SACHBERICHT ZUM VERWENDUNGSNACHWEIS

Teil I: Kurzbericht

Zuwendungsempfänger:	Universität Bremen
Projektleitung:	Prof. Dr. Dr. h.c. Peter Maaß
Förderkennzeichen:	03TR07W15
Vorhaben:	T!Raum – MOIN – MUKIDerm – Multimodale KI-Verfahren zur Detektion und Klassifikation von Tumorentitäten in der Dermapathologie
Laufzeit:	01.11.2023 – 31.10.2025

1. Ziel und Inhalt des Projektes

Ziel dieses Projektes war die Entwicklung von KI-Verfahren zur Detektion und Klassifikation von zwei Tumorentitäten der Dermatologie. Diese beiden Entitäten wurden ausgewählt, da sie prototypische Szenarien darstellen, bei denen medizinische Spezialist:innen Information von verschiedenen Datenquellen, mehrere visuelle Darstellungen (u.a. H&E, IHC Färbungen) und Text, gleichzeitig verarbeiten müssen. Diese Anwendungen gelten als besonders anspruchsvoll und als besonders geeignet, um von einer KI-gestützten Auswertung zu profitieren.

2 Ablauf und Ergebnisse des Vorhabens

Alle Arbeitspakete wurden bearbeitet, wesentlich Änderungen ergaben sich nicht. Kleinere Abweichungen gab es bei AP 2.4 und AP 4.3. AP 2.4. wurde letztendlich der wissenschaftliche Schwerpunkt des Projektes und insbesondere die Fertigstellung der Publikationen benötigte mehr Zeit als ursprünglich geplant. Bei AP 4.3 war der numerische Aufwand für die End-to-End Optimierung insbesondere bedingt durch die langen Rechenzeit höher als ursprünglich erwartet. Der vermehrte Personalaufwand wurde durch die Umwandlung des ursprünglich geplanten Unterauftrags an die aisencia GmbH in Personalmittel gedeckt.

Alle Ergebnisse des Projektes wurden in wissenschaftlichen Journalen publiziert.

3 Darstellung der wesentlichen Ergebnisse und deren konkreter Nutzen sowie ggf. die Zusammenarbeit mit anderen Forschungseinrichtungen

Die Erstellung synthetischer Gewebeschnittbilder wurde erfolgreich abgeschlossen und eine passende Netzwerkarchitektur in Form eines Generative Adversarial Networks (GAN) identifiziert.

Die Ergebnisse werden beim 10th International Conference on Multimedia and Image Processing (ICMIP 2025) präsentiert.

Hierzu wurde eine interaktive Oberfläche erstellt, mit der händisch Bereiche eines Gewebeschnitts vorgegeben werden können, die dann automatisch mit den relevanten Strukturen gefüllt werden. In

dem Beispiel aus Grafik 1 wurde beispielhaft ein Bereich des. Gewebeschnitts als ‚Melanom Typ Z' markiert (blau) und der Rest als gesundes Gewebe vorgegeben.

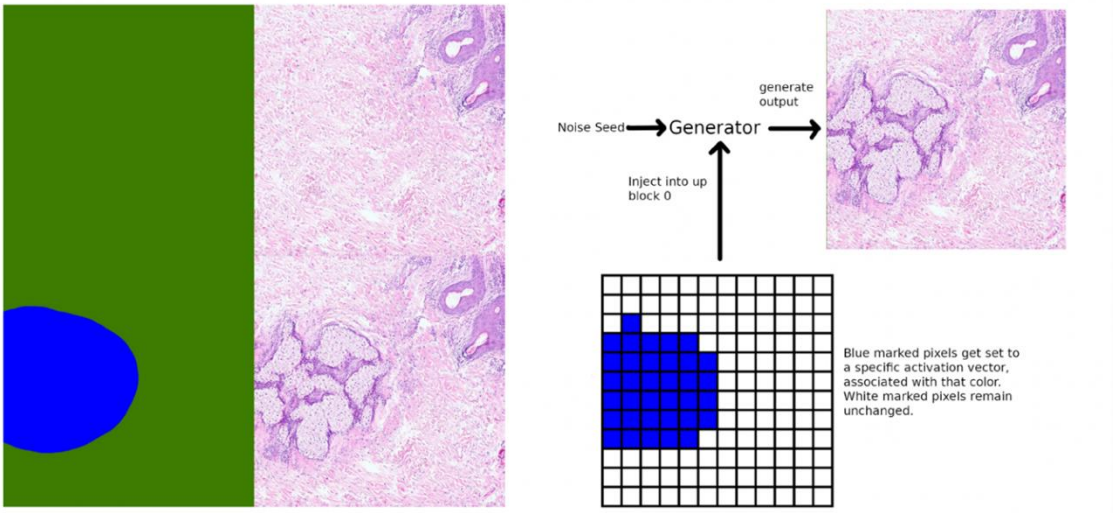

Grafik 1: Händische Erzeugung von Trainingsdaten mit vorgegebenen kritischen Bereichen, blau wurde mit ‚Melanom Typ Z' markiert, grün als gesundes Gewebe. Rechts oben ist das so generierte künstliche histologische Bild dargestellt.

Die Visualisierung von Zwischenaktivierungen eines Segmentierungs-Netzwerks, welches auf dermatopathologischen Daten trainiert wurde, konnte erfolgreich umgesetzt werden.

Die Ergebnisse für die Visualisierung wurden unter dem Titel "Explaining a Deep U-Net Trained for Tumor Detection in Histological Whole Slide Images" als Poster Präsentation beim 20th European Congress on Digital Pathology (ECDP) 2024, sowie unter "Visualize and Paint GAN Activations". beim IEEE 34th International Workshop on Machine Learning for Signal Processing (MLSP) im Jahr 2024 präsentiert und als Konferenzbeitrag publiziert.

Darauf aufbauend können dann die Strukturen, die vom KI-Modell zur Klassifizierung verwendet werden, visualisiert werden.

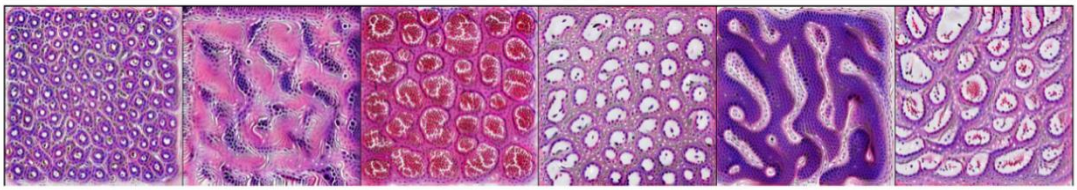

Grafik 4: Visualisierung KI-relevanter Strukturen zur Melanom-Charakterisierung

Eine umfangreiche Evaluation der Ergebnisse der bisher durchgeführten Entwicklungen wurde anhand des Krankheitsbilds Aktinische Keratose durchgeführt. Hierzu wurde eine retrospektive Studie mit Fällen von fast 1.000 Patient:innen durchgeführt. Hierbei konnte die überarbeitete Netzarchitektur eine Genauigkeit von über 97% erzielen – im Vergleich zu 92% mit der alten Architektur.

Eine umfangreiche Publikation zu diesen Evaluationsergebnissen unter Einbeziehung zahlreicher medizinischer Experten wurde im Italian Journal of Dermatology and Venereology publiziert.

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.

SACHBERICHT ZUM VERWENDUNGSNACHWEIS

Teil II: Schlussbericht

Zuwendungsempfänger:	Universität Bremen
Projektleitung:	Prof. Dr. Dr. h.c. Peter Maaß
Förderkennzeichen:	03TR07W15
Vorhaben:	T!Raum – MOIN – MUKIDerm – Multimodale KI-Verfahren zur Detektion und Klassifikation von Tumorentitäten in der Dermapathologie
Laufzeit:	01.11.2023 – 31.10.2025

Zusammenfassung der durchgeführten Arbeiten:

Auf der wissenschaftlichen Seite wurden KI-Verfahren zur Detektion und Klassifikation von zwei Tumorentitäten der Dermatologie entwickelt. Diese beiden Entitäten wurden ausgewählt, da sie prototypische Szenarien darstellen, bei denen medizinische Spezialist:innen Information von verschiedenen Datenquellen, mehrere visuelle Darstellungen (u.a. H&E, IHC Färbungen) und Text, gleichzeitig verarbeiten müssen. Diese Anwendungen gelten als besonders anspruchsvoll und als besonders geeignet, um von einer KI-gestützten Auswertung zu profitieren.

Für beide Tumortypen waren anerkannte klinisch-medizinische Expert:innen aus der Uniklinik Essen und der Uniklinik Bonn beteiligt, die das Projekt mit ihrer Expertise sowohl bei der Auswahl der Daten als auch der Bewertung der Ergebnisse unterstützten. Für die Forschung werden keine Versuche an Menschen oder Tieren durchgeführt.

Als erstes Fallbeispiel wurde in Kooperation mit Prof. Dr. med. Jennifer Landsberg und Dr. med. Philipp Jansen (Universitätsklinikum Bonn) die Diagnose von Melanom-Metastasen in Lymphknoten ausgewählt. Diese Metastasen von Melanomen der Haut sind typischerweise in Sentinel-Lymphknoten (Schildwächter – LK) zu finden.

Als zweites Fallbeispiel aus der klinischen Forschung wurde in Zusammenarbeit mit Prof. Dr. med. Eva Hadaschik und Prof. Dr. med. Klaus Griewank, Universitätsklinikums Essen, analysiert in wie weit die Hinzunahme von Sequenzierungen dieser Hauttumore (Next Generation Sequencing - NGS) die klassische rein histologische Analyse ergänzen kann.

Diese Anwendungen erforderten mehrere technische Neuerungen, die beiden wichtigsten Ergebnisse dieses Projektes sind:

1) Die Entwicklung generativer Verfahren zur Erzeugung von histologisch adäquaten Trainingsdaten. Dies ist notwendig um die notorisch kleinen Datensätze für spezialisierte pathologische Diagnosen zu augmentieren, siehe Grafik 1. Unsere Forschungsergebnisse sind in der Publikation ‚Visualize and paint GAN activations' zusammengefasst.
2) Die Akzeptanz von KI-Verfahren hängt insbesondere im medizinischen Beriech davon ab , daß dem Nutzer die Entscheidungskriterien der KI-Modell in der jeweils fachspezifischen Frage erklärt werden. Hier haben wir Beiträge zur ‚explainable AI' publiziert, die z.B. die von der KI-

detektierten kritischen Strukturen auf Grwebeschnitten visualisieren, siehe Grafik 4 und die Publikation ‚Smooth Deep Saliency'.

Alle Verfahren wurden modular implementiert, um sie problemlos an unseren Anwendungspartner aisencia weitergeben und dort testen zu können.

		Beteiligte Partner	2023	2024				2025		
		UB	Q4	Q1	Q2	Q3	Q4	Q1	Q2	Q3
AP 1	**Med. Herausforderung und Daten-Preprocessing**									
AP 1.1	Pathologisch-diagnostische Zielgrößen	0,5								
AP 1.2	Testdat erste Entwicklungsstufe	1,5								
AP 1.3	Testdaten zweite Entwicklungsstuft	1,5								
AP 2	**Data Augmentation auf medizinischen Daten**									
AP 2.1	Vergleich generativer Netzwerkansätze	1,5								
AP 2.2	Generative Netzwerke und Segmentierung	2								
AP 2.3	Segmentierungsmasken und synthetische Daten	3								
AP 2.4	Visualisierung der Aktivierungen	1,5								
AP 3	**Skalierbare Netzwerkarchitekturen**									
AP 3.1	Adaption skalierbarer Netzwerkarchitekturen	2								
AP 3.2	Optimierung skalierbarer Netzwerke, 1. Stufe	2								
AP 3.3	Performance	1,5								
AP 3.4	Optimierung skalierbarer Netzwerke, 2. Stufe	2								
AP 4	**Konditionierte Netzwerke für multimodale Datenstrukturen**									
AP 4.1	Konditionierte Netzwerkarchitekt. für multimodale Daten	2,5								
AP 4.2	Stabilität konditionierter Netzwerkarchitekturen	2								
AP 4.3	Performance	1,5								
AP 4.4.	Optimierung konditionierter Netzwerkarchitekturen	2,5								
AP 5	**Stabil lernende KI**									
AP 5.1	Konzepte kontinuierlich lernender KI-Systeme im Labor	2,5								
AP 5.2	Performance	1,5								
AP 5.3	Implement. u. Evaluation der stabilisierten KI-Systeme	2,5								
AP 6	**Komplettes Netzwerk und Evaluation**									
AP 6.1	Definition Gesamtnetzwerk	1								
AP 6.2	End-to-end Training erste Entwicklungsstufe	2,5								
AP 6.3	End-to-end Training zweite Entwicklungsstufe	2,5								
AP 6.4	Klinisch-medizinische Evaluation	2								
						MS 1			MS 2	

Tabelle 1 Ursprünglicher Zeitplan

		Beteiligte Partner	2023	2024				2025			
		UB	Q4	Q1	Q2	Q3	Q4	Q1	Q2	Q3	Q4
AP 1	**Med. Herausforderung und Daten-Preprocessing**										
AP 1.1	Pathologisch-diagnostische Zielgrößen	0,5									
AP 1.2	Testdaten erste Entwicklungsstufe	2									
AP 1.3	Testdaten zweite Entwicklungsstuft	1,5									
AP 2	**Data Augmentation auf medizinischen Daten**										
AP 2.1	Vergleich generativer Netzwerkansätze	1,5									
AP 2.2	Generative Netzwerke und Segmentierung	2									
AP 2.3	Segmentierungsmasken und synthetische Daten	3									
AP 2.4	Visualisierung der Aktivierungen	4									
AP 3	**Skalierbare Netzwerkarchitekturen**										
AP 3.1	Adaption skalierbarer Netzwerkarchitekturen	2									
AP 3.2	Optimierung skalierbarer Netzwerke, 1. Stufe	2									
AP 3.3	Performance	1,5									
AP 3.4	Optimierung skalierbarer Netzwerke, 2. Stufe	2									
AP 4	**Konditionierte Netzwerke für multimodale Datenstrukturen**										
AP 4.1	Konditionierte Netzwerkarchitekt. für multimodale Daten	2,5									
AP 4.2	Stabilität konditionierter Netzwerkarchitekturen	2									
AP 4.3	Performance	1,5									
AP 4.4.	Optimierung konditionierter Netzwerkarchitekturen	1,5									
AP 5	**Stabil lernende KI**										
AP 5.1	Konzepte kontinuierlich lernender KI-Systeme im Labor	2,5									
AP 5.2	Performance	1,5									
AP 5.3	Implement. u. Evaluation der stabilisierten KI-Systeme	3									
AP 6	**Komplettes Netzwerk und Evaluation**										
AP 6.1	Definition Gesamtnetzwerk	1,5									
AP 6.2	End-to-end Training erste Entwicklungsstufe	2,5									
AP 6.3	End-to-end Training zweite Entwicklungsstufe	3									
AP 6.4	Klinisch-medizinische Evaluation	2									
		45,5				MS 1			MS 2		

Tabelle 2: Tatsächlicher Verlauf des Projektes: Arbeitspakete mit abweichendem Arbeitseinsatz sind farblich markiert. Abweichungen gab es insbesondere bei AP 2.4 und AP 4.3. AP 2.4. wurde letztendlich der wissenschaftliche Schwerpunkt des Projektes und insbesondere die Fertigstellung der Publikationen benötigte mehr Zeit als ursprünglich geplant. Bei AP 4.3 war der numerische Aufwand für die End-to-End Optimierung insbesondere bedingt durch die langen Rechenzeiten höher als ursprünglich erwartet. Der vermehrte Personalaufwand wurde durch die Umwandlung des ursprünglich geplanten Unterauftrags an die aisencia GmbH in Personalmittel gedeckt.

Zu den Arbeiten im Einzelnen:

Nachfolgend fassen wir die wichtigsten Ergebnisse aus den einzelnen Arbeitspaketen im Projektzeitraum zusammen:

AP1) Medizinische Herausforderungen und Daten-Processing:

- Neben den Projektpartnern aus den Unikliniken Essen & Bonn wurden auch weitere Dermatopatholog:innen, u.a. von der Uniklinik Leipzig, der Charité in Berlin, sowie aus Laboren in Hamburg, Wuppertal, Potsdam und Berlin zu den Zielgrößen befragt.
- Zudem konnte auch ein Kontakt zum renommierten Melanoma Institute in Australien aufgebaut werden.
- Für das Projekt wurden über 1.000 Objektträger mit Melanomfällen digitalisiert und erfasst.
- Aktinische Keratose – eine Vorstufe von Hautkrebs – wurde als weiteres Krankheitsbild in die Untersuchung im Rahmen des Projekts mit aufgenommen.

AP2) Data Augmentation auf medizinischen Daten:

- Die Erstellung synthetischer Gewebeschnittbilder wurde erfolgreich abgeschlossen und eine passende Netzwerkarchitektur in Form eines Generative Adversarial Networks (GAN) identifiziert. Die Ergebnisse werden beim 10th International Conference on Multimedia and Image Processing (ICMIP 2025) präsentiert.
  Hierzu wurde eine interaktive Oberfläche erstellt, mit der händisch Bereiche eines Gewebeschnitts vorgegeben werden können, die dann automatisch mit den relevanten Strukturen gefüllt werden. In dem Beispiel aus Grafik 1 wurde beispielhaft ein Bereich des. Gewebeschnitts als ‚Melanom Typ Z' markiert (blau) und der Rest als gesundes Gewebe vorgegeben.

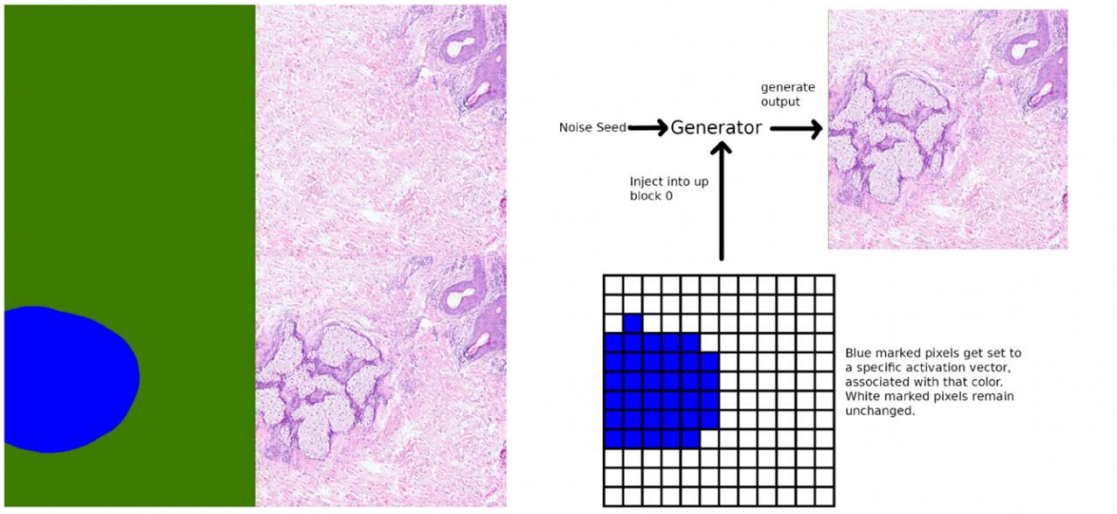

Grafik 1: Händische Erzeugung von Trainingsdaten mit vorgegebenen kritischen Bereichen, blau wurde mit ‚Melanom Typ Z' markiert, grün als gesundes Gewebe. Rechts oben ist das so generierte künstliche histologische Bild dargestellt.

- Die Visualisierung von Zwischenaktivierungen eines Segmentierungs-Netzwerks, welches auf dermatopathologischen Daten trainiert wurde, konnte erfolgreich umgesetzt werden. Die Zwischenaktivierungen wurden anschließend mit Dermatopatholog:innen diskutiert. Hierbei konnten von den Mediziner:innen Strukturen identifiziert werden, die auch in der Literatur als

wichtige diagnostische Merkmale festgehalten sind. Ein Beispiel ist das sogenannte „Palisading“, eine palisadenartige Zellaufreihung, die unter anderem bei Basalzellkarzinomen (heller Hautkrebs) zu finden ist. Die Informationen helfen somit, ein tieferes Verständnis über die Arbeitsweise des Segmentierungsnetzes zu gewinnen. Gleichzeitig wurden auch Strukturen beobachten, die bisher nicht für die Diagnostik berücksichtigt werden. Hier könnten sich in Zukunft Erweiterungen für diagnostische Leitlinien entwickeln.

- Die Ergebnisse für die Visualisierung wurden unter dem Titel “Explaining a Deep U-Net Trained for Tumor Detection in Histological Whole Slide Images” beim 20th European Congress on Digital Pathology (ECDP) 2024, sowie “Visualize and Paint GAN Activations”. beim IEEE 34th International Workshop on Machine Learning for Signal Processing (MLSP) im Jahr 2024 präsentiert und als Konferenzbeitrag publiziert.
- Unter dem Titel “Smooth Deep Saliency” ist zudem ein Beitrag bei der 10th International Conference on Multimedia and Image Processing (ICMIP) akzeptiert worden.

Unserer Ansicht nach, ist dies das zweite wesentliche wissenschaftliche Ergebnis dieses Projektes, deshalb soll auch hier etwas genauer darauf eingegangen werden:

Auch hier wird wieder eine U-Net Architektur verwendet siehe Grafik 2. Diese wird diesmal allerdings nicht zur Segmentierung, sondern als autoencoder zur Reproduktion der Eingabedaten trainiert.

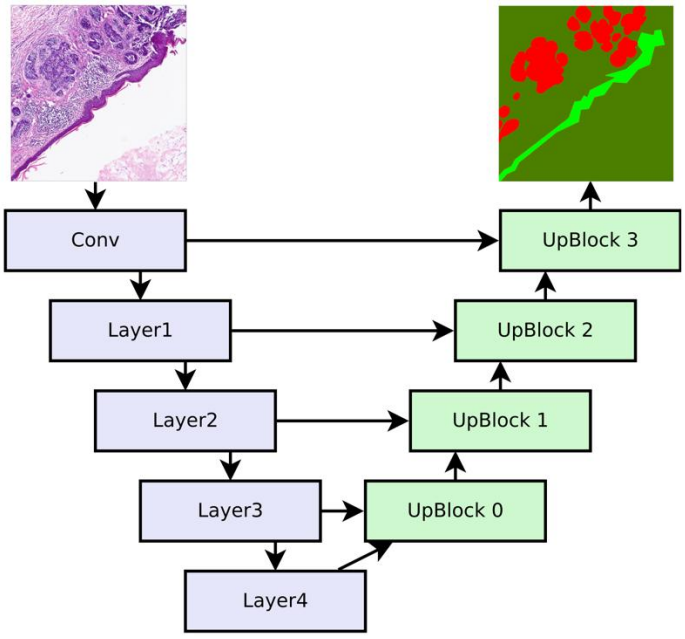

Grafik 2: U-Net Architektur zur semantischen Segmentierung

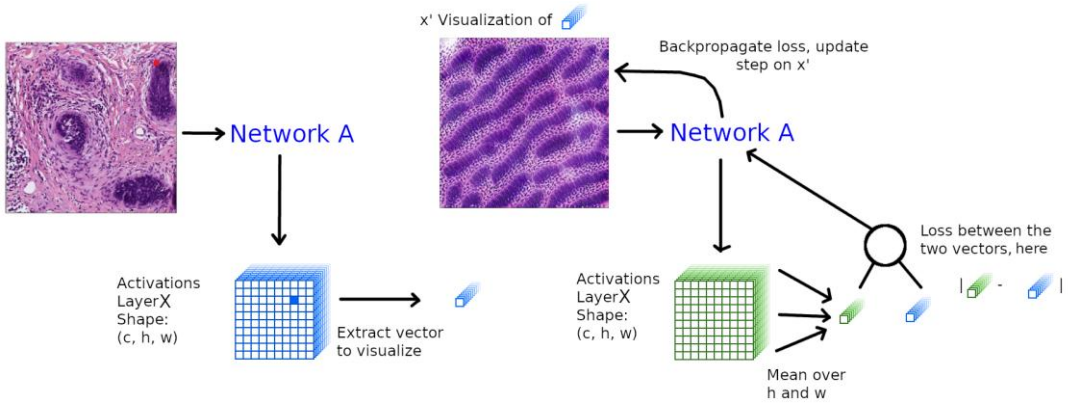

Grafik 3: Schematische Darstellung der Methodik zur Visualisierung ‚tiefer' Aktivierungen.

Wie in Grafik 3 dargestellt, werden unterschiedlichen histologischen Bereichen im Ausgangsbild einzelne Pixel in einem tiefen Layer X zugeordnet. Dies sind allerdings nicht Pixel, sondern entsprechend der Anzahl N der ‚channels' Aktivierungsvektoren der Dimension N. Wenn nun ein einzelner dieser Aktivierungsvektoren ausgewählt wird und damit alle anderen Aktivierungsvektoren überschrieben werden, ist zu erwarten, dass das generative Netzwerk die damit verbundene lokale histologische Struktur auf das gesamte Bild überträgt. Damit lassen sich die Strukturen, die das trainierte Netz zur Analyse der Eingabedaten verwendet, einfach visualisieren.

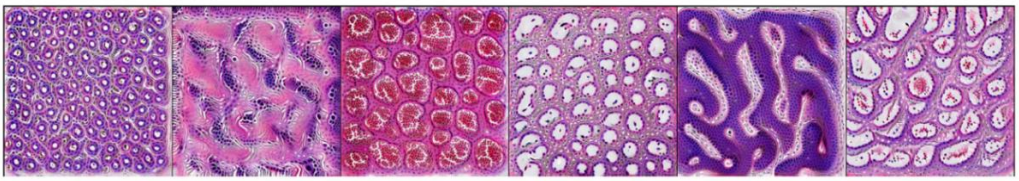

Grafik 4: Visualisierung KI-relevanter Strukturen zur Melanom-Charakterisierung

Dies ist eine vereinfachte Darstellung, deshalb der Vollständigkeit halber, hier das Diagramm der vollständigen Architektur. Für eine detaillierte Darstellung siehe Rudolf Herdt, Daniel Otero Baguer, **Concept Based Explanations and Class Contrasting,** 2025 https://arxiv.org/abs/2502.03422

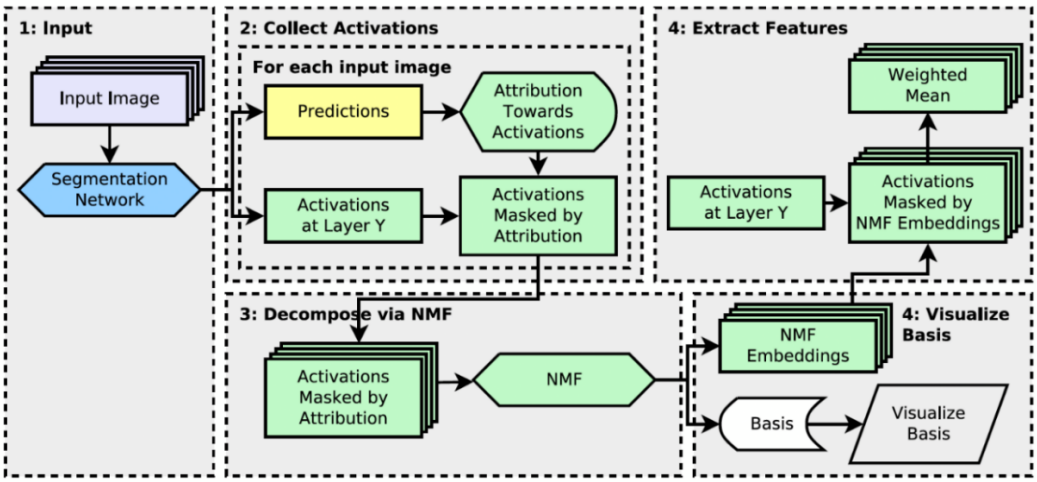

Grafik 5: Schematische Darstellung der Architektur zur Visualisierung histologisch relevanter Strukturen.

AP3) Skalierbare Netzwerkarchitekturen:

Eine bestehende Netzwerk-Architektur wurde für die Anwendung bei verschiedenen Vergrößerungsstufen erweitert und evaluiert. Neben der standardmäßig eingesetzten Bildvergrößerung von 10x haben sich auch die Vergrößerungsstufen 5x und 20x als relevant für die diagnostische Genauigkeit herausgestellt, um großflächigere bzw. kleinere Veränderungen der Haut zu erfassen.

AP4) Konditionierte Netzwerke für multimodale Datenstrukturen:

Es wurde eine Konditionierung für die Einbeziehung von immunhistochemischen Färbungen (IHC) entwickelt. Diese konnte für einige Krankheitsbilder eine Verbesserung der diagnostischen Genauigkeit liefern erfordert aktuell jedoch noch einen deutlichen numerischen Mehraufwand. Die anschließende Optimierungsphase wird zeigen, ob ein genereller Einsatz im Labor praktikabel ist.

AP5) Kontinuierlich stabil lernende KI:

Ein Konzept für kontinuierliches Lernen der KI im Labor wurde erstellt und getestet. Dabei hat sich gezeigt, dass das spezielle Weiterlernen auf Daten nur eines Labors zu Instabilitäten führen kann – es kommt zu Einbußen bei der Generalisierungsfähigkeit. Daher ergibt das kontinuierliche Lernen auf Basis unserer Beobachtungen in der Praxis nur Sinn, wenn es mit Techniken des föderierten Lernens kombiniert wird. Das heißt, dass das KI-Modell parallel an verschiedenen Laborstandorten trainiert und die Ergebnisse anschließend zu einer neuen Modellversion kombiniert werden. Dies gibt zudem die Möglichkeit, diese konsolidierte Version vor dem Ausrollen noch einmal gezielt auf einem speziellen Testdatensatz auszuwerten und mit der vorherigen Version zu vergleichen.

AP6) Training des kompletten Netzwerks, Evaluation:

Eine erste Zwischenevaluation der Ergebnisse der bisher durchgeführten Entwicklungen wurde anhand des Krankheitsbilds Aktinische Keratose durchgeführt. Hierzu wurde eine retrospektive Studie mit Fällen von fast 1.000 Patient:innen durchgeführt. Hierbei konnte die überarbeitete Netzarchitektur eine Genauigkeit von über 97% erzielen – im Vergleich zu 92% mit der alten Architektur.

Eine umfangreiche Publikation zu diesen Evaluationsergebnissen unter Einbeziehung zahlreicher medizinischer Experten wurde im Italian Journal of Dermatology and Venereology publiziert.

Meilensteinplanung und Zwischenziele

Alle im Antrag genannten Meilensteine, siehe Tabelle, wurden mit geringfügigen zeitlichen Verschiebungen erreicht.

Beschreibung	**Nr.**	**Termin**
Konzeption und Training generativer Netzwerke abgeschlossen, erfolgreiche Simulation zusätzlicher Daten	1	Nach Monat 9
Erste Stufe der Methodenentwicklung abgeschlossen und positiv evaluiert	2	Nach Monat 15

6. Notwendigkeit und Angemessenheit der geleisteten Arbeit

Das Projekt „MUKIDerm – Multimodale KI-Verfahren zur Detektion und Klassifikation von Tumorentitäten in der Dermapathologie ist durch seine Ausrichtung auf mathematische Konzepte komplementär zu den KI-spezifischen BMFTR-Programmen anderer Disziplinen angelegt.

Die vom Projektträger zur Verfügung gestellten Mittel wurden ausschließlich zur Deckung der Personalkosten des eingesetzten Personals benötigt (312.788,64 €).

7. Voraussichtlicher Nutzen, insbesondere Verwertbarkeit der Ergebnisse

Dieses Projekt wurde für für den NICHT-WIRTSCHAFTLICHEN Teil beantragt. Als Forschungseinrichtung strebt die Universität Bremen auch keine wirtschaftliche Verwertung der Ergebnisse an.

Unser industrieller Partner aisencia GmbH, der dieses Projekt begleitet und insbesondere bei der Bewertung der Ergebnisse unterstützt hat, beurteilt das zukünftige Verwertungspotential in Abhängigkeit externer Faktoren wie folgt:

Das wirtschaftliche Potential, das mit den in diesem Projekt entwickelten Methoden erreicht werden kann, hängt wesentlich von drei Faktoren ab:

1) Grad der Digitalisierung der pathologischen Labore. Der ist in einigen Ländern (Niederlande, Skandinavien) weit fortgeschritten, im deutschsprachigen Raum jedoch noch in den Anfängen. Derzeit sind etwa 15% aller pathologischen Labore in Deutschland soweit digitalisiert, dass ein Einsatz der geplanten KI-Methoden möglich wäre. Dieser Anteil wird in den nächsten Jahren voraussichtlich stark ansteigen.
2) Eine zweiter Erfolgsfaktor wird sein, ob es im Anschluss an dieses Projekt gelingt, die für dermatopathologische Anwendungen entwickelten Verfahren soweit zu funktionalisieren, dass sie im Labor-Routine-Betrieb einsetzbar sind. Der Aufwand für die dafür notwendigen Entwicklungsarbeiten inkl. der Adaption an die jeweilige vor Ort im Einsatz befindlichen IT-Struktur, lässt sich aktuell nicht abschätzen.
3) Außerdem hat der deutschsprachige Raum seine eigenen gesetzlichen Regularien zur Zertifizierung derartiger medizinisch – technischer Module. Die dafür notwendigen regulatorischen Anforderungen werden derzeit von aisencia in Zusammenarbeit mit medizinischen Experten diskutiert.

Insgesamt ist zu erwarten, dass die fortschreitende Digitalisierung pathologischer Labore den Einsatz derartiger Verfahren, wie sie in diesem Projekt erarbeitet wurden, ermöglichen wird. Dies setzt weitere Entwicklungsarbeiten und vor allem eine Zertifizierung der Verfahren voraus. Wann dies realisierbar und wirtschaftlich sinnvoll ist, lässt sich aktuell nur schwer abschätzen.

8. Der während der Durchführung des Vorhabens dem Zuwendungsempfänger bekannt gewordene Fortschritt auf dem Gebiet des Vorhabens

Nicht bekannt.

9. Erfolge und geplante Veröffentlichungen der Ergebnisse

R. Herdt, P. Maaß. **Visualize and Paint GAN Activations.** 2024 IEEE 34th International Workshop on Machine Learning for Signal Processing (MLSP), 22.09.-25.09.2024, London, Großbritannien. IEEE, 2024. DOI: 10.1109/MLSP58920.2024.10734757

J. Balkenhol, M. Schmidt, T. Schnauder, J. Langhorst, J. Le'Clerc Arrastia, D. Otero Baguer, G.Gilbert, F. Lacarrubba, T. Dirschka, L. Schmitz. **A deep learning model for histopathological diagnosis of actinic keratosis: a diagnostic case control accuracy study**. Italian Journal of Dermatology and Venereology 2026 April;161(2):104-14. DOI: 10.23736/S2784-8671.25.08336-7

R. Herdt, M. Schmidt, D. Otero Baguer, P. Maaß. **Smooth Deep Saliency.** Zur Veröffentlichung eingereicht. online unter: https://arxiv.org/abs/2404.02282

J. G. Maaß, R. Herdt, L. Kinzel, M. Walther, H. Fröhlich, T. Schubert, C. Schaaf, P. Maaß. **Enhancing the analysis of murine neonatal ultrasonic vocalizations: Development, evaluation, and application of different mathematical models.** The Journal of the Acoustical Society of America, 156(4):2448-2466, 2024. DOI: 10.1121/10.0030473

R Herdt, D. Otero Baguer. **Concept Based Explanations and Class Contrasting**. arXiv preprint arXiv:2502.03422

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt gefördert. Die Verantwortung für den Inhalt der Veröffentlichung liegt beim Autor.