, haben in den ersten Lebenswochen weiße Flecken, die als Tarnfärbung dienen und sie vor Fressfeinden schützen. In den ersten Lebenswochen erreichen die Kitze eine Schulterhöhe von etwa 30 bis 40 cm und ein Gewicht von 1,5 bis 2 kg. Nach etwa fünf bis sechs Monaten erreichen die Jungtiere in der Regel ein Gewicht von 15 bis 20 Kilogramm und eine Schulterhöhe von 50 bis 60 Zentimetern.

(Fiala-Köck et al. 2019) (Herberstein und Zeiler, 2019)

4.2.1.1 Geweih

Böcke zeichnen sich durch ein relativ kurzes Geweih aus, das in der Regel bis zu drei Enden aufweist. Im Gegensatz zu den Böcken haben Geißen keinen Kopfschmuck. Das Geweih spielt eine wichtige Rolle im Sozial- und Fortpflanzungsverhalten der Tiere. Es dient sowohl der Verteidigung des Territoriums gegenüber Artgenossen als auch der Imponierung gegenüber den Weibchen während der Paarungszeit.

Die Geweihbildung bei Böcken beginnt bereits im Kitzalter. Die ersten Strukturen, die sich entwickeln, sind die Rosenstöcke, die aus den Knochenkernen des Stirnbeins entstehen. Die Rosen dienen als Grundlage für das Wachstum der Geweihstangen, die sich auf ihnen entwickeln und an ihrer Basis durch eine verbreiterte Struktur, die so genannte Rose, stabilisiert werden.

Das Geweih wird jährlich, meist im November oder Dezember, abgeworfen und anschließend sofort neu gebildet. Unmittelbar nach dem Abwurf bildet sich an der Abwurfstelle eine stark durchblutete, behaarte Haut, der sogenannte Bast. Sie dient dem Schutz und der Ernährung des neuen Geweihs. Unter dem Bast entwickelt sich zunächst eine knorpelige Vorstufe des neuen Geweihs.

Die Verknöcherung des Geweihs erfolgt schrittweise von der Basis her und beinhaltet die Einlagerung von Mineralstoffen wie Kalzium, Phosphor und Magnesium. Dieser Prozess führt zu einer Verfestigung und Stabilisierung des Geweihs. Wenn die Verknöcherung abgeschlossen ist, wird die Blutversorgung des Bastes unterbrochen, was zu seinem Absterben führt. Der abgestorbene Bast wird dann durch Reiben an Bäumen entfernt. Die Farbe des neuen Geweihs ist zunächst gelblich-weiß. Erst durch den Einfluss von Pflanzensäften, Harz, Sonnenlicht und verschiedenen Witterungseinflüssen verändert sich diese Farbe in die typische dunkelbraune Färbung. (Fiala-Köck et al. 2019) (Herberstein und Zeiler, 2019)



*Abbildung 1: Einjähriger Bock:
Die rechte Geweihstange ist noch
voll im Bast während bei der
linken Stange das Abwetzen
begonnen hat. Die gelblich-weiße
Farbe der Stange ist gut zu
erkennen.*



*Abbildung 2: Zweijähriger Bock:
Die dunkelbraune Färbung des
Geweihes nach der Einwirkung
von unterschiedlichen
Umweltfaktoren ist gut zu
erkennen.*

4.2.2 Verbreitung und Lebensraum

Das Europäische Reh ist in ganz Europa von den Küstenregionen bis zu den Alpen verbreitet. Es bevorzugt eine Vielzahl von Lebensräumen, wie Wälder, Waldränder, landwirtschaftlich genutzte Flächen und Heckenlandschaften. Insbesondere Mosaiklandschaften aus Wald und offenen Flächen werden bevorzugt, da sie ein reiches Nahrungsangebot und ausreichend Deckung bieten.

(Fiala-Köck et al. 2019)

4.2.3 Ernährung

Rehe sind spezialisierte Pflanzenfresser und gehören zu den sogenannten Konzentratselektierern, weshalb sie bei der Wahl ihrer Nahrung sehr wählerisch sind. Sie bevorzugen nahrhafte und leicht verdauliche Pflanzenteile. Ihre Nahrung umfasst eine Vielzahl von Pflanzen und Pflanzenteilen, darunter Wildkräuter, Knospen, Beeren, junge Triebe und Blätter. Auch Kulturpflanzen wie Getreide, Hülsenfrüchte, Raps und

Kohl gehören zum Nahrungsspektrum. Im Herbst kommen Eicheln, Bucheckern, verschiedene Obstsorten und Pilze hinzu. Die Vielfalt ihrer Nahrung ermöglicht es ihnen, sich an unterschiedliche Lebensräume und jahreszeitliche Veränderungen anzupassen. Dadurch können sie sowohl in Wäldern als auch in der Kulturlandschaft erfolgreich überleben.

(Fiala-Köck et al. 2019) (Herberstein und Zeiler, 2019)

4.2.4 Soziales Verhalten und Fortpflanzung

Das Sozialverhalten des Rehwildes unterliegt jahreszeitlichen Schwankungen, wobei die individuellen Verhaltensmuster stark von den jeweiligen Umweltbedingungen beeinflusst werden. In den Wintermonaten schließen sich Rehe zu nach Geschlechtern getrennten Rudeln zusammen. Die Größe dieser Rudel variiert je nach Lebensraum. In bewaldeten Gebieten umfassen sie in der Regel drei bis sieben Tiere, während in offenen Feldrevieren Rudelgrößen von bis zu 100 Rehen beobachtet werden können.

Im Frühjahr, ab März, führt ein Anstieg des Testosteronspiegels bei den Böcken zu erhöhter Aggressivität und damit zur Auflösung der Winterrudel. Territoriale Böcke markieren ihr Revier mit Duftstoffen, die von verschiedenen Drüsen produziert werden. Dabei werden rangniedere Böcke verdrängt, während junge Böcke in der Regel noch keine eigenen Territorien beanspruchen, sondern sich in den Grenzbereichen der etablierten Reviere aufhalten. Mit Beginn der kalten Jahreszeit schließen sich die Rehe wieder zu Rudeln zusammen, um den winterlichen Umweltbedingungen besser begegnen zu können.

Rehe sind meist Einzelgänger oder leben in kleinen Familienverbänden, die aus einer Geiß und ihren Kitzen bestehen. Böcke zeigen vor allem während der Paarungszeit ein ausgeprägtes Territorialverhalten. Die Paarungszeit erstreckt sich über die Monate Juli und August. In dieser Zeit markieren die Böcke ihr Territorium verstärkt und verteidigen es vehement gegen konkurrierende Böcke.

Die Interaktionen zwischen den Böcken während der Paarungszeit beinhalten häufig Kommentkämpfe. Diese Kämpfe folgen festgelegten Ritualen, die Verletzungen minimieren und vor allem dazu dienen, die Rangordnung festzulegen. Junge Böcke werden in der Regel toleriert, solange sie keine Bedrohung für die dominanten Böcke darstellen.

(Fiala-Köck et al. 2019) (Herberstein und Zeiler, 2019)

4.2.5 Geburtszeit

Die Tragzeit der Geißen beträgt etwa 40 Wochen, was auf eine verzögerte Einnistung der befruchteten Eizelle zurückzuführen ist. Nach der Befruchtung entwickelt sich der Keimling zunächst kaum weiter und tritt in eine mehrere Monate andauernde

Ruhephase ein, die als Keimruhe bezeichnet wird. Erst gegen Ende des Jahres setzt die Embryonalentwicklung wieder ein. Diese Anpassung gewährleistet, dass die Geburt der Kitze im Mai oder Juni erfolgt, wenn die Nahrungsverfügbarkeit optimal ist.

Die Geburt erfolgt typischerweise in der Dämmerung oder nachts, was das Risiko einer Prädation reduziert. In der Regel gebären Geißen ein bis zwei, selten drei Kitze, die unmittelbar nach der Geburt gesäugt werden. Als Nestflüchter sind die Kitze kurz nach der Geburt bereits in der Lage zu laufen, verbleiben jedoch in den ersten Lebenswochen gut versteckt im hohen Gras, wo sie durch ihre Tarnfärbung vor Fressfeinden geschützt sind.

(Fiala-Köck et al. 2019) (Herberstein und Zeiler, 2019)

4.2.6 Verhalten der Jungtiere bei Gefahr

In den ersten Wochen nach der Geburt sind Rehkitze in besonderem Maße verletzlich. Das gepunktete Fellmuster stellt für die Jungtiere jedoch eine essentielle Überlebensstrategie dar, da es eine hervorragende Tarnung in der Vegetation bietet. Bei Bedrohungen durch potenzielle Feinde wie Füchse und Greifvögel drücken sie sich reglos auf den Boden und verlassen sich vollständig auf ihre Tarnung, um nicht entdeckt zu werden. Diese Strategie erweist sich in der Natur als außerordentlich effektiv, allerdings sind mit ihr während der Mähzeit erhebliche Gefahren verbunden. Landwirte sind häufig nicht in der Lage, die im hohen Gras versteckten Kitze zu erkennen. Da die Jungtiere instinktiv regungslos liegen bleiben, werden sie häufig von den Mähmaschinen erfasst. (Fiala-Köck et al. 2019) (Cukor et al. 2019b)

5. Generelles zur Kitzrettung

Die Kitzrettung während der Mähseason stellt eine essentielle Maßnahme zum Schutz neugeborener Rehe dar. Der natürliche Instinkt der Kitze, sich regungslos auf den Boden zu drücken, anstatt zu fliehen, bietet zwar optimalen Schutz vor natürlichen Feinden wie Füchsen und Greifvögeln. Diese Verhaltensweise birgt jedoch ein beträchtliches Risiko, wenn landwirtschaftliche Maschinen in Betrieb sind.

In den vergangenen Jahrzehnten hat die moderne Landwirtschaft einen enormen Wandel durchgemacht. Die Intensivierung der landwirtschaftlichen Produktion, gekennzeichnet durch den verstärkten Einsatz von Maschinen, Chemikalien und optimierten Anbaumethoden, hat zu einer erheblichen Steigerung der Effizienz und Erträge geführt. Gleichzeitig hat jedoch der verstärkte Einsatz von Maschinen die Gefahr für Kitze deutlich erhöht.

In der Vergangenheit, als das Mähen noch manuell erfolgte, stellte die Kitzrettung kein Problem dar. Die Jungtiere wurden entweder ignoriert oder durch Wegtragen aus der Gefahrenzone gebracht.

Von modernen Mähmaschinen aus ist es Landwirten jedoch nicht möglich, die gut getarnten Kitze zu erkennen. Dies hat zur Konsequenz, dass die Jungtiere häufig schwere Verletzungen erleiden oder gar sterben.

Die Mähseason erstreckt sich in erster Linie auf die Monate Mai und Juni, was eine zeitliche Überschneidung mit der Phase der Geburt der Rehkitze darstellt. In dieser Zeit ist die Länge des Grases optimal für die Ernte, was die Gefahr für die Jungtiere signifikant erhöht. Um diesem Problem entgegenzuwirken, wurden verschiedene Methoden der Kitzrettung entwickelt. Diese zielen darauf ab, die Kitze vor dem Mähen aus den betroffenen Flächen zu entfernen und in Sicherheit zu bringen. Die Umsetzung solcher Maßnahmen ist nicht nur aus ethischen Gründen geboten, sondern trägt auch zur Erhaltung der Rehpopulationen und zur nachhaltigen Bewirtschaftung landwirtschaftlicher Flächen bei.

(Fiala-Köck et al. 2019)

5.1 Auswirkungen der landwirtschaftlichen Intensivierung

Die Intensivierung der Landwirtschaft hat verschiedene direkte und indirekte Auswirkungen auf die Tierwelt, insbesondere auf Wildtiere wie das Rehwild. Die wichtigsten Aspekte sind:

1. **Verlust von Lebensräumen:** Traditionelle Formen der Landwirtschaft boten Wildtieren eine große Vielfalt an Lebensräumen. Die moderne, intensivierte Landwirtschaft hingegen reduziert diese Vielfalt durch großflächige Monokulturen und den Verlust von Randstreifen, Hecken und kleinen Wäldern. Diese Elemente sind aber für viele Wildtierarten überlebenswichtig.
2. **Vermehrter Maschineneinsatz:** Der Einsatz schwerer Maschinen in der Landwirtschaft, insbesondere bei der Mahd, stellt eine erhebliche Gefahr für Jungtiere dar. Rehkitze, die sich instinktiv im hohen Gras verstecken, können den herannahenden Maschinen nicht entkommen.
3. **Zeitliche Verdichtung der Arbeitsabläufe:** Die Notwendigkeit, große Flächen in möglichst kurzer Zeit zu bewirtschaften, zwingt Landwirte, die Mahd oft in einem kurzen Zeitraum durchzuführen. Dies fällt häufig mit der Brut- und Setzzeit vieler Wildtiere zusammen.

(Fiala-Köck et al. 2019)

5.2 Methoden zur Kitzrettung

5.2.1 Traditionelle Suche

Die traditionelle Suche zur Rettung von Rehkitzen vor der Mahd ist eine der ältesten und am weitesten verbreiteten Methoden. Dabei werden die zu mähenden Wiesen in regelmäßigen Abständen von ca. 10 m von Menschen abgesucht, um systematisch eine möglichst große Fläche abzudecken und das Risiko, Rehkitze zu übersehen, zu minimieren. Häufig werden auch Jagdhunde eingesetzt, deren ausgeprägter Geruchssinn das Aufspüren der gut getarnten Kitze erleichtert. Diese Hunde werden speziell darauf trainiert, Kitze aufzuspüren, ohne sie zu verletzen (Cukor et al. 2019b).

Die traditionelle Suche ist arbeitsintensiv und erfordert eine gut koordinierte Gruppe von Personen. Des Weiteren ist die Methode fehleranfällig, da die gut getarnten Liegeplätze der Kitze vor allem in dicht bewachsenen Wiesen schwer zu erkennen sind. Witterung und Tageszeit können die Sichtverhältnisse und damit die Effizienz der Suche zusätzlich beeinträchtigen. Die Erfolgsquote der traditionellen Suche hängt stark von der Erfahrung und Aufmerksamkeit der Suchenden ab. Trotz dieser Herausforderungen bleibt die traditionelle Suche eine wichtige Methode, insbesondere in Gebieten, in denen keine technischen Hilfsmittel zur Verfügung stehen. Im

Durchschnitt verwenden 0,26 Rehkitze pro Hektar bei der Verwendung dieser Methode. (Cukor et al. 2019b)

5.2.2 Akustische Methoden

Akustische Methoden zur Kitzrettung nutzen Geräte, welche in regelmäßigen Intervallen Geräusche aussenden, um Wildtiere aus den zu mähenden Flächen zu vertreiben. Die Geräte können von einfachen Lärmemittern bis hin zu komplexen akustischen Systemen reichen, die spezifische Töne erzeugen, um Wildtiere zu alarmieren. Typischerweise werden diese Geräte über Nacht und in den frühen Morgenstunden eingeschaltet, um die Tiere rechtzeitig vor Beginn der Mahd aus den Wiesen zu vertreiben. (Cukor et al. 2019b)

Die Wirksamkeit dieser Methode variiert und hängt maßgeblich von der Art und Lautstärke der ausgesendeten Geräusche ab. Es besteht jedoch das Risiko, dass sich die Tiere an die Geräusche gewöhnen und nicht mehr darauf reagieren, was die Effektivität der Methode im Laufe der Zeit verringern kann. Des Weiteren können akustische Methoden andere Wildtiere sowie potenziell auch Haustiere in der Umgebung irritieren. (Cukor et al. 2019b)

Eine Studie aus Tschechien hat gezeigt, dass im Durchschnitt 0,11 Rehkitze pro Hektar bei der Verwendung akustischer Methoden verwenden. (Cukor et al. 2019b)

5.2.3 Geruchsmethoden

Geruchsmethoden zur Kitzrettung basieren auf dem Einsatz von Substanzen, die spezifische Gerüche aussenden, um Wildtiere abzuschrecken. Die Verteilung der Substanzen kann in Form von Sprays, Granulaten oder speziellen Behältern, welche die Duftstoffe langsam freisetzen, auf den betroffenen Wiesen erfolgen. Die Duftstoffe sind so konzipiert, dass sie für Wildtiere unangenehm sind und sie dazu veranlassen, die Flächen zu verlassen. (Cukor et al. 2019b)

Die Effektivität der Geruchsmethoden ist von der Intensität und der Art der verwendeten Gerüche abhängig. Ein wesentlicher Aspekt, der bei dieser Methode zu berücksichtigen ist, ist die Beständigkeit der Duftstoffe, die durch Witterungseinflüsse wie Regen oder starken Wind beeinträchtigt werden kann. Des Weiteren besteht die Möglichkeit, dass sich die Tiere an die Gerüche gewöhnen und die abschreckende Wirkung nachlässt. Dennoch stellen Geruchsmethoden eine zusätzliche Möglichkeit dar, die Kitze vor der Mahd zu schützen, insbesondere in Kombination mit anderen Techniken. (Cukor et al. 2019b)

Eine Studie aus Tschechien hat gezeigt, dass im Durchschnitt 0,06 Rehkitze pro Hektar bei der Verwendung von Geruchsmethoden verwenden. (Cukor et al. 2019b)

5.2.4 Optische Methoden

Optische Methoden zur Kitzrettung basieren auf dem Einsatz von visuellen Abschreckungsvorrichtungen, die Lichtsignale aussenden, um Wildtiere abzuschrecken. Die Installation der Vorrichtungen erfolgt auf Holzpfählen, welche über die Vegetation hinausragen. Durch die Aussendung regelmäßiger Lichtblitze wird eine Bewegung von Rehgeißen und ihren Kitzen in Richtung der gefährdeten Flächen induziert. Die Lichtsignale werden in der Regel durch eingebaute Sensoren bei Dämmerung aktiviert und blinken in Intervallen von etwa fünf Sekunden. Die Installation der Vorrichtungen erfolgt üblicherweise am Abend vor dem Mähen und deren Entfernung am Morgen des Mähens, um die maximale Wirkung zu erzielen. (Cukor et al. 2019b) (Jarnemo 2002)

Ein wesentlicher Aspekt, der bei dieser Methode zu berücksichtigen ist, ist die Sichtbarkeit der Lichtsignale, die durch Witterungseinflüsse wie Nebel oder dichtes Pflanzenwachstum beeinträchtigt werden kann. Des Weiteren besteht die Möglichkeit, dass sich die Tiere an die Lichtsignale gewöhnen und die abschreckende Wirkung nachlässt. (Cukor et al. 2019b)

Die Effektivität der optischen Methoden ist von der Sichtbarkeit und der Intensität der Lichtsignale abhängig. Eine Studie aus Tschechien hat gezeigt, dass bei optischen Abschreckungsvorrichtungen im Durchschnitt 0,12 Kitze pro Hektar verenden. (Cukor et al. 2019b)

Eine weitere Untersuchung demonstrierte, dass die Anwendung optischer Methoden zu einer signifikanten Reduktion der Kitzmortalität führt. In einer Studie in Schweden konnte nachgewiesen werden, dass der Einsatz von Plastikbeuteln auf Stangen dazu führt, dass 82 % der beobachteten Jungtiere von ihren Müttern aus den gefährdeten Gebieten entfernt werden. (Jarnemo 2002)

5.2.5 Kombination von Methoden

Die kombinierte Methode zur Kitzrettung vereint die traditionelle Suche mit einer oder mehreren Abschreckungsmethoden. Im Wesentlichen basiert die Methode auf dem Einsatz von optischen, akustischen und geruchlichen Abschreckungsmitteln sowie der Suche nach Kitzen durch freiwillige Helfer und Jagdhunde. (Cukor et al. 2019b)

Die kombinierte Methode ermöglicht eine Steigerung der Anzahl geretteter Jungtiere sowie einen umfassenden Schutz, da verschiedene Abschreckungsarten und Suchmethoden ineinandergreifen. Des Weiteren zeichnet sich die Methode durch ihre Flexibilität aus, die eine Anpassung an unterschiedliche Feldgrößen und -formen ermöglicht. Allerdings ist zu berücksichtigen, dass diese Methode einen höheren Arbeitsaufwand erfordert, da sie eine sorgfältige Koordination und mehr Arbeitskräfte erfordert. (Cukor et al. 2019b)

5.2.6 Drohnen mit Wärmebildkameras

5.2.6.1 Methodik

Eine in den letzten Jahren zunehmend genutzte Methode zur Rettung von Rehkitzten ist der Einsatz von Drohnen in Kombination mit Wärmebildkameras zur Durchsuchung von Wiesen. Dabei werden die Wiesen mit Drohnen überflogen, die mit Wärmebildkameras ausgestattet sind. Die Wärmebildgeräte erfassen die Körperwärme der Kitze, die sich deutlich von der Umgebungstemperatur abhebt. Die thermografischen Bilder ermöglichen eine einfache Erkennung von Jungtieren.

Sobald ein Rehkitz lokalisiert wurde, verbleibt die Drohne über dem Tier, um dessen Position zu markieren. Gleichzeitig bewegt sich ein Rettungsteam am Boden zur durch die Drohne markierten Position und fängt das Kitz ein.

Eine alternative und ebenfalls effiziente Vorgehensweise besteht darin, die Position des Rehkitzes mittels der Drohne zu ermitteln und zu speichern. Der Vorteil dieser Methode ist, dass die Drohne nach dem Aufspüren des Kitzes die genaue Position abspeichern kann, ohne dass sofortiges Eingreifen erforderlich ist. Später begeben sich Personen mit Positionsbestimmungsgeräten in das Feld und bergen die Jungtiere. Diese Alternative erweist sich als besonders nützlich, wenn mehrere Kitze in einem großen Gebiet verteilt sind oder eine sofortige Rettung nicht möglich ist.

5.2.6.2 Erfolgsquote

Cukor et al. (2019a) fokussierten sich auf die spezifische Anwendung zur Kitzrettung. Bei Flughöhen von 120 Metern betrug die Detektionsrate lediglich 90%. Ihre Tests zeigten, dass eine Flughöhe von 50 bis 70 Metern optimal ist und bei optimalen Bedingungen eine Detektionsrate von 100% erreicht werden kann.

Meyer et al. (2019) setzten Drohnen zur Wildtierüberwachung ein und zeigten, dass Drohnen mit Wärmebildkameras bei einer Flughöhe von 100 Metern über dem Boden eine Detektionsrate von 92,8% ergab.

5.2.6.3 Optimale Bedingungen

Beide Studien betonten die Bedeutung der Flugzeit und der klimatischen Bedingungen. Cukor et al. (2019a) stellten fest, dass die besten Ergebnisse in den frühen Morgenstunden (4 bis 6 Uhr) erzielt wurden, wenn der Temperaturkontrast zwischen den Rehkitzten und ihrer Umgebung am größten ist.

Natürlich spielt auch die verwendete Wärmebildkamera eine wesentliche Rolle für die Erfolgsquote.

5.2.6.4 Mögliche Schwächen

Obwohl die Technologie vielversprechend ist, gibt es auch einige Schwächen und Herausforderungen. Eine der größten Schwächen ist der menschliche Faktor. Cukor et

al. (2019a) wiesen darauf hin, dass die Effektivität der Detektion stark von der Aufmerksamkeit und dem Ermüdungsgrad des Drohnenpiloten abhängt. Verlust der Aufmerksamkeit oder Müdigkeit können dazu führen, dass Kitze übersehen werden, was die Erfolgsrate der Methode verringert.

Darüber hinaus sind die klimatischen Bedingungen ein limitierender Faktor. Starke Winde, Nebel und Regen können die Bildqualität beeinträchtigen und die Detektion erschweren. Diese Bedingungen erfordern eine sorgfältige Planung und gegebenenfalls eine Verschiebung der Flüge, um die besten Ergebnisse zu erzielen

5.2.7 Drohnen mit künstlicher Intelligenz

Eine neue Methode zur Kitzrettung basiert auf der Kombination von künstlicher Intelligenz (KI) und Drohnentechnologie. Dabei wird wie bei der vorherigen Methode eine Fläche überflogen und dann automatisch mit Hilfe von KI erkannt, ob sich ein Rehkitz in dieser Fläche befindet. Diese Methode eliminiert den Menschen als potenzielle Fehlerquelle und kann die Detektionsrate erhöhen, insbesondere bei Ermüdung des Drohnenpiloten.

Im Rahmen der Kitzrettung durch KI bestehen grundsätzlich zwei Möglichkeiten einer Optimierung:

1. **Echtzeit-Auswertung:** Hierbei erfolgt eine Echtzeit-Auswertung des Videos, sodass der Drohnenpilot am Bildschirm eine Anzeige erhält, sobald ein Rehkitz erkannt wurde. Dies erleichtert die unmittelbare Lokalisierung und Rettung der Kitze und steigert die Effektivität der Suche.
2. **Nachträgliche Auswertung:** Das Videomaterial wird nach dem Flug analysiert, und die Koordinaten der Kitze werden ermittelt. Diese Methode ist insbesondere dann von Vorteil, wenn die Jungtiere nicht sofort aus den Wiesen geholt werden müssen. Durch die Entkopplung von Fliegen und Retten wird eine flexible und effiziente Rettungsplanung ermöglicht.

(Rivas et al. 2018)

(Corcoran et al. 2021)

(Meyer et al. 2019)

6. Ortungstechnologien

Ortungssysteme spielen eine entscheidende Rolle in zahlreichen modernen Anwendungen, von der Navigation über die Vermessung bis hin zu fortschrittlichen wissenschaftlichen Untersuchungen. Sie ermöglichen die genaue Bestimmung von Positionen und die Verfolgung von Bewegungen.

6.1 Geografisches Koordinatensystem

Das geografische Koordinatensystem ermöglicht die präzise Bestimmung von Positionen auf der Erdoberfläche durch die Verwendung von Längengraden (Longitude) und Breitengraden (Latitude). Diese Koordinaten bilden ein Netzwerk aus Längen- und Breitengradlinien, die sich kreuzen und eine Art Gitter über die Erde legen. (Wikipedia 2024i)

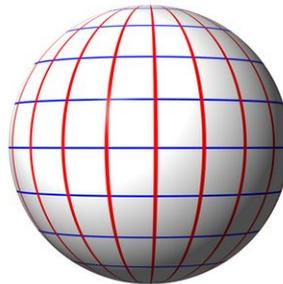


Abbildung 3: Längengrade (rot) und Breitengrade (blau)

6.1.1 Längengrad

Längengrade verlaufen von Nord- zu Südpol und werden vom sogenannten Nullmeridian in Greenwich aus gemessen. Der Abstand zwischen den Längengraden ist am Äquator am größten und wird zu den Polen hin kleiner. (Wikipedia 2024i)

6.1.2 Breitengrad

Breitengrade verlaufen parallel zum Äquator und messen die Entfernung nördlich oder südlich davon. Die Abstände zwischen den Breitengraden sind überall gleich. (Wikipedia 2024i)

6.2 Global Navigation Satellite System

6.2.1 Generelles

Das Global Navigation Satellite System (GNSS) ist ein Überbegriff für alle satellitengestützten Systeme zur Positionsbestimmung. Diese Technologie ermöglicht es, weltweit und auf wenige Meter genau Positionen zu bestimmen. Die bekanntesten GNSS sind:

1. Global Positioning System (GPS) der USA
2. GLONASS aus Russland
3. Galileo der Europäischen Union
4. BeiDou aus China

(Wikipedia 2024c)

6.2.2 Technische Grundlagen von GNSS

GNSS-Satelliten bewegen sich in festen Umlaufbahnen um die Erde und senden kontinuierlich Signale aus. Die Signale enthalten sowohl die exakte Sendezeit als auch die aktuelle Position des jeweiligen Satelliten. Ein GNSS-Empfänger auf der Erde empfängt die Signale und ermittelt die Differenz zwischen der Sende- und Empfangszeit. Aus der ermittelten Zeitdifferenz wird schließlich die Entfernung zu jedem einzelnen Satelliten berechnet. (Wikipedia 2024c)

Um die genaue Position auf der Erdoberfläche zu bestimmen, benötigt der Empfänger Signale von mindestens vier Satelliten. Mithilfe der Methode der Trilateration, bei der die Schnittpunkte der kugelförmigen Entfernungsradien der Satelliten berechnet werden, kann der Empfänger seine genaue Position bestimmen. Diese Technik ermöglicht eine Positionsgenauigkeit im Bereich von etwa 4 bis 10 Metern. (Wikipedia 2024c)

6.2.3 GNSS-Systeme

6.2.3.1 Global Positioning System

Das bekannteste GNSS ist das Global Positioning System (GPS), welches seit den 1970er-Jahren vom US-Verteidigungsministerium entwickelt wird. Seit den 1990er-

Jahren ist GPS voll funktionsfähig und ermöglicht eine präzise Positionsbestimmung weltweit. Im Jahr 2000 wurde die künstliche Signalverschlechterung, auch als Selective Availability bezeichnet, abgeschaltet. Dadurch konnte die Positionsgenauigkeit für zivile Nutzer erheblich verbessert werden und liegt seither bei unter 10 Metern. Vor der Abschaltung der Selective Availability lag die Genauigkeit ziviler GPS-Geräte bei etwa 100 Metern. (Wikipedia 2024d)

6.2.3.2 GLONASS

GLONASS ist das GNSS-System Russlands und bietet ähnliche Dienste wie GPS. Es wird von der russischen Raumfahrtagentur betrieben und ist seit den 1980er-Jahren in Betrieb. GLONASS bietet vergleichbare Genauigkeiten wie GPS. (Wikipedia 2024e)

6.2.3.3 Galileo

Galileo bietet hochpräzise Positionierungsdienste und ist insbesondere für zivile Anwendungen optimiert. Ein besonderer Vorteil von Galileo ist die höhere Signalgenauigkeit sowie die Fähigkeit, in städtischen Umgebungen bessere Leistungen zu erbringen. Die volle Funktionsfähigkeit von Galileo wird durch eine Konstellation von insgesamt 30 Satelliten erreicht, die auf drei Umlaufbahnen verteilt sind. Dadurch wird eine Positionsgenauigkeit im Bereich von 1 bis 5 Metern ermöglicht. (Wikipedia 2024f)

6.2.3.4 BeiDou

BeiDou ist das GNSS Chinas, das ebenfalls in den letzten Jahrzehnten entwickelt wurde. Es bietet ähnliche Dienste wie GPS und GLONASS und wird kontinuierlich ausgebaut. (Wikipedia 2024g)

6.3 Differential Global Positioning System

Das Differential Global Positioning System (DGPS) ermöglicht eine Verbesserung der Genauigkeit von GNSS durch die Nutzung von fest installierten Referenzstationen an bekannten Positionen. Die Referenzstationen empfangen die gleichen GNSS-Signale wie die mobilen Empfangsgeräte und berechnen die Differenz zwischen der gemessenen und der bekannten Position. Die Korrekturdaten werden daraufhin an die mobilen Empfänger gesendet. Dadurch können die mobilen Empfangsgeräte ihre Positionsberechnungen entsprechend anpassen. Die Anwendung von DGPS ermöglicht eine signifikante Steigerung der Positionsgenauigkeit auf wenige Zentimeter. (Wikipedia 2024h)

7. Drohnen

Unbemannte Luftfahrzeuge (Unmanned Aerial Vehicles, UAVs), umgangssprachlich oft als Drohnen bezeichnet, haben sich in den letzten Jahrzehnten als eine der bedeutendsten technologischen Entwicklungen in der Luftfahrt etabliert. UAVs umfassen eine Vielzahl von Fluggeräten, die ohne direkten menschlichen Piloten an Bord betrieben werden. Diese Technologie ermöglicht eine breite Palette von Anwendungen, von militärischen Operationen über wissenschaftliche Forschung bis hin zu kommerziellen und privaten Nutzungen. (Hoang et al. 2023) (Otto et al. 2018)

7.1 Multikopter

Multikopter, insbesondere Quadrocopter, sind eine der populärsten Drohnenkategorien für den privaten Gebrauch. Sie zeichnen sich durch mehrere Rotoren aus, die symmetrisch um den Rahmen angeordnet sind und eine hohe Stabilität und Manövrierfähigkeit bieten. Diese Drohnen sind in der Regel einfach zu bedienen und eignen sich hervorragend für Anwendungen wie Luftaufnahmen, Freizeitflüge und technische Experimente. (Hoang et al. 2023) (Otto et al. 2018)

7.1.1 Funktionsweise

Multikopter fliegen, indem sie den Schub jedes Propellers individuell anpassen, um Auftrieb und Stabilität zu erzeugen. Durch die Variation der Drehzahl der Propeller können sie aufsteigen, sinken, sich drehen und in alle Richtungen bewegen. Ein Flugcontroller, der das Herzstück des Multikopters darstellt, verarbeitet die Daten von Sensoren wie Gyroskopen, Beschleunigungssensoren und GPS-Modulen und steuert die Motoren entsprechend. (FPV Sports 2024)

7.1.2 Anwendungen im privaten Bereich

Im privaten Bereich werden Multikopter hauptsächlich für Freizeit- und Hobbynutzungen eingesetzt. Luftaufnahmen und Videografie sind besonders beliebt, da sie atemberaubende Perspektiven und Aufnahmen ermöglichen, die mit herkömmlichen Kameras nicht möglich wären. Auch technische Bastler und Ingenieure nutzen Multikopter für Experimente und Entwicklungen neuer Technologien. (Hoang et al. 2023) (Otto et al. 2018)

7.1.3 Steuerung und Übertragung von Kamerabildern

Multikopter werden in der Regel über Funkfernbedienungen oder Smartphone-Apps gesteuert. Diese bieten eine benutzerfreundliche Oberfläche und ermöglichen es dem Piloten, die Drohne präzise zu steuern und Flugeinstellungen anzupassen. Die

Fernsteuerung erfolgt oft über eine 2,4 GHz oder 5,8 GHz Frequenz, wobei moderne Systeme beide Frequenzen nutzen, um Interferenzen zu minimieren und eine stabile Verbindung zu gewährleisten.

Die Übertragung von Kamerabildern erfolgt über verschiedene Technologien. Einige Modelle nutzen Wi-Fi zur Übertragung von Videodaten, wobei die Drohne ein eigenes Wi-Fi-Netzwerk erzeugt, mit dem sich das mobile Gerät verbindet. Fortgeschrittene Drohnen verwenden proprietäre Funktechnologien wie Lightbridge oder OcuSync, die speziell für die Übertragung von Videosignalen optimiert sind und größere Reichweiten sowie stabilere Verbindungen bieten.

Hersteller bieten oft spezielle Apps an, die die empfangenen Videodaten anzeigen und zusätzliche Steuerungs- und Konfigurationsmöglichkeiten bieten. Diese Apps ermöglichen es den Nutzern, die Kameraeinstellungen anzupassen, Flugrouten zu planen und in Echtzeit auf die Videostreams zuzugreifen. Die Kombination aus fortschrittlicher Steuerungstechnologie und leistungsfähiger Bildübertragung macht Multikopter zu vielseitigen Werkzeugen für eine Vielzahl von Anwendungen.

(Waldmann 2019)

7.2 DJI Mavic 3T

Die DJI Mavic 3T ist eine Drohne des chinesischen Herstellers DJI, die speziell für industrielle Anwendungen, Such- und Rettungsaktionen sowie Notfalleinsätze entwickelt wurde. Diese Drohne ist mit einer 48-Megapixel-Hauptkamera, einer 12-Megapixel-Zoom-Kamera mit bis zu 56-fachem Hybridzoom sowie einer Wärmebildkamera ausgestattet. Vor allem durch die Wärmebildkamare findet sie auch oft Anwendung zur Rehkitzrettung. Die Drohne weist eine maximale Flugzeit von 45 Minuten sowie eine maximale Reichweite von 32 Kilometern auf. Die 360-Grad-Hindernisvermeidung sowie die automatische Rückkehrfunktion gewährleisten ein hohes Maß an Sicherheit. (DJI 2024a)



Abbildung 4: DJI Mavic 3T (DJI 2024b)

8. Wärmebildgeräte

Wärmebildgeräte erfassen Infrarotstrahlung und wandeln diese in für den Menschen sichtbare Bilder um. Dadurch wird die Wärmeverteilung auf Oberflächen sichtbar, was besonders bei völliger Dunkelheit oder schlechten Lichtverhältnissen nützlich ist.

Die Sensoren von Wärmebildkameras bestehen häufig aus Materialien wie Vanadiumoxid oder amorphem Silizium. Diese Materialien ändern ihren elektrischen Widerstand in Abhängigkeit von der Temperatur. Die von den Objekten emittierte Infrarotstrahlung wird durch eine Linse auf den Sensor fokussiert, wo die Temperaturänderungen in elektrische Signale umgewandelt werden. Diese Signale werden dann von einer Signalverarbeitungseinheit in ein sichtbares Wärmebild, das sogenannte Thermogramm, umgewandelt.

Es gibt zwei Haupttypen von Infrarotdetektoren, die in Wärmebildgeräten verwendet werden: gekühlte und ungekühlte Detektoren. Gekühlte Infrarotdetektoren arbeiten bei sehr niedrigen Temperaturen (ca. 70 K) und bieten eine hohe thermische Empfindlichkeit und Bildqualität. Allerdings benötigen diese Detektoren aufwendige Kühlsysteme wie flüssigen Stickstoff oder Stirling-Kühler, was die Geräte teurer und weniger mobil macht. Im Gegensatz dazu arbeiten ungekühlte Infrarotdetektoren bei Umgebungstemperatur und sind einfacher und kostengünstiger zu betreiben. Diese Detektoren verwenden Mikrobolometer, die die Infrarotstrahlung in Wärme umwandeln und dadurch den elektrischen Widerstand ändern, der gemessen wird.

(Wikipedia 2024a)

(Wikipedia 2024b)

9. Künstliche Intelligenz

Der Begriff Künstliche Intelligenz (KI) bezeichnet die Fähigkeit von Maschinen und Computern, Aufgaben zu erledigen, die normalerweise menschliche Intelligenz benötigen. Dazu zählen beispielsweise das Erkennen von Mustern, das Lernen aus Erfahrungen sowie das Treffen von Entscheidungen. (IBM 2024a)

9.1 Grundbegriffe der Künstlichen Intelligenz

9.1.1 Maschinelles Lernen (ML)

Maschinelles Lernen (ML) bezeichnet das wissenschaftliche Studium von Algorithmen und statistischen Modellen, welche von Computersystemen zur Lösung spezifischer Aufgaben eingesetzt werden, ohne dass eine explizite Programmierung erforderlich ist.

Dies ermöglicht es Computern aus Daten zu lernen und auf dieser Grundlage Vorhersagen oder Entscheidungen zu treffen. Die Definition des maschinellen Lernens geht auf Arthur Samuel zurück, der es als das Forschungsgebiet beschreibt, das Computern die Fähigkeit verleiht, ohne explizite Programmierung zu lernen. Samuel erlangte Bekanntheit durch sein Dame-Spielprogramm, welches bereits zu einem frühen Zeitpunkt das Potenzial maschinellen Lernens demonstrierte.

Maschinelles Lernen findet in zahlreichen alltäglichen Anwendungen Anwendung, beispielsweise in Websuchmaschinen, bei der Datenanalyse, Bildverarbeitung und prädiktiven Analysen.

Es gibt verschiedene Arten von maschinellem Lernen:

1. **Überwachtes Lernen (Supervised Learning):** Dies umfasst Algorithmen, welche aus annotierten Trainingsdaten lernen und eine Funktion erstellen, welche die Eingabedaten mit den entsprechenden Ausgabedaten verknüpft. Ein Beispiel hierfür sind Entscheidungsbäume, welche Entscheidungen und deren mögliche Konsequenzen in einer baumartigen Struktur darstellen.
2. **Unüberwachtes Lernen (Unsupervised Learning):** Dabei werden aus ungelabelten Daten Muster extrahiert und Strukturen innerhalb der Daten erkannt.
3. **Halbüberwachtes Lernen (Semi-Supervised Learning):** Bei dieser Methode lernen Algorithmen aus einem Teil annotierter und nicht annotierter Daten. Dabei werden Elemente des überwachten und unüberwachten Lernens kombiniert, um bessere Vorhersagen zu treffen, insbesondere wenn das Labeling von Daten zu teuer oder zeitaufwendig ist.

4. **Bestärkendes Lernen (Reinforcement Learning):** Bei dieser Methode lernen Algorithmen Handlungen zu optimieren, indem sie mit ihrer Umgebung interagieren. Sie erhalten Feedback in Form von Belohnungen oder Bestrafungen. Das Ziel ist eine Strategie zu entwickeln, die langfristige Belohnung maximiert.

(IBM 2024c) (Mahesh und Batta 2019)

9.1.2 Labeling (Annotieren)

Beim Labelling werden Daten mit Informationen oder Etiketten (Label) versehen, damit diese von maschinellen Lernmodellen verwendet werden können.

Beispielsweise können Bilder von Katzen und Hunden mit dem Etikett „Katze“ und „Hund“ versehen werden. Dieser Prozess ist vor allem wichtig für das überwachte Lernalgorithmen, damit diese in der Lage sind die genannten Etiketten basierend auf den Eingabedaten korrekt zu erkennen und zu klassifizieren. (IBM 2024b)

9.1.3 Model

Ein Model (Modell) in der KI bezeichnet eine mathematische Repräsentation, die mit dem Ziel entwickelt und trainiert wurde, bestimmte Aufgaben zu erledigen. Dazu zählen beispielsweise das Erkennen von Bildern, das Verstehen von Sprache oder das Treffen von Vorhersagen. Das Modell basiert auf Algorithmen und wird durch Training mit großen Datenmengen angepasst, sodass es in der Lage ist, Muster und Zusammenhänge in den Daten zu erkennen und zu generalisieren. Auf diese Weise kann es neue, unbekannte Daten analysieren. (IBM 2024c)

9.1.4 Foundation Model

Ein Foundation Model stellt ein großes, vortrainiertes Modell dar, welches auf einer umfangreichen und vielfältigen Datengrundlage trainiert wurde. Diese Modelle bieten eine breite Basis für eine Vielzahl von Aufgaben und können durch Feintuning auf spezifische Anwendungen adaptiert werden. Der Vorteil von Foundation Models besteht darin, dass sie grundlegendes Wissen über eine Vielzahl von Bereichen hinweg erfasst haben und dieses Wissen effizient auf spezifische Aufgaben übertragen können. (Murphy 2024)

9.1.5 Bounding Box

Eine Bounding Box stellt einen rechteckigen Rahmen dar, welcher zur Markierung und Lokalisierung von Objekten in Bildern dient. Diese Rahmen finden häufig Anwendung in der Bildverarbeitung sowie beim Training von Objekterkennungsalgorithmen. Die Bounding Box definiert die x- und y-Koordinaten der oberen linken Ecke sowie die Breite und Höhe des Rechtecks. Die Bounding Box hilft bei der Lokalisierung des Bereiches eines Objektes innerhalb eines Bildes. Dies ist insbesondere von Relevanz

für Anwendungen wie die Gesichtserkennung, Fahrzeugverfolgung oder andere Objekterkennungsaufgaben. (Redmon et al. 2016)

9.1.6 Neuronale Netze

Neuronale Netze stellen computergestützte Modelle dar, welche sich in ihrer Struktur und Funktion an den biologischen Gehirnen orientieren. Sie setzen sich aus mehreren Schichten von miteinander verbundenen Neuronen zusammen, welche mathematische Operationen zur Verarbeitung von Daten und Erkennung von Mustern ausführen. Diese Netzwerke haben sich in verschiedenen Bereichen der künstlichen Intelligenz (KI) durchgesetzt, darunter in der visuellen Objekt- und Sprachwiedererkennung, maschinellen Übersetzung sowie der Steuerung von Robotern.

Die grundlegende Struktur eines neuronalen Netzes umfasst Eingabeschichten, verborgene Schichten sowie eine Ausgabeschicht. Jede Schicht setzt sich aus Neuronen zusammen, welche Informationen von der vorherigen Schicht empfangen, verarbeiten und an die nächste Schicht weitergeben. In den verborgenen Schichten werden komplexe Berechnungen durchgeführt, wodurch das Netzwerk in der Lage ist, abstrakte Merkmale und Muster in den Eingangsdaten zu erkennen.

(Kietzmann et al. 2019)

9.1.7 Tiefe neuronale Netze (Deep Neural Networks, DNNs)

Tiefe neuronale Netze sind dadurch gekennzeichnet, dass sie mehrere verborgene Schichten nutzen, um tieferliegende und komplexere Merkmale zu extrahieren. Diese Modelle können eine hohe Anzahl an Parametern aufweisen, welche während des Trainingsprozesses adaptiert werden, um die Präzision der Prognosen zu optimieren.

Obwohl tiefen neuronalen Netzen zahlreiche Details biologischer Gehirne fehlen, haben sie sich gleichwohl als überaus effektiv erwiesen, bestimmte Aspekte der Gehirnfunktion zu modellieren. So weisen beispielsweise tiefgehende neuronale Netze, die für die Objekterkennung trainiert wurden, ähnliche Reaktionsmuster auf wie die visuellen Verarbeitungsbereiche im Gehirn von Primaten.

(Kietzmann et al. 2019)

9.2 Convolutional Neural Networks

Convolutional Neural Networks (CNNs) sind eine spezielle Klasse tiefer neuronaler Netze, deren Hauptanwendungsgebiet die Bild- und Spracherkennung ist. Ihre Effizienz beruht auf ihrer Fähigkeit, räumliche Hierarchien in den Daten zu erkennen. Die Architektur von CNNs wurde von der Struktur des visuellen Kortex im menschlichen Gehirn inspiriert, der eine spezialisierte Verarbeitung visueller Reize ermöglicht. (Wang et al. 2020)

9.2.1 Funktionsweise von CNNs

Ein Convolutional Neural Network besteht aus mehreren Schichten (Layer), von denen jede eine bestimmte Funktion erfüllt. Diese Schichten arbeiten zusammen, um Eingabedaten, beispielsweise Bilder, zu verarbeiten. (Wang et al. 2020)

9.2.1.1 Convolutional Layer (Faltungsschicht)

Diese Schicht ist für die Extraktion der Merkmale aus dem Eingabebild verantwortlich. In dieser Schicht werden Filter, auch Kernel genannt, auf das Eingabebild angewendet, um Merkmalskarten (Feature Maps) zu erzeugen. Jeder Filter extrahiert unterschiedliche Merkmale wie Kanten, Ecken oder Texturen. (Wang et al. 2020)

9.2.1.2 Activation Layer (Aktivierungsschicht)

Anschließend wird oft eine Aktivierungsfunktion angewendet, um Nichtlinearität in das Modell einzuführen. Eine häufig verwendete Aktivierungsfunktion ist die ReLU (Rectified Linear Unit), die negative Werte auf Null setzt und positive Werte unverändert lässt. Dies hilft dem Netzwerk, komplexe Muster zu lernen. (Wang et al. 2020)

9.2.1.3 Pooling Layer (Pooling-Schicht)

Diese Schicht dient dazu, die Dimension der Merkmalskarten und damit die Anzahl der Parameter und der Berechnungen im Netz zu reduzieren. Eine gebräuchliche Methode ist das Max-Pooling, bei dem aus jedem Bereich der Merkmalskarte das Maximum extrahiert wird. (Wang et al. 2020)

9.2.1.4 Fully Connected Layer (Vollständig verbundene Schicht)

Am Ende des Netzes befinden sich vollständig verbundene Schichten, die alle Neuronen der vorherigen Schicht mit jedem Neuron der nächsten Schicht verbinden. Diese Schichten kombinieren die extrahierten Merkmale, um die endgültige Klassifikation vorzunehmen. (Wang et al. 2020)

10. Objekterkennung in Videos

Die Objekterkennung in Videos ist eine zentrale Aufgabe im Bereich der künstlichen Intelligenz und des maschinellen Lernens. Sie ermöglicht es, Objekte in Videodaten zu identifizieren, zu klassifizieren und deren Bewegung über die Zeit zu verfolgen. Anwendungen dieser Technologie finden sich in zahlreichen Bereichen wie Überwachung, autonomes Fahren, Robotik und Gesundheitswesen. Diese Technologie ist entscheidend für die Entwicklung intelligenter Systeme, die visuelle Informationen in Echtzeit analysieren und darauf reagieren können.

10.1 You Only Look Once

YOLO (You Only Look Once) ist ein Objekterkennungssystem, das von Joseph Redmon entwickelt wurde. Es unterscheidet sich von herkömmlichen Objekterkennungssystemen, da es das gesamte Bild in einem einzigen Durchgang analysiert und sowohl die Positionen als auch die Wahrscheinlichkeiten der Objekte direkt vorhersagt. Diese Methode ermöglicht eine schnelle und genaue Echtzeit-Objekterkennung. (Redmon et al. 2016)

10.1.1 Funktionsweise von YOLO

YOLO verwendet eine einheitliche Netzwerkarchitektur, die das Problem der Objekterkennung als Regressionsaufgabe behandelt. Dabei erfolgt die Erkennung direkt auf Basis von Bildpixeln, wobei die Bounding Box Koordinaten und die Klassenwahrscheinlichkeiten ebenfalls berücksichtigt werden. (Redmon et al. 2016)

10.1.1.1 Gitteraufteilung des Bildes

Das Eingabebild wird in ein $S \times S$ Gitter aufgeteilt, wobei jede Zelle die Vorhersage von Bounding Boxen sowie die Klassenwahrscheinlichkeit von Objekten, deren Zentrum in diese Zelle fällt, übernimmt. (Redmon et al. 2016)

10.1.1.2 Bounding Box Vorhersage

Für jede Gitterzelle werden mehrere Bounding Boxen vorausgesagt, die durch fünf Werte definiert sind: x und y (Koordinaten des Box-Zentrums relativ zur Gitterzelle), w und h (Breite und Höhe der Box relativ zur Bildgröße) sowie der Konfidenzwert (Wahrscheinlichkeit, dass die Box ein Objekt enthält). Zusätzlich werden die Klassenwahrscheinlichkeiten für jede Box vorhergesagt. (Redmon et al. 2016)

10.1.1.3 Verlustfunktion

Die Verlustfunktion von YOLO bewertet die Genauigkeit der vorhergesagten Bounding Boxes und die Klassifizierung der Objekte. Sie kombiniert Fehler in der Position, Größe und Konfidenz der Bounding Boxes sowie in den vorhergesagten Klassen. Ziel ist es,

die Gesamtvorhersageleistung des Modells zu optimieren, indem verschiedene Aspekte der Vorhersagen gleichzeitig berücksichtigt werden. (Redmon et al. 2016)

10.1.2 Darknet

Darknet ist ein Open-Source-Framework für die Implementierung und Ausführung tiefer neuronaler Netzwerke, das von Joseph Redmon entwickelt wurde. Es basiert auf den Programmiersprachen C und CUDA, wodurch es eine hohe Effizienz und Geschwindigkeit bei der Verarbeitung großer Datenmengen bietet, insbesondere durch die Nutzung der parallelen Rechenleistung von GPUs. Es ist besonders bekannt für seine Anwendung in der Echtzeit-Objekterkennung durch das "You Only Look Once" (YOLO)-Modell. (Redmon 2013-2016) (Charette 2024a)

10.1.3 DarkHelp

DarkHelp ist eine benutzerfreundliche C++-Bibliothek und -Anwendung, die entwickelt wurde, um die Verwendung von Darknet-Modellen zu erleichtern. Zu diesem Zweck stellt sie Funktionen zur Verfügung, die die Erkennung und Visualisierung von Objekten in Bildern und Videos erleichtern. Dadurch wird die Integration von YOLO-Modellen in Anwendungen vereinfacht. (Charette 2019-2024)

10.1.4 DarkMark

DarkMark ist eine grafische Desktopanwendung zur Erstellung von Trainingsdaten für Objekterkennungsmodelle, die mit dem Darknet trainiert werden. Es ermöglicht Benutzern, Bilder zu annotieren, indem sie Bounding Boxes um Objekte zeichnen und entsprechende Labels hinzufügen. Diese annotierten Bilder können dann verwendet werden, um neue Modelle zu trainieren. (Charette 2019-2023)

10.1.5 Vergleich mit anderen Modellen

10.1.5.1 Einleitung

Neben YOLO gibt es noch eine Vielzahl an anderen Modellen zur Objekterkennung. Hier wird auf die bekanntesten eingegangen und ein Vergleich zu You Only Look Once gemacht.

10.1.5.2 SSD (Single Shot MultiBox Detector)

SSD führt die Objekterkennung unter Verwendung mehrerer Feature-Maps und Default Boxes unterschiedlicher Größe und Form durch. Es kombiniert Vorhersagen aus verschiedenen Maßstäben und Aspekten, um eine genaue Erkennung zu ermöglichen. SSD bietet ein gutes Gleichgewicht zwischen Genauigkeit und Geschwindigkeit. (Liu et al. 2015)

10.1.5.3 Faster R-CNN (Region-based Convolutional Neural Networks)

Faster R-CNN verwendet ein Region Proposal Network (RPN) zur Identifizierung potenzieller Objekte und führt dann eine genauere Klassifizierung und Abgrenzung durch. Es ist sehr genau, aber oft langsamer als YOLO und SSD. (Ren et al. 2015)

10.1.5.4 EfficientDet

EfficientDet basiert auf der EfficientNet-Architektur und zielt darauf ab, eine effiziente und skalierbare Lösung für die Objekterkennung bereitzustellen. Es bietet eine hohe Genauigkeit bei geringem Rechenaufwand. EfficientDet erreicht aber nicht die Geschwindigkeit von YOLO. (Tan et al. 2019)

10.1.5.5 Fazit

You Only Look Once bietet im Vergleich zu anderen Modellen die schnellste Geschwindigkeit bei gleichzeitig hoher Genauigkeit und überschaubarem Ressourcenbedarf. Diese Voraussetzungen sind optimal, wenn man Objekterkennung bei der Rehkitzrettung einsetzen will, da dadurch eine Auswertung der Videos in Echtzeit bzw. je nach Hardware sogar noch schneller möglich ist. Ein weiterer Vorteil ist der nicht zu hohe Ressourcenbedarf, da bei der Kitzrettung in der Regel lediglich ein Laptop mit begrenzter Rechenleistung zur Verfügung steht.

11. Konzeptioneller Vorgehens- und Lösungsansatz

Im Rahmen dieser Bachelorarbeit soll ein Prototyp zur Erkennung von Rehkitzen mithilfe von künstlicher Intelligenz entwickelt werden.

Bei der herkömmlichen Methode zur Kitzrettung mit Drohnen wird eine Wiese von einem Menschen mit einer Drohne in einer Höhe von 40 bis 80 Metern überflogen. Sobald dieser eine Wärmequelle erkennt, fliegt er näher heran und verwendet die Tageslichtkamera, um das Objekt eindeutig identifizieren zu können.

Dieser Prototyp soll eine Identifikation von Wärmequellen ohne ein vorheriges Annähern ermöglichen. Der Prototyp soll in der Lage sein, die Rehkitze in den Wärmebildaufnahmen in einer Höhe von 40 bis 80 Metern zuverlässig von anderen Wärmequellen zu unterscheiden. Dadurch ist es möglich, eine Fläche in einer festen Höhe abzufliegen und die Aufnahmen anschließend durch eine künstliche Intelligenz auswerten zu lassen.

11.1 Daten

Im Zuge dieser Arbeit werden mehrere Aufnahmen der Rehkitzrettung einer DJI Mavic 3T ausgewertet, welche von einem Jäger zur Verfügung gestellt wurden. Die Aufnahmen umfassen sowohl Wärmebild- als auch Tageslichtaufnahmen. Des Weiteren enthalten die Untertitel der Videos die Koordinaten, die Höhe sowie die Blickwinkel der Drohne zum jeweiligen Zeitpunkt. Dadurch soll es möglich sein, die Position des Rehkitzes im Video genau zu bestimmen. Die Daten werden im Rahmen dieser Arbeit ausgewertet. Ein Teil davon wird für das Training des Prototypen verwendet. Der andere Teil der Daten dient als Testmaterial, um die Leistung des trainierten KI-Modells zu evaluieren und mit der manuellen Auswertung zu vergleichen.

11.2 Prototyp

Der Prototyp soll eine praktische Anwendung von künstlicher Intelligenz zur Rehkitzrettung bieten. Dabei soll eine Person mit einer Drohne in einer Höhe von 40 bis 80 Metern über eine Wiese fliegen. Anschließend werden die Wärmebildaufnahmen von dem Prototypen ausgewertet. Dieser soll die einzelnen Rehkitze erkennen und die Koordinaten dieser berechnen. Dadurch spart sich die drohnenfliegende Person die Zeit für das manuelle Erkennen der Rehkitze. Dafür müsste sie näher heranfliegen, um es eindeutig als Rehkitz zu erkennen. Die künstliche Intelligenz soll diese Aufgabe bereits in einer Höhe von 40 bis 80 Metern erfüllen können. Daher erfolgt das Training der KI ausschließlich mit Wärmebildaufnahmen dieser Höhen, da ein Training mit Aufnahmen der Tageslichtkamera aufgrund der Flughöhe und geringen Auflösung keine Erkennung ermöglicht.

Die künstliche Intelligenz des Prototypen basiert auf einem YOLO-Modell, welches mit den Aufnahmen der DJI Mavic 3T mithilfe von DarkMark trainiert wird. Des Weiteren wird eine grafische Desktopanwendung entwickelt, welche eine Visualisierung und Auswertung der Ergebnisse ermöglicht.

Da sich bei der Rehkitzrettung auch andere Wärmequellen wie Kitze in den Wiesen befinden, soll der Prototyp in der Lage sein, das Rehkitz von anderen Wärmequellen zu unterscheiden. Das trainierte YOLO-Modell soll Rehkitze, Hasen und Rehe voneinander unterscheiden können.

11.2.1 Anforderungen an das YOLO-Modell

1. Das trainierte YOLO-Modell soll Rehkitze erkennen können.
2. Das trainierte YOLO-Modell soll Rehe erkennen können.
3. Das trainierte YOLO-Modell soll Hasen erkennen können.

11.2.2 Anforderungen an die grafische Desktopanwendung

1. Die grafische Desktopanwendung soll es ermöglichen, ein Video zu importieren.
2. Die grafische Desktopanwendung soll es ermöglichen, die Untertitel zum Video zu importieren.
3. Die grafische Desktopanwendung soll Darknet mit einem trainierten YOLO-Modell aufrufen, um das Video auszuwerten.
4. Die grafische Desktopanwendung soll das Video anzeigen und die durch die KI erkannten Objekte inklusive deren Klassifizierung mit einer Bounding Box markieren.
5. Wenn auf die Bounding Box im Video geklickt wird, soll angezeigt werden, an welchen Koordinaten sich das Objekt befindet.
6. Über einen Zeitstrahl soll angezeigt werden, wann im Video ein Objekt erkannt wurde.
7. Über einen Zeitstrahl soll es möglich sein, direkt zu der Stelle im Video zu springen, wo dieses Objekt erkannt wurde.

11.3 Experiment

Das Ziel dieses Experiments ist die Methode der künstlichen Intelligenz mit der herkömmlichen Methode der manuellen Auswertung zu vergleichen. Im Zuge dessen erfolgt eine Gegenüberstellung der ermittelten Ergebnisse hinsichtlich der Schnelligkeit sowie der Detektionsrate.

Entscheidend für den Vergleich der Leistung zwischen Mensch und künstlicher Intelligenz ist, wie schnell eine Wärmequelle identifiziert werden kann und ob diese richtig klassifiziert wurde.

Im Rahmen des Experiments werden zwei Videos erstellt, welche mehrere Ausschnitte der zur Verfügung gestellten Aufnahmen enthalten. Die beiden Videos zeigen exakt dasselbe, jedoch einmal aus der Perspektive der Wärmebildkamera und andererseits aus der Perspektive der Tageslichtkamera.

11.3.1 Auswertung durch die Versuchspersonen

Für die Testpersonen soll ein Drohnenflug simuliert werden. Die Testpersonen sehen das Wärmebildvideo, können aber jederzeit auf die Tageslichtkamera umschalten. Sobald sie ein Objekt erkennen, geben sie dies bekannt und die dafür benötigte Zeit wird aufgezeichnet. Wenn sie das Objekt identifiziert haben, beurteilen sie, um was für ein Objekt es sich ihrer Meinung nach handelt. Durch das Umschalten zwischen dem Wärmebild- und dem Tageslichtvideo haben sie die Möglichkeit, bei Aufnahmen aus nächster Nähe, zu bestimmen worum es sich genau handeln könnte.

Für das Experiment wird eine Web-basierte App entwickelt, um allen Versuchspersonen die gleichen Bedingungen zu bieten. Diese Webanwendung soll auf einem Smartphone aufgerufen werden, um einen Bildschirm in der gleichen Größe wie bei der Steuerung einer Drohne zur Verfügung zu stellen.

Diese Webanwendung solle mehrere Funktionen haben:

1. Wechseln zwischen dem Tageslicht- und Wärmebildvideo
2. Pausieren des Videos
3. Zehn Sekunden zurückspringen
4. Bekanntgabe, dass ein Objekt erkannt wurde
5. Bekanntgabe, wie dieses Objekt klassifiziert wird (Kitz, Reh oder Hase)

Bei jeder dieser Aktionen wird der Zeitpunkt der Betätigung gespeichert. Dies ermöglicht eine einfache Auswertung der Werte für den späteren Vergleich.

11.3.2 Auswertung durch den Prototypen

Vom Prototypen wird nur das Wärmebildvideo ausgewertet. Dies liegt daran, dass in der realen Anwendung des Prototypen eine Wiese nur in einer festen Höhe zwischen 40 und 80 Metern überflogen wird und nie näher an eine Wärmequelle herangeflogen wird. Daher ist für die Bewertung der KI nur relevant, ob die Wärmequelle in dieser Höhe richtig erkannt wird und wie schnell das Objekt erkannt wird.

11.3.3 Signifikanztest für die Auffindungszeit

Um zu vergleichen, ob das KI-unterstützte Verfahren zu einer signifikanten Verkürzung der Detektionszeit führt, wird die Zeitdifferenz zwischen dem ersten Erscheinen eines Objekts im Video und seiner ersten Erkennung durch den Prototypen beziehungsweise der Testpersonen gemessen. Aus den Ergebnissen der Versuchspersonen wird zu jedem Objekt die durchschnittliche Zeitdifferenz berechnet, um diese mit den Werten des Prototypen zu vergleichen. Wird ein Objekt vom Prototypen oder einer Testperson nicht erkannt, wird als Annäherung die durchschnittliche Erkennungszeit aller anderen Objekte verwendet.

Um zu überprüfen, ob die künstliche Intelligenz die Erkennungszeit signifikant verkürzt, wird ein Signifikanztest durchgeführt. Da es sich bei den Stichproben um keine Normalverteilung und zwei unabhängige Gruppen handelt, wird ein Mann-Whitney-U-Test gewählt. Es wird ein einseitiger Test durchgeführt, da eine gerichtete Hypothese geprüft werden soll. Das Signifikanzniveau wird mit fünf Prozent festgelegt.

11.3.4 Vergleich der Detektionsrate

Für den Vergleich der Detektionsraten werden zwei Parameter berechnet:

1. Die Anzahl der korrekt erkannten Objekte in Prozent
2. Die Anzahl der erkannten Objekte, die nicht zu den Kategorien Kitz, Reh oder Hase gehören, aber als solche klassifiziert wurden, in Prozent

Aus den Werten der Testpersonen wird jeweils ein Mittelwert gebildet, der dann mit dem Ergebnis des Prototypen verglichen wird.

12. Aufbau des Prototypen

Der Prototyp besteht aus zwei Komponenten:

1. Einem trainierten YOLO-Modell zur Bilderkennung
2. Einer grafischen Desktopanwendung zur Visualisierung der Ergebnisse der KI

12.1 YOLO-Modell

Für das KI-Modell wurde YOLO gewählt und mithilfe von DarkMark ein Prototyp trainiert.

12.1.1 Trainingsdaten

Für das Training des YOLO-Modells wurden ausgewählte Bilder aus den zur Verfügung gestellten Aufnahmen der Rehkitzrettung verwendet. Dabei wurde ein YOLO-Modell mit zwölf Aufnahmen von Rehen, neun Aufnahmen von Hasen und 35 Aufnahmen von Kitzen trainiert. Insgesamt wurden 19 Stunden Videomaterial ausgewertet, aus denen jedoch nur diese wenigen relevanten Aufnahmen ausgewählt wurden. Dies liegt unter anderem daran, dass häufig nicht näher an die potenziellen Objekte herangeflogen wurde, wodurch eine eindeutige Identifizierung oft nicht möglich war. Zudem sind auf vielen Bildern keine relevanten Objekte wie Rehe, Hasen oder Kitze zu sehen, was die Anzahl der auswertbaren Bilder weiter reduziert. Alle Bilder haben eine Auflösung von 640x512 Pixel. Abbildung 5 zeigt ein Reh in der grünen Bounding Box. Die Bounding Box dieses Rehs hat eine Größe von 7x6 Pixel. Abbildung 6 zeigt einen Hasen mit einer Größe von 8x8 Pixel. Abbildung 7 zeigt ein Kitz mit einer Größe von 9x9 Pixel. Alle diese Bilder wurden aus einer Höhe von 40 bis 80 Metern aufgenommen. Es ist zu erkennen, dass aufgrund dieser hohen Flughöhen die Objekte bereits sehr klein sind und eine eindeutige Identifizierung nur schwer möglich ist.

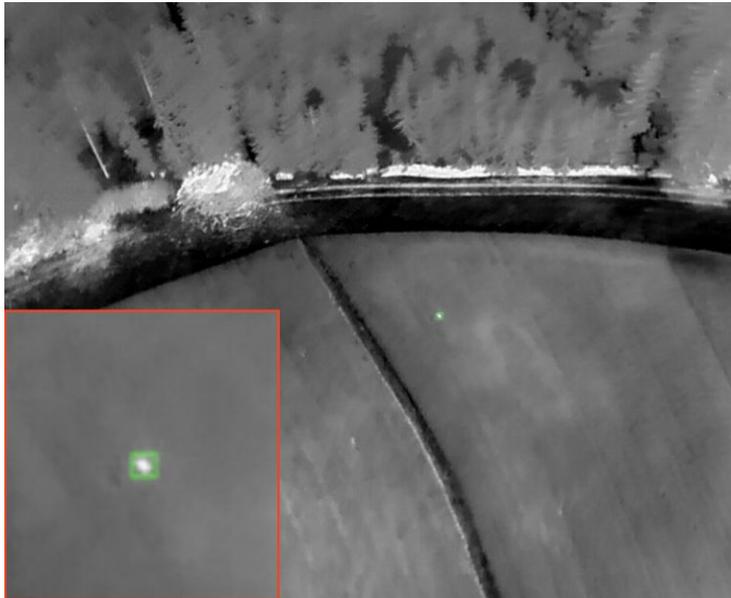


Abbildung 5: Bei der Wärmequelle in der grünen Bounding Box handelt es sich um ein Reh (7x6 Pixel). Die rote Box zeigt einen vergrößerten Ausschnitt.



Abbildung 6: Bei der Wärmequelle in der grünen Bounding Box handelt es sich um einen Hasen (8x8 Pixel). Die rote Box zeigt einen vergrößerten Ausschnitt.

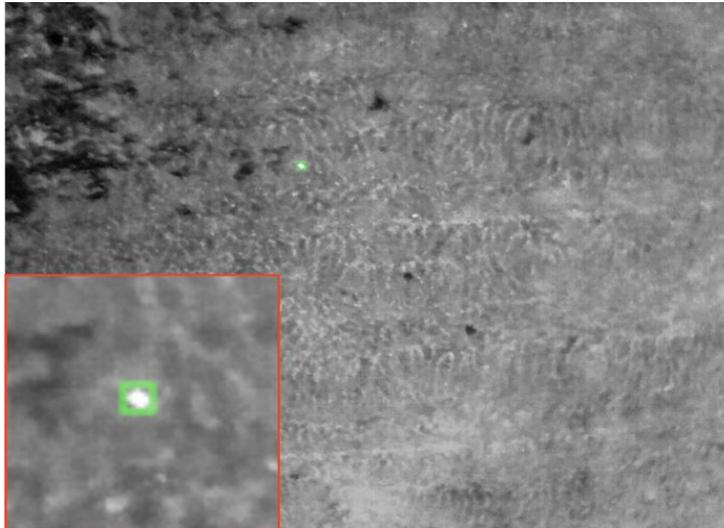


Abbildung 7: Bei der Wärmequelle in der grünen Bounding Box handelt es sich um ein Rehkitz (9x9 Pixel). Die rote Box zeigt einen vergrößerten Ausschnitt.

12.2 Trainieren mit DarkMark

Zum Trainieren eines YOLO-Modells wurde DarkMark gewählt, da es eine einfache Bedienung und Möglichkeit zur Annotierung von Trainingsdaten bietet.

Als ersten Schritt muss ein neuer Ordner angelegt werden. In diesem Ordner wird ein Unterordner erstellt, in dem alle Trainingsdaten liegen. Zusätzlich wird noch eine „names“ Datei erstellt. Darin wird für jedes Label eine eigene Zeile erstellt die den Namen des jeweiligen Labels enthält. Anschließend wird DarkMark gestartet.

Über „Add...“ kann nun der zuvor erstellte Ordner ausgewählt werden. (Charette 2024b)

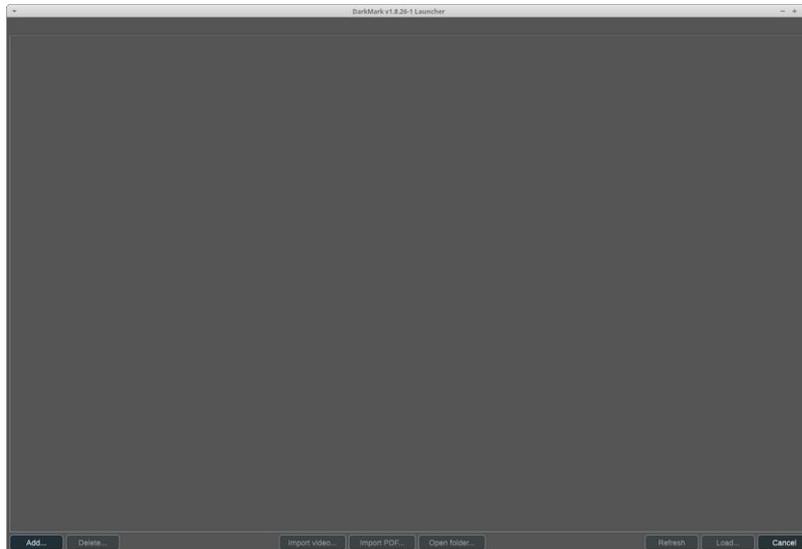


Abbildung 8: Initiale Ansicht von DarkMark

Nach dem Laden des Ordners werden alle erkannten Dateien angezeigt. Über den Button „Load...“ können alle Bilder des Projektes geladen und annotiert werden. (Charette 2024b)

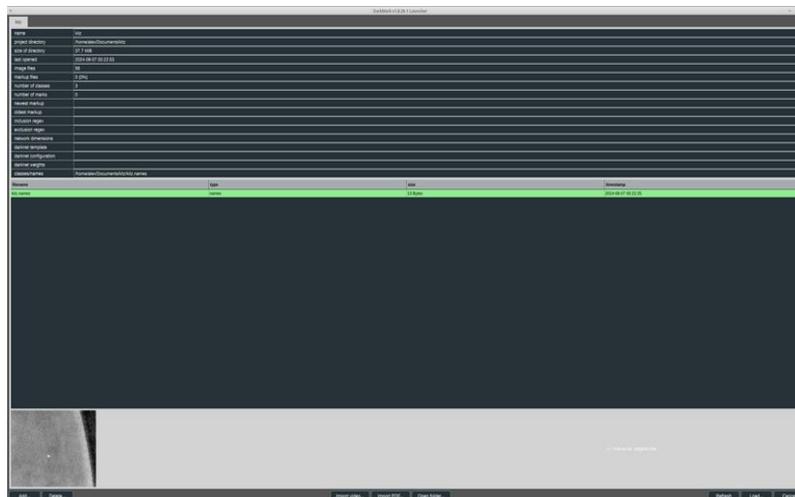


Abbildung 9: Laden des Projekts

Anschließend öffnet sich eine neue Ansicht. Das erste Bild wird angezeigt. Über das Mausekranz können die einzelnen Trainingsbilder durchgegangen werden. Das rote Fadenkreuz in Abbildung 10 stellt den Mauszeiger dar, mit dem eine Bounding Box erstellt werden kann. (Charette 2024b)

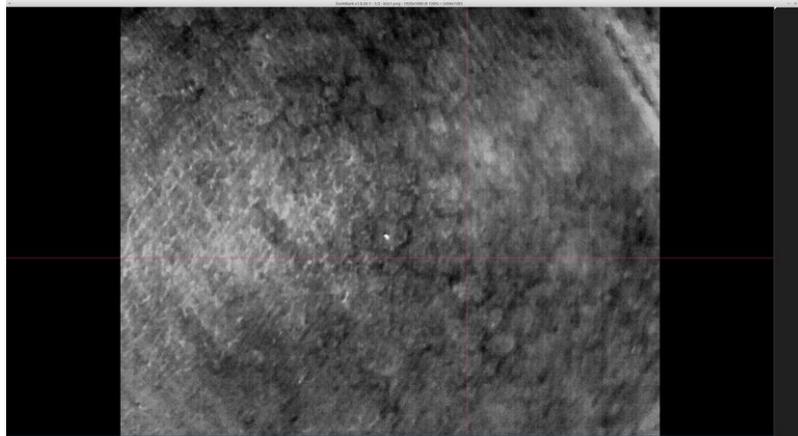


Abbildung 10: Anzeige der Trainingsdaten

Mit der Maus kann nun eine Bounding Box gezeichnet werden, um Objekte zu markieren. (Charette 2024b) (Charette 2024c)

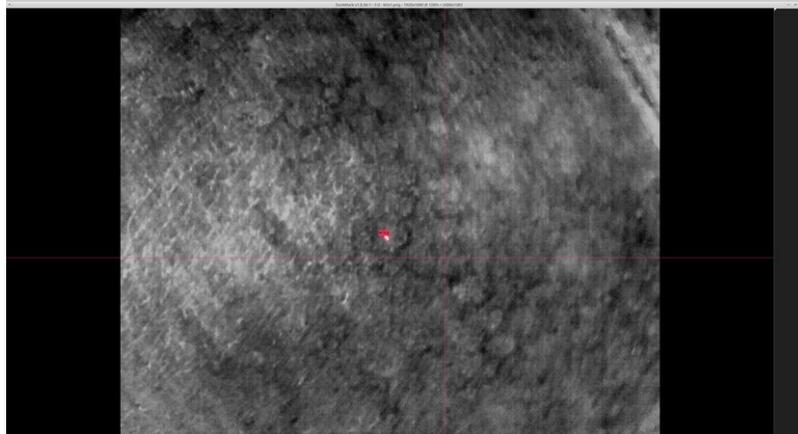


Abbildung 11: Bounding Box in DarkMark

Über Rechtsklick kann ein Kontextmenü geöffnet werden, mit welchem die Klassifizierung des erkannten Objektes geändert werden kann. Dieser Prozess wird nun so lange wiederholt, bis alle Bilder annotiert sind. (Charette 2024b) (Charette 2024c)

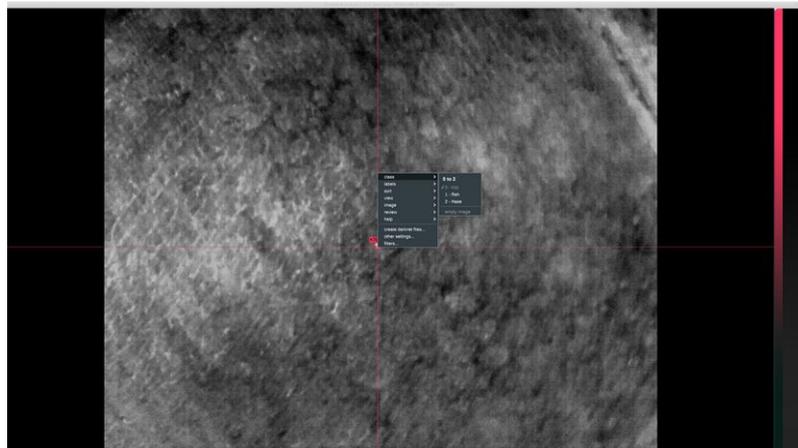


Abbildung 12: Klassifizierung in DarkMark

Anschließend ist es möglich über das Kontextmenü mit der Option „flip images...“ aus den bestehenden Bildern gespiegelte Bilder zu generieren. Mit der Option „rotate images...“ können rotierte Bilder generiert werden. Dadurch können aus einem bestehenden Datensatz weitere Trainingsdaten erzeugt werden. (Charette 2024b) (Charette 2024c)

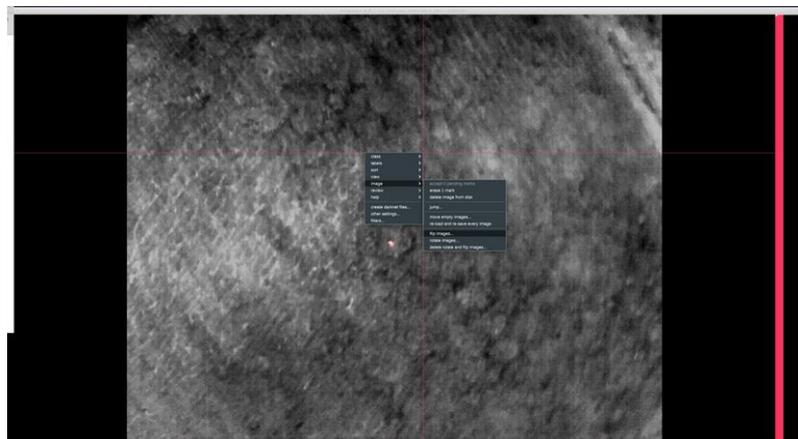


Abbildung 13: Bilder rotieren und spiegeln

Anschließend können über die Option „gather statistics...“ im Kontextmenü Statistiken über die annotierten Bilder angezeigt werden. (Charette 2024b)

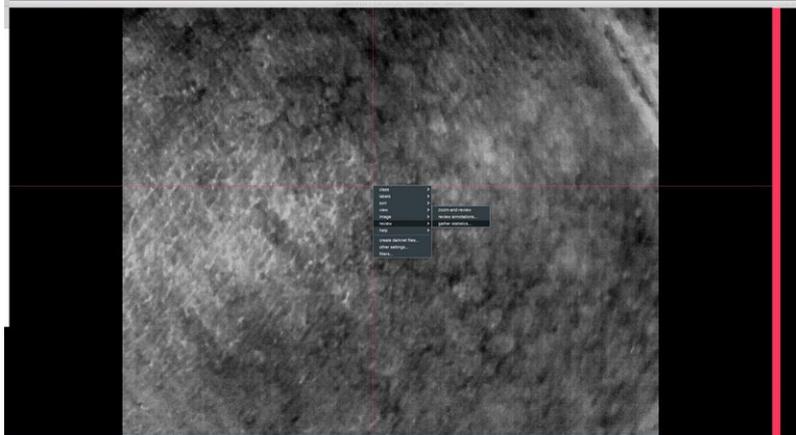


Abbildung 14: Statistiken

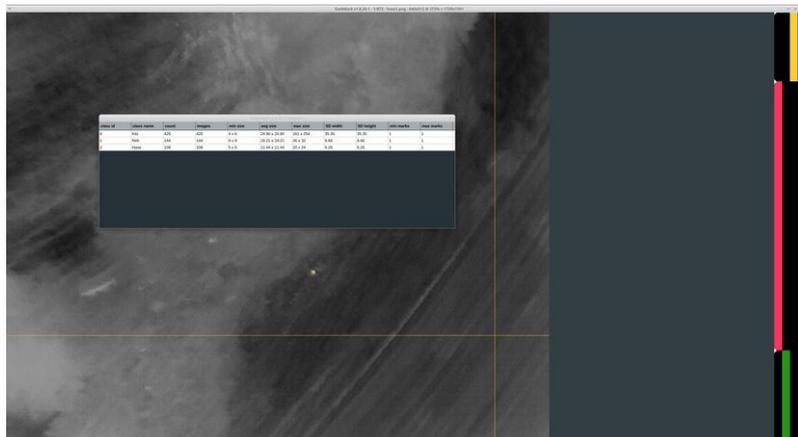


Abbildung 15: Statistiken

Abschließend lassen sich über die Option „create darknet files...“ im Kontextmenü die benötigten Dateien für das Training mit Darknet erstellen. Dabei stehen mehrere Einstellungen zur Verfügung, von denen die wichtigsten „network width“, „network height“ und „max_batches“ sind. Mit „network width“ und „network height“ werden die Dimensionen des Netzwerks festgelegt.

Mit der Option „max_batches“ wird angegeben, wie oft der Trainingsprozess mit den Trainingsdaten wiederholt werden soll. Ein höherer Wert bedeutet mehr Iterationen und eine bessere Generalisierung. (Charette 2020)

YOLO liefert die besten Ergebnisse, wenn das kleinste zu erkennende Objekt mindestens eine Größe von 16x16 Pixeln erreicht. Um dies zu gewährleisten, wird die

Netzwerkgröße so skaliert, dass das kleinste Objekt diese Größe ungefähr erreicht. In diesem Fall beträgt die kleinste Objektgröße 4x6 Pixel. Ein Skalierungsfaktor von drei wurde gewählt, wodurch die Objektgröße auf 12x18 Pixel anwächst. Daraus ergeben sich Netzwerkdimensionen von 1920x1536 Pixel, da die Auflösung des ursprünglichen Bildes 640x512 Pixel beträgt. Wichtig ist, dass die Dimensionen durch 32 teilbar sind, um eine optimale Netzwerkstruktur sicherzustellen. (Charette 2024d) (Charette 2024e) (Charette 2024f)

Bei den Dateien für das Training wird unter anderem ein Shellskript von DarkMark erzeugt, welches das Training des Modells durchführt. Dieses heißt in diesem Fall „kitz_train.sh“. Nachdem dieses Skript erfolgreich durchgelaufen ist, kann mithilfe von Darknet eine Vorhersage mit dem trainierten YOLO-Modell gemacht werden (Kapitel 12.3).



Abbildung 16: Darknet Dateien erzeugen

12.3 Aufrufen von Darknet

Mit Darknet kann anschließend das trainierte YOLO-Modell aufgerufen werden, um einzelne Bilder beziehungsweise Videos zu verarbeiten.

Mit folgendem Befehl kann Darknet aufgerufen werden um ein Video auszuwerten:
„darknet detector demo kitz.data kitz.cfg kitz_final.weights -ext_output /home/alex/input.mp4“

Dabei sind „kitz.data“, „kitz.cfg“ und „kitz_final.weights“ die Informationen über das YOLO-Modell.

Eine Ausgabe dieses Befehls schaut folgendermaßen aus:

```
FPS:0.0      AVG_FPS:0.0
Objects:
kitz: 45%    (left_x: 974  top_y: 511  width: 15  height: 31)
FPS:3.8      AVG_FPS:0.0
Objects:
kitz: 45%    (left_x: 974  top_y: 511  width: 15  height: 31)
FPS:5.5      AVG_FPS:0.0
Objects:
kitz: 46%    (left_x: 974  top_y: 511  width: 15  height: 31)
```

Abbildung 17: Ausgabe von Darknet

Dabei werden die Bilder pro Sekunde, die Verarbeitet werden angezeigt. Sobald ein Objekt erkannt wurde, wird das passende Label angezeigt und die Wahrscheinlichkeit, mit der die Detektion stimmt. Zusätzlich wird noch die Bounding Box ausgegeben. Zusätzlich wird noch eine Video-Anzeige gestartet, mit der man die Auswertung des aktuellen Bildes sieht:

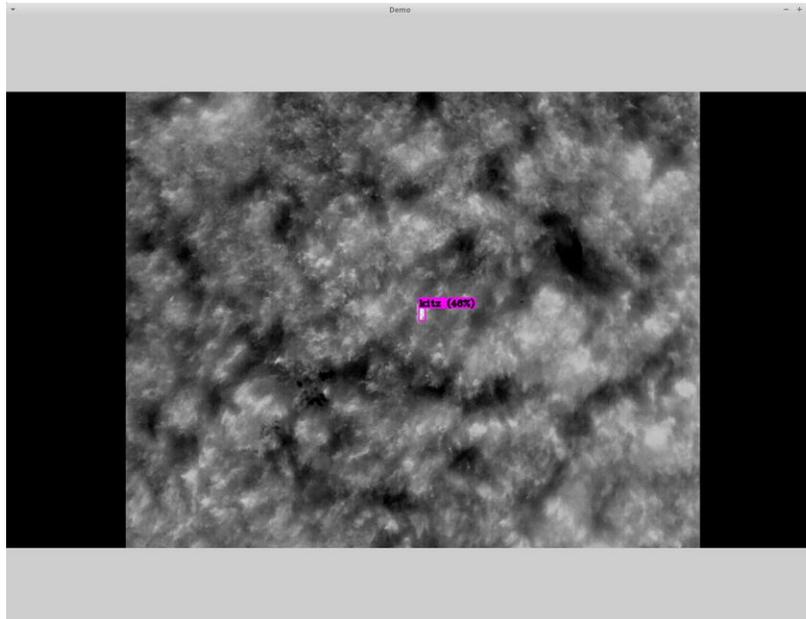


Abbildung 18: Videoanzeige von Darknet

Diese Anzeige zeigt die Echtzeit-Auswertung von Darknet und kann nicht pausiert werden. Daher wurde im Zuge dieser Arbeit entschieden eine zusätzliche Anwendung zu entwickeln, welche die Ausgabe von Darknet als Eingabe nimmt, um selbst das Video anzuzeigen und die Funktionalitäten wie in Kapitel 11 beschrieben zur Verfügung stellt.

Für die spätere Verarbeitung der Ausgabe von Darknet wäre es nötig die aktuelle Zeit des Videos zum erkannten Objekt zu wissen. Mit der Standardausgabe erfährt man zwar, dass ein Objekt erkannt wurde und die Pixelkoordinaten davon. Jedoch erhält man keine Information darüber, wann im Video dies ist.

Daher wurde der Python-Wrapper von Bochkovskiy et al. modifiziert, um eine Ausgabe des Zeitpunktes zu jedem erkannten Objekt zu erhalten. (Bochkovskiy et al. 2023)

```
Objects:
kitz: 50.26% (left_x: 198 top_y: 170 width: 16 height: 21)
Current Time (ms): 2702.7000000000003
Current Frame: 82.0
Processed Frames: 82
FPS: 21

Objects:
kitz: 49.15% (left_x: 199 top_y: 170 width: 16 height: 21)
Current Time (ms): 2736.0666666666667
Current Frame: 83.0
Processed Frames: 83
FPS: 19

Objects:
kitz: 47.52% (left_x: 198 top_y: 170 width: 16 height: 21)
Current Time (ms): 2769.4333333333334
Current Frame: 84.0
Processed Frames: 84
FPS: 17
```

Abbildung 19: Modifizierte Ausgabe

Durch die zusätzliche Ausgabe der Zeit im Video ist es nun möglich mit dieser Ausgabe die Auswertung von Darknet in einer zusätzlichen Anwendung zu visualisieren.

12.4 Grafische Desktopanwendung

Im Zuge dieser Arbeit wurde eine grafische Desktopanwendung mithilfe von JavaFX entwickelt. JavaFX ist eine Open-Source-Plattform für Client-Anwendungen auf Desktop-, Mobil- und eingebetteten Systemen, die auf Java basiert (Gluon 2024). Diese Anwendung ruft den modifizierten Python-Wrapper auf und verarbeitet anschließend die Ausgabe, um sie in einer benutzerfreundlichen Weise darzustellen. Durch diese Anwendung soll eine praktische Anwendung von künstlicher Intelligenz zur Rehkitzrettung geboten werden. Der Quellcode der Anwendung wird in einem privaten GitLab-Repository gehostet.

12.4.1 Aufbau der Anwendung

Nach dem Starten des Prototypen müssen das Video und die dazugehörigen Untertitel ausgewählt werden.

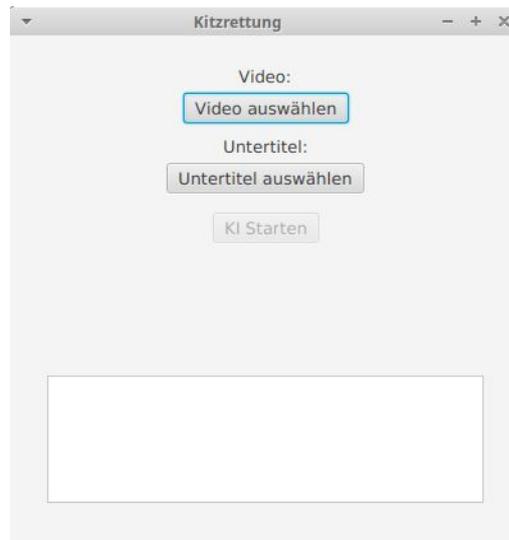


Abbildung 20: Startbildschirm

Nachdem die zwei Dateien ausgewählt wurden, kann die KI gestartet werden. Dabei wird im unteren Fenster die Ausgabe dieser angezeigt.

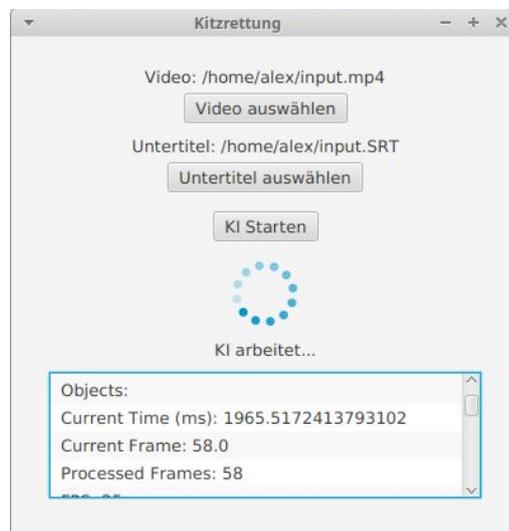


Abbildung 21: KI arbeitet im Hintergrund

Nach Abschluss der Verarbeitung durch die künstliche Intelligenz wird ein neues Fenster geöffnet, in dem das Video angezeigt wird. Alle erkannten Objekte werden mit

einer Bounding Box markiert und die Klassifizierung wird angezeigt. Das Video kann jederzeit angehalten werden. Über den Zeitstrahl unter dem Video, wird mit einem roten Balken markiert, wann ein Objekt im Video erkannt wurde. So kann die benutzende Person auf einen Blick erkennen, wann im Video eine Wärmequelle detektiert wurde. Durch Anklicken eines Punktes im Zeitstrahl wird zu diesem Zeitpunkt im Video gesprungen.



Abbildung 22: Anzeige des Videos

Sobald eine Bounding Box im Video angeklickt wird, wird auf der linken Seite angezeigt, wie das dazugehörige Objekt klassifiziert wurde. Zusätzlich wird die Wahrscheinlichkeit angezeigt, mit der diese Klassifizierung laut der KI stimmt.

Des Weiteren werden die berechneten Koordinaten der Wärmequelle als Längen- und Breitengrad angezeigt.

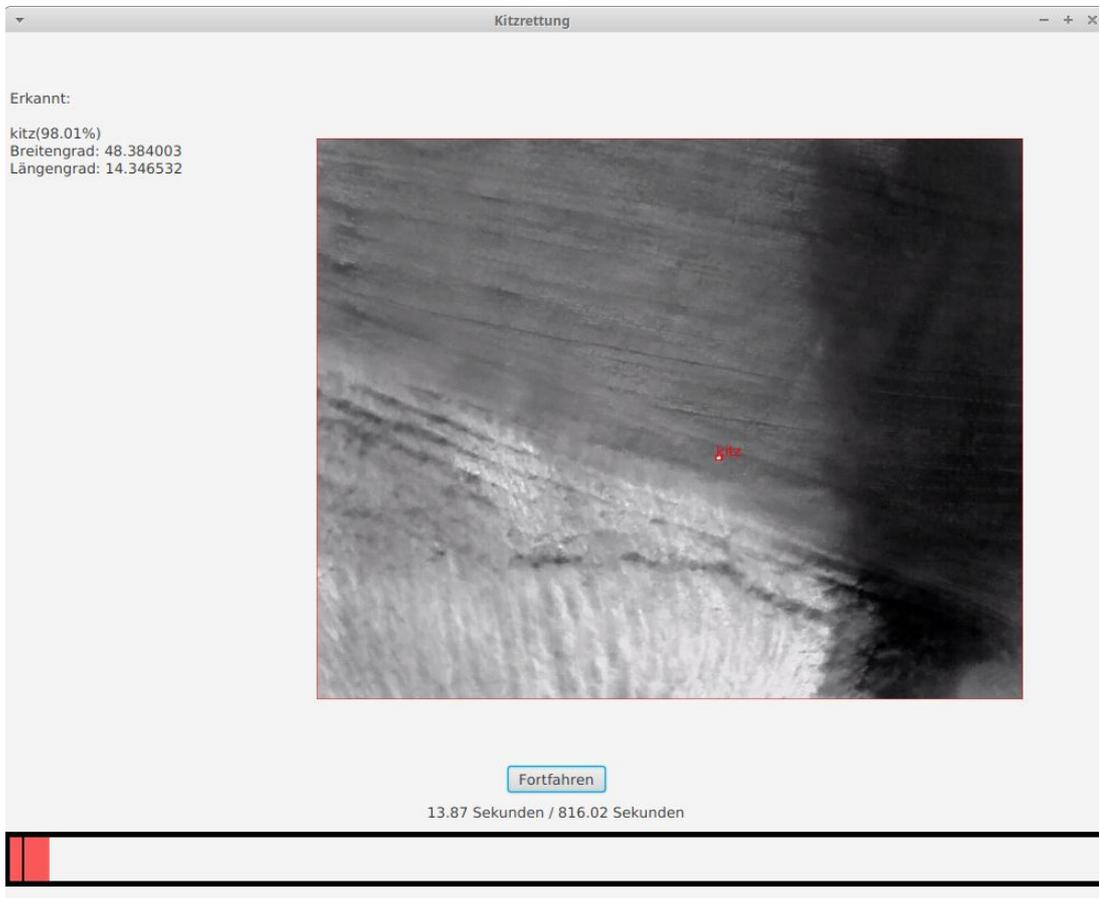


Abbildung 23: Auswahl einer Bounding Box

12.5 Berechnung der Koordinaten der erkannten Objekte

Die Berechnung der geografischen Koordinaten der erkannten Objekte geht von der Annahme aus, dass die Aufnahmen gemacht wurden, wenn die Kamera direkt 90° nach unten zeigt.

Es wird auch davon ausgegangen, dass die Koordinaten der Drohne am unteren mittleren Bildrand sind.

Folgende Daten stehen in den Metadaten der Drohnenaufnahmen zur Verfügung:

1. Die Rotation um die vertikale Achse (Yaw) der Drohne in Grad
2. Die Flughöhe der Drohne in Meter
3. Das Sichtfeld der Kamera in Grad

4. Die Auflösung des Bildes
5. Die Pixelkoordinaten im Bild des Punktes, der berechnet werden soll
6. Die geografischen Koordinaten der Drohne.

Beim Yaw handelt es sich um die Rotation der Drohne um die vertikale Achse. Damit kann bestimmt werden, in welche Himmelsrichtung die Drohne blickt. In der folgenden Grafik entspricht der Winkel α dem Yaw.

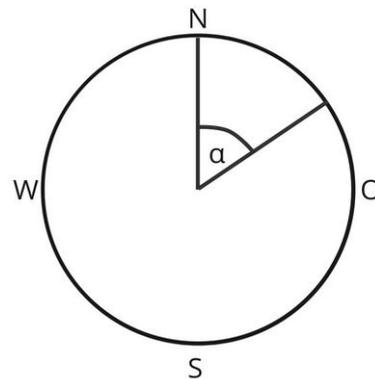


Abbildung 24: Yaw (α)

12.5.1 Objekt im Bild ermitteln

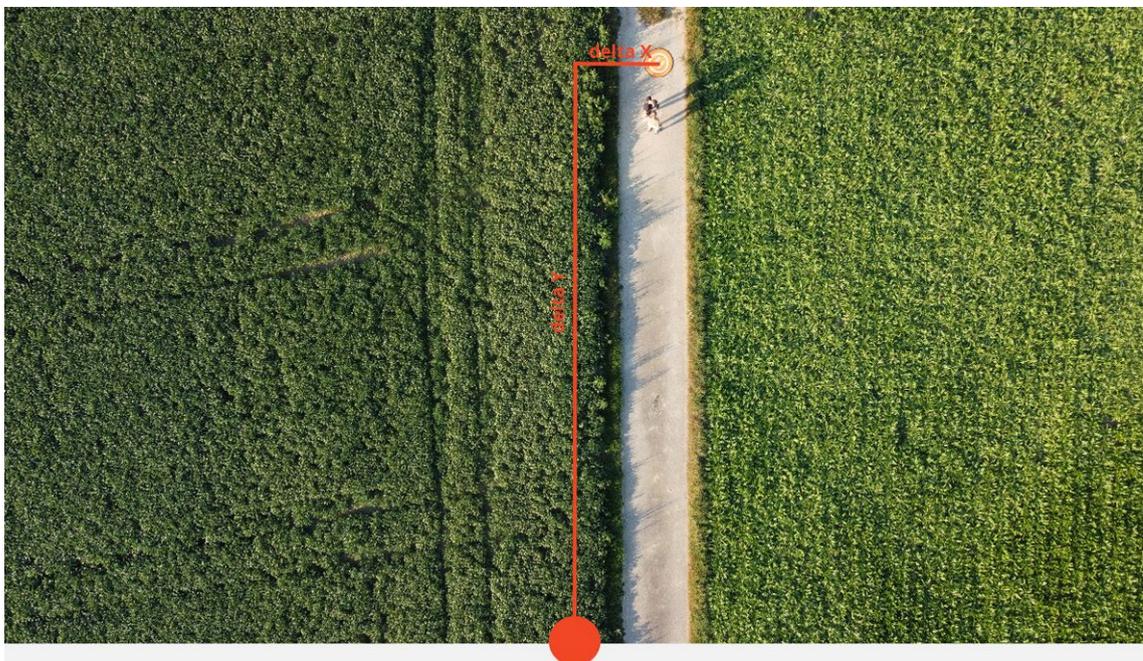


Abbildung 25: Testbild zur Berechnung der geografischen Koordinaten

Als Testbild dient diese Aufnahme. Die geografischen Koordinaten des orangenen Kreises sind zu ermitteln. Die Drohne hat die Position des roten Punktes im Bild.

Im ersten Schritt wird sich delta X und delta Y berechnet. Dabei handelt es sich um die Differenz der Pixelkoordinaten im Bild zwischen der Drohne und dem zu ermittelnden Objekt.

Die beiden Delta-Werte werden anschließend mit den Metern pro Pixel multipliziert, um die genaue Distanz zwischen der Drohne und dem Punkt zu ermitteln.

12.5.2 Berechnung wie viele Meter einem Pixel im Bild entsprechen

Mithilfe der Höhe der Drohne und des Sichtfelds der Kamera lässt sich berechnen, wie viele Meter einem Pixel im Bild entsprechen.

Dafür wird das Sichtfeld halbiert, um einen rechten Winkel zu erhalten und mithilfe des Tangens und der Höhe der Drohne kann anschließend berechnet werden, wie weit das Halbe Sichtfeld in Metern sehen kann (n). Damit lässt sich dann die Sehweite in Meter für das komplette Sichtfeld ermitteln (m). Durch Division der Sehweite durch die Breite des Bildes lässt sich berechnen, wie viele Meter einem Pixel entsprechen.

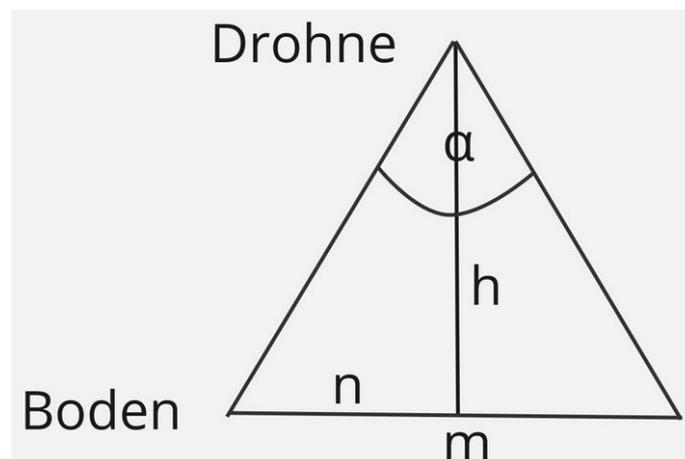


Abbildung 26: Höhe der Drohne (h), Sehweite (m), Halbe Sehweite (n), Sichtfeld (α)

12.5.3 Rotation des Punktes

Nun wird der ermittelte Punkt um das Yaw rotiert. Dafür wird folgende Formel verwendet:

$$x_{rotiert} = x * \cos(\alpha) - y * \sin(\alpha)$$

$$y_{rotiert} = x * \sin(\alpha) + y * \cos(\alpha)$$

12.5.4 Berechnung der geografischen Koordinaten

Für die finale Berechnung der geografischen Koordinaten des zu erkennenden Objektes, wird die Änderung des Breitengrades und des Längengrades berechnet.

Da alle Breitengrade die gleiche Breite aufweisen, muss dafür lediglich x_{rotiert} durch den Radius der Erde dividiert werden.

Die Entfernung zwischen den Längengraden nimmt mit zunehmendem Abstand zum Äquator ab, weshalb für die Berechnung vom Längengrad der Breitengrad berücksichtigt werden muss.

Die Berechnungen dafür schauen wie folgt aus:

$$\text{Abweichung}_{\text{Breitengrad}} = y_{\text{rotiert}} / \text{Erdradius}$$

$$\text{Abweichung}_{\text{Längengrad}} = x_{\text{rotiert}} / (\text{Erdradius} * \cos(\text{Längengrad}_{\text{Drohne}}))$$

Anschließend werden diese Winkelabweichungen mit den aktuellen Koordinaten der Drohne addiert.

12.5.5 Finaler Algorithmus in Java

```
/**
 *
 * @param droneLat Breitengrad der Drohne
 * @param droneLon Längengrad der Drohne
 * @param droneYaw Yaw der Drohne in Grad
 * @param droneHeight Höhe der Drohne in Meter
 * @param imageWidth Breite des Bildes in Pixel
 * @param imageHeight Höhe des Bildes in Pixel
 * @param fov Sichtfeld der Kamera in Grad
 * @param pointX Pixelkoordinate in X-Richtung des Punktes, dessen geografische Koordinaten berechnet werden sollen
 * @param pointY Pixelkoordinate in Y-Richtung des Punktes, dessen geografische Koordinaten berechnet werden sollen
 * @return Array mit dem Breiten- und Längengrad des Punktes
 */
public static double[] calculateGeoLocation(double droneLat, double droneLon, double droneYaw, 1 usage ± Alexander Pichle
    double droneHeight, double imageWidth, double imageHeight,
    double fov, double pointX, double pointY) {

    // Berechnung der Entfernung des zu berechnenden Punktes im Bild
    double deltaX = (pointX - imageWidth / 2);
    double deltaY = (imageHeight - pointY);

    // Berechnung der Meter pro Pixel
    double groundDistance = 2 * droneHeight * Math.tan(Math.toRadians(fov / 2));
    double metersPerPixel = groundDistance / imageWidth;

    // Berechnung der Entfernung des Punktes zur Drohne in Meter
    double meterX = deltaX * metersPerPixel;
    double meterY = deltaY * metersPerPixel;

    // Rotieren des Punktes basierend auf dem Yaw
    double rotatedX = meterX * Math.cos(Math.toRadians(droneYaw)) - meterY * Math.sin(Math.toRadians(droneYaw));
    double rotatedY = meterY * Math.sin(Math.toRadians(droneYaw)) + meterX * Math.cos(Math.toRadians(droneYaw));

    // Berechnung der Abweichung zum Längengrad und Breitengrad
    double earthRadius = 6378137; // Erdradius in Metern
    double dLat = rotatedY / earthRadius;
    double dLon = rotatedX / (earthRadius * Math.cos(Math.toRadians(droneLat)));

    // Berechnung der finalen geografischen Koordinaten
    double pointLat = droneLat + Math.toDegrees(dLat);
    double pointLon = droneLon + Math.toDegrees(dLon);

    return new double[]{pointLat, pointLon};
}
```

Abbildung 27: Berechnung der geografischen Koordinaten in Java

13. Durchführung des Experiments

Im Rahmen des Experiments wurden zwei Videos erstellt, welche mehrere Ausschnitte der zur Verfügung gestellten Aufnahmen enthalten. Die beiden Videos zeigen exakt dasselbe, jedoch einmal aus der Perspektive der Wärmebildkamera und einmal aus der Perspektive der Tageslichtkamera. Diese Videos sind jeweils 13:36 Minuten lang und zeigen acht Rehkitze, drei Rehe und vier Hasen.

Für die Versuchspersonen soll ein Drohnenflug mithilfe einer Webanwendung simuliert werden, in der die beiden Videos angezeigt werden.

13.1 Ermittlung der Daten der künstlichen Intelligenz

Mithilfe der grafischen Desktopanwendung des Prototypen wurde das Wärmebildvideo des Experiments durch das trainierte YOLO-Modell ausgewertet. Durch das Anzeigen der einzelnen erkannten Wärmequellen im Video konnte genau ermittelt werden, wann ein Objekt zum ersten Mal erkannt wurde. Zusätzlich konnte damit auch bestimmt werden, wie die jeweilige Wärmequelle durch das trainierte YOLO-Modell klassifiziert wurde.

13.2 Ermittlung der Daten der Versuchspersonen

Um den Testpersonen jeweils die gleichen Bedingungen zu bieten und eine einfache Möglichkeit zu haben, die Ergebnisse später auszuwerten, wurde eine Web-basierte App mithilfe von Angular entwickelt. Angular ist ein von Google entwickeltes Open-Source-Framework für die Erstellung von dynamischen Webanwendungen (Google 2024).

13.2.1 Auswahl der Versuchspersonen und Einschulung

Die Auswahl der Versuchspersonen erfolgte nach folgenden Kriterien: Sie sollten grundlegende Kenntnisse im Umgang mit Drohnen sowie technische Kenntnisse zur effizienten Nutzung der Web-App aufweisen. Darüber hinaus wird eine gute visuelle Wahrnehmung vorausgesetzt, um Wärmequellen auf den Drohnenaufnahmen zuverlässig zu erkennen. Zudem wird Erfahrung in der Landwirtschaft oder mit Wildtieren erwartet, da dies ein besseres Verständnis für das Verhalten von Wildtieren und die Umgebung bietet, was die Erkennung von Rehkitzen erleichtert.

Den Versuchspersonen wurde eine ausführliche und präzise Einschulung in die Verwendung der Webanwendung gegeben, um potenzielle Fehlerquellen zu minimieren.

13.2.2 Verwendung der Webanwendung

Beim Öffnen der Web-App wird ein Button zum Starten des Versuchs angezeigt.

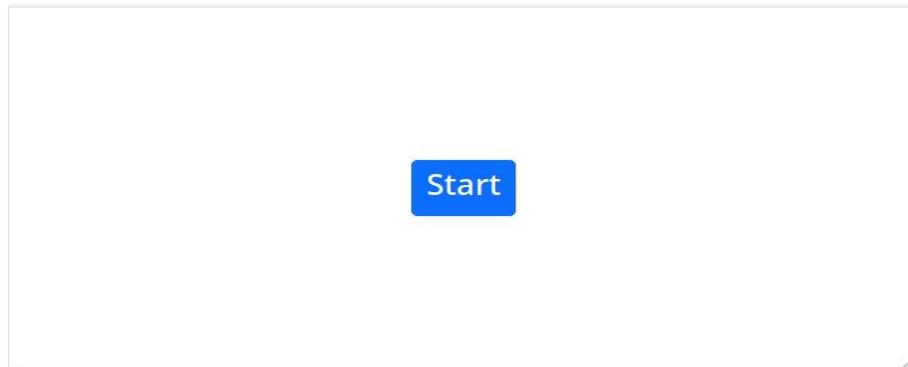


Abbildung 28: Startbildschirm der Webanwendung

Nachdem auf „Start“ geklickt wurde, startet der Versuch. Dabei wird zur nächsten Ansicht gewechselt und das Wärmebildvideo abgespielt. Im Hintergrund wird automatisch eine Stoppuhr gestartet, die die Gesamtzeit des Versuchs misst.



Abbildung 29: Starten des Versuchs

Sobald ein Objekt erkannt wurde, soll die Testperson auf „Erkannt“ klicken. Dadurch wird im Hintergrund abgespeichert, dass zu diesem Zeitpunkt ein Objekt erkannt wurde. Anschließend wird am oberen Bildschirmrand angezeigt, wie viele Objekte insgesamt bereits erkannt wurden und wie viele Objekte der einzelnen Kategorien erkannt wurden.

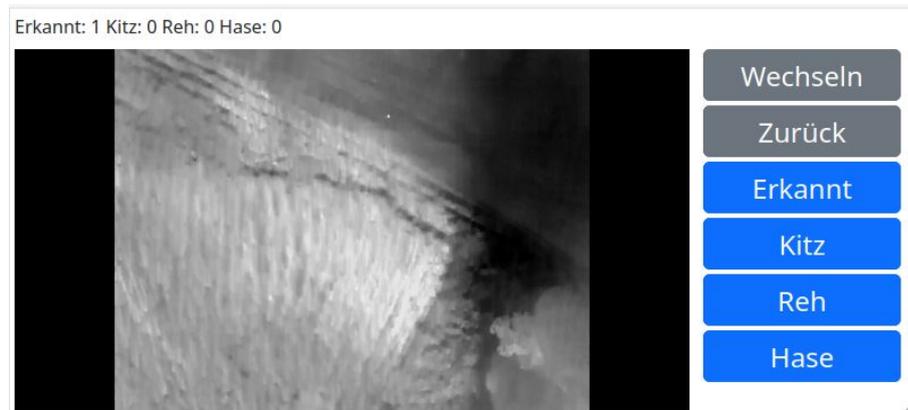


Abbildung 30: Objekt erkannt

Wenn auf „Kitz“, „Reh“ oder „Hase“ geklickt wird, wird der jeweilige Zähler erhöht und im Hintergrund abgespeichert, dass zu diesem Zeitpunkt ein Objekt klassifiziert wurde.

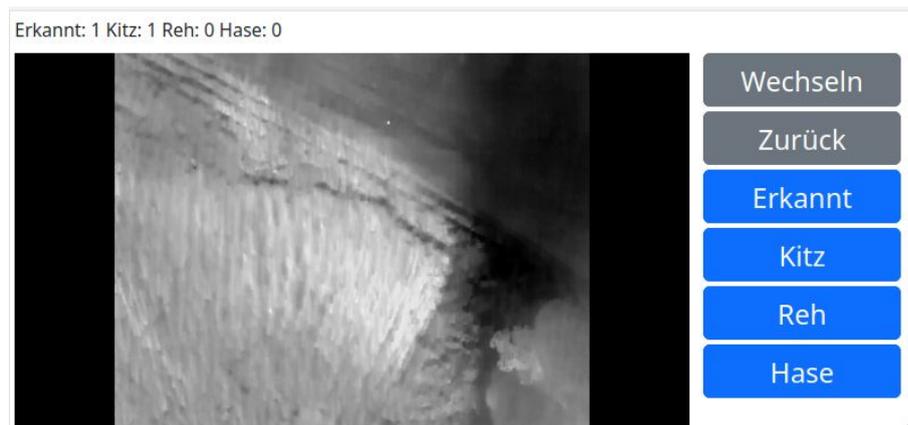


Abbildung 31: Objekt klassifiziert

Sobald auf die Videoanzeige geklickt wird, wird das Video pausiert. Nach erneutem Anklicken wird es fortgesetzt. Durch Drücken auf „Zurück“, springt das Video um 10 Sekunden zurück. Durch das Klicken auf „Wechseln“ wird zwischen der Wärmebildkamera und der Tageslichtkamera gewechselt.

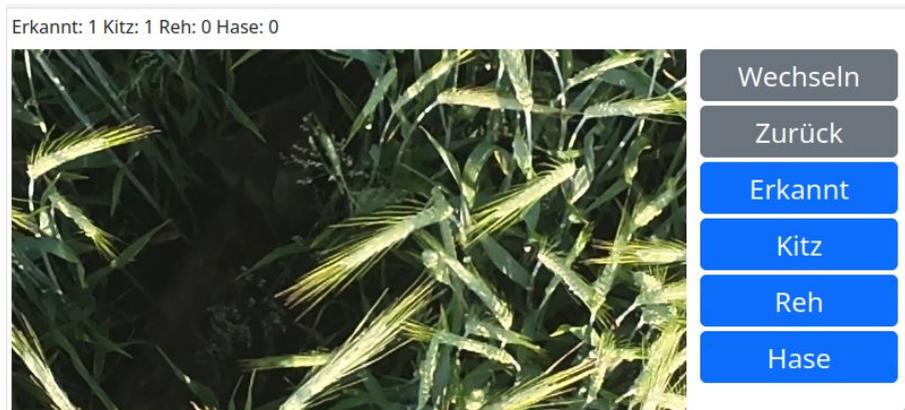


Abbildung 32: Wechsel auf die Tageslichtkamera. Das Objekt von Abbildung 31 ist aus der Nähe zu erkennen und kann als Kitz identifiziert werden.

Am Ende des Videos wird eine Übersicht mit den Ergebnissen angezeigt. Diese werden als JSON angezeigt, damit die Daten für den folgenden Vergleich einfacher aufbereitet werden können.



Abbildung 33: Abgeschlossener Versuch: Es wurden insgesamt 19 Objekte erkannt. Davon konnten 12 durch die Testperson klassifiziert werden.

13.2.3 Ergebnis der Webanwendung

In der Auswertung gibt es ein Array namens „foundLabels“, das alle Aktionen der Testperson abbildet. Für jedes Element dieses Arrays werden zwei Zeitstempel gespeichert: „foundVideoTimeSec“ und „foundTotalTimeSec“. Der erste Zeitstempel gibt die Zeit im Video an; der Zweite die Gesamtzeit. Dadurch kann jederzeit nachvollzogen werden, wo sich die Testperson zu einem bestimmten Zeitpunkt im Video befand, auch wenn das Video pausiert wurde.

Sobald eine der vier Optionen „Erkannt“, „Kitz“, „Reh“ oder „Hase“ ausgewählt wurde, wird dies im Feld „label“ gespeichert. So kann nachverfolgt werden, ob und wie ein Objekt zu einem bestimmten Zeitpunkt erkannt oder klassifiziert wurde.

Das Feld „thermalActive“ gibt an, ob die Wärmebild- oder die Tageslichtkamera aktiv ist. Die Felder „paused“ und „started“ zeigen, ob das Video gerade pausiert oder fortgesetzt wurde. Das Feld „totalTimesPaused“ zählt, wie oft das Video pausiert wurde. „totalTimesSwitched“ zählt, wie oft zwischen der Wärmebild- und der Tageslichtkamera gewechselt wurde. Schließlich gibt das Feld „totalMilliseconds“ an, wie viel Zeit die Testperson insgesamt für den Versuch benötigt hat.

```
1  {
2    "foundLabels": [
3      {
4        "label": "Erkannt",
5        "foundVideoTimeSec": 9.489416,
6        "foundTotalTimeSec": 9.489416,
7        "paused": false,
8        "started": false,
9        "thermalActive": true
10     },
11     {
12       "label": "Kitz",
13       "foundVideoTimeSec": 37.693455,
14       "foundTotalTimeSec": 37.693455,
15       "paused": false,
16       "started": false,
17       "thermalActive": false
18     },
19     {
20       "foundVideoTimeSec": 50.777705,
21       "foundTotalTimeSec": 50.777705,
22       "paused": true,
23       "started": false,
24       "thermalActive": false
25     },
26     {
27       "paused": false,
28       "started": true,
29       "thermalActive": false
30     },
31     {
32       "label": "Erkannt",
33       "foundVideoTimeSec": 194.087475,
34       "foundTotalTimeSec": 209.722,
35       "paused": false,
36       "started": false,
37       "thermalActive": true
38     }
39   ],
40   "totalTimesPaused": 1,
41   "totalTimesSwitched": 5,
42   "totalMilliseconds": 210000
43 }
```

Abbildung 34: Ergebnis eines Versuchs

14. Auswertung der Ergebnisse

14.1 Ergebnis des Prototypen

Die Zeitdifferenz wurde anhand des Zeitpunkts im Video, als das jeweilige Objekt erstmals sichtbar war, und des Zeitpunkts, als es erstmals von der KI erkannt wurde, berechnet. War ein Objekt nicht erkennbar, wurde der Durchschnittswert aller anderen Zeitdifferenzen herangezogen.

Die Detektionsrate wurde als richtig oder falsch klassifiziert. Eine Erkennung wurde als richtig gewertet, wenn sie in mehr als 50 Prozent der Fälle korrekt war, andernfalls wurde sie als falsch eingestuft. Zusätzlich zu den Werten in Tabelle 1 erkannte der Prototyp acht weitere Wärmequellen, die nicht den Kategorien Hase, Reh und Kitz angehören, jedoch als eine dieser klassifiziert wurden. Des Weiteren wurde ein Objekt nicht erkannt. Für dieses wurde die Durchschnittszeit der anderen Erkennungen genommen.

	Zeitdifferenz (Sekunden)	Erkennung
1	0,00	Richtig
2	0,00	Falsch
3	7,72	Falsch
4	0,32	Falsch
5	0,00	Falsch
6	1,08	Falsch
7	0,16	Richtig
8	0,89	Falsch
9	0,44	Richtig
10	0,00	Falsch
11	0,00	Richtig
12	0,00	Richtig
13	0,00	Falsch
14	1,08	Richtig
15	1,72	Richtig

Tabelle 1: Ergebnis des Prototypen

14.2 Ergebnis der Versuchspersonen

Zwölf Versuchspersonen führten die manuelle Auswertung durch. Aus all diesen Ergebnissen wurde die durchschnittliche Zeitdifferenz berechnet. Auch hier wurde, falls ein Objekt nicht erkannt wurde, die mittlere Zeitdifferenz aller anderen Werte dieser Person gewählt.

Die Erkennung wurde ebenfalls als richtig oder falsch gewertet. Ein Objekt galt als richtig erkannt, wenn es von mindestens 50% der Versuchspersonen korrekt klassifiziert wurde.

Zusätzlich zu den Werten in Tabelle 2 erkannten die Versuchspersonen im Durchschnitt 1,5 weitere Wärmequellen, die nicht den Kategorien Hase, Reh und Kitz angehören, aber als solche klassifiziert wurden.

	Zeitdifferenz (Sekunden)	Erkennung
1	1,30	Richtig
2	3,01	Richtig
3	2,68	Richtig
4	7,16	Richtig
5	4,91	Richtig
6	1,95	Richtig
7	1,49	Richtig
8	1,69	Falsch
9	2,31	Falsch
10	2,27	Richtig
11	1,80	Falsch
12	1,88	Falsch
13	1,48	Richtig
14	2,54	Richtig
15	1,87	Richtig

Tabelle 2: Ergebnis der Versuchspersonen

14.3 Vergleich der Detektionsraten

Der Vergleich dieser Daten ergibt für den Prototypen eine Detektionsrate von 46,67%. Zusätzlich wurden 53,33% mehr Objekte einer der drei Kategorien zugeordnet, obwohl sie nicht zu diesen Kategorien gehören.

Die manuelle Auswertung ergab eine Detektionsrate von 73,33%. Durch die Versuchspersonen wurden 12,5% mehr Objekte einer der drei Kategorien zugeordnet, obwohl sie nicht zu diesen Kategorien gehören.

Die Versuchspersonen erkannten insgesamt mehr Wärmequellen korrekt und hatten eine niedrigere Rate an falsch-positiven Erkennungen.

Die Analyse der erhobenen Daten zeigt, dass der Prototyp im Vergleich zur manuellen Auswertung eine geringere Detektionsrate aufweist. Der Prototyp hat insgesamt weniger Objekte korrekt klassifiziert und zusätzlich mehr Objekte erkannt, die nicht zu den Zielkategorien gehören.

14.4 Vergleich der Auffindungszeiten

Zur Untersuchung der Auffindungszeiten wurde ein einseitiger Mann-Whitney-U-Test durchgeführt. Zur Durchführung des Signifikanztests wurde Python verwendet. Die Hypothesen lauteten wie folgt:

1. Nullhypothese H_0 : Die Auffindungszeiten der KI-gestützten Methode sind nicht signifikant kürzer als die der manuellen Auswertung.
2. Alternativhypothese H_1 : Die Auffindungszeiten der KI-gestützten Methode sind signifikant kürzer als die der manuellen Auswertung.

Der p-Wert des Mann-Whitney-U-Tests betrug 0,0000518. Da dieser Wert kleiner als das gewählte Signifikanzniveau von 0,05 ist, wird die Nullhypothese abgelehnt.

Daraus lässt sich schließen, dass es durch ein KI-unterstütztes Verfahren zur Bilderkennung zu einer signifikanten Verringerung der Zeit für das Auffinden von Wärmequellen kommt.

```

import scipy.stats as stats

ai_times = [
    0.00,
    0.00,
    7.72,
    0.32,
    0.00,
    1.08,
    0.16,
    0.89,
    0.44,
    0.00,
    0.00,
    0.00,
    0.00,
    1.08,
    1.72
]

human_times = [
    1.30,
    3.01,
    2.68,
    7.16,
    4.91,
    1.95,
    1.49,
    1.69,
    2.31,
    2.27,
    1.80,
    1.88,
    1.48,
    2.54,
    1.87
]

result = stats.mannwhitneyu(ai_times, human_times, alternative='less')

print(f'Mann-Whitney-U-Test: p-Wert={result.pvalue}')

```

Abbildung 35: Python-Skript zur Durchführung des Mann-Whitney-U-Tests

15. Beantwortung der Forschungsfrage

Die Forschungsfrage lautet: „Kommt es durch ein KI-unterstütztes Verfahren zur Bilderkennung zu einer signifikanten Verringerung der Zeit für das Auffinden von Rehkitzen bei gleichbleibender Detektionsrate gegenüber der herkömmlichen Methode?“

Basierend auf der Analyse der im Zuge dieser wissenschaftlichen Arbeit erhobenen Daten, konnte mit Hilfe eines Signifikanztests nachgewiesen werden, dass die KI-gestützte Methode zu einer signifikanten Verringerung der Auffindungszeit führt. Jedoch bietet der Prototyp des YOLO-Modells keine gleichbleibende Detektionsrate im Vergleich zur herkömmlichen Methode. Die Detektionsrate des Prototypen war niedriger als die der manuellen Auswertung. Außerdem wurden mehr Objekte als falsch-positiv erkannt.

Ein entscheidender Faktor für die geringere Detektionsrate des KI-unterstützten Verfahrens könnte der kleine Trainingsdatensatz sein. Der Datensatz enthält möglicherweise nicht genügend Variationen und repräsentative Beispiele, was die Fähigkeit des Modells, generalisierbare Muster zu erkennen, erheblich einschränkt. Ein größerer und vielfältigerer Datensatz könnte helfen, die Genauigkeit zu verbessern.

Die Testergebnisse basieren auf Aufnahmen aus einer Flughöhe von 40 bis 80 Metern, was dazu führt, dass Rehkitze bei einer Auflösung von 640x512 Pixeln oft weniger als 10x10 Pixel groß sind. Dadurch ist der Detailgrad gering, was sich negativ auf die Detektionsrate auswirkt.

Darüber hinaus wurde bei der manuellen Bewertung durch Menschen die Erkennungsrate mit einer relativ kleinen Stichprobe von nur zwölf Testpersonen durchgeführt.

16. Beantwortung der Hypothese

Die Hypothese lautet: „Durch ein KI-unterstütztes Verfahren zur Bilderkennung kommt es bei gleichbleibender Detektionsrate gegenüber der herkömmlichen Methode zu einer signifikanten Verringerung der Zeit für das Auffinden von Rehkritzen.“

Die Hypothese konnte nur teilweise bestätigt werden. Während die KI-gestützte Methode tatsächlich zu einer signifikanten Verringerung der Auffindungszeit führte, war jedoch die Detektionsrate des Prototypen im Vergleich zur manuellen Auswertung niedriger. Der Prototyp klassifizierte weniger Objekte korrekt und führte außerdem zu mehr falsch-positiven Erkennungen.

17. Ausblick

Der im Zuge dieser wissenschaftlichen Arbeit entwickelte Prototyp des YOLO-Modells ist aufgrund der geringen Detektionsrate nicht praktikabel für die nachträgliche Auswertung von Wärmebildvideos. Durch die geringe Genauigkeit wäre ein erheblicher menschlicher Aufwand nötig, um die Wärmequellen im Anschluss richtig zu klassifizieren.

Eine mögliche Verbesserung der Detektionsrate könnte durch einen größeren Datensatz an Trainingsdaten erreicht werden. Darüber hinaus könnte auch eine geringere Flughöhe der Drohne eine entscheidende Rolle bei der Verbesserung der Detektionsrate spielen. Ein geringerer Abstand zur beobachteten Fläche würde den Detailgrad der aufgenommenen Wärmebilder erhöhen und damit eine bessere Unterscheidung einzelner Wärmequellen ermöglichen.

Eine alternative Anwendung des Prototypen könnte in der Echtzeitauswertung der Drohnenvideos bestehen, bei der erkannte Objekte während des Fluges angezeigt werden. Dies würde die drohnensteuernde Person bei der Erkennung unterstützen und die Wahrscheinlichkeit verringern, dass, insbesondere bei Ermüdung, Wärmequellen übersehen werden. Durch die Anzeige erkannter Objekte in Echtzeit könnten Bounding Boxes genutzt werden, um die Aufmerksamkeit auf relevante Bereiche zu lenken, wodurch die Effizienz und Genauigkeit der Kitzrettung erhöht werden könnte.

Anhang

Liste aller Wärmequellen im Video des Experiments:

	Erster Zeitpunkt der Sichtbarkeit im Video (Sekunden)	Letzter Zeitpunkt der Sichtbarkeit im Video (Sekunden)	Klassifizierung
1	8,00	118,68	Kitz
2	192,92	210,24	Hase
3	243,88	311,80	Reh
4	257,16	319,68	Reh
5	284,80	323,32	Reh
6	321,20	402,64	Kitz
7	425,96	460,36	Hase
8	476,32	482,68	Kitz
9	476,40	483,00	Kitz
10	501,08	586,88	Hase
11	595,12	637,84	Kitz
12	595,52	637,92	Kitz
13	654,68	679,52	Hase
14	734,32	816,04	Kitz
15	739,52	793,80	Kitz

Tabelle 3: Liste aller Wärmequellen im Video des Experiments

Ergebnis des Prototypen:

Zusätzlich zu diesen Objekten erkannte der Prototyp acht weitere Wärmequellen, die nicht zu den Kategorien Reh, Hase oder Kitz gehören, aber als solche klassifiziert wurden.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	8,00	0,00	Kitz
2	192,92	0,00	Kitz
3	251,60	7,72	Kitz
4	257,48	0,32	Kitz
5	284,80	0,00	Kitz
6	322,28	1,08	Hase
7	426,12	0,16	Hase
8			
9	476,84	0,44	Kitz
10	501,08	0,00	Kitz
11	595,12	0,00	Kitz
12	595,52	0,00	Kitz
13	654,68	0,00	Kitz
14	735,40	1,08	Kitz
15	741,24	1,72	Kitz

Tabelle 4: Ergebnis des Prototypen

Ergebnis der Versuchsperson 1:

Versuchsperson 1 erkannte keine weiteren Wärmequellen.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	8,67	0,67	Kitz
2	194,00	1,08	Hase
3	258,14	14,26	Reh
4	266,94	9,78	Reh
5	288,45	3,65	Reh
6	322,14	0,94	Kitz
7	427,55	1,59	Hase
8	478,04	1,72	Hase
9	478,49	2,09	Hase
10	502,77	1,69	Hase
11	596,40	1,28	Hase
12	596,94	1,42	Hase
13	655,54	0,86	Hase
14	738,70	4,38	Kitz
15	741,36	1,84	Kitz

Tabelle 5: Ergebnis der Versuchsperson 1

Ergebnis der Versuchsperson 2:

Zusätzlich zu diesen Objekten erkannte die Versuchsperson 2 zwei weitere Wärmequellen, die nicht zu den Kategorien Reh, Hase oder Kitz gehören, aber als solche klassifiziert wurden.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	10,03	2,03	Kitz
2	194,63	1,71	Hase
3	245,77	1,89	Reh
4	286,46	29,30	Reh
5	310,16	25,36	Reh
6	323,39	2,19	Kitz
7	427,38	1,42	Kitz
8	478,74	2,42	Hase
9	480,84	4,44	Hase
10	502,93	1,85	Hase
11	596,57	1,45	Hase
12	597,64	2,12	Hase
13	655,89	1,21	Hase
14	738,74	4,42	Kitz
15	741,92	2,40	Kitz

Tabelle 6: Ergebnis der Versuchsperson 2

Ergebnis der Versuchsperson 3:

Zusätzlich zu diesen Objekten erkannte die Versuchsperson 3 vier weitere Wärmequellen, die nicht zu den Kategorien Reh, Hase oder Kitz gehören, aber als solche klassifiziert wurden.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	9,49	1,49	Kitz
2	194,09	1,17	Hase
3	244,57	0,69	Reh
4	261,13	3,97	Reh
5	287,95	3,15	Reh
6	322,46	1,26	Kitz
7	426,98	1,02	Hase
8	478,04	1,72	
9	478,41	2,01	
10	502,58	1,50	Hase
11	596,52	1,40	
12	597,20	1,68	
13	655,63	0,95	Hase
14	738,85	4,53	Kitz
15	741,19	1,67	Kitz

Tabelle 7: Ergebnis der Versuchsperson 3

Ergebnis der Versuchsperson 4:

Zusätzlich zu diesen Objekten erkannte die Versuchsperson 4 drei weitere Wärmequellen, die nicht zu den Kategorien Reh, Hase oder Kitz gehören, aber als solche klassifiziert wurden.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	8,81	0,81	Kitz
2	199,41	6,49	Hase
3	244,35	0,47	Reh
4	260,94	3,78	Reh
5	289,38	4,58	
6	322,53	1,33	Hase
7	427,48	1,52	Kitz
8	477,53	1,21	Hase
9	478,05	1,65	Hase
10	504,58	3,50	Hase
11	596,94	1,82	Hase
12	597,42	1,90	Hase
13	655,45	0,77	Hase
14	737,54	3,22	Kitz
15	740,86	1,34	Kitz

Tabelle 8: Ergebnis der Versuchsperson 4

Ergebnis der Versuchsperson 5:

Zusätzlich zu diesen Objekten erkannte die Versuchsperson 5 zwei weitere Wärmequellen, die nicht zu den Kategorien Reh, Hase oder Kitz gehören, aber als solche klassifiziert wurden.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	9,95	1,95	Kitz
2	196,09	3,17	Hase
3	244,83	0,95	Reh
4	259,65	2,49	Reh
5	287,39	2,59	Reh
6	326,21	5,01	Kitz
7	427,35	1,39	Hase
8	477,42	1,10	Hase
9	477,90	1,50	Hase
10	503,25	2,17	Hase
11	597,22	2,10	Kitz
12	598,14	2,62	Kitz
13	656,45	1,77	Hase
14	736,70	2,38	Kitz
15	741,07	1,55	Kitz

Tabelle 9: Ergebnis der Versuchsperson 5

Ergebnis der Versuchsperson 6:

Versuchsperson 6 erkannte keine weiteren Wärmequellen.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	8,95	0,95	Kitz
2	198,09	5,17	Hase
3	245,83	1,95	Reh
4	260,65	3,49	Reh
5	287,39	2,59	Reh
6	322,21	1,01	Kitz
7	426,85	0,89	Hase
8	478,42	2,10	Hase
9	478,90	2,50	Hase
10	504,25	3,17	Hase
11	596,22	1,10	Hase
12	597,14	1,62	Hase
13	657,45	2,77	Hase
14	736,70	2,38	Kitz
15	741,07	1,55	Kitz

Tabelle 10: Ergebnis der Versuchsperson 6

Ergebnis der Versuchsperson 7:

Zusätzlich zu diesen Objekten erkannte die Versuchsperson 7 eine weitere Wärmequellen, die nicht zu den Kategorien Reh, Hase oder Kitz gehören, aber als solche klassifiziert wurden.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	9,15	1,15	Kitz
2	194,95	2,03	Hase
3	245,25	1,37	Reh
4	261,21	4,05	Reh
5	286,64	1,84	Reh
6	323,07	1,87	Kitz
7	427,40	1,44	Kitz
8	477,67	1,35	
9	478,33	1,93	
10	502,92	1,84	Hase
11	596,54	1,42	Hase
12	597,30	1,78	Hase
13	655,76	1,08	Hase
14	735,61	1,29	Kitz
15	740,92	1,40	Kitz

Tabelle 11: Ergebnis der Versuchsperson 7

Ergebnis der Versuchsperson 8:

Zusätzlich zu diesen Objekten erkannte die Versuchsperson 8 zwei weitere Wärmequellen, die nicht zu den Kategorien Reh, Hase oder Kitz gehören, aber als solche klassifiziert wurden.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	9,05	1,05	Kitz
2	196,52	3,60	Hase
3	245,54	1,66	Reh
4	263,43	6,27	Reh
5	287,51	2,71	Reh
6	322,64	1,44	Kitz
7	427,51	1,55	Hase
8	478,04	1,72	Hase
9	478,62	2,22	Hase
10	503,59	2,51	Hase
11	596,38	1,26	Hase
12	597,22	1,70	Hase
13	656,60	1,92	Hase
14	735,66	1,34	Kitz
15	741,49	1,97	Kitz

Tabelle 12: Ergebnis der Versuchsperson 8

Ergebnis der Versuchsperson 9:

Versuchsperson 9 erkannte keine weiteren Wärmequellen.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	9,32	1,32	Kitz
2	196,90	3,98	Hase
3	245,40	1,52	Reh
4	264,57	7,41	Reh
5	287,76	2,96	Reh
6	323,68	2,48	Kitz
7	427,92	1,96	Kitz
8	477,96	1,64	Hase
9	478,47	2,07	Hase
10	503,70	2,62	Hase
11	596,60	1,48	Hase
12	597,50	1,98	Hase
13	656,83	2,15	Hase
14	736,35	2,03	Kitz
15	742,88	3,36	Kitz

Tabelle 13: Ergebnis der Versuchsperson 9

Ergebnis der Versuchsperson 10:

Versuchsperson 10 erkannte keine weiteren Wärmequellen.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	9,40	1,40	Kitz
2	195,44	2,52	Hase
3	245,36	1,48	Reh
4	263,61	6,45	Reh
5	286,29	1,49	Reh
6	322,78	1,58	Kitz
7	428,85	2,89	Hase
8	478,22	1,90	Hase
9	479,12	2,72	Hase
10	503,17	2,09	Hase
11	596,46	1,34	Hase
12	597,32	1,80	Hase
13	656,18	1,50	Hase
14	735,72	1,40	Kitz
15	740,52	1,00	Kitz

Tabelle 14: Ergebnis der Versuchsperson 10

Ergebnis der Versuchsperson 11:

Zusätzlich zu diesen Objekten erkannte die Versuchsperson 11 drei weitere Wärmequellen, die nicht zu den Kategorien Reh, Hase oder Kitz gehören, aber als solche klassifiziert wurden.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	9,40	1,40	Kitz
2	195,70	2,78	Hase
3	248,64	4,76	Reh
4	260,42	3,26	Reh
5	290,59	5,79	Reh
6	323,48	2,28	Kitz
7	427,30	1,34	Kitz
8	478,15	1,83	Hase
9	479,03	2,63	Hase
10	503,30	2,22	Hase
11	600,67	5,55	
12	597,47	1,95	
13	656,33	1,65	Hase
14	735,96	1,64	Kitz
15	740,60	1,08	Kitz

Tabelle 15: Ergebnis der Versuchsperson 11

Ergebnis der Versuchsperson 12:

Zusätzlich zu diesen Objekten erkannte die Versuchsperson 12 eine weitere Wärmequellen, die nicht zu den Kategorien Reh, Hase oder Kitz gehören, aber als solche klassifiziert wurden.

	Zeitpunkt im Video (Sekunden)	Zeitdifferenz der ersten Sichtbarkeit im Video und der Erkennung (Sekunden)	Klassifizierung
1	9,44	1,44	Kitz
2	195,33	2,41	Hase
3	245,04	1,16	Reh
4	262,78	5,62	Reh
5	286,95	2,15	Reh
6	323,23	2,03	Kitz
7	426,85	0,89	Hase
8	477,85	1,53	Hase
9	478,37	1,97	Hase
10	503,09	2,01	Hase
11	596,58	1,46	Hase
12	597,45	1,93	Hase
13	655,82	1,14	Hase
14	735,78	1,46	Kitz
15	742,76	3,24	Kitz

Tabelle 16: Ergebnis der Versuchsperson 12

Literaturverzeichnis

- Armstrong, D. M. , Wilson, . Don E. and Jones, . J. Knox. „mammal“ Encyclopedia Britannica, Abgerufen am 21. Juni 2024.
<https://www.britannica.com/animal/mammal>.
- Gentry, A. William. „artiodactyl“ Encyclopedia Britannica, Abgerufen am 21. Juni 2024.
<https://www.britannica.com/animal/artiodactyl>.
- Etnyre, E.; J. Lande; A. Mckenna and J. Berini 2011. „Artiodactyla“ (On-line), Animal Diversity Web. Abgerufen am 23. Juni 2024.
<https://animaldiversity.org/accounts/Artiodactyla/>.
- Nicola S. Heckeberg. „A comprehensive approach towards the phylogeny and evolution of cervidae.“ (2017). <https://doi.org/10.7934/P1021>.
- Dr. Barbara Fiala-Köck, Dr. Harald Fötschl, Werner Ch. Leitner, Dr. Bruno Pflüger, und Mag. Benjamin Sartori. Der Lehrprinz. 7. Auflage. Wildon: Leitner&Partner Ges.b.R. (W. Ch. Leitner - Ch. Zweytik), 2019. ISBN 978-3-200-06371-6.
- Paul Herberstein und Hubert Zeiler, Rehwild Ansprechfibel, 2019, ISBN 978-3-85208-107-6.
- Martin Israel. "A UAV-BASED ROE DEER FAWN DETECTION SYSTEM." ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 3822 (2011): 51-55.
<https://doi.org/10.5194/ISPRSARCHIVES-XXXVIII-1-C22-51-2011>.
- Jan Cukor, J. Bartoska, Jan Rohla, Jan Sova and A. Machálek. „Use of aerial thermography to reduce mortality of roe deer fawns before harvest.“ PeerJ, 7 (2019). <https://doi.org/10.7717/peerj.6923>. (a)
- Cukor, J., Havránek, F., Vacek, Z., Bukovjan, K., Podrázský, V., & Sharma, R. (2019). Roe deer (*Capreolus capreolus*) mortality in relation to fodder harvest in agricultural landscape. *Mammalia*, 83, 461 - 469.
<https://doi.org/10.1515/MAMMALIA-2018-0002>. (b)
- Jarnemo, A. (2002). Roe deer *Capreolus capreolus* fawns and mowing - mortality rates and countermeasures. *Wildlife Biology*, 8, 211 - 218.
<https://doi.org/10.2981/wlb.2002.035>.
- Meyer, Adrian, Natalie Lack, und Denis Jordan. „Wildtier-Monitoring mit UAVs – Künstliche Intelligenz zur automatisierten Detektion von Infrarot-Signaturen.“ (Januar 2019).

- Mahesh, Batta. „Machine Learning Algorithms - A Review.“ International Journal of Science and Research (IJSR) 9 (Januar 2019).
<https://doi.org/10.21275/ART20203995>.
- Tim C. Kietzmann, Patrick McClure and Nikolaus Kriegeskorte. „Deep Neural Networks in Computational Neuroscience.“ Oxford Research Encyclopedia of Neuroscience (2019).
<https://doi.org/10.1093/ACREFORE/9780190264086.013.46>.
- Wang, Z., Turko, R., Shaikh, O., Park, H., Das, N., Hohman, F., Kahng, M., & Chau, D. (2020). CNN Explainer: Learning Convolutional Neural Networks with Interactive Visualization. IEEE Transactions on Visualization and Computer Graphics, 27, 1396-1406. <https://doi.org/10.1109/TVCG.2020.3030418>.
- Wikipedia. 2024 „Wärmebildkamera“. In: Wikipedia – Die freie Enzyklopädie. Bearbeitungsstand: 10. Mai 2024, Abgerufen am 13. Juli 2024.
<https://de.wikipedia.org/w/index.php?title=%C3%A4rmebildkamera&oldid=244842760> (a)
- Wikipedia. 2024 „Thermografie“. In: Wikipedia – Die freie Enzyklopädie. Bearbeitungsstand: 25. April 2024, Abgerufen am 13. Juli 2024.
<https://de.wikipedia.org/w/index.php?title=Thermografie&oldid=244384752> (b)
- Wikipedia. 2024 „Globales Navigationssatellitensystem“. In: Wikipedia – Die freie Enzyklopädie. Bearbeitungsstand: 26. Dezember 2023, Abgerufen am 13. Juli 2024.
https://de.wikipedia.org/w/index.php?title=Globales_Navigationssatellitensystem&oldid=240548506 (c)
- Wikipedia. 2024 „Global Positioning System“. In: Wikipedia – Die freie Enzyklopädie. Bearbeitungsstand: 22. Juni 2024, Abgerufen am 13. Juli 2024.
https://de.wikipedia.org/w/index.php?title=Global_Positioning_System&oldid=246115803 (d)
- Wikipedia. 2024 „GLONASS“. In: Wikipedia – Die freie Enzyklopädie. Bearbeitungsstand: 14. Juni 2024, Abgerufen am 13. Juli 2024.
<https://de.wikipedia.org/w/index.php?title=GLONASS&oldid=245912655> (e)
- Wikipedia. 2024 „Galileo (Satellitennavigation)“. In: Wikipedia – Die freie Enzyklopädie. Bearbeitungsstand: 6. Juli 2024, Abgerufen am 13. Juli 2024.
[https://de.wikipedia.org/w/index.php?title=Galileo_\(Satellitennavigation\)&oldid=246510728](https://de.wikipedia.org/w/index.php?title=Galileo_(Satellitennavigation)&oldid=246510728) (f)
- Wikipedia. 2024 „Beidou (Satellitennavigation)“. In: Wikipedia – Die freie Enzyklopädie. Bearbeitungsstand: 31. März 2024, Abgerufen am 13. Juli 2024.
[https://de.wikipedia.org/w/index.php?title=Beidou_\(Satellitennavigation\)&oldid=243601923](https://de.wikipedia.org/w/index.php?title=Beidou_(Satellitennavigation)&oldid=243601923) (g)

- Wikipedia. 2024 „Differential Global Positioning System“. In: Wikipedia – Die freie Enzyklopädie. Bearbeitungsstand: 23. Juni 2023, Abgerufen am 13. Juli 2024.
https://de.wikipedia.org/w/index.php?title=Differential_Global_Positioning_System&oldid=234850310 (h)
- Wikipedia. 2024 „Geographische Koordinaten“. In: Wikipedia – Die freie Enzyklopädie. Bearbeitungsstand: 2. Juni 2024, Abgerufen am 6. August 2024.
https://de.wikipedia.org/w/index.php?title=Geographische_Koordinaten&oldid=245557105 (i)
- Mingxing Tan, Ruoming Pang and Quoc V. Le. „EfficientDet: Scalable and Efficient Object Detection.“ 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) (2019): 10778-10787.
<https://doi.org/10.1109/cvpr42600.2020.01079>.
- Shaoqing Ren, Kaiming He, Ross B. Girshick and Jian Sun. „Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks.“ IEEE Transactions on Pattern Analysis and Machine Intelligence, 39 (2015): 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>.
- W. Liu, Dragomir Anguelov, D. Erhan, Christian Szegedy, Scott E. Reed, Cheng-Yang Fu and A. Berg. „SSD: Single Shot MultiBox Detector.“ (2015): 21-37.
https://doi.org/10.1007/978-3-319-46448-0_2.
- Joseph Redmon, S. Divvala, Ross B. Girshick and Ali Farhadi. „You Only Look Once: Unified, Real-Time Object Detection“ 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (2015): 779-788.
<https://doi.org/10.1109/CVPR.2016.91>.
- IBM. „Was ist künstliche Intelligenz (KI)?“ Abgerufen am 13. Juli 2024.
<https://www.ibm.com/de-de/topics/artificial-intelligence> (a)
- IBM „What is data labeling?“ Abgerufen am 13. Juli 2024.
<https://www.ibm.com/topics/data-labeling> (b)
- IBM „What is an AI model?“ Abgerufen am 13. Juli 2024.
<https://www.ibm.com/topics/ai-model> (c)
- Murphy, „What are foundation models?“ Abgerufen am 13. Juli 2024.
<https://research.ibm.com/blog/what-are-foundation-models>
- Joseph Redmon. 2013-2016 „Darknet: Open Source Neural Networks in C“ Abgerufen am 1. Juli 2024 <http://pjreddie.com/darknet/>
- Stéphane Charette 2024 „Darknet/YOLO FAQ“ Abgerufen am 13. Juli 2024.
https://www.coderun.ca/programming/darknet_faq/#what_is_darknet (a)

- Stéphane Charette 2019-2024 „DarkHelp“ Abgerufen am 13. Juli 2024.
<https://www.ccoderun.ca/DarkHelp/api/index.html>
- Stéphane Charette 2019-2023 „DarkMark“ Abgerufen am 13. Juli 2024.
<https://www.ccoderun.ca/DarkHelp/api/index.html>
- FPV Sports. „Was ist ein Quadrocopter?“ Abgerufen am 13. Juli 2024.
<https://fpvracing.ch/de/content/7-grundsatzliche-funktion-quadrocopter-multicopter>
- Alena Otto, Niels A. H. Agatz, James F. Campbell, B. Golden and E. Pesch.
"Optimization approaches for civil applications of unmanned aerial vehicles (UAVs) or aerial drones: A survey." Networks, 72 (2018): 411 - 58.
<https://doi.org/10.1002/net.21818>
- Maria-Theresa Oanh Hoang, N. V. Berkel, M. Skov and Timothy R. Merritt. "Challenges and Requirements in Multi-Drone Interfaces." Extended Abstracts of the 2023 CHI Conference on Human Factors in Computing Systems (2023).
<https://doi.org/10.1145/3544549.3585673>
- Nils Waldmann. 2019 „DJI OcuSync 2.0 / 3.0 / O3+ / O3 Pro / O4: Der ultimative OcuSync & Lightbridge Guide“ Abgerufen am 13. Juli 2024. <https://www.drone-zone.de/dji-ocusync-2-0-der-ultimative-ocusync-lightbridge-guide/>
- Alberto Rivas, P. Chamoso, Alfonso González-Briones and J. Corchado. „Detection of Cattle Using Drones and Convolutional Neural Networks.“ Sensors (Basel, Switzerland), 18 (2018). <https://doi.org/10.3390/s18072048>
- Evangeline Corcoran, Megan Winsen, Ashlee Sudholz and Grant Hamilton.
„Automated detection of wildlife using drones: Synthesis, opportunities and constraints.“ Methods in Ecology and Evolution, 12 (2021): 1103 - 1114.
<https://doi.org/10.1111/2041-210X.13581>
- DJI. „DJI Mavic 3E / 3T User Manual“ Abgerufen am 6. August 2024.
https://dl.djicdn.com/downloads/DJI_Mavic_3_Enterprise/DJI_Mavic_3E_3T_User_Manual_EN.pdf (a)
- DJI „DJI Mavic 3T“ Abgerufen am 6. August 2024. <https://store.dji.com/at/product/dji-mavic-3t-and-dji-care-enterprise-basic?vid=120171> (b)
- Google. „What is Angular?“ Abgerufen am 6. August 2024 <https://angular.dev/overview>
- Gluon. „JavaFX“ Abgerufen am 6. August 2024 <https://openjfx.io/>
- Alexey Bochkovskiy, John Aughey, Stéphane Charette, und Jason Daniel
„darknet_video.py.“ Darknet, GitHub, zuletzt aktualisiert am 23. Dezember 2023.
https://github.com/hank-ai/darknet/blob/master/src-python/darknet_video.py

Stéphane Charette 2024 „Summary“ Abgerufen am 8. September 2024.

<https://www.ccoderun.ca/darkmark/Summary.html> (b)

Stéphane Charette 2024 „Image Markup“ Abgerufen am 8. September 2024.

<https://www.ccoderun.ca/darkmark/ImageMarkup.html> (c)

Stéphane Charette 2024 „Image Markup“ Abgerufen am 8. September 2024.

https://www.ccoderun.ca/programming/darknet_faq/#optimal_network_size (d)

Stéphane Charette 2024 „Image Size and Tiling“ Abgerufen am 8. September 2024.

<https://www.ccoderun.ca/darkmark/ImageSize.html> (e)

Stéphane Charette 2024 „Does the network have to be perfectly square?“ Abgerufen am 8. September 2024.

https://www.ccoderun.ca/programming/darknet_faq/#square_network (f)

Stéphane Charette 2020 „Does the network have to be perfectly square?“ Abgerufen am 8. September 2024. [https://www.ccoderun.ca/programming/2020-01-](https://www.ccoderun.ca/programming/2020-01-04_neural_network_training/)

[04_neural_network_training/](https://www.ccoderun.ca/programming/2020-01-04_neural_network_training/)

Abbildungsverzeichnis

Abbildung 1: Einjähriger Bock: Die rechte Geweihstange ist noch voll im Bast während bei der linken Stange das Abwetzen begonnen hat. Die gelblich-weiße Farbe der Stange ist gut zu erkennen.....	10
Abbildung 2: Zweijähriger Bock: Die dunkelbraune Färbung des Geweihs nach der Einwirkung von unterschiedlichen Umweltfaktoren ist gut zu erkennen.....	11
Abbildung 3: Längenkreise (rot) und Breitenkreise (blau).....	20
Abbildung 4: DJI Mavic 3T (DJI 2024b).....	24
Abbildung 5: Bei der Wärmequelle in der grünen Bounding Box handelt es sich um ein Reh (7x6 Pixel). Die rote Box zeigt einen vergrößerten Ausschnitt.....	38
Abbildung 6: Bei der Wärmequelle in der grünen Bounding Box handelt es sich um einen Hasen (8x8 Pixel). Die rote Box zeigt einen vergrößerten Ausschnitt.....	38
Abbildung 7: Bei der Wärmequelle in der grünen Bounding Box handelt es sich um ein Rehkitz (9x9 Pixel). Die rote Box zeigt einen vergrößerten Ausschnitt.....	39
Abbildung 8: Initiale Ansicht von DarkMark.....	40
Abbildung 9: Laden des Projekts.....	40
Abbildung 10: Anzeige der Trainingsdaten.....	41
Abbildung 11: Bounding Box in DarkMark.....	41
Abbildung 12: Klassifizierung in DarkMark.....	42
Abbildung 13: Bilder rotieren und spiegeln.....	42
Abbildung 14: Statistiken.....	43
Abbildung 15: Statistiken.....	43
Abbildung 16: Darknet Dateien erzeugen.....	44
Abbildung 17: Ausgabe von Darknet.....	45
Abbildung 18: Videoanzeige von Darknet.....	46
Abbildung 19: Modifizierte Ausgabe.....	47
Abbildung 20: Startbildschirm.....	48
Abbildung 21: KI arbeitet im Hintergrund.....	48
Abbildung 22: Anzeige des Videos.....	49
Abbildung 23: Auswahl einer Bounding Box.....	50

Abbildung 24: Yaw (α).....	51
Abbildung 25: Testbild zur Berechnung der geografischen Koordinaten.....	51
Abbildung 26: Höhe der Drohne (h), Sehweite (m), Halbe Sehweite (n), Sichtfeld (α). ..	52
Abbildung 27: Berechnung der geografischen Koordinaten in Java.....	54
Abbildung 28: Startbildschirm der Webanwendung.....	56
Abbildung 29: Starten des Versuchs.....	56
Abbildung 30: Objekt erkannt.....	57
Abbildung 31: Objekt klassifiziert.....	57
Abbildung 32: Wechsel auf die Tageslichtkamera. Das Objekt von Abbildung 31 ist aus der Nähe zu erkennen und kann als Kitz identifiziert werden.....	58
Abbildung 33: Abgeschlossener Versuch: Es wurden insgesamt 19 Objekte erkannt. Davon konnten 12 durch die Testperson klassifiziert werden.....	58
Abbildung 34: Ergebnis eines Versuchs.....	59
Abbildung 35: Python-Skript zur Durchführung des Mann-Whitney-U-Tests.....	64

Tabellenverzeichnis

Tabelle 1: Ergebnis des Prototypen.....	61
Tabelle 2: Ergebnis der Versuchspersonen.....	62
Tabelle 3: Liste aller Wärmequellen im Video des Experiments.....	68
Tabelle 4: Ergebnis des Prototypen.....	69
Tabelle 5: Ergebnis der Versuchsperson 1.....	70
Tabelle 6: Ergebnis der Versuchsperson 2.....	71
Tabelle 7: Ergebnis der Versuchsperson 3.....	72
Tabelle 8: Ergebnis der Versuchsperson 4.....	73
Tabelle 9: Ergebnis der Versuchsperson 5.....	74
Tabelle 10: Ergebnis der Versuchsperson 6.....	75
Tabelle 11: Ergebnis der Versuchsperson 7.....	76
Tabelle 12: Ergebnis der Versuchsperson 8.....	77
Tabelle 13: Ergebnis der Versuchsperson 9.....	78
Tabelle 14: Ergebnis der Versuchsperson 10.....	79
Tabelle 15: Ergebnis der Versuchsperson 11.....	80
Tabelle 16: Ergebnis der Versuchsperson 12.....	81