# NatureAI-Abschlussbericht

15. Juli 2025

## 1 Eingehende Darstellung

### 1.1 Zusammenfassung

Die Ziele des NatureAI-Projekts umfassten sowohl die Erstellung des Vollantrags für die Umsetzungsphase (Phase 2) als auch den Aufbau des dafür notwendigen Konsortiums. Zusätzlich wurden geeignete Anwendungsfälle ausgearbeitet sowie ein erstes vortrainiertes Modell zur Tierstimmenerkennung entwickelt und evaluiert.

Für den Aufbau des Konsortiums konnten weitere zentrale Partner gewonnen werden: Einerseits für die Entwicklung geeigneter Rekorder, andererseits durch Expertise in funktioneller Biodiversitätsforschung und Ökoakustik, wodurch die geplanten Feldversuche maßgeblich unterstützt worden wären. Zudem konnte das bereits bestehende Konsortium weiter vernetzt werden. Der Meilenstein MS1 „Konsortium ist erfolgreich aufgebaut“ wurde damit erreicht.

In mehreren Workshops wurden geeignete Anwendungsfälle für die Feldtests identifiziert und in den Gesamtprojektplan für Phase 2 integriert. Damit wurde der Meilenstein MS2 „Repräsentative Use-Cases (UC) zur Bearbeitung für die Umsetzungsphase sind ausgewählt“ erfüllt. Aufbauend auf diesen Use-Cases konnten zentrale technische und methodische Schlüsselfaktoren identifiziert und die Vorhabensbeschreibung in Arbeitspaket 5 konzipiert und ausgearbeitet werden.

Mit der fristgerechten Einreichung der Gesamtvorhabens- und Teilvorhabensbeschreibungen aller neun Partner wurde schließlich auch der Meilenstein MS3 „Antrag für die Umsetzungsphase ist eingereicht“ erfolgreich erreicht.

In der letzten Phase wurde schließlich ein erstes vortrainiertes Deep-Learning-Modell mit Contrastive-Learning-Ansätzen zur Tierstimmenerkennung entwickelt und evaluiert.

### 1.2 Detaillierte Ergebnisse der Arbeitspakete

#### AP 1: Projektmanagement & Aufbau des Konsortiums.

**Projektmanagemnet** Die Plattform MS Teams wurde so eingerichtet, dass die Kommunikation und Zusammenarbeit innerhalb des neu gebildetetn Konsortiums erleichtert wurde. Die digitale Plattform ermöglichte einen effizienten Austausch von Informationen, Diskussionen und das Teilen von Dateien. Durch hybride Meetings und eine agile Arbeitsmethode wurde eine effiziente Zusammenarbeit gewährleistet.

**Konsortium: Kooperationen und Arbeitsteilung** Im Rahmen des Projekts wurde erfolgreich ein interdisziplinäres Konsortium für die Umsetzungsphase aufgebaut, das sich mit den Herausforderungen und Chancen im Biodiversitätsmonitoring von National- und Naturparks (NP), sowie mit dem Know-how-Transfer von KI-Methoden in die Biodiversitätsforschung befasst hat. Zusätzliche Partner aus der Biodiversitätsforschung konnten gewonnen werden wie die Universität Freiburg und der Nationalpark Bayrischer Wald als assoziierter Partner. Auf der technischen Seite konnte das junge Unternehmen FoldAI für die Entwicklung der smarten Rekorder hinzugefügt werden. Die insegsamt neun Partner mit weiteren fünf assoziierten Partner, darunter National- und Naturparks, Universitäten, Forschungsinstitute und Technologieanbieter, haben gemeinsam Co-Creation Workshops durchgeführt, um Fachwissen auszutauschen und die Zusammenarbeit zu stärken.

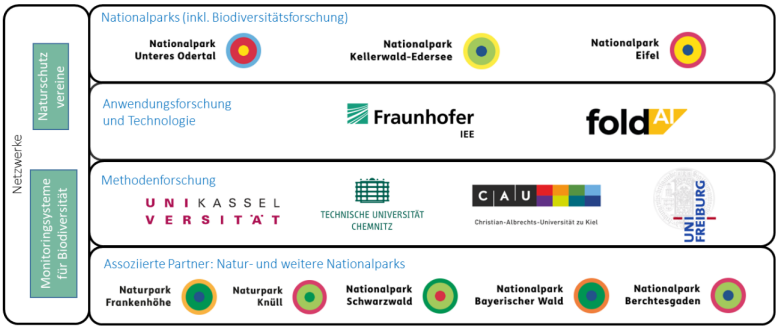


**Abbildung 1:** Kernkonsortium in NatureAI

Das sehr diverse Konsortium vereinte breit gefächertes Fachwissen aus verschiedenen Bereichen: dem klassischen Biodiversitätsmonitoring und der Analyse von Tierbeständen in Nationalparks, der funktionellen Biodiversitätsforschung und Ökoakustik, der Entwicklung energieeffizienter Hardware (z.B. Ultra-Low-Power-Technologien und Edge Computing) für autarke smarte Rekorder, modernen Machine-Learning-Technologien zur intelligenten Verknüpfung von KI und Biodiversitätsforschung – darunter die Entwicklung von Foundation-Modellen zur Erkennung von Tierstimmen und Ruftypen – sowie umfassender Erfahrung in der Leitung und Koordination von Forschungsprojekten. Das Konsortium strebte eine enge interdisziplinäre Zusammenarbeit an, um innovative Lösungen zur Erfassung und Erhaltung der biologischen Vielfalt zu fördern. Regelmäßige Abstimmungen mit den Partnern sorgten dafür, dass die Projektziele mit den Interessen aller Beteiligten übereinstimmten, wobei der Schwerpunkt auf der gemeinsamen Antragstellung für die Umsetzungsphase lag, sowie der Etablierung langfristiger Partnerschaften, die über das Projekt hinausgehen und zum Schutz der Biodiversität beitragen.

### AP 2: Studie: Eignung relevanter Arten zur akustischen Erfassung

Ergebnis des APs ist eine Grundlage für den Aufbau eines bioakustischen Monitoringsystems. Es wurde eine Auswahl von für die National- und Naturparks relevanten Tierarten zusammengestellt und dokumentiert. Zudem wurden verfügbare Daten gesammelt, aufbereitet und evaluiert, um eine Grundlage für das vortrainierte Modell in AP5 und die Umsetzungsphase zu schaffen. Es wurden verschiedene Arten von Grasshüpfern, in Wasser lebenden Säugertieren (Watkins-Marine-Sound) und Fröschen mit dem in AP5 entwickelten Foundationmodell evaluiert. Die Ergebnisse sind in AP 5 Evaluation Foundationmodell: dargestellt. Im Allgemeinen kann man hier sehen, dass sich das Modell sehr gut auf andere Tiere als Vögel übertragen lässt.

### AP 3: Use-Cases

Das Ergebnis des Arbeitspakets ist eine repräsentative Sammlung überzeugender Anwendungsfälle für die Umsetzungsphase, erarbeitet und priorisiert in Design Thinking Workshops mit dem Konsortium. Die Fokussierung lag auf Übertragbarkeit, Skalierbarkeit und Anwendbarkeit für den Nutzer. Die Ergebnisse dienen als Grundlage zur Ableitung von Forschungsfragen aus der Biodiversitätsperspektive und zur Überprüfung und Anpassung der Forschungsfragen aus KI-Sicht.

Als Teil unserer strategischen Vorbereitungen haben wir in Phase 1 (Konzeptphase) einen umfassenden **Design-Thinking-Workshop** durchgeführt. Dort entwickelten wir innovative Lösungsansätze und identifizierten Herausforderungen und Schwerpunkte für das NatureAI-Projekt.
**Einführung und Workshop-Ziele:** In der Vorbereitungsphase des NatureAI-Projekts führten wir einen produktiven Design-Thinking-Workshop mit dem Science Park Kassel und der Universität Kassel durch, um Konzepte für innovative bioakustische Überwachungslösungen zu entwickeln, Prioritäten festzulegen, das Projekt vorzustellen und neue Konsortiumspartner zu gewinnen. **Vorbereitung und Durchführung des Workshops:** Vor und während des Workshops erarbeiteten wir mit Parks ein detailliertes Use-Case-Dokument, das als Diskussionsgrundlage diente und die Basis für das Projektkonzept bildete, nachdem es analysiert und priorisiert wurde. Ein Beispiel dazu ist in Abbildung 2 zu sehen.

| Anwendungsfall: Wachtelkönig (*Crex crex*) | | Ansprechpartner: Maria Serocki | Institution: Nationalpark Unteres Odertal |
|---|---|---|---|
| **Nutzer:**<br>**Welcher Nutzer (Rolle, Funktion)?** | **Problemstellung:**<br>**Was braucht der Nutzer?** | **Nutzen:**<br>**Welchen Mehrwert bringt das mit sich?** | **Wirkungen:**<br>**Welche positiven Wirkungen entstehen?** |
| Referentin für Forschung und Monitoring | Es wird benötigt:<br>1) Detektion und Lokalisation des Wachtelkönigs, verifiziert durch akustische Aufnahmen (ggf. mit Individuenerkennung)<br>2) Zeitreihen mit Angaben zum Klima, Wetter und Phänologie<br>3) Übertragung der Daten und zugehörigen Meta-Daten an den Nationalpark Unteres Odertal | - qualitativ hochwertige Monitoring-Daten einer sehr scheuen, nachtaktiven und wanderungsfreudigen Vogelart<br>- als Schirmart lassen Daten auch Rückschlüsse über andere, ökologisch ähnliche Wiesenbrüter zu<br>- ermöglicht zeitgenaue Abstimmung mit Maßnahmen des dynamischen Grünlandmanagements | Saisonale Habitatwahl und räumliche Verteilung erlauben Rückschlüsse über präferierte Lebensräume in Abhängigkeit von klimatischen Bedingungen und wechselnden Wasserständen. Dies ermöglicht die Planung effektiver Schutzmaßnahmen in Reaktion auf 1.) den Klimawandel, 2.) Grünlandnutzung, 3.) Herstellung naturnaher Wasserverhältnisse und 4.) befürchtete Grundwasserabsenkungen durch Oderausbau |
| **Zeitliche Auflösung der Monitoring-Daten:**<br>**(Echtzeit, minütlich, stündlich, täglich)** | **Räumliche Auflösung der Monitoring-Daten:**<br>**(Hotspots oder räumliche Verteilung, qm?)** | **Tierarten:**<br>**Welche Tierarten sollen erfasst werden?** | **Frequenzbereich:**<br>**Welcher?** |
| Zeitreihe, stündlich | Räumliche Verteilung | Wachtelkönig (*Crex crex*)<br>Anwesend von Ende April bis Anfang September | Einzelrufe bestehend aus 10 bis mehr als 20 breitbandigen Pulsen mit maximaler Energie im Bereich 4 bis 8 kHz (DeViSe 2021) |
| **Relevante Standortfaktoren**<br>**(Erreichbarkeit, Strom, WLAN, Wasser)** | **Status quo: Sind Daten bereits vorhanden, die verwendet werden können?** | **Sonstiges:**<br>**Gerne Anregungen oder Kommentare** | |
| Stromversorgung vorhanden: nein<br>Erreichbarkeit: nur zu Fuß erreichbar<br>Internetverbindung vorhanden: nein<br>Bestimmte Auenwiesen stehen von November bis Mai unter Wasser | Ja, es wurden bereits akustische Daten zur Detektion des Wachtelkönigs aufgenommen. | | |

UNIKASSEL VERSITÄT

**Abbildung 2:** Anwendungsfall Beispiel Wachtelköning

Für die einzelnen Nationalparks wurden spezifische Schwerpunkte identifiziert – darunter die Überwachung von Brutvögeln und Rothirschen im Nationalpark Kellerwald-Edersee, von Amphibien, dem Wachtelkönig und Heuschrecken im Nationalpark Unteres Odertal sowie von Fledermäusen und Wiesenbrütern im Nationalpark Eifel. Abbildung 3 ordnet diese Schwerpunkte in das Gesamtkonzept des NatureAI-Projekts ein – insbesondere im Hinblick auf die Evaluierungskomplexität aus biodiversitäts- und KI-technischer Perspektive. In Abbildung 4 sind darüber hinaus die projektspezifischen Zielsetzungen der einzelnen Partner dargestellt.

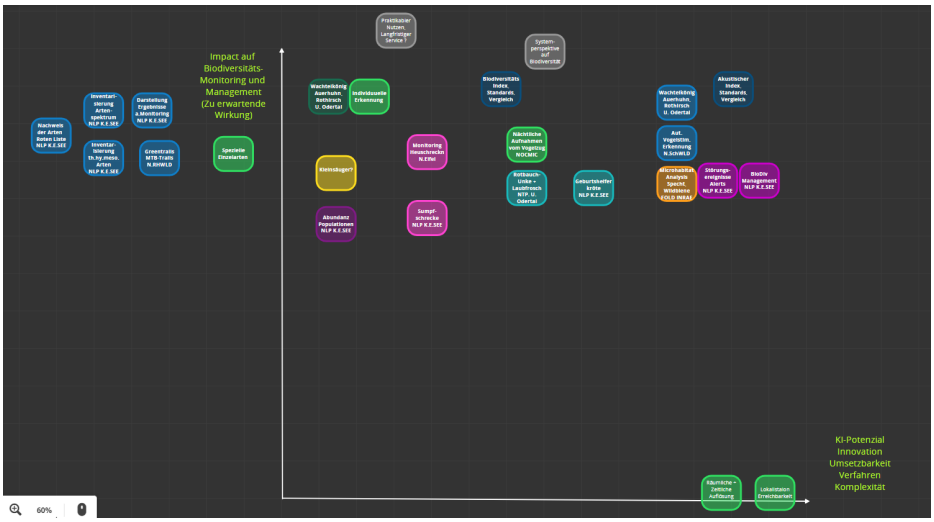


**Abbildung 3:** Einordnung der Use Cases in NatureAI

### AP 4: Schlüsselfaktoren, Verwertung und Antrag

Das Ergebnis des Arbeitspakets umfasst technische und methodische Schlüsselfaktoren für NatureAI, welche u.a. aus AP2 und den Ergebnissen der Desig-Thinking Workshops und den Use-Cases abgeleitet wurden. Es wurden Anforderungen bzgl. der Entwicklung von Edge Computing und Tiny ML-Algorithmen und der entsprechenden Hardwarenutzung identifiziert. Zusätzlich wurden potenzielle Kooperationspartner identifiziert. Insgesamt haben neun Partner sowie fünf weitere assoziierte Partner gemeinsam eine Vorhabensbeschreibung (VHB) sowie neun Teilvorhabensbeschreibungen (TVBs) erstellt und ein Verwer-

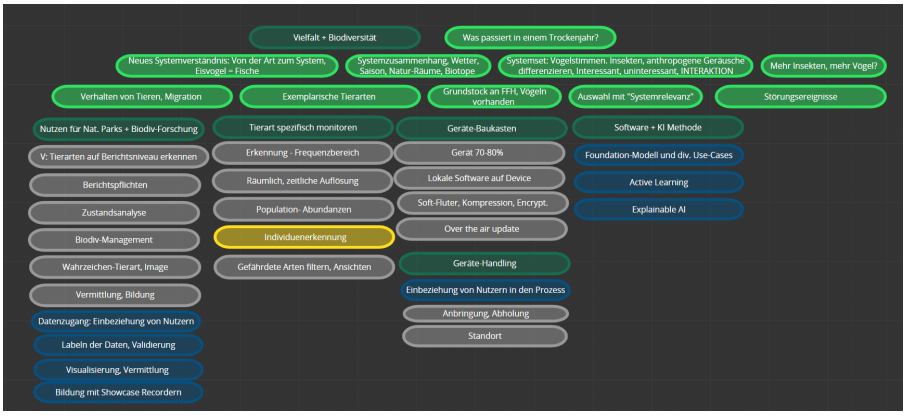


**Abbildung 4:** Ziele der Partner in NatureAI

tungskonzept erarbeitet. Ziel war es, aufzuzeigen, wie das NatureAI-Projekt in Planung, Durchführung und Finanzierung unterstützt worden wäre und wie eine nachhaltige Nutzung der entwickelten Technologie sichergestellt werden könnte.

**Technische Anforderungen und Herausforderungen** Nach dem Design-Thinking-Workshop analysierten wir die Anwendungsfälle unserer Park- und Forschungspartner im Detail und leiteten daraus vorläufige technische Spezifikationen für die Entwicklung eines intelligenten Rekorders ab. Bei der Auswahl existierender Plattformen fokussierten wir uns auf Anwendungspotenzial, technische Skalierbarkeit und Anpassbarkeit. Eine zentrale Herausforderung war der Einsatz von Edge-Geräten, die trotz geringem Stromverbrauch und limitierter Rechenkapazität besonders für den Outdoor-Einsatz geeignet sind. Um deren technische Einschränkungen zu überwinden, sollte KI auf Ultra-Low-Power Geräten implementiert werden. Weiterhin wurden spezifische Strategien zur Effizienzsteigerung entwickelt, darunter den Einsatz sequenzieller Modelle und die Quantisierung von Tensoren. Zudem legten wir Wert auf die Wartung der Geräte, insbesondere die Batterielaufzeit und die Robustheit, um nachhaltige und kosteneffiziente Überwachungslösungen sicherzustellen.

### AP 5: Pretraining is all You Need

**Datengrundlage und Foundationmodell:** In der ersten Phase unseres Projekts haben wir eine solide Datengrundlage geschaffen, die für die Entwicklung von KI-Modellen zur bioakustischen Detektion von Tierarten essentiell ist. Durch die Kooperation mit dem BMUV-Projekt „DeepBirdDetect“ initiierten wir „BirdSet“ [Rauch et al., 2024], ein Projekt zum Sammeln und Katalogisieren hochwertiger akustischer Daten, einschließlich Umweltgeräuschen und Störgeräuschen, welches bereits Open Source zur Verfügung gestellt wurde. Erste Versionen eines Foundationmodells wurde mittels Self-Supervised Learning SSL, sowie Supervised Learning SL entwickelt.

**Evaluation Foundationmodell:** Für das selbstüberwachte Lernen von Repräsentationen in unserem SSL Modell "ChirpCLR_SSL"haben wir uns an SimCLR orientiert – einem Framework, das ursprünglich für visuelle Daten entwickelt wurde ([Chen et al., 2020]). Die zentrale Idee besteht darin, aus jedem Bild zwei stark augmentierte Versionen zu erzeugen und ein neuronales Netzwerk so zu trainieren, dass es diese beiden Varianten als zusammengehörig erkennt, während es andere Bilder im Batch als unterschiedlich behandelt. Durch das kontrastive Lernprinzip entstehen Repräsentationen, die sich in nachgelagerten Aufgaben – wie etwa der Klassifikation – besonders effektiv nutzen lassen. Um diesen Ansatz auf Audiodaten zu übertragen, haben wir Tierstimmen-Aufnahmen in Mel-Spektrogramme umgewandelt, die sich anschließend wie Bilddaten im Framework weiterverarbeiten lassen. Zusätzlich wurden gezielte Anpassungen vorgenommen, darunter die Integration geeigneter Audio-Augmentationstechniken sowie der Einsatz von EfficientNet-B1 anstelle von ResNet als Encoder, um die Methode besser an unsere Datenstruktur und Zielsetzung anzupassen. Weiterhin haben wir ein SL Modell entwickelt, das hauptsächlich auf einem EfficientNet-B1 Modell beruht "ChirpSR_SL".
**Training Datensatz:** Für das ChirpCLR_SSL-Modell verwenden wir das Xeno-Canto Large Dataset

aus Rauch et al. [2025]. Dieses Datenset besteht aus Fokusaufnahmen und umfasst insgesamt 10.297 Arten und 686.593 Aufnahmen. Alle Aufnahmen haben eine Abtastrate von 32kHz. Weitere Informationen finden sich in Rauch et al. [2025].

**Few-Shot Evaluation:** Zur Klassifikation von Vogelarten werden häufig Fokusaufnahmen von Plattformen wie Xeno-Canto und Zenodo verwendet. Diese Datensätze bieten qualitativ hochwertige Aufnahmen einzelner Rufe in ruhiger akustischer Umgebung und eignen sich gut für das initiale Training von Modellen. In der Praxis zeigen solche Modelle jedoch oft unzureichende Leistung, wenn sie an einem spezifischen Standort mit komplexeren akustischen Bedingungen und lokalem Artenspektrum eingesetzt werden. Eine Möglichkeit zur Verbesserung besteht darin, Modelle mit standortbezogenen Aufnahmen gezielt anzupassen.

Eine zusätzliche Herausforderung ist der Umgang mit bislang unbekannten oder seltenen Arten. Daher ist es wichtig, dass Modelle sich mit nur wenigen Trainingsbeispielen an neue Umgebungen und Arten anpassen können. Im Projekt wurden vortrainierte Foundation-Modelle mit Verfahren wie Linear Probing und Few-Shot Learning gezielt auf standortspezifische Daten angepasst. Few-Shot Learning hat das Ziel Kategorien anhand einer geringen Zahl an Beispielen zu erlernen. Die Evaluierung erfolgte unter kontrollierten Bedingungen: Für jedes Experiment wurden 32 Beispiele pro Klasse und Seed für das Training ausgewählt. Um die Aussagekraft der Ergebnisse zu erhöhen, wurden fünf unterschiedliche Seeds verwendet, bei denen jeweils zufällig unterschiedliche, aber gleich strukturierte Teilmengen der Daten gezogen wurden. Dabei wurde darauf geachtet, dass in allen Seeds die gleichen Klassen enthalten sind. Zusätzlich wurde sichergestellt, dass Aufnahmen derselben Originalquelle nicht gleichzeitig im Training und im Test vorkommen, um eine saubere Trennung und realistische Bewertung der Generalisierungsfähigkeit zu gewährleisten. Im Test wurden für jede Klasse mindestens acht Beispiele benötigt; Klassen, für die diese Anzahl nicht zur Verfügung stand, wurden von der jeweiligen Evaluation ausgeschlossen. Diese Vorgehensweise stellt sicher, dass die Testergebnisse nicht durch zu kleine oder unausgewogene Testmengen verzerrt werden. Die Ergebnisse sind in Abbildung 5 über alle verwendeten Few-Shot Datensätze und in Abbildung 6 gemittelt über diese Datensätze dargestellt. Wie hier zu sehen ist, konnten zwar geeignete Repräsentationen mit dem SSl Modell erzeugt werden, aber bisher noch keine ähnlich gute Performanz wie für die SL Modelle erreicht werden. Wir vermuten, dass dies u.a. an den noch viel zu wenigen Trainingsdaten für ein SSL Setting liegen könnte. Das eigene SL Modell wiederum kann für die 16 verschiedenen Datensätze vergleichbar gute Ergebnisse wie die State-of-the-Art etablierten Modelle wie BirdNET [Kahl et al., 2021] und Perch [Ghani et al., 2023] liefern. Eine Liste der verwendeten Few-Shot Datensätze ist in Tabelle 1 zu finden.

**Tabelle 1:** Evaluation-Datensätze. Die Spalte Samples gibt die Gesamtanzahl der gelabelten Aufnahmeausschnitte an. Für das Training werden davon nur 32 zufällig ausgewählte Samples und des Rest für den Test verwendet.

| | dataset name | # classes | # samples | geo |
|---|---|---|---|---|
| Vogelarten | Columbia Costa Rica (NES, costarica) | 4 | 876 | COL; CRI |
| | Hawaiian Islands (UHH, hawaii) | 16 | 40,327 | HI, USA |
| | High Sierra Nevada (HSN, uswest) | 5 | 1,141 | CA, USA |
| | Sierra Nevada (SNE, sierranevada) | 6 | 5,926 | CA, USA |
| | Sapsucker Woods (SSW, usnortheast) | 30 | 19,307 | NY, USA |
| | NIPS4Bplus (NBP, NIPS4B_fewshot) | 6 | 949 | FR; ES |
| | Yellowhammer Dialects (YD) | 2 | 1,543 | EU; AS; NZL |
| Call Types | Godwit Calls (GC, godwit) | 5 | 6,715 | NLD |
| | Black Woodpecker (BW) | 3 | 459 | DE; CH; FR |
| | Dunnock (DU) | 3 | 459 | DE; CH; FR |
| | Eurasian Blackbird (EB) | 6 | 918 | DE; CH; FR |
| | European Robin (ER) | 4 | 610 | DE; CH; FR |
| | Song Trush (ST) | 3 | 459 | DE; CH; FR |
| Other | Rainforest Frogs (RFCX, rfcx_frogs) | 10 | 500 | n/A |
| | XC Grasshoppers (XCG, xc_grasshoppers) | 13 | 3,192 | World |
| | Watkins Marine Mammals (WMM, Watkins_Marine_Sound) | 26 | 3,157 | World |

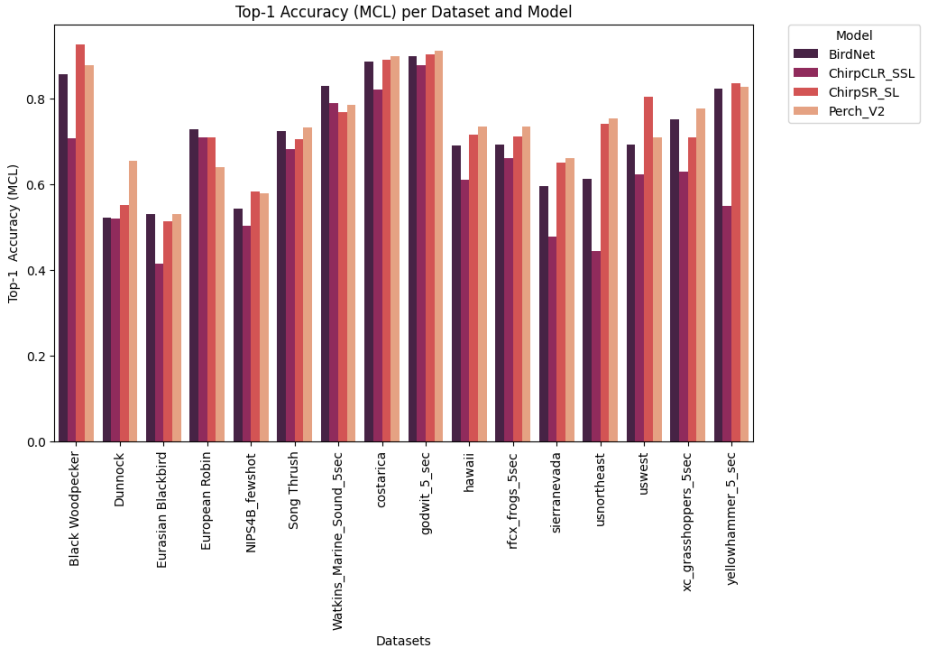


**Abbildung 5:** Evaluation der unterschiedlichen Datensätze und Modelle

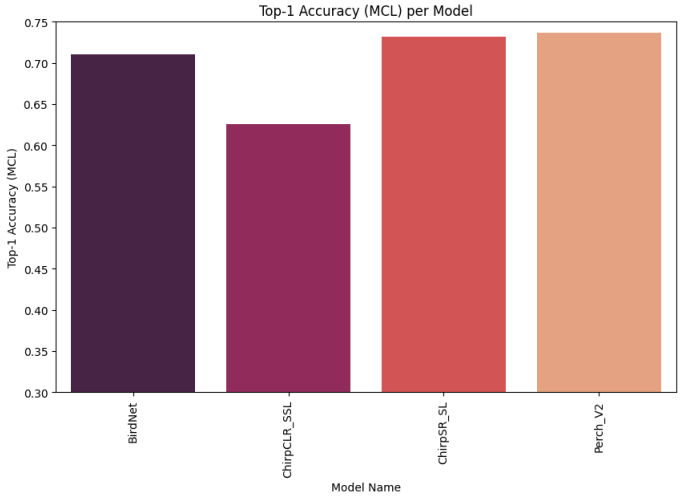


**Abbildung 6:** Evaluation der unterschiedlichen Modelle gemittelt über die Datensätze

- **Veröffentlichungen**
  - Die Ergebnisse aus AP5 werden derzeit systematisch aufbereitet und im Kontext aktueller Forschungsfragen weiterentwickelt. Im Fokus stehen dabei Themen wie der Umgang mit unsauberen oder schwachen Labels (weak label noise), der Einsatz von Sekundär-Labels, die Optimierung audio-spezifischer Augmentationsstrategien sowie die Anwendung und Evaluation von Multi-Label-Ansätzen. Die daraus resultierenden Ergebnisse werden in kürze in einem Paper veröffentlicht.
- Weitere wissenschaftliche Ergebnisse:
  - Um Studenten auch schon frühzeitig an die Thematik des bioakustischen Monitoring heranzuführen, wurden die Inhalte in der Veranstaltung Deep-Learning-Lab der Universität Kassel (wird gemeinsam vom IEE und IES organisiert) angeboten.

  - Ein Demonstrator wurde (weiter)-entwickelt, der sowohl in der IEE-Leitwarte zu mehreren Anlässen (Tag der offenen Tür am IEE, Girlsday, etc.) eingesetzt wurde als auch am IES zur Veranstaltung "Girls Go Informatics".

- Besuch von Konferenzen und Präsentation der Projektergebnisse
  - Teilnahme am BMUV-Vernetzungstreffen (11.06.2024) in Berlin. Dort wurde ein Vortrag zum Thema "KI Foundations Models für den Artenschutz"gehalten.
- Eingeworbene Projekte
  - Die Projektidee Distr@l „BioActiveAI – Standortspezifisches, KI-gestütztes Biodiversitätsmonitoring durch Active Learning und Citizen Science“ wurde in der ersten und zweiten Evaluierungsphase der (Förderlinie 2B „Digitale Prozessinnovationen“, Forschung  Entwicklung) positiv evaluiert und zum Antrag aufgefordert. BioDroneAI wurde bei DigitalGreenTech zum Antrag aufgefordert.
  - Es werden darüberhinaus gerade weitere Skizzen erarbeitet und bei entsprechenden Förderinitiativen (BMUKN Biologische Vielfalt, DFG) eingereicht

# Literatur


Ting Chen, Simon Kornblith, Mohammad Norouzi, and Geoffrey Hinton. A simple framework for contrastive learning of visual representations. In *Proceedings of the 37th International Conference on Machine Learning*, ICML'20. JMLR.org, 2020.

Burooj Ghani, Tom Denton, Stefan Kahl, and Holger Klinck. Feature Embeddings from Large-Scale Acoustic Bird Classifiers Enable Few-Shot Transfer Learning. *CoRR*, 2023. doi: 10.48550/arXiv.2307.06292.

Stefan Kahl, Connor M. Wood, Maximilian Eibl, and Holger Klinck. BirdNET: A deep learning solution for avian diversity monitoring. *Ecological Informatics*, 61:101236, March 2021. ISSN 15749541. doi: 10.1016/j.ecoinf.2021.101236.

Lukas Rauch, Raphael Schwinger, Moritz Wirth, René Heinrich, Denis Huseljic, Marek Herde, Jonas Lange, Stefan Kahl, Bernhard Sick, Sven Tomforde, and Christoph Scholz. Birdset: A large-scale dataset for audio classification in avian bioacoustics, 2025. URL `https://arxiv.org/abs/2403.10380`.

# 2 Kurzbericht

## Projektinhalt und Ausgangslage

Das Projekt NatureAI verfolgte das Ziel, Methoden der künstlichen Intelligenz für die automatisierte Erfassung und Analyse von Biodiversität nutzbar zu machen. Im Mittelpunkt stand der Aufbau eines interdisziplinären Konsortiums, das technologische, ökologische und methodische Expertise vereint, um KI-basierte Anwendungen in der Umweltforschung, insbesondere im Naturschutz, zu ermöglichen.

Ausgangspunkt war die wachsende Nachfrage nach automatisierten Monitoringlösungen, die dem Rückgang der biologischen Vielfalt wirkungsvoll begegnen können. Mit Fortschritten im Bereich von Edge-Computing, Machine Learning und sensorbasierten Datenerhebungen bestehen neue Chancen, Artenvielfalt großflächig, effizient und mit minimalem personellen Aufwand zu erfassen.

Im NatureAI-Projekt wurden der Vollantrag für die Umsetzungsphase erstellt und das erforderliche Konsortium erfolgreich aufgebaut (MS1). Zwei zentrale Partner konnten dafür zusätzlich gewonnen werden – einer für die Rekorderentwicklung, einer mit Expertise in Biodiversitätsforschung und Ökoakustik. In Workshops wurden geeignete Anwendungsfälle identifiziert und in den Projektplan integriert, womit Meilenstein MS2 erreicht wurde. Darauf aufbauend wurden technische und methodische Anforderungen definiert und in den Gesamtprojektplan der Umsetzungsphase überführt. Mit der fristgerechten Einreichung aller Vorhabensbeschreibungen wurde auch Meilenstein MS3 erfüllt; zudem entstand ein erstes vortrainiertes Modell zur Tierstimmenerkennung auf Basis kontrastiven Lernens.

## Ablauf und Umsetzung

In der Konzeptphase wurden gemeinsame Ziele, Anwendungsfälle und technische Grundlagen definiert. Dazu wurde sich in einer agilen Arbeitsweise mit regelmäßigen Update-Meetings und den Design Thinking Workshops ausgetauscht. Das neu gebildete Konsortium, welches schließlich gemeinsam den Antrag für die Umsetzungsphase einreichte, bestand aus neun Partnern aus Wissenschaft, Praxis und Technologie, ergänzt durch fünf assoziierte Partner, darunter Betreiber von Schutzgebieten und Hersteller intelligenter Rekorder.

Im Fokus stand der Aufbau einer belastbaren Planungs- und Entscheidungsgrundlage für die nachgelagerte Umsetzungsphase. Parallel dazu wurden erste KI-Modelle weiterentwickelt, um Potenziale und Herausforderungen frühzeitig sichtbar zu machen. Zentrale Arbeitsschritte waren:

- Auswahl geeigneter Zielarten und Bewertung ihrer akustischen Erfassbarkeit.
- Entwicklung und Training von KI-Modellen, Self-Supervised Deep Learning Modellen, zur Erkennung und Klassifikation akustischer Signale.
- Evaluation realistischer Few-Shot Szenarien.
- Analyse technischer Anforderungen an Edge-Systeme und energieeffiziente Hardware.
- Erarbeitung eines konkreten Plans für die Umsetzung und Verstetigung des Vorhabens.

## Wesentliche Ergebnisse und Zusammenarbeit

Die Konzeptphase verlief erfolgreich und schuf die wissenschaftlich-technische Grundlage für ein skalierbares, KI-gestütztes Biodiversitätsmonitoring. Wesentliche Ergebnisse waren:

- Ein robustes, repräsentatives Konsortium mit klar definierten Rollen.
- Ein umfassender Gesamtantrag für die Umsetzungsphase, der auf Praxistauglichkeit, Übertragbarkeit und Weiterentwicklung ausgelegt war.
- Entwicklung eines ersten Foundationmodells mit Self-Supervised Learning und darauf aufbauendes Few-Shot-Klassifikationsmodell, das sowohl methodisch als auch praktisch evaluiert wurde.
- Konkrete Anwendungsfälle in Natur- und Nationalparks mit Potenzial zur bundesweiten Ausweitung.

- Erste Ansätze zur wirtschaftlichen Verwertung über Hardware-Integration und Service-Modelle.

  Die Zusammenarbeit im Projekt zeichnete sich durch Offenheit, hohe Koordinationsfähigkeit und einen intensiven interdisziplinären Austausch aus. Durch digitale Tools, geteilte Infrastruktur und regelmäßige Feedbackschleifen konnten Herausforderungen effizient adressiert und eine gemeinsame Vision entwickelt werden. Das Projekt hat gezeigt, dass der Schulterschluss von KI-Forschung und Biodiversitätsmonitoring nicht nur machbar, sondern hochrelevant ist.