



### **Abschlussbericht**

Vorhabenbezeichnung: Zuwendungsbescheid/Aktenzeichen: Intelligente Diagnostik 2 3-4332.62-FZI/62

ZE:

**FZI Forschungszentrum Informatik** 

ILM - Institut für Lasertechnologien in der Medizin und Meßtechnik

Hahn-Schickard (HS VS)

Hahn-Schickard (HS S)

NMI Naturwissenschaftliches und Medizinisches Institut an der Universität Tübingen

Laufzeit des Vorhabens:

24. Juni 2021 bis 30. November 2023

Berichtszeitraum:

24. Juni 2021 bis 30. November 2023













## Inhalt

1		Kurzzusa	ımmenfassung – Management Report	4				
	1.1	Einlei	tung	4				
	1.2	Ziele	des Vorhabens Intelligente Diagnostik 2	5				
	1.3	Zusar	mmenfassung der Projektergebnisse unter Berücksichtigung der Zielerreichung .	6				
	1.4	Verw	ertbarkeit der Projektergebnisse	9				
		1.4.1	Wirtschaftliche Verwertbarkeit der Ergebnisse	9				
		1.4.2	Maßnahmen zur Verbreitung der Projektergebnisse	11				
2		Wissens	chaftlich-technische Ergebnisse	12				
	2.1	AP1 -	Analyse der Anforderungen und Nutzungsszenarien (FZI)	12				
		2.1.1	AP1.1 - Anwendungsdomänen, Nutzungsszenarien und Anforderungen	12				
		2.1.2	AP2.2 - Modellierung von Prozessen sowie der Diagnosekette	14				
		2.1.3	AP2.3 - Risikoanalyse	16				
	2.2	AP2 -	- Optische Messsysteme (ILM+HS-S)	17				
		2.2.1	AP2.1 - Verbesserung der Hardware & Software des aktuellen Systems	17				
		2.2.2 Gewebe	AP2.2 - Erweiterung der modellgestützten Datennachbearbeitung auf Grundloptik	-				
		2.2.3	AP2.3 - Aufbau und Hardwareevaluation der KOMPASSpro Demonstratoren	23				
	2.3	AP3 -	- Feldversuche und Referenzdiagnostik von Proben aus Arztpraxen und Kliniken	(NMI).				
				28				
	2.4	AP4 -	KI - Algorithmen (HS-VS)	33				
		2.4.1	AP4.1 - Weiterentwicklung der Deep-Learning-Algorithmen	34				
		2.4.2	AP4.2 - Training von Deep-Learning-Modellen unter Einhaltung der Privatsph	äre der				
		Patienten						
		2.4.3 durch De	AP4.3 - Ermittlung der Relevanz von einzelnen Parametern des optischen Messs eep-Learning-Modelle	•				
		2.4.4 KOMPAS	AP4.4 - Optimierung des Deep-Learning-Modells für die Inferenz au SSmobile-System					
	2.5	AP5 -	Federated Learning Plattform (FZI)	51				
		2.5.1 Learning	AP5.1 - Konzeption der Managementplattform zur Umsetzung des Fed					
		2.5.2	AP5.2 - Implementierung der Globalen Federated Learning Plattform	56				
		2.5.3 Managei	AP5.3 - Implementierung funktionaler Erweiterungen der mentplattform	lokalen 59				
		2.5.4	AP5.4 - Entwicklung eines globalen Management-UI	62				





66	AP6 - Entwicklung des KOMPASSmobile-Systems (ILM, HS-S, FZI)	2.6
66	AP6.1 - Technologiefestlegung / Hardwarekonzept (ILM)	:
, ,	2 AP6.2 - Miniaturisierung multispektraler Beleuchtung auf Mobilgerät	
•	3 AP6.3 - Neue Hardware für Mobilgeräte basiertes System amtsystems & der Optik) (HS-S, ILM)	
	4 AP6.4 - Fertigung und Assemblierung der Optik-Komponenten des lems (HS-S)	
	5 AP6.5 - Entwicklung einer Schnittstellenelektronik zw. Optikeinhogerät und Systemintegration (HS-VS)	
, , ,	6 AP6.6 - Entwicklung einer Software-Anwendung für das KOMPASSmo	
80	AP7 - Evaluation des KOMPASSmobile-Systems (FZI, ILM)	2.7
80	AP7.1 - Integration und Zusammenführung aller Komponenten	:
83	2 AP7.2 - Validierung des Messkopfes des KOMPASSmobile-Systems	:
en Diagnose 83	3 AP7.3 - Durchführung von Feld-Tests und Auswertung der KI-basierte	





## 1 Kurzzusammenfassung – Management Report

## 1.1 Einleitung

Intelligente Diagnostik 2 ist ein Forschungsverbundprojekt der Innovationsallianz Baden-Württemberg, gefördert durch das Ministerium für Wirtschaft, Arbeit und Tourismus. Ziel des Projekts war es aufbauend auf den Ergebnissen des Projekts Intelligente Diagnostik ein verbessertes, verteiltes Diagnosesystem mit einem kompakten, handgeführten Messsystem zu entwickeln, mit dem in Kliniken und dermatologischen Praxen maligne Hautläsionen und weitere Hautkrankheitsbilder unter Einsatz von künstlicher Intelligenz und quantitativer Bildgebung robust und sicher diagnostiziert werden können.

Die Früherkennung von Hautkrebs und entsprechend eingeleitete Maßnahmen steigern in erheblichen Maße die Heilungs- und Behandlungschancen. Gerade beim schwarzen Hautkrebs, dem malignen Melanom, führt eine zu späte Erkennung zu schwerwiegenden Folgen und häufig zum Tod. Genau aus diesem Grund wurden in den letzten Jahren Ansätze erforscht und Anwendungen entwickelt, die den Arzt bei der Diagnose von Hautkrebs unterstützen. Die klassische visuelle Inspektion, bei der auch mit unterstützender Auflichtmikroskopie nur eine Treffsicherheit von ca. 85% erzielt wird, soll durch KIbasierte Systeme verbessert werden. Wie bereits im Projekt Intelligente Diagnostik festgestellt wurde, wird trotz großer verfügbarer Datenmengen auch mit Hilfe neuronaler Netze keine erheblich verbesserte Erkennungsrate erzielt. Zur signifikanten Steigerung der Performance dieser Netze müsste die zum Training verwendete Datenmenge vermutlich noch einmal deutlich vergrößert werden oder es müssten spezifischere Daten pro Bild betrachtet werden. Das Projekt Intelligente Diagnostik 2 konzentriert sich, wie auch das Projekt Intelligente Diagnostik, auf die Erzeugung und Auswertung spezifischer Bilder. Mit Beginn der ersten Projektphase wurde mit der Datenakquise begonnen, sodass zunächst nur eine erste kleinere Datenbasis für das Training des KI-Modells zur Verfügung stand. Da gerade der Aufbau einer entsprechenden Datenbasis entscheidend für den langfristigen Erfolg des im Projekt verfolgten KI-basierten Ansatzes ist, wurden im Projekt Intelligente Diagnostik 2 Ansätze untersucht, die zum schnelleren Aufbau der notwendigen Datenmengen beitragen. Im Fokus steht dabei die datenschutzkonforme Vernetzung verschiedener Kliniken. Ein weiterer wichtiger Baustein für die Praxistauglichkeit war die Miniaturisierung des Systems zur Verbesserung der Handhabung. Durch die Entwicklung eines handgeführten Systems soll perspektivisch der Einsatz in Haut- oder Hausarztpraxen ermöglicht werden.

Das Konsortium besteht aus den Forschungsinstituten der Innovationsallianz Baden-Württemberg (innBW): FZI Forschungszentrum Informatik, ILM – Institut für Lasertechnologien in der Medizin und Meßtechnik, Hahn-Schickard Stuttgart sowie Hahn-Schickard Villingen-Schwenningen und NMI Naturwissenschaftliches und Medizinisches Institut an der Universität Tübingen. Das Universitätsklinikum Tübingen und die Charité in Berlin sind ebenfalls in das Projekt eingebunden.

Der Abschlussbericht ist in zwei Abschnitte unterteilt. Abschnitt 1 bietet einen Überblick über das Projekt Intelligente Diagnostik 2 und dessen Ziele. Zudem wird auf die Erreichung der Ziele sowie auf





die Verwertungsperspektive eingegangen. In Abschnitt 2 erfolgt die detaillierte Vorstellung der Ergebnisse. Strukturiert ist Abschnitt 2 entsprechend der im Projekt bearbeiteten Arbeitspakete.

## 1.2 Ziele des Vorhabens Intelligente Diagnostik 2

Das Projekt Intelligente Diagnostik 2 führt die Arbeiten des Projekts Intelligente Diagnostik fort und adressiert im Besonderen Teilziele, welche allesamt zum gemeinsamen Gesamtziel, der Entwicklung eines verteilten, KI-basierten, miniaturisierten und kostengünstigen Diagnosesystems zur Unterstützung bei der Erkennung von Hautkrankheiten auf Basis multimodaler Aufnahmen beitragen. Zusammengefasst wurden aus den Erkenntnissen der ersten Projektphase (Intelligente Diagnostik 1) die folgenden Teilziele für das Projekt Intelligente Diagnostik 2 abgeleitet:

- Verbesserung der Messsystemhandhabung sowie der Messqualität
- Fortführung der Evaluation von Intelligente Diagnostik 1
- Anwendung des Verfahrens auf weitere dermale Krankheitsbilder
- Erhöhung der Prognosegenauigkeit

Im Folgenden werden die Teilziele kurz vorgestellt. Die Zielerreichung wird im Kapitel 1.3 adressiert. Im Kapitel 2 werden die konkreten Ergebnisse darauffolgend ausführlich beschrieben.

Verbesserung der Messsystemhandhabung sowie der Messqualität: Die Weiterentwicklung der Messsysteme zur Erzeugung multimodaler Aufnahmen von Hautläsionen unter strukturierter Beleuchtung unterteilt sich in die Konzeption und den Aufbau des KOMPASSpro-Systems sowie der Konzeption und Entwicklung eines miniaturisierten, handgeführten KOMPASSmobile-Systems. Bezüglich der KOMPASSpro-Systeme ist im Wesentlichen die Weiterentwicklung der Streifenprojektionsgeräte und Auswertemethodik sowie deren Implementierung das Ziel. Die Entwicklung des KOMPASSmobile-Systems erfordert zunächst die Erarbeitung eines Konzepts und die Definition von Schnittstellen. Neben der Umsetzung der einzelnen Bestandteile des Systems sollen insbesondere auch Vorgehensweisen zur Fertigung der Optik und Optomechanik erarbeitet werden. Des Weiteren umfasst die Zielsetzung die Planung sowie anschließende Realisierung der Elektronik des KOMPASSmobile-Systems. Die Implementierung geeigneter Software für den neuen Demonstrator wird ebenfalls fokussiert.

Fortführung der Evaluation von Intelligente Diagnostik 1: Zeitgleich zur Weiterentwicklung der Messsysteme soll die Akquise von Trainingsdaten ausgeweitet werden, um ein besseres Training der KI-Modelle zu ermöglichen. Begleitet wird die Datenakquise durch die Referenzdiagnostik, im Rahmen derer zudem nachvollzogen werden soll, welche Untergruppen von Melanomen, die mit Expressionsprofilen klassifiziert worden sind, sicher detektiert werden können. Ergänzend hierzu soll die Anwendung des Verfahrens auf weitere dermale Krankheitsbilder ausgeweitet und untersucht werden.

Erhöhung der Prognosegenauigkeit: Kern des Gesamtsystems und damit auch entscheidend für die Akzeptanz eines entsprechenden Verfahrens, ist die Genauigkeit der KI-Modelle. Aus diesem Grund sollen die KI-Modelle im Hinblick auf die neuen Trainingsdaten, aber auch hinsichtlich neuer Algorithmen, weiterentwickelt und verbessert werden. Erkenntnisse aus den Trainingsvorgängen können zudem zur weiteren Verbesserung der Messsysteme genutzt werden, indem die Relevanz





verschiedener Parameter ermittelt und bei künftigen Weiterentwicklungen des Systems entsprechend berücksichtig wird.

Die Erweiterung des Gesamtsystems zu einem verteilten Diagnosesystem soll eine möglichst breite Verfügbarkeit sowie einen schnelleren Aufbau einer diversifizierten Trainingsdatengrundlage ermöglichen. Der Prozess des Federated Learnings soll an die spezifischen Anforderungen des Projekts angepasst und umgesetzt werden. Die im Projekt Intelligente Diagnostik für den lokalen Betrieb des Diagnosesystems umgesetzte Plattform ist daher hinsichtlich der Vernetzung mehrerer entsprechender Plattformen zu erweitern, sodass ein datenschutzkonformer und performanter Austausch von lokal gewonnen Erkenntnissen ermöglicht wird.

# 1.3 Zusammenfassung der Projektergebnisse unter Berücksichtigung der Zielerreichung

Die in Kapitel 1.2 beschriebenen Ziele werden in diesem Kapitel bezüglich der Zielerreichung untersucht. Eine detaillierte Beschreibung der Ergebnisse folgt in Abschnitt 2.

**Verbesserung der Messqualität:** Weiterentwicklung des in Intelligente Diagnostik 1 entwickelten Systems zu einem klinisch einsetzbaren, miniaturisierten Demonstrator (KOMPASSpro), mit gleichzeitiger Erhöhung der Robustheit und Usability des Diagnose-Systems.

Ziele in Arbeitspaket 2 waren die Weiterentwicklung der Streifenprojektionsgeräte und der Auswertemethodik, sowie Verbesserungen für die Software zur Datenaufnahme und Auswertung. In all diesen Bereichen konnten wesentliche Fortschritte gemacht und Erkenntnisse gewonnen werden. Die Verbesserung des Hardwaredesigns zum KOMPASSpro-System konnte zu einer Reduzierung der bewegten Teile bei einer gleichzeitigen flexibleren Anwendung durch den DMD genutzt werden. Die Miniaturisierung der Belichtungseinheit war nicht erfolgreich, da das miniaturisierte Bauteil keine ausreichend uniforme Beleuchtung ermöglicht. Der grundsätzliche Aufbau des neuen Messgerätes erlaubt aber unter Verwendung einer anderen Lichtquelle einen verbesserten Messprozess. Wesentliche Fortschritte konnten in der Analysemethodik im Hinblick auf die Bestimmung von physiologischen Parametern auf Basis der Streifenprojektion gemacht werden.

**Aufbau einer umfassenden Datenbasis:** Ausweitung der Kooperation mit Kliniken und Hautärzten und paralleler Betrieb mehrere Demonstratoren an unterschiedlichen Standorten.

Das Messsystem konnte an zwei unterschiedlichen Standorten aufgebaut und zur Datensammlung eingesetzt werden. Beim Aufbau der Datenbasis wurden weitere Krankheitsbilder berücksichtigt. Insgesamt blieb die Fallzahl jedoch hinter den Erwartungen zurück. Die Herausforderungen in der Datenerhebung waren vielfältig, wodurch der Aufbau der Datenbasis nicht wie geplant erfolgen konnte. Beispielhaft sind hier formale Prozesse zu nennen, wie die Diskussionen zur gemeinsamen Verantwortlichkeit bei der Verarbeitung der Daten über Klinik und Institutsgrenzen hinweg.

Im Rahmen des Projekts wurde die DigiWest Technologie eingesetzt, um Proteine zu untersuchen, die Signalprozesse beeinflussen und zu unkontrolliertem Wachstum der Tumore führen. Die Deregulation derartiger Signalprozesse erlaubt eine funktionelle Klassifizierung primärer Melanome, die über eine reine Mutationsanalyse hinausgeht und Hinweise auf wirksame Therapiekonzepte geben kann.





**Aufbau einer verteilten KI-Infrastruktur:** Umsetzung des Federated Learning Ansatzes zum effizienten Training von KI-Modellen unter Wahrung eines niederschwelligen Zugangs und datenschutztechnische Betrachtung zur rechtskonformen Verarbeitung der Daten.

Die Erweiterung der in Intelligente Diagnostik entwickelten lokalen Managementplattform zu einer globalen Federated Learning Plattform wurde vollständig umgesetzt. Das entwickelte Konzept greift die zu Beginn des Projekts spezifizierten Anforderungen auf und wurde durch Anpassungen bereits bestehender Komponenten sowie der Implementierung vollständig neuer Komponenten erfolgreich realisiert. Insbesondere konnten hierbei die von HS-VS umgesetzten Federated Learning Algorithmen in das Gesamtsystem integriert und die Kommunikation zwischen den Komponenten in AP 7 erfolgreich getestet werden.

Verbesserung der Prognosegenauigkeit der KI-Diagnose: Training neuer KI-Modelle auf Basis der neuen erweiterten Datenbasis sowie Verbesserung der KI-Algorithmen für alle im Vorhaben betrachteten Krankheitsbilder.

Das Projekt Intelligente Diagnostik 2 hat insbesondere mit seinem Fokus auf künstliche Intelligenz bemerkenswerte Fortschritte bei der Erkennung von Hautkrebs aus hyperspektralen Bildern erzielt. Die Anstrengungen des Projekts konzentrierten sich in Arbeitspaket 4 darauf, Deep-Learning-Algorithmen zur Klassifizierung dieser Bilder zu verbessern, indem mehr Klassen für eine höhere Genauigkeit integriert wurden. Ein wesentlicher Aspekt des Projekts war auch der verwendete datenschutzorientierte Ansatz zum Training von Deep-Learning-Modellen, welcher Datenschutz-Anforderungen gewährleistet und gleichzeitig die Effizienz der Algorithmen beibehält. Darüber hinaus umfasste das Arbeitspaket 4 eine eingehende Studie zur Identifizierung der relevantesten Wellenlängen für das optische Messsystem. Diese Analyse führte zur Entwicklung eines verfeinerten und effizienteren Modells, das nur die bedeutendsten Wellenlängen nutzt. Dies war ein entscheidender Schritt zur Miniaturisierung des endgültig bereitgestellten Modells. Zusätzlich konnte im Projekt das verteilte Lernframework durch die Integration von Differential Privacy und Server-Client-seitiger Authentifizierung erfolgreich erweitert werden. Diese Verbesserung macht die Architektur des verteilten Lernens sicherer und robuster. Für die abschließende Bereitstellungsphase durchlief das Modell einen Komprimierungsprozess unter Verwendung von NVIDIAs TensorRT. Diese Optimierung war entscheidend für eine effiziente Inferenz auf dem KOMPASSmobile-System und gewährleistete, dass die Effektivität des Modells in einem kompakteren und bereitstellbaren Format erhalten blieb.

**Entwicklung einer flexiblen Prototypen-nahen Prozesskette:** Durch den Einsatz der Nanoprägelithographie sollen verschiedene optische Ansätze frühzeitig als funktionsfähige miniaturisierte Prototypen testbar sein und die Entwicklung des KOMPASSmobile-Systems unterstützen.

Im Rahmen des Projekts zeigten sich große Herausforderungen bei der galvanischen Abformung im Rahmen der Bauteilherstellung (Wabenkondensor) für das KOMPASSpro-System. Über den Projektverlauf wurden neben der mechanischen Nachbearbeitung des Spritzgusswerkzeugs auch der Prozess der galvanischen Abformung weiter untersucht und überarbeitet. Mit Hilfe eines erarbeiteten Halterungssystems können Nickelstrukturen nun reproduzierbar in gleichbleibenden Geometrien abgeformt werden. Auch der Übertrag optischer Mikrostrukturen ist möglich.





**Entwicklung des KOMPASSmobile-Systems**: Hierzu gehören u.a. die Optimierung der Demonstratoren (KOMPASSpro) sowie die Entwicklung eines miniaturisierten Systems mit integrierter Client-Anwendung (KOMPASSmobile).

Die im Rahmen von AP 2 erstellten Konzepte zur Verbesserung des Messsystems wurden in den KOMPASSpro-Demonstrator überführt. Im Rahmen von AP6 und AP 7 konnte erfolgreich ein Messgerät im Tablet-Format fertig gestellt werden, mit dem rudimentäre Messungen möglich sind. Auch die Software-Anwendung für das KOMPASSmobile-System mit Anbindung an die Federated Learning Plattform wurde erfolgreich umgesetzt. Allerdings konnte nicht ausreichend getestet werden, ob das KOMPASSmobile-Konzept einen Vorteil gegenüber rein optischer Melanom Detektion bringt.

In Tabelle 1 sind die Ziele des Projekts in Form von Meilensteinen aufgelistet. Auf die Erreichung dieser wird im Bericht nachfolgend im Detail eingegangen.

Tabelle 1: Arbeitspakete und Meilensteine

Meilenstein	Inhalt	Status	
M1.1	Ergebnisse zu Einsatzszenarien und Grobspezifikation der Architektur liegen vor und sind dokumentiert	abgeschlossen	
M1.2	Prozessmodelle und Diagnosekette liegen vor	abgeschlossen	
M1.3	Risikoanalyse liegt vor	abgeschlossen	
M2.1	Modifikationen für das klinische Gerät (KOMPASSpro) konzipiert und implementiert	abgeschlossen	
M2.2	Modellgestützte Bestimmung von Gewebeparametern möglich und gegebenenfalls mit dem KI-System verknüpft	abgeschlossen	
M2.3	KOMPASSpro-Geräte aufgebaut und Messsysteme evaluiert	abgeschlossen	
M3.1	Vergleich der Messung der optimierten Demonstratoren (KOMPASSpro) mit Expressionsanalyse ist abgeschlossen	weiterer Forschungsbedarf	
M3.2	Vergleich von KOMPASSmobile-Messung mit Expressionsanalyse ist abgeschlossen	weiterer Forschungsbedarf	
M4.1	Ein Deep-Learning-Modell liegt vor, welches eine Genauigkeit von > 90% auf Testdaten erzielt	abgeschlossen	
M4.2	Ein Federated Learning Framework liegt vor, welches das Klinikübergreifende Training von Deep-Learning-Modellen ermöglicht	abgeschlossen	
M4.3	Die Relevanz einzelner Parameter des optischen Messsystems (bspw. Wellenlängen, Frequenzen) wurden ermittelt und an das ILM zur Optimierung des KOMPASS-Systems zurückgespielt.	Abgeschlossen	
M4.4	Das Deep-Learning-Modell ist zur Inferenz auf dem KOMPASSmobile- System optimiert	abgeschlossen	
M5.1	Architekturmodell für das Backendsystem liegt vor	abgeschlossen	
M5.2	Globales Federated Learning Backend liegt vor und ist deployed	abgeschlossen	
M5.3	Weiterentwicklung des lokalen Backends für Federated Learning ist umgesetzt	abgeschlossen	
M5.4	Federated Learning UI ist umgesetzt	abgeschlossen	
M6.1	Konzept des KOMPASSmobile-Systems festgelegt und Schnittstellen definiert	abgeschlossen	
M6.2	Entwicklung der gesamten Hardware (Optischen Elemente, Optomechanik und Elektronik) des KOMPASSmobile-Systems abgeschlossen	abgeschlossen	
M6.3	Optik und Optomechanik des KOMPASSmobile-Systems gefertigt, alle Einzelkomponenten vorhanden	abgeschlossen	





146.4	Optik-Komponenten des KOMPASSmobile-Systems gefertigt und	weiterer	
M6.4	assembliert und an HS-VS übergeben	Forschungsbedarf	
NAC E	Messkopf des KOMPASSmobile-Systems aufgebaut und	abgeschlossen	
M6.5	Einzelkomponenten sowie Elektronik integriert		
M6.6	Software Client für das KOMPASSmobile-System ist umgesetzt	abgeschlossen	
	Integriertes Gesamtsystem bestehend aus KOMPASSmobile-System	abgeschlossen	
M7.1	(Sensorik, Mobiler Clientanwendung) und Backend (KI-Modell,		
	Verwaltungs- und Diagnose-Komponenten) liegt vor		
M7.2	Validierung des Messkopfs des KOMPASSmobile-Systems ist	weiterer	
1017.2	abgeschlossen	Forschungsbedarf	
M7.3	Klinische Tests wurden durchgeführt und die abschließende Auswertung	Weiterer	
1017.3	der KI-basierten Diagnosen ist erfolgt.	Forschungsbedarf	

## 1.4 Verwertbarkeit der Projektergebnisse

Aus dem Projektvorhaben von Intelligente Diagnostik 2 resultieren unterschiedlichste Ergebnisse, die teils großes Potential zur weiteren Verwertung in zukünftigen Systemen und Vorhaben aufweisen. Die Möglichkeiten zur wirtschaftlichen Verwertung werden im nachfolgenden Unterkapitel 1.4.1 vorgestellt. Welche Maßnahmen zur Verbreitung der erzielten Resultate durchgeführt wurden und welche weiteren Maßnahmen geplant sind, wird im Unterkapitel 1.4.2 präsentiert.

#### 1.4.1 Wirtschaftliche Verwertbarkeit der Ergebnisse

Das im Projekt entwickelte Diagnosesystem dient der Verbesserung der Hautkrebsdiagnostik in Kliniken und Arztpraxen. Eine Weiterentwicklung von diesem Demonstrator zu einem produktiven System ermöglicht den Einsatz in bestehenden Diagnoseprozessen zur Unterstützung einer zuverlässigen Beurteilung auffälliger Hautläsionen. Der Einsatz des Systems reduziert somit potenziell die Anzahl von Fehldiagnosen und führt wiederrum zu einer Verringerung der Anzahl unentdeckter bösartiger Melanome, welche gerade bei später Diagnose mit einer hohen Sterblichkeitsrate einhergehen. Auch die Anzahl invasiv zu entfernender Muttermale, welche zuvor fälschlicherweise als Melanome klassifiziert worden wären, kann durch die Integration des Diagnosesystems potenziell reduziert werden. Für das Gesamtsystem besteht derzeit noch weiterer Forschungs- und Evaluationsbedarf. Teilergebnisse können bereits jetzt in unterschiedlichen Szenarien verwertet werden und werden im Folgenden näher beschrieben.

Im Rahmen von Arbeitspaket 1 wurden weitere Anwendungsbereiche für das im Projekt entwickelte Gesamtsystem und für die Teil-Komponenten identifiziert. Diese Auflistung an alternativen Anwendungsbereichen verdeutlicht die umfangreichen Verwertungsmöglichkeiten der erarbeiteten Ergebnisse (siehe Abschnitt 2.1.1). Neben dem Anwendungsbereich der Hautkrebsdiagnostik wurde beispielsweise der Einsatz des Messsystems zur Qualitätssicherung in der Lebensmittelindustrie oder die Nutzung der multispektralen Lichtquelle als variables Beleuchtungssystem in medizinischen Geräten als zusätzliche Verwertungsmöglichkeiten identifiziert. Weitere zusätzliche Anwendungsbereiche sind in Tabelle 2 aufgeführt.

Auch die Arbeiten und Ergebnisse in der modellgestützten Auswertung der Reflektanzkurven zur Bestimmung physiologischer Parameter können in vielen Bereichen zur Anwendung kommen. Viele





der Prozesse sind generell bei der Auswertung von Messergebnissen gültig und könnten sowohl im biomedizinischen Bereich als auch in technischen Bereichen genutzt werden.

Das im Projekt entwickelte neue Konzept für die Erzeugung der Streifenmuster mithilfe eines DMDs und Doppelprismen stellt eine deutliche Verbesserung der Messinstrumente dar. Zusammen mit den Neuerungen in der Software erlaubt es eine deutlich robustere Handhabung und Anwendbarkeit der Messmethode. Die entwickelten Geräte sollen mit einer angepassten Lichtquelle in weiteren Projekten eingesetzt werden.

Das Konzept der Belichtungsoptik für das KOMPASSmobile-System (AP6 und AP7), bei dem zwischen Streifenmustern und Spektralkanälen ohne bewegte Teile oder aufwendige Elektronik wie DMDs geschaltet werden kann, kann ebenfalls potenziell für miniaturisierte und spezialisierte Anwendungen genutzt werden.

Mit den am NMI in AP2.3 entwickelten Methoden zur Fein-Charakterisierung von Tumorgewebe hat das NMI die Möglichkeit in öffentlich geförderten Projekten als kompetenter Partner in der angewandten Forschung mitzuwirken. Weiterhin werden die im Projekt entwickelten und verbesserten Methoden in direkten Forschungs- und Entwicklungsaufträgen der Pharmaindustrie und von Biotechfirmen eingesetzt.

In Bezug auf die Deep Learning Modelle des Projekts Intelligente Diagnostik 2 ist die wirtschaftliche Tragfähigkeit der Ergebnisse, insbesondere für das Modell "Netcdf Importance", aufgrund der guten Ergebnisse in den Bereichen Precision und Recall klar ersichtlich. Die hohe Leistung dieses Modells in diesen Bereichen, die für eine genaue Krebserkennung entscheidend sind, deutet darauf hin, dass es die Fehldiagnosen erheblich reduzieren und das umfassende Screening verbessern könnte. Darüber hinaus unterstreicht seine ausgewogene Leistung, mit dem höchsten Matthews-Korrelationskoeffizienten (MCC) und einem starken F1-Score, seine Eignung für medizinische Diagnostik und steigert damit seinen wirtschaftlichen Wert. Im Gegensatz dazu waren die Modelle "Image" und "Image + ISIC Dataset" weniger umfassend als der hyperspektrale Ansatz, obwohl sie in AUROC und Spezifität herausragten.

Aus wirtschaftlicher Sicht hebt die überlegene Leistung des Modells "Netcdf Importance" in Sensitivität, Spezifität und F1-Scores das Potenzial der hyperspektralen Bildgebung als genaueres und zuverlässigeres Werkzeug über die medizinische Diagnostik mit traditioneller RGB-Bildgebung. Darüber hinaus verbesserte die Verwendung weniger Wellenlängen nicht nur die Leistung, sondern reduziert auch die Kosten, da im Vergleich zum Projekt Intelligente Diagnostik weniger umfangreiche Hardware benötigt wird. Dieser neue Ansatz senkt somit die Gesamtkosten diagnostischer Geräte und macht sie für den klinischen Einsatz wirtschaftlich rentabler.

Zusammenfassend konnte, insbesondere durch das Modell "Netcdf Importance" und dessen Genauigkeit, Effizienz und Wirtschaftlichkeit gezeigt werden, dass der im Projekt verfolgte Ansatz der hyperspektralen Bildgebung, ein signifikantes wirtschaftliches Potenzial besitzt und einen bemerkenswerten Fortschritt gegenüber herkömmlichen RGB-basierten Modellen in der Hautkrebsdiagnostik ermöglicht.





Der Ansatz des Verteilten Lernens wird bereits aktiv weiterentwickelt und für die Anwendung in anderen Einsatzszenarien generalisiert. Im Projekt ROUTINE werden beispielsweise auf Basis der im Projekt entwickelten, globalen Federated Learning Plattform, Prozessmuster für den flexiblen Entwurf entsprechender Systeme abgeleitet. Mit der Projektskizze FEDERALIS wird zudem eine weitere Modularisierung der Softwarekomponenten verfolgt. Ziel ist es, dass flexible Federated Learning Prozesse auf den Anwendungsfall der Darmkrebserkennung übertragen werden.

Schließlich bietet das im Projekt entwickelte verteilte Lernframework in Kombination mit der globalen Managementplattform Vielseitigkeit für verschiedene Anwendungen und erhöht sein wirtschaftliches Potenzial unter anderem durch die Ausweitung des Einsatzgebietes. Durch den verteilten Betrieb können Standorte von Trainingsdaten anderer Standorte profitieren und auch Haus- sowie Hautarztpraxen an das Gesamtsystem angebunden werden (siehe Abschnitt 2.1.2). Auch die mögliche Weiterentwicklung des umgesetzten KOMPASSmobile-Systems zu einem produktiven System vergrößert den potenziellen Anwenderkreis, indem auch kleinere Praxen ein entsprechendes Messsystem aufgrund dessen Kompaktheit stellen könnten.

#### 1.4.2 Maßnahmen zur Verbreitung der Projektergebnisse

Das Forschungsverbundprojekt Intelligente Diagnostik 2 wurde von einem Ausschuss mit zehn Vertretern der Wirtschaft begleitet. Zwei veranstaltete Projekttreffen (ein Online-Workshop am 13. Oktober 2022 und eine hybride Abschlussveranstaltung am 28. November 2023) ermöglichten es dem Projektbegleitenden Ausschuss sich über die erzielten Projektergebnisse zu informieren und gezielt Anregungen und Feedback in das Projektvorhaben einzubringen. Die im Rahmen des Projekts Intelligente Diagnostik erstellte Projektwebsite wurde um die Inhalte des Projekts Intelligente Diagnostik 2 erweitert. Die Website ist weiterhin unter <a href="www.intelligente-diagnostik.de">www.intelligente-diagnostik.de</a> sowie unter <a href="www.intelligente-diagnostik.de">www.intelligente-diagnostik.de</a> sowie unter <a href="www.intelligente-diagnostik2.de">www.intelligente-diagnostik.de</a> sowie unter <a href="www.intelligente-diagnostik.de">www.intelligente-diagnostik.de</a> sowie unter <a href="w

Auch auf institutseigenen Veranstaltungen, wie beispielsweise dem FZI Open House, wurde das Projektvorhaben vorgestellt. Zudem sind Teilnahmen auf zukünftigen Veranstaltungen geplant. So wird das KOMPASSmobile-System beispielsweise auf der Embedded World 2024 in Nürnberg ausgestellt. Darüber hinaus wurde eine Bewerbung für einen Vortrag zum Projekt Intelligente Diagnostik 2 auf der re:publica 24 in Berlin eingereicht. Neben der Verbreitung der Projektergebnisse über Vorträge, trägt auch die Fortführung der Arbeiten im Rahmen weiterer Forschungsprojekte zur Verbreitung der Projektergebnisse bei.





## 2 Wissenschaftlich-technische Ergebnisse

## 2.1 AP1 - Analyse der Anforderungen und Nutzungsszenarien (FZI)

#### 2.1.1 AP1.1 - Anwendungsdomänen, Nutzungsszenarien und Anforderungen

Im Hinblick auf eine mögliche spätere Verwertung der Projektergebnisse auch in anderen Bereichen als der Hautkrebsdiagnostik, waren im Arbeitspaket 1.1 zunächst mögliche zusätzliche Anwendungsdomänen für das gesamte System und Teilkomponenten zu identifizieren. Dazu wurde von den Projektpartnern eine Auflistung bezüglich der möglichen weiteren Anwendungsgebiete der jeweiligen Inhalte erstellt. Dabei wurden allgemeine Aussagen zur Übertragbarkeit der Ansätze abgeleitet, wie beispielsweise, dass das Managementsystem-Backend für nahezu beliebige Anwendungsbereiche, in denen überwachtes Lernen auf Basis hyperspektraler Bilddaten durchgeführt wird, ohne große Änderungen verwendet werden kann, wenn die netCDF-Datenstruktur beibehalten wird. Auch spezifische Anwendungsbeispiele, wie die Fernüberwachung des Wachstums von Nutzpflanzen, die Überwachung der Wundheilung von Brandwunden oder die Fluoreszenzanregung in der Mikroskopie wurden identifiziert und dokumentiert. Einen Ausschnitt aus der Liste aller identifizierten Anwendungsdomänen bietet Tabelle 2. Neben der Komponente sowie der Nennung der Anwendungsdomäne, enthält die Tabelle zudem eine kurze Beschreibung der notwendigen Anpassungen.

Tabelle 2: Auszug aus der Tabelle der identifizierten weiteren Anwendungsdomänen (neben der Hautkrebsdiagnostik)

KOMPONENTE	BESCHREIBUNG DER NEUEN ANWENDUNGSDOMÄNE	GROBE BESCHREIBUNG DER NOTWENDIGEN ANPASSUNGEN
GESAMTSYSTEM	Überwachung von verderblichen Waren/Chemikalien während/nach dem Transport	Die Hyperspektralkamera muss durch geeignete Sensoren und/oder Kameras ersetzt werden und es müssen geeignete Daten gesammelt werden, um die KI-Modelle zu trainieren (das Managementsystem ist entsprechend anzupassen).
GESAMTSYSTEM	Überwachung schädlicher Umgebungsbedingungen, z.B. Mülldeponien, Recyclinganlagen, Industrieanlagen	Die Hyperspektralkamera muss durch geeignete Sensoren und/oder Kameras ersetzt werden und es müssen geeignete Daten gesammelt werden, um die KI-Modelle zu trainieren (das Managementsystem ist entsprechend anzupassen).
SFD MESSSYSTEM	Bildgebendes Verfahren für Surgical Guiding	Real-Time Datenaufnahme und Verarbeitung, Kombination mit Endoskop
SFD MESSSYSTEM	Industrielle Prozessüberwachung bzw. Qualitätssicherung in der Lebensmittelindustrie	Real-Time Datenaufnahme und Verarbeitung
MULTISPEKTRALE LICHTQUELLE	Variables Beleuchtungssystem für medizinische Geräte	Anpassung der Strahlformung und Ansteuerung

Neben der Identifikation weiterer Anwendungsdomänen war die Grobspezifikation der Systemarchitektur Teil von Arbeitspaket 1.1. Die Anpassung der im vorangegangenen Projekt Intelligente Diagnostik erstellten Grobspezifikation war insbesondere aufgrund des verfolgten Federated Learning Ansatzes und der Entwicklung der mobilen KOMPASS-Systeme notwendig. Abbildung 1 zeigt den geplanten Systemaufbau. Dabei wird zwischen der globalen Federated Learning Plattform sowie einem oder mehreren lokalen Managementplattformen unterschieden. Die Spezifikation der lokalen Plattform orientiert sich an der Systemspezifikation im Projekt Intelligente





Diagnostik. Die folgenden Punkte mussten jedoch im Vergleich zum Projekt Intelligente Diagnostik auf lokaler Ebene angepasst werden:

- Kombination aus Messsystemsoftware und Managementsystem-Client für die KOMPASSmobile-Systeme
- Empfang von netCDF-Dateien über Micro Services (anstelle der Kommunikation über das Filesystem) sowie das Starten der entsprechenden Postprocessing-Prozesse vom Managementsystem aus
- Kommunikation mit dem globalen System insbesondere auch bezüglich des Austauschs von KI-Modellen

Die wesentliche Anpassung des bestehenden Konzepts ist jedoch die Hinzunahme globaler Systemkomponenten. Diese ist notwendig um zukünftig den angestrebten Federated Learning Ansatz umzusetzen. Demnach werden im Vergleich zum Projekt Intelligente Diagnostik die folgenden Systemkomponenten zusätzlich Teil des Gesamtsystems:

- Globales Managementsystem
- Globale Meta-Datenbank
- Komponente mit globalen Federated Learning Funktionalitäten
- Webbasiertes GUI für administrative Funktionen

Die Kommunikation zwischen dem globalen und den lokalen Systemen erfolgt sowohl zwischen den KI-System-Komponenten als auch zwischen den beiden Managementsystem-Komponenten. Konkrete Ablaufpläne der Kommunikation wurden im Rahmen von AP 1.2 und 5.1 entworfen.

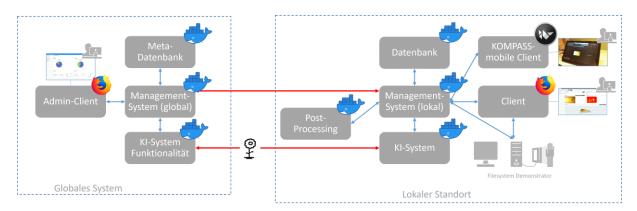


Abbildung 1: Grobspezifikation der Systemarchitektur

Zusätzlich zur Grobspezifikation und der Identifikation weiterer Anwendungsdomänen wurden die Nutzungsszenarien untersucht, die durch den Einsatz und der Vernetzung mehrerer verteilter Demonstratoren mit miniaturisierten Messsystemen neu entstehen. Diesbezüglich wurden insbesondere die folgenden weiteren Anforderungen an das Gesamtsystem abgeleitet:

 Im Rahmen von Intelligente Diagnostik 2 sollen verschiedene Standorte mit einem globalen System, welches die gewonnenen Erkenntnisse aus den einzelnen Standorten nach dem Prinzip des Federated Learnings kombiniert, verbunden werden.





- Hierzu ist insbesondere die Orchestrierung der lokalen Trainingsvorgänge wichtig und muss in den zugrunde liegenden Prozessen berücksichtigt werden (siehe 2.1.2). Im Speziellen soll die Möglichkeit bestehen zentral, innerhalb des globalen Systems, lokale Trainingsvorgänge an unterschiedlichen Standorten zu starten.
- Administratoren sollen im globalen System die Möglichkeit besitzen neue lokale Standorte (lokale Managementplattformen) persistent anzubinden.
- Durch die Fusion von Erkenntnissen aus unterschiedlichen Standorten kann es aufgrund von Standort-spezifischen Ausprägungen zu ungewollten Verzerrungen in der Qualität der Prognose-Genauigkeit kommen. Für dieses Problem sind mögliche konzeptuelle Lösungen zu beschreiben.
- KI-Modelle von Standorten mit einer vergleichsweise größeren Menge an neuen Daten sollen mit einer entsprechenden höheren Gewichtung in die Fusion einfließen können als KI-Modelle von Standorten mit einer geringeren Anzahl neuer Daten.

Die Miniaturisierung des Messsystems impliziert weitere Anforderungen. Neben den Anforderungen an die Umsetzung des konkreten Demonstrator-Aufbaus (Größe, Stromversorgung, etc.), die in Arbeitspaket 6 (siehe 2.6) zusammengetragen wurden, bestehen auch Anforderungen im Kontext des Gesamtsystems. Im Projekt werden die Daten mit den Demonstratoren aus Intelligente Diagnostik erzeugt. Damit die Aufnahmen, welche durch das miniaturisierte System (KOMPASSmobile) erstellt werden, mit Hilfe des KI-Systems klassifiziert werden können, muss die Datenstruktur der Aufnahmen nahezu unverändert bleiben. Dies gilt insbesondere dann, wenn die KOMPASSmobile-Systeme am Federated Learning Prozess teilnehmen. Falls aus designtechnischen Gründen eine Veränderung der Datenstruktur festgelegt wird, muss eine entsprechende Transformation nach den jeweiligen Aufnahmen erfolgen.

#### 2.1.2 AP2.2 - Modellierung von Prozessen sowie der Diagnosekette

Im Arbeitspaket 1.2 wurden die Prozesse des Federated Learning Ansatzes bezüglich der definierten Anforderungen entworfen und modelliert. Der Fokus lag auf der Darstellung der Kommunikation zwischen den einzelnen verteilten Standorten, um auf dieser Basis die konkreten System-Anpassungen und -Erweiterungen im Rahmen von Arbeitspaket 5.1 zu konzipieren (siehe 2.5.1).

In Abbildung 2 ist der angepasste Prozess des Federated Learnings dargestellt. Der Prozess des Prädizierens erfordert keine Kommunikation zwischen dem globalen und den lokalen Systemen und ähnelt daher dem bereits modellierten Prozess aus Intelligente Diagnostik. Der Prozess des Federated Learnings soll in einem regelmäßigen Rhythmus automatisiert ausgeführt werden. Eine zusätzliche Möglichkeit des manuellen Startens durch einen Administrator ist ebenfalls vorgesehen, aber wird als Ausnahmefall angesehen und ist somit nicht Teil der in Abbildung 2 dargestellten Modellierung. Bevor das konkrete Training gestartet wird, wird eine Abfrage bezüglich der Anzahl neu akquirierter Daten je Standort durchgeführt. Auf Basis dieser Informationen kann entschieden werden, ob ein Trainingsvorgang sinnvoll durchgeführt werden kann oder zu wenige Daten zur Verfügung stehen. Falls genügend Daten in den Standorten akquiriert werden konnten, starten lokale Trainingsvorgänge in den jeweiligen lokalen Systemen. Die lokal trainierten Modelle werden daraufhin zum globalen System übermittelt. Dabei handelt es sich lediglich um einen Austausch der Parameter des KI-Modells. Konkrete Trainingsdaten (Rohdaten), die insbesondere im medizinischen Kontext unter Umständen





eine besondere Datenschutz-freundliche Verarbeitung erfordern, werden nicht übermittelt. Durch die Fusion der einzelnen KI-Modelle je Standort wird im globalen System ein neues Modell erstellt. Das fusionierte Modell wird daraufhin wieder an die Standorte verteilt und in diesen als Modell für die Prädiktion gespeichert. Dieses Vorgehen ermöglicht somit, dass Klinik 1 von den Erkenntnissen, die aus den akquirierten Daten von Klinik 2 gewonnen wurden, profitieren kann, ohne dass ein expliziter Austausch der konkreten Rohdaten erfolgen muss.

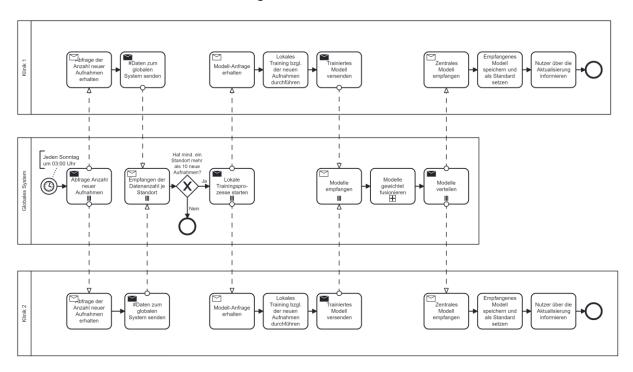


Abbildung 2: Modellierter Federated Learning Prozess zwischen Kliniken

In Abbildung 2 ist der Federated Learning Prozess zwischen zwei Kliniken dargestellt. Beide Kliniken verfügen über die Möglichkeit histopathologische Untersuchungen und damit ein Labeling der Trainingsdaten vorzunehmen. In Arbeitspaket 1.2 wurden zudem Prozesse für die Anbindung von Hautarztpraxen an die globale Federated Learning Plattform untersucht. Aus potenziellen Abweichungen in der Durchführung von Untersuchungen und der Erstellung von Aufnahmen folgt keine direkte Beeinflussung des modellierten Federated Learning Prozesses in Abbildung 2. Falls jedoch in Hautarztpraxen keine histopathologische Untersuchung durchgeführt werden kann, können keine Trainingsdaten in der erforderlichen Qualität erstellt werden. Für Hautarztpraxen, welche keine histopathologische Untersuchung durchführen, ändert sich somit die Anbindung an das System wie in Abbildung 3 dargestellt. Die Hautarztpraxis wird in diesem Fall vom konkreten Trainingsvorgang getrennt, kann aber dennoch vom Federated Learning Ansatz profitieren, indem nach dem Federated Learning Prozess zwischen Kliniken ein neues Modell der Praxis übermittelt wird und somit immer das aktuelle Modell zur Verfügung steht. So kann die Hautarztpraxis Prädiktionen auf Basis der neuesten trainierten Kl-Modelle erstellen, ohne selbst Trainingsdaten akquirieren zu müssen.





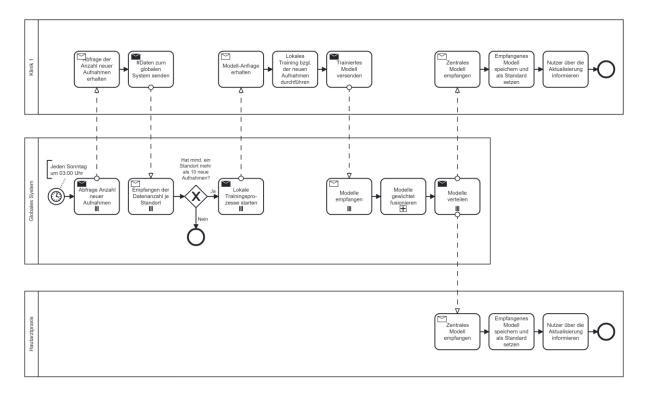


Abbildung 3: Modellierter Federated Learning Prozess mit der Einbindung einer Hautarztpraxis, welche keine Trainingsdaten akquiriert.

In Hautarztpraxen wird zwar in der Regel keine histopathologische Untersuchung vorgenommen, aber Hautläsionen werden von Fachärzten klassifiziert. Auch diese Diagnosen liefern wertvolle Erkenntnisse und sollen somit ebenfalls gesammelt sowie als gesonderte Trainingsdaten im Federated Learning Prozess eingebunden werden. Das Vorgehen ist analog zu dem in Abbildung 2 beschriebenen Prozess. Es wird jedoch empfohlen eine gesonderte Betrachtung beziehungsweise Gewichtung der Modelle aus Praxen, ohne histopathologische Untersuchung, zu berücksichtigen.

Ergänzend zum Einsatz des Systems in Kliniken und Hautarztpraxen war die Verwendung in Hausarztpraxen zu untersuchen. Für die Einbindung von Hausarztpraxen wird ebenfalls der Prozess des Federated Learnings aus Abbildung 3 betrachtet. Entsprechend findet keine Beteiligung an der Trainingsdatenerzeugung und dem Training statt, stattdessen werden Hausärzte ausschließlich als Nutzende (Prädiktion) an den Prozess angebunden. Mit Hilfe des vernetzten Ansatzes erhalten dadurch auch die Hausarztpraxen die jeweils aktuellen KI-Modelle und können somit Prädiktionen für eine vorläufige Diagnose durchführen. Diese könnte beispielsweise zukünftig bei der Entscheidung hinsichtlich einer Überweisung zu einem Facharzt unterstützen.

#### 2.1.3 AP2.3 - Risikoanalyse

Im Rahmen des Arbeitspakets 1.3 fand die Risikoanalyse für das Projektvorhaben statt. Die Bewertung der Risiken erfolgte nach den üblichen Kriterien Eintrittswahrscheinlichkeit und Schweregrad (oft auch als Schadensmaß bezeichnet). Für das Kriterium Eintrittswahrscheinlichkeit (EW) wurde eine Unterteilung in die Klassen häufig, wahrscheinlich, gelegentlich, fernliegend, unwahrscheinlich und unglaubhaft gewählt, für das Kriterium Schweregrad (SG) wurden die Klassen katastrophal, sehr kritisch, kritisch, marginal und vernachlässigbar betrachtet. Abhängig dieser Bewertung wurden die





Risiken in die Klassen Allgemein vertretbarer Bereich (AVB), As Low As Reasonable Practicable (ALARP) und Unvertretbarer Bereich (UVB) gruppiert. Für alle Risiken des Bereiches UVB wurden Gegenmaßnahmen identifiziert und dokumentiert. Auch für die Risiken des allgemein vertretbaren Bereichs und des Bereiches ALARP konnten i.A. Gegenmaßnahmen gefunden werden.

## 2.2 AP2 - Optische Messsysteme (ILM+HS-S)

### 2.2.1 AP2.1 - Verbesserung der Hardware & Software des aktuellen Systems

Ziel von AP 2.1 war, zunächst das in Intelligente Diagnostik 1 entwickelte optische Messsystem instrumentell zu verbessern und schnellstmöglich der Klinik wieder zur Verfügung zu stellen. Als Basis dienten die Ergebnisse aus der bereits durchgeführten klinischen Studie.

Hierzu wurden folgende Verbesserungen durchgeführt:

- Optimierung der Signalqualität durch technische Anpassung der Lichtquelle, u.a. konkret der zentralen Positionierung der lichtschwachen NIR-LED und damit einer erhöhten Intensität
- Entwicklung und Verwendung einer neuen Steuerungselektronik für die bessere Ansteuerung und Integration in das Messgerät
- Entwicklung eines Abstandshalters für Messungen im Kontakt, um Bewegungsartefakte zu
  eliminieren. Im Rahmen der Genehmigung des Ethikantrags wurde hierfür die Verwendung eines
  speziellen Kunststoffes gefordert, der eine mehrfache zuverlässige Desinfektion des
  Abstandshalters gewährleisten soll. Als Material wurde der Kunststoff MED610 gewählt, da er für
  medizinische Anwendungen zertifiziert ist und im 3D-Druck verwendet werden kann. Der Druck
  des Abstandshalters in mehrfacher Ausfertigung und in dem geforderten Kunststoff erfolgte durch
  einen Dienstleister.

Das System wurde erfolgreich überarbeitet, vermessen und dem Klinikum Tübingen zur Verfügung gestellt (s. Abbildung 4). Aufgrund der Schwierigkeiten mit den neuen KOMPASSpro-Systemen wurden alle Messungen in diesem Projekt mit dem Aufbau gemacht. Ein baugleiches System wurde außerdem der Charité in Berlin zur Verfügung gestellt, um weitere Patientendaten zu generieren.









Abbildung 4: Links: Überarbeitetes Messsystem 1 im Untersuchungsraum der Uniklinik Tübingen; rechts: Detailaufnahme des Messkopfes mit additiv gefertigtem Abstandshalter aus weißem Spezialkunststoff (MED610) zur Messung im Kontakt.

#### Konzipierung des neuen KOMPASSpro-Systems

Im Rahmen des Projektes sollten die alten Messgeräte aus Intelligente Diagnostik 1 ersetzt werden, um bessere Bildqualität, Handhabung und Datenauswertung zu ermöglichen. Hierzu wurden folgende Verbesserungen durchgeführt:

- Optimierung der Signalqualität durch technische Überarbeitung der Lichtquelle, insbesondere Verwendung einer eigens entwickelten, speziellen mikrooptischen Einheit zur wesentlich verbesserten Strahlhomogenisierung und Farbmischung sowie eines DMDs (Digital Mirror Device, Vialux Messtechnik) für die Mustergenerierung ohne bewegte Teile (s. Abbildung 5). Hierzu gehört auch die Entwicklung und Umsetzung einer neuen Optomechanik.
- Überarbeitung der LED-Treiberplatine mit verbesserter Helligkeitsstabilität und Triggereingang zur Synchronisation von DMD und LEDs
- Konstruktion und Herstellung neuer Werkzeugeinsätze inkl. der entsprechenden galvanischen Abformung
- Abmusterung weiterer Bauteile in Spritzgussanlage





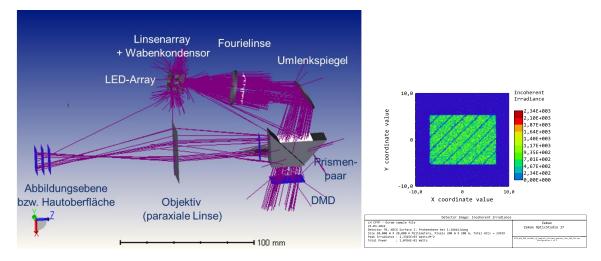


Abbildung 5: Links: Optikdesign des neuen Messsystems mit Prismenpaar und DMD für die Mustergenerierung; es sind nur Strahlen der zentralen NIR-LED dargestellt; rechts: simulierte Strahlverteilung auf der Haut bei homogener Beleuchtung (die dünnen Streifen dienen der besseren Erkennung der Abbildungsebene).

In Abbildung 5 ist das optische Design der neuen Messgeräte abgebildet. Die angesprochene mikrooptische Einheit zur Homogenisierung der LED-Strahlen bildet den ersten Teil des Aufbaus. Anstatt eines Lichtmischstabes, wie er in den Messgeräten aus Intelligente Diagnostik 1 eingebaut ist, wird die LED-Beleuchtung über ein Linsenarray kollimiert, einen Wabenkondensor homogenisiert und mit einer Fourierlinse auf den DMD abgebildet. Vor dem DMD ist ein Doppelprisma positioniert, was den Strahlengang auf den DMD und zum Objektiv festlegt. Dieses Design bedeutet eine deutliche Platzeinsparung bei der miniaturisierten Lichtquelle und die Möglichkeit beliebige Streifenmuster zu projizieren ohne bewegte Teile.



Abbildung 6: DMD der Firma Vialux Messtechnik für die Generierung von beliebigen Streifenmustern ohne bewegte Teile.

#### **Verbesserung Software**

Die Software für die Koordination der Messungen und Verwaltung der Daten wurde neu geschrieben. Die Kommunikation mit der neuen Treiberplatine und dem DMD musste implementiert werden. Bei der Entwicklung der Software wurde darauf geachtet, das Datenmanagement zu verbessern und Schnittstellen zu schaffen mit denen die direkte Auswertung der Messungen möglich ist.

Die neuen Features in der Software sind:

Ansteuerung von DMD und neuer LED-Treiberplatine





- Verbessertes Datenmanagement
- Direkte Auswertung der Messungen im Hinblick auf die optischen Eigenschaften

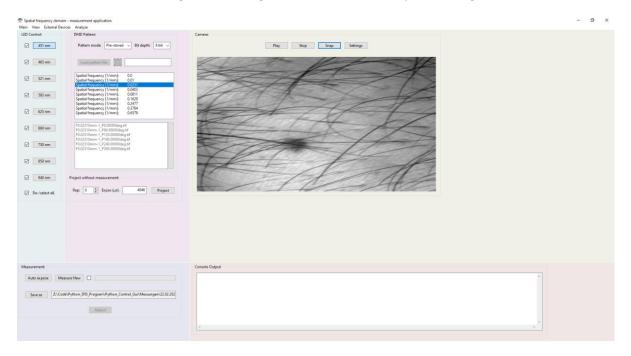


Abbildung 7: Oberfläche der neuen Messsoftware mit Steuerungselementen für Lichtquelle, DMD und Kamera.

## 2.2.2 AP2.2 - Erweiterung der modellgestützten Datennachbearbeitung auf Grundlage der Gewebeoptik

In AP 2.2 sollten die instrumentellen Anpassungen des Systems zunächst validiert werden und insbesondere die modellgestützte Bestimmung von physiologischen Parametern auf Grundlage der klinischen Daten weiterentwickelt werden. Für den Vergleich der Messsysteme anhand von Phantomen wurden insgesamt 4 Proben konzipiert, die die optischen Eigenschaften von Haut weitestmöglich entsprechen (siehe Abbildung 8).





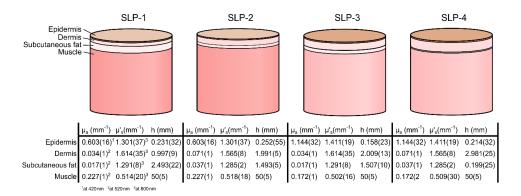
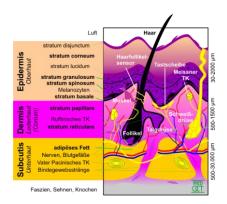




Abbildung 8: (Oben) Parametervariation für die vier Phantome. Die Dicken der Schichten sowie die optischen Eigenschaften werden variiert. (Unten) Gefertigte Proben.

Vor der Auslieferung aller optischen Messsysteme in diesem Projekt wurden die Proben gemessen. Diese Hautphantome sollten dazu beitragen, die Systeme untereinander zu vergleichen.

Die Datenauswertung in Hinblick auf physiologische Parameter wurde auch weiterentwickelt. Die Lichtausbreitung im Gewebe wird von mehreren Faktoren beeinflusst, unter anderem die Streu- und Absorptionskoeffizienten der involvierten Gewebearten. Im Falle von Haut sollte man zusätzlich den geschichteten Aufbau der Haut berücksichtigen. Physiologische Parameter wie die Hämoglobin-, Melanin- und Wasserkonzentration können von Hautschicht zu Hautschicht variieren und dementsprechend unterschiedlichen Einfluss auf die Ortsfrequenzmessungen nehmen. Insbesondere die Melanin-Konzentration ist im Falle von Melanomen ein wichtiges physiologisches Merkmal.



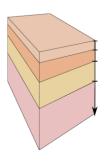


Abbildung 9: Physiologischer Aufbau der Haut (links). Rechts: Hautmodel für die Vorwärtsrechnung mit der Monte-Carlo-Simulation. Die einzelnen Hautschichten werden als homogene Schichten mit einheitlichen Streu- und Absorptionseigenschaften angenommen.





In den Voruntersuchungen werden Monte-Carlo-Simulationen verwendet, um in Vorwärtsrechnungen die Reflektanz (Rsfd) für unterschiedliche Zusammensetzungen der Haut zu berechnen. Diese Monte-Carlo-Rechnungen dienen als Ersatz für die Messungen mit den KOMPASS-Systemen. Die Ergebnisse werden nach Ortsfrequenz und Spektralbereich aufgezeichnet (siehe Abbildung 10). Es wurde eine Methodik entwickelt, die physiologischen Parameter mithilfe eines iterativen Anpassungsverfahrens bestimmen. Dafür wurde hergeleitete Lösung zu eine am ILM analytische Strahlungstransportgleichung für mehrschichtige Systeme hinzugezogen. Für die Anpassung werden erste Annahmen zu den Konzentrationen der wichtigen Chromophore (Melanin, Hämoglobin, Wasser) sowie den Streueigenschaften gemacht. Mit der Lösung der Strahlungstransportgleichung wird in der Vorwärtsrechnung die Reflektanz für dieselben Spektralbereiche und Ortsfrequenzen wie in der Monte-Carlo-Simulation bestimmt und miteinander verglichen. Nach dem Vergleich werden die Annahmen für die physiologischen Parameter angepasst. Dieser Prozess wird iterativ wiederholt, um mit der Methode der kleinsten Abstandsquadrate die Differenz zwischen den Monte-Carlo-Simulationen und den Vorwärtsrechnungen zu minimieren und somit die tatsächlich vorliegenden physiologischen Parameter zu finden.

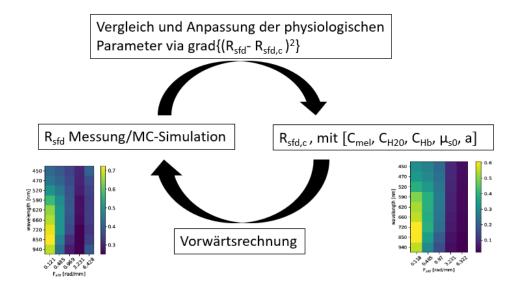


Abbildung 10: Schema für die Bestimmung der physiologischen Parameter. Iterative Anpassung der Konzentrationen von Melanin, Hämoglobin und Wasser für die Vorwärtsrechnung und Vergleich mit den Messergebnissen.

Grundsätzlich ist die Bestimmung der physiologischen Parameter mit diesem Verfahren möglich. Allerdings ist dieses iterative Verfahren sehr rechenintensiv und benötigt spezielle, am ILM geschriebene Software, damit die Vorwärtsrechnung funktioniert. Außerdem konnte die Genauigkeit, mit der physiologische Parameter bestimmt werden, nicht ausreichend getestet werden, um eine Einbindung in das KI-System während der Laufzeit des Projektes sinnvoll durchzuführen. Starken Einfluss auf die Anpassung hat auch die Qualität der Messdaten selbst. Einen Vergleich dafür wurde mit den Hautphantomen gemacht, die im Projekt als Referenz dienten (siehe oben). Ein Vergleich zwischen diesen Messungen an den Hautphantomen und einer Vorwärtsrechnung mit Monte-Carlo-Simulation ergaben eine Differenz der Reflektanzwerte von ca. 10 %. Bei der Evaluierung der Genauigkeit der physiologischen Parameter sollte daher nicht von einer besseren Genauigkeit als 10 % ausgegangen werden.





#### 2.2.3 AP2.3 - Aufbau und Hardwareevaluation der KOMPASSpro-Demonstratoren

Ein großes Problem währende des Projektes waren die Lieferengpässe besonders in dessen Anfangsstadium. Viele Komponenten kamen mit Verzögerung oder es mussten Alternativen gefunden werden, was zu deutlichen Verspätungen im Aufbau geführt hat. Ein wesentlicher Schritt im Rahmen der Arbeiten in AP 2 zum Aufbau verbesserter Systeme (KOMPASSpro) für die Klinik war der Aufbau und Test der multispektralen LED-Beleuchtungseinheit inkl. Des Wabenkondensors zur Strahlhomogenisierung.

Beim Aufbau der mikrooptischen Einheit zeigte sich schnell, dass die von HS-S zur Verfügung gestellte Aufnahme zur Halterung der ebenfalls von HS-S im Spritzguss hergestellten 3x3 Mikrolinsenarrays (MLA) keine ausreichend exakte Positionierung der einzelnen MLA-Elemente erlaubt. Die mikrostrukturierten optische Kunststoffkomponenten, welche zur Homogenisierung der Lichtquelle dienen, wurden als doppelseitig strukturiertes Mikrolinsenarray ausgelegt und im ersten Projektteil auf Basis der galvanischen Replikation mittels Spritzgusses hergestellt.

Eine große Herausforderung bildet die Ausrichtung der Wabenkondensoren untereinander, da jede LED der Beleuchtungseinheit einen nachfolgenden Wabenkondensor erfordert. Da in der multispektralen Lichtquelle neun LEDs vorgesehen sind, werden daher neun zueinander ausgerichtete Wabenkondensoren benötigt.

Hierzu wurden die Wabenkondensoren mit einer Entformschräge von 3 Grad an den Seiten des Bauteils versehen. Die Bauteile selbst sind, bedingt durch den Spritzprägeprozess, in einer Polymerplatte eingefasst (siehe Abbildung 12). Verringerte Wanddicken an den Seiten des Bauteils sollen als Soll-Bruchstellen ein einfaches Herauslösen der Bauteile nach dem Spritzguss ermöglichen.

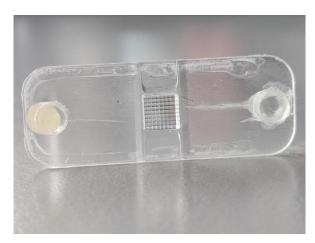


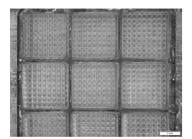
Abbildung 12: Wabenkondensor vor dem Heraustrennen

Das Heraustrennen der Bauteile stellte sich im Projektverlauf als kritisch heraus (siehe Abbildung 13). Ein Herausbrechen oder –trennen der Bauteile führte zu einer stark hervortretenden Naht an den Bauteilflanken. Diese konnte nicht präzise von dem Bauteil entfernt werden, was zu einem Verkippen in der gefertigten Halterung führte. Diese Verkippung wirkt sich entsprechend negativ auf die Homogenisierung des Lichts aus. Installation und Halterung der Wabenkondensoren konnte realisiert werden, jedoch Qualitätseinbußen, durch die mechanische Nacharbeiten bislang noch nicht ausgeglichen

werden konnten. Eine Heraustrennung mittels Stanzen konnte im Rahmen des Projekts nicht mehr realisiert und untersucht werden.











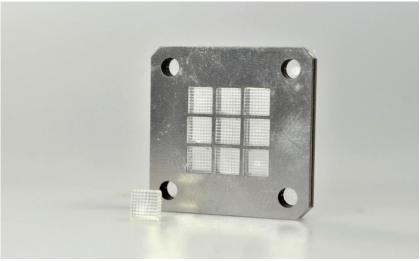


Abbildung 13: Die Entgratung der Wabenkondensoren nach dem Heraustrennen konnte nicht hinreichend gezeigt werden. Dies hatte eine Verkippung der Wabenkondensoren zueinander in der vorgesehenen Haltung zufolge.

Insbesondere die stark variierende Verkippung der Elemente wirkt sich direkt als inhomogene Ausleuchtung des DMDs aus. In einem verbesserten Aufbau zur korrekten Ausrichtung und Fixierung der Elemente mittels eines aufgeweiteten Helium-Neon-Laserstrahls anstelle der LEDs wurden die, in einer Halterung beweglich fixierten MLA-Elemente bestrahlt und im Fokus der Fourierlinse auf einer Mattscheibe die Lage des resultierenden homogen ausgeleuchteten Quadrats überprüft. Hierzu wurden die Wabenkondensoren zwischen zwei additiv gefertigten Halterungen positioniert, die speziell an die unterschiedlichen konischen Verläufe der MLA-Seitenwände angepasst sind. Ausgehend von der Bildlage des mittleren MLA-Elements, wurden so die anderen 8 MLAs sukzessive justiert. Zur Verifikation im eigentlichen Aufbau wurden über die spezielle Softwaresteuerung die LED-Beleuchtungslichtquellen einzeln angesprochen. So konnte über eine Abbildung wiederum auf eine Mattscheibe (anstelle des DMDs) die Positionierung der Wabenkondensoren zueinander verifiziert werden. Über ein Kamerasystem wurden die so erzeugten Muster dokumentiert und in der Qualität der Ausleuchtung final beurteilt (s. Abbildung 14).





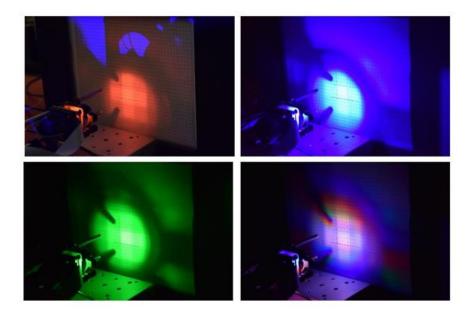


Abbildung 14: Kamerabilder zu Lage der homogen ausgeleuchteten Areale bei vier verschiedenen LEDs. Die Mattscheibe ist dort positioniert, wo im Gerät der DMD zur Mustererzeugung sitzt; bei der roten LED ist eine fehlerhafte Positionierung vor Justage des MLA zu sehen.

Diese Schwierigkeiten mit den Wabenkondensoren erlauben es nicht mit dem Gerät eine ausreichende Abbildungsqualität zu erzeugen. Eine homogene Ausleuchtung der Messebene ist eine Voraussetzung für eine sinnvolle Streifenprojektion. Die Problematik konnte für die KOMPASSpro-Systeme nicht ausreichend gelöst werden, sodass die Geräte während des Projekts nicht im Einsatz waren. Die weiteren Arbeiten zur Konstruktion und Herstellung der mechanischen Komponenten wurden abgeschlossen. Spezialhalterungen für DMD, Objektiv und Umlenkspiegel sowie Kamerahalterung wurden konstruiert und gefertigt. Die neue Steuerungsplatine für die Lichtquelle wurde ebenfalls gefertigt und in den Aufbau integriert. Abbildung 15 zeigt das KOMPASSpro-System ohne Gehäuse. Alle Komponenten konnten in einem geschlossenen System zum Laufen gebracht werden.

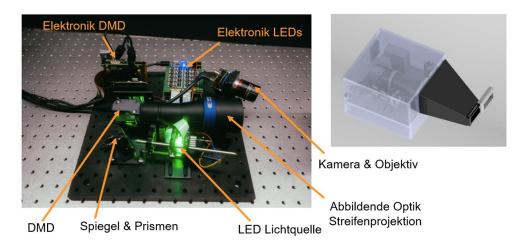


Abbildung 15: Links: KOMPASSpro-System ohne Gehäuse. Rechts: Darstellung des KOMPASSpro-Systems mit Gehäuse und Abstandshalter.

Um das Gerät weiter für zukünftige Projekte zu entwickeln, wurden auch Versuche mit alternativen Lichtquellen gemacht. Eine derartige Lichtquelle war eine fasergekoppelte LED, wobei das Faserende





auf den DMD abgebildet wird. Diese alternative Lichtquelle hat zu einer ausreichenden homogenen Ausleuchtung des Messbereichs geführt. Diese Untersuchungsergebnisse standen erst zu einem weit fortgeschrittenen Zeitpunkt des Projektes zur Verfügung. Eine derartige Lichtquelle wäre auch nicht mehr im Budget des Projektes vorhanden gewesen (die Größenordnung der Kosten für eine äquivalente fasergekoppelte liegt bei 20.000 €).

Neben der mechanischen Nachbearbeitung des Spritzgusswerkzeugs wurde auch der Prozess der galvanischen Abformung weiter untersucht und überarbeitet. Dazu wurden mithilfe eines "Deposit Stress Analyzers" der Einfluss der galvanischen Badparameter auf die Eigenspannung von galvanischen Nickelschichten untersucht, um optimale Parameter für die Abscheidung möglichst spannungsarmer Schichten festzulegen. Für Abscheideraten im Bereich von 5 A/dm² wurde die geringste interne Spannung festgestellt. Für die Anwendung müssen die galvanischen Badparameter zukünftig entsprechend angepasst werden.

Diese Ergebnisse sollten auf das 60L Galvanikbecken bei HS-S übertragen werden, um spannungsarme, galvanisch abgeformte Bauteile zu erzeugen. Nachdem die optische Gitterstruktur von ILM in überarbeiteter Form neu gedruckt wurde, wurde diese nach den zuvor bestimmten Parametern galvanisch mit Nickel beschichtet. Für die Abformung wurde eine Elektrolyt-Temperatur von 55°C sowie eine Stromdichte von 5 A/dm² gewählt. Zusätzlich wurden dem Bad HAR-1000 und Wetting Agent für eine bessere Bauteilbenetzung zugegeben. Das Bauteil wurde für 10 Tage in dem Becken gelagert. Jedoch wurde nach Entnahme ein starker Verzug an der Oberfläche des Bauteils festgestellt, wodurch das Bauteil nicht für nachfolgende Spritzgussversuche genutzt werden konnte.

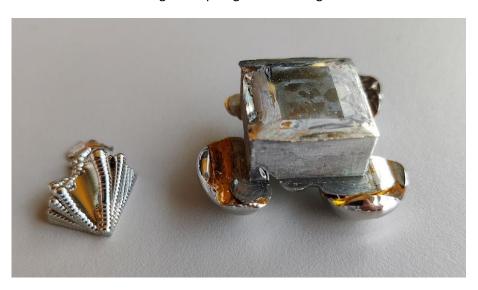


Abbildung 16: Starke mechanische Spannungen führten zu einem Verzug der Nickelbauteile, welche sich dadurch nicht für den Einsatz im Spritzgusswerkzeug eigneten.

Die Gründe für den vorliegenden Spannungsverzug konnten nur unzureichend aufgeklärt werden. Ein starker Verzug nach der Zugabe der organischen Komponenten deutet jedoch darauf hin, dass nicht mehr genügend Haftung zwischen Substrat und Nickeloberfläche vorhanden war, wodurch sich die Ecken des Nickelbauteils (also die Orte höchster auftretender Spannungen) aufrichten und sich das Bauteil durch den schichtweisen wachsenden Aufbau stark verzieht (s. Abbildung 16). Auf Grund der hohen Herstellungszeit der Prototypen wurde auf eine weitere Wiederholung der Abformung





verzichtet. Für das Messsystem wurden daher die ursprünglichen mikrostrukturierten Bauteile weiter vorgesehen.

Um eine zukünftige reproduzierbare Abformung und damit eine bessere Bauteilqualität zu garantieren, wurde der Abformungsprozess im Anschluss überarbeitet. In einem ersten Schritt wurde hierzu eine bauteilspezifische Halterung entworfen und konstruiert. Diese wurde mittels Stereolithographie produziert und wird durch mehrere O-Ringe abgedichtet. Eine Blattfeder erlaubt die gleichmäßige elektrische Kontaktierung der Substratoberfläche. Im geschlossenen Zustand kann ein Substrat mit elektrisch leitfähiger Oberfläche in die entsprechende Form eingelegt und durch die Verschraubung der zwei Hälften über eine kabelgeführte Verbindung mit dem Gleichrichter verbunden werden.







Abbildung 17: Die Halterung wurde additiv gefertigt und besteht aus verschiedenen Einzelkomponenten. Die Blattfeder ist über ein stromführendes Kabel (violett) mit dem Gleichrichter verbunden und stellt bei geschlossener Halterung somit die Verbindung zwischen Gleichrichter und leitfähiger Substratoberfläche her.

Die Herstellung reproduzierbarer Proben konnte durch die vorangegangenen Verbesserungen deutlich gesteigert werden. Die Höhe der erhaltenen Nickelabformungen ist dabei abhängig von der Zeit im Nickelbad und der eingesetzten Stromdichte. Durch die Konstruktion der Halterung ergibt sich ein zylinderförmiges Nickelbauteil, welches keinen mechanischen Verzug der Oberfläche aufweist. Eine Abformung der Mikrostrukturen ist somit wiederholbar bzw. defektfrei möglich. An der Oberfläche der abgeformten Nickelstrukturen bleiben zeitweise organische Verunreinigungen zurück. Diese können z.B. durch den Einsatz von Plasmaveraschung reduziert werden.







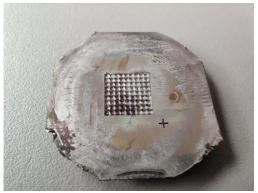


Abbildung 18: Nickelstrukturen können mit dem erarbeiteten Halterungssystem reproduzierbar in gleichbleibenden Geometrien abgeformt werden. Auch der Übertrag optischer Mikrostrukturen ist, wie im gezeigten Beispiel, möglich.

# 2.3 AP3 – Feldversuche und Referenzdiagnostik von Proben aus Arztpraxen und Kliniken (NMI)

In diesem Arbeitspaket wurde eine Referenzdiagnostik mit Proben aus dem Universitätsklinikum Tübingen auf Basis der NMI proprietären DigiWest-Technologie etabliert. Mittels DigiWest können eine Vielzahl zellulärer Proteine semi-quantitativ erfasst werden. Von besonderem Interesse sind hierbei Proteine, die zentral zelluläre Signalprozesse kontrollieren. Diese Signalprozesse sind bei Tumoren dereguliert und führen daher zu unkontrolliertem Wachstum der Tumore. Die Bestimmung des Aktivitätszustands intrazellulärer Signalübertragungswege ermöglicht eine funktionelle Klassifikation in verschiedene Tumorsubtypen und spezifische Änderungen in der zellulären Signalübertragung weisen direkt auf wahrscheinliche Zielorte einer therapeutischen Intervention hin. Das aufgebaute System zur Vermessung zentraler zellulärer Signalwege beruht auf der Analyse von ca. 80 verschiedenen molekularen Varianten (insbesondere durch Phosphorylierung aktivierte Proteine) von Signalüberträgern, die im Melanom ursächlich für deren Wachstum sind. Die Ergebnisse der Analysen können visualisiert werden und bieten somit die Möglichkeit den Aktivierungszustand relevanter Signalwege zu visualisieren und können so zur funktionellen Klassifizierung von primären Melanomen führen, die über eine reine Mutationsanalyse hinausgeht; Hinweise auf wirksame Therapiekonzepte können aus solchen Analysen gewonnen werden.

Zum Aufbau des Analysesystems auf Basis der DigiWest-Technologie wurden primäre Melanomgewebe eingesetzt, die vom klinischen Partner, der Hautklinik des Universitätsklinikums Tübingen, umfassend histologisch untersucht und klassifiziert worden war. Für die Adaption des Analyseprozesses an primäres Melanomgewebe wurde asserviertes Gewebe aufgeschlossen, um nach Qualitätskontrolle in eine standardisierte DigiWest-Analyse eingebracht zu werden. Auf Grundlage vorliegender Erfahrungen mit Geweben anderer Tumorentitäten konnte dieser Prozess direkt erfolgen und wurde direkt zum Aufbau eines an das Melanom angepassten Assayspanels genutzt. So konnte ein





System etabliert werden, das eine spezifische Bestimmung des Status der zellulären Signaltransduktion für wichtige Subtypen des Melanoms erlaubt. Ergebnisse, die mit dem angepassten System zur funktionellen Klassifizierung von primären Melanomen generiert wurden, sind für vier Melanom-Gewebeproben (Lentigo-maligna-Melanom (LMM), LMM-Gewebe aus LK-Metastasen, Primärkultur aus Nodulärem malignem Melanom, Melanom Metastasen) beispielhaft dargestellt (Abbildung 19).

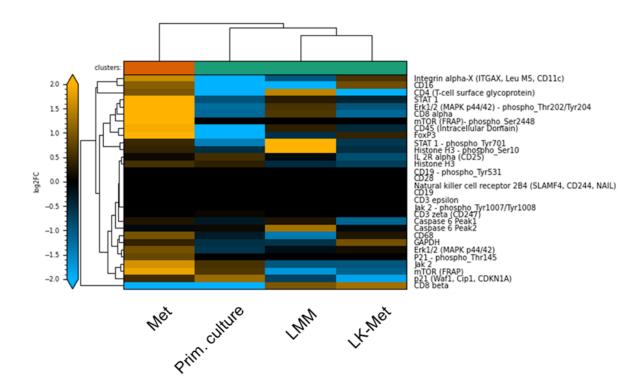


Abbildung 19: Graphische Darstellung der Proteinexpressionsanalyse in 4 Melanom-Gewebeproben (Lentigo-maligna-Melano (LMM), LMM-Gewebe aus LK-Metastasen LK-Met, Primärkultur aus Nodulärem malignem Melanom, Melanom Metastasen (Met)). Mittels DigiWest wurden gezielt intrazelluläre Signalmoleküle vermessen und deren Aktivierungsstatus bestimmt. Die dargestellte Heatmap zeigt die relative Expression von 30 zentralen regulatorischen Proteinen und Proteinvarianten. Zur Visualisierung der Daten wurden die erhaltenen Daten median-zentriert und logarithmiert und Expressionsunterschiede (als Abweichung vom Median) farbig kodiert. Die generierte Heatmap (nach hierarchischer Cluster Analyse, Pearson Correlation, complete linkage) zeigt Ähnlichkeiten zwischen den untersuchten Proben und erlaubt es co-regulierte Proteine zu definieren. Bei der MET Melanom-Probe wird ein starkes Signal für Immunzellmarker beobachtet.

Da die Entstehung und Ausbildung von Tumorzellen häufig mit der Entwicklung von tumorspezifischen Antikörpern einhergeht, wurde untersucht, ob die Erkennung und Klassifizierung eines individuellen Autoantikörpermusters einen Ansatz für eine personalisierte Stratifizierungsstrategie darstellen kann. Zu diesem Zweck wurden Proteine aus primärem Tumorgewebe mittels DigiWest separiert und für ein Antikörper-Screening vorbereitet. Ein entsprechender Assay wurde aufgebaut, um personalisierte Autoantikörpermuster auf primären Tumorgewebe darzustellen.

Im Arbeitspaket durchgeführte Experimente nutzen die proprietäre DigiWest Technologie, die in der Lage ist, die Expression einer Vielzahl zellulärer Proteine semi-quantitativ zu erfassen und somit erlaubt den Aktivitätszustand zentraler intrazellulärer Signalübertragungswege zu bestimmen. Die Deregulation derartiger Änderungen erlaubt eine funktionelle Klassifizierung primärer Melanome, die über eine reine Mutationsanalyse hinausgeht und Hinweise auf wirksame Therapiekonzepte geben kann.





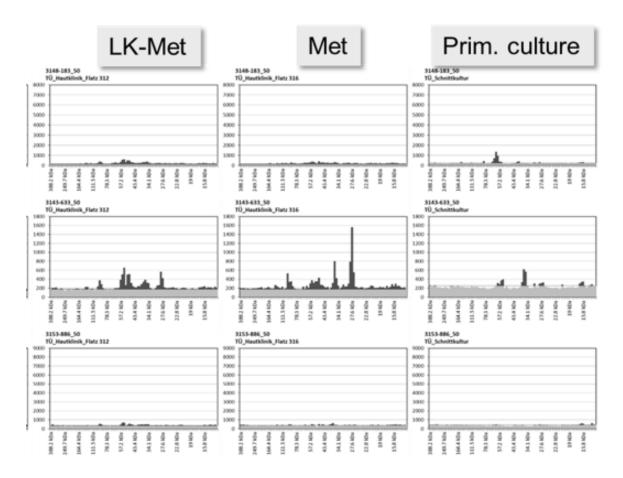


Abbildung 20: Graphische Darstellung der personalisierten Autoantikörperantwort auf im DigiWest aufgetrennte Tumorproteine. Individuelle Unterschiede der verschiedenen Patientenseren werden bei einer 1:50 Serumverdünnung beobachtet. Ein mittleres bis hohes Signal wird hierbei für Responder beobachtet. Dieses Testverfahren ist als Assay für das Screening sehr gut geeignet.

Weiterhin wurden mittels der DigiWest Technologie Autoantikörperprofile gegen Tumorproteine nachgewiesen. Hierzu wurde Tumorlysate, die mittels DigiWest-Technologie aufgetrennt wurden, mit Serum der Tumorpatienten zusammengeführt. Somit konnten im Serum vorhanden Autoantikörper individuell nachgewiesen werden. Mit weiteren Experimenten sollen die Zielproteine der Autoantikörper mittels Massenspektrometrie identifiziert werden und in ein Routinescreening überführt werden. Die hierbei eingesetzten primären Tumorproben LMM, LK-Met und Met zeigten hierbei unterschiedliche Muster. Derartige Muster können für eine Therapieentscheidung von Bedeutung werden.





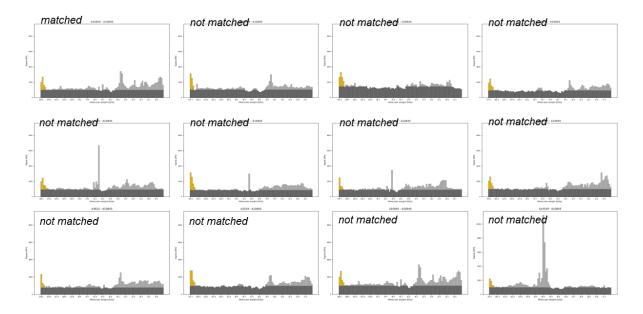


Abbildung 21: DigiWest-basierter Nachweis von patientenspezifischen Autoantikörpern auf Proteinextrakten von primären Tumoren. Verdünntes Serum eines Patienten wurde auf Proteinen des patienteneigenen Tumors und auf Tumorextrakten von 11 anderen Patienten inkubiert. Reaktivität der patientenspezifischen Autoantikörper auf der patienteneigenen Probe (matched, Diagramm links oben) und auf den 11 anderen Tumorextrakten (not matched) wurde mittels DigiWest ermittelt. Das gleiche Serum führt auf den verschiedenen primären Tumorgeweben zu unterschiedlichen Peak-Mustern, die die komplexe Reaktivität der patientenspezifischen Autoantikörper verdeutlicht. Auf jedem Tumorextrakt entsteht ein individuelles Peak-Muster, das auf die Anwesenheit verschiedener sero-reaktiver Antigene in den individuellen Tumorgeweben hindeutet.

Die Sektion für Dermatologische Onkologie der Universitätshautklinik Tübingen am Universitätsklinikum Tübingen war im Unterauftrag in Zusammenarbeit mit dem NMI tätig, um das Geräts KOMPASSpro klinisch zu erproben. Die Erprobung erfolgte im Studienzentrum Onkologie der Sektion für Dermatologische Onkologie unter der Projektleitung Prof. Dr. Lukas Flatz und der Stellvertreterin Dr. Teresa Amaral.

Im Zuge dieser Erprobung wurden Messungen an Hauttumorpatienten durchgeführt, um Daten zum Trainieren des KI-Systems zu erheben beziehungsweise um das System zu testen. Hierzu wurden Verdachtsfälle auf Malignome der Haut mit geplanter Operation oder Biopsie zunächst identifiziert und auf einen möglichen Einschluss in die Studie geprüft (klinische Diagnose). Die Patienten wurden bei Erfüllen der Einschlusskriterien darauffolgend aufgeklärt und das Einverständnis zur Teilnahme an der Untersuchung gemäß der unter 012/2020BO1 geführten Projektnummer der Ethikkommission am Universitätsklinikum Tübingen eingeholt.

Im Folgenden wurden Kameraaufnahmen mit dem KOMPASS-System von den betroffenen Hautstellen erhoben (Intelligente Diagnostik). Erst dann erfolgten eine Biopsie oder die operative Entfernung der Hautläsion. Die entnommenen Gewebeproben wurden im Zuge der routinemäßig durchgeführten Diagnostik und klinischen Prozedur feingeweblich untersucht und eine histopathologische Diagnose durch einen Facharzt für Dermatologie mit der Zusatzbezeichnung Dermatopathologie gestellt (OP). Diese Diagnose diente als Referenzdiagnostik für die mit dem KOMPASSpro-System erhobenen Daten. Gleichzeitig wurde eine KI gestützte Diagnose am Gerät ermittelt, welche dem Patienten jedoch, aufgrund der Erprobungsphase nicht mitgeteilt wurde.





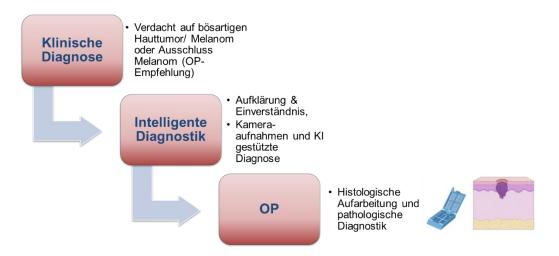


Abbildung 22: Flussschema zum Arbeitsablauf innerhalb der Feldversuche zur Erprobung des KOMPASSpro-Systems an der Universitätshautklinik Tübingen. Die einzelnen Schritte lassen sich unterteilen in Klinische Diagnose durch einen Arzt zur Identifizierung möglicher Probanden, gefolgt von der Intelligenten Diagnostik durch das KOMPASSpro-System und im Anschluss die operative Entfernung der Hautläsion oder einer Biopsie mit anschließender histologischer Diagnosestellung als Referenz.

Insgesamt wurden derart 231 Hautläsionen untersucht. Davon waren 169 (73%) gutartige Hautveränderungen und 62 (27%) bösartige Hauttumore. Darunter fielen 48 Melanome (21%) in unterschiedlichen T-Stadien (unterschiedliche Tumordicken). Die Fallzahl blieb damit deutlich hinter den Erwartungen zurück. Die Ursachen hierfür sind komplex wie vielfältig und umfassen organisatorische wie logistische Prozesse. Beispielhaft kann der Abstimmungsbedarf für Datenschutztechnische Fragestellungen genannt werden, die im Rahmen einer komplexen Projektstruktur und der angestrebten gemeinsame Verantwortlichkeit durch die Partner-übergreifende Datenverarbeitung zeitaufwändig war. Logistische Schwierigkeiten gab es bei der Installation des geräumigen KOMPASSpro-Systems in der Nähe der Operationssäle der Universitätshautklinik. Hierdurch wurde es schwierig Patienten zu akquirieren und einzubinden, ohne dass der Prozess für die Behandlung der Patienten in der Klinik verlangsamt bzw. verzögert wird. Eine Miniaturisierung in Form des KOMPASSmobile-Systems ist daher unbedingt notwendig. Die technischen Schwierigkeiten wurden den entsprechenden Projektpartnern rückgemeldet und zeitnah durch Software oder Hardware-Verbesserungen behoben. Dadurch diente die klinische Erprobung auch der kontinuierlichen Verbesserung des Systems.





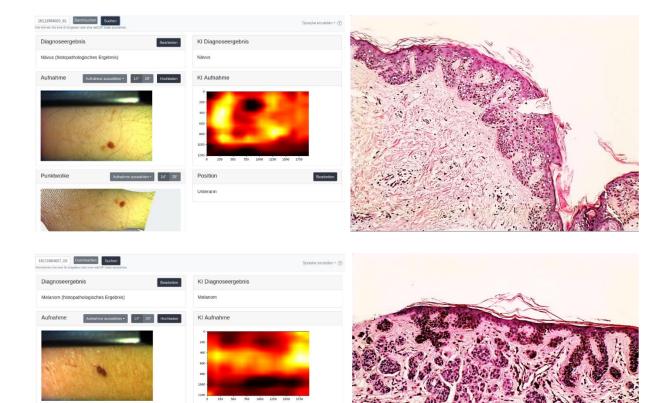


Abbildung 23: Beispiele zweier melanozytärer Hautveränderungen. Oben links zeigt eine benigne Hautläsion aufgenommen durch das KOMPASSpro-System sowie die feingewebliche Darstellung in mikroskopischer Vergrößerung (oben rechts) welche die Referenzdiagnose "Nävus" (benigne melanozytäre Hautläsion ergab). Das KI System ergab in diesem Fall ebenfalls die Diagnose "Nävus". Unten links zeigt sich ebenfalls eine melanozytäre Läsion in zentraler Lage der Kameraaufnahme, welche von der KI als Melanom identifiziert wurde. Dies wurde in der feingeweblichen Untersuchung als "Melanoma in situ" bestätigt.

## 2.4 AP4 - KI - Algorithmen (HS-VS)

Das Projekt Intelligente Diagnostik 2 konzentriert sich auf die Nutzung künstlicher Intelligenz zur Erkennung von Hautkrebs aus hyperspektralen Bildern. Dieses Arbeitspaket widmet sich der Weiterentwicklung von KI-Algorithmen.

In AP 4.1 liegt das Hauptaugenmerk auf der weiteren Verbesserung von Deep-Learning-Algorithmen für die Klassifizierung von hyperspektralen Bildern.

AP 4.2 befasst sich mit dem Training von Deep-Learning-Modellen unter besonderer Berücksichtigung des Datenschutzes.

AP 4.3 ist der Bestimmung der relevanten Parameter für das optische Messsystem durch die Nutzung von Deep-Learning-Modellen gewidmet.

Abschließend konzentriert sich AP 4.4 auf die Optimierung von Deep-Learning-Modellen, um eine effiziente Inferenz auf dem KOMPASSmobile-System zu ermöglichen.





#### 2.4.1 AP4.1 - Weiterentwicklung der Deep-Learning-Algorithmen

Deep Learning, ein Teilgebiet des maschinellen Lernens, beinhaltet das Trainieren von Algorithmen, um Muster zu erkennen und Entscheidungen zu treffen. In diesem Projekt wird es verwendet, um komplexe hyperspektrale Bilder zur Früherkennung von Hautkrebs zu analysieren. Für dieses Projekt wurden insgesamt 206 hyperspektrale Bilder zu Trainingszwecken verwendet. Die Tabelle 3 zeigt die Anzahl der Elemente in den Daten.

Tabelle 3: Anzahl der Bilder für den jeweiligen Hautkrebstyp

Тур	Anzahl
Plattenepithelkarzinom	13
Basalzellkarzinom	35
Melanom	23
Nävus	115
Andere	20

Angesichts der begrenzten Größe unseres hyperspektralen Datensatzes erwies sich Transferlernen als unverzichtbare Technik. Dieser Ansatz beinhaltete die Verwendung eines zunächst auf einem umfassenden Datensatz trainierten neuronalen Netzwerks und dessen Feinabstimmung speziell für unsere hyperspektralen Bilder, eine Methode, die sich gut für Datenformate eignet, die über die traditionelle Drei-Kanal-Struktur hinausgehen.

Unsere Methodik umfasste eine Reihe von Deep-Learning-Techniken, die jeweils sorgfältig auf die einzigartigen Eigenschaften von hyperspektralen Daten zugeschnitten waren. Hierzu wurden Backend-Netzwerke wie den Vision Transformer (VIT) und EfficientNet angepasst, wobei die effektivsten Modelle alle spektralen Wellenlängen nutzten, aber besonderes Augenmerk auf die ersten drei räumlichen Frequenzen in jedem Spektrum legten.

Für das Training verwendeten wir die PyTorch-Bibliothek und setzten eine k-Fold-Validierungsstrategie mit fünf Folds ein, um eine gründliche Bewertung der Modelle zu gewährleisten. Unser Klassifikationssystem basierte auf einer einheitlichen Verlustfunktion, die Fokalverlust, Kreuzentropieverlust und KL-Divergenzverlust umfasste.

Es wurden sechs verschiedene Experimente durchgeführt, die sich jeweils auf verschiedene Aspekte der Analyse von hyperspektralen Bildern zur Erkennung von Hautkrebs konzentrierten:

- 1. **Image Experiment:** In diesem Experiment wurden RGB-Bilder aus hyperspektralen Daten extrahier mit die Ziel die reichhaltigen Informationen in diesen Bildern zur Verbesserung der Hautkrebsdetektion zu nutzen.
- 2. **Image + ISIC Dataset Experiment:** Dieses Experiment beinhaltete die Kombination von RGB-Bildern aus hyperspektralen Daten mit dem ISIC-Dermatoskopiebilddatensatz. Ziel war es, den Trainingsdatensatz mit einer größeren Bandbreite an Hautläsionsbildern zu erweitern, indem sowohl hyperspektrale als auch dermatoskopische Bilder genutzt wurden.
- 3. **Netcdf Experiment:** Dieses Experiment konzentrierte sich ausschließlich auf Netcdf-Dateien für das Training und die Validierung und legte den Schwerpunkt auf die Analyse von rohen hyperspektralen Daten.





- 4. **Netcdf + Aug Experiment:** Aufbauend auf dem Netcdf-Modell führte dieses Experiment Datenerweiterungstechniken ein, um den Trainingsdatensatz zu diversifizieren und die Fähigkeit des Modells zur Generalisierung zu verbessern.
- 5. **Netcdf Importance Experiment:** Dieses Experiment konzentrierte sich auf Schlüsselwellenlängen, die aus unserer Analyse innerhalb der Netcdf-Dateien identifiziert wurden. Es optimierte die Genauigkeit für die Hautkrebsdetektion, ohne sich auf Datenerweiterung zu verlassen.
- 6. **VIT Experiment:** In diesem Experiment verwendeten wir Vision Transformers in Kombination mit Netcdf-Daten, divergierend von der EfficientNet-B3-Architektur, die in den anderen Experimenten verwendet wurde. Diese Untersuchung zielte darauf ab, die Fähigkeiten von Transformatoren in der hyperspektralen Bildgebung zu verstehen.

Mit Ausnahme des VIT-Experiments nutzten alle Modelle die EfficientNet-B3-Architektur mit Modifikationen der Eingabeschicht, um die Verarbeitung hyperspektraler Daten zu ermöglichen.

Spezifitäts-, F1-Score-, Kalibrierungsfehler-, AUROC-, Genauigkeits-, Durchschnittspräzisions-, Matthews-Korrelationskoeffizient-, Präzisions- und Recall-raten sowie KFold-Genauigkeit wurden für jedes Experiment ermittelt. Diese werden in Form von Tabellen und Diagrammen dargestellt.

Die Analyse von hyperspektralen Bilddaten zur Hautkrebsdetektion beinhaltete die Bewertung mehrerer Deep-Learning-Modelle anhand einer Reihe von Leistungsmetriken. Jede Metrik bietet Einblicke in verschiedene Aspekte der Fähigkeiten der Modelle, wie Genauigkeit, Präzision, Recall und Spezifität. Tabelle 4 zeigt die Zusammenfassung aller für die durchgeführten Experimente bewerteten Metriken.

Tabelle 4: Ergebnisse der durchgeführten Untersuchungen

	Specific ity	F1 Sco re	Calibrat ion Error	AUR OC	Accur acy	Avera ge Precisi on	Matthe ws Corr Coef	Precisi on	Rec all	KFold Accur acy
Image	0.90	0.4	0.29	0.81	0.46	0.55	0.54	0.42	0.46	72.79
Image + ISIC Dataset	0.95	0.2 5	0.28	0.46	0.27	0.55	0.56	0.26	0.27	71.84
Netcdf	0.90	0.4 2	0.32	0.79	0.45	0.55	0.50	0.45	0.45	69.38
Netcdf + Aug	0.88	0.3	0.27	0.74	0.37	0.44	0.47	0.31	0.37	68.44
Netcdf Importa nce	0.91	0.4 6	0.28	0.80	0.49	0.53	0.56	0.48	0.49	70.87
VIT	0.91	0.3 9	0.34	0.79	0.45	0.48	0.56	0.37	0.45	73.29





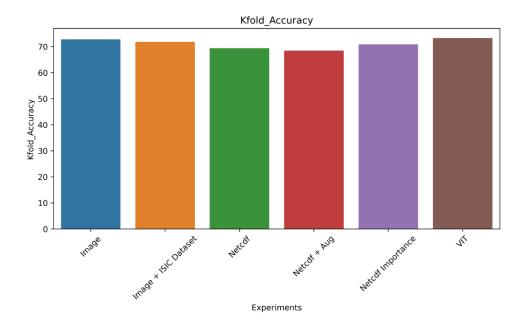


Abbildung 24: **K-Fold Cross-Validation Genauigkeit** - Dieses Balkendiagramm zeigt die Genauigkeit, die durch die K-Fold Cross-Validation für jede experimentelle Einrichtung erzielt wurde und bietet Einblicke in die Stabilität und Zuverlässigkeit des Modells über verschiedene Datensätze hinweg.

In Abbildung 24 wird die K-Fold Cross-Validation Genauigkeit für verschiedene Modelle dargestellt, die in der hyperspektralen Bildanalyse zur Hautkrebsdetektion verwendet wurden. Die Genauigkeitswerte reichen von 68,44% bis 73,29%, wobei das "VIT"-Modell die höchste Genauigkeit von 73,29% erreicht. Dies weist auf seine Robustheit und Zuverlässigkeit bei der Handhabung hyperspektraler Daten hin und deutet auf effektive Merkmalsextraktion und Generalisierungsfähigkeiten hin. Diese Werte unterstreichen die Bedeutung der Verwendung verschiedener Datenpartitionen zur Bewertung der Stabilität und Vorhersagbarkeit der Modelle in realen Szenarien.





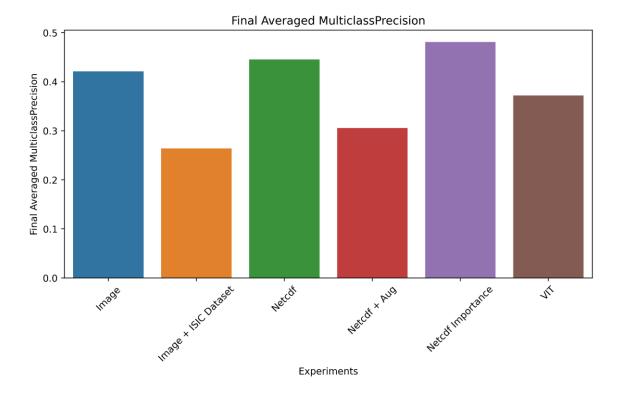


Abbildung 25: Endgültige Durchschnittliche Multiklassen-Präzision - Stellt die Präzisionsmetrik für mehrere Klassen dar, die die Fähigkeit des Modells anzeigt, eine Probe nicht als positiv zu kennzeichnen, wenn sie negativ ist.

Abbildung 25 zeigt die endgültige Durchschnittliche Multiklassen-Präzision. Diese stellt die Fähigkeit des Modells dar, eine Probe nicht als positiv zu kennzeichnen, wenn sie tatsächlich negativ ist. Präzision misst die Korrektheit der positiven Vorhersagen des Modells. Das "Netcdf Importance"-Modell erreicht die höchste Präzision von 0,48, was seine Fähigkeit unterstreicht, krebsartige Fälle in der hyperspektralen Bildgebung präzise zu erkennen. Dies macht es zu einem wertvollen Werkzeug für präzise Diagnosen im Gesundheitswesen.





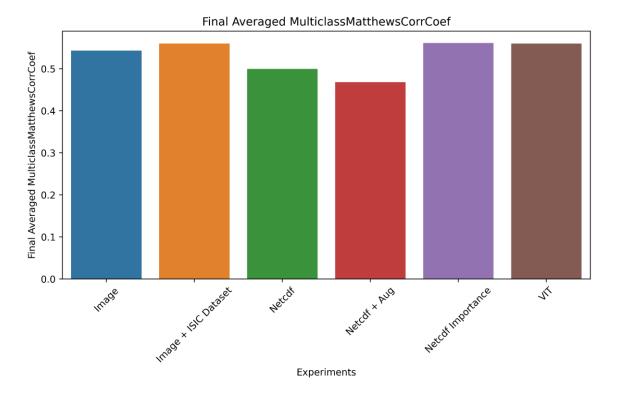


Abbildung 26: **Endgültiger Durchschnittlicher Multiklassen-Matthews-Korrelationskoeffizient** - Stellt ein ausgewogenes Maß dar, das auch verwendet werden kann, wenn die Klassen sehr unterschiedliche Größen haben.

Abbildung 26 zeigt den endgültigen Durchschnittlichen Multiklassen-Matthews-Korrelationskoeffizient (MCC). Dieser stellt ein ausgewogenes Maß für die Leistung eines Modells dar und kann auch verwendet werden, wenn die Klassen sehr unterschiedliche Größen haben. Der Matthews-Korrelationskoeffizient (MCC) bietet ein ausgewogenes Maß für die Leistung eines Modells und berücksichtigt wahre und falsche Positive sowie Negative. Mit dem höchsten MCC von 0,5612 zeigt das "Netcdf Importance"-Modell eine überlegene ausgewogene Klassifizierungsleistung und weist auf seine Robustheit für den Einsatz in der hyperspektralen Bildungsdiagnostik hin.





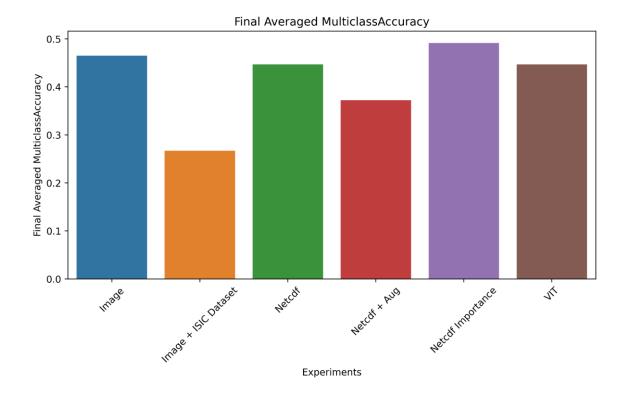


Abbildung 27: Endgültige Durchschnittliche Multiklassen-Genauigkeit - Diese Metrik bietet eine Gesamtgenauigkeitsrate über alle Klassen hinweg und dient als allgemeiner Indikator für die Wirksamkeit des Modells.

Abbildung 27 zeigt die Genauigkeit verschiedener Modelle bei der Klassifizierung von hyperspektralen Bildern zur Hautkrebsdetektion. Die Multiklassen-Genauigkeit misst den Anteil der korrekten Vorhersagen an den Gesamtfällen über alle Klassen hinweg. Eine höhere Genauigkeit deutet auf eine bessere Leistung bei der Identifizierung von krebsartigen und nicht-krebsartigen Geweben hin. In der medizinischen Diagnostik können Fehlklassifikationen kostspielig sein. Das "Netcdf Importance"-Modell erreicht die höchste Genauigkeit von 49,15%, was seine Wirksamkeit bei der Klassifizierung von Fällen widerspiegelt.





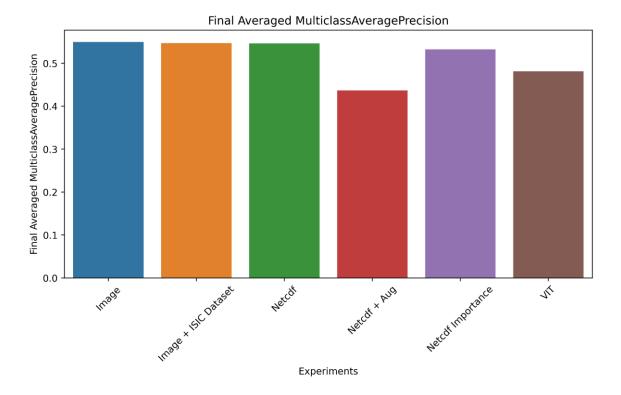


Abbildung 28: **Endgültige durchschnittliche Multiklassen-Präzision** - Diese Abbildung zeigt die durchschnittliche Präzision über alle Klassen hinweg, die eine Präzisions-Rückruf-Kurve als einzelnen Wert zusammenfasst.

Abbildung 28 zeigt die durchschnittliche Präzision über alle Klassen hinweg, die durch eine Präzisions-Recall-Kurve als einzelnen Wert zusammengefasst wird. Die Fläche unter der Receiver Operating Characteristic (AUROC)-Kurve ist ein Maß für die Fähigkeit eines Modells, zwischen Klassen zu unterscheiden. Ein höherer AUROC-Wert deutet auf eine bessere Leistung bei der Unterscheidung zwischen krebsartigen und nicht-krebsartigen Geweben hin. Das 'Image'-Modell erreicht den höchsten AUROC-Wert von 0,8097, was auf seine überlegene Diskriminierungskraft bei der Analyse von hyperspektralen Bildern zur Hautkrebsdetektion hinweist.





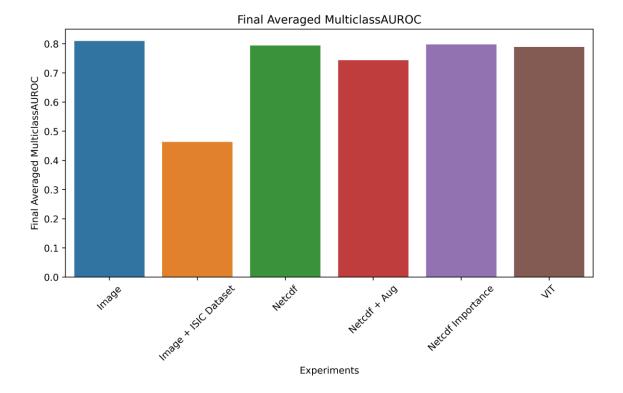


Abbildung 29: **Endgültige durchschnittliche Multiklassen-AUROC** - Diese Grafik veranschaulicht die Fläche unter der Receiver Operating Characteristic-Kurve und zeigt die Fähigkeit des Modells, zwischen Klassen zu unterscheiden.

Abbildung 29 zeigt die durchschnittliche Fläche unter der Receiver Operating Characteristic (AUROC)-Kurve, die die Fähigkeit des Modells zeigt, zwischen Klassen zu unterscheiden. Die AUROC ist ein Maß für die Fähigkeit eines Modells, zwischen krebsartigen und nicht-krebsartigen Geweben zu unterscheiden. Ein höherer AUROC-Wert deutet auf eine bessere Leistung hin. Das 'Image'-Modell erreicht den höchsten AUROC-Wert von 0,8097, was auf seine überlegene Fähigkeit zur Unterscheidung bei der Analyse von hyperspektralen Bildern zur Hautkrebsdetektion hinweist.





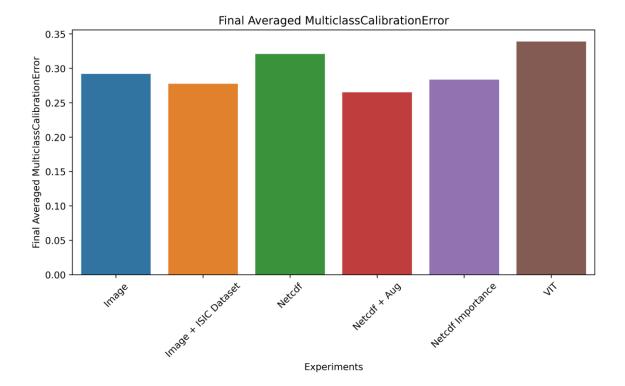


Abbildung 30: **Endgültiger durchschnittlicher Multiklassen-Kalibrierungsfehler** - Spiegelt den Kalibrierungsfehler des Modells über mehrere Klassen hinweg wider, was sich auf die Zuverlässigkeit der probabilistischen Ausgaben des Modells hezieht

Abbildung 30 zeigt den endgültigen durchschnittlichen Multiklassen-Kalibrierungsfehler, der den Kalibrierungsfehler des Modells über mehrere Klassen hinweg reflektiert und sich auf die Zuverlässigkeit der probabilistischen Ausgaben des Modells bezieht. Der Kalibrierungsfehler zeigt den Unterschied zwischen erwarteten Ergebnissen und tatsächlichen Modellvorhersagen. Niedrigere Werte deuten auf ein Modell hin, dessen Wahrscheinlichkeitsschätzungen zuverlässig sind. Das 'Netcdf + Aug'-Modell weist mit 0,2652 den niedrigsten Kalibrierungsfehler auf und macht es zu einem potenziell vertrauenswürdigen Modell für probabilistische Vorhersagen in der klinischen Diagnose von Hautkrebs.





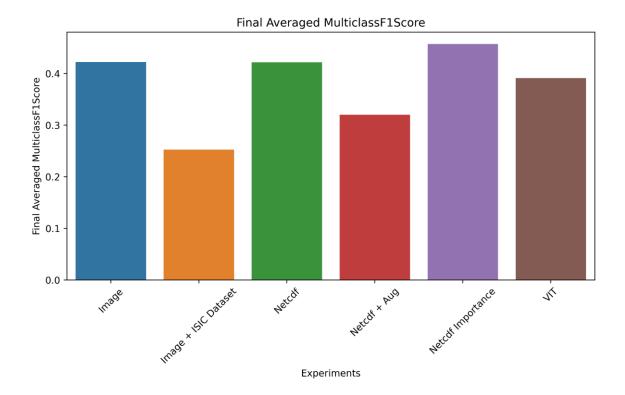


Abbildung 31: **Endgültiger durchschnittlicher Multiklassen-F1-Score** - Kombiniert Recall und Präzision in einem einzigen Metrik, was besonders nützlich für unausgewogene Klassen ist.

Abbildung 31 zeigt den endgültigen durchschnittlichen Multiklassen-F1-Score, der Recall und Präzision in einem einzigen Metrik kombiniert, was besonders nützlich für unausgewogene Klassen ist. Der F1-Score ist das harmonische Mittel aus Präzision und Recall und liefert einen einzelnen Wert, der sowohl falsch Positive als auch falsch Negative ausgleicht. Diese Abbildung zeigt die F1-Scores für verschiedene Modelle und bietet Einblicke, welche Modelle Präzision und Recall effektiv harmonisieren. Modelle mit höheren F1-Werten sind besonders geschickt darin, den Kompromiss zwischen der Identifizierung aller relevanten Fälle (Recall) und der Aufrechterhaltung einer niedrigen Rate falsch positiver Ergebnisse (Präzision) zu navigieren, was für medizinische Diagnosen auf Basis hyperspektraler Bildgebung von unschätzbarem Wert ist. Diese Abbildung zeigt das 'Netcdf Importance'-Modell als führenden Performer mit einem F1-Score von 0,4573 und deutet auf eine optimale Harmonie zwischen der Identifizierung wahrer positiver Hautkrebsfälle und der Minimierung falsch-positiver Diagnosen hin.





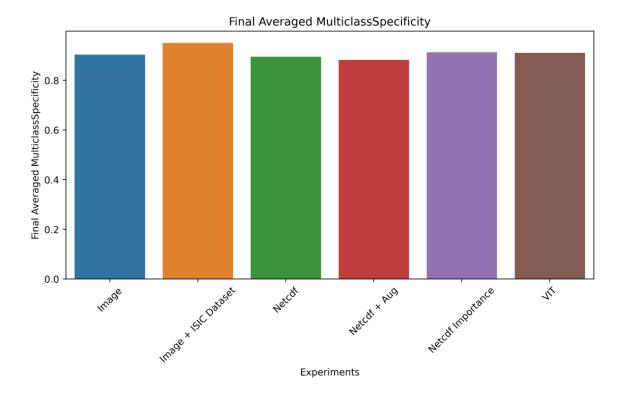


Abbildung 32: **Endgültige durchschnittliche Multiklassen-Spezifität** - Zeigt die Fähigkeit des Modells, Negatives korrekt zu identifizieren, was für die korrekte Nicht-Diagnose von gesunden Fällen als krank entscheidend ist.

Abbildung 32 zeigt die durchschnittliche Multiklassen-Spezifität, die die Fähigkeit des Modells zeigt, Negatives korrekt zu identifizieren, was für die korrekte Nicht-Diagnose von gesunden Fällen als krank entscheidend ist. Die Spezifität, oder die wahre negative Rate, ist in der medizinischen Diagnostik entscheidend, um Nicht-Fälle korrekt zu identifizieren. Diese Abbildung zeigt die Fähigkeit der Modelle, negative Fälle korrekt zu kennzeichnen und das Risiko falscher Alarme zu verringern. Eine höhere Spezifität ist besonders wichtig bei der hyperspektralen Bildgebung für Hautkrebs, wo es entscheidend ist, zwischen krebsartigen und nicht-krebsartigen Geweben genau zu unterscheiden. Das 'Image + ISIC Dataset'-Modell sticht mit der höchsten Spezifität von etwa 0,9508 hervor und zeigt seine Wirksamkeit bei der genauen Identifizierung von nicht-krebsartigen Geweben in hyperspektralen Bildern.





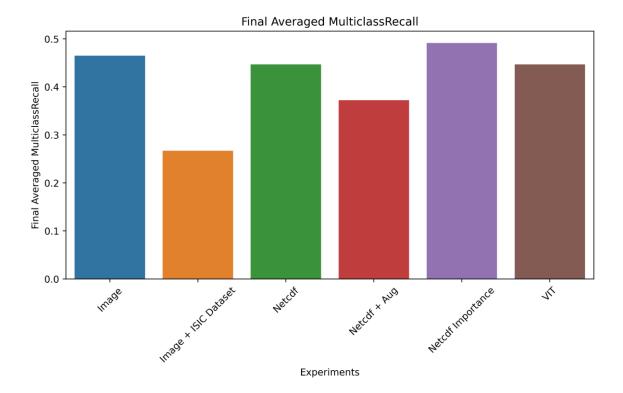


Abbildung 33: Endgültiger durchschnittlicher Multiklassen-Recall über verschiedene Experimente

Abbildung 33 zeigt den endgültigen durchschnittlichen Multiklassen- Recall über verschiedene Experimente hinweg. Der Recall oder die Sensitivität ist in der medizinischen Bildgebung von entscheidender Bedeutung und bezeichnet die Fähigkeit des Modells, alle relevanten Fälle zu erfassen. Diese Abbildung vergleicht den endgültigen durchschnittlichen Multiklassen- Recall für die untersuchten Modelle und zeigt ihre Wirksamkeit bei der Identifizierung aller Hautkrebsfälle in den hyperspektralen Bildern. Erhöhte Recall-Werte sind entscheidend, um sicherzustellen, dass kein Fall unentdeckt bleibt, und stehen im Einklang mit dem Ziel des Projekts, umfassende diagnostische Algorithmen zu entwickeln. Das 'Netcdf Importance'-Modell hat mit 0,4915 den höchsten Recall und zeigt seine Wirksamkeit bei der Erfassung wahrer positiver Fälle von Hautkrebs, was für ein umfassendes Screening und eine frühzeitige Erkennung entscheidend ist.

Die Analyse von hyperspektralen Bilddaten zur Hautkrebsdetektion umfasste die Bewertung mehrerer Deep-Learning-Modelle anhand einer Reihe von Leistungsmetriken. Jede Metrik bietet Einblicke in verschiedene Aspekte der Fähigkeiten der Modelle, wie Genauigkeit, Präzision, Recall und Spezifität.

- 1. **K-fold Cross-Validation Accuracy:** Das 'VIT'-Modell zeigte mit 73,29 % die höchste Genauigkeit. Dies deutet auf seine Robustheit und Zuverlässigkeit hin und zeigt seine Effektivität bei der Verallgemeinerung von Trainings zu unbekannten Daten.
- 2. Multiklassen-Präzision und Recall: Das 'Netcdf Importance'-Modell zeichnete sich sowohl in der Präzision (0,4812) als auch im Recall (0,4915) aus und zeigte seine Wirksamkeit bei der Minimierung falsch positiver und der Maximierung wahrer positiver Erkennungen. Dieses Gleichgewicht ist entscheidend für die medizinische Diagnostik, bei der eine Fehldiagnose von gesundem Gewebe oder das Übersehen von Krebszellen schwerwiegende Folgen haben kann.1





- 3. **Matthews-Korrelationskoeffizient (MCC):** Auch hier zeigte das 'Netcdf Importance'-Modell mit 0,5612 den höchsten MCC und deutet auf eine ausgewogene Leistung über alle Klassen hinweg hin, was auf seine Kompetenz im Umgang mit den nuancierten Anforderungen hyperspektraler Daten hindeutet.
- 4. **F1-Score:** Das 'Netcdf Importance'-Modell führte auch im F1-Score mit 0,4573, was besonders wichtig im medizinischen Bereich ist, da es die Aspekte von Präzision und Recall in einer einzigen Metrik kombiniert.
- 5. **AUROC und Spezifität:** Das 'Image'-Modell und das 'Image + ISIC Dataset'-Modell zeigten überlegene Leistungen in AUROC (08097) und Spezifität (0,9508) bzw. Diese Metriken sind entscheidend für die genaue Unterscheidung verschiedener Hautzustände.
- 6. **Kalibrierungsfehler**: Das 'Netcdf + Aug'-Modell hatte mit 026,52 den niedrigsten Kalibrierungsfehler, was auf die Zuverlässigkeit seiner probabilistischen Vorhersagen hinweist.

Beste Gesamtwahl des Modells: Unter Berücksichtigung aller Metriken erweist sich das 'Netcdf Importance'-Modell als das beste Gesamtmodell. Seine führende Leistung in Präzision, Recall, MCC und F1 Score macht es besonders geeignet für medizinisch-diagnostische Anwendungen in der hyperspektralen Bildgebung. Das Gleichgewicht zwischen der genauen Identifizierung von krebsartigen Geweben (hohe Präzision und Recall) und der Aufrechterhaltung eines hohen Grades an Zuverlässigkeit (wie durch den hohen MCC und F1 Score belegt) unterstreicht seine Wirksamkeit bei der Hautkrebsdetektion. Während das 'Image'-Modell Stärken im AUROC zeigt, macht die umfassende Leistung des 'Netcdf Importance'-Modells über mehrere kritische Metriken hinweg es zur bevorzugten Wahl für diese Anwendung.

## 2.4.2 AP4.2 - Training von Deep-Learning-Modellen unter Einhaltung der Privatsphäre der Patienten

Das Training von Deep-Learning-Modellen unter Wahrung der Privatsphäre der Patienten erfordert den Einsatz von Federated Learning. Federated Learning beinhaltet die Schaffung eines dezentralen Lernrahmens, in dem Daten nicht zentralisiert, sondern auf verschiedene Standorte wie Hautärztepraxen und Kliniken verteilt werden. Bei diesem Lernansatz werden Daten nicht an einen zentralen Computer übertragen; stattdessen werden Modellgewichte zwischen einzelnen Teilnehmern und dem Server ausgetauscht.





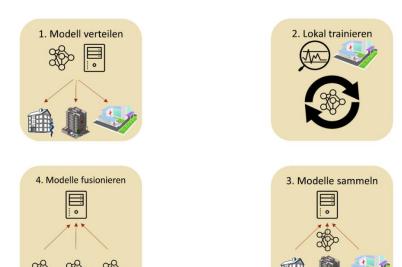


Abbildung 34: Schritte beim Federated Learning. (1) Verteilen des KI-Modells an die Teilnehmer durch einen Server; (2) Nachtrainieren der KI-Modelle bei jedem Teilnehmer mit den lokalen Daten; (3) KI-Modelle werden zurück an den Server gesendet; (4) Der Server führt die KI-Modelle zusammen und fährt mit Schritt (1) fort.

In Abbildung 34 wird der Prozess des Federated Learning dargestellt. Zunächst initialisiert der Server ein neuronales Netzwerk und sendet es an entfernte Geräte. Anschließend trainieren diese entfernten Geräte die empfangenen Modelle lokal mit ihren spezifischen Daten. Nach dem Training auf den entfernten Geräten werden die Modelle an den Server zurückgesendet. Nach Erhalt dieser neuronalen Netze werden ihre Gewichte gemittelt, um ein konsolidiertes Modell (ein Modell mit gemittelten Gewichten) auf der Serverseite zu erzeugen. Die gemittelten Gewichte des Modells werden dann wieder an die entfernten Geräte übertragen. Dieser Prozess wiederholt sich, bis ausreichend Daten verfügbar sind oder gemäß einem vorher festgelegten Zeitplan. Am Ende des Trainings besitzt jedes teilnehmende entfernte Gerät ein verbessertes Modell, wobei die Privatsphäre der Patienten gewahrt bleibt.

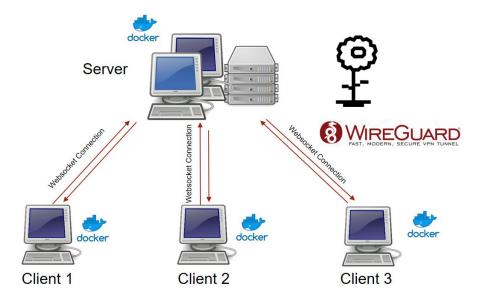


Abbildung 35: Federated Learning Architektur. Die Toolbox Flower wird für Federated Learning und WireGuard verwendet, um eine sichere Verbindung zwischen dem Server und Client herzustellen.





Im Verlauf des Projekts hat HS eine Federated-Learning-Architektur entworfen, die derzeit auf der Hardware-Ressourcen des Clients betrieben wird und es Einzelpersonen ermöglicht, über das Internet eine Verbindung herzustellen. Abbildung 35 zeigt die für das Federated Learning bei Hahn-Schickard verwendete Einrichtung. Die Entwicklung dieser Federated-Learning-Architektur umfasste die Verwendung von PyTorch- und Flower-Bibliotheken sowie Docker-Containern auf den Clients. Flower (https://flower.dev/) dient als ein für verschiedene ML-Frameworks kompatibles Framework für verteiltes Lernen (Federated Learning). Die Internetverbindung ist durch die Verwendung von Wireguard VPN gesichert. Docker ermöglicht eine einfache und standardisierte Bereitstellung der entwickelten Anwendung und ihrer Abhängigkeiten, während Wireguard VPN einen sicheren Zugriff auf die Clients gewährleistet. Zusammengenommen ermöglichen diese Komponenten eine schnelle und unkomplizierte Bereitstellung der entwickelten Anwendung für unterschiedliche Clients.

Das Federated-Learning-Framework wurde durch die Integration von drei Schlüsselfunktionen erweitert: Verschlüsselung, Server-Client-Authentifizierung und Differential Privacy. Darüber hinaus wurde für dieses Training ein neues Backend für das Federated Learning-Verfahren integriert. Während des Trainings von Deep-Learning-Modellen im Federated Learning werden nur die Modellgewichte zwischen den Geräten übertragen. Die Verschlüsselung, die im Kommunikationsprozess im Federated Learning angewendet wird, stellt sicher, dass die zwischen den Geräten ausgetauschten Modellgewichte für andere unverständlich bleiben.

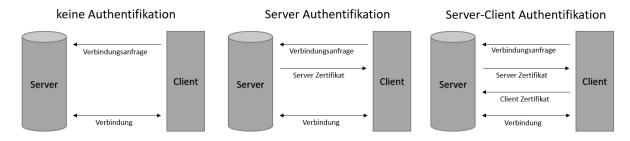


Abbildung 36: Verschiedene Arten von Authentifizierungsverfahren

Ein Zwei-Wege-Authentifizierungsprozess wurde sowohl auf der Client- als auch auf der Serverseite implementiert. Dieser Prozess gewährleistet eine sichere Kommunikation zwischen Geräten (Server und der Clients), die am Federated-Learning-Prozess beteiligt sind, in dem sich beide Seiten authentifizieren. Abbildung 36 veranschaulicht verschiedene Arten von Authentifizierungsmethoden.

Darüber hinaus wurde Differential Privacy implementiert, um die Ununterscheidbarkeit der Gewichte unter den teilnehmenden Clients im Federated-Learning-Prozess zu erreichen. Bei diesem Ansatz wird eine Rauschschicht zu den Gewichten lokal trainierter Modelle hinzugefügt, die anschließend zur Durchschnittsbildung an den Server übertragen werden. Dies führt dazu, dass die Gewichte über alle Geräte, die am Federated-Learning-Prozess beteiligt sind, ununterscheidbar sind.

## 2.4.3 AP4.3 - Ermittlung der Relevanz von einzelnen Parametern des optischen Messsystems durch Deep-Learning-Modelle

Um die Relevanz der hyperspektralen Parameter für die Weiterentwicklung optischer Systeme zu erforschen, wurden verschiedene maschinelle Lernalgorithmen für die Klassifikation ausgewählt. Um die Eingabemerkmale vorzubereiten, wurde ein Vorverarbeitungsschritt implementiert, um





Datenpunkte im Bereich von 0 bis 1 zu skalieren. Anschließend wurden für die experimentelle Phase alle Wellengruppen in das Segment der Hauptkomponentenanalyse mit 100 Komponenten einbezogen, mit Ausnahme derjenigen, die derzeit auf ihre Auswirkungen auf die Leistung untersucht werden. Diese Komponenten wurden dann beim Training einer Reihe von Klassifikatoren eingesetzt.

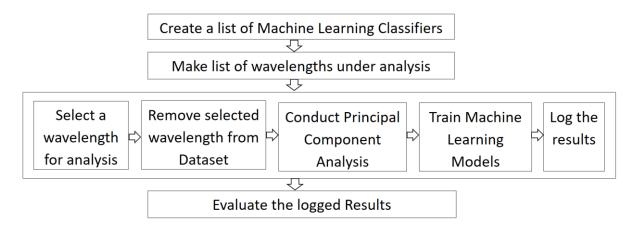


Abbildung 37: Beispiel für das Pruning der Gewichte eines neuronalen Netzes

In der dargestellten Abbildung 37 besteht der erste Schritt darin, eine Liste von Klassifikatoren zusammen mit den für die Analyse vorgesehenen Wellenlängen zu erstellen. Anschließend wird systematisch eine bestimmte Wellenlänge aus dem Datensatz entfernt. Danach wird die Hauptkomponentenanalyse auf den verbleibenden Wellenlängen angewendet. Das maschinelle Lernmodell wird dann trainiert und die Ergebnisse werden aufgezeichnet. Dieser Prozess wiederholt sich, bis die Ergebnisse für jede Wellenlänge ordnungsgemäß protokolliert sind. Schließlich wird eine umfassende Auswertung der Ergebnisse durchgeführt, um die Leistung zu bewerten. Diejenigen Wellenlängen, deren Entfernung zu der signifikantesten Reduzierung der Genauigkeit führte, werden als die wirkungsvollsten identifiziert.

Aus dem Pool der trainierten Klassifikatoren wurden die Top 5 Modelle, basierend auf ihrer Genauigkeit, verwendet, um den Einfluss der Wellenlängen zu bewerten. Diejenigen Wellenlängen, deren Ausschluss zu einer Verringerung der Genauigkeit führte, wurden systematisch nach ihrem Einfluss sortiert – insbesondere nach der erreichten Genauigkeit ohne sie. Die resultierende Tabelle (Tabelle 5) präsentiert die Top 5 Klassifikatoren mit wirkungsvollen Wellenlängen in aufsteigender Reihenfolge und unterstreicht die entscheidende Rolle dieser Wellenlängen bei der Weiterentwicklung optischer Systeme. Es ist wichtig zu beachten, dass trotz des beobachteten Einflusses in den robustesten Klassifikatoren eine definitive Aussage aufgrund der begrenzten Verfügbarkeit von Daten herausfordernd ist.





Tabelle 5: Tabelle mit verschiedenen Wellenlängen, sortiert nach ihrem Einfluss auf die Genauigkeit, mit Spalten für den betroffenen Klassifikator

	LogisticRegressionCV	PassiveAggressiveClassifier	LinearSVC	RidgeClassifierCV	SGDClassifier
0	590	590	720	450	590
1	520	720	620	590	620
2	620	620	850	620	850
3	660	850	520	520	450
4	720	450	590	660	520
5	450	660	940	940	720
6	940	940	450	470	470
7	470	520	470	850	660
8	850	470	660	720	940

Aus Tabelle 5 wird deutlich, dass in den leistungsstärksten Klassifikatoren die Wellenlängen 590 nm, 620 nm, 720 nm, 450 nm und 520 nm den größten Einfluss auf die Klassifikation haben. Allerdings reichen die verfügbaren Daten nicht aus, um eine definitive Aussage zu treffen.

## 2.4.4 AP4.4 - Optimierung des Deep-Learning-Modells für die Inferenz auf dem KOMPASSmobile-System

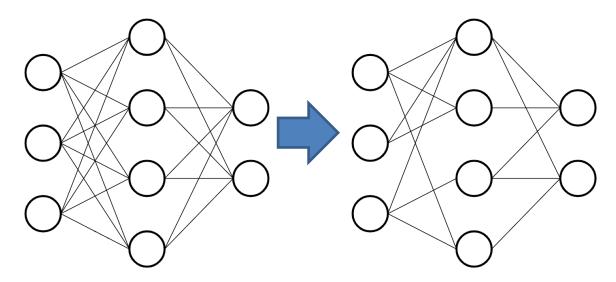


Abbildung 38: Beispiel für das Pruning der Gewichte eines neuronalen Netzes

Bei der Optimierung des Deep-Learning-Modells für das KOMPASSmobile-System wurden verschiedene Techniken eingesetzt. Insbesondere erwies sich unter verschiedenen Modellkompressionsmethoden wie Pruning, Quantisierung, Tensorzerlegung und Wissensdestillation die Quantisierung als die wirksamste. Abbildung 38 veranschaulicht den speziell für die Modellkompression verwendeten Pruning-Prozess.





Da das KOMPASSmobile-System auf Nvidia-Jetson Nano basiert und mit PyTorch-Version 1.10 arbeitet, führten Kompatibilitätsüberlegungen zur Übernahme von EfficientNet-b3. Zur weiteren Verbesserung der Optimierung wurde die NVIDIA TensorRT-Bibliothek verwendet. Diese Bibliothek nutzte eine Kombination von Techniken wie Quantisierung, Layer- und Tensorfusion, Kernelabstimmung usw., um die Effizienz des Modells zu verbessern.

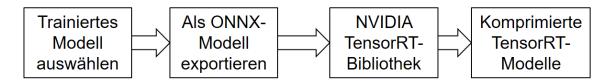


Abbildung 39: Optimization process for Deep learning Model

Der Optimierungsprozess, wie in Abbildung 39 dargestellt, folgt einem systematischen Ablauf. Zunächst wird das Modell ausgewählt und in das standardisierte ONNX-Format exportiert. Anschließend wird die NVIDIA TensorRT-Bibliothek verwendet, um das Modell für den Einsatz auf dem NVIDIA Jetson Nano zu optimieren und ein TensorRT-Modell zu erstellen. Bemerkenswert ist, dass das exportierte ONNX EfficientNet-b3-Modell, das anfangs eine Größe von 48,8 MB hatte, auf ein kompakteres 27,3 MB TensorRT-Modell optimiert wurde.

## 2.5 AP5 - Federated Learning Plattform (FZI)

### 2.5.1 AP5.1 - Konzeption der Managementplattform zur Umsetzung des Federated-Learning-Ansatzes

Im Rahmen von Arbeitspaket 5.1 wurde die Managementplattform zur Umsetzung des Federated-Learning-Ansatzes konzipiert. Dabei wurden auf Basis der in Arbeitspaket 1.1 entwickelten Grobspezifikation der Systemarchitektur unter anderem Schnittstellen, konkrete Abläufe und Austauschformte festgelegt und dokumentiert. Wie der Grobspezifikation zu entnehmen ist, wurde im Projekt eine Aufteilung zwischen globaler Federated Learning Plattform und lokaler Managementplattform angestrebt. Die Verwaltung von Daten und Modellen auf lokaler Ebene unterscheidet sich nur geringfügig von dem System aus dem Projekt Intelligente Diagnostik. Die Änderungen betreffen die neue Schnittstelle zwischen der Managementplattform und der globalen Federated Learning Plattform. Bevor diese Schnittstelle ausführlich konzipiert wurde, wurden zunächst die Abläufe der Kommunikation zwischen den beiden Plattformen spezifiziert. Dazu wurde ein ausführliches Sequenzdiagramm erstellt. Ein Auszug von diesem ist in Abbildung 40 dargestellt. Für die konkreten Federated Learning Funktionalitäten, wie den Austausch und die Fusion der Modelle, wird das Framework Flower verwendet (siehe Abschnitt 2.4.2). Im Sequenzdiagramm ist die Kommunikation, welche durch Flower abgewickelt wird, entsprechend mit der Ergänzung "[Flower]" gekennzeichnet. Zur Erfüllung identifizierter Anforderungen (siehe Abschnitt 2.1.1) ist die alleinige Verwendung von Flower für die Kommunikation zwischen globalem und lokalem System jedoch nicht ausreichend. Der Austausch bezüglich der Anzahl neuer Daten je Standort (wie in 2.1.2 spezifiziert) erfolgt separat in vorgelagerten Schritten. Auch die Registrierung der Clients für die Federated Learning Vorgänge erfordert zusätzliche Kommunikation, wie dem Sequenzdiagramm-Auszug zu entnehmen ist, da mit Flower in der Regel eine Registrierung von lokaler Seite vorgesehen ist und diese für jeden Trainings-Prozess neu erfolgen muss. Durch die dargestellte





zusätzliche Kommunikation kann die Registrierung in der globalen Federated Learning Plattform ausgelöst werden und bereits einmalig registrierte lokale Standorte (Clients) werden automatisch zu jedem Trainingsvorgang hinzugezogen.

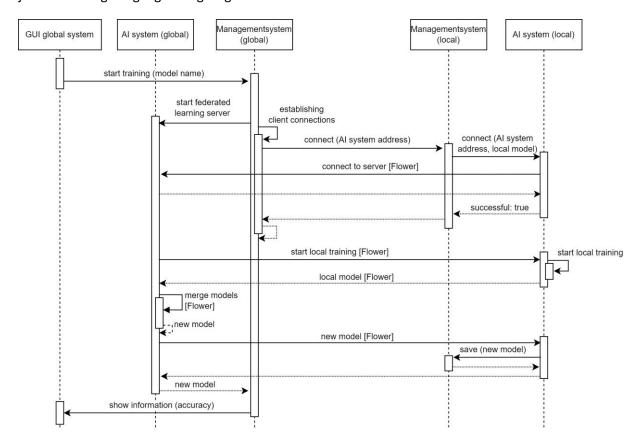


Abbildung 40: Sequenzdiagramm-Auszug zur Kommunikation zwischen der globalen Federated Learning Plattform und der lokalen Managementplattform innerhalb des Trainings-Prozesses.

Durch die mittels des Sequenzdiagramms spezifizierte Kommunikation zwischen lokaler Managementplattform und globaler Federated Learning Plattform konnte die neue Schnittstelle entworfen werden. Die geplanten neuen Endpunkte der lokalen Managementplattform sind in Tabelle 6 aufgelistet.

Tabelle 6: Auflistung der geplanten Endpunkte der Schnittstelle zwischen der globalen Federated Learning Plattform und der lokalen Managementplattform, auf Seiten der lokalen Managementplattform.

ENDPUNKT	BESCHREIBUNG	ÜBERMITTELTE DATEN
CONNECT	[POST] Löst die Anmeldung des lokalen Systems bei dem Flower Federated Learning Server aus	U.a. Adresse (IP und Port) des globalen KI-Containers sowie des globalen Managementsystems
CONNECT COM TEST	[POST] Löst die Anmeldung des lokalen Systems bei dem Flower Federated Learning Server zum Kommunikationstest aus	Adresse (IP und Port) des globalen KI- Containers
NEW-DATA	[GET] Ermöglicht die Abfrage der Anzahl neuer akquirierter Daten, abhängig des übergebenen Zeitstempels	Zeitstempel [Rückgabe] Anzahl neuer Daten und Anzahl aller Daten
ADD-MODEL	[POST] Ermöglicht das Hinzufügen eines neuen Modells für zukünftige Federated Learning Vorgänge	Adresse (IP und Port) der globalen Federated Learning Plattform, Modell- Bezeichnung sowie PT-Datei in Form eines Base64-Codes





Die globale Federated Learning Plattform nutzt diese Endpunkte zur Orchestrierung der Federated Learning Vorgänge. Damit zudem die lokalen Managementplattformen die Möglichkeit erhalten Informationen bzw. Mitteilungen zu aktuellen Vorgängen (wie vergangener sowie zukünftiger Trainingsdurchläufe) abzufragen, wurde ergänzend spezifiziert, dass die globale Federated Learning Plattform einen entsprechenden Endpunkt "Messages" bereitstellt.

Neben der neuen Schnittstelle wurden folgende weitere Punkte identifiziert, welche bezüglich der lokalen Managementplattform und somit im Rahmen von Arbeitspaket 5.3 (siehe Abschnitt 2.5.3) anzupassen sind. Auch hierzu fand jeweils die Planung der Umsetzung statt. Die geplanten Anpassungen umfassen unter anderem:

- Die Erweiterung des grafischen User-Interface, der Datenbank und des Managementsystems zur Verwaltung neuer Metadaten (Alter, Geschlecht und Position der Hautläsion) sowie weiterer Krankheitsbilder (Basalzellkarzinom, Plattenepithelkarzinom, Merkelzellkarzinom, Seborrhoische Keratose, Aktinische Keratose und Angiom). Zudem soll hinsichtlich der Dokumentation der Diagnosen eine Unterscheidung zwischen histopathologischer und ärztlicher Diagnose unterstützt werden.
- Die Ergänzung der bereits bestehenden Schnittstelle zwischen der lokalen Managementplattform und dem lokalen KI-Container, um die Endpunkte zum Federated Learning
- Das Entfernen redundanter bzw. nicht notwendiger Endpunkte zwischen der lokalen Managementplattform und dem lokalen KI-Container (bspw. der Endpunkt Accuracy, da die entsprechenden Informationen bereits in der Rückgabe des Endpunkts Models enthalten sind.)
- Die Anpassung des Endpunkts Diagnose zwischen lokaler Managementplattform und dem lokalen Client, sodass dieser zukünftig auch eine direkte Übertragung der Aufnahmen unterstützt (mit automatisierter Ausführung des anschließenden Post-Processing)
- Die Ausweitung der Verwaltung der Informationen je Modell, sodass Daten zu möglichen zugehörigen Federated Learning Servern dokumentiert und abgerufen werden können

Die globale Federated Learning Plattform war hingegen vollständig neu umzusetzen, wobei auf bewährte Konzepte der lokalen Managementplattform aus Intelligente Diagnostik, wie beispielsweise der Einbindung der KI-Funktionalität im Managementsystem mit dem Adapter-Entwurfsmuster, zurückgegriffen werden konnte. Die globale Federated Learning Plattform soll nach der Grobspezifikation aus Abbildung 1 die folgenden direkten Schnittstellen enthalten:

- Globales Managementsystem globales Management UI
- Globales Managementsystem globale Meta-Datenbank
- Globales Managementsystem lokales Managementsystem
- Globales Managementsystem globaler KI-Container

Durch die Festlegung der erforderlichen Funktionen konnten auch diese Schnittstellen detailliert spezifiziert werden. Im Folgenden sind in Tabelle 7 die geplanten Schnittstellen-Endpunkte des globalen Managementsystems für das globale Management-UI und in Tabelle 8 die Endpunkte des globalen KI-Systems, inklusive während der Umsetzung identifizierter Anpassungen, exemplarisch aufgelistet.





Tabelle 7: Auflistung der Endpunkte der Schnittstelle zwischen dem globalen Managementsystem und dem globalen Management-User-Interface

ENDPUNKT	BESCHREIBUNG	ÜBERMITTELTE DATEN
CLIENTS	[GET] Ermöglicht die Abfrage aller Informationen zu den aktuell registrierten Iokalen Managementplattformen	[Rückgabe] U.a. Adresse, Datum der Registrierung, Anzahl akquirierter Daten, 
MODELS	[GET] Ermöglicht die Abfrage aller Informationen zu den aktuell verwalteten KI- Modellen	[Rückgabe] U.a. Name, Trainings- Intervall, gewichtetes Training (ja/nein), Accuracy,
LOGS	[GET] Ermöglicht die Abfrage der gespeicherten Logs zu u.a. den registrierten Clients, der Trainingsvorgänge und zu Fehlern	[Rückgabe] Log-Einträge inkl. dem Datum für u.a. Trainings- / und Test-Prozesse / Client-Registrierung /
COM-TEST	[GET] Ermöglicht das Starten eines Kommunikations-Tests (Lediglich Durchführung der FL-Kommunikation ohne die Ausführung eines Trainings)	[Rückgabe] Information, ob der Kommunikations-Test erfolgreich war
START-FEDERATED- LEARNING	[GET] Ermöglicht das Starten eines konkreten Federated Learning Vorgangs mit allen registrierten lokalen Systemen für ein spezifisches Modell	[Rückgabe] Information, ob der Federated Learning Vorgang abgeschlossen werden konnte (Informationen wie die Accuracy werden direkt in der Datenbank gespeichert)
CONNECT-CLIENT	[POST] Ermöglicht die Anmeldung einer lokalen Plattform bei der globalen Federated Learning Plattform	Adresse der lokalen Managementplattform (IP + Port)
DISCONNECT- CLIENT	[POST] Ermöglicht die Abmeldung einer lokalen Plattform von der globalen Federated Learning Plattform	Adresse der lokalen Managementplattform (IP + Port)
SET-TRAINING- PARAMETER	[POST] Ermöglicht das Aktualisieren der Trainingsparameter	U.a. Informationen zum Trainings- Intervall, zur gewichteten Fusion, zur Fusions-Strategie,
ADD MODEL	[POST] Ermöglicht das Hinzufügen einer Modell-Datei	PT-Datei in Form eines Base64-Codes

Tabelle 8: Auflistung der Endpunkte der Schnittstelle zwischen dem globalen Managementsystem und dem globalen KI-System

ENDPUNKT	BESCHREIBUNG	ÜBERMITTELTE DATEN
FEDERATED LEARNING	[POST] Ermöglicht das Starten des Federated Learning Servers	U.a. mind. Anzahl an Clients,
ADD-MODEL	[POST] Ermöglicht das Hinzufügen eines neuen KI-Modells	PT-Datei in Form eines Base64- Codes und Modell-Bezeichnung
EXPORT-MODEL	[GET] Ermöglicht die Abfrage eines KI- Modells	[Rückgabe] PT-Datei des angefragten Modells

Die weiteren Schnittstellen beziehungsweise die Änderungen dieser im Vergleich zu dem System aus Intelligente Diagnostik wurden ebenfalls konzipiert. Insgesamt existieren im Gesamtsystem sieben REST-Schnittstellen mit insgesamt 42 Endpunkten. Zusätzlich dazu waren die Schnittstellen zu den Datenbanken und zwischen dem lokalen und globalen KI-System-Containern umzusetzen. Die anfangs erstellten Konzepte aus diesem Arbeitspaket bildeten das Grundkonzept, welches in den konkreten Implementierungen der globalen Federated Learning Plattform (siehe 2.5.2) und der lokalen Managementplattform (siehe 2.5.3) umgesetzt und schrittweise zu den hier vorgestellten Konzepten erweitert beziehungsweise spezifiziert wurde.

Zur einheitlichen Dokumentation der Schnittstellenendpunkte wurde swagger (<a href="https://swagger.io/">https://swagger.io/</a>) eingesetzt. Gerade die Schnittstellen zwischen Management- und KI-Systemen wurden während der





Implementierung kontinuierlich angepasst. Um eine stets aktuelle Schnittstellendokumentation zu gewährleisten, wurde mittels *swagger* die Dokumentation der Flask-Endpunkte direkt aus der Python-Datei realisiert.

Ein weiterer Arbeitsinhalt in AP 5.1, welcher die Konzeption abschließt, war die Sammlung von Sonderfällen hinsichtlich der Abläufe und der bereitgestellten Funktionalität. Die Identifikation der Sonderfälle sowie die Erstellung von Konzepten zum Umgang mit diesen fand in Zusammenarbeit mit HS-VS statt. Ein exemplarischer Auszug der erarbeiteten Sammlung ist in Tabelle 9 dargestellt.

Tabelle 9: Auflistung der identifizierten Sonderfälle mit entsprechenden Lösungsansätzen, welche zum Teil bereits innerhalb des Projektvorhabens umgesetzt werden konnten.

SONDERFALL	BESCHREIBUNG	LÖSUNGSANSATZ
VERSCHLECHTERUNG DER PRÄDIKTIONSGÜTE	Ablauf für den Fall, dass nach einem Federated Learning Vorgang eine Verschlechterung hinsichtlich der Prädiktionsgüte festgestellt wird.	Das Modell soll nicht automatisiert ohne Benachrichtigung an die einzelnen lokalen Systeme verteilt werden. Ein Administrator soll in diesem Fall über die Verteilung entscheiden und es wird ggf. eine Benachrichtigung an die jeweiligen Standorte versendet. Siehe Anpassung des Prozesses in Abbildung 41. (Umgesetzt wurde die Benachrichtigung der lokalen Standorte mithilfe des Messages Endpunkt. Die automatisierte Verteilung wird in der Umsetzung in AP5.2 nicht unterbrochen, sodass KI-Modelle ggf. manuell entfernt werden müssen)
NEUES MODELL HINZUFÜGEN	Ablauf für den Fall, dass ein neues globales Modell angelegt wird.	Nach dem Speichern eines neuen Modells im globalen System müssen die einzelnen Standorte das neue Modell ebenfalls erhalten. Daher wurden entsprechende Endpunkte im lokalen System (siehe Tabelle 6) und innerhalb des globalen Systems (siehe Tabelle 7 und Tabelle 8) zum Konzept hinzugefügt.
NEUES LOKALES SYSTEM HINZUFÜGEN	Ablauf für den Fall, dass ein neuer Standort hinzugefügt wird.	Der neue Standort muss die global verwalteten Federated Learning Modelle erhalten. Dazu können ähnlich wie beim Hinzufügen eines neuen Modells von Seiten des globalen Systems je Modell entsprechende Endpunktaufrufe ausgeführt werden. (Dies wurde in AP5.2 nicht umgesetzt – Modelle können alternativ manuell hinzugefügt werden)
UMGANG MIT VERSCHIEDENEN MODELL-VERSIONEN	Ablauf bei der Sicherung älterer Modell-Versionen.	Auf eine Versionierung im Managementsystem wird verzichtet, da dies die Übersichtlichkeit mindern könnte. Stattdessen werden veraltet Modellversion im Filesystem gesichert.
TRANSPARENTE BEKANNTMACHUNG VON MODELL- UPDATES	Ablauf für das Informieren aller Nutzer hinsichtlich durchgeführter Federated Learning Vorgänge und aktualisierter Modelle.	Innerhalb des lokalen UI (zur Betrachtung der Prädiktionsergebnisse) sollen Benachrichtigungen abgefragt und übersichtlich angezeigt werden.





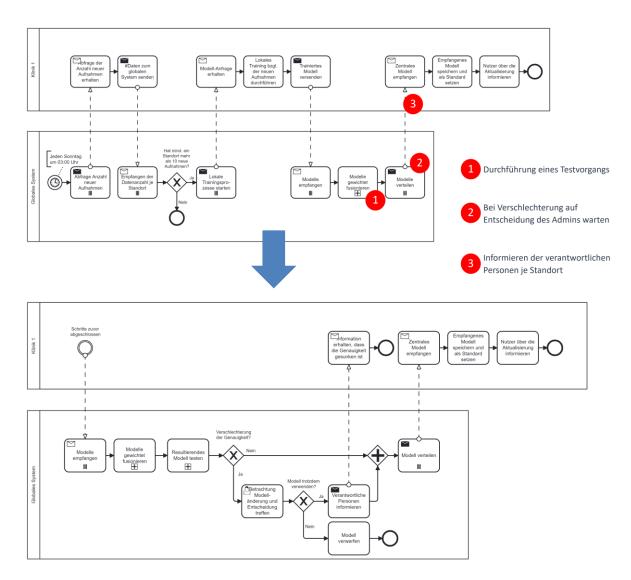


Abbildung 41: Darstellung der Anpassung des geplanten Federated Learning Prozesses hinsichtlich des Umgangs mit evtl. entstehender Verschlechterung der Prognose-Genauigkeit.

#### 2.5.2 AP5.2 - Implementierung der Globalen Federated Learning Plattform

Die im Rahmen vom Projekt Intelligente Diagnostik erstellte Container-Struktur wurde wie in AP1.1 geplant um ein weiteres Docker-Netzwerk für die globale Federated Learning Plattform erweitert. Zur Vorbereitung der Umsetzung der Federated Learning Funktionalität wurde zudem die Kommunikation zwischen den beiden Netzwerken für die Managementsystem- und KI-System-Container sichergestellt. Die hinzugekommenen Container sind in Tabelle 10 mit den jeweils verwendeten Images aufgelistet.





Tabelle 10: Übersicht über die Container der globalen Federated Learning Plattform

KOMPONENTE	CONTAINER-BEZEICHNUNG	IMAGE
MANAGEMENT-SYSTEM (GLOBAL)	Global_client	tomcat
METADATENBANK	Global_meta_database	mysql
KI-SYSTEM FUNKTIONALITÄT	Global_ai_system	nvidia/cuda
ADMIN-CLIENT	Global_managementsystem	nginx

Wie in der lokalen Managementplattform bildet auch in der globalen Federated Learning Plattform das Managementsystem die zentrale Komponente. Diese steuert die Kommunikation zwischen den einzelnen Komponenten der globalen Federated Learning Plattform und orchestriert die konkreten Federated Learning Vorgänge (wie in AP1.1 – Abschnitt 2.1.1 – skizziert). Zur Umsetzung des für das globale Managementsystem in AP5.1 entworfene Konzept (siehe Abschnitt 2.5.1) wurden die in Tabelle 11 aufgelisteten Klassen implementiert.

Tabelle 11: Übersicht über die Klassen des globalen Managementsystems.

NAME	BESCHREIBUNG	ART
AI ADAPTER	Adapter des Adapter-Entwurfsmusters für die Kommunikation mit dem KI-Container.	Adapter-Klasse
AI MODELL	Interface des Adapter-Entwurfsmusters. Definiert alle KI-Funktionen, die implementiert werden müssen.	Interface
AI MODEL ACTIONS	Beinhaltet alle Aktionen bezüglich der KI-Modelle, welche in den Logs gespeichert werden.	Enum
CLIENT	Beinhaltet alle Informationen zu einem lokalen System.	Hilfsklasse
CLIENT ACTIONS	Beinhaltet alle Aktionen bezüglich der lokalen Systeme, welche in den Logs gespeichert werden.	Enum
CLIENT API	Beinhaltet die Schnittstellenendpunkte für die Anfragen des globalen User-Interface.	Servlet-Klasse
CLIENT LOG	Beinhaltet alle Informationen eines Log-Eintrags zur Änderung der Daten eines lokalen Systems. Erbt hierzu von Klasse Client.	Hilfsklasse
CONNECT CLIENT RUNNABLE	Beinhaltet die Funktionalität, welche bei der Ausführung der Timer aufgerufen wird.	Hilfsklasse
DATABASE CONNECTION EXCEPTION	Für den Fall, dass keine Verbindung zum Datenbank-Container aufgebaut werden konnte.	Exception
FEDERATED LEARNING PARAMETER	Beinhaltet die Werte aller Parameter eines Federated Learning Vorgangs.	Hilfsklasse
FUSION STRATEGY INTERVAL ASSIGNMENT EXCEPTION	Beinhaltet alle unterstützten Fusions-Strategien. Für den Fall, dass zu wenige oder zu viele Zeit-Parameter in Bezug zum angegebenen Trainingsintervall spezifiziert wurden.	Enum Exception
LOCAL MANAGEMENTSYSTEM	Interface des Adapter-Entwurfsmusters. Definiert alle Funktionen der lokalen Systeme, die vom globalen System aufgerufen werden können.	Interface
LOCAL MANAGEMENTSYSTEM ADAPTER	Adapter des Adapter-Entwurfsmusters für die Kommunikation mit den lokalen Managementsystemen.	Adapter-Klasse
LOCAL MANAGEMENTSYSTEM API	Beinhaltet den Schnittstellenendpunkt für die lokalen Managementsysteme zur Abfrage von Informationen bzw. Mitteilungen zu aktuellen Federated Learning Vorgängen.	Servlet-Klasse
MANAGEMENTSYSTEM	Zentrale Klasse mit allen wichtigen Funktionen. Umgesetzt als Singleton-Entwurfsmuster.	Singleton-Klasse
META DATABASE	Beinhaltet alle Funktionen zur Kommunikation mit der Datenbank- Komponente. Erbt hierzu von der MySQL-Database Klasse.	Adapter-Klasse
META DATA AI MODEL	Beinhaltet alle Meta-Informationen, die zu einem KI-Modell verwaltet werden.	Hilfsklasse
META DATA AI MODEL LOG	Beinhaltet alle Informationen eines Log-Eintrags zur Änderung der Meta-Informationen eines KI-Modells. Erbt hierzu von Klasse Meta-Data-AI-Model.	Hilfsklasse
MODEL INFO	Beinhaltet alle Informationen, die nach einem Trainingsvorgang vom KI-Container zurückgegeben werden.	Hilfsklasse
MYSQL DATABASE	Beinhaltet grundlegende Funktionen für den Verbindungsaufbau mit einer MySQL-Datenbank.	Adapter-Klasse





STANDARD MODEL NOT AVAILABLE EXCEPTION	Für den Fall, dass ein KI-Modell als Standard-Modell festgelegt werden soll, dieses aber nicht mehr / noch nicht existiert.	Exception
TIMER COLLECTION	Verwaltet alle Timer für die regelmäßigen Trainingsvorgänge.	Hilfsklasse
TRAINING ACTIONS	Beinhaltet alle Aktionen bezüglich der Federated Learning Vorgänge, welche in den Logs gespeichert werden.	Enum
TRAINING INTERVAL	Beinhaltet alle unterstützten Trainingsintervalle.	Enum
TRAINING LOG	Beinhaltet alle Informationen eines Log-Eintrags zu einem Trainingsvorgang.	Hilfsklasse
TRAINING PARAMETER RANGE	Beinhaltet die Wertebereiche der Parameter für die Trainings- Vorgänge.	Hilfsklasse
WEEK DAY	Beinhaltet alle Wochentage.	Enum

Die in Tabelle 11 aufgelisteten Klassen adressieren unterschiedliche Funktionalitäten und können entsprechend gruppiert werden. Die Klassen *Client-Log, Metadata-Al-Model-Log* und *Training-Log* wurden beispielsweise implementiert, um Funktionalitäten zum Dokumentieren von Logs zu ermöglichen. Die Klassen *Al Adapter* (mit dem Interface *Al Model*) und *Local Managementsystem Adapter* (mit dem Interface *Local Managementsystem*) hingegen realisieren jeweils das Adapter-Entwurfsmuster für die Anbindung der Schnittstelle zum globalen KI-Container sowie zur Schnittstelle des lokalen Managementsystems.

Insgesamt umfasst die Implementierung der globalen Federated Learning Plattform 213 Methoden. Ein Teil dieser Methoden gehört zur Umsetzung des automatisierten regelmäßigen Startens der Federated Learning Vorgänge. Hierzu wurde eine Verwaltung von Timern, welche auf dem Framework *java.util.Timer* basieren, implementiert. Diese Verwaltung erfolgt wie in Abbildung 42 dargestellt persistent, indem die Meta-Daten der Timer in einer Tabelle der Metadatenbank gespeichert werden, sodass nach einem Neustart des globalen Systems die zugehörigen Timer neu angelegt werden können.

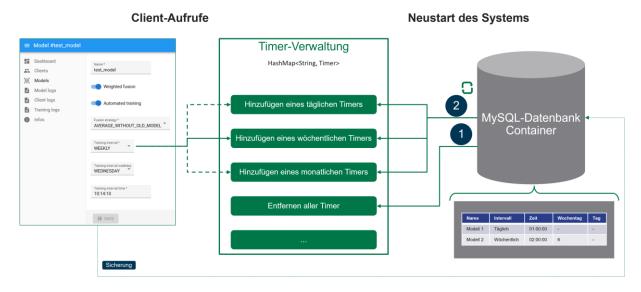


Abbildung 42: Visualisierung der Timer-Verwaltung zum Auslösen der regelmäßigen Trainings-Vorgänge.

Neben den Informationen zu den Timern werden auch die aktuellen registrierten lokalen Systeme, die Metadaten der aktuell verwalteten KI-Modelle sowie die Logs in der globalen Datenbank verwaltet. Zur Visualisierung der Struktur der Datenbank ist in Abbildung 43 das Entity-Relationship-Modell dargestellt.





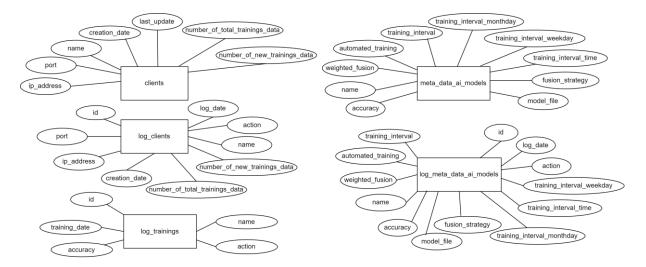


Abbildung 43: Visualisierung der Struktur der globalen Metadatenbank

Analog zur lokalen Managementplattform, wurde in Intelligente Diagnostik 2 für die globale Federated Learning Plattform die KI-System-Funktionalität mittels einer Flask Schnittstelle in einem separaten Container zur Verfügung gestellt. Die konkreten KI-Funktionen wurden von HS-VS umgesetzt (siehe Kapitel 2.4) und umfassen für das globale System unter anderem die Funktionalitäten zur Ausführung des Flower Federated Learning Servers. Die im Rahmen von AP 5.2 implementierte Flask Schnittstelle beinhaltet entsprechend Aufrufe der im Code von HS-VS zur Verfügung gestellten Methoden, welche insbesondere den Flower Federated Learning Server starten und nach der Registrierung der lokalen Standorte den konkreten Federated Learning Prozess durchführen.

Die vierte Komponente stellt einen webbasierten Client zur Interaktion mit dem globalen Managementsystem zur Verfügung. Hierzu wurden die Endpunkte aus Tabelle 7 umgesetzt. Der entstandene webbasierte Client wird ausführlich in Abschnitt 2.5.4 vorgestellt.

#### 2.5.3 AP5.3 - Implementierung funktionaler Erweiterungen der lokalen Managementplattform

Die lokale Managementplattform wurde im Projekt Intelligente Diagnostik umgesetzt. Durch die neuen Anforderungen, insbesondere hinsichtlich der Vernetzung mehrerer lokaler Plattformen zu einem verteilten System, entstand die Notwendigkeit der funktionalen Erweiterung. Diese wurde im Detail in Arbeitspaket 5.1 konzipiert (siehe Abschnitt 2.5.1) und im Rahmen von Arbeitspaket 5.3 erfolgreich umgesetzt.

Die lokale Managementplattform wurde im Universitätsklinikum Tübingen zur Akquirierung und Dokumentation der Trainingsdaten für das Projekt eingesetzt. Um im Projektverlauf auch die in Intelligente Diagnostik 2 hinzugekommenen Krankheitsbilder und Metainformationen dokumentieren zu können, erfolgte zu Beginn des Projekts die Erweiterung der lokalen Managementplattform im Hinblick auf die Verwaltung dieser Daten. Insbesondere betrifft dies Anpassungen an den Komponenten lokales Managementsystem, lokale Metadatenbank sowie dem webbasierten lokalen Managementsystem Client. Das lokale ist die zentrale Komponente Managementplattform, welche die Kommunikation steuert. Zur Dokumentation der neuen Informationen wurden entsprechend Schnittstellen-Endpunkte im lokalen Managementsystem erweitert und neue Schnittstellen-Endpunkte erstellt. Beispielsweise sind in der Rückgabe des





Diagnose-Endpunkts nun die Position der Hautläsion und die histopathologische Diagnose enthalten und es wurde u.a. ein neuer POST-Endpunkt zum Speichern des Alters von Patienten zu einer Aufnahme implementiert. Im lokalen webbasierten Client von Intelligente Diagnostik wurden die zusätzlichen Metainformationen in Form von verschiedenen Karten-Widgets hinzugefügt und können innerhalb dieser auch bearbeitet werden (siehe Abbildung 44 links). Das Karten-Widget zur Dokumentation der Diagnose wurde zum einen um die Möglichkeit der Dokumentation der weiteren Krankheitsbilder und zum anderen um die Möglichkeit der Unterscheidung zwischen ärztlicher und histopathologischer Diagnose erweitert (siehe Abbildung 44 rechts). Zur persistenten Speicherung der neuen Daten wurde zudem das Datenbankschema um die Attribute *position*, age und *gender* ergänzt, wie in Abbildung 45 in Rot dargestellt.

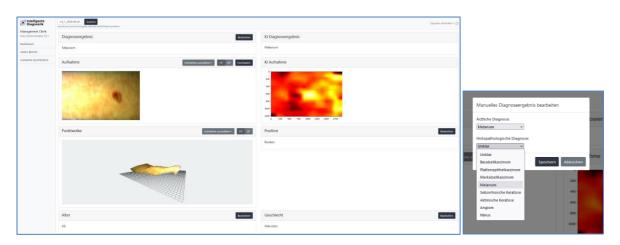


Abbildung 44: Erweiterung des webbasierten User-Interface aus Intelligente Diagnostik

Die Erweiterung hinsichtlich des Federated Learning Ansatzes erforderte verschiedene Anpassungen, welche in AP5.1 konzipiert wurden und in Abschnitt 2.5.1 aufgelistet sind. Im Folgenden wird auf die Umsetzung der hier aufgelisteten wesentlichen Anpassungen im Detail eingegangen:

- Erweiterung der Verwaltung der KI-Modelle um die Unterscheidung zwischen lokalen und Federated Learning Modellen
- Erweiterung der Schnittstelle zwischen dem lokalen Managementsystem und dem lokalen KI-Container
- Implementierung der Schnittstelle zwischen lokaler Managementplattform und globaler Federated Learning Plattform
- Umsetzung der neuen Funktionalität im lokalen Managementsystem

Die in Intelligente Diagnostik umgesetzte lokale Managementplattform soll den gesamten Funktionsumfang beibehalten und hinsichtlich des Federated Learning Ansatzes lediglich erweitert werden. Dies impliziert, dass eine Unterscheidung zwischen zwei Arten von Modellen erfolgen muss. Zum einen werden Modelle verwaltet, welche für das Federated Learning bestimmt sind und zwischen Systemen ausgetauscht werden. Zum anderen existieren Modelle im lokalen System, welche nur lokal verwendet und trainiert werden. Um die Verwaltung beider Modell-Arten zu ermöglichen, musste die Datenbankstruktur nochmals erweitert werden. Die Tabelle Meta-Data-Al-Model beinhaltet die Informationen zu den verwalteten Modellen. In dieser wurden federated\_learning\_server\_ip\_address und federated\_learning\_server\_port ergänzt (siehe Abbildung





45), welche für Federated Learning Modelle die entsprechende Server-Adresse beinhalten und für lokale Modelle auf *null* gesetzt werden. Dies ermöglicht die interne Unterscheidung in Modelle des Typs *local* und *federated\_learning* und darauf aufbauend die Sicherstellung, dass nur Modelle des Typs *local* unabhängig lokal angepasst werden können und somit, dass das Training von Modellen des Typs *federated\_learning* zentral ausgelöst werden muss. Im lokalen Managementsystem wurde eine entsprechende Klasse *Federated-Model* implementiert, welche von der Klasse *Model* erbt und die allgemeinen Modell-Informationen um die Adressinformationen des Federated Learning Servers erweitert. Im resultierenden JSON-String des Models-Endpunkts ist anhand des Attributs *address* auch für den Client zu erkennen, bei welchen Modellen es sich um ein Federated Learning Modell oder ein lokales Modell handelt.

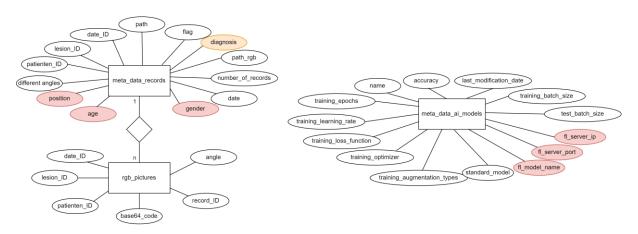


Abbildung 45: Visualisierung der Struktur der lokalen Metadatenbank. Angepasste Attribute sind in Orange und neu hinzugefügte Attribute in Rot dargestellt.

Die Bezeichnung der Federated Learning Modelle in den lokalen Managementplattformen kann flexibel und unabhängig von der Bezeichnung der Modelle in der globalen Federated Learning Plattform gewählt werden. Um dies zu ermöglichen, wird in der lokalen Metadatenbank im neuen Attribut federated\_learning\_model\_name die in der globalen Federated Learning Plattform gewählte Bezeichnung des Modells gespeichert, sodass eine Abbildung der Bezeichnungen bei Anfragen vom globalen Managementsystem erfolgen kann.

Der Client-seitige Federated Learning Code von HS-VS kann im gleichen KI-Docker-Container ausgeführt werden wie die bereits implementierten lokalen KI-Funktionen. Aus diesem Grund war es ausreichend die bereits bestehende Schnittstelle aus Intelligente Diagnostik um die neuen Endpunkte connect und connect\_com\_test zu erweitern. Im Code des lokalen Managementsystems war, aufgrund der gewählten Softwarearchitektur und insbesondere aufgrund der Verwendung des Adapter-Entwurfsmusters zur Anbindung von Schnittstellen, bezüglich dieser Erweiterung nur eine Anpassung der Klassen des Entwurfsmusters notwendig. Im Detail wurde bezüglich der zwei neuen Endpunkte das Interface KI-Modell die Funktionen connect for federated learning connect\_for\_federated\_learning\_com\_test ergänzt. Die Implementierung des Interfaces von der Klasse KI-Adapter wurde daraufhin ebenfalls entsprechend erweitert. Die Funktionen connect for federated learning und connect for federated learning com test werden aufgerufen, wenn von Seiten der globalen Federated Learning Plattform der Federated Learning Prozess beziehungsweise der Kommunikationstest gestartet wird.





Um entsprechende Anfragen, wie das Starten der Federated Learning Vorgänge, von der Federated Learning Plattform entgegennehmen zu können, muss eine passende Schnittstelle zwischen globalem und lokalem Managementsystem bereitgestellt werden. Die notwendigen Endpunkte hierzu wurden ebenfalls im AP 5.1 (siehe Tabelle 6) entworfen und innerhalb dieses Arbeitspakets als neue http-Servlet Klasse umgesetzt. Wie der Konzeption in Abschnitt 2.5.1 zu entnehmen, werden zunächst vom globalen Managementsystem quantitative Informationen zu den verwalteten Datenbeständen abgefragt, ehe der konkrete Federated Learning Vorgang über den Schnittstellen Endpunkt connect, in Form der Registrierung des lokalen Systems beim Federated Learning Server, gestartet wird. Entsprechende Datenbankabfragen und notwendige Berechnungen konnten zu den bereits bestehenden Klassen des lokalen Managementsystems, wie beispielsweise der Klasse zur Anbindung der lokalen Metadatenbank, hinzugefügt werden. Die für die Umsetzung der Erweiterung des Managementsystems neu hinzugefügten Klassen sind in Tabelle 12 aufgelistet.

Tabelle 12: Auflistung der im Hinblick auf die Umsetzung der Federated Learning Funktionalität neu hinzugefügten Klassen im lokalen Managementsystem. Zu den hier aufgelisteten Klassen wurden Hilfsklassen für die Verwaltung der neuen Metainformationen hinzugefügt und bestehende Klassen erweitert.

NAME	BESCHREIBUNG	ART
GLOBAL MANAGEMENTSYSTEM ADAPTER	Adapter des Adapter-Entwurfsmusters für die Kommunikation mit dem globalen Managementsystem (dieser wird für die Abfrage von aktuellen Mitteilungen vom globalen Federated Learning System verwendet)	Adapter-Klasse
GLOBAL MANAGEMENTSYSTEM	Interface des Adapter-Entwurfsmusters. Definiert alle Funktionen, welche das globale Managementsystem bereitstellt und im lokalen Managementsystem angebunden werden müssen.	Interface
FEDERATED LEARNING API	Beinhaltet die Schnittstellenendpunkte, welche dem globalen Managementsystem zur Kommunikation mit dem lokalen Managementsystem zur Verfügung stehen.	Servlet-Klasse
LOCAL MODEL	Beinhaltet alle Meta-Informationen eines lokalen KI-Modells, welches nicht für Federated Learning Vorgänge verwendet wird. Erbt hierzu von der Klasse Model.	Hilfsklasse
FEDERATED MODEL	Beinhaltet alle Meta-Informationen eines KI-Modells, welches für Federated Learning Vorgänge verwendet wird. Erbt hierzu von der Klasse Model.	Hilfsklasse
FEDERATED LEARNING MESSAGE	Beinhaltet alle Informationen zu einer Mitteilung, welche vom globalen Federated Learning System abgefragt wurde.	Hilfsklasse
MESSAGE ACTION	Beinhaltet alle Aktionen bezüglich der Federated Learning Vorgänge, welche in den Mitteilungen vom globalen Federated Learning System enthalten sein können.	Enum

#### 2.5.4 AP5.4 - Entwicklung eines globalen Management-UI

Zur zentralen Administration der Federated Learning Vorgänge wurde im Rahmen von AP 5.4 ein grafisches Management-User-Interface umgesetzt. Die zu unterstützenden Funktionen basieren auf der Planung in AP 5.1 (siehe Tabelle 7). Unterteilt werden können die Funktionen in administrative Funktionen hinsichtlich der lokalen Systeme, administrative Funktionen hinsichtlich der Modelle, administrative Funktionen zur Steuerung der Federated Learning Prozesse und Funktionen zur Darstellung relevanter Informationen. Zunächst wurde analog zum webbasierten lokalen Client aus Intelligente Diagnostik eine auf Bootstrap basierte vorläufige Version des User-Interface umgesetzt (siehe Abbildung 46). Die unterschiedlichen Informationen werden in diesem in verschiedenen Karten-Widgets dargestellt. Widget 1 listet hierbei alle lokalen Standorte auf, im Widget 2 werden alle aktuell verwalteten KI-Modelle dargestellt, in Widget 4 die verschiedenen Federated Learning Vorgänge und in Widget 6 die restlichen Logs. Über die Menüleiste auf der linken Seite (Punkt 3 in Abbildung 46)





können Dialogfenster für die einzelnen Funktionen, wie dem Hinzufügen neuer Standorte oder dem Anpassen von Trainingsparametern, geöffnet werden.

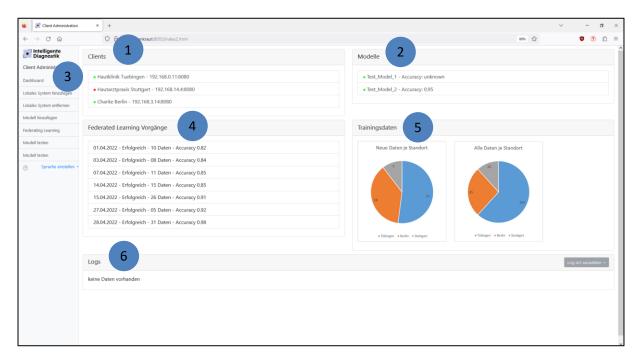


Abbildung 46: Darstellung der ersten Version des Management-UI.

Während der Umsetzung des in Abbildung 46 dargestellten User-Interface wurde mit der Realisierung eines alternativen User-Interface begonnen. Dieses basiert im Gegensatz zur ersten Version auf der Javascript-Bibliothek React. Durch die für den Anwendungsfall geeigneteren Gestaltungsmöglichkeiten der einzelnen Bereiche wurde das auf React basierte User-Interface im weiteren Verlauf des Projekts fokussiert und somit alle notwendigen Funktionen in diesem umgesetzt. Die Benutzeroberfläche ist in Abbildung 47 dargestellt und unterscheidet sich insbesondere zum UI in Abbildung 46 durch die Aufteilung der informativen Darstellungen sowie der Funktionen auf separate Seiten. Das in Abbildung 47 dargestellte Dashboard beinhaltet eine Übersicht über die aktuelle Datensituation in den angebundenen Kliniken. Diese ist mit zwei Kreisdiagrammen visualisiert. Die linke Seite zeigt die Anzahl aller in der jeweiligen Klinik nutzbaren Aufnahmen, das Kreisdiagramm auf der rechten Seite visualisiert die Anzahl der seit dem letzten Trainingsvorgang neu akquirierten Daten. Zudem beinhaltet das Dashboard eine Auflistung der aktuell registrierten lokalen Systeme (Kliniken) und den aktuell verwalteten Modellen.







Abbildung 47: Dashboard der zweiten Version des Management-UI.

#### Administrative Funktionen hinsichtlich der lokalen Systeme

Zur Verwaltung der lokalen Systeme (der lokalen Managementplattformen bzw. Standorte) besteht zunächst die Möglichkeit lokale Systeme durch die Angabe der zugehörigen Netzwerkadresse und einer eindeutigen Bezeichnung hinzuzufügen (siehe Abbildung 49). Das Entfernen eines lokalen Systems ist direkt in der Detailansicht, in der alle aktuell registrierten Standorte aufgelistet sind, möglich (siehe Abbildung 48). Hierzu ist das zu entfernende lokale System in der Liste auszuwählen, woraufhin oberhalb der Liste eine Schaltfläche zum Löschen des Modells angezeigt wird. Neben den Adressinformationen werden in der Auflistung auch das Datum der letzten Aktualisierung sowie die Anzahl der im lokalen System verwalteten Daten angezeigt.



Abbildung 48: Detailansicht der registrierten Standorte bzw. Kliniken.



Abbildung 49: Bereich im User-Interface zum Hinzufügen neuer lokaler Standorte bzw. Kliniken.





#### Administrative Funktionen hinsichtlich der Modelle und der Federated Learning Vorgänge

Das Hinzufügen beziehungsweise Entfernen von Modellen erfolgt analog zum Hinzufügen und Entfernen von Standorten. Für das Entfernen eines Modells muss dieses zunächst markiert werden. Anschließend erscheint eine Schaltfläche zum Löschen des Modells oberhalb der Auflistung. Um ein neues Modell hinzuzufügen, ist die Modellbezeichnung anzugeben und die zugehörige pt-Datei hochzuladen. Dies erfolgt in einem separaten Bereich im User-Interface (siehe Abbildung 51 links), welcher über die Schaltfläche "Create" in der Detailansicht zu den aktuell verwalteten Modellen (siehe Abbildung 50) geöffnet werden kann. Auch die Einstellung der Trainingsparameter erfolgt im User-Interface in einem separaten Bereich (siehe Abbildung 51 rechts). Über die Schaltfläche "Edit" in der Detailansicht besteht die Möglichkeit je Modell die entsprechenden Parameter zu ändern. Insbesondere kann hier das automatisierte Starten der Trainingsvorgänge konfiguriert werden, wie in Abbildung 51 rechts zu sehen. Hierbei kann zwischen einem täglichen, wöchentlichen oder monatlichen Trainingsintervall gewählt werden. Abhängig von der Auswahl werden die notwendigen Informationen, wie Uhrzeit, Wochentag oder Tag im Monat abgefragt. Neben dem automatisierten, regelmäßigen Training können zudem Federated Learning Vorgänge manuell für die jeweiligen Modelle gestartet werden. Hierzu wurde zur Auflistung der Modelle jeweils ein Button "Start Training" hinzugefügt (siehe Abbildung 50).

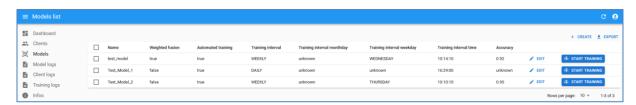


Abbildung 50: Detailansicht der aktuell verwalteten KI-Modelle mit den Informationen zur jeweiligen Trainingsstrategie.

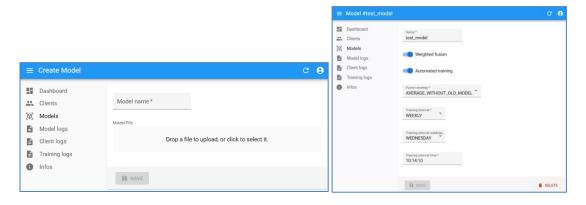


Abbildung 51: Auf der linken Seite ist der Bereich im User-Interface zum Hinzufügen neuer Modelle dargestellt. Auf der rechten Seite der Bereich zur Anpassung der Trainingsparameter (insb. hinsichtlich der Trainingsintervalle).

#### Funktionen zur informativen Darstellung

Neben der Auflistung aktuell verwalteter KI-Modelle und der registrierten lokalen Systeme existieren im globalen Management User Interface drei weitere Bereiche zur Darstellung von Informationen. In den Bereichen *Model logs, Client logs* und *Training logs* werden Änderungen sowie durchgeführte Federated Learning Vorgänge protokolliert. Im Bereich *Model logs* (siehe Abbildung 52) sind beispielsweise alle Änderungen bezüglich der verwalteten KI-Modelle und der zugehörigen





Trainingsparameter aufgelistet. In Abbildung 53 ist ein Ausschnitt aus den Logs zu den Federated Learning Vorgängen dargestellt. Analog existiert ein Bereich zur Darstellung der Logs hinsichtlich Änderungen der verwalteten lokalen Standorte. Änderungen bezüglich der zugehörigen Netzwerkadresse oder dem Hinzufügen und Entfernen von Standorten werden dort festgehalten.

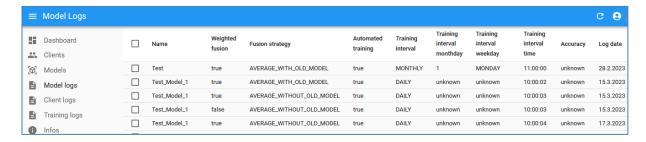


Abbildung 52: Darstellung der Auflistung der Logs im User-Interface bezüglich Änderungen an Trainingsstrategien sowie den verwalteten Modellen.



Abbildung 53: Darstellung der Auflistung der Logs im User-Interface bezüglich erfolgter Federated Learning Vorgänge sowie Kommunikationstests.

### 2.6 AP6 - Entwicklung des KOMPASSmobile-Systems (ILM, HS-S, FZI)

In diesem Arbeitspaket sollte das KOMPASSmobile-System entwickelt werden. Es besteht sowohl aus einer Software-Anwendung zur Läsionserfassung und KI-basierten Diagnose auf einem kompakten handgeführten Endgerät als auch aus den benötigten Hardware-Komponenten für die Messung und Detektion. Hierfür war unter anderem eine weitere Miniaturisierung des bestehenden KOMPASSpro-Systems, insbesondere des Messkopfes, erforderlich. Statt eines stationären Aufnahmegerätes sollte ein mobiles System (KOMPASSmobile) mit handgeführtem Messkopf und mobilem Endgerät zur entwickelt werden. Für die Entwicklung der Client-Anwendung konnte zum Teil auf die im Projekt Intelligente Diagnostik 1 entwickelten Funktionen zurückgegriffen werden. Der Einsatz des KOMPASSmobile-Systems besitzt den großen Vorteil der optimierten, vereinfachten Bedienung und Handhabung für den Endnutzer.

#### 2.6.1 AP6.1 - Technologiefestlegung / Hardwarekonzept (ILM)

In AP 6.1 sollten zunächst verschiedene Konzepte für die Kombination einer speziell angepassten multispektralen Lichtquelle des KOMPASSmobile-Systems erarbeitet und bewertet werden. Der Lösungsansatz umfasst die Ausführung der Lichtquelle als Dockinggerät an das KOMPASSmobile-





System. Besonderes Augenmerk sollte auf das Handling gelegt werden. So sollte das System, als Resultat aus den klinischen Tests (z.B. möglichst wenige Spektralbereiche und Muster), robust, kompakt und minimalisiert auf das Nötigste sein. Als Steuerungseinheit wurde ein NVIDIA Jetson Nano Computer gewählt, da dieser über die nötige Performance verfügt sowie einen kleinen Formfaktor besitzt. Bei den rechnerischen Fähigkeiten wurde berücksichtigt, dass in der letztendlichen Anwendung eine KI-gestützte Auswertung der Messdaten stattfinden sollte. Der Jetson Nano erlaubt eine einfache Implementierung von KI-Anwendungen. Um ein kompaktes System zu ermöglichen, wurde ein Tablet Design gewählt. Der Messaufbau besteht aus einem Touchscreen in einer Halterung, die handgeführt werden kann, mit der Messtechnik auf der Rückseite. Die Hardware besteht aus dem Touchscreen, Jetson Nano, dem Optikmodul zur Streifenprojektion, der Steuerungselektronik und einer Kamera.

Mehrere Konzepte für die Beleuchtungseinheit wurden entwickelt. Eine wesentliche Gemeinsamkeit aller erarbeiteten und bewerteten Konzepte war zum einen der Verzicht auf bewegte Teile und zum anderen die Vermeidung des DMD als Kosten- und Bauraumtreiber. Zudem sollten wieder leistungsstarke LEDs verschiedener Farbe als Lichtquellen verwendet werden. Diese sollen wiederum als Array auf einer gemeinsamen Platine angeordnet sein. Aufgrund der Ergebnisse der ersten Studie wurde entschieden, nur noch 4 Farben und eine Streifenfrequenz (1mm<sup>-1</sup>) in 3 Phasen (jeweils um 120°, d.h. 1/3 Streifenbreite verschoben) sowie ein Bild mit homogener Ausleuchtung zu verwenden.

Zur Streifenmustergenerierung wurde entschieden, die Muster mithilfe von Transmissionsdias zu generieren. Auf viele Ergebnisse von Intelligente Diagnostik 1 und den vorhergehenden Arbeitspaketen konnte aufgebaut werden. So konnten dieselben LEDs und LED-Treiber genutzt werden, die auch schon in den KOMPASSpro-Systemen Verwendung gefunden hatten. Außerdem wurden die Wabenkondensoren von Hahn Schickard auch in diesem Aufbau verwendet.

### 2.6.2 AP6.2 - Miniaturisierung multispektraler Beleuchtung auf Mobilgeräte-Niveau (ILM)

Ziel von AP 6.2 war die Bereitstellung einer multispektralen Beleuchtungseinheit, welche als Teil des KOMPASSmobile-Systems vorgesehen ist. Dabei wurden folgende Spezifikationen erarbeitet:

Messfeldgröße: 30 x 30 mm²

• Ortsfrequenzen: Eine (3 Phasen) + homogene Belichtung

• Spektralkanäle: 4 (Rot, Grün, Blau, NIR)

Diodenstrom: bis zu 1 AMessung im Kontakt

Die Ausführung wurde folgendermaßen festgesetzt:

- LED-Homogenisierung über mikrooptischen Wabenkondensor
- Mustergenerierung über Transmissionsdias
- Arbeitsabstand: 100 mm
- Steuerung: Jetson Nano
- Handhabung: handgeführt, Auflage über Abstandshalter; Auflagefläche sterilisierbar, z.B. durch austauschbaren Aufsatz.
- Display: Touch-Tablet
- Stromversorgung: Power over Ethernet





Kamera: Allied Vision Kamera 1800 C-240m mono C-Mount, Sony IMX392 mono 1/2.3"
 1936x1216 CMOS ,126fps, 29x29x26mm

Für die Auslegung des Systems ist es notwendig, 4 Muster pro Spektralkanal zu generieren, also in Summe 16 Muster. Zwei Varianten der Auslegung wurden untersucht (siehe Zwischenbericht) und eine final für das Projekt ausgewählt:

• Schema des optischen Designs (s. Abbildung 54): jeweils 2 x 2 verschieden einfarbige LEDs inkl. jeweiliger MLA-Kollimationslinse bilden eine Untereinheit. Um die 4 spektralen Kanäle umzusetzen, wird die Untereinheit mit den LEDs und MLA-Kollimatoren viermal ausgeführt und über Dichroiten überlagert. Das kollimierte Licht wird über einen Wabenkondensor homogenisiert und gemischt. Die für die Beleuchtung des jeweiligen Musters notwendige Asphäre muss noch nicht achromatisch ausgeführt sein, da eine (aufgrund der Farbfehler) leicht unscharf abgebildete homogene Lichtverteilung homogen bleibt. Im Zwischenbild ist jeweils eines der 4 Streifenmuster positioniert, welches über ein kommerziell verfügbares Hasting-Triplet nach unendlich abgebildet wird. Eine weitere achromatische Linse (Brennweite 150 mm) bildet dann das Bild über einen Umlenkspiegel auf die Hautoberfläche ab.

Ein Vorteil dieses Systems ist, dass dieselben Muster für alle Spektralkanäle genutzt werden können. Außerdem kann so erreicht werden, dass zwischen Mustern und Spektralkanälen gewechselt werden kann, indem einzelne LEDs an und aus geschaltet werden. Dadurch gibt es keine bewegten Teile oder aufwendige Elektronik wie DMDs im Aufbau und die Komplexität wird reduziert. Außerdem ist der Aufbau modular in dem Sinne, dass man leicht LEDs austauschen kann für andere Spektralkanäle, falls diese für spezifische Anwendungen besser geeignet sind. Die Muster können ebenfalls leicht getauscht werden, falls man mit anderen Ortsfrequenzen arbeiten will. Die eingesetzten Muster im KOMPASSmobile-System sollten aufgrund des Optikdesigns Transmissionsmuster sein. In der Anwendung ist es schwierig und teuer passende Transmissionsmuster zu finden. Traditionell werden bei der Ortsfrequenzmessung sinusförmige Muster verwendet. Die Qualität der Graustufen in Transmission solcher Muster ist schwer zu gewährleisten. Deswegen wurden im gewählten Aufbau Binärmuster verwendet. Die Verwendung von Binärmustern kann Vorteile bringen. Mehrere Ortsfrequenzen können aus einer Messung in Form von höheren Harmonischen extrahiert werden. Dieser Schritt konnte allerdings nicht getestet werden.

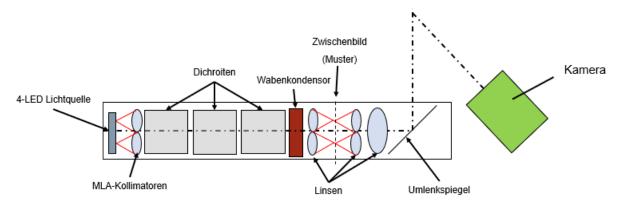


Abbildung 54: Schema des optischen Designs für die Belichtungsoptik des KOMPASSmobile-Systems.





## 2.6.3 AP6.3 - Neue Hardware für Mobilgeräte basiertes System (Mechanik des Gesamtsystems & der Optik) (HS-S, ILM)

Das Design des Systems ist in Abbildung 55 dargestellt. Für das in 2.6.2 beschriebene Design mussten noch einige Komponenten gefertigt werden. Die LED-Lichtquellen beruhen auf demselben Aufbau wie die Lichtquellen im KOMPASSpro-System. Die LED-Platinen wurden auf ein 2x2 Muster angepasst und vier Stück gefertigt. Die Halterungen für die Dichroiten und MLA-Kollimatoren wurden dabei mithilfe eines 3D-Druckers gefertigt, genauso wie die Halterungen für die Kamera und die Wabenkondensoren. Die Wabenkondensoren wurden baugleich zu den bereits gefertigten Wabenkondensoren für das KOMPASSpro-System gewählt. Für die Wabenkondensoren wurde eine eigene Halterung entwickelt, um die Justage zu ermöglichen. Ursprünglich war geplant, dass die Linsen zur Generierung des Zwischenbildes als Asphären modelliert werden. Es war vorgesehen, dass diese Asphären von Hahn-Schickard Stuttgart gefertigt werden. Aus Zeit- und Machbarkeitsgründen wurden diese Sonderfertigung aber durch kommerziell verfügbare Komponenten ersetzt.

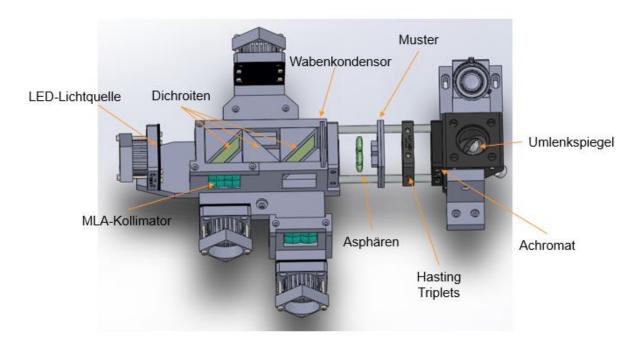


Abbildung 55: CAD-Modell der Belichtungseinheit mit Kamera für das KOMPASSmobile-System.

# 2.6.4 AP6.4 - Fertigung und Assemblierung der Optik-Komponenten des KOMPASSmobile-Systems (HS-S)

Parallel zur Entwicklung des Optikkonzepts wurden von HS-S Versuche zur Nanoprägelithographie von optischen Strukturen auf einer Häcker- Ultrapräzisionsbestückungsanlage durchgeführt. Dafür wurde ein entsprechendes Werkzeug gefertigt, welches sich unter kontrollierten Druck- und Temperaturbedingungen in ein Werkstück eintauchen lässt. Als Werkstück kommen grundsätzlich Kunststoffbauteile oder Lacksysteme in Frage. Diese können zur besseren Bearbeitung auch auf einer dafür vorgesehenen Heizplatte gelagert werden. Zusätzlich kann ein LED-UV-Ring zur späteren Aushärtung von Fotolackstrukturen genutzt werden. Das Tool kann über einen Weg von 500 µm in Z-Achse verfahren werden mit einem Pitch von 10 µm zwischen den einzelnen Strukturen.





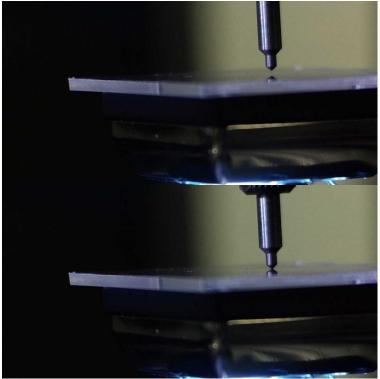
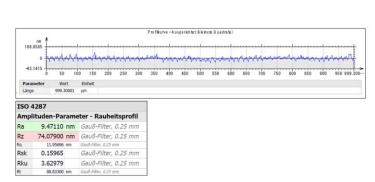


Abbildung 56: Stempel-Werkzeug fährt in die Oberfläche des Werkstücks

Nach der Einrichtung des Programms wurden in Abstimmung mit dem ILM Substrate gefertigt, welche mittels zwei Photonenlithographie strukturiert werden sollen, um diese im Anschluss als Stempel für die Prägelithographie zu nutzen.

Am ILM wurden an den von HS-S zur Verfügung gestellten Aluminiumsubstraten Druckversuche zur Parameterfindung bzw. Prozessoptimierung durchgeführt. Diese dienen der Eignungsprüfung von Aluminium als Substratmaterial für die zur Nanoprägelithographie notwendigen Stempel. Nachdem erste Druckversuche auf gewalzte Aluminiumoberflächen keine reproduzierbaren Ergebnisse erbrachten, wurden die Oberflächen am ILM stufenweise mit immer kleinerer Korngröße poliert (bis zu  $6,4~\mu m$ ). Es zeigte sich, dass eine möglichst glatte Oberfläche für ein zufriedenstellendes Druckergebnis erforderlich ist.









#### Abbildung 57: Stempel-Werkzeug fährt in die Oberfläche des Werkstücks

Daraufhin wurden von HS-S verbesserte Aluminiumsubstrate hergestellt, wobei die zu bedruckenden Oberflächen mittels Fly-Cutting bearbeitet wurden, um eine optische Oberfläche zu schaffen. Auf der Rückseite der Platten wurden Gewinde eingelassen, um die Platten sowohl in der 2-Photonenlithographie-Anlage, als auch nachfolgend in der Bestückungsanlage zu lagern. Die Oberflächenrauheit der Substrate konnte auf Ra< 10 nm reduziert werden, um eine saubere Anhaftung der gedruckten Bauteile zu ermöglichen. Unebenheiten und Verschmutzungen hätten zur Folge, dass keine Haftung zwischen gedrucktem Bauteil und Substrat hergestellt werden könnte. Ein Ablösen bei dem nachfolgenden Stempel-Prozess soll durch eine entsprechend starke Anhaftung verhindert werden.

Zum Bedrucken dieser Substrate wurde folgender Workflow erarbeitet und bei den Druckversuchen angewandt:

- Schutzlack von Aluminiumsubstraten mit Pflaster abgezogen (Auflösen im Acetonbad sehr/zu langwierig)
- Standardreinigung mit Isopropanol und Aceton
- Aluminium substrate auf Standard-ITO-Substraten mit IP-S fixiert und polymerisiert
- Plasmaaktivierung
- Bedrucken mittels 2-Photonenlithographie (MFS, 25x, IP-S)
- Standardentwicklungsprozedur (PGMEA + IPA)
- Mechanische Ablösung des Alusubstrates vom ITO-Träger

Nach einer sorgfältigen Charakterisierung der Oberflächenbeschaffenheit u. a. mit dem Lichtmikroskop (s. Abbildung 58, links) wurden die eigentlichen Druckversuche durchgeführt. Die größte Herausforderung stellte dabei die axiale Positionierung der spiegelnden Aluminiumoberfläche dar, da der automatische Interfacefinder nicht funktionierte. Ein Druckstart bei visuell scharf gestellter Probenebene führt zu einem Ablösen bzw. Wegschwimmen des Drucks. Letztendlich ist eine Positionierung der Druckebene ca. 16 µm in die Probe notwendig, im Vergleich zur visuell scharf gestellten Probe. Ursachen hierfür kann laut Aussage vom Hersteller Nanoscribe das Ausbilden einer stehenden Welle an der spiegelnden Oberfläche und dadurch entstehender Inhomogenitäten in axialer Richtung sein.







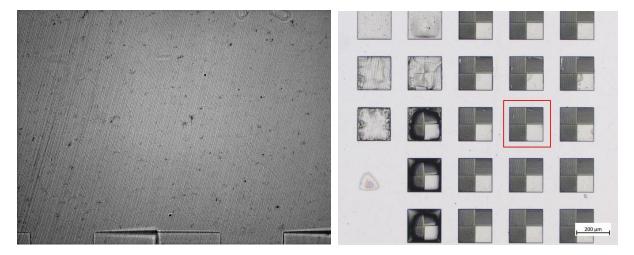


Abbildung 58: Links: Lichtmikroskopische Aufnahme (Vergrößerung 25x) der Aluminiumoberfläche; deutlich erkennbar als Längsriefen sind die cutter marks (Orientierung der Riefen ist ortsabhängig). Rechts: Verschiedene Druckversuche von Rampen und Ebenen unter Variation der Druckparameter BaseLaserPower und SolidLaserPower (rot markiert ist das Optimum).

Da ein manuelles Scharfstellen gerade bei mehreren auf ein Substrat zu druckenden Strukturen nicht optimal erscheint, wurde mit Unterstützung des Herstellers die Konfiguration des automatischen Interfacefinders so angepasst, dass dieser zumindest mit eingeschränkter Präzision  $\pm 5~\mu m$  die axiale Position für den Druckbeginn bestimmen und anfahren kann. Die Präzision zeigt zudem eine gewisse Ortsabhängigkeit.

Neben den bereits erzielten Ergebnissen, welche an Hahn-Schickard Stuttgart übergeben wurden, sollen die Strukturen zusätzlich auf Silizium erzeugt werden und im Anschluss von HS-S galvanisch in Nickel abgeformt werden, um einen alternativen Stempel für die Prägelithographie zu schaffen. Derzeitig werden die bereits verschickten Stempel von Hahn-Schickard mit Gold beschichtet, während parallel ein Prozess zum Auftragen von Lackschichten mittels Spincoating eingerichtet wurde. Die Goldbeschichtung ist wenige Nanometer dick und dient zum einen als zusätzliche Haftvermittlung zwischen gedrucktem Bauteil und Aluminium-Substrat, zum anderen als Antihaftbeschichtung zwischen Stempel und Fotolack.

Die Ergebnisse der Druckversuche sind nachfolgend zusammengefasst:

- Bedrucken von Aluminiumsubstraten (Oberflächenbearbeitung: fly-cut) ist grundsätzlich möglich (25x Objektiv, Material: IP-S); s. Abbildung 58, rechts
- Interface Finder nur eingeschränkt funktionstüchtig
  - In jedem Fall ist ein höherer Sockel notwendig (doppelte Höhe: ≥ 30 μm, strukturgrößenabhängig)
- Mögliche Ursachen der ortsabhängigen Variation des Interfacefinders (NanoScribe-Support)
  - Intensitätsmodulation durch cutter marks
  - Wechselnde Ausrichtung der cutter marks
- Höherer Aufwand beim Drucken, da Prüfung erforderlich, ob Interface Finder im gesamten Druckfeld zuverlässig funktioniert

Nach Übertrag der Strukturen in die Präzisionsbestückungsanlage wurde jedoch das sofortige Ablösen der gedruckten Strukturen beobachtet, wenn die Strukturen in Lackschichten transferiert werden





sollten. Ein Übertrag war unabhängig von Anpressdruck und Temperatur der Lackschicht nicht möglich, da die gedruckten Strukturen von der Aluminiumoberfläche gelöst wurden. Auf Grund der fortgeschrittenen Projektlaufzeit wurde entschieden mit konventionellen Linsen weiterzuarbeiten, um den Demonstratoraufbau nicht zu verzögern. Das Arbeitspaket konnte daher nur bedingt abgeschlossen werden.

Für Folgeprojekte müssten folgende Schritte zur Ermöglichung der Strukturierungstechnik durchgeführt werden:

- Erarbeitung von Beschichtungssystemen, die:
  - o die Haftung zwischen Stempel und Lacksubstrat verringern
  - o die Haftung zwischen gedruckter Struktur und dem zu bedruckenden Aluminium-Stempel erhöhen

Als Anti-Haftbeschichtung bietet sich in vielen Fällen eine Silanisierung an, diese beschränkt sich jedoch meistens auf Siliziumschichten und konnte daher nicht auf die Aluminiumstempel übertragen werden. Eine weitere Möglichkeit ist der Auftrag von Antihaftbeschichtungen auf bereits bedruckte Stempel. Hierzu bietet sich zum Beispiel eine Beschichtung mit dotiertem DLC (Diamond Like Carbon) an. Hierbei ist jedoch der zusätzliche Schichtauftrag von ca. 2-5 µm zu beachten, welcher die optischen Strukturen in ihrer Geometrie beeinträchtigt. Abschließend konnte die direkte Nutzung von gedruckten Stempelstrukturen für das vorgesehene Nanoprägeverfahren nicht gezeigt werden und bedarf erheblicher Mehraufwände, um einen prozesssicheren Ablauf zu ermöglichen.

# 2.6.5 AP6.5 - Entwicklung einer Schnittstellenelektronik zw. Optikeinheit und mobilem Endgerät und Systemintegration (HS-VS)

Eine der Anforderungen an das KOMPASSmobile-System ist die Möglichkeit der lokalen Ausführung Klbasierter Funktionen Dies erfordert den Einsatz des NVIDIA Jetson Nano. Um die Funktionssicherheit des medizinischen Systems zu erhöhen, wird nur eine funktionale Steuereinheit verwendet, die umprogrammiert werden kann. Alle anderen Komponenten des Systems (Kameramodul, Digital-Analog-Wandler) wurden mit einer festen Funktionslogik entwickelt und produziert. Ein funktionaler Algorithmusfehler: Kamerasteuerung, unangemessene LED-Funktionalität - kann nur von der NVIDIA Jetson Nano Recheneinheit ausgehen.

Der NVIDIA Jetson Nano verfügt nicht über einen steuerbaren analogen Ausgang. Um die Helligkeit von 16 unabhängigen LEDs zu steuern, wird ein LED-DC-Driver mit analogem Steuereingang in Kombination mit einem Digital-Analog-Wandler (DAC) mit Serial Peripherial Interface (SPI) verwendet. Das Alvium Kameramodul kommuniziert mit dem NVIDIA Jetson Nano über die CSI-Schnittstelle. Eine zusätzliche I2C-Schnittstelle ist für die Licht emittierenden Platinen vorgesehen, um die Temperatur der LED zu überwachen und zusätzliche Sicherheit zu bieten.





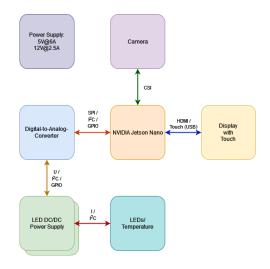


Abbildung 59: System Architektur

Das System bietet zwei Stromversorgungsbereiche - 5 und 12 Volt Schienen. Die 5-Volt-Schiene versorgt die NVIDIA Jetson Nano Prozessoreinheit, das Alvium-Kameramodul und den Digital-Analog-Wandler. Die 12-V-Schiene versorgt den LED-DC-DC-Treiber und das 14-Zoll-LCD-Modul mit Touchscreen-Funktionen. Verschiedene Stromversorgungen werden mit DC-DC-Wandlern mit breitem Eingangsspannungsbereich hergestellt, die es ermöglichen, verschiedene Stromversorgungsquellen ohne zusätzliche Stromumwandlung zu nutzen: USB Power Delivery, PoE oder DC-Stromversorgung.

Der Entwurf der Hardware der Verarbeitungseinheit und die Optimierung des optischen Systems erfolgten gleichzeitig, daher umfasste die erste Entwurfsiteration nur 3 entworfene Systemkomponentenplatinen: LED-DC-DC-Treiberplatine mit 16 Treibern, DAC- und Stromversorgungsplatinen, die gestapelt werden können (siehe Abbildung 60). Dieser Ansatz erhöht die Modularität und ermöglicht die Anpassung der einzelnen Funktionskomponenten.

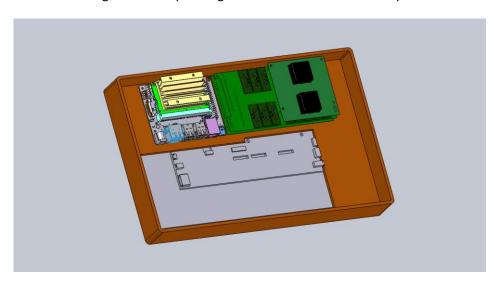


Abbildung 60: Erster Systementwurf

Um die Mobilität mit dem optimierten Design des optischen Systems zu erhalten, wurde der stapelbare Parameter des Hardware-Designs entfernt: Die Abmessungen der Platine zur Erzeugung von 16 analogen Signalen wurden reduziert, um sie direkt auf dem NVIDIA Jetson Nano stapeln und befestigen





zu können. Die LED-DC-DC-Treiber wurden in Gruppen entsprechend der Wellenlängen der LEDs aufgeteilt, was eine effizientere Raumnutzung ermöglicht.

Der NVIDIA Jetson Nano läuft mit einem Linux-Betriebssystem. Das System verwendet einen LTS-Kernel, daher begann die Softwareentwicklung des Systems mit der Anpassung des neuesten Kernel Industrial Input Output (IIO) DAC-Treibers an den von NVIDIA verwendeten LTS-Kernel. Der Entwicklungs-, Verbesserungs- und Aktualisierungsprozess des NVIDIA Jetson Nano OS ist nicht gut dokumentiert, was eine eingehende Systemanalyse und Quellcodeprüfung erforderte.

Durch die Aktualisierung des Betriebssystems haben bestimmte Funktionen des Jetson Nano zu einer nicht rückgängig zu machenden Fehlfunktion der SPI-Schnittstelle geführt: Im letzten System-Update haben die NVIDIA-Entwickler die Hardware-Beschreibung des Geräts geändert, wodurch die SPI-Schnittstelle deaktiviert wurde. Die Änderungen können nicht rückgängig gemacht werden, da die Hardwarebeschreibung von den externen Medien ins interne ROM verschoben wurde. Das ROM kann nur während der Aktualisierung des Systems geändert werden. Um die Integrität des internen ROMs zu erhalten, wurde dem Kernel eine zusätzliche Pin-Konfigurationsfunktionalität hinzugefügt - ein NVIDIA-Treiber vergleicht beim Laden des Betriebssystems die Pin-Konfiguration des Bootloaders und konfiguriert die Pins bei Bedarf neu.

Die Entwickler der Alvium-Kamerasoftware stellen den veralteten NVIDIA LTS-Kernel-Quellcode und das Skript zur Erstellung der notwendigen Debian-Pakete für den NVIDIA Jetson Nano zur Verfügung. Um die Kameraunterstützung in den neuesten Kernel einzubinden, wurden zwei Versionen (die veraltete von Alvium und die aktuelle von NVIDIA) analysiert, verglichen und die Kamerafunktionalität in den neuesten NVIDIA-Kernel-Source portiert.

IIO DAC Kernel-Modul und 2 Patches: Alliedvision-Kameratreiber und NVIDIA-Pin-Konfigurationsmodul - wurden generiert, die eine separate Verwendung von Kamera, DAC oder NVIDIA-Konfigurationsmodulen ermöglichen. Die Geräteinformationen des Systems wurden ausdrücklich nicht als Patch platziert, da das DAC- oder Kameramodul in anderen Systemen mit anderen Anschlussmöglichkeiten verwendet werden kann. Abbildung 61 zeigt den Funktionstest des nicht montierten Systems.

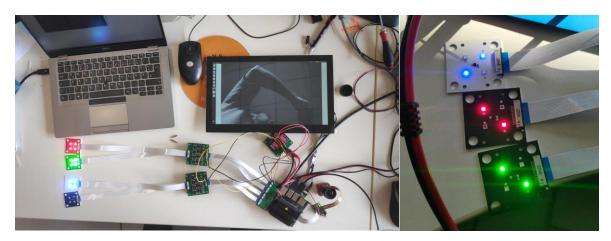


Abbildung 61: Systemfunktionstest





Aufgrund der nicht dokumentierten Eigenschaften einiger Systemteile wurden lokale Änderungen an der Hardware vorgenommen. Das zukünftige Hardware-Design sollte an die Eigenschaften angepasst werden.

## 2.6.6 AP6.6 - Entwicklung einer Software-Anwendung für das KOMPASSmobile-System (FZI)

In dem Folgeprojekt Intelligente Diagnostik 2 wurde eine plattformunabhängige, native App für das KOMPASSmobile-System entwickelt. Die App wurde unter Verwendung des Kivy-Frameworks für Python realisiert. Die Entwicklung dieser App zielt darauf ab, die Bedienbarkeit auf mobilen Endgeräten zu optimieren und das Ansteuern verschiedener Hardwarekomponenten zu ermöglichen, beispielsweise der LEDs zur multispektralen Belichtung der Haut während der Bildaufnahme. Ebenso bietet diese App die Möglichkeit, direkt das Kamerabild zu erfassen und sowohl dem Nutzer als auch der KI für die anschließende Prädiktion zur Verfügung zu stellen. Weitere Funktionen umfassen die Verwaltung und Bearbeitung der Patienten und Diagnose-Metadaten.



Abbildung 62: Exemplarisch verschiedene Ansichten der Client-Anwendung des KOMPASSmobile-Systems (von links nach rechts: Login-Screen, Ansicht der Diagnose, Änderungs-Menü der Diagnose)

Ausgehend von der webbasierten Client-Anwendung aus dem Vorgängerprojekt wurde das Design der Benutzeroberfläche grundlegend angepasst, um die Nutzerfreundlichkeit auf dem mobilen Endgerät durch eine Touch-optimierte Bedienung zu erhöhen. Die Neuanordnung der Bedienelemente zielte dabei auf eine klarere Strukturierung für eine bessere Nutzererfahrung ab.





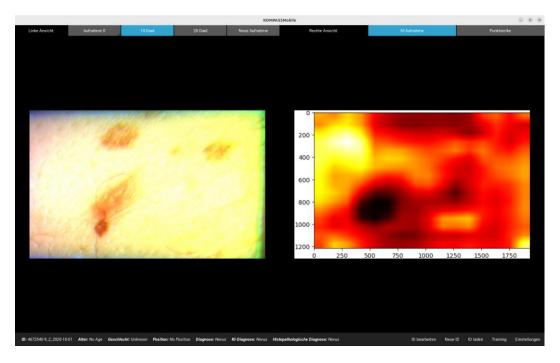


Abbildung 63: Hauptansicht der KOMPASSmobile Kivy-App

## Allgemeine Beschreibung des Aufbaus der KOMPASSmobile-Kivy-app

In Abbildung 63 ist die Hauptansicht der KOMPASSmobile-App nach dem Start und dem Öffnen einer vorhandenen Patienten-ID zu erkennen. Auf der linken Seite befinden sich die Kamera-Aufnahmen der betroffenen Hautareale. In einem Dropdown-Menü darüber kann zwischen unterschiedlichen Aufnahmen gewählt werden, falls zu einer bestimmten Patienten-ID mehrere Aufnahmen existieren. Rechts neben diesem Dropdown befinden sich zwei Buttons, um zwischen einer 14 Grad und 24 Grad Ansicht wechseln zu können, da Aufnahmen, welche mit dem Messsystem aus Intelligente Diagnostik durchgeführt wurden, Bilder aus diesen beiden Winkeln enthalten. Neue Aufnahmen können erstellt werden durch einen Klick auf den entsprechenden Button in der oberen Leiste.

Auf der rechten Seite der Anwendung befindet sich die Heatmap einer Aufnahme, welche durch die KI generiert wird und Bereiche mit hoher Relevanz für die KI-Prädiktion anzeigt. Durch das Klicken des Buttons ganz rechts oben kann schließlich die zugehörigen Punktwolke geladen und angezeigt werden. Die Punktewolke stellt eine zusätzliche 3D-Visualisierung der Hautoberfläche dar und kann dem Nutzer weitere, möglicherweise entscheidende Informationen liefern (siehe Abbildung 64). Die Punktewolke ist für die 14 Grad sowie die 24 Grad Ansicht verfügbar.

Die Leiste am unteren Rand der Anwendung liefert die wesentlichen Informationen zum Patienten und zur Aufnahme, dazu zählt das Alter des Patienten, das Geschlecht, die Position der Aufnahme und die Diagnosen, sowie das Ergebnis der KI-Prädiktion. Auf der rechten Seite der unteren Leiste befinden sich des Weiteren Schaltflächen zum Laden einer Aufnahme aus der Datenbank, zum Bearbeiten des aktuell geladenen Eintrags und zum Erstellen eines neuen Eintrags (einer neuen ID). Ebenso kann ein Menü geöffnet werden, um neue Trainingsvorgänge durchzuführen und vorhandene KI-Modelle zu verwalten. Schließlich können über einen weiteren Button App-Einstellungen vorgenommen werden, beispielsweise die Auswahl der Sprache. Aktuell steht die App sowohl auf Deutsch, als auch auf Englisch zur Verfügung.







Abbildung 64: Darstellung einer 3D-Punktwolke innerhalb der App

#### Bearbeiten, Laden und Anlegen von IDs

Zu den grundlegenden Funktionen, die die Applikation bereitstellt, gehören das Bearbeiten vorhandener IDs, das Laden und Anzeigen von IDs aus der Datenbank, sowie das Erstellen von neuen IDs. Unter ID wird hierbei ein Eintrag bzw. Fall in der lokalen Managementplattform und somit die Kombination aus einer Aufnahme und der zugehörigen Metadaten verstanden. Für jede dieser Funktionen existiert in der Anwendung ein eigenes Popup-Menü, diese sind in Abbildung 65 dargestellt. Beim Anlegen neuer IDs und dem Bearbeiten vorhandener IDs können alle verfügbaren Metadaten auf einfache Art und Weise über die grafische Benutzeroberfläche geändert werden. Hierbei wurde Wert daraufgelegt, dass die Bedienung auch über den Touch-Bildschirm bequem möglich ist. So wurde beispielsweise auf Freitexteingaben weitgehend verzichtet und diese durch Buttons ersetzt, welche bei Touch-Eingaben weitaus bedienungsfreundlicher sind. Beim Erstellen einer neuen ID wird ein eindeutiger Key erzeugt und direkt im Texteingabefeld angezeigt, sodass ebenso hier auch auf eine Texteingabe durch den Nutzer verzichtet werden kann. Beim Laden vorhandener IDs aus der Datenbank kann der Nutzer diese aus einer Liste auswählen.

Bei den hier dargestellten Funktionen ist erwähnenswert, dass hierbei Datenbank-Operationen auf der dahinterliegenden lokalen Managementplattform ausgeführt werden, da die Patientendaten in der Datenbank verwaltet werden und nicht in der Kivy-App auf dem mobilen Endgerät gespeichert sind. Daher ist eine Verbindung zum lokalen Managementsystem eine Grundvoraussetzung.







Abbildung 65: Die Applikation ermöglicht sowohl das Bearbeiten vorhandener IDs (Screenshot oben links), das Laden von IDs aus der Datenbank (Screenshot oben rechts), als auch das Erstellen neuer IDs (Screenshot unten)

## Durchführen von Aufnahmen

Eine weitere Grundfunktionalität der entwickelten Kivy-App ist das Durchführen und Hochladen von neuen Aufnahmen. Vorteil der nativen Client-Anwendung im Vergleich zur webbasierten Anwendung aus Intelligente Diagnostik ist die direkte Integration von Hardware-Schnittstellen in die App. Hierzu zählt sowohl das Ansteuern der LED-Treiber als auch das Auslesen der Kamera-Bilder. Sobald eine neue Aufnahme vom Nutzer gestartet wird, schaltet die Applikation nacheinander alle 16 LEDs einzeln durch und nimmt pro LED automatisch ein Bild auf. Das Ansteuern aller LEDs erfolgt dabei zeitlich versetzt, so dass genügend Zeit für die Bildaufnahme durch die Kamera bleibt. Das Durchschalten aller LEDs ist hierbei optisch für den Nutzer gut nachvollziehbar. Nachdem alle 16 Aufnahmen getätigt wurden, kann der Anwender sich diese zunächst anschauen und überprüfen. Durch einen Klick auf die Schaltfläche Hochladen werden die Aufnahmen aufbereitet und an das lokale Managementsystem für eine Kl-Analyse übertragen. Der gesamte Aufnahme- und Prädiktionsprozess erfolgt automatisiert.





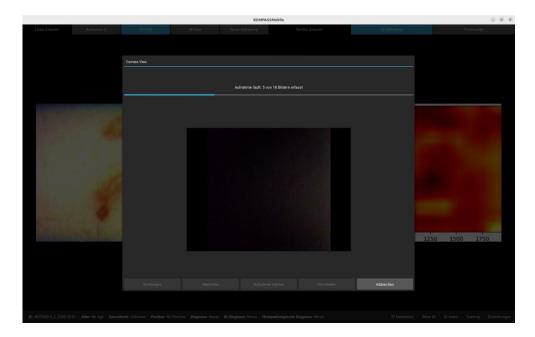


Abbildung 66: Bildaufnahme in der KOMPASSmobile Kivy-App

# 2.7 AP7 - Evaluation des KOMPASSmobile-Systems (FZI, ILM)

# 2.7.1 AP7.1 - Integration und Zusammenführung aller Komponenten

Die Integration und Zusammenführung aller im Projekt Intelligente Diagnostik 2 entwickelten Komponenten ist in mehrere Arbeitsschritte unterteilt. Insbesondere mussten die angepassten KI-Modelle und -Algorithmen aus AP4 (siehe Abschnitt 2.4) in die in AP5 entwickelte globale Federated Learning Plattform (siehe Abschnitt 2.5) eingebunden sowie die Optik, Elektronik und Software des KOMPASSmobile-Systems (siehe Abschnitt 2.6) zu einem Demonstrator kombiniert werden. Auch die Anbindung des KOMPASSmobile-Systems an die Federated Learning Plattform wurde im Rahmen dieses Arbeitspakets umgesetzt.

Die Einbindung der KI-Modelle und -Algorithmen aus AP4 in die entwickelte globale Federated Learning Plattform aus AP5 erfolgte analog zur Einbindung der KI-Funktionalität im Projekt Intelligente Diagnostik. Für die lokale Managementplattform existierte bereits ein separater Docker-Container für die KI-Funktionalität, welcher mit dem lokalen Managementsystem über eine REST-API kommuniziert. Die KI-Skripte in diesem Container wurden durch die neuen Skripte für die Federated Learning Funktionalität ergänzt und auch die Schnittstelle zum lokalen Managementsystem wurde entsprechend erweitertet (detailliertere Beschreibung in Abschnitt 2.5). Wie in Abschnitt 2.5 beschrieben, wurde auch für die globale Federated Learning Plattform ein separater Docker-Container für die KI-Funktionalität erstellt. Dieses Vorgehen ermöglichte, nach der Spezifizierung der notwendigen Schnittstelle, eine weitestgehend unabhängige Konzeption und Implementierung der globalen Federated Learning Plattform sowie der KI-Funktionalität. Die spätere konkrete Implementierung der Endpunkte und insbesondere die Umsetzung der Methodenaufrufe der KI-Skripte erfolgte in Zusammenarbeit zwischen dem FZI und HS-VS. Während dieser Arbeiten wurden konkrete Funktionen in der lokalen Managementplattform, der globalen Federated Learning Plattform





sowie den KI-Skripten leicht angepasst und verbessert, sodass die im Rahmen von AP 5.1 konzipierten Prozesse (siehe Abschnitt 2.5.1) erfolgreich umgesetzt werden konnten (siehe Abschnitt 2.7.3).

Die Zusammenführung der lokalen Managementplattform und der globalen Federated Learning Plattform wurde exemplarisch über Docker-Netzwerke umgesetzt und in Abschnitt 2.5 zum Arbeitspaket 5 thematisiert. Die Federated Learning Vorgänge erfordern neben der Kommunikation zwischen lokalen und globalen Managementsystem zudem einen Informationsaustausch zwischen lokalen und globalen KI-Container. Hierzu mussten die Docker-Netzwerke leicht um zusätzliche Port-Freigaben angepasst werden. Zum Testen der Kommunikation zwischen den lokalen Managementplattformen und der globalen Federated Learning Plattform wurde von HS-VS eine dedizierte Test-Funktionalität im KI-Skript zur Verfügung gestellt. Der sogenannte Kommunikationstest ermöglicht das Durchlaufen der Schnittstellenaufrufe eines Federated Learning Prozesses, ohne dabei ein konkretes Training durchzuführen und die Modell-Dateien anzupassen. Hierdurch konnte die Erreichbarkeit der Komponenten untereinander im Demonstrator (siehe Abschnitt 2.7.3) sichergestellt werden.

Der Aufbau des KOMPASSmobile-Systems wurde am ILM mit Kollegen vom FZI und Hahn Schickard durchgeführt. Für den Aufbau wurde eine Halterung gefertigt, auf der die Komponenten befestigt werden können. Zudem wurden Griffe vorgesehen, um die Handhabbarkeit das Geräts zu steigern und dieses tragbar zu machen. Der komplette Aufbau ist in Abbildung 67 zu sehen. Die gezeigte Rückseite des Geräts umfasst die Belichtungsoptik, Elektronik, Kamera sowie den Jetson Nano. Dabei wurden die Kamera und die Belichtungsoptik präzise ausgerichtet, um eine optimale Qualität für die Bildverarbeitung zu gewährleisten. Der Jetson Nano fungiert dabei als Recheneinheit und ist sowohl verantwortlich für die Ausführung der grafischen Client-Anwendung zur Interaktion mit dem Nutzer als auch für die Ansteuerung der dargestellten Hardware-Komponenten. Für die Kommunikation und Datenübertragung dienen entsprechende Kabel, wobei überwiegend flexible Flachbandkabel zum Einsatz kamen. Die Vorderseite des Geräts, dargestellt in der unteren Hälfte von Abbildung 67, zeigt den eingebetteten Touchscreen, welcher eine Benutzerschnittstelle zur Interaktion mit dem KOMPASSmobile-System bietet. Dieser Bildschirm dient insbesondere zur Eingabe von Befehlen per Touch sowie zur Überwachung des Systems durch den Benutzer und ermöglicht eine intuitive Bedienung.





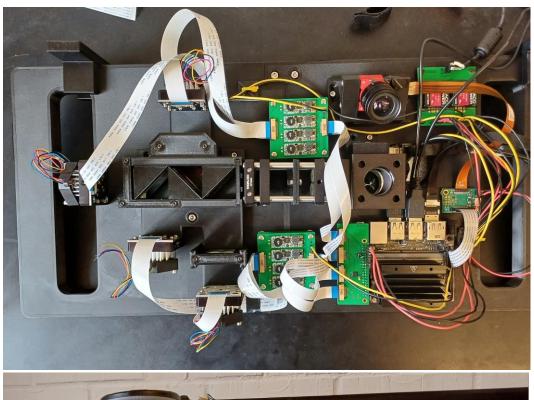




Abbildung 67: Fertig aufgebautes KOMPASSmobile System. Oben: Rückseite des Gerätes mit Belichtungsoptik, Elektronik, Kamera und Jetson Nano. Unten: Vorderseite des Gerätes mit Touchscreen.

Die Anbindung des KOMPASSmobile Systems an die globale Federated Learning Plattform erfolgte über die Implementierung entsprechender Schnittstellen-Aufrufe. Das KOMPASSmobile System kommuniziert primär mit der vom lokalen Managementsystem bereitgestellten Schnittstelle. Die Anbindung des KOMPASSmobile Systems an das lokale Managementsystem unterscheidet sich in einem Punkt von der Anbindung des webbasierten Clients aus Intelligente Diagnostik an das lokale Managementsystem. Beim KOMPASSmobile-System erfolgt die Übertragung der Aufnahme-Dateien direkt an das Backend, ohne Umweg über das Filesystem. Hierzu wurde ein entsprechender neuer Endpunkt im lokalen Managementsystem zur Verfügung gestellt. Die weiteren Anfragen, wie die Abfrage von KI-Ergebnissen oder das Speichern von Diagnosen, erfolgen wie bereits für den





webbasierten Client umgesetzt, in Form von entsprechenden Aufrufen der Endpunkte des lokalen Managementsystems.

Die Integration beziehungsweise Anbindung weiterer KOMPASSmobile-Systeme ist durch die Anpassung der Netzwerkadresse des lokalen Managementsystems im Code der Kivy-Anwendung des entsprechenden Demonstrators möglich. An einer lokalen Managementplattform können gleichzeitig mehrere Systeme angebunden sein. Zum Hinzufügen einer weiteren lokalen Managementplattform zum gesamten Federated Learning System, beispielsweise falls eine weitere Klinik angebunden werden soll, ist ebenfalls nur ein Arbeitsschritt notwendig. In dem globalen Management User Interface ist hierzu im Bereich Clients lediglich die Netzwerkadresse des lokalen Managementsystems und eine eindeutige Bezeichnung einzutragen, wie in Abschnitt 2.5.4 in Abbildung 49 dargestellt. Sobald dies erfolgt ist, wird auch die neu hinzugefügte Managementplattform bei zukünftigen Federated Learning Vorgängen hinzugezogen.

### 2.7.2 AP7.2 - Validierung des Messkopfes des KOMPASSmobile-Systems

Die Validierung konnte nicht durchgeführt werden. Der Aufbau und Stand des Messgerätes am Ende des Projektes war nicht ausreichend, um einen quantitativen Vergleich des Messsystems mit den Messungen am KOMPASSpro-System oder dem Messgerät aus Intelligente Diagnostik 1 zu machen. Qualitativ konnte ein Gerät gebaut werden, dass die Projektion von Streifenmustern mit 3 Phasen und 4 Spektralbereichen ermöglicht. Dieser Demonstrator wurde im Rahmen der Abschlussveranstaltung erfolgreich vorgestellt.

# 2.7.3 AP7.3 - Durchführung von Feld-Tests und Auswertung der KI-basierten Diagnose

Zur Evaluierung der Software-Komponenten und insbesondere des Zusammenspiels zwischen KOMPASSmobile-System sowie der lokalen Management- und globalen Federated Learning Plattform, wurde ein exemplarischer Testaufbau umgesetzt. Der Testaufbau wurde am FZI realisiert und umfasste 3 separate Maschinen, welche über ein Netzwerk miteinander verbunden waren. Auf einer Maschine wurde die Container-Umgebung der globalen Federated Learning Plattform betrieben, die beiden anderen Maschinen stellten jeweils eine lokale Management Plattform bereit. Das KOMPASSmobile-System wurde zudem als Client an einer der beiden lokalen Management Plattformen angebunden.

Zum einfachen Testen der neuen Federated Learning Funktionalität wurde von HS-VS die Möglichkeit implementiert Kommunikationstests auszuführen – dies ermöglicht das Testen der gesamten Federated Learning Funktionalität ohne eine Ausführung des konkreten Trainings der Modelle. Die Tests führen lediglich die Kommunikation während des Federated Learning Vorgangs aus und konnten erfolgreich in das globale sowie lokale System integriert werden. Mit Hilfe dieser Kommunikationstests konnten die regelmäßigen Trainingsstarts und somit die Funktionsfähigkeit der Timer im globalen Managementsystem (siehe Abschnitt 2.5.2) sowie die Kommunikation mit den lokalen Managementplattformen erfolgreich getestet werden. Das konkrete Federated Learning konnte ebenfalls inklusive des Authentifizierungsverfahrens (siehe Abschnitt 2.4.2) erfolgreich im Testaufbau durchgeführt werden. Hierzu wurden exemplarisch in den beiden lokalen Managementplattformen vereinzelte Trainingsdaten hinzugefügt und in der globalen Federated Learning Plattform die Trainingsvorgänge ausgelöst. Der Federated Learning Prozess wurde entsprechend ausgeführt und in





beiden lokalen Managementplattformen wurde das zuvor verwendete Modell durch das neu trainierte Modell automatisch ersetzt.

Das KOMPASSmobile-System konnte nicht im Feld getestet werden. Die KI-basierte Diagnostik bezüglich der Aufnahmen des KOMPASSmobile-Systems konnte auch aufgrund von fehlenden Messdaten aus den vorhergehenden Arbeiten nicht implementiert werden.

Die Software-technische Anbindung des **KOMPASSmobile-Systems** die lokale an Managementplattform konnte hingegen erfolgreich umgesetzt werden und wurde im Rahmen dieses Arbeitspakets zunächst durch die Abfrage von zu Aufnahmen verwalteten Metadaten überprüft. Das KOMPASSmobile-System ist in der Lage zur lokalen Management Plattform hinzugefügte Aufnahmen anzuzeigen sowie zugehörige KI-Ergebnisse abzurufen. Auch die 3D-Punktwolken-Darstellung der Hautläsion konnte jeweils geladen und visualisiert werden. Die KI-Modell-Dateien werden in der lokalen Managementplattform verwaltet, sodass Änderungen an KI-Modellen durch Federated Learning Vorgänge, wie gefordert auch auf die KI-Ergebnisse, welche im KOMPASSmobile-System angezeigt werden, Auswirkung haben. Der wesentliche Unterschied im Vergleich zum webbasierten Client aus dem Projekt Intelligente Diagnostik hinsichtlich der Anbindung an das lokale Managementsystem, ist die direkte Übertragung von Aufnahmen (netCDF-Dateien) zwischen dem KOMPASSmobile und dem Managementsystem ohne Umweg über das Filesystem. Zum Testen dieser Übertragung wurde eine in der Klinik erstellte externe Aufnahme im Roh-Format auf dem KOMPASSmobile-System gespeichert und die Übertragung an das lokale Managementsystem ausgelöst. Wie im Rahmen des Treffens mit dem projektbegleitenden Ausschuss am 28. November 2023 gezeigt, konnte die Aufnahmedatei erfolgreich zwischen KOMPASSmobile-System und lokalen Managementsystem übermittelt werden und auch das nachgelagerte Post-Processing wurde automatisch ausgeführt, sodass auch zu dieser Aufnahme Informationen wie das KI-Ergebnis oder die Punktwolke abgerufen werden konnten. Die Übertragung nimmt jedoch zu viel Zeit in Anspruch, sodass im Hinblick eines praktikablen Einsatzes dieser Funktionalität noch Verbesserungen notwendig sind. Auch die zuvor erwähnten Tests bezüglich der globalen Federated Learning Plattform und der Vernetzung der lokalen Managementplattformen, wie die Ausführung der Federated Learning Vorgänge, konnten mit dem Testaufbau im Rahmen des Abschlussevents erfolgreich dem projektebegleitenden Ausschuss in Form einer Live-Demo gezeigt werden.