Schlussbericht

Thema: **Verbundprojekt:**

KI für nachhaltige Lebensmittelqualität in Lieferketten (KINLI) - Teilprojekt C

Zuwendungsempfänger: **Hochschule Niederrhein University of Applied Sciences (HSNR)**

Förderkennzeichen: **28DK124C20**

Laufzeit: **01.09.2022 bis 31.12.2025**

Monat der Erstellung: **12/2025**

Inhaltsverzeichnis

I. Kurzbericht 2

1. Aufgabenstellung 2
2. Planung und Ablauf des Vorhabens 2
3. Resümee der wesentlichen Ergebnisse 3

a) Arbeitspakete und Meilensteine 3

b) Zusammenfassung 4

II. Ausführliche Darstellung der Ergebnisse 5

1. Erzielte Ergebnisse 5

Arbeitspaket 1: Konzept 5

Arbeitspaket 2: Datenhaltung und Technische Plattform 8

Arbeitspaket 3: KI- basierte Dienste 11

Arbeitspaket 4: Use Cases 18

Arbeitspaket 5: Evaluierung 21

Arbeitspaket 6: Sichtbarkeit und Verwertung 24

Arbeitspaket 7: Projektmanagement 26

2. Verwertung 26

a) Erfindungen/Schutzrechtsanmeldungen 26

b) Wirtschaftliche Erfolgsaussichten nach Projektende 26

c) Wissenschaftliche und/oder technische Erfolgsaussichten nach Projektende 27

d) Wissenschaftliche und wirtschaftliche Anschlussfähigkeit 27

3. Erkenntnisse von Dritten 27
4. Veröffentlichungen 27

I. Kurzbericht

1. Aufgabenstellung

Basierend auf den Zielstellungen leitet die Hochschule Niederrhein (HSNR) die konzeptionelle Bearbeitung des Vorhabens. Der Fokus im ersten Arbeitspaket liegt auf dem Anforderungsmanagement, indem die HSNR als Schnittstelle zu den Anwendungspartnern fungiert. Zudem leitet die HSNR das vierte Arbeitspaket und sichert die Überführung von Anforderungen in die modellhafte Abbildung der KINLI-Lösung in die Umwelt der Anwendungspartner. Die Evaluierung der entwickelten KINLI-Lösung ist zudem Bestandteil der HSNR. Durch die Förderung von Projekten zum Einsatz von Künstlicher Intelligenz (KI) in der Landwirtschaft und den ländlichen Räumen wird in KINLI das Ziel verfolgt, einen prädiktiven Ansatz zur Gewährleistung nachhaltiger Lebensmittelqualität durch Einsatz von KI zu konzeptionieren und anhand von zwei Use Cases entlang der Fleischverarbeitung umzusetzen. Erweiterte Voraussetzungen sind, dass die Projektleitung durch das Fraunhofer FIT übernommen wird. Wissenschaftlich begleitet wird das Projekt zudem durch die Hochschule Offenburg und HSNR. Praxisorientierte Forschung wird durch die Anwendungspartner aus der Fleischverarbeitung Kolsert KG (Haltung von Puten) und Sauels frische Wurst GmbH Fleischwaren & Co. KG (Produktion von Kochschinken) realisiert. Der wissenschaftliche und techniche Stand, an dem das Projekt angeknüpft, besteht in der Forschung und Entwicklung von Assistenzsystemen für die landwirtschaftliche Tierhaltung sowie in KI-Lösungen zur Prozessoptimierung in der Lebensmittelproduktion. Eine im Projekt durchgeführte Marktanalyse zeigt auf, dass die Ernährungs- und Landwirtschaft hohes Potenzial zur Digitalisierung und weiterführend zur Einbindung neuartiger Technologien wie KI aufweisen. Der bestehende wissenschaftliche und technische Stand zeigt keine marktfähigen Lösungen zum Einsatz von KI in der Produktion von Kochschinken auf. Die Untersuchung zeigt den bisherigen Einsatz von KI zur Entwicklung von Assistenzsystemen innerhalb der landwirtschaftlichen Tierhaltung für einige Nutztiere auf, jedoch bestehen keine marktfähigen Lösungen für den Einsatz in der Putenhaltung.

2. Planung und Ablauf des Vorhabens

Zunächst wurde die konzeptionelle Vorarbeit, die Erstellung einer Marktanalyse, die Durchführung des Anforderungsmanagements sowie die Skizzierung der ersten Referzarchitektur und -prozesse erstellt. Anschließend wurde die Datenhaltung sowie die technische Plattform mit Fokus auf das Datenmodell, der Plattform sowie dem Management entwickelt. Die nutzerorientierte Anwendung erfolgte auf zwei Use Cases mit dem Fokus auf Feinkonzeption, eigene Datenerfassung und -aufbereitung, Erstellung von Modellen und Analysen. Infolgedessen konnten KI-basierte Dienste entwickelt und folglich in die Umwelt der Anwendungspartner integriert werden. Die praxisorientierte Forschung wird abschließend evaluiert. Die Durchführung des Projektes stimmt weitestgehend mit der Planung des Antrags überein. Verzögerungen ergaben sich in der Datenhaltung, -erfassung und -aufbereitung zu KI-Modellen. Diese konnten durch die genehmigte, viermonatige Verlängerung weitestegehend kompensiert werden. Die Zusammenarbeit mit anderen Stellen wurde in regelmäßigen Online-Meetings organisiert. Unter den Forschungspartnern fanden Meetings mit

kürzeren Abständen statt, um kurzfristig auf Neuerungen reagieren zu können. Ergänzend fanden persönliche Konsortialtreffen statt. Die notwendigen Daten wurden durch die Anwendungspartner zur Verfügung gestellt und gemeinsam wurden weiterführende Datenaufnahmen und -aufbereitung durchgeführt. Innerhalb des Anforderungsmanagements wurden Stakeholder aus den Domänen Lebensmittel und Landwirtschaft in Interviews befragt. Darüber hinaus werden Kontakte mit Landwirten und wissenschaftlichem Personal aus den Bereichen Landwirtschaft und Veterinärmedizin für weiteren Datenaustausch im zweiten Use Case aufgenommen. Weiterführende Arbeiten zur Marktanalyse sowie zur Entwicklung von Geschäftsmodellen für den zweiten Use Case wurden bei EQAsce Education beauftragt.

3. Resümee der wesentlichen Ergebnisse

a) Arbeitspakete und Meilensteine

Arbeitspakete (AP), Bearbeitungszeitraum, Meilensteine (M) und Fälligkeit beziehen sich in der nachfolgenden Tabelle auf die Planung im Antrag.

AP	Bearbeitungszeitraum	Zielerreichung
AP 1 Konzept	09/2022 bis 08/2025	E1: Initiales Konzept für Lebensmittelketten fertig gestellt E2: Erste Version Anforderungskatalog fertig gestellt E3: Referenzarchitektur Datenplattform und KI-Dienste E4: Aktualisierter Anforderungskatalog fertig gestellt E5: Finales Konzept zu KI-Diensten in Lebensmittelketten E6: Finaler Anforderungskatalog fertig gestellt
AP 2 Datenhaltung/ Technische Plattform	12/2022 bis 02/2025	E1: Erste Version KINLI-Plattform einsatzbereit
AP 3 KI- basierte Dienste	12/2022 bis 06/2025	E1: Design der KI-Dienste-Architektur durchgeführt E2: Erste Version der KI-Dienste anwendungsbereit E3: Evaluation und Implementierung KI-Modelle E3: Prototyp KI-basierte Dienste und Modul zur Nachvollziehbarkeit umgesetzt
AP 4 Use Cases	12/2022 bis 07/2025	E1: Use Cases liegen als modellierte Prozesse vor E2: Datenerfassung und -aufbereitung abgeschlossen E3: Daten analysiert und ggf. transformiert E4: Ergebnisse in Nutzerstudien aufbereitet
AP 5 Evaluierung	09/2023 bis 08/2025	E1: Evaluierungskonzept fertig gestellt E2: Evaluationsergebnisse erste Phase vorliegend E2: Erkenntnisse in Anforderungsmanagement integriert E3: Evaluationsergebnisse zur finalen Phase liegen vor E3: Erkenntnisse in Anforderungsmanagement integriert E4: Lessons learned und Praxiserfahrungen dokumentiert
AP6 Sichtbarkeit/ Verwertung	09/2022 bis 08/2025	E1: Dokument zur Zielstellung und Planung liegt vor E1: KINLI Homepage ist online E2: Öffentlichkeitsarbeiten stattgefunden E3: Wissenschaftliche Veröffentlichungen vorhanden E4: Ziele für Öffentlichkeitsarbeit erfüllt E5: Ziele für wissenschaftliche Veröffentlichungen erfüllt E6: Wirtschaftliche Betrachtung liegt vor
AP7 Projekt-management	09/2022 bis 08/2025	Koordination des Konsortiums Sicherstellung Kommunikation und Zusammenarbeit Veranstaltungsorganisation

M	Fälligkeit	Zielerreichung
M 1	02/2023	Initiales KI-Konzept für Lebensmittelketten fertiggestellt Erste Version Anforderungsdokument erstellt und für Partner verfügbar

M	Fälligkeit	Zielerreichung
		Die Referenzarchitektur und -prozesse bezüglich Datenplattform und KI-Dienste erarbeitet Design der KI-Dienste-Architektur liegt vor Use Cases liegen als modellierte Prozesse vor Dokument zur Zielstellung und Planung für öffentlichkeitswirksame Aktivitäten liegt vor Die KINLI-Homepage ist online
M 2	02/2024	Aktualisierte Anforderungsdokument liegt vor Erste Version der KINLI-Plattform ist einsatzbereit Erste Version der KI-Dienste definiert und anwendungsbereit Datenerfassung und -aufbereitung sind abgeschlossen, Nutzung für die Use Cases Daten wurden analysiert und transformiert, Eingabe in Machine-Learning-Modelle Evaluierungskonzept fertig gestellt Erste Öffentlichkeitsarbeiten haben stattgefunden Erste wissenschaftliche Veröffentlichungen vorhanden
M 3	08/2025	Finales Konzept zu KI-Diensten liegt vor Finales Anforderungsdokument liegt vor Finale Referenzarchitektur ist spezifiziert KINLI-Plattform ist einsatzbereit und evaluiert Evaluation und Implementierung der KI-Modelle durchgeführt Demonstrator KI-basierte Dienste und das Modul zur Nachvollziehbarkeit sind umgesetzt Ergebnisse wurden in Nutzerstudien aufbereitet Evaluationsergebnisse zur ersten Evaluationsphase liegen vor, die gewonnenen Erkenntnisse sind in das Anforderungsmanagement eingegangen Evaluationsergebnisse zur finalen Evaluationsphase liegen vor, die gewonnenen Erkenntnisse sind in das Anforderungsmanagement eingegangen Lessons learned und Praxiserfahrungen dokumentiert Ziele für Öffentlichkeitsarbeit sind erfüllt Ziele für wissenschaftliche Veröffentlichungen sind erfüllt Wirtschaftliche Betrachtung liegt vor

b) Zusammenfassung

Durch das Forschungsprojekt KINLI konnte ein prädiktiver Ansatz zur Gewährleistung nachhaltiger Lebensmittelqualität durch Einsatz von KI konzeptioniert und anhand von zwei Use Cases entlang der Lieferkette in der Fleischverarbeitung, umgesetzt werden. Die entwickelten Lösungen demonstrieren die Möglichkeit zum frühen Erkennen von Herausforderungen und dem frühen Eingreifen in Prozesse. Dadurch schafft KINLI ein ressourcenschonendes Produzieren in der Agrar- und Lebensmittelwirtschaft. Zum einen demonstriert KINLI ein KI-gestütztes Managementsystem/ Assistenzsystem in der Tierhaltung am Beispiel Puten unter Berücksichtigung der Darstellung von Klima- und Verbrauchswerten in Echtzeit, der Ermittlung der Kotqualität, des durchschnittlichen Lebendgewichts der Herde sowie der Herdenaktivität. Zum anderen demonstriert KINLI eine KI-gestützte Lösung zur automatisierten Prozessoptimierung in der Lakedosierung im Rahmen der Kochschinkenproduktion sowie das Erkennen von optischen Abweichungen, in Form von destrukturierten Stellen, Blutpunkten, zu viel Fett- und zu viel Sehnenanteil, in der Rohware. Mittels der entwickelten KI-Anwendung kann die identifizierte Forschungslücke zum Teil geschlossen werden.

II. Ausführliche Darstellung der Ergebnisse

1. Erzielte Ergebnisse

Arbeitspaket 1: Konzept

Die HSNR hatte im AP1 einen Aufwand von 16 Personenmonaten und übernahm die Leitung des Arbeitspakets. Der Aufwand wurde geleistet und die erzielten Ergebnisse **voll erfüllt**. Zu diesen zählen das Initiale KI-Konzept für Lebensmittelketten, der Anforderungskatalog und die Referenzarchutektur und -prozesse bezüglich der Datenplattform und der KI-Dienste.

Die **Marktanalyse** wird initial im Winter 2022 bis Frühjahr 2023 erstellt. Weiterführende Untersuchungen werden im gesamten Projektverlauf durchgeführt. Im Folgenden werden die Ergebnisse der Marktanalyse zum aktuellen wissenschaftlichen Kenntnisstand und der Praxis im Bereich Einsatz von KI in Lieferketten aufgeführt. Der Einsatz von KI in der Landwirtschaft und Lebensmittelproduktion nimmt stetig zu. Besonders in der Tierhaltung und Fleischverarbeitung eröffnet diese Technologie neue Möglichkeiten, um Prozesse effizienter zu gestalten, die Tiergesundheit zu verbessern und Verluste zu minimieren. [ARAÚJO 2024] Der gezielte Einsatz von KI kann nicht nur die Produktivität steigern, sondern auch wirtschaftliche Verluste verringern. Zudem trägt die Technologie dazu bei, Ausschuss zu reduzieren und das Tierwohl nachhaltig zu verbessern. [HÄRTEL 2020] Unternehmen, welche sich mit KI-Anwendungen im Bereich der Geflügelhaltung beschäftigen werden, folgend exemplarisch skizziert**:** *Chickencheck* mit Ensatz von KI-gestützter Bilderkennung zur kontinuierlichen Überwachung des Gesundheitszustands und Verhaltens von Geflügel zur automatischen Erkennung von Anomalien wie Lahmheit oder Federverlust zur Verbesserung des Tierwohls. *Evonik Porphyrio* mit dem Projektnamen Lay-Insight und Broiler-Insight als cloud-basierte Software zur Tierdatenanalyse zur Produktionsoptimierung und zur Förderung von Tierwohl. *EW-Group* mit dem Projektnamen Genetic Optimization zur KI-gestützter Verbesserung von Zucht- und Haltungsbedingungen. *BigDutchman* mit Projektnamen BigFarmNet zur KI-gestützte Verhaltensanalyse für Schweine und Geflügel zur automatisierten Steuerung von Fütterung, Lüftung, Wasser- und Futterverbrauch zur Optimierung der Tierhaltung mit dem Ziel Produktionsprozesse zu optimieren, Kosten zu senken und Tierwohl zu fördern. *VedVis*e KI-gestützte Analyse Bild- und Videodaten von Tierbeständen (Schwein und Geflügel) zur Ableitung von Handlungsempfehlungen zur Verbesserung des Tierwohls und Steigerung der Farmeffizienz. Im Fokus steht die Anwendung zur Gesundheitsüberwachung und Automatisierung der Pflege beifolgenden KI- gestützten Projekten. *Projekt KAMI führt die* Atemüberwachung von Milchkühen mittels Wärmebildkameras durch. Das Projekt *smartMILC* setzt Tiefenkameras und Sensoren zur automatischen Gesundheitsüberwachung von Kühen ein und schafft eine Klimakontrolle im Stall und frühzeitiger Problemerkennung. Die Anwendung zum Fütterungs- und Reproduktionsmanagement steht bei folgenden Projekten im Fokus: *EVOLECTION* fokussiert den Einsatz von KI in der Schweinezucht. 3D-Kameras und Algorithmen analysieren Tierparameter, um die besten Zuchttiere auszuwählen und die genetische Qualität zu verbessern. Die Anwendung zur Überwachung der Haltungsbedingungen wird in folgenden Projekten betrachtet: *mAInZaun*

entwickelt ein KI-gestütztes autonomes Schutzsystems für Weidetiere mit Computer Vision, es erkennt Raubtiere und ergreift präventive Maßnahmen. Die Anwendung zur Überwachung von Geflügel explizit in der Putenhaltung wird neben des Projektes KINLI in wenigen weiteren Projekten untersucht. Dazu zählen beispielsweise die KI-basierte Lösung des akustischen Monitorings für Putenküken in Großbritannien. Die Analyse von Vogelvokalisationen erkennt Stress und Krankheiten anhand akustischer Muster. Ein exemplarischer Auszug zur Anwendung von KI in der Fleischverarbeitung zeigen folgende Lösungsansätze auf. Mit dem Fokus zur Automatisierung der Verarbeitung und Qualitätskontrolle ermöglich**t** *Marel AI Solutions* durch Maschinelles Lernen die Analyse der Fleischstruktur, Haltbarkeitsprognosen und Optimierung der Zerlegung. Mit dem Fokus der Lebensmittelsicherheit optimieren Cloud und IoT-Technologien die Rückverfolgbarkeit und Transparenz der Produktionsprozesse. Dabei analysiert die KI-Sensordaten, um Abweichungen frühzeitig zu erkennen und Produktionsfehler zu reduzieren. Zudem kann eine KI-gestützte Qualitätskontrolle mittels Computer Vision erfolgen, um Fremdkörper in Fleischprodukten zu erkennen und diese automatisch auszusortieren.
Basierend auf der durchgeführten Marktanalyse wird ein **initiales KI-Konzept für Lebensmittelketten** durch die HSNR erstellt und im Projektverlauf erfogreich in der Industry Science 4.0 veröffentlicht. Fokussiert wird das allgemeine KI-Konzept für Lieferketten, beschrieben am Beispiel Use Case zwei. Der Titel der Veröffentlichung lautet „Nachhaltige Lebensmittellieferketten durch Künstliche Intelligenz. Konzeptionelle Visualisierung am Beispiel von Puten zur Förderung von Tierwohl und Lebensmittelqualität.

Das **Anforderungsmanagement** wird differenziert in Anforderungen der Nutzergruppe des ersten und zweiten Use Cases sowie Anforderungen, welche sich durch Befragungen mittels Interviews von identifizierten Stakeholdern ergeben. Die durchgeführten Interviews erfolgen innerhalb des ersten halben Projektjahres mit Stakeholdern entlang der Lebensmittellieferkette von Fleischerzeugnissen. Dabei wurden vor allem die Lebensmittellieferkette betrachtet. Die Ergebnisse der Interviews werden folgend in Form von Clustern der Kernaussagen dokumentiert. Die untersuchten Aspekte lauten: Herausforderungen der Lebensmittelqualität und -sicherheit, Definition, Herausforderungen und Förderung von Tierwohl und -gesundheit, häufige Erkrankungen in Aufzucht und Mast von Puten, Entwicklung Landwirtschaft, Landwirtschaft und Digitalisierung, Situation Markt (Verbraucher und Handel), Ausschuss und Konfiskat in der Lieferkette, Potenziale KI in der Lieferkette, Potenziale ungenutzter Daten in der Lieferkette und potenzielle Barrieren in der Entwicklung von KI. Im Rahmen des durchgeführten Anforderungsmanagements mit dem Fokus auf die Anwendungspartner wird in Form von Interviews innerhalb des ersten Projektjahres sowie während regelmäßig durchgeführten Meetings im Projektverlauf durchgeführt. Aus den Anforderungen der Praxispartner ließen sich insgesamt zwei Use-Cases definieren. Der erste Use-Case wird durch die Firma Sauels bestimmt, in dessen sich wiederum zwei Epics eingliedern. Der zweite Use-Case ist definiert durch die Anforderungen der Firma Kolsert und umfasst vier Epics, welche in AP3 und 4 detailliert dargestellt werden. Als weiterführendes Ergebnis wird der ergänzende Anforderungskatalog pro Use Case dargestellt.

Weiterführendes Anforderungsmanagement | Use Case 1 | exemplarisch			
E	Neue Erkenntnis	Nutzungsanforderung	Technische Anforderung
E1	Die Nutzergruppe wünscht sich im Falle der Umsetzung einer Mittelung über Fleischfehler an der Linie, dass die Mitteilung den Arbeitsfluss für die Mitarbeiter:innen nicht stört.	Als Mitarbeiter:in an der Linie wünsche ich mir eine Mittelung über Fleischfehler, die ich erkennen kann, die mich aber nicht zu sehr aus meinem Arbeitsfluss bringt und mich bei meiner Arbeit stört.	Langfristig besteht die Installation von geeignetem technischem und eine hohe Wahrscheinlicht zur Erkennung sowie Benachrichtigung bei Vorliegen von Fleischfehlern, nach Art der Fehler.
E1	Zukünftig wünscht sich die Nutzergruppe präzisere Algorithmen zur Identifikation von Sehnen und Fettanteilen im Fleisch.	Als Mitarbeiter:in an der Linie wünsche ich mir genaue und wenig fehlerhafte Informationen zu erhalten, wenn die Fehler „zu viel Sehne“ sowie „zu viel Fett“ vorliegen.	Es werden weitere Test zur Verfeinerung der Datenaufzeichnung und Validierung der Erkennungstechnologien durchgeführt.
E2	Zukünftig wünscht sich die Nutzergruppe Live-Zugriffe auf die genaue Vorhersage der Injektionsrate.	Als Mitarbeiter:in mit wenig Erfahrung wünsche ich mir Live-Zugriff auf die Vorhersage der Injektionsrate, um die Lakedosierung besser einzuschätzen und mein Wissen zu verbessern.	Es werden aktuellen Datenaufzeichnungen am Fließband analysiert, um die Parameter für die Vorhersage zu optimieren.

Weiterführendes Anforderungsmanagement | Use Case 2 | exemplarisch			
E	Neue Erkenntnis	Nutzungsanforderung	Technische Anforderung
E3	Bei der Gewichtserfassung der Tiere über optische Vermessungs-technologie stellt die Waagenposition und Zugänglichkeit der Waage einen wichtigen Faktor dar.	Für die Nutzergruppe ist eine Technik wichtig, die das Tiergewicht richtig ermittelt und dadurch verlässlich ist.	Es werden Tests zur Verbesserung der optischen Vermessungstechnologie durchgeführt für eine genauere Gewichtserfassung.
E3	Bei frei zugänglichem Waage-Plateau können nahestehende oder die Waage berührende Puten zu fehlerhafter Gewichtseinschätzung führen.	Für die Nutzergruppe ist eine Technik wichtig, die das Tiergewicht korrekt ermittelt und dadurch verlässlich ist.	Die Waage wird durch die Verkleinerung des Plateaus modifiziert, so dass die Tiere nur noch von einer Seite auf die Waage steigen können.
E3	Der Kamerawinkel ist für die optische Vermessung des Tiergewichts entscheidend.	Als Landwirt:in und Techniker:in ist es wichtig für mich zu wissen, welche Anforderungen an die Waage und Kameraeinstellung bestehen, um eine Funktionalität der Technik gewährleisten zu können.	Durchführung unterschiedlicher Positionen mit anschließender Datenauswertung. Die Kameraposition darf nicht schräg sein, sondern sollte senkrecht ausgerichtet sein.
E3	Die Nutzergruppe erwähnt, dass die Tiere mit der Waagevorrichtung interagieren. Sie erregt	Die Waagevorrichtung bietet einen Nebeneffekt der Beschäftigung. Es muss auf Sicherheit und Eignung im Stall geachtet werden.	Die Interaktion der Tiere mit der Waagevorrichtung muss in der Auswahl und Anbringung der Technik beachtet werden.

Weiterführendes Anforderungsmanagement | Use Case 2 | exemplarisch			
E	Neue Erkenntnis	Nutzungsanforderung	Technische Anforderung
	Aufmerksamkeit. Ein entstehender Nebeneffekt ist eine Art des Beschäftigungs-materials.		
neu	Fragestellung, ob der erfolgte Ausbruch der Vogelgrippe anhand der untersuchten Parameter hätte erkannt werden können.	Als Landwirt:in is es von Interesse, ob ein eintretender Ausbruch der Vogelgrippe vor Beginn anhand von Stallparametern zu erkennen.	Es muss der zeitliche Faktor miteinbezogen werden, da die Erkrankung weniger Tiere ausreicht, um sich auf die gesamte Herde auszuweiten.

Die **Referenzarchitektur und -prozesse** der Plattform wird basierend auf dem Anforderungsmanagement gestaltet. Die Referenzarchitektur durchlief mehrere Iterationsschleifen. Zunächst wurde mit einem Aufbau auf den Standards des International Data Spaces (IDS) und GAIA-X geplant; im weiteren Verlauf ist jedoch eine spezialisiertere Architektur entworfen worden, die hauptsächlich auf den Anforderungen des Use Cases 2 basiert. Für Use Case 1 bestand kein Bedarf an einer Datenplattform und die technischen Gegebenheiten vor Ort (Sicherheitskonzepte) hätten diese zusätzlich limitiert. Daher ist das erste Epic in Use Case 2 zu einer Referenzarchitektur ausgebaut worden, welche mit z.B. GAIA-X kompatibel ist.

Arbeitspaket 2: Datenhaltung und Technische Plattform

Die HSNR hatte keine Aufwände im zweiten AP. Da die Ergebnisse die Grundlage zur Erfüllung von AP3 und AP4 bilden, werden diese dennoch komprimiert dargestellt.

Die erste Fassung der **Datenplattform Architektur** wurde mit bestehenden Technologien konzipiert. Im Frontend wird Streamlit eingesetzt, während im 4kend die Datenplattform aus dem vorangegangenen Forschungsprojekt CERES mit einer Postgres-Datenbank als zentrale Komponenten dienen. Für das Modelltraining sowie das Monitoring kommen Rapids.ai, Ray, Seldon (zur Drift-Erkennung), Label Studio und Fastai zum Einsatz, welche bereits in der bestehenden ProgressivKI Plattform integriert sind. Die Verwaltung und Bereitstellung der Modelle erfolgen über MLflow, ergänzt durch FastAPI für den Model-Serving-Prozess. Als Infrastruktur stehen GPU-Trainingsserver, Edge-Cloud-Lösungen und Docker zur Verfügung. Diese Auswahl bildet die Grundlage für die initiale Referenzarchitektur der Datenplattform. Die Datenplattform besteht aus zwei grundlegenden Komponenten: Die reine Datenplattform zur Datenhaltung in der Postgres-Datenbank und die Serviceplattform zum Trainig und Deployment von KI-Systemen mit ProgressivKI. In der Implementierung wird ein **Datenmodell** verwendet, um entweder nur Daten, die innerhalb der Richtlinien des Modells liegen, in der Datenplattform zuzulassen oder bei jedem Verstoß gegen die Richtlinien des Datenmodells wird dieses gemeldet und möglicherweise automatisiert berichtigt. Die bestehende Anforderung an das Datenmodell ist, dass es FAIR ist und dass es die Daten, die für die Nutzung der KI benötigt werden, vorverarbeiten kann. Hierzu ist es

notwendig, die im Training verwendeten Vorverarbeitungsschritte aus AP3 in die Datenplattform zu übertragen, damit sie automatisiert durchgeführt werden können. Aus der Datenanalyse für AP3 werden auch die Richtlinien definiert, die regelmäßige Werte der Daten bestimmen, wie es in Use Case 2, Epic 1 der Fall ist. Es stehen folgende Schritte zur Erstellung des Datenmodells voran:

- UC1 – E1: Analyse von Bilddaten, Vorverarbeitung und Nutzung des KI-Systems
- UC1 – E2: Sensordatenanalyse und Aufbereitung
- UC2 – E1: Tierwohlindikatoren und Analyse der Daten des Klimacomputers
- UC2 – E2: Analyse von Bildern und Labels sowie Vorverarbeitung und Nutzung des KI-Systems
- UC2 – E3: Analyse von Waagendaten, Bildern, sowie Nutzung des KI-Systems
- UC2 – E4: Analyse von Bilddaten, Vorverarbeitung und Nutzung der KI-Systems

Es wurde ein **Datenmodell anhand von Use Case 2** entwickelt, da hier eine direkte Notwendigkeit zur Datenmodellierung besteht. Um die Entwicklung an der **Datenplattform** im Rahmen der finalen Architektur und der Funktionen mit der Use Case Entwicklung zu vereinen, soll das Epic 1 aus Use Case 2 als erstes an die Sensordatenbank angebunden werden, welche die unterschiedlichen Datenquellen der Epics miteinander vereint. Die Architektur beinhaltet als zentralen Aspekt das Datenbankmanagementsystem**,** in dem die Daten aus den eingebundenen Systemen gespeichert werden. Aktuell gibt es zur Erfassung von Daten für das Ampelsystem einen Scraper, der Daten aus dem bestehenden Informationssystem sammelt. Diese Daten werden durch den Blockchain Proxy in die Datenbank eingespeichert, wobei sie vorher quellenspezifisch aufbereitet werden. Das Epic 1 liest die aufbereiteten Daten aus der Datenbank und visualisiert diese entsprechend den Nutzungsanforderungen. Zusätzlich wird die zweite Datenquelle, der Sensoren, direkt in der Datenbank gespeichert. Dabei werden wieder quellenspezifische Aufbereitungen durchgeführt. Über diese **modulare Architektur** können weitere Datenquellen angebunden werden. Die zentrale Komponente der Datenplattform ist die Datenbank, in der Sensordaten zu Use Case 2, Epic 1 auf verschiedenen Datenquellen gespeichert werden. Sensordaten und Messungen aus anderen Epics werden auch in der Datenbank gespeichert, während Bilddaten separat in Buckets mit einer Verbindung zu dem Labelingsystem LabelStudio gespeichert werden. Ein **Management Frontend** für die Datenbank bietet Informationen über die Datenbank und erlaubt ein einfaches Verwalten der Datenplattform. Die Anbindung an die ProgessivKI Plattform zur Entwicklung und Deployment von KI-Services ist erfolgt. Für die Ausführung der **KI-Services** wird hierbei auf Docker gesetzt. Die Images für die einzelnen Services werden hierfür über CI/CD Pipelines der GitLab Instanz erzeugt, welche dann auf einem entsprechenden Server oder direkt auf einem Edge Device deployed werden können. Dies kann entweder direkt durchgeführt werden oder automatisiert im Hintergrund. Dem Docker Container kann dann von Außen als Environment Parameter mitgegeben werden, welche KI-Modelle dieser beim Start laden soll und wo die Ergebnisse der Services gespeichert werden sollen. Hiermit kann der Prozess für das Anlegen eines Service modularisiert werden. Zusätzlich bietet das Management Dashboard verschiedene Analysen zu Daten und zeigt die Ergebnisse und deren Interpretation der KI-Services/ Ergebnisse an. Die KI-Services selbst können in verschiedenen Arten auftreten. Dies kann ein Service sein, welcher im Hintergrund arbeitet und Daten analysiert

und nur dann aktiv wird, wenn Auffälligkeiten erkannt werden. Ist dies der Fall, werden an die jeweiligen Nutzer Nachrichten versendet. Services können aber auch eine aktive UI haben, bei denen die jeweiligen Ergebnisse in Echtzeit angesehen werden können. KI-Services können aber auch inkrementell in zuvor festgelegten Zeitabständen die jeweiligen Vorhersagen oder Empfehlungen generieren und diese in der Datenplattform speichern und dann über das Dashboard oder eine entsprechende UI sicht- und nutzbar machen. Auch andere Services spielen ihre Ergebnisse zurück an die Datenplattform. Die KI-Services erhalten ihre Daten nicht direkt von der Quelle, sondern von der Datenplattform. Diese kann die Daten vorverarbeiten, damit der eigentliche Service nur noch mit der Vorhersage bzw. der Auswertung der Daten beschäftigt ist. Hierdurch werden die versendeten Daten über das Internet minimiert. Bei besonders zeitkritischen Services ist es möglich, dass der Umweg über die Datenplattform nicht verwendet wird und direkt mit einem Edge-Device kommuniziert wird. Hierbei muss sich dann der Service darum kümmern, dass die entsprechenden Daten in die Plattform geladen werden. In beiden Fällen muss aber dafür gesorgt werden, dass ein Quellsystem in nicht zu kurzen Abständen einen Service triggert. Damit soll verhindert werden, dass ein Nutzer die immer wieder identische Auffälligkeit mitgeteilt wird, obwohl dieser diese schon erhalten hat. Erzielt wurde die **Integrierung von Blockchain**. Das Blockchainkonzept wird in einer flexiblen Architektur umgesetzt, die eine Blockchain-API und einen Blockchain-Proxy enthält. Die Blockchain-API protokolliert sicher die Einzelheiten der KI-Prozesse, von Trainingsdaten bis hin zu Modellen und KI-Entscheidungen und sichert die Datenintegrität durch Speicherung einzigartiger Hashes auf der Blockchain. Zusätzlich nutzt sie das Interplanetary File System für verbesserte Datenspeicherung und Zugänglichkeit. Der Blockchain-Proxy verbindet diese API mit Datenconnectoren und sichert die Integrität der Daten, indem Hashes neu eintreffender Daten in Echtzeit oder nach festgelegtem Zeitplan an die Blockchain übermittelt wird. Die Entscheidung, Datenbanken in einer späteren Phase des Projekts zu integrieren, stellte zeitliche und gestalterische Herausforderungen dar, da dieser Wechsel eine vollständige Neugestaltung der Blockchain-Komponenten erfordern würde. Während Buckets Daten in regelmäßigen Zehn-Minuten-Intervallen speichern und dadurch das Hashing zur Sicherung der Datenintegrität vereinfachen, müssten für Datenbanken vordefinierte Datensegmente zum Hashing festgelegt werden. Jegliche bewussten Änderungen innerhalb dieser Segmente über das Management-Frontend würden die Nachverfolgung der Daten verkomplizieren. Darüber hinaus könnten mögliche Optimierungen in Zeitreihendatenbanken, wie die Komprimierung älterer Datenpunkte, das Auffinden spezifischer Datenpunkte erschweren. Dies führt zur Beeinträchtigung der Sicherheit und Rückverfolgbarkeit der Daten auf der Blockchain. Es wurde beschlossen, die bestehende Struktur mit den Rohdaten beizubehalten und diese nicht mit der Datenbank zu verbinden, um die Blockchain-Funktionalitäten mit den durch den Scraper gesammelten Rohdaten zu demonstrieren und einen schlanken Ansatz zu gewährleisten, der die derzeitige Integrität und Nachverfolgbarkeit der Rohdaten sicherstellt. Die Blockchain-Verifizierung der Daten ist aufgrund der mit jedem Upload verbundenen Kosten und des Zeitaufwands auf bestimmte Intervalle begrenzt. Um Effizienz und Kosteneinsparungen zu erreichen und dennoch die Funktionalität zu demonstrieren, wurde entschieden, die Integrität der Daten nur für festgelegte Zeiträume zu sichern.

Durch die Definition von Zeitfenstern, in denen Daten gesammelt und anschließend als Hash auf der Blockchain gespeichert werden, entsteht jedoch ein Zeitpuffer, der theoretisch Manipulationen zwischen den Intervallen ermöglichen könnte. Diese Balance zwischen Sicherheit und Kosteneffizienz erforderte eine sorgfältige Gestaltung der Blockchain-Komponenten, wobei die Größe der gesicherten Datenpakete gezielt gewählt wurde, um die Anzahl der Transaktionen zu minimieren und dennoch die Integrität zu gewährleisten. Eine neue Funktionalität im Blockchain-Proxy ermöglicht es, ein **Non-Fungible Token (NFT)** für die gespeicherten Daten zu erstellen und somit eine digitale Repräsentation des Eigentums zu schaffen. Dadurch entstehen zusätzliche Optionen, wie etwa die Monetarisierung der Daten, da das NFT als beweisbares Zertifikat für den Besitz dient und den Handel sowie die Nutzung der Daten in weiteren Anwendungen vereinfacht. Dies erweitert die Anwendungsfälle der Blockchain und eröffnet **neue wirtschaftliche und praktische Möglichkeiten**. Folgend wird die angestrebte Anbindung an **GAIA-X-konforme Datenräume** dargestellt. Die Datenplattform kann mithilfe eines Datenconnectors an einen beliebigen Datenraum angebunden werden, insofern dieser Connector die Richtlinien des gewählten Datenraumes erfüllt. Eine Implementierung eines entsprechenden Eclipse Dataspace Connectors wurde umgesetzt und steht zur Verfügung. Über diesen Connector könnten Assets, die Daten aus der Datenplattform referenzieren, angelegt werden. Da im Projektzeitraum kein geeigneter Datenraum identifiziert werden konnte, der als Ziel für eine Anbindung angesteuert werden könnte, steht eine notwendige Anpassung dieses Connectors an einen entsprechenden Datenraum aus. Ein **Datenmanagement Frontend**, in dem die Datenplattform allgemein verwaltet werden kann, wurde entwickelt.

Arbeitspaket 3: KI- basierte Dienste

Die HSNR hatte keine Aufwände im dritten AP. Die Arbeiten aus AP3 überschneiden sich jedoch stark mit den Arbeiten aus AP4 Use Cases, welches die HSNR leitet. **Aufgrunddessen werden zur besseren Nachvollziehbarkeit die Ergebnisse aus AP3 folgend gemeinsam mit den Ergebnissen aus AP4 dargestellt.** Die jeweiligen Use Cases wurden unter Berücksichtigung der erhobenen Anforderungen und Daten der Anwendungspartner konzipiert. Im Rahmen des **UC 1 in der verarbeitenden Fleischwirtschaft** wird innerhalb eines Use Cases zwei Epics experimentell erarbeitet. Diese Epics verfolgen das Ziel, die Lebensmittelqualität und -sicherheit in der Kochschinkenproduktion zu steigern. **Epic 1 fokussiert das systematische Erkennen von fehlerhaften Stellen in Fleischstücken** unter Berücksichtigung von Vorliegen von Blutpunkten, destrukturierten Stellen, zu viel Sehnenanteil und zu viel Fettanteil. Eine zu große Anzahl von fehlerhaften Stellen in dieser Rohware führt zu einem erhöhten Ausschuss am Ende der Produktion. Die fehlerhaften Stellen umfassen die Klassen fettig, destrukturiert und blutig. Zusätzlich unterscheiden sich die untersuchten Fleischstücke auch in ihrer generellen Beschaffenheit, z.B. Stücke aus Unter- oder Oberschale. Zu Beginn der Arbeiten sind einzelne Fleischstücke auf einem blauen Untergrund (gleiche Farbe wie der spätere Steigförderer) händisch abgelegt und vom Praxispartner fotografiert worden. FIT stellte eine Label-Studio-Instanz bereit, in der die Bilder manuell hochgeladen werden und im Nachgang gelabelt werden konnten. Dabei

handelt es sich um eine gängige Open-Source-Lösung, die auch für die anderen Epics im Bereich Bildverarbeitung eingesetzt wurde. Die vorliegende Herausforderung ist in die Kategorie Objekterkennung einzuordnen; es sollen im Bild die fehlerhaften Stellen innerhalb einer Bounding-Box gefunden und einer Klasse zugeordnet werden. Bei dieser ersten Stichprobe wurden etwa 450 Bilder annotiert und erste Experimente mit dem YOLOv7-Modell durchgeführt. Dabei handelt es sich um eine etablierte Python-Bibliothek zur Objekterkennung, die die Anpassung von vortrainierten Modellen auf eigene Daten erlaubt (Transfer-Learning). Erste Ergebnisse waren vielversprechend, zeigten jedoch auch Herausforderungen mit einigen Klassen auf, da die Stichprobe ungleich verteilt war. Parallel dazu fanden Untersuchungen statt, die fehlerhaften Stellen im Fleisch mithilfe von verschiedenen Beleuchtungen und Spektraldaten besser sichtbar zu machen. Für die Klassen blutig und fettig zeigten diese Arbeiten verlässliche Ergebnisse. Da dieser Entwicklungspfad aber nicht Teil der ursprünglichen Vorhabensbeschreibung war, wurde er nach dieser Proof-of-Concept-Phase eingestellt. Für die nächsten Schritte ist ein Rechner konfiguriert und bestellt worden, welcher über eine passende GPU verfügt. Dieser sollte beim Anwendungspartner eingesetzt werden, um mit einer Kamera Bilder am Steigförderer sowohl aufzunehmen als auch später die Objekterkennung mittels KI in Echtzeit ausführen zu können. Im Anschluss wurde eine Kamera von IDS am Förderband positioniert und in mehreren Iterationen ausgerichtet, um die Fleischstücke möglichst gut aufnehmen zu können. Dies stellte die Beteiligten vor eine Herausforderung, da Winkel, Fokus und andere Schwierigkeiten wie Kondensat viele Positionierungs- und Konfigurationsversuche erforderten.

Bevor neue Bilder in größerer Menge aufgenommen werden konnten, mussten diese Herausforderungen behoben werden, da unscharfe Bilder beim Training des KI-Modells zu schlechter Performanz führen. Darüber hinaus wurde eine Software zur Ansteuerung der Kamera implementiert, damit diese nur Bilder aufnimmt, wenn das Förderband in Betrieb ist (Anbindung an die SPS der Anlage). Zusätzliche Funktionen dieser Software sind die Möglichkeit, sich das letzte aufgenommene Bild live anzeigen zu lassen, die Steuerung der Bandgeschwindigkeit (daraus resultierend die Frame-Rate) sowie Zuordnung zum jeweiligen Fleischtyp. Die auf den Computer vor Ort ausgebrachte Software sammelte folglich automatisiert Bilder aus der Zielumgebung und übertrug sie auf die Datenplattform, damit sie wieder in Label-Studio annotiert werden konnten. Zusätzlich entfernte sie leere Bilder ohne Fleisch, um nicht unnötig Daten ohne Relevanz an die Datenplattform zu schicken. Insgesamt sorgte die lange Lieferzeit der Kamera sowie die vielen Iterationen zur Positionierung und Integration an die bestehenden Systeme zu einer mehrmonatigen Verzögerung. Die im Anschluss aufgenommenen Daten wurden händisch, unterstützt durch HSO und HSNR, gelabelt sowie mit den Domänenexperten geprüft. Ein neues KI-Modell wurde trainiert und als Service samt Web-Oberfläche auf dem Rechner an der Produktionslinie installiert. Vor allem fettige Stellen lassen sich gut erkennen; Herausforderungen gab es weiterhin mit sich leicht verschlechternder Bildqualität durch Kondensat oder Reinigungsarbeiten. Um die Erkennung für destrukturierte Stellen zu optimieren, sind perspektivisch weitere Trainingsdaten nötig, da diese in den am Band aufgenommenen Bildern weiterhin unterrepräsentiert waren. **Epic 2 erzielt die Bestimmung der korrekten Trefferquote**

von Lake zur Zugabe in Fleischstücke unter Berücksichtigung zur Vermeidung von Über- und Unterdisuerung, vermindeter Textur im Schinken sowie einer ggf. geringeren Haltbarkeit. In diesem Epic sollten die Einstellungen des Lake-Injektors optimiert werden. Als Basis dienen dazu verschiedenen Rezepten und historischen Daten. Dieses Epic wurde gemeinsam mit der HSNR konzipiert. Die Entwicklung wurde hauptsächlich durch HSO durchgeführt. FIT hat die notwendigen Prozesse und Tools aus AP2 der Datenplattform bereitgestellt, um eine Entwicklung dieses Epics in der Referenzarchitektur zu ermöglichen. Darüber hinaus installierte FIT die als KI-Service samt Web-Oberfläche bereitgestellte Software auf dem in Epic 1 beschriebenen Rechner an der Produktionslinie des Anwendungspartners.

Innerhalb des **Use Case 2 Stallmanagement Tierhaltung zur Förderung von Tiergesundheit und Tierwohl** werden insgesamt die folgenden vier Epics experimentell erarbeitet. **Epic 1 namens Ampelsystem** forciert die Datenaufnahme und -auswertung zur visualisierenden Auskunft über die bestehende Momentaufnahme im Stall sowie zur Prognose von zukünftigen Handlungsmaßnahmen. In diesem Epic soll die Putengesundheit im Stall überwacht und vorhergesagt, indem durch eine Vielzahl von Sensoren die Situation im Stall ausgewertet wird. Ziel ist es, Abweichungen (z.B. im Temperaturbereich oder Futter-Wasser-Verhältnis) rechtzeitig zu identifizieren und agieren zu können, bevor weitere Herausforderungen auftreten. Gestalterisch ist diese Überwachung als „Ampelsystem“ umgesetzt, das bei entsprechend großen Abweichungen (mit Domänenexperten und Literatur bestimmt) die Zustände in den Ställen entweder grün, gelb oder rot markiert. Die Konzeptionierung wurde durch die HSNR bereitgestellt. Die Entwicklung ist hauptsächlich von HSO durchgeführt worden. FIT hat die in AP2 definierte Datenplattform anhand des Ampelsystems weiter ausgebaut, welche die Grundlage für weitere Epics bildet. Nachdem zunächst nur S3-Buckets genutzt wurden, ist innerhalb der Laufzeit dieses Arbeitspaketes auch eine Zeitreihendatenbank für weitere Sensorik und Performanzverbesserungen eingebaut worden. Darüber hinaus wurde seitens FIT eine Sensorbox entwickelt und an die Datenplattform angeschlossen, sodass das Ampelsystem angereichert werden konnte. Folgende KI-Modelle und Ansätze wurden in der Entwicklung des ersten Epics verwendet. ARIMA, Prophet, XGBoost, LSTM, TimesFM und PatchTST mit verschiedenen LLM als Basis zur Realisierung der univarianten Vorhersage. Zur multivariaten Vorhersage wurden die Ansätze ARIMA, Prophet, XGBoost, LSTM und TimesFM gewählt. Die Idee hinter der Verwendung von LLM als Vorhersage Modell, liegt in der Chance, dass diese nicht trainiert werden müssen. Andernfalls müsste für jeden Stall ein eigenes Modell trainiert werden und eine entsprechende Datenvorbereitung sowie Parameteroptimierung durchgeführt werden. Ebenso ist die vorhandene Datenlage nicht ausreichend, um hinreichend mächtig Modelle zu trainieren. In Betracht gezogen wird dabei die univariate Vorhersage von Wasser und Futter, da diese mit weniger Aufwand umgesetzt werden kann und dabei vergleichbare Ergebnisse liefert. Gute Ergebnisse zeigten dabei XGBoost, ein LSTM sowie TimesFM. Die Integration der Modelle wurde softwaretechnisch umgesetzt, jedoch nicht in den Produktivbetrieb übernommen, da anhaltende Herausforderungen bei der Datenerfassung bestanden. Damit eine Bewertung der Daten aus dem Stall vorgenommen werden kann, wurden die vorhandenen Werte aus jedem Stall nach einzelnen Wochen gruppiert und der Durchschnitt gebildet. Anschließend wurde basierend auf Six-

Sigma die einzelnen Grenzwerte berechnet. Die schlussendlichen Grenzwerte werden anhand der Standardabweichung gebildet und davon abgezogen bzw. addiert. Für die Ampelfarbe grün ist dies die einfache Standardabweichung, für die Farbe gelb die zweifache und für die Farbe rot die dreifache Standardabweichung. Das **Epic 2 Kotqualität** erzielt die kontinuierliche Bildaufnahme und -auswertung zur Auskunft über Vorliegen von nicht konformem Kot zur Feststellung möglicher Krankheitsbilder sowie zur Analyse der Futterverwertung und Wasseraufnahme. In diesem Epic ist eine KI-basiertes Software entwickelt worden, um die Qualität von Putenkot anhand von Bilddaten zu bestimmen. Da Kotveränderungen auf Krankheiten hinweisen können, soll dieses System eine automatisierte und kontinuierliche Analyse durchführen, die eine derzeitig stattfindende, tägliche Sichtkontrolle unterstützt. Mittels hochauflösender Kamerabilder wird der Kot in bestimmte Qualitätskategorien eingeordnet – es handelt sich hierbei also um ein Klassifikationsproblem. Bei Auffälligkeiten kann der Landwirt zeitig benachrichtigt werden und frühzeitig Gegenmaßnahmen ergreifen. Für dieses Epic wurde ein hoher Nutzen identifiziert, jedoch ist die technische Umsetzung gleichzeitig als schwierig einzuordnen. Anfangs ist eine Web-Applikation entwickelt und online bereitgestellt worden, mit der sowohl von einem Rechner als auch einem Mobiltelefon Bilder an die Datenplattform übermittelt werden können. Durch Kolsert sind vier Abstufungen in der Kotqualität jeweils im Bereich fäkal und zäkal festgelegt worden (basierend auf Erfahrung und dem “Kot-Quartett”), die in verschiedenen Kombinationen vorkommen können. Während Kotqualitäten der Klasse eins auf einen guten Zustand hindeuten, kann Klasse zwei auf erste, leichte Probleme hinweisen. Klasse drei ist deutlich schlechter und Klasse vier schließlich als schlechteste Qualitätsstufe zu bewerten. In der Web-Applikation können die Kotbilder direkt mit der zuvor beschriebenen Qualitätsstufe annotiert werden. Darüber hinaus werden Alter der Tiere, das Datum der Aufnahme sowie Einstreu und Stallname erfasst, um bei Bedarf Bilder auch wieder löschen zu können. Eine Schulung für die Beteiligten wurde durchgeführt, sodass verschiedene Entitäten mit der Akquise-App vertraut waren. Nachdem erste Bilder verfügbar waren, ist mit dem Aufsetzen der KI-Pipeline gemäß Referenzarchitektur begonnen worden, wissend, dass bei der gegebenen Datenlage noch keine generalisierten Modelle entstehen konnten. Das Aufbereiten, Filtern und Augmentieren der Daten wurden in einer ersten Version implementiert. Zusätzlich sind die Berechnung verschiedener Metriken wie beispielsweise die Klassenverteilung innerhalb der Trainingsdaten sowie die Bereitstellung des noch unfertigen KI-Modells als Web-Service-Backend erfolgt. Eine Web-Oberfläche zur Prädiktion von Bildern ist an dieses angeschlossen worden. Diese Schritte erlaubten einen schnelleren Iterationszyklus, sobald neue Trainingsdaten vorlagen. Die erste große Menge an Bilddaten (ca. 1000 Stück) lag erst in der zweiten Projekthälfte vor. Von dort aus sind tiefgehende Analysen und Experimente durchgeführt worden. Darunter zählt beispielsweise die Untersuchung der Bilder auf “Ähnlichkeit” mittels Dimensionsreduktion- und Clustering-Verfahren (PCA, TSNE, K-Means). Es stellte sich heraus, dass der Hintergrund des Bildes einen zu hohen Anteil an der Klassifikation hatte; die Arbeiten von HSO im Bezug auf Nachvollziehbarkeit für das Epic unterstützten diese Feststellung. Um dieses Problem zu mildern, ist das KI-Modell in ein zweistufiges Modell umgebaut worden. Ein erstes Modell (YOLO-Variante) erkennt nur den Kot als solches im Bild, innerhalb einer Bounding-Box, kann aber nur die

Unterscheidung zwischen Kot und Hintergrund treffen. In einem nachgelagerten Modell (MobileNet, ResNet) wird dieser zuvor detektierte Bereich dann nach fäkal und zäkal (je eins bis vier) klassifiziert. Dies erforderte allerdings eine nachgelagerte Annotation mit Bounding-Boxen aller bestehenden Bilddaten mittels Label-Studio. Das so aufgebaute, zweistufige Modell war besser in der Lage, die entsprechende Kotqualität zu bestimmen und nicht so sensitiv auf den Untergrund zu reagieren. Eine weitere Herausforderung blieb jedoch die Verfügbarkeit der Trainingsdaten. Für die gewünschte Abstufung in die jeweils vier Klassen lagen mit etwa 1000 Bildern nicht genug Daten vor. Darüber hinaus sind diese Bilder nicht gleichmäßig über die Klassen verteilt. Zum einen ist dies ein positiver Umstand im Stall, dass vor allem in den sehr schlechten Klassen kaum Bilder vorlagen. Zum anderen bedeutet dies, dass die KI nicht genug generalisieren kann. Daher hat der Partner HSNR ab November 2024 selbständig in mehreren Besuchen Bilder im Putenstall aufgenommen. Diese und weitere vom Praxispartner bereitgestellten Bilddaten wurden durch Unterstützung von HSO und HSNR in den entsprechenden Tools händisch annotiert, sodass schließlich etwa 3000 Kotbilder zur Verfügung standen. Es sind im Anschluss verschiedene State-of-the-Art Modellarchitekturen (Transfer-Learning) experimentell evaluiert worden, und es war weiterhin beobachtbar, dass bestimmte Klassen nicht gut eingeordnet werden konnten. Daher ist ein Software-Tool geschrieben worden, welches die Kotbilder nach Klassen in eine Kacheloptik “stitched”, sodass man auf einen Blick alle Bilder der Klasse sehen kann. Per Mausklick können dann einzelne Bilder angeklickt und ihr Label angepasst werden. Bilder von schlechter Qualität (Farbfehler, Grünstich) können entfernt werden; in der KI-Pipeline werden zudem verschwommene Bilder automatisch entfernt. Mit den händisch so nochmals nachkontrollierten Trainingsdaten hat sich die Modellperformanz deutlich verbessert. Allerdings zeigten sich weiterhin für die Randklassen (Abstufung drei bis vier) Probleme bei der Klassifikation. Zum einen ist es auch als Mensch nicht immer eindeutig feststellbar, ob ein Kotbild eher auf Stufe eins/zwei oder drei/vier einzuordnen ist, da die Grenzen nicht absolut scharf sind. Zum anderen sind die Bilder in eben diesen Randbereichen weiterhin stark unterrepräsentiert (es bestehen relative Häufigkeiten zwischen den Klassen von 25% bis unter 1%). Um das Problem weiter auf die Stichprobenverteilung einzugrenzen, sind Experimente durchgeführt worden, die ein KI-Modell für jeweils nur zwei Klassen trainiert haben. Dort zeigte sich, dass sich die Metriken bei entsprechend gleich verteilten Daten verbesserten. Daraus ist abzuleiten, dass dieses Epic grundsätzlich technisch umsetzbar ist, für eine robuste Erkennung der vor allem sehr schlechten Klassen vier im Bereich fäkal und zäkal aber deutlich mehr Trainingsdaten benötigt werden. Hier liegt großes Potenzial vor - auch über das Projektende hinaus - weiter kontinuierlich Trainingsdaten zu erfassen, da es keine vergleichbaren, öffentlich zugänglichen Sammlungen gibt. **Epic 3 Durchschnittliches Tiergewicht** erzielt die kontinuierliche Bildaufnahme und gibt Auskunft über das durchschnittliche Lebendgewicht der Tiere zur Feststellung der Futterverwertung und Schachtreife. In diesem Epic ist ein KI-basiertes System zur optischen Bestimmung des durchschnittlichen Lebendgewichtes von Puten entwickelt worden. Gängige Messmethoden sind oft ungenau (Pendelwaage) oder erfordern ein aufwändiges Eingreifen (manuelles Wiegen). Eine kontinuierliche, automatische Erfassung erlaubt verlässlichere Aussagen zu auftretendem Über- oder Untergewicht. Zu Beginn der Arbeiten sind zwei

fernsteuerbare Kameras mit 4K-Auflösung gekauft und im Stall des Anwendungspartners Kolsert angebracht worden. Eine Software ist entwickelt worden, welche die beiden Kameras zyklisch an vordefinierte Positionen fährt (Pitch, Roll und Zoom-Level), Bilder aufnimmt und diese an die S3-Buckets der Datenplattform übermittelt. So wurden automatisiert Bilder von Tieren auf der Pendelwaage aufgenommen. Parallel bestand eine Herausforderung mit dieser Pendelwaage; sie verfügte nicht über offene Schnittstellen, sodass es nicht möglich war, den aktuellen Messwert abzufragen und zusammen mit dem aufgenommenen Bild zu speichern. Daher ist ein Beschaffungsprozess für eine neue Waage angestoßen worden. Nach der Installation im Stall wurde ein Software-Modul implementiert und auf dem Server von FIT bereitgestellt, welche die Waagendaten über eine Web-Schnittstelle abfragbar macht. Damit konnten Bilder zusammen mit Gewichtsdaten (Ground-Truth) kombiniert aggregiert und gespeichert werden. Die Partner HSO und HSNR haben im Anschluss dabei unterstützt, die gewonnen Bilddaten zu annotieren. Experimentelle Versuche mit State-of-the-Art Vision-Modellen wie SAM2 wurden durchgeführt, um die Puten im Bild zu segmentieren und anschließend mit dem Gewicht zu korrelieren. Allerdings bereiteten die Perspektive der Kamera (schräg) sowie die Verdeckung der Tiere durch Metallstäbe der Pendelwaage und weitere Tiere in der Nähe der Waage Herausforderungen, eine verlässliche Detektion zu ermöglichen. Daher wurde sich dazu entschlossen, eine neue Kamera direkt über der Waage anzubringen (Draufsicht). Der zuvor skizzierte Prozess begann damit erneut, Bilder zusammen mit Gewichtsdaten aufzunehmen und gemeinsam mit den Forschungspartnern zu annotieren. Die Arbeiten an einem neuen KI-Modell mit diesen Daten erfolgte dann hauptsächlich über die HSO. FIT hat weiterhin Unterstützung geleistet bei Akquise und Management der Kamera und Bereitstellung der Software-Tools. Während der Nutzen als sehr hoch eingeschätzt wird, gilt die technische Umsetzbarkeit als anspruchsvoll. Es wurden mehrere KI-Modelle verwendet, um das Gewicht bestimmen zu können. Zuerst muss hier die Waage im Bild erkannt werden. Masking Methoden versprechen keinen Erfolg, da sich die Waage im Bild bewegt und somit fixe Masken nicht möglich sind. Deshalb wird ein KI-Modell verwendet, welches die Waage selbst erkennt. Da sich die diese nicht einem rechten Winkel zu den Bildkaten befindet und sich bewegen kann, muss ein spezielles Modell zur Objekterkennung verwendet werden. Verwendet wurde ein YOLO OBB (Oriented Bounding Boxes) und ein Modell von MMRotate. Diese wurden miteinander verglichen. Zur Erkennung der einzelnen Tiere wird ein Segmentierungsmodell verwendet. Hierfür kommen Modelle aus der YoloV11-Seg Familie sowie aus der MMDetection Bibliothek zum Einsatz. Für die Bestimmung des Gewichts wird ein Convolutional Neural Network (CNN) verwendet. Hierbei werden vortrainierte Modelle aus der Keras Bibliothek sowie ein Vision Transformer verwendet. Die Modelle werden jeweils angepasst und entsprechend mit Transfer Learning auf den Use Case trainiert. Die Vorhersage wird alle fünf Minuten automatisch angestoßen, dabei wird ein Bild aus dem Stall aufgenommen und durch das Segmentierungsmodell und das Gewichtsmodell gegeben, um eine Vorhersage zu erhalten. Die einzelnen Vorhersagen werden anschließend im Epic 1 integriert und zusätzlich in einer Datenbank gespeichert. Mit diesen Werten kann der Durschnitt der letzten 24 Stunden berechnet werden. **Epic 4 Herdenverhalten** fokussiert die kontinuierliche Bild- und Videoaufnahme und identifiziert das

Tierverhalten und Auffälligkeiten. Basierend darauf wird die Auskunft über die allgemeine Mobilität und Agilität der Herde zur frühzeitigen Erkennung von Pickverhalten (Schäden wie Nasenzapfen-Picken, Federziehen und Hautschädigungen) ermöglicht. In diesem Epic sollte ursprünglich das Verhalten der gesamten Herde und einzelner Aggressoren analysiert werden. Die Identifikation und anschließende Verfolgung einzelner Tiere sind technisch nur sehr schwer bis nicht machbar – zusätzlich stellte sich die Frage, falls einzelne Tiere tatsächlich als Aggressoren über längere Zeit identifiziert werden, wie diese dann vom Rest der Gruppe getrennt werden könnten. Daher ist dieses Epic umformuliert worden, um die Herde als Ganzes zu betrachten. Nach der Installation zweier Kameras im Putenstall des Praxispartners Kolsert ist eine davon so konfiguriert worden, dass sie einen Überblick über die gesamte Herde von der Mitte des Stalls bietet. Sie ist mittig unter dem Dach positioniert und kann automatisiert in beide Richtungen der Halle Bilder aufnehmen. Anfangs ist eine Software basierend auf klassischer Bildverarbeitung implementiert worden. Dabei wurde mithilfe einer Heatmap der prozentuale Weißanteil der Fläche (Puten) im Bild berechnet. Zusätzlich ist es über ein Softwaremodul samt Frontend - integriert in das Ampelsystem-Frontend - möglich, im Kamerabild freihändig Polygone im Bild einzuzeichnen, so Segmente zu definieren und diesen einen Namen zuzuweisen (z.B. Futterbereich 1). Für diese definierten Segmente wird dann in einem wählbaren Intervall (z.B. alle 60 Sekunden ein Bild) sowie Sliding-Window (z.B. zehn konsekutive Bilder) der prozentuale Weißanteil berechnet. So lassen sich über die Zeit Aussagen zum mengenmäßigen Zu- und Abfluss von Tieren in diesen Segmenten treffen; der aktuelle Trend (zunehmend, abnehmend, gleichbleibend) ist ebenfalls in der Web-Anwendung zu sehen. Diese Implementierung ist im weiteren Verlauf durch ein KI-Modell abgelöst worden. Um die Anzahl der Puten im Kamerabild bestimmten zu können, sind verschiedene Segmentierungsmodelle getestet worden (u.a. SAM2 und weitere Derivate). Schließlich wurde sich für CountGD entschieden, ein für das Zählen beliebiger Objekte optimiertes Vision-Transformer-Modell. Dieses gibt nun nicht nur den groben prozentualen Teil weißer Fläche pro Segment an, sondern kann die einzelnen Tiere detektieren und zählen. Die pro Segment ermittelten Summen und Trends werden ebenfalls in die Zeitreihen-Datenbank der Datenplattform geschrieben, um sie weiter auszuwerten und kombiniert anzuzeigen. Die HSNR unterstützte stark in dem Annotieren der Trainingsdaten. Weitere Arbeiten in diesem AP zur Bewegungsaktivität der Puten sind von HSO durchgeführt worden. Die Umsetzbarkeit und der Nutzen werden als hoch, jedoch in der Realisierung als herausfordernd eingeschätzt. In Ergänzung wurden verschiedene Ansätze zur Verfolgung der Tiere untersucht, die von traditionellen Computer-Vision-Algorithmen, die auf einfacher Bildverarbeitung basieren, bis hin zu fortschrittlicheren Deep-Learning-Verfahren reichten. Die traditionellen Methoden waren jedoch für den Datensatz nicht geeignet, so dass neuere, auf Deep Learning basierende Algorithmen für die Verfolgung mehrerer Objekte (Multi Object Tracking, MOT) eingesetzt werden mussten. Zu diesem Zweck wurde eine umfassende Pipeline für die Vorverarbeitung des Datensatzes, das Modelltraining und die Auswertung entwickelt. Das System ist in der Lage, Tiere in einem bestimmten Gebiet zu zählen, ihre relative Geschwindigkeit zu messen und ihre Gesamtaktivität mit einem Bewegungsgraphen und Zeitstempeln zu analysieren. Zur Bewertung der Verfolgungsgenauigkeit wurden einzelne Frames der Videoaufnahmen manuell

annotiert, um den Ground-Truth zu ermitteln. Mehrere hochmoderne MOT-Algorithmen wurden implementiert und getestet, um ihre Leistung zu vergleichen. Hierbei hat sich der auf die Putenvideos angepasste Algorithmus DeepSort als bestes herausgestellt.

Arbeitspaket 4: Use Cases

Die Leitung von AP4 wurde durch die HSNR durchgeführt. Der personelle Aufwand von nen Personenmonaten wurde **voll erfüllt**. Die Ergebnisse zur Detaillierung der KI-Dienste, die Umsetzung derer in einem Prototyp wurden erfüllt. Eine detaillierte Beschreibung der technischen Umsetzung ist bereits unter AP3 zusammengefasst. Innerhalb des Projektverlaufs wurde eine starke Verzahnung von AP3 und AP4 festgestellt, weswegen sich eine AP übergreifende Zusammenarbeit als sinnvoll herausgestellt hat. Es folgt eine Kurzübersicht über die durch AP1 zusammen mit den Praxispartnern abgeleiteten Use Cases. **Use-Case 1 mit Epic Erkennung von Fehlern im Rohfleisch** Zusammenfassung: Identifikation von fehlerhaften Stellen in Fleisch, bevor dieses verarbeitet wird. Hintergrund: Derzeit sichten Mitarbeitende die Rohware an einem Förderband. Werden qualitätsmindernden Stellen am Fleisch erkannt, werden diese händisch aussortiert und auch händisch an weitere Mitarbeitende übergeben, die an ihrem Arbeitsplatz die aussortierten Fleischstücke nacharbeiten. Die betroffenen Stellen werden weggeschnitten und händisch zurück in den Produktionsprozess gegeben. Diese beschriebene Sichtkontrolle findet am laufenden Band statt, so dass Entscheidungen zum einen unter Zeitdruck getroffen werden und zum anderen subjektiv ausfallen. Entsprechend kommt es häufig dazu, dass Fleisch mit schadhaften Stellen nicht identifiziert wird. Die schadhaften Stellen werden häufig erst vor dem Slicen identifiziert, wodurch ein höherer Ausschuss entsteht. Diese aktuelle Herausforderung soll durch das Ziel einer systematischen Erkennung von fehlerhaften Stellen in der Rohware optimiert werden. Zu diesen fehlerhaften Stellen gehören Blutpunkte, restrukturiertes Fleisch, hoher Sehnenanteil und hoher Fettanteil. Aktivitäten: Konzeptionelle Entwicklung Use Case, Unterstützung Annotation von Daten in Label-Studio. **Use-Case 1 mit Epic 2 Analyse der Rezeptur des Injektors** Zusammenfassung: Optimierung der Lakeeinspritzung zur Reduktion von Ausschuss. Hintergrund: Die Lake ist im Kochschinken ein wertgebender Bestandteil im Kochschinken. Sie besteht vor allem aus Gewürzen und Fleischsaft und wird in die Fleischstücke eingearbeitet. Die Zudosierung der Lakemenge orientiert sich an der eingegebene Fleischmenge in Kilogramm. Aktuell ist eine exakte Dosierung mit einem idealen Verhältnis von Lake zu Fleisch nicht möglich. Durch eine deutlich zu niedrige oder zu hohe Dosierung entstehen Ausschüsse. Zudem können die Nährwertangaben gegebenenfalls nicht mit der Deklaration übereinstimmen. Bei einer Unterdosierung kann eine verminderte Textur im Schinken erzeugen, wodurch der Kochschinken auseinanderfällt. Ebenfalls kann eine verminderte Haltbarkeit des Schinkens auftreten. Eine Überdosierung hat hingegen die Folge, dass sich Sud im Schinken absetzt**.** Aktivitäten: Konzeptionelle Entwicklung Use Case. **Use-Case 2 mit Epic 1 Putenstallüberwachung mithilfe von Sensoren** Zusammenfassung: Überwachung und Visualisierung sämtlicher verfügbarer (Sensor-) Daten der Farm-Management-Systeme. Erkennung von Abweichungen. Darstellung als Ampelsystem. Ausbau zum Einstiegspunkt für weitere Epics dieses Use-Cases. Hintergrund:

Aktuell kann der bereits genutzte Klimacomputer relevante Informationen, wie beispielsweise Temperatur und Luftfeuchtigkeit wiedergeben, es fehlt jedoch ein übersichtliches visuelles Gesamtbild, welches alle vorliegenden Informationen zusammenfasst und mögliche zukünftige Szenarien skizziert. Ziel ist es dem Landwirt/ der Landwirtin und den Mitarbeitenden die bestehende Momentaufnahme im Stall mitzuteilen, sowie Prognosen für zukünftige Handlungsmaßnahmen aufzuzeigen. Der Nutzen besteht darin Krankheitsbilder frühzeitig zu erkennen und Maßnahmen ergreifen zu können, um fortgeschrittene Krankheitsfälle oder Verluste zu reduzieren. Ein weiterer Nutzen besteht in der hohen Informationsdichte über ein visuelles Schaubild, wodurch komplexe Inhalte in einfache Benachrichtigung übersetzt werden können. Aktivitäten: Konzeptionelle Entwicklung Use Case. **Use-Case 2 mit Epic 2 Auswertung der Kotqualität** Zusammenfassung: Überwachung der Kotqualität im Putenstall. Klassifizierung der Kotbilder in den Bereichen fäkal und zäkal in jeweils vier Klassen. Hintergrund: Die optische Kotuntersuchung hat das Ziel der Gesundheitsüberprüfung und wird aktuell nur bei den üblichen Stallrundgängen (2x am Tag) durchgeführt, so dass sie nicht kontinuierlich stattfindet. Für Puten sind eine schnelle Krankheitserkennung und Behandlung entscheidend. Zudem verändert sich der Kot bei Krankheit sehr schnell. Ziel des Epics ist es, den Landwirt/ die Landwirtin so früh wie möglich über Kotveränderungen zu informieren. Dabei sollen die Bildaufnahmen über die Futterverwertung und Wasseraufnahme der Tiere informieren. Technisch werden dafür Bildaufnahmen des Kotes aufgenommen und Auswertungen genutzt. Gegebenenfalls erfolgt eine Einbindung von Daten des Klimacomputer und den Daten zu Futter, Wasser, Tiergewicht, Luftqualität. Der Kot soll anhand von Qualitätsstufen kategorisiert werden. Bei Veränderungen und nicht konformem Kot erfolgt eine Benachrichtigung auf dem Smartphone. Der Einsatz soll vor allem im hinteren Bereich des Stalls, an den Futterbereichen und an den Außenwänden erfolgen. Bei Ersterem und Letzterem halten sich schwache, gesundheitlich beeinträchtigte Tiere auf. Aktivitäten: Konzeptionelle Entwicklung Use Case, Akquise von Trainingsdaten sowie Labeln Daten mittels Label Studio.

Use-Case 2 mit Epic 3 Tiergewichtsvermessung Zusammenfassung: Optische Vermessung von Puten zur Bestimmung des durchschnittlichen Lebendgewichts. Hintergrund: Die Gewichtsbestimmung von Puten stellt aktuell eine Herausforderung dar. Über eine integrierte Pendelwaage werden ungenaue Messwerte erhalten. Das Wiegen der Puten per Hand ist zwar genau, aber sehr aufwändig. Ziel ist es, kontinuierlich Informationen über die Tiergewichte unter Realisierung eines reduzierten Arbeitsaufwands, zu erhalten. Für den Landwirt/ die Landwirtin ist das Wissen über das genaue Gewicht der Puten wichtig, um bei Über- oder Untergewicht eingreifen zu können, damit Tiere mit dem optimalen Schlachtgewicht ausgestallt werden. Technisch werden Bilddaten der Tiere erhoben. Aktivitäten: Konzeptionelle Entwicklung Use Case, Labeling von Daten mittels Label Studio sowie Unterstützung bei Experimenten zur Segmentierung von Puten auf der Waage. **Use-Case 2 mit Epic 4 Herdenbild** Zusammenfassung: Analyse des Aktivitätsverhalten der Herde. Tracking von einzelnen Puten in definierten Bildbereichen, Bewegungsmuster, Zählen von Tieren und Ermittlung von Zu- und Abfluss aus bestimmten Bereichen (Futter, Wasser). Hintergrund: In der Herde gibt es durch Kannibalismus verletzte Tiere, teilweise auch Verluste. Einzelne Tier werden durch sogenannte „Aggressoren“ angegriffen. Andere Tiere

schließen sich dem Verhalten der Aggressoren an. Durch eine kontinuierliche Bilddatenaufnahme sollen Aggressor-Tiere erkannt werden. Dies hat das Ziel der Reduzierung von Schäden wie Gehirnerschütterungen, Nasenzapfen-Picken, Federziehen und Hautschädigungen, als auch von Verlusten. Aktivitäten: Konzeptionelle Entwicklung Use Case, Labeling von Daten mittels Label Studio.

Nach Entwicklung der KI-Services werden Nutzerstudien durch die HSNR dokumentiert, um die Erfahrungen und Bedürfnisse der Nutzergruppen zu erfassen. Die zentralen Cluster und Fragestellungen in der Durchführung der Nutzerstudie sind folgende nach der Nutzerakzeptanz (abgekürzt mit N) und der zentralen Frage: Wie offen sind die Nutzer gegenüber der KI-Anwendung? Die Benutzerfreundlichkeit (abgekürzt mit B) mit der zentralen Frage: Wie einfach ist die Nutzung der Anwendung? Das Vertrauen (abgekürzt mit V) und der Fragestellung: Inwieweit vertrauen die Nutzer den Ergebnissen der KI? Verbesserungsvorschläge (abgekürzt mit VV) und der Fragestellung: Welche Wünsche haben die Nutzer? Im Projektverlauf finden im regelmäßigen Turnus Absprachen mit den Anwendungspartnern statt. Diese regelmäßigen Interviews werden als qualitative Methode zur Nutzerstudie herangezogen. Der Input aus diesen Besprechungen wird tabellarisch dokumentiert sowie in das kontinuierliche Anforderungsmanagement integriert. Weiterführende Nutzerstudien werden in AP5 im Rahmen der Evaluation durchgeführt.

UC	Epic & Beschreibung	Herausforderung	Zeitfenster	Status	Prio-rität	Input Praxis	Ziel
1&2	Alle Epics: Aktualisierung Proxy	Keine	Kurzfristig	Erledigt	2	Nein	B
1	E1: Upload von Bildern funktioniert	Daten nicht hochfrequent	Kurzfristig	Erledigt	1	Ja	B
1	E1: Implementierung Akquise-Software auf Kamera-SDK-Level	Daten nicht hochfrequent	Kurzfristig	Erledigt	1	Ja	B
2	E2: Erstellung von Heatmaps für Kotbilder mit GradCam++	Bewertung nicht durchgehend Kot	Mittelfristig	Erledigt	2	Nein	B
2	E3: Training Modell Putenerkennung an Waage	Kameraeinstellung	Kurzfristig	Erledigt	1	Nein	B
1	E1: Dokumentation Anwendung Injektor-App	Keine	Kurzfristig	Erledigt	2	Nein	N, B, V
2	E2: Kopplung der Bilder und Prüfung der Klassen	Keine Hinweise auf Clusterbildung	Kurzfristig	Erledigt	1	Nein	B
2	E1: Ampeldaten in LLM einbinden	Keine	Mittelfristig	Erledigt	2	Nein	B
1&2	Alle Epics: Fertigstellung Nachvollziehbarkeitsmodul	Hinreichende Qualität KI-Modelle ausstehend	Mittelfristig	Erledigt	1	Nein	B, N, V
2	E1: Scraper speichert Daten über Blockchain API in Buckets	Keine	Kurzfristig	Erledigt	1	Nein	B, N, V
1	E2: Demonstrator Box zu Box Ansatz	Keine	Kurzfristig	Erledigt	1	Ja	B
2	E1: Ampel Frontend Integration für Blockchain Verifikation	Keine	Mittelfristig	Erledigt	2	Nein	B, V
2	E3: Putenerkennung an Waage erneut trainiert	Test offen	Kurzfristig	Erledigt	1	Ja	B

UC	Epic & Beschreibung	Herausforderung	Zeitfenster	Status	Prio-rität	Input Praxis	Ziel
1	E1: Neues Projekt für Förderband bei Label Studio erstellt	Keine	Kurzfristig	Erledigt	1	Nein	B
2	E1: Deployment vom Blockchain-Proxy und Ampelsystem durchgeführt	Keine	Kurzfristig	Erledigt	2	Nein	B
2	E2: Projekt in Label Studio für Kot-Bilder aufgesetzt	Keine	Kurzfristig	Erledigt	1	Nein	B
1&2	Alle Epics: Behebung von Bugs in Proxy und BC API	Keine	Kurzfristig	Erledigt	2	nein	B
1&2	Alle Epics: Abschluss der Datenmigration zu Buckets	Verfügbarkeit valider Daten	Mittelfristig	Erledigt	1	Ja	B
1	E4: Zwei Entwicklungsansätze weiterverfolgen: Indikator für Bewegung im Stall und Indikator von Aktivität in bestimmten Zonen	ggf. Beschaffung und Ausrichtung weiterer Kameras	Mittelfristig	Erledigt	1	Ja	N, VV
1	E4: Entwicklung nicht in Echtzeit, Live-Tracking nicht notwendig. Sondern 3x täglich zu festen Zeitpunkten (z.B. 7, 12, & 19Uhr)	Valide Daten müssen vorliegen	Mittelfristig	Erledigt	1	Ja	N, VV
2	E4: Erstellung Ground Truth für Tracking der Tiere	Keine	Kurzfristig	Erledigt	1	Nein	B
2	E4: Erster Prototyp für Tracking Videos von Tieren erstellen	Keine	Kurzfristig	Erledigt	1	Nein	B
1	E1: Integration von Start/Stopp, Geschwindigkeit und Containerisierung	Zugriff auf Soft- und Hardware	Kurzfristig	Erledigt	1	Ja	B
1	E2: Überwachung Datenerfassungs-App und Prüfung auf Fehler	Keine	Mittelfristig	Erledigt	1	Ja	B, V
1	E1: Start Bildaufnahme über containerisierte API	Keine	Kurzfristig	Erledigt	1	Ja	B
2	E4: Verbesserung Segmentierung im gesamten Bildausschnitt	Tiererkennung nicht im gesamten Bild	Mittelfristig	Erledigt	1	Ja	B
1	E1: Segmentierung mit SAM2	Keine	Kurzfristig	Erledigt	1	Nein	B
1	E1: Beginn der Bilderfassung seitens Forschungspartner	Keine	Kurzfristig	Erledigt	1	Ja	B, V
2	E1: Beschaffung und Erstellung einer weiterführenden Sensorik-Box	Beschaffungszeit	Mittelfristig	Erledigt	1	Ja	B, V
2	E1: Durchführung-E-Mail-Benachrichtigung	Kontaktadressen	Kurzfristig	Erledigt	1	Ja	B

Arbeitspaket 5: Evaluierung

Die HSNR hatte in AP5 einen Aufwand von vier Personenmonaten. Der personelle Aufwand sowie die inhaltlichen Ziele wurden **erfüllt.** Die Evaluierungskonzept, Evaluierungsplan sowie Durchführung und Dokumentation der Ergebnisse der Zwischenevaluation wurden von der HSNR unterstützend begleitet. Zudem wurden von der HSNR Lessons learned und Praxiserfahrungen dokumentiert. Das **Evaluierungskonzept** wurde durch die HSNR unterstützend erstellt und dokumentiert. Zur **qualitativen** Bewertung der jeweiligen KI-Systeme werden pro Use Case entsprechend der Nutzungsanforderungen, Evaluationskriterien innerhalb von Nutzerbefragungen

abgefragt. Die Durchführung der **Zwischenevaluation** im Jahr 2024 wurde durch die HSNR unterstützend begleitet und dokumentiert. Innerhalb der Projektverlängerung wurde die **Endevaluation** durchgeführt. Das zuvor erarbeitete Konzept wurde dazu gemäß des Entwicklungsstands der Use Cases (UC) und deren Epics (E) angepasst. Das Ergebnis des finalen Interviews zur Evaluation wird folgend tabellarisch aufgeführt.

UC und E	Evaluationsfrage	Ja / Nein	Erklärung
UC1 E1	KI identifiziert Stellen mit zu hohem Sehnenanteil?	Nein	Aufgrund der vor einem Jahr unzureichenden Datenlage wurde die Entwicklung schrittweise priorisiert: zunächst auf Fett, anschließend auf Blut und „destrukturiert". Die Klasse „Sehnen" war als nachgelagerte Erweiterung vorgesehen, erfordert jedoch zusätzliche, qualitativ hochwertige Trainings- und Referenzdaten. Angesichts des verbleibenden Projektzeitrahmens ist eine belastbare Integration der Sehnen-Erkennung nicht mehr realistisch und müsste in eine mögliche Folgephase überführt werden.
UC1 E1	KI identifiziert Stellen mit zu hohem Fettanteil?	Ja	KI kann Fett erkennen, aber die Zuverlässigkeit ist unklar.
UC1 E1	KI identifiziert Blutpunkte?	Ja	KI identifiziert Blutpunkte, jedoch ist eine qualitative Aussage dazu nicht möglich.
UC1 E1	KI identifiziert destrukturierte Stellen?	Ja	KI identifiziert destrukturierte Stellen, jedoch ist eine qualitative Aussage dazu nicht möglich.
UC1 E2	Kann das KI-System einen Hinweis über Abweichungen von der gewünschten Injektionsrate geben?	Nein	Nein, dafür müssten Live-Zugriffe bestehen. Es ist parameterabhängig; Aufzeichnungen der Aktivitäten am Fließband wären erforderlich.
UC2 E1	Das Ampelsystem zeigt auf einen Blick an, wenn alle Werte des Klimacomputers innerhalb des Toleranzbereichs liegen?	Ja	Das Ampelsystem zeigt alle relevanten Werte an, wobei die Formulierung "alle Werte" präzisiert werden muss. Der Begriff bezieht sich auf die "ausgewählten Parameter", die im System gemeinsam definiert wurden. Es ist anzumerken, dass nicht alle Werte angezeigt werden; das System bietet lediglich eine Übersicht über bestimmte Parameter. Einzelne Werte können abgerufen werden, um spezifische Abweichungen zu identifizieren.
UC2 E1	Das Ampelsystem sendet eine automatische Mitteilung, wenn ein definierter Wert außerhalb der Toleranzgrenzen liegt?	Nein	Aktuell erfolgt die automatische Mitteilung bei Abweichungen noch nicht. Diese Funktion ist jedoch in der Entwicklung und soll in Zukunft implementiert werden.
UC2 E1	Das Ampelsystem ermöglicht das Priorisieren von Maßnahmen durch Warnfarben?	Ja	Die Priorisierung von Maßnahmen durch Warnfarben wird vom System unterstützt und ist bereits implementiert.
UC2 E1	Das System ermöglicht das Priorisieren von Maßnahmen durch die Anzeige von Prognosen?	Nein	Eine Prognosefunktion zur Priorisierung von Maßnahmen ist implementiert, wurde jedoch noch nicht in die Ampelanzeige integriert. Entsprechend steht eine sichtbare Prognoseanzeige in der Oberfläche derzeit nicht zur Verfügung. Ob die Integration bis zum Projektende erfolgt, ist aktuell offen.
UC2 E2	Das System sendet eine Benachrichtigung (Mitteilung auf Smartphone) an den Landwirt, falls im Stall nicht-konformer Kot erkannt wird?	Nein	Die automatische Benachrichtigung bei der Erkennung von nicht-konformem Kot erfolgt derzeit nicht automatisch, sondern lediglich manuell, sobald ein Bild hochgeladen wird. Dies ist ein angestrebtes Ziel, jedoch noch nicht umgesetzt.
UC2 E2	Das System informiert den Landwirt darüber, ob im Fall von nicht-konformem Kot auch eine veränderte Wasser- und/ oder Futteraufnahme vorliegt?	Nein	Eine direkte Information über Veränderungen in der Wasser- und Futteraufnahme erfolgt nicht, kann jedoch über das Ampelsystem abgerufen werden. Hierbei ist es erforderlich, die zeitlichen Daten der hochgeladenen Bilder zu berücksichtigen.
UC2 E2	Das System informiert den Landwirt über Details zum Grad	Nein	Derzeit konnte die Funktion zur detaillierten Informationsübermittlung über nicht-konformen Kot noch nicht beobachtet werden; eine Implementierung ist jedoch

	der Veränderung des nicht-konformen Kotes?		gewünscht. Die Anzahl der Abstufungen zur Klassifizierung des Kots ist momentan noch unklar und steht noch nicht fest. Die gewünschte Funktionalität zur detaillierten Bewertung von Kotqualitäten wurde bisher noch nicht gesehen.
UC2 E3	Das System informiert den Landwirt automatisch über eine Benachrichtigung auf das Smartphone über das tagesaktuelle Durchschnittsgewicht der Herde im Stall?	Nein	Die Funktion zur Gewichtserkennung ist bisher noch nicht vollständig implementiert. Zwar liegt bereits eine optische Messmethode vor, die Gewichte schätzt; die aktuellen Ergebnisse sind jedoch noch zu ungenau und zeigen deutliche Abweichungen gegenüber Referenzmessungen. Daher ist eine weitere Entwicklung, Kalibrierung und Validierung erforderlich. Bis zur Erreichung der Zielgenauigkeit sollten die optischen Gewichtsschätzungen nur indikativ verwendet werden. Derzeit wird an der Verbesserung der Erkennungstechnologie gearbeitet. Die optische Vermessung, die zur Gewichtserfassung verwendet wird, ist noch nicht umfassend genug, und es wird Zeit benötigt, um die Genauigkeit zu erhöhen. Diese Verbesserung stellt einen weiteren Entwicklungsschritt dar, der aktuell nicht im unmittelbaren Fokus steht. Die optische Vermessung erfolgt durch das Erstellen von Bildern der Tiere, während diese auf einer Waage stehen. Anschließend müssen das Gewicht und die entsprechenden Bilder miteinander korreliert werden. Hierbei ist die Erhebung zusätzlicher Daten erforderlich, um die Zuverlässigkeit des Systems zu erhöhen.
UC2 E3	Das System informiert den Landwirt über die Genauigkeit der Gewichtsmessungen.	Nein	Es ist derzeit noch zu früh, um eine abschließende Aussage zur Genauigkeit und Funktionalität des Systems zu treffen. Eine umfassende Bewertung wird im dritten Entwicklungsabschnitt angestrebt.
UC2 E4	Das System ermöglicht dem Landwirt kontinuierlich den Einblick in das Herdenverhalten in ausgewählten Bereichen der Stallfläche?	Ja	Ja, das System erfasst die Bewegungsdaten der Tiere sowie deren Geschwindigkeit.
UC2 E4	Das System bewertet die Agilität des Herdenbildes im Stall im zeitlichen Verlauf und zeigt dem Landwirt die entsprechende Bewertung an?	Nein	Obwohl alle relevanten Aspekte besprochen wurden, konnten die Daten bislang noch nicht beobachtet werden. Die Datenerhebung ist durch wiederkehrende Kameraausfälle erschwert; teils werden diese erst mit deutlicher Verzögerung behoben (z. B. der Ausfall im September). Zur Sicherstellung von Konsistenz und Genauigkeit ist es erforderlich, zusätzliche Daten zu erheben und mit Referenzquellen abzugleichen. Bis dahin sind die vorhandenen Daten nicht als „sauber“ bzw. qualitätsgesichert zu betrachten und nur eingeschränkt auswertbar.

Die Dokumentation der **Lessons Learned und Praxiserfahrungen** beleuchten Erfolge und Herausforderungen sowie Empfehlungen für zukünfige Projekte. Diese wurden durch die HSNR dokumentiert. Folgend ein exemplarischer Ausschnitt mit den wichtigsten drei Lessons Learned:

- Verzögerter Projektstart und unter anderem verzögerte Einstellung von Mitarbeitenden sowie Verfügbarkeit und Kapazitäten von Forschungs- und Anwendungspartner. Lösungsansätze:
  - Reduzierter Zeitaufwand von Forschungsskizze bis Förderbescheid mit Planungssicherheit

- Anpassung der notwendigen zeitlichen und personellen Ressourcen unter anderem bei Anwendungspartnern, insbesondere bei Forschungsarbeiten mit KI (Datenerfassung, -aufbereitung und -analyse als zentrales Arbeitspaket formulieren)
  - Reduzierung der Erstellung von detaillierteren Anträgen bezogen auf Beschaffung von Hardware
  - Förderung des Vertrauens innerhalb des Konsortiums zur Stärkung der Offenheit gegenüber einer Zusammenarbeit mit Daten
- Fehlende Interoperabilität/ Anpassungen zwischen Systemen innerhalb des Forschungskonsortiums. Lösungsansatz:
  - Inhaltliche Ziele auf die Bereitschaft in der zu untersuchende Domäne anpassen, z.B. fehlende Praktikabilität Datenplattform in Agrar- und Lebensmittelwirtschaft
- Herausforderungen in der Datenerfassung und -qualität. Technisch bedingt gab es verschiedene Herausforderungen, wie beispielsweise Internetausfälle, fehlende Zugänge zu bestehenden Systemen, und fehleranfällige Sensorik. In der Landwirtschaft sind solche Probleme weit verbreitet, und stellen bei jedem Partner individuelle Herausforderungen dar. Empfehlung für zukünftige Projekte:
  - Funktionale Datenerfassung in Verbindung mit notwendiger Hard- und Software als erstes Ziel im Projekt definieren. Je schneller eine Datenerfassung möglich ist, desto mehr Zeit bleibt, um diese Herausforderungen zu erfassen.

Arbeitspaket 6: Sichtbarkeit und Verwertung

Die HSNR hatte in AP6 einen Aufwand von sechs Personenmonaten. Der personelle Aufwand wurde erfüllt. Die Ergebnisse Aktivitäten und Materialien für die Öffentlichkeitsarbeit, wissenschaftliche Veröffentlichungen sowie Businessstrategien wurden **erreicht**.
Zusammenfassend zeigt sich, dass KINLI von überdurchschnittlichem Interesse für die Öffentlichkeit ist. Das Projekt erhielt (Presse-)Anfragen sowie Anfragen aus der Forschung, den (Populär-)Wissenschaften und von (Fach-)Zeitschriften, (Regional-)Medien und Studierenden. Zudem wurde das Projekt zu (wissenschaftlichen) Veranstaltungen in Form von Vorträgen und Informationsständen eingeladen sowie zu Interviews und Austauschformaten. Zu **öffentlichkeitswirksame Aktivitäten** zählen neben der Teilnahme an relevanten Veranstaltungen für die Forschung und/oder Industrie variabel kontinuierliche Beiträge in sozialen Medien und Rundfunksendungen, wie beispielsweise im Radiobeitrag des Senders „Radio Mönchengladbach“ durch die HSNR im Mai 2023. Dem Projekt ist es gelungen, KI in Verbindung mit einer nachhaltigeren Fleischindustrie in der Öffentlichkeit zu platzieren. Es folgt eine exemplarische Aufzählung von Aktivitäten, bei denen die HSNR vertreten war:

- Hochschulzentrum LAKUM (Juni 2023, Mönchengladbach)
- Gastvortrag VL Grundlagen der Logistik, FB05 HSNR (Jan. 2024, Mönchengladbach)
- Clusterübergreifendes Präsenztreffen Verbundprojekte KINLI (Februar 2024, Berlin)
- DAFA-Konferenz (März 2024, Potsdam)

- ANUGA FoodTech (März 2024, Köln)
- CERES Tag (Mai 2024, Sankt Augustin)
- I.O.P Interessengemeinschaft Optimierung Putenhaltung (Mai 2024, Kalkar)
- Tag der offenen Türe, FB Oecotrophologie, HSNR (Mai 2024, Mönchengladbach)
- EuroTier (November 2024, Hannover)
- KIDA-KON (Dezember 2024, Leipzig)
- Tag der offenen Türe, FB Oecotrophologie, HSNR (Mai 2025, Mönchengladbach)
- Gastvortrag VL Lebensmittelinnovation, FB05 HSNR. (Juni 2025, Mönchengladbach)
- Ringvorlesung KI an der HSNR (Oktober 2025, Mönchengladbach)

Wissenschaftliche Veröffentlichungen entstanden nicht nur Beiträge in Journals, sondern auch in Fachzeitschriften und Magazinen. Eine detaillierte Auflistung erfolgt in Kapitel 4 Veröffentlichungen. Um eine **wirtschaftliche Betrachtung** der Plattform und ihrer Dienste zu gewährleisten und Konzepte für mögliche Geschäftsmodelle nach Projektabschluss zu entwickeln, erstellen die Projektpartner, insbesondere die HSNR, eine Dokumentation zur wirtschaftlichen Verwertung. Das Geschäftsmodell umfasst die Komponenten Strategie, Kunde, Markt und Wertschöpfung. An dieser Stelle wird, aufgrund der Fokussierung auf die wirtschaftliche Betrachtung, hervorgehoben, dass eine Kombination mehrerer Erlösmodelle möglich ist, welches ein Diversifizieren der Einnahmeströme ermöglicht. Die Einschätzung geeigneter Erlösmodelle beziehen sich auf den Direktvertrieb, Dienstleistungsverträge, Abonnement, Crowdfunding oder Spenden, Datenverkauf oder dem Freemium- Modell. Exemplarisch wird folgend der weiterführende Exkurs zum Marktpotenzial des Produktes aus UC 2 dargestellt. Das Marktpotenzial für eine KI-Lösung im Live-Stock-Monitoring, speziell in der Putenhaltung, kann als vielversprechend eingeschätzt werden. Es folgt eine Beschreibung von Faktoren, die das Marktpotenzial positiv beeinflussen. Als erstes ist die wachsende Marktgröße der Putenhaltung zu nennen. Global betrachtet hat die Produktion von Puten in den vergangenen Jahren weltweit kontinuierlich zugenommen. Nach der FAO (Ernährungs- und Landwirtschaftsorganisation der Vereinten Nationen) liegt die globale Putenproduktion bei etwa sechs Millionen Tonnen pro Jahr, bei steigender Nachfrage. Innerhalb von Regionen wie Nordamerika und Europa ist die Produktion von Puten von besonderer Bedeutung. Die USA gelten als einer der größten Produzenten, neben Ländern wie Brasilien und der Türkei. Im Rahmen des technologischen Fortschritts ist festzuhalten, dass die Landwirtschaft sich zunehmend digitalisiert. Der Markt für IoT in der Landwirtschaft wird bis 2025 auf mehrere Milliarden Dollar geschätzt. Auf der anderen Seite legen Konsumenten zunehmend Wert auf eine artgerechte Tierhaltung und nachhaltige Praktiken in der Landwirtschaft. Allgemein wird der Markt als anpassungsfähig eingeschätzt, da die Flexibilität der Lösung nicht ausschließlich auf die Haltung von Puten, sondern auch auf andere Geflügelarten sowie Nutztiere ausgeweitet werden kann. Dies bringt eine Erhöhung des Marktpotenzials mit sich. Ein weiterer Beitrag zur Umsatzsteigerung kann zusätzliche Dienstleistungen wie Datenanalysen und Beratung sein. Im Fokus der Betrachtung steht eine Analyse des wirtschaftlichen Potentials der Putenkot-Webapplikation (UC 2 – Epic 2). Es wird ein Freemium Produkt vorgeschlagen, bei dem jeder

angemeldete Nutzer eine bestimmte Anzahl Bilder pro Tag bewerten lassen kann. Diese Bilder werden nicht langfristig gespeichert oder für das weitere Training der KI genutzt. Falls ein Nutzer mehr Bilder pro Tag bewerten möchte, kann er das Limit durch ein Subscription Tier erhöhen. In einem zuvor gestalteten Vorschlag mit Freemium Modell wurde der hohe Moderationsaufwand im Bezug zum Hochladen von Bildern bemängelt, aufgrund des Themas. Deswegen wird der Upload von neuen Trainingsbildern nur ausgewählten Nutzern ermöglicht. Nutzer können sich für eine Testphase anmelden, in der sie innerhalb einer bestimmten Zeit eine bestimmte Quantität und Qualität and Bildern hochladen müssen, um danach für einen langfristigen Zeitraum die Möglichkeit zu erhalten, Bilder hochzuladen. Somit wird der Moderationsaufwand begrenzt, vor allem im Segment der Bildüberprüfung, die im Bereich der Kotanalyse schwierig ist. Weiterführende Arbeiten zur Marktanalyse und Geschäftsmodellen für den zweiten UC wurden bei EQAsce Education beauftragt.

Arbeitspaket 7: Projektmanagement

Die HSNR hatte in AP7 einen Aufwand von einem Personenmonat im Rahmen der Meilensteine und Reporting und hat diesen **voll erfüllt**. Die Ergebnisse Überwachung des Budgets, Sicherstellung der Kommunikation, sowie einen kontrollierten und organisierten Projektablauf wurden erreicht. Innerhalb des **allgemeinen Managements** wirkte die HSNR unterstützend. Neben der Kommunikation mit dem Projektträger, administrativen Koordination der Verbundpartner, Vorbereitung von Berichten und der Veranstaltungsorganisation, erfolgt die Verwaltung und Aufbau einer entsprechenden Kommunikations-Infrastruktur zur Koordination des Konsortiums. Diese beinhaltet Microsoft Teams als Ablage und Ort zum Bearbeiten gemeinsamer Dokumente. Eine allgemeine Mailingliste ist zur Kommunikation mit dem gesamten Projektkonsortium sowie darüber hinaus mit den Forschungspartnern implementiert worden. Updates zum aktuellen Projektstand erfolgten online sowie in Präsenz im regelmäßigen Turnus. Die **technische Koordination** erfolgte über GitLab. Das durchgeführte Projektmanagement stellte die Kommunikation und die Zusammenarbeit im Konsortium über die gesamte Projektlaufzeit sicher.

2. Verwertung

a) Erfindungen/Schutzrechtsanmeldungen

Es liegen keine Erfindungen/ Schutzrechtsanmeldungen vor. Der Fokus im Projekt lag auf der Entwicklung von nicht schützbarer Software.

b) Wirtschaftliche Erfolgsaussichten nach Projektende

Wirtschaftliche Erfolgsaussichten für Use Case 1: Die wirtschaftlichen Erfolgsaussichten für Epic 1 werden als hoch angesehen. Eine Übertragbarkeit des Prozesses auf andere, vergleichbare, Use Cases ist möglich. Die wirtschaftlichen Erfolgsaussichten für Epic 2 werden als niedrig angesehen, dies ist mit der hohen Individualität der Lösung für den Praxispartner zu begründen. Wirtschaftliche Erfolgsaussichten für Use Case 2: Die wirtschaftlichen Erfolgsaussichten für Epic 1 werden als

weniger hoch angesehen, da hier vergleichbare Lösungen von bereits bestehenden Agrarunternehmen (z.B. Stienen und BigDutchman) während der Projektlaufzeit entwickelt werden und voraussichtlich zeitnahe am Markt verfügbar sind. Die wirtschaftlichen Erfolgsaussichten für die KI-Modelle in Epic 2-4 werden aufgrund ihres Innovationscharakters als hoch angesehen. Begründung liegt in der geringen Forschungsaktivität in der Putenhaltung.

c) Wissenschaftliche und/oder technische Erfolgsaussichten nach Projektende

Das methodische Vorgehen innerhalb der Projektlaufzeit fokussierte stark die individuellen Anforderungen der Praxispartner. In der Projektlaufzeit wurde mittels eigener Datenerhebung erfolgsversprechende Ansätze in der Entwicklung von KI-Lösungen für die Bereiche Agrar- und Lebensmittelwirtschaft, an den Beispielen Haltung von Puten und Produktion von Kochschinken, geschaffen. Wissenschaftliche Erfolgsaussichten ergeben sich durch die bestehenden und geplanten Veröffentlichungen sowie der Verfolgung einer Promotionsarbeit. Technische Erfolgsaussichten ergeben sich im UC2 in der Entwicklung eines Proof of Concepts für eine kostensensitive Sensorplattform zur herstellerunabhängigen Integration weiterer Daten.

d) Wissenschaftliche und wirtschaftliche Anschlussfähigkeit

Zur wissenschaftlichen Anschlussfähigkeit des zweiten UC kann die Einreichung der Forschungsskizze „KIMPUT- KI-basiertes Managementsystem in der Putenhaltung für Tierwohl“ im Rahmen des Förderprogramms „Innovationen in Haltungssystemen in der landwirtschaftlichen Tierhaltung“ vom Projektträger BLE genannt werden. Die Skizze, eingereicht im Frühjahr 2025, befindet sich in Prüfung. An der HSNR werden die Erkenntnisse aus dem Projekt am Fachbereich Oecotrophologie in den Studiengängen Ernährungs- und Lebensmittelwissenschaften, in wissenschaftlichen Veranstaltungen des Lehrgebiets Lebensmittellogistik integriert. An der Hochschule Offenburg werden die Erkenntnisse aus dem Projekt KINLI in wissenschaftlichen Veranstaltungen des DSC (Digital Supply Chain) Labs integriert. Die wirtschaftliche Anschlussfähigkeit ergibt sich in der möglichen Verwertung des zweiten Use Cases. Arbeitspaket sechs stellt die Erkenntnisse im Bezug zur wirtschaftlichen Anschlussfähigkeit detailliert dar.

3. Erkenntnisse von Dritten

Nach Projektende liegen keine Erkenntnisse von Dritten vor. Es werden keine KI-gestützten Marktlösungen für die spezifischen Use Cases unter Berücksichtigung der Haltung von Puten und der Produktion von Kochschinken angeboten.

4. Veröffentlichungen

In der Projektlaufzeit entstanden nicht nur Beiträge in wissenschaftlichen Journals und auf Konferenzen, sondern auch in Fachzeitschriften und Magazinen. Eine Auflistung der **wissenschaftlichen Veröffentlichungen** wird folgend dargestellt:

Titel	Journal/ Konferenz	Inhalt
Nachhaltige Lebensmittellieferketten durch Künstliche Intelligenz: Konzeptionelle Visualisierung am Beispiel von Puten zur Förderung von Tierwohl und Lebensmittelqualität	Industry Science 4.0	Allgemeines KI-Konzept beschrieben am Beispiel Use Case 2
Sustainable food supply chain: promoting animal health and welfare of turkeys	Konferenz Agrarforschung zum Klimawandel der DAFA	Überblick über die 4 Epics im Use Case 2
A Literature Review on Explainable AI in Manufacturing	30th ICE IEEE/ITMC	Überblick über XAI in der industriellen Produktion
Künstliche Intelligenz zur Förderung von Tierwohl und Lebensmittelqualität in der Lieferkette	KIDA-KON24	AI for Research in Food, Agriculture and Environment
Parameteroptimierung für einen Lakeinjektor	Industry Science 4.0	Beschreibung und Lösung des Injektor Use Cases
KINLI: Time Series Forecasting for Monitoring Poultry Health in Complex Pen Environments	MDPI Animals	Time Series Forecasting unter Einsatz von LLM

Mögliche zukünftige Veröffentlichungen können die KI-gestützte Bestimmung des Lebensgewichts, das Tracking der Bewegungsprofile sowie die Analyse von Putenkot sein. Ebenso ist eine Veröffentlichung mit Fokus auf der KI-gestützten Rohwarenkontrolle von Schweinefleisch möglich.

Ergänzend dazu erfolgt ebenfalls eine Auflistung der Magazinbeiträge im Rahmen von KINLI:

- KINLI: Lieferketten optimieren mit künstlicher Intelligenz zur prädiktiven Förderung von Tierwohl und Lebensmittelsicherheit (Lebensmittelbrief) – HSNR vertreten
- KINLI: Lieferketten optimieren mit künstlicher Intelligenz zur prädiktiven Förderung von Tierwohl und Lebensmittelsicherheit (Magazin für Amtstierärzte) – HSNR vertreten
- Künstliche Intelligenz in der Fleischwirtschaft: Nachhaltige Lieferketten mit KINLI (Fleischwirtschaft) – HSNR vertreten
- KINLI: Lieferketten optimieren mit künstlicher Intelligenz zur prädiktiven Förderung von Tierwohl und Lebensmittelsicherheit (Lebensmittelbrief II) – HSNR vertreten