



## **Schlußbericht**

**zum im DBU-Förderthema 12  
Bewahrung und Sicherung national wertvoller Kulturgüter vor schädlichen  
Umwelteinflüssen geförderten Projektes**

**Entwicklung und modellhafte Anwendung einer Systemplattform zur  
automatischen Detektion von durch anthropogene Umwelteinflüsse  
verursachter Schimmelbildung an Kulturgütern mittels künstlicher Intelligenz**

**(Projektlaufzeit: 16.12.2019 – 15.12.2021)**

Zuweisungsempfänger: Hajurveda Heritage

Aktenzeichen: 35604/01

Autoren: Hans-Jürgen Daams, Markus Böger, Albert Seifried,  
Martin Hahn, Alexander Agethen

Telefon: +49 176 22234430

E-Mail: [hans.daams@hajurveda.solutions](mailto:hans.daams@hajurveda.solutions)

Erstellt am: 21.01.2022

**für den Berichtszeitraum  
16.12.2019 – 15.12.2021**

Gefördert durch



1	Einleitung .....	4
2	Entwicklung des Echtzeit-Controllersystems .....	5
2.1	Auswahl der Baugruppen des Echtzeit-Controllersystems.....	5
2.2	Entwicklung und Bau der Schimmel-Kamera .....	9
2.3	Stativ zur Unterstützung der Bilderfassung.....	14
2.4	Untersuchung des Einflusses der Beleuchtung.....	16
2.4.1	Beispiele von Bildmaterial aus Xanten.....	16
2.4.2	Literaturrecherche zur Fluoreszenz .....	19
2.4.3	Erneute Felderprobung Fluoreszenz .....	20
2.4.4	Erprobung der Fluoreszenzmethode von Prof. Rapp.....	21
2.4.5	Schlußfolgerungen zur Beleuchtung.....	25
2.5	Programmierung der Algorithmen.....	25
2.5.1	Einrichtung des FTP-Servers als zentrales Element der Kommunikation.....	26
2.5.2	Erstellung der Datenbank für die Speicherung und Verwaltung der Fotos und Thermodaten.	26
2.5.3	Skript zum Zerschneiden der Fotos in kleinere Bildsegmente .....	29
2.5.4	Skript zur Sortierung der Bilder nach Schadensarten.....	32
2.5.5	Skript für die Erstellung und das Training der Convolutional Neural Networks (CNN.....	32
2.5.6	Skript zur automatischen Erkennung des Merkmales: das Prediction Skript. ....	39
2.6	Training der neuronalen Netze in der Praxis .....	40
2.6.1	Bildbeschaffung.....	40
2.6.2	Aufbau der Bilddatenbank.....	41
2.6.3	Ablauf des Trainings der neuronalen Netze.....	43
2.6.4	Ergebnisse der vielen Trainings.....	45
2.7	Funktionstest des Prediction Skriptes.....	48
2.8	Erprobung des Prediction Skriptes am Schimmel auf Glas .....	49
2.9	Feldtestphase mit den Anwendern.....	50
2.10	Bestimmung der Foto-Wiederholrate .....	53
2.10.1	Erfassung der vorliegenden Schimmelarten .....	53
2.10.2	Untersuchung des Klimas im Xantener Dom .....	57
2.10.3	Abschätzung des Schimmelwachstums am Beispiel von St.Laurentius in Erwitte .....	60
2.11	Feldtest in Xanten.....	64
2.12	Feldtest in Münster .....	69
2.13	Schimmeluntersuchung im Kölner Dom .....	73

2.14	Kleinste erkennbare Schimmelgröße.....	80
2.15	Quantifizierung des Schimmelwachstums.....	83
2.16	Vorgehen nach Erkennen eines Schimmels mit der Kamera .....	84
2.16.1	Biolumineszenz-Schnelltest.....	84
2.16.2	Schimmelpilzanalytik nach Judith Meider .....	85
2.16.3	Reinigung von schimmelbefallenen Oberflächen.....	86
2.17	Schlußwort und Ausblick.....	87
3	Anhang .....	88
3.1	Technische Daten des Raspberry Pi 4.....	88
3.2	Einrichten und Bedienen des Schimmel-Controllers.....	90
3.2.1	Einrichten des Schimmel-Controllers.....	90
3.2.2	Bedienen des Schimmelcontrollers.....	91
3.3	Systematisierung des Anlernprozesses .....	93
3.3.1	Bilddatensatz 1: Schimmel/Staub mit 2000 Trainings-Bildern und Löschen der Gewichtsfunktion bei jedem Lauf .....	94
3.3.2	Bilddatensatz 1: Schimmel/Staub mit 2000 Trainings-Bildern und Akkumulieren der Gewichtsfunktion bei jedem Lauf .....	102
3.3.3	Bilddatensatz 2: Schimmel/Staub mit 2000 Trainings-Bildern und Akkumulieren der Gewichtsfunktion bei jedem Lauf .....	108
3.3.4	Training bei festen Einstellparametern: Hier Wiederholungsprüfung für Bilddatensatz 3 für Schimmel und ok.....	111
3.3.5	Picture Set 4, Staub gegen ok bei 2000 Trainingsbildern .....	113
3.3.6	Picture Set 5 Schimmel gegen ok bei 4000 Bildern .....	114
3.3.7	Picture Set 6 Staub gegen ok bei 4000 Bildern .....	115
3.3.8	Picture Set 7 Schimmel gegen Staub bei 4000 Bildern .....	116
3.3.9	Picture Set 8 Schimmel gegen ok mit 6000 Bildern.....	117
3.3.10	Picture Set 9 Staub gegen ok mit 6000 Bildern.....	118
3.3.11	Picture Set 10 Schimmel gegen Staub mit 6000 Bildern.....	119
3.4	(Gedächtnis-)Protokoll der Beiratssitzung .....	120
3.5	Unterstützer des Projektes .....	122
3.6	Veröffentlichungen .....	125
3.7	Abbildungsverzeichnis .....	125
4	Literaturverzeichnis .....	127

## 1 Einleitung

Die Entstehung und Ausbreitung von Schimmel in Deutschland hat während der Projektlaufzeit signifikant zugenommen. Aktuelle Beispiele aus bedeutenden Kulturgütern in West- und Ostdeutschland sind lebendiges Zeugnis hierfür.

Oft wird der starke Befall von Schimmel in den Objekten kaum erkannt, sei es, daß das geübte Auge hierfür fehlt oder daß schlicht keine Zeit dafür da ist. In ganz Deutschland werden in den Kirchen Kosten gedrückt und Personal reduziert. Damit stehen für Kontrollrundgänge auf Schimmel kaum noch Kapazitäten zur Verfügung. Oft wird Schimmel von der Putzfrau einfach weggewischt, was die Situation nochmals unkontrolliert verschlimmert.

Schimmel befällt mittlerweile Ausstellungsstücke in Museen, antike Glasmalereien in Kirchenfenstern und macht auch vor Reliquienschreinen keinen Halt mehr.

In Anbetracht dieser Situation ist zum Schutz unserer Kulturgüter ein System sinnvoll und auch notwendig, welches Schimmelentstehung und Schimmelwachstum unabhängig vom Menschen erkennt und den verantwortlichen Personen meldet. Diese können dann gezielt und rechtzeitig Gegenmaßnahmen einleiten.

Ein solches System wurde in diesem Projekt entwickelt.

Es entstand eine Systemplattform, welche über einen Echtzeit-Controller eine digitale Kamera ansteuert, die Beleuchtung für die Zeit der Aufnahme einschaltet, Thermodaten im Nahfeld des Objektes erfasst und diese Informationen über eine Mobilfunkleitung an den Cloud-Server schickt. Hier wird mit einem neuartigen, innovativen Ansatz, basierend auf Algorithmen aus der künstlichen Intelligenz (KI) eine Schimmelanalyse für jedes Bild durchgeführt. Das System erkennt Schimmel bereits ab einer Größe von 1mm Durchmesser und warnt den Anwender automatisch und in Echtzeit über dieses Risiko. Darüber hinaus lässt sich mit diesen Algorithmen auch das Schimmelwachstum quantitativ darstellen.

Eine Datenbank speichert alle Bildinformationen und gleichzeitig hierzu die Thermodaten, um später aus diesen Daten eventuelle Korrelationen zwischen vorliegenden Thermodaten und Schimmelentstehung abzuleiten.

Es ist ein System entstanden, deren Ergebnisse ohne Expertenwissen zu verstehen sind und die mit minimalem Aufwand zu installieren ist.

Darüber hinaus konnten interessante Ergebnisse zur richtigen Beleuchtung erarbeitet werden, die auch das Thema Fluoreszenz beinhalten.

Der Schlußbericht folgt inhaltlich den Arbeitspaketen, fasst aber die einzelnen Punkte thematisch zusammen. Gerade beim Training der neuronalen Netze entsteht eine große Menge an Daten. Diese werden im Anhang im Detail dargestellt, im Schlußbericht dann aber im Ergebnis zusammengefasst.

Ergänzt wird der Bericht durch zahlreiche Beispiele aus der Praxis.

Alle Arbeitspakete wurden erfolgreich und im Kosten- und Zeitplan fristgerecht abgearbeitet. Das Projekt konnte sehr erfolgreich abgeschlossen werden.



## **2 Entwicklung des Echtzeit-Controllersystems**

Das Echtzeit-Controllersystem ist das Herz der gesamten Systemplattform. Es befindet sich vor Ort in der Kirche, ist unauffällig, steuert die Beleuchtung und die Bildaufnahme an, erfasst die Thermodaten und sendet alle Informationen zum Cloudserver für die Auswertung. Wenn die Auswertung entstehenden Schimmel erkennt, erfolgt eine Warnung an den Nutzer über E-Mail.

### **2.1 Auswahl der Baugruppen des Echtzeit-Controllersystems**

Die Auswahl der geeigneten Elektronik greift auf Standardbauteile zurück, um die Kosten des Systems tief zu halten.

Als zentrale Recheneinheit für die Steuerung aller Aufgaben wurde der Raspberry Pi-4 ausgesucht. Er ist ein eigenständiger Mikrocontroller und zeichnet sich durch zahlreiche Schnittstellen aus. Dies erhöht die Anpassungsfähigkeit des Systems an die Gegebenheiten des Bauwerks und der Kunstwerke. Die aufgenommenen Daten können über Netzwerk-Kabel, WLAN (WLAN und Bluetooth integriert) oder über einen LTE-Stick mit Mobilfunkvertrag/Prepaid an die Cloud gesendet werden.

Für die Arbeit auf dem Mikrocontroller sind Anschlüsse für einen externen Monitor und für Keyboard und Maus verfügbar.

Das Betriebssystem befindet sich auf einer microSD-Karte. Damit kann der Mikrocontroller wie ein „normaler“ Computer bedient werden.

Die technischen Details sind im Anhang 3.1 beschrieben.

Das folgende Bild gibt einen Überblick über die Anschlussstellen:




Abbildung 1 Raspberry Pi 4 Funktionsschaltbild 2020 © iXtronics-Hajurveda

Das Zeit- und Energiemanagement wird über ein Zusatzmodul (WittyPi3) realisiert. Das Modul erweitert den Raspberry Pi 4 um eine Echtzeitschaltuhr (RTC) und um das Energiemanagement, welches mithilfe von Skripten (also Softwareprogrammen) auch komplexe Start- und Ausschaltsequenzen umsetzbar machen. Zum Anschluss an den Raspberry Pi wird der 40-Pin GPIO Header genutzt. Damit wird es möglich auch ohne aktive Internetverbindung die Uhrzeit auf dem Raspberry Pi vorzuhalten. Dies ist wichtig, um zu den zuvor gewählten Uhrzeiten das System hoch- oder runterzufahren. Wird das System mithilfe des WittyPi3 heruntergefahren trennt das WittyPi3 die Stromversorgung zum Raspberry Pi komplett, so dass ein schleichender Stromverbrauch durch den Raspberry Pi ausgeschlossen ist. Dies ist sehr wichtig, um das System möglichst energiesparend zu betreiben und sicher zu sein, dass auch die Peripherie Geräte an dem Raspberry stromlos sind. Ein weiterer Vorteil ist, dass durch das WittyPi3 das System um einen Ein-Ausschalter erweitert wird. So kann das System auch manuell gestartet werden. Zusätzlich kann das System auch neugestartet werden, falls es sich aufgehängt hat. Dazu kann der Schalter länger gedrückt gehalten werden, bis das System neu startet.





Abbildung 2 Zeit- und Energiemanagement mit WittyPi3 2020 © Raspberry

Damit die Zeit- und Alarmsteuerung bei einem Stromausfall nicht verloren geht, verfügt das WittyPi3 über eine kleine Batterie, welche die Echtzeituhr auch ohne Netzspannung mit Strom versorgt.

Außerdem kann das System dank des WittyPi3 auch mit höheren Spannungen betrieben werden, falls nötig. Sollte die Eingangsspannung unter einen Grenzwert fallen kann auch automatisch heruntergefahren werden, bevor das System sich aufhängt.

Als Kamera wurde eine HQ-Kamera der neusten Generation ausgesucht, die direkt an den Raspberry anschließbar ist. Sie ist im folgenden Diagramm dargestellt:



Der Kamerachip ist inliegend auf der Platine integriert und misst 8,5 mm im Quadrat. Mit 4056 x 3040 Pixels wird eine Auflösung von 12,3 Megapixels erreicht. Die Platine wird über 4 Verschraubungen direkt mit dem Gehäuse verbunden. Im inneren Ring wird dann das Objektiv eingeschraubt.

Abbildung 3 HQ-Kamera mit 12.3 MPixel Auflösung 2020 © Sony

Der verwendete Sensor ist ein SONY IMX477R gestapelter, hintergrund-beleuchteter Sensor. Die Empfindlichkeit ist gegenüber den Vorgängern verbessert worden. Es sind ca. 50% mehr Fläche pro Pixel verwendet worden, um so die Leistung bei schlechten Lichtverhältnissen zu verbessern. Dies ist für den Einsatz in Kirchen sehr wichtig. Des Weiteren verfügt die Kamera auch über einen Stativ Anschluss (1/4"-20) Was uns bei der Verwendung eines Statives hilft.



Abbildung 4 HQ-Kamera mit SONY IMX477R Sensor 2020 © SONY

In das oben dargestellt Gewinde kann direkt ein geeignetes Objektiv eingeschraubt und befestigt werden.



Abbildung 5 Weitwinkelobjektiv mit 6mm Brennweite 2020 © Raspberry

Das Objektiv verfügt über eine einstellbare Blende und eine Möglichkeit zur Scharfeinstellung des Bildes.

Das gewählte Weitwinkelobjektiv mit 6mm Brennweite und CS-Mount ist optimal für die Verwendung mit der Raspberry Pi HQ Kamera abgestimmt. Das Bildformat ist  $\frac{1}{2}$ " bei einer Brennweite von 6mm und einer Auflösung von 3 Megapixel. Die Blende F1.2 hat einen Feldwinkel von 63°. Nächster Objektstand (MOD) ist 0,20 m. Die Blende wird manuell verstellt und am Ort der Installation eingestellt.




Abbildung 6 zeigt die verwendeten LED-Stäbe mit tageslichtnahem Licht. Alternative LED für den UV und IR-Bereich sind ebenfalls verfügbar. Die winzigen LEDs (5mm \*5 mm) sind auf einer Leiterplatte montiert und können mit weiteren LED-Sticks verkettet werden. So kann man optional, falls nötig noch mehr Licht auf die zu beobachteten Objekte bringen. Die LED-Sticks werden mit nur einem verwendeten Mikrocontroller Pin angesteuert.

Abbildung 6 LED-Stäbe mit tageslichtnahem Licht 2020 © Adafruit




Abbildung 7 hochgenauer I<sup>2</sup>C-Temperatur & Luftfeuchte-Senso  
2020 © seedGrove

kürzerer Laufzeit des Gesamtsystems und somit zum Einsparen von Energie. Aufgrund der dringenden Empfehlung von Herrn Schubert von der Dombauhütte Xanten wird der Sensor nicht in ein Gehäuse eingelassen, damit möglichst wenig Störungen der Umgebungsbedingungen stattfinden.

Der Nahbereich der Altäre wird aufgrund mehrerer Untersuchungen als sehr wichtig für die Entstehung von Schimmel betrachtet. Der Sensor sollte daher frei in unmittelbarer Nähe der Oberflächen montiert werden.

Für das Betriebssystem wird eine microSD-Card mit der Speedclass A1, VideoClass V30 und UHS-I U3 verwendet. Dies gewährleistet einen schnellen Systemstart. Die Lesegeschwindigkeit der Karte liegt bei 100MB/s. Die Speichergröße beträgt aktuell 32GB, kann aber wenn es das Projekt erfordert oder ein Kunde es wünscht, deutlich erhöht werden. Da in unseren Fall hauptsächlich mit der Cloud gearbeitet werden soll, ist die gewählte Größe mehr als ausreichend.

## 2.2 Entwicklung und Bau der Schimmel-Kamera

Erforderlich war die Auswahl eines Gehäuses, welches zu den Abmessungen des Raspberry und zu allen weiteren Modulen kompatibel war. Es konnte glücklicherweise auf ein Kaufteil zurückgegriffen werden. Ein Prototyp im 3-D-Rapidprototypingverfahren wäre sehr teuer geworden.

Zum Messen von Temperatur und Luftfeuchtigkeit kommt ein hochgenauer I<sup>2</sup>C-Temperatur & Luftfeuchte-Sensor zum Einsatz. Seine Eigenschaften überzeugen neben der hohen Genauigkeit von  $\pm 1,5\% \text{rF}$  und  $\pm 0,1\text{ }^\circ\text{C}$  durch einen vollständig kalibrierten, linearisierten und temperaturkompensierten Digitalausgang sowie eine I<sup>2</sup>C Schnittstelle mit Kommunikationsgeschwindigkeiten von bis zu 1 MHz. Dadurch wird eine sehr schnelle Start- und Messzeit erreicht. Dies führt zu





Abbildung 8 zeigt die bisherige Integration der Bauteile im kubischen Gehäuse. Die Abmessungen des Kubus sind 9,5x9,5x9,5 cm.


Die unterste Platine ist der Raspberry-Mikrokontroller und darüber ist das Power-Management Modul. Über das Flachbandkabel ist die Kamera angeschlossen. Die bunten Kabel schließen den Sensor und die LED an.

Aufgrund der Auswahl und Zusammenstellung der Komponenten wird voraussichtlich der Zielverkaufspreis von unter 1000€ pro Modul eingehalten werden können.

Für die zahlreichen Ein- und Ausgänge mussten mehrere Öffnungen in das Gehäuse gefräst und gebohrt werden.

Abbildung 8 Kunststoffgehäuse Schimmelkamera mit PI 4 und Witty 2021© iXtronics-Hajuveda

Abbildung 9 zeigt den Schimmel-Controller mit Kamera und LED-Sticks:




Die Kamera und die VIS-Dioden werden auf der Frontplatte befestigt. Das Objektiv sollte so eingestellt sein, daß die Blende voll geöffnet ist. Man kann das leicht erkennen, wenn man von vorne hineinsieht und dann an der hinteren Justierung dreht. Unbedingt wichtig ist das Fixieren mit der hinteren Rändelschraube, da ansonsten bei der Montage ein Verdrehen erfolgen kann und das Bild dadurch dunkel bleibt.

Die vordere Justierung wird für die Einstellung der Schärfe benötigt und muß danach auch unbedingt fixiert werden.

Die Beleuchtung mit sichtbarem Licht wurde mit 3 Lichtstäben realisiert, die über Kabel verbunden sind und dann direkt mit der Frontplatte verklebt wurden.

Abbildung 9 Schimmelkamera mit Objektiv und VIS-Dioden 2021© iXtronics-Hajuveda

Abbildung 10 zeigt das Sensormodul. Es wird über Kabel direkt mit dem Controller verbunden. Das Kabel kann über Steckverbindungen verlängert werden. Das Sensormodul selbst wird nicht in einem Gehäuse verbaut, da der direkte Kontakt mit dem Nahfeld des Messobjektes erforderlich ist. Es dürfen keine Strömungsbedingten Abweichungen stattfinden.



Der Bereich unter dem Objektiv ist für Kabelanschlüsse zum Betrieb der digitalen Kamera, zur Stromversorgung der LED und zum Anschluss des Sensormoduls vorgesehen.

Abbildung 10 Schimmelkamera mit Sensoranschluß 2021© iXtronics-Hajuveda



Abbildung 11 zeigt die Rückwand. Sie beinhaltet Öffnungen und Stecker für die Stromversorgung und Monitoranschlüsse. Mit dem roten Punkt gekennzeichnet ist der Eingang (Stecker Micro USB) für die Stromversorgung. Der grüne Punkt (Micro-HDMI-Ports) kennzeichnet den Ausgang für den Monitor, der für die on-line Scharfstellung des Bildes vor Ort notwendig ist.

Abbildung 11 Schimmelkamera Rückwand 2021© iXtronics-Hajuveda.png



Abbildung 12 zeigt die Seitenansicht. Hier sind Öffnungen für Netz, Tastatur, Maus und LTE-Stick, der über USB angeschlossen wird.

Der Ethernet-Anschluss ist ganz rechts im Bild zu sehen. Nach links folgen dann 2 USB 3.0 und 2 USB 2.0 Anschlüsse. Tastatur und Maus werden über die USB 2.0 Anschlüsse verbunden. Es empfiehlt sich jedoch wegen der Arbeiten in großer Höhe eine drahtlose Verbindung für Tastatur und Maus. Der LTE-Stick wird wegen der hohen Datenrate über die USB 3.0 Schnittstelle verbunden. Dort kann auch ein weiteres USB-Gerät angeschlossen werden.

Abbildung 12 Schimmelkamera Seitenwand 2021© iXtronics-Hajuveda



Abbildung 13 Schimmelkamera Seitenwand für Schalter  
2021© iXtronics-Hajuveda

Abbildung 13 zeigt die andere Seite. Sie beinhaltet Eingänge für die Speicherkarte, der Funktionsanzeige und den An-Aus-Schalter

Mit dem An-Aus-Schalter wird das Gerät in Betrieb genommen. Nach Programmierung des Gerätes für eine Zeitschaltung geht die Kamera in den Schlafmodus über. Die Zeitschaltung sollte möglichst geringe „An-Zeiten“ von weniger als 5 Minuten pro Tag haben, um Akku-Kapazität zu schonen. Unten befindet sich linkerhand der Slot für die Speicherkarte, auf der alle Skripte zur Auswertung der Kamerabilder enthalten sind. Daneben sieht man eine Kontroll-LED, die ganz wichtig für die Erkennung des Kamerazustandes ist. Insbesondere im Schlafmodus blinkt die Leuchte immer

wieder auf und zeigt somit, daß das System aktiv ist.

Die ursprüngliche Idee, mehrere Kameras und Sensoren an einen Controller anzuschließen, wurde verworfen. Die Kosten für die Realisierung eines entsprechenden Interfaces sind zu hoch, da hier eine Spezialplatine entwickelt und dann auch auswärts gefertigt werden müsste. Dadurch würden die Kosten für das Modul erheblich erhöht. Es ist preiswerter, 3 Controllermodule incl. Kamera und Sensor anzuschaffen, da bei der bisherigen Auswahl der elektronischen Komponenten nur Standardbauteile verwendet werden.




Abbildung 14 Schimmelkamera mit eingebautem Akku an der Oberseite  
2021© iXtronics-Hajuveda

Um in Kirchen auf elektrische Anschlußkabel zu verzichten wurden im Deckel der Schimmelkamera ein Akkusatz mit 4 Akkus eingeklebt. Er kann dann über einen Stecker auf den DC-Eingang des WittyPI3 gesteckt werden. Dies ist in Abbildung 14 gezeigt.





Abbildung 15 zeigt die Montagemöglichkeiten, die auf der Oberseite realisiert wurden. Die Kamera kann über den mittleren Messingzapfen direkt auf einem Stativ verbaut werden. Darüber hinaus dienen die drei Ösen zur Aufhängung an Nylonschnüren.

Die Montage über Messingzapfen erlaubt eine Vielzahl von Montagepositionen.

Die Aufhänge Ösen sind relativ zum Schwerpunkt austariert. Sie erlauben die Aufhängung über Nylonfäden mit zusätzlicher Schwerpunktkorrektur durch die hintere Öse. Diese Lösung hat sich aber nicht bewährt, da durch Temperaturschwankungen die Nylonfäden beginnen, sich zu verdrehen und damit die Position des Bildes sich leicht verändert. Daher wurde diese Konstruktion durch Gewindestangen ersetzt, die eine starre Anbindung der Kamera erlauben.

*Abbildung 15 Schimmelkamera Oberseite mit Anschlüssen über Stativ und Aufhängung  
2021© iXtronics-Hajuveda*




Abbildung 16 zeigt die Montage mit Gewindestangen.

*Abbildung 16 Schimmelkamera Oberseite mit Anschlüssen  
über Gewindestangen 2021© iXtronics-Hajuveda*

Die Entwicklung und der Bau der Schimmelkamera ist damit abgeschlossen.

**Eine Anleitung zur Einrichtung der Schimmelkamera und deren Bedienung befindet sich im Anhang 3.2**

### ***2.3 Stativ zur Unterstützung der Bilderfassung***

Speziell in der Anfangsphase zur Erarbeitung der richtigen Beleuchtung für die Aufnahme von Fotos ist ein vielseitiges Stativ nötig. Unter den vielen potentiellen Lieferanten wurde auf Manfrotto zurückgegriffen.

Manfrotto ist eine italienische Firma mit hochqualitativen Systemen im mittleren Preissegment und einem vielfältigen Zubehörsortiment für mobile und stationäre Applikationen. Dies schließt Kamera und Beleuchtungshalterungen, Stangen, Superklemmen und Beleuchtungssysteme und noch ganz viel mehr ein.



Abbildung 17 Schimmelstativ mit allen notwendigen Komponenten und Beleuchtungen 2020© iXtronics-Hajuveda

Abbildung 17 zeigt das Stativ mit allen benötigten Komponenten: Hierzu gehören universelle mechanische Verstellungen in alle Raumrichtungen und die Beleuchtungselemente. Die Querstange wird direkt auf die 3-Wege Winkeleinstellung montiert und hält in der linken Klemme eine IR-Leuchte, in der Mitte zunächst eine Handyhalterung (hier mit Handy) für die Fotos und darüber eine VIS-Beleuchtung mit 8 LED's. Die rechte Klemme hält eine UV-Lampe. Unterhalb der Winkeleinstellung kann ein Flexarm mit UV-C-Lampe montiert werden. Die Mittelsäule ist ausfahrbar und die Stativbeine verfügen über rastbare Winkeleinstellungen.

Die verschiedenen Lichtquellen sind wichtig, um deren Wirkung auf die Sichtbarmachung von Schimmel zu untersuchen.



Abbildung 18 Schimmelstativ auch für knifflige Ecken 2020© iXtronics-Hajuveda

Abbildung 18 ist ein Beispiel für sehr herausfordernde Montagen.

Mit dieser Auswahl an Montage- und Beleuchtungskomponenten wurden nun die Aufnahmen in den Kirchen durchgeführt. Pro Motiv hat man dabei 4 Beleuchtungsquellen und 3 Objektivinstellungen, so daß insgesamt 12 Bilder zur Verfügung stehen.

## **2.4 Untersuchung des Einflusses der Beleuchtung**

Aufgrund von einigen Veröffentlichungen im Vorfeld des Antrages war wegen möglicher Fluoreszenzen von Schimmel geplant, zusätzlich zum sichtbaren Bereich auch infrarote und ultraviolette Lichtquellen einzusetzen. Dabei sollen die Frequenzen im IR und UV-Bereich möglichst weit weg vom sichtbaren Bereich liegen, um Überlappungen zu vermeiden, wie z.B. bläuliches Schimmern, wenn die UV-Anregungsfrequenzen zu nahe am sichtbaren Bereich liegen. Für den IR-Bereich gibt es im Wesentlichen Frequenzen um die 850 nm und 950 nm. Falls biologisch nichts entgegensteht, sollte daher die 950 nm gewählt werden. Im UV-Bereich stehen 365 nm und 395 nm als Anregungslichtquellen zur Verfügung. Im Sinne der Trennung vom sichtbaren wird daher die 365 nm-Linie gewählt. Entsprechende Lichtquellen wurden für das Projekt angeschafft. Wichtig bei der Betrachtung ist, daß aufgrund des Aufbaus der Kamera nur Auflicht und kein Streiflicht verwendet werden kann.

Aufgrund von Hinweisen aus der Literatur wurden für die Aufnahmen unterschiedliche Lichtquellen ausgewählt, um den Schimmel möglicherweise durch Lichteffekte, wie Fluoreszenzen besser sichtbar zu machen. So berichtete /Wooley 18/ über Fluoreszenzen bei unsichtbarem Schimmel in Wohnungen unter Verwendung von Schwarzlicht bei seitlicher Anstrahlung. Im DBU Abschlußbericht zum Schimmelbefall an Orgeln wird über Fluoreszenzen bei Schimmel berichtet. Weitere Untersuchungen wurden aber nicht gemacht /Henning 18/. In /Degand 20/ wird über fluoreszierende Schimmelpilze berichtet. Auf der 10. Grazer Pilztagung wurde über optische Bauforensik zur Aufklärung von Bauschäden /Rapp 2019/ berichtet, der auch das Thema Schimmel beinhaltet.

Daher wurden als Lichtquellen sichtbares Licht (VIS), Infrarot (IR bei 950 nm) und in den ultravioletten Bereichen UV (bei 365 nm) und UV-C Strahlung (bei 282 nm) ausgewählt.

### **2.4.1 Beispiele von Bildmaterial aus Xanten**

Die Untersuchung zum Einfluss der Beleuchtung auf die Sichtbarkeit von Schimmel wurde im Xantener Dom gestartet. Die Aufnahmen wurden je nach Platzangebot mit oder ohne Schimmelstativ gemacht.

Abbildung 19 zeigt Schimmel auf der Rückseite des Holzaltars im Xantener Dom. Die Sichtbarkeit des Schimmelpilzes ist bei VIS-Beleuchtung eher besser als bei Beleuchtung mit UV.






Abbildung 19 Sichtbarkeit von Schimmel bei VIS- und UV-Beleuchtung 2020© iXtronics-Hajuveda

Abbildung 20 zeigt einen Vergleich zwischen UV-C und IR ohne erkennbare Bevorzugung einer der beiden Lichtquellen:



Abbildung 20 Sichtbarkeit des Schimmels bei UV-C und IR-Beleuchtung 2020© iXtronics-Hajuveda

Abbildung 21 zeigt einen Vergleich der Beleuchtung mit VIS, dann UV, dann UV-C und dann IR.



*Abbildung 21 Vergleich Sichtbarkeit Schimmel für alle 4 Beleuchtungsquellen 2020© iXtronics-Hajuveda*

Während UV-C und IR keine Verbesserung der Erkennbarkeit der Schimmelstrukturen liefern, scheint es Situationen zu geben, wo die Strahlkraft mit UV-Beleuchtung etwas besser ist.

Abbildung 22 zeigt eine Situation, wo UV bessere Bildqualität liefert als VIS:



*Abbildung 22 Beispiel für ein besseres Ergebnis bei UV-Beleuchtung 2020© iXtronics-Hajuveda.png*

Abbildung 23 zeigt ein ähnliches Ergebnis bei Beleuchtung mit VIS, dann UV, dann UV-C und dann IR:






Abbildung 23 Vergleich der Sichtbarkeit bei allen 4 Beleuchtungsquellen mit Verbesserung bei UV 2020© iXtronics-Hajuveda

Auch hier zeigt sich, daß UV-C und IR keine Vorteile bringt. Allerdings bringt in dieser Situation die UV-Beleuchtung mehr Sichtbarkeit als die VIS-Beleuchtung. Es scheint also Situationen zu geben, wo UV-Strahlung eine bessere Sichtbarkeit von Phänomenen ergibt, die sehr nach Schimmelpilzen aussehen. Bei anderen Situationen ist das aber überhaupt nicht so. Es besteht die Vermutung, daß vielleicht bereits gereinigte Flächen den zuvor vorhandenen Schimmel bei UV-Bestrahlung zeigen, aber das ist nicht nachgewiesen.

Um mehr darüber zu erfahren, unter welchen Bedingungen Schimmel fluoresziert, wurde eine Literaturrecherche durchgeführt.

### 2.4.2 Literaturrecherche zur Fluoreszenz

Ein sehr guter, ausführlicher und sehr gut beschriebener Überblick über die Fluoreszenz von Kulturgütern findet sich in /Measday 17/ mit dem Titel:

“A summary of ultra-violet, fluorescent materials relevant to Conservation”.

Hier findet man alle Informationen und Referenzen über UV-angeregte Fluoreszenz z.B. von Kulturgütern aus Porzellan, Glas, Stein, Elfenbein, Knochen, Metall, Holz, Textil, Kleber, Beschichtungen und vieles mehr.

Unter anderem wird hier auch Schimmel kurz erwähnt mit einer weiteren Literaturstelle /Florian 97/ zu „Heritage Eaters – Insects and Fungis in heritage collections“. Hier werden zwar Fluoreszenzen auf Papier des 19. Jahrhunderts beschrieben, aber leider kein Nachweis, dass dies auf Schimmelpilze zurückzuführen ist.

Auch andere Medien fluoreszieren und daher könnte es sein, daß Vertauschungen der Aussagen vorkommen. /Gram00/ berichtet über Fluoreszenzen von unsichtbarem Schimmel auf Papier. In /Becca 12/ wird Botrytis auf Weintrauben mit UV-Fluoreszenz erkannt. /Floyd 16/ schildert Fluoreszenzemissionen unter UV-LED-Bestrahlung von angeschimmeltem Mais für eine Sortieranlage. Im DBU Abschlußbericht /Köhler 18/ wird über Fluoreszenzen von Kristallen in Marmor berichtet. /Rapp 2019/ berichtet über Fluoreszenz von Urin, Leim und Dispersionsfarbe.

Die Literaturrecherche ergibt ein uneinheitliches Bild. Während Fluoreszenzen bei UV-Beleuchtung in der Nahrungsmittelindustrie ein durchaus gängiges Verfahren sind, entsteht hier bei den in Kirchen und Museen vorhandenen Kulturgütern eher der Eindruck, dass vieles bei UV-Beleuchtung anfängt zu fluoreszieren, aber nur der Schimmel nicht /Measday 17/. Dort wo auf die Fluoreszenz von Schimmel eingegangen wird, wird gleichzeitig gesagt, daß die Ursache der Fluoreszenz nicht eindeutig auf Schimmel zurückführbar ist, daß das Phänomen nicht eingehender untersucht wurde und manchmal ist es auch ein wenig unglaubwürdig, was dort behauptet wird. Es konnten keine grundlegenden Forschungsuntersuchungen hierzu gefunden werden. Damit befindet man sich in unsicherem Gebiet.

### **2.4.3 Erneute Felderprobung Fluoreszenz**

Um die Ergebnisse aus der Literaturrecherche zu verifizieren, wurden in Xanten und Glösa weitere Untersuchungen durchgeführt. Abbildung 23 zeigt die starke Fluoreszenz von Staub auf einem Steinsockel. Abbildung 24 zeigt Fluoreszenzen im Mörtel, Abbildung 25 zeigt Fluoreszenzen an einer Lötstelle.



*Abbildung 24 Fluoreszenz von Staub auf Steinsockel 2020© iXtronics-Hajuveda*





Abbildung 25 Fluoreszenz im Mörtel 2020© iXtronics-Hajuveda



Abbildung 26 Fluoreszenz von Lötstellen 2020© iXtronics-Hajuveda

#### 2.4.4 Erprobung der Fluoreszenzmethode von Prof. Rapp

Auf Veranlassung des Beiratsmitglieds Judith Meider wurde die Fluoreszenzmethode von Prof. Rapp genauer untersucht. Grundlage der Untersuchung war eine Veröffentlichung auf der 10. Grazer Schimmelpilztagung in 2019 /Rapp 2019/. Dort wird über optische Bauforensik zur Aufklärung von Bauschäden berichtet. Hierfür werden Methoden der Kriminalforensik eingesetzt. Insbesondere wird hier Bezug genommen auf ein eigenes Forschungsgebiet an der Leibniz Universität in Hannover seit 2013 mit dem Thema: Systematische Untersuchung von Materialien im Bauwesen durch bildgebende optische Bauforensik

- Fluoreszenzverhalten
- NUV-Absorptionsverhalten
- NIR-Absorptionsverhalten

Im Buch /Kraus-Johnsen, 2018/ werden die Details des Verfahrens vorgestellt. Es wird davon ausgegangen, daß fast jedes organische Material, wie z.B. Pilzhyphen, Sporen, Enzyme und Metabolite eine ausgeprägte UV-Absorption aufweisen und daher bestens für

die Fluoreszenzanalyse geeignet sind. Dabei absorbieren sie die UV-Strahlung (hier bei 365 nm) und strahlen dann langwelligeres Licht ab, welches über ein Beige-Filter beobachtet werden kann. Beleuchtung und Filter müssen aufeinander abgestimmt sein. Die im Buch vorgeschlagene Firma Lumatec kennzeichnet sich selbst als Lieferant für Lichtspektren für Tatort und Labor. Die empfohlene Tatortlampe vom Typ M05 ergab auf Basis eines Angebotes einen Preis von 1610 Euro plus 119 Euro für ein gelb-dunkel-Filter. Die Lampe strahlt UVA 365 nm mit 1.100 mW Lichtleistung ab. Sie dient zur Erkennung von Körpersekreten, Waschmittel, Fette, Öle und Kontrastierung mit Hintergrund-Fluoreszenz Lumicyano® / Policyano® Fluoreszenz-Pulver. Aufgrund des hohen Preises wurden andere Lösungen gesucht und gefunden:

Die LIGHTFE UV-Taschenlampe UV301D verwendet hochwertige 365nm UV-LED-Perlen mit 3 W optischer Leistung und einem starken Lichtstrahl von 115 mW/cm. Der Strahlabstand kann bis zu 50 m betragen. Sehr wichtig ist der Einbau eines UV-Filters, welches insbesondere den sichtbaren Anteil des Lichtes wegfiltert und daher einen sauberen Bereich um die 365 nm durchlässt. Der Preis liegt bei 36 €.

Das Beige-Filter wurde als Interferenzfilter mit einer Cutoff-Wellenlänge bei 550nm bei Edmund Optics in UK bestellt, was wegen Brexit zu erheblicher Lieferzeitverzögerung führte. Das Filter blockt mit hoher Effizienz alle Wellenlängen, die kleiner als 550 nm sind und lässt alle Wellenlängen darüber mit hoher Transparenz durch.

Zusätzlich wurde eine PTFE-Platte bestellt. Diese Platte ist schneeweiß und reflektiert maximal alle Wellenlängen ohne eigene Fluoreszenz. Jedes Objekt, das im Fluoreszenzbild heller als PTFE erscheint, besitzt mit 100 %-iger Sicherheit Fluoreszenz. Auch schwach fluoreszierende Objekte sind so mithilfe eines danebengelegten Stückes PTFE erkennbar.

Außerdem wurde ein Baumwollnesseltuch bestellt mit schwacher bis mittelstarke Fluoreszenz mit breitem Maximum im leicht gelblichen Bereich. Diese Referenz fluoresziert nach Art und Stärke etwa so, wie das Chitin der pilzlichen Zellwand. Fluoreszenzbilder sind besonders aussagekräftig, wenn ein manueller Weißabgleich mit der Kamera vor der Aufnahme des Objektes durchgeführt wird. Die Lichtquelle wird im verdunkelten Raum auf das Nesseltuch gerichtet, dann mit der Kamera und aufgesetztem Beigefilter fotografiert. In der Kamera wird dann ein Weißabgleich durchgeführt, der für alle folgenden Fotos gilt.

### **Erprobung im Office:**

Alle für das Experiment benötigten Teile sind in Abbildung 27 zu sehen (Das Handy ist hier nicht zu sehen, weil das Bild damit gemacht wurde):




Abbildung 27 Benötigte Materialien für die Rapp-Methode 2021© iXtronics-Hajuveda

In Abbildung 28 ist das Baumwollnestseltuch und die PTFE-Platte zu sehen. Es wurde ein manueller Weißabgleich im Handy im Pro-Modus durchgeführt.



Abbildung 28 Manueller Weißabgleich nach der Rapp-Methode 2021© iXtronics-Hajuveda

Mit dieser Ausrüstung wurde dann eine Erprobung im Xantener Dom an Originalschimmel der Sorte Aspergillus Glaucus gemacht.

Abbildung 29 zeigt die Vorderseite des Helena-Altars mit Schimmel auf der hinteren Holzwand und drei verschiedenen Beleuchtungsquellen: Sichtbares Licht (1. Bild), UV-Licht bei 365 nm (2. Bild) und UV-Licht bei 365 nm mit Beige-Filter (Transmission oberhalb von 550 nm) nach der Rapp-Methode (3. Bild).



Abbildung 29 Helena-Altars mit Schimmel für Erprobung Rapp-Methode 2021© iXtronics-Hajuveda

Der Schimmel ist mit sichtbarem Licht am besten erkennbar. Bei UV-Beleuchtung sieht man den Staub im vorderen linken Teil der Figur recht gut. Im hinteren Grund wird der Schimmel überstrahlt und das Bild nach der Rapp-Methode lässt keinen Schimmel erkennen (wobei die Ausleuchtung nicht optimal war).

Abbildung 30 zeigt die Situation an der Figur:




Abbildung 30 Helena-Altars Figur mit Schimmel für Erprobung Rapp-Methode 2021© iXtronics-Hajuveda

Bei allen drei Methoden ist der Schimmel gut erkennbar. Bei Beleuchtung mit UV scheint die Strahlkraft größer zu sein. Die Rapp-Methode scheint etwas besseren Kontrast zu haben.

Auf der Rückseite des Altars zeigt Abbildung 31 folgendes Bild:




Abbildung 31 Rückseite des Altars mit Schimmel für Erprobung Rapp-Methode 2021 © iXtronics-Hajuveda

Die Rückseite des Altars ist mit einer Hartfaserplatte beschlagen. Bei Anstrahlung mit sichtbarem Licht von vorne ist die Erkennung des Schimmels schwierig. Im Streiflicht ist es deutlich besser. Bei UV-Bestrahlung ist der Schimmel deutlich erkennbar. Bei der Rapp-Methode stellt sich kein Vorteil heraus.

Insgesamt gesehen hat die Rapp-Methode keine Vorteile gegenüber den anderen Beleuchtungen mit einfachem sichtbarem Licht oder UV-Lampe bei *Aspergillus Glaucus*. Das bedeutet nicht, daß es andere Schimmelarten gibt, wo die Methode signifikant besser ist. Aber aufgrund der hohen damit verbundenen Kosten wird dieser Weg nicht weiterverfolgt.

### 2.4.5 Schlußfolgerungen zur Beleuchtung

Als Lichtquellen werden UV-C und IR gestrichen. Sie bringen keine besseren Erkenntnisse.

UV hat in manchen Fällen bessere Ergebnisse als VIS. Die Bilder, die mit UV gemacht wurden, gehen daher mit ins Training der neuronalen Netze ein. Die Kosten für eine UV-Beleuchtung für die Schimmelkamera sind sehr hoch. Dafür muß eine Platine entwickelt werden, um die einzelnen UV-Dioden anzulöten. Bei der anstehenden eher geringen Stückzahl wird die Entwicklung des Layouts und die insbesondere auch die Fertigung von Einzelstückzahlen so teuer, dass der angestrebte Kaufpreis von unter 1000 € nicht mehr gehalten werden kann. Daher wird auf die UV-Beleuchtung verzichtet. Die Lösung für eine Lichtquelle im sichtbaren Bereich kann auf Standardbauteile zurückgreifen und ist daher sehr preiswert. Da die Ergebnisse bei sichtbarer Lichtquelle überall ausreichen, wird daher diese Lösung favorisiert.

## 2.5 Programmierung der Algorithmen

Die Aufgabe der Algorithmen wird in folgende Teilschritte zerlegt:

- Erstellen der Datenbank für die Speicherung und Verwaltung der Fotos und Thermodat
- Zerschneiden der Fotos in kleinere Segmente von 200x200 Pixel
- Sortieren der zerschnittenen Fotos in Merkmalklassen



- Training der neuronalen Netze
- Programmieren eines Vorhersagealgorithmus für die automatische Auswertung der Schimmelkamera-Fotos
- Automatische Auswertung der Fotos und Warnung des Benutzers bei Schimmel

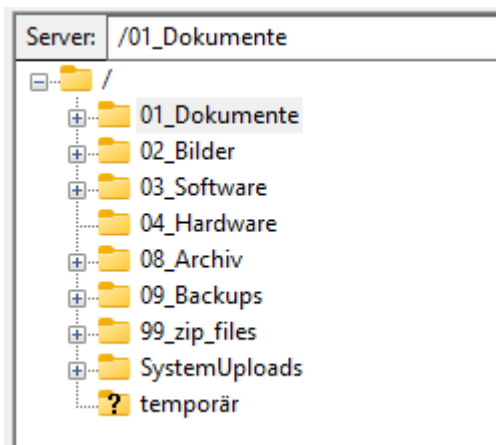
### 2.5.1 Einrichtung des FTP-Servers als zentrales Element der Kommunikation

Der FTP-Server (File-Zilla) ist die gemeinsame Basis, auf den alle internen und externen Stellen zugreifen können. Er ist bei iXtronics installiert.

Er erlaubt den Zugriff auf Daten von iXtronics intern.

Darüber hinaus erlaubt er externen Zugriff von lokalen Computern (bei Hajurveda), von lokalen Computern später beim Kunden, insofern der File-Zilla Client installiert ist und Benutzername und Passwort bekannt sind.

Die Schimmelkameras senden Daten zum Server und vom Server können Daten zu den Schimmelkameras gesendet werden.



Die Ordnerstruktur ist in Abbildung 32 gezeigt.

Im Dokumentenordner sind alle Dokumente gespeichert, die für die Bearbeitung des Projektes notwendig sind.

Bilder werden im Ordner 02 gespeichert.

Alle Skripte sind im Software-Ordner gespeichert. Die Programmiersprache ist Python.

Der Hardware-Ordner enthält die Details zur Schimmelkamera.

Der Archivordner und Der Backup-Ordner werden

für die Sicherheit der Daten benötigt.

Abbildung 32 Ordnerstruktur auf dem FTP-Server

Im System-Uploads Ordner befinden sich alle Kamerabilder und Thermodaten der unterschiedlichen Schimmelkameras im Feld.

### 2.5.2 Erstellung der Datenbank für die Speicherung und Verwaltung der Fotos und Thermodaten

Die Datenbank kann auf einem externen Rechner oder auf dem Server installiert werden. Hier wird das Vorgehen auf dem externen Hajurveda-Rechner beschrieben.

Die Installation der Datenbank ist im Detail in Anhang 3.2 „Installationsanweisung für die Schimmelkamera Custos Mucoris“ beschrieben.

Die für das Einlesen in die Datenbank vorgesehenen Fotos werden im Ordner: „custos\_original\_images“ gespeichert. Sie werden dann gepackt (gezippt) und mit einem bestimmten Namen versehen. Die Namensgebung der gezippten Datei erfordert folgendes Format:

Ort\_Bauwerkname\_Objekt\_Objektnamen\_Traeger\_Person\_Beleuchtung\_Spektralbereich  
Die „Underlines“ sind wichtiges Merkmal für die Datenbank zur Zuordnung der Bilder zu den Feldtypen der Datenbank.

Ein Beispiel für die Namensgebung ist wie folgt:

Herdecke-Kirchende\_Dorfkirche\_Orgelkanzelaltar\_Kanzelkorb\_wood\_Helena-Dick\_LED\_VIS

Damit wird der Standort, der Name der Kirche, das Objekt, der Name des Objektes, der Träger des Schimmels, die beteiligte Person, die Beleuchtungsart und der Spektralbereich der Beleuchtung identifiziert.

Als Datenbank wurde die MySQL Datenbank von ORACLE ausgewählt. Sie ist lokal gespeichert auf dem Hajurveda-Rechner.

Die Datenbank enthält über 20 Feldgrößen. Sie sind in Abbildung 33 gezeigt.

```
322 #.....#
323 # function: generate data base table
324 #.....#
325
326 def generate_db_table(db_table_names):
327
328     image_list = (
329         " `ID` int NOT NULL AUTO_INCREMENT,"
330         " `site` varchar(64) NOT NULL,"
331         " `building` varchar(64) NOT NULL,"
332         " `object_type` varchar(64) NOT NULL,"
333         " `object_name` varchar(64) NOT NULL,"
334         " `substrate` varchar(32) NOT NULL,"
335         " `author` varchar(32),"
336         " `import_date` datetime NOT NULL,"
337         " `creation_date` datetime,"
338         " `image_name` varchar(128) NOT NULL UNIQUE,"
339         " `original_image_name` varchar(128) NOT NULL UNIQUE,"
340         " `memory_location` varchar(256) NOT NULL,"
341         " `focal_length` varchar(16),"
342         " `resolution` varchar(45),"
343         " `f_number` varchar(16),"
344         " `image_width` int,"
345         " `image_height` int,"
346         " `exposure_time` varchar(16),"
347         " `orientation` varchar(16),"
348         " `illumination` varchar(45),"
349         " `wave_length` varchar(45),"
350         " `GPSInfo` varchar(78),"
351         " `aufzaehlung` enum('M','F') NOT NULL,"
352         " PRIMARY KEY (`ID`)"
353
354     TABLES = {}
355     for (key, value) in db_table_names.items():
```

Abbildung 33 Definition der Feldgrößen im Skript 2020© iXtronics-Hajurveda

Die durch „Underlines“ spezifizierten Feldgrößen werden mit dem Filenamen direkt in die Datenbank eingetragen. Hinzu kommen Foto-spezifische Merkmale, die in den EXIF-Files abgespeichert sind.

Der Ablauf der automatischen Erstellung der Datenbank ist in Abbildung 34 gezeigt.

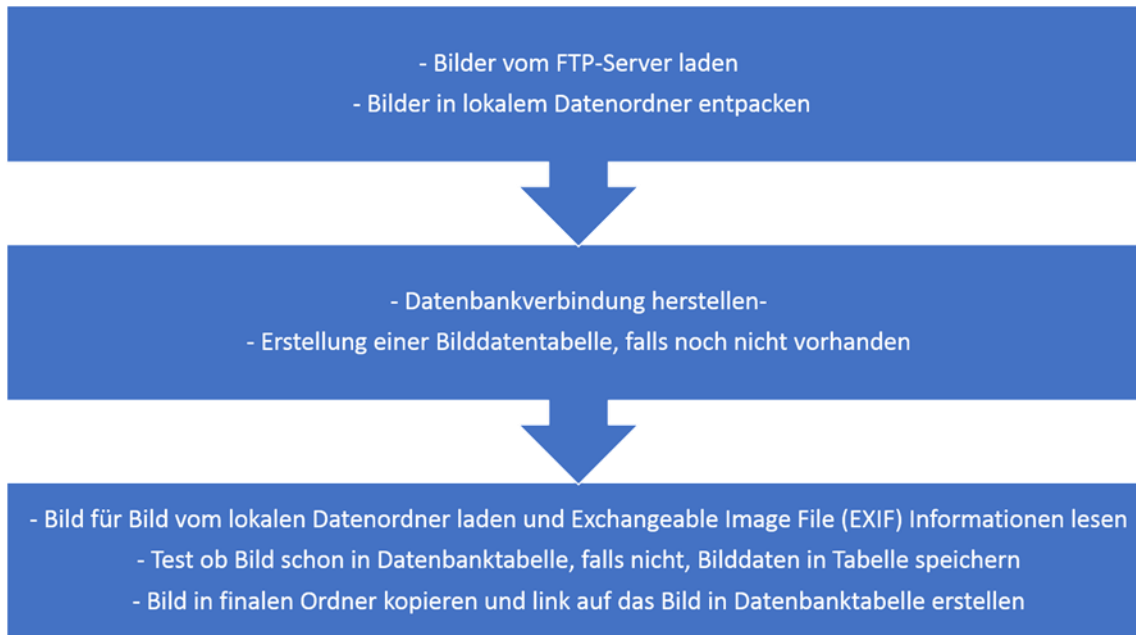


Abbildung 34 Datenbankprogrammablaufplan 2020© iXtronics-Hajuveda

Nach Start des Datenbank-Skriptes werden die gezippten Dateien eingelesen, mit den Zusatzinformationen verbunden und die Datenbank wird getrennt von den Bilddateien auf dem lokalen Hajuveda-Rechner gespeichert bzw. auf Wunsch auf den Server hochgeladen. Die Bilder selber bleiben auf dem Dateisystem des Servers bzw. lokalen Rechners und sind mit der Datenbank verlinkt. Diese Vorgehensweise, die Bilder nur mit der Datenbank zu verlinken, wurde gewählt, um den Datenbankinhalt auf die wesentlichen Informationen zu konzentrieren und nicht unnötig aufzublähen. Die Datenbank Zugriffe bleiben somit möglichst schnell und effizient.

Die Bilder werden nach Einlesen in die Datenbank mit neuen Namen versehen, die die wesentlichen Merkmale des Bildes beinhalten. Jedes Bild bekommt eine unverwechselbare Nummer und wird im Ordner: „custos\_data\_base\_original\_images“ lokal auf dem Rechner abgespeichert.

Das Filename-Format ist dann:

Ort\_Bauwerkname\_Objekt\_Traeger.Nummer

Wie z.B. Erwitte\_St.Laurentius\_Altar\_wood.1133

Der Ablauf der automatisierten Erstellung und auch der Zugriff auf Bilder und Informationen während des Trainings der neuronalen Netze ist in Abbildung 35 dargestellt:



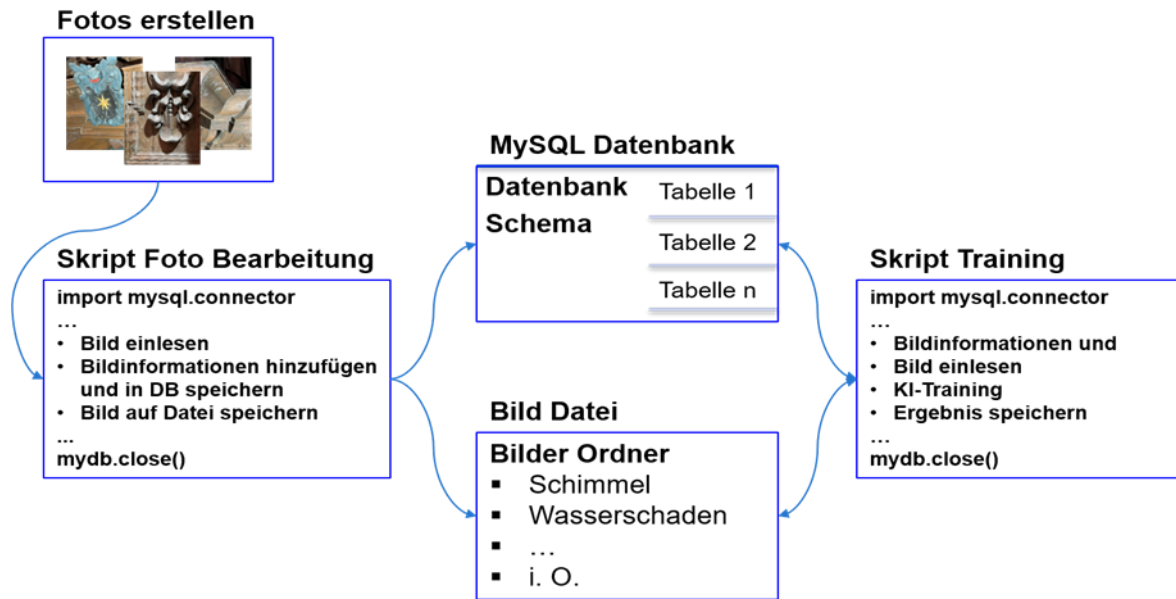


Abbildung 35 Ablauf der automatisierten Erstellung der Bilddatenbank 2020© iXtronics-Hajurveda

Im rechten Teil des Schaubildes ist der Zugriff auf die Datenbank und die Bilder in der Trainingsphase für die neuronalen Netze zu sehen.

Abbildung 36 zeigt eine gefüllte Datenbank.




Abbildung 36 Datenbanktabelle mit aktuellen Inhalten 2020© iXtronics-Hajurveda

## 2.5.3 Skript zum Zerschneiden der Fotos in kleinere

## Bildsegmente

Ziel ist es, dem neuronalen Netz beizubringen, wie Schimmel aussieht und wie etwas aussieht, dass nicht Schimmel ist.

Auf einem einzigen Bild kommen aber sehr viele Informationen vor:



Abbildung 37 Foto aus dem Xantener Dom mit mehreren Schadenmerkmalen 2020© iXtronics-Hajuveda

Es gibt daher zwei Gründe, die Bilder zu zerschneiden:

1. Erfordern die Algorithmen der neuronalen Netze ca. 256x256 Pixel, weil sonst die Rechenzeit exponentiell ansteigt.
2. Es dürfen möglichst nicht mehr als 2 Fehlerkategorien in einem Bild sein.

Für die Reduktion der Bilder wurde ein weiteres Skript entwickelt, welches die Bilder aus dem Ordner „custos\_data\_base\_original\_images“ einliest und auf eine vordefinierte Größe von 256x256 Pixel zerlegt. Die reduzierten Bilder werden mit ihrem Ursprungsnamen, erweitert um einen Index bestehend aus x- und y-Koordinate im Ordner



„custos\_splited\_images“ gespeichert.

Aus einem Kamerabild werden dann je nach Größe des Originalbildes 150 - 700 kleine Bilder. Die hohen Bildmengen ergeben sich für die Pro-Dateien, die im Handy eine Spezialfunktion haben. Hier werden die Rohdaten der Kamera ohne Komprimierung abgespeichert.

Die Namensgebung beinhaltet nun auch die Bildnummer und die Zeilen- und Spaltennummer

Abbildung 38 zeigt beispielhaft eine Auswahl an geschnittenen Fotos:


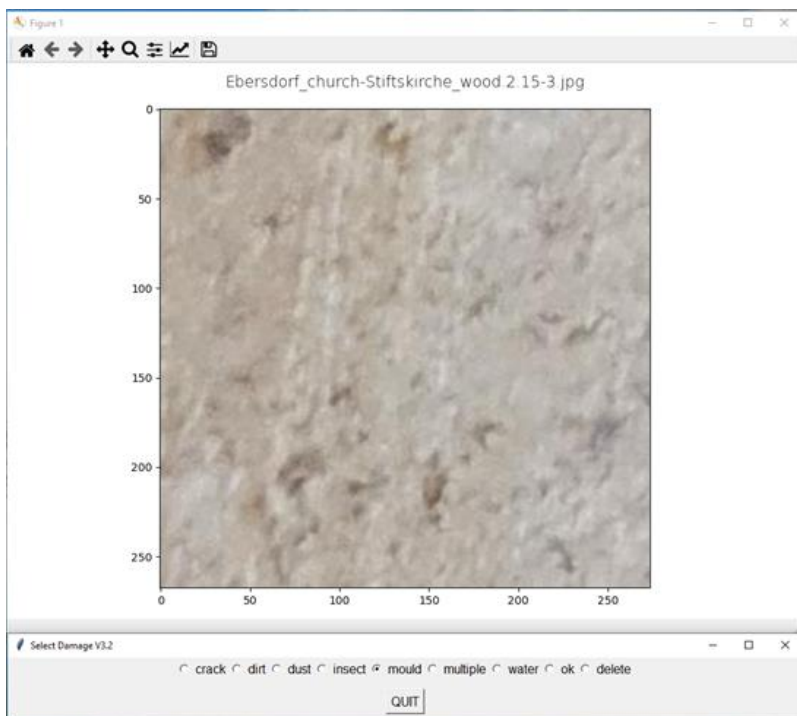


Abbildung 38 Beispiele geschnittener Bilder 2020© iXtronics-Hajuveda

## 2.5.4 Skript zur Sortierung der Bilder nach Schadensarten

Die Sortierung der Bilder nach Schadensarten ist ein Schlüsselement für das Gelingen des Trainings der neuronalen Netze. Hier erfolgt die Erkennung von Schadenarten durch den Menschen. Fehler, die der Mensch hierbei macht, finden sich nachher auch im Training der neuronalen Netze wieder und können dazu führen, daß die Erkennungsrate schlecht ist. Hinzu kommt, daß diese Erkennung Bild für Bild einzeln und manuell erfolgen muß. Bei aktuell 350000 geschnittenen Bildern im Ordner wird der Umfang dieser Arbeiten deutlich.



Um die manuelle Arbeit der Sortierung der Bilder nach Schadensarten zu unterstützen, wurde ein weiteres Skript erstellt, das die zuvor reduzierten Bilder einzeln aus dem Ordner in den Speicher einliest und auf dem Bildschirm darstellt. Es wurde ein Auswahlménü programmiert, in dem die Schadensart zum angezeigten Bild ausgewählt werden kann (Abbildung 39). Das Bild wird nach der Auswahl in den Ordner „custos\_inspected\_images“ in einen Unterordner mit dem Namen der Schadensart gespeichert.

Abbildung 39 Oberfläche des Programms zur Schadenseinteilung 2020© iXtronics-Hajuveda

## 2.5.5 Skript für die Erstellung und das Training der Convolutional Neural Networks (CNN)

Das Training der CNN ist das Kernstück des Projektes. Hier soll dem Algorithmus beigebracht werden, zwischen Schimmel auf den Oberflächen und keinem Schimmel auf den Oberflächen (im Folgenden mit „ok“ bezeichnet) zu unterscheiden.

Die künstliche Intelligenz ist ein äußerst komplexes Thema, bei dem es schwierig ist zu vermitteln, was dort überhaupt passiert. Daher wird in diesem Kapitel versucht, eine Analogie zum menschlichen Sehen und Verstehen herzustellen.

Wenn ein Baby das erste Mal die Augen aufmacht, sieht es viele verschiedene Gegenstände:



*Abbildung 40 Baby in der Lernphase 2020© Pixabay*

Die Netzhaut mit über einer Millionen Pixeln überträgt diese Bilder über den Sehnerv zum Sehzentrum in der Großhirnrinde.



*Abbildung 41 Netzhaut mit über 1 Millionen Pixeln 2020© Pixabay*

Das Baby kann aber noch nichts damit anfangen.





Erst durch überwachtes Lernen von den Eltern ergibt sich eine Verknüpfung von dem Gesehenen mit verstandenen Begriffen.

Erst nach sehr langem Lernen versteht das Kind den Satz: Gehe zum Tisch, setze Dich auf den Stuhl und trink ein Glas Milch

Abbildung 42 Überwachtes Lernen 2020© Pixabay

Ermöglicht wird dies durch Neuronen im Gehirn (grün gezeichnet).

Neuronen sind die Schaltzentralen zur Weiterleitung von Informationen.

Unser Gehirn besteht aus ca. 100 Milliarden Nerven-zellen, die mit über einer Trillion Synapsen miteinander verbunden sind.

Abbildung 42 zeigt schematisch die Analogie zwischen Gehirn und Computersimulation.

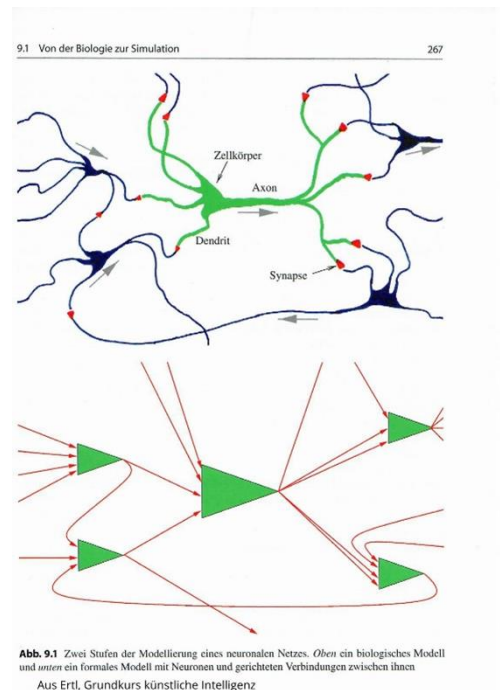


Abbildung 43 Von den Neuronen zur Simulation 2020© Ertl

Die Verbindung zwischen 2 Neuronen sind die Synapsen (rote Rechtecke).

Die Übertragung der Spannungsimpulse von einem Neuron zum anderen kann in den Synapsen mehr oder weniger gut erfolgen (also die Leitfähigkeit ändern)

Synapsen, die viel benutzt werden, haben eine höhere Leitfähigkeit.

Synapsen, die wenig oder gar nicht benutzt werden, können sogar sterben.




Abbildung 44 Synapsen verbinden Neuronen miteinander 2020© Ertl

Neuron  $i$  erhält von Neuronen  $x_1 \dots x_n$  Spannungsimpulse

Jeder hereinkommende Impuls wird mit der Übertragungs-gewichtung der Synapsen  $w_{ij}$  multipliziert.

Alle Spannungswerte werden dann aufaddiert

Ist die Summe größer als ein bestimmter Schwellwert, feuert das Neuron  $i$

Ansonsten feuert es nicht.




Abbildung 45 Struktur eines formalen Neurons 2020© Ertl

In Abbildung 46 wird beispielhaft der Weg von der Biologie zur Computersimulation dargestellt.

Das Auge hat ca. 1 Millionen Sehzellen. Das Ergebnis jeder Sehzelle wird 1 Million Eingangsneuronen mitgeteilt. Diese Informationen werden nun über ca. eine Trillionen Synapsen mit der Leitfähigkeit  $w_{i,j}$  an die 100 Milliarden Neuronen in unserem Gehirn übertragen. Diese schalten wiederum weiter zum nächsten Satz an Neuronen. Dies wiederholt sich bis zur Ausgangsschicht. In der Ausgangsschicht stehen dann unsere Begriffe mit der bewussten Wahrnehmung von Tisch, Stuhl, Glas, ....

- 1 Mio Sehzellen 
- 1 Millionen Neuronen in Leit-Eingangsschicht
- Trillionen Synapsen mit Leitfähigkeit  $W$
- 100 Milliarden Neuronen 
- Trillionen Synapsen mit Leitfähigkeit  $W$
- 100 Milliarden Neuronen 
- Überwachtes Lernen 

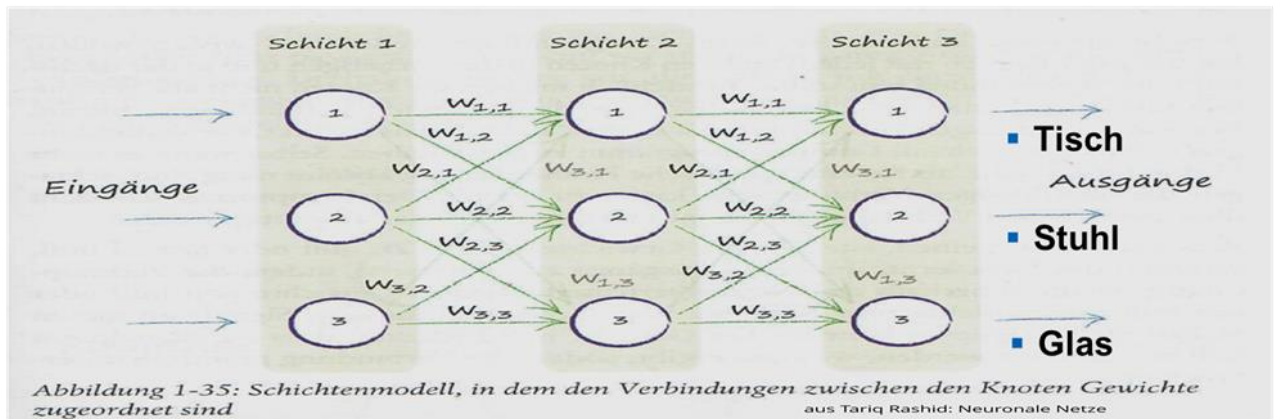



Abbildung 46 Von der Biologie zur Computersimulation 2020© Rashid

In Abbildung 47 wird versucht, diese biologischen Vorgänge in die Vorgänge am Computer zu übertragen. Dargestellt wird ein neuronales Netz (NN) anstatt des Convolutional NN (CNN), um die Komplexität nicht noch unnötig zu erhöhen. Die erwähnten Zahlen sind beispielhaft:




- 20 Mpixel 
- Zerschnitten auf 256x256 Pixel = 62500 Neuronen
- 4 Milliarden Synapsen
- 62500 Neuronen
- 4 Milliarden Synapsen
- 62500 Neuronen
- Überwachtes Lernen 

Abbildung 47 Darstellung des CNN im Schimmelprojekt 2020© Rashid-iXtronics-Hajuvda



Als Eingang dient das Bild der Kamera mit ca. 20 MPixeln oder weniger, je nach Komprimierung, die in den einzelnen fotografischen Einheiten durchgeführt wird. Diese Bilder werden zerschnitten auf 256x256 Pixel-Bilder, um den Anforderungen der Algorithmen gerecht zu werden und um möglichst nur ein Fehlerbild im Foto zu haben. Diese 256x256 Pixel-Informationen werden dann auf 62500 Eingangsneuronen geschaltet und über die Synapsen auf die nächste verdeckte Neuronenschicht übermittelt. Dies wiederholt sich noch einmal bis zur Ausgangsschicht, in der die Begriffe Schimmel, Staub, ok mit ca. 3 Ausgangsneuronen bereitgestellt werden. Zu jedem Bild, was vorne eingegeben wird, wird der Inhalt des Bildes als überwachtetes Lernen dem Endergebnis des Durchlaufes mitgeteilt.

Im Projekt werden immer nur 2 Merkmale trainiert: Schimmel und ok, Staub und ok oder Schimmel und Staub. Das Training auf 3 Merkmale gleichzeitig würde die Computerleistung übersteigen und den Zeitrahmen des Projektes signifikant überschreiten.

Für die Bildverarbeitung werden neuronale Netze um eine weitere Eigenschaft (Faltung) ergänzt.

Das Eingangsbild wird stufenweise gefiltert und in seine Merkmale von einfach bis komplex zerlegt.

Das neuronale Netz identifiziert aus den komplexen Merkmalen das Eingangsbild. Abbildung 48 zeigt die Struktur eines CNN. Auf weitere Details hierzu wird verzichtet, weil es nur die Komplexität erhöht, ohne zum Verständnis näher beizutragen.

Beispiel: Bild einer Katze




Abbildung 48 Struktur von CNN 2020© NN

Das CNN basiert auf dem sogenannten Inception\_V3 CNN-Modells. In unserem Fall wurde jedoch nur der Detektionsteil des Inception\_V3 CNNs, zur Bilderkennung verwendet. Die nachgeschalteten Identifikationsebenen des Projekt-CNNs wurden im Projekt neu aufgebaut.

Während des Trainings hat sich gezeigt das die mit dem Inception\_V3-Modelle mitgelieferten vortrainierten Modellgewichte im Projekt nur zu suboptimalen Ergebnissen führten. Daher wurde das komplette Modell neu trainiert. Das sind ca. 38 Millionen Parameter. In der aktuellen Skriptfassung werden ca. 38.650.337 Parameter berechnet, um zu einer Erkennungsgenauigkeit von 97% zu kommen.

Damit das Training in einem akzeptablen Zeitraum durchgeführt werden konnte, wurde über die Projektmittel ein neuer PC mit einer leistungsfähigen Grafikkarte angeschafft. Durch die Portierung des CNN-Trainings von der CPU auf die Grafikkarte (GPU) des neuen PCs ist es nun möglich eine Trainingsepoche mit ca. 4.000 Bildern in ca. 10 s auszuführen. Pro Epoche können bis zu 200 Durchläufe nötig sein und es können maximal 500 Epochen gerechnet werden. Erfahrungsgemäß ist aber das Training nach ca. 1 Stunde abgeschlossen. Wenn die Ergebnisse die geforderten 97% Erkennungsrate nicht erreicht, dann können mit Verwendung der vorherigen Gewichtsfunktionen auch schon einmal 10 Trainings erforderlich sein. Wenn das auch nicht reicht, hilft nur ein Neustart des gesamten Trainings bei gelöschter Gewichtsfunktion.

Die Bildererkennungsrate konnte durch viele Parametervariationen (beschrieben im nächsten Kapitel) von ca. 85 % auf nun über 97 % gesteigert werden. Abbildung 49 zeigt die Ergebnisse für die Erkennung von Staub- (dust) und Schimmelmerkmalen (mould). Für das Training standen jeweils 6000 Staub- und Schimmelbilder zur Verfügung. Die Validierung und der Test wurden mit jeweils 100 Staub- und Schimmelbildern durchgeführt. In diesem Fall wurde eine Erkennungsrate von über 99% erreicht.

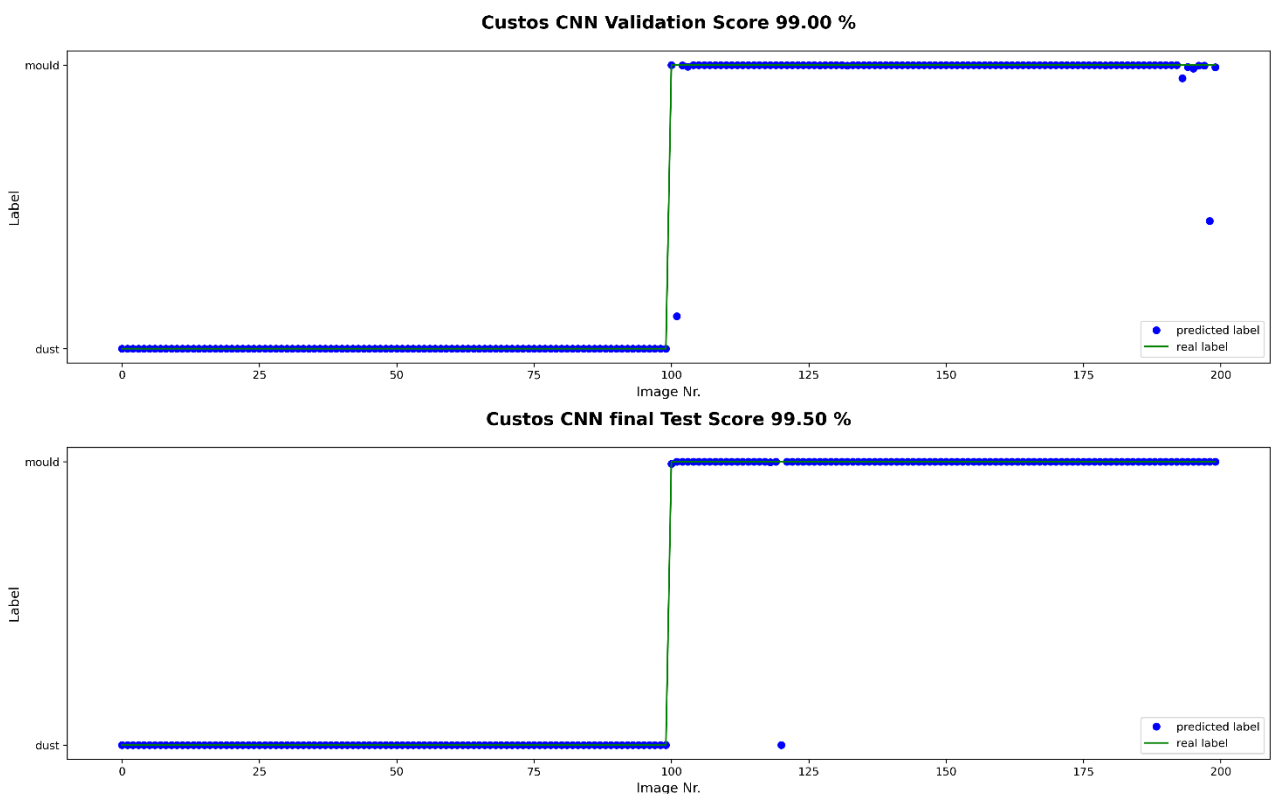


Abbildung 49 Ergebnisse der Validierungs- und Testphase des CNNs 2021© iXtronics-Hajuveda

Die Ergebnisse des CNN-Trainings zeigen sehr gut, dass eine Klassifizierung von Bildern mit dem gewählten CNN Netzwerk möglich ist.

## 2.5.6 Skript zur automatischen Erkennung des Merkmales: das Prediction Skript.

Wenn die Schimmelkamera später im Feld eingesetzt wird, dann werden am Anfang viele Bilder gesendet, die nur das Objekt darstellen, ohne daß bereits ein Schimmel vorliegt. Wenn aber der erste Schimmel entsteht, dann soll eine Warnmeldung an den Benutzer geschickt werden. Hierfür wurde ein Skript entwickelt, welches aufgrund des Bildes von der Schimmelkamera erkennt, ob Schimmel da ist oder nicht. Die Bilder werden im ersten Schritt geschnitten. Das Prediction Skript lädt dann die geschnittenen Bilder aus dem Ordner „custos\_prediction\_images“ und analysiert jedes einzelne Bild auf Schimmel oder „ok“. Als Ausgabe steht eine Datei oder ein Plot zur Verfügung, welche Auskunft darüber gibt, ob Schimmel zu sehen ist. Ist auf einem der Bilder Schimmel erkennbar, erfolgt eine Warnmeldung an den Benutzer.

Abbildung 50 zeigt beispielhaft Bilder, die in das Prediction Skript reingeladen werden:



Abbildung 50 Bilder für das Prediction Skript 2021© iXtronics-Hajuveda

Bild 1,2,3,4,11,12 sind Bilder ohne Schimmel, also „ok“.


Bild 5,6,7,8,9,10 sind Bilder mit Schimmel.

Nach Berechnung mit den durch Anlernen im Trainingslauf erfolgten Algorithmen erfolgt eine Alphanumerische Ausgabe wie folgt, wobei die Zahl 1 eine 100ige Erkennung von „ok“ anzeigt und die Zahl „0“ einen 100 %-ige Anzeige von Schimmel darstellt:

```
[[0.99354726]
[0.86766046]
[0.96342885]
[0.94881445]
[0.    ]
[0.    ]
[0.    ]
[0.    ]
[0.    ]
[0.    ]
```

[0.     ]  
[1.     ]  
[0.98834234]]

Ein einfacher Vergleich aller Zahlen in dieser Tabelle zeigt an, ob ein Schimmel erkannt wurde und löst dann eine E-Mail mit einer Schimmelwarnung an den Benutzer aus.



Der Plot in Abbildung 51 wird ebenfalls erstellt, um das Analyseergebnis schnell darzustellen.

Abbildung 51 Ergebnisplot aus dem Prediction Skript 2021© iXtronics-Hajuveda

## 2.6 Training der neuronalen Netze in der Praxis

Die praktische Arbeit mit den neuronalen Netzen umfasst folgende Aktivitäten:

- Bildbeschaffung
- Systematisierung des Anlernprozesses
- Durchführung der Trainings

### 2.6.1 Bildbeschaffung

Um möglichst viele Bilder von Schimmel an Kulturgütern zu erhalten, wurden insgesamt 5 Strategien verfolgt:

- Direktkontakt zum Xantener, Münsteraner und Kölner Dom und zum LWL
- Verschicken von kompletten Mappen mit VIPost und Projektpräsentation zu „wichtigen“ Leuten
- Mailing-Aktion an über 800 mit Kulturgut befassten Leuten
- Benutzung sozialer Netzwerke in LinkedIn und Xing



- Recherchen in Internet-Bilddatenbanken

Glücklicherweise konnte auf die Recherche in Internet-Bilddatenbanken verzichtet werden, weil über die anderen Maßnahmen genügend viele Fotos zusammengekommen sind. Leider hat sich von den „wichtigen“ Leuten keiner gemeldet.

Die anderen Aktionen waren aber sehr erfolgreich und mittlerweile liegen mehr als 4000 Fotos von Schimmel und/oder Staub vor, die insgesamt zu 350000 geschnittenen Fotos für die Selektion in Merkmalklassen führte. Das war für das Training der neuronalen Netze mehr als ausreichend.

Insgesamt gibt es mittlerweile 57 Unterstützer des Projektes, die im Anhang 3.4.1 namentlich genannt sind und regelmäßig über den Projektfortschritt informiert wurden. Darüber hinaus wurde das Vorhaben im Verband der Restauratoren publiziert.

Auch wenn allen Unterstützern großer Dank gebührt, so haben doch einige von Ihnen sich besonders aktiv beteiligt. Hierzu gehören Johannes Schubert vom Xantener Dom, Frau Goeddeker, Frau Friedrich und Herr Lemke vom Münsteraner Dom, Frau Wittstadt und Herr Distelrath vom Kölner Dom, Frau Graue und Frau Dick vom LWL, Herr Löther vom IDK-Dresden, Frau Meider vom Schimmellabor Urbanus, Herr Klumpp von Knowtion, Frau Hammer vom österreichischen Museum für Volkskunde, Frau Brozio und Herr Sturmfels vom VDR, Frau Heckenbücker und Herr Peez vom LVR und Frau Schmauch von Derix. Ohne deren aktive Unterstützung hätte das Projekt nicht so gut gelingen können.

Durch die Veröffentlichungen in Xing und LinkedIn konnten mittlerweile mehr als 500 internationale Follower gewonnen werden.

## 2.6.2 Aufbau der Bilddatenbank

Alle Fotos sind fest als Originalbilder lokal im Ordner „1\_Bilddaten\_Original\_nicht-löschen“ abgespeichert. Sie dürfen nicht gelöscht werden.

Mehrere manuellen Läufe sortieren nun Bilder schlechter Qualität aus:

1. Lauf: unscharfe Bilder werden gelöscht
2. Lauf: manuelle Formatänderung auf .jpg,

Der Grund hierfür liegt in der Profi-Einstellung des Handys, bei der 20 Mega-Pixel ohne Komprimierung gespeichert werden. Bei der normalen Einstellung ohne Profi-Version werden die Daten vom Handy selbständig komprimiert und der Algorithmus hierfür ist unbekannt. Oft reichen die komprimierten Bilder aus, aber wenn hohe Auflösung nötig ist, dann muss man auf die Profi-Bilder zurückgreifen. Diese müssen allerdings manuell in .jpg umgewandelt werden. Das ist sehr zeitaufwendig, lohnt sich aber wegen der höheren Schärfe. Benutzt wurde hierfür das Programm XARA Designer Pro.

3. Lauf: manuelles Ausschneiden unrelevanter Hintergründe (Wand, Boden, Fenster)

Der Grund hierfür liegt darin, dass später die Bilder geschnitten werden und einzeln manuell in Fehlerkategorien einsortiert werden. Hat man aber unrelevante Hintergründe auf dem Foto, dann müssen viele geschnittenen Bilder gelöscht werden. Der Aufwand ist erheblich.

Die nach den 3 Durchgängen verbleibenden Bilder werden lokal im Ordner

„2\_Bilddaten\_Original\_Qualität“ gespeichert.

Im Ordner „3\_Bilddaten\_Image\_to\_database“ werden dann alle Skripte (Programme) ausgeführt.

Ein Beispiel für Bilder in den Merkmalklassen ist in Abbildung 52 für Schimmel und in Abbildung 53 für Staub gezeigt.




Abbildung 52 Bilder in Merkmalklasse Schimmel 2021© iXtronics-Hajuveda




Abbildung 53 Bilder in Merkmalklasse Staub 2021© iXtronics-Hajuveda

Im Ordner „4\_CNN\_Training\_Ergebnisse“ werden die Ergebnisse der Trainings dokumentiert.

### 2.6.3 Ablauf des Trainings der neuronalen Netze

Die Zahl der für das Training benutzten Bilder ist beliebig. Einzige Einschränkung ist, daß die Zahl der Bilder in den Merkmalklassen „Schimmel/ok“, „Staub/o.k“ und „Schimmel/Staub“ gleich sein muss.

Es werden z.B. 2000 Bilder im Unterordner „Schimmel“ und 2000 Bilder im Unterordner „Staub“ gespeichert. Hinzu kommen jeweils je 100 Bilder für die Validierung und je 100 Bilder für den Test.

Wird das Skript zum Training der neuronalen Netze gestartet, dann liest das System Bild



für Bild für jede Merkmalsklasse ein. Gleichzeitig wird das Ergebnis „Schimmel“ oder „Staub“ mitgeteilt. In jedem Durchlauf, auch Epoche genannt, werden die Gewichtsfunktionen so abgeändert, daß bei jedem Bild „Schimmel“ auch das Ergebnis mit der angepassten Gewichtsfunktion das Wort „Schimmel“ zeigt. Ist das Ergebnis falsch, werden die Gewichtsfunktionen rückwärts angepasst. Bei jeder Epoche wird die Korrektheitsrate ermittelt. Sie gibt an, wie gut die Erkennungsrate für die einzelnen Bildmerkmale ist. Je höher der Wert desto besser die Erkennungsrate. 0 % bedeutet kein Bild wird erkannt, 100 % alle Bilder werden erkannt.

Nach dem ersten Durchlauf (Epoche) liegt der Wert bei etwa 90%. Diese Zahl bezieht sich auf die Erkennungsrate aller beliebig gezeigten Bilder mit Schimmel oder Staub.

Nun werden je 100 andere Bilder, die nicht im Training verwendet wurden, zur Validierung eingelesen. Beim ersten Durchlauf liegt die Erkennungsrate bei 87%.

Nun finden weitere Durchgänge (Epochen) statt.

Wieder werden die gleichen Trainingsbilder (anders gemischt und mit Datenaugmentation leicht verändert) gezeigt und die Korrektheitsrate steigt über 95% bis ca. 100% an.

Die Validierungsergebnisse (diese Bilder sind immer gleich) schwanken.

Es werden insgesamt maximal 32 Epochen durchgeführt und abgebrochen, wenn keine weitere Ergebnisverbesserung mehr erzielt wird.

Dann wird der Datensatz genommen, der das beste Ergebnis fuer die Validierung brachte. Hier z.B.: Datensatz 10




Abbildung 54 Custos CNN Korrektheitsrate für die Klassifizierung 2021© iXtronics-Hajuveda

Mit den Gewichtsfunktionen von Datensatz 10 werden nun ganz neue Bilder bewertet.

Je 100 dem System unbekannte Testbilder mit Schimmel und Staub werden eingelesen und die Abweichung im untenstehenden Bild dargestellt. Staub liegt bei Label 0 und Schimmel liegt bei Label 1. Es zeigen sich kleine Abweichungen, aber beide Klassen werden sehr gut erkannt. Die Prozentzahl gibt an, wieviele Bilder richtig erkannt wurden.






Abbildung 55 Custos CNN finales Testergebnis in Prozent 2021© iXtronics-Hajuveda

## 2.6.4 Ergebnisse der vielen Trainings

Die Vorstellung der vielen zeitintensiven Trainingsläufe ist mühselig und langweilig. Daher werden die Trainingsläufe im Anhang 3.4 detailliert beschrieben.

Da viele Parameter im Skript für das Training wählbar sind, wurde im ersten Abschnitt des Anhangs 3.4 systematisch untersucht, welcher Parametersatz für das Training die besten Ergebnisse liefert. Mit diesem Parametersatz wurden dann Trainings für die Erkennung von Schimmel/ok, Staub/ok und Schimmel/Staub mit 2000, 4000 und 6000 Bildern durchgeführt.

Da die Gewichtsfunktion zu Beginn eines Trainings mit Zufallswerten besetzt wird, war es erst einmal wichtig, herauszufinden, unter welchen Einstellungen am Schluß vergleichbare Ergebnisse erzielt werden können. Dabei stellte sich heraus, daß von einem Durchlauf zum nächsten die Gewichtsfunktion nicht gelöscht werden sollte. Damit setzt man bei jedem neuen Durchlauf auf die bereits optimierte alte Gewichtsfunktion auf und erzielt ein besseres Ergebnis. Letztendlich sollte man für den Einsatz im Prediction-Skript diejenige Gewichtsfunktion auswählen, die Bewertungszahlen für Validierung und Test von über 97 Prozent erreicht hat.

Abbildung 56 zeigt das beste Ergebnis für Schimmel/ok.

Schimmel wird immer richtig erkannt und 3 ok-Bilder werden dem Schimmel zugeordnet. Dies würde theoretisch zu 3 Fehlalarmen führen. Dabei ist zu bedenken, daß o.k. Bilder die ganze Welt repräsentieren und es ungleich schwieriger für die neuronalen Netze ist z.B. Bilder eines Baumes, einer Maschine oder eines Berges als o.k. zu erkennen. Schimmel hingegen wird aufgrund der recht eindeutigen Strukturen viel besser erkannt – hier zu 100%. Die Lösung des Problem es ist aber einfach. Im Feldtest beobachtet die Kamera ja Oberflächen, die keine Schimmel haben. Sie soll ja alarmieren, wenn der erste Schimmel kommt. Diese schimmelfreien Bilder werden für ein Nachtraining benutzt. Hierdurch kann die Erkennungsrate der schimmelfreien Oberfläche und des Schimmels auf nahe 100% gesteigert werden. Der Feldtest nachher zeigt aber, daß durch ein Nachtraining mit der zu beobachtenden Fläche die Erkennungsrate von Schimmel auf 100% gesetzt werden kann und keine Fehlalarme mehr entstehen.




Abbildung 56 mould\_ok\_32\_30 6000 run\_3\_0125 2021© iXtronics-Hajuveda

Abbildung 57 zeigt das beste Ergebnis für Staub/ok.  
Auch hier kommt es zu einem Fehlalarm.





Abbildung 57 dust\_ok\_32\_30 6000 run\_4\_0118 2021© iXtronics-Hajuveda

Abbildung 58 zeigt das beste Ergebnis für Schimmel/Staub mit ebenfalls einem Fehlalarm.




Abbildung 58 dust\_mould\_32\_30 6000 run\_3\_0212 2021© iXtronics-Hajuveda

Insgesamt liegen die Erkennungsraten alle über 97,5 %, was ein sehr gutes Ergebnis ist. Die Gewichtsfunktionen zu den einzelnen Bildern wurden für die Prediction Skripte abgespeichert.

## 2.7 Funktionstest des Prediction Skriptes

Um die Vorhersage-Qualität des Prediction Skriptes zu testen, wurden die in Abbildung 59 gezeigten Bilder ausgewählt:



Abbildung 59 Bilder für den Prediction Test 2021© iXtronics-Hajuveda

Und das Ergebnis ist in Abbildung 60 gezeigt. Dabei steht die 1 für ok und die 0 für Schimmel.






Abbildung 60 Ergebnis des Prediction Tests 2021© iXtronics-Hajuveda

Alle Bilder wurden richtig erkannt.

## 2.8 Erprobung des Prediction Skriptes am Schimmel auf Glas

Ohne Änderung der Gewichtsfunktionen wurde eine Sammlung von Schimmel auf Glas zur Erkennung in das Prediction Skript eingeladen. Die Bilder wurden von Derix, dem Kölner Dom und dem Xantener Dom bereitgestellt. Außerdem wurden 5 Bilder von „ok“-Oberflächen beigemischt.

29 von 31 Merkmalen wurden richtig erkannt. Das ist insbesondere deshalb bemerkenswert, weil auf Glasschimmelsorten nicht trainiert worden ist und der Schimmel beim Kölner Dom von einer mittelalterlichen Ornamentglasscheibe kam.

Abbildung 61 zeigt die untersuchten Bilder.




Abbildung 61 Erprobung des Prediction Skriptes bei Schimmel auf Glas 2021© iXtronics-Hajuveda

Eine Erkennungsrate von 94% ist insofern erstaunlich, weil auf diese Glasschimmelsorten nicht explizit trainiert wurde.

## 2.9 Feldtestphase mit den Anwendern

Ein erster Feldtest wurden im Xantener Dom durchgeführt. Ziel war es, zu untersuchen, ob das Controller-Kamera-Sensormodul in realistischer Umgebung hinreichend helles Licht hat, Fotos getaktet im Stundentakt macht, die Fotos über WLAN, Ethernet oder LTE-Stick direkt nach jeder Aufnahme in die Cloud schickt und die Sensordaten misst und überträgt. Die Länge des Sensorkabels spielte erstmal keine Rolle, da sie später im Dauerversuch auf den Altar oder die Orgel angepasst werden muß.



Der Feldtest wurde am Barbara Altar durchgeführt, weil hier noch Schimmel zu sehen war. Alle anderen Altäre wurden in der Zwischenzeit gereinigt. Abbildung 62 zeigt das Prüfobjekt.

Abbildung 62 Funktionstest in Xanten am Barbara Altar 2021© iXtronics-Hajuveda



Als Montage wurde eine Stativaufstellung (Abbildung 63) gewählt, die später aus ästhetischen Gründen so nicht umgesetzt werden kann. Für einen Funktionstest über 1 Nacht war das Motiv aber sehr geeignet.

Die Kamera wurde in etwa 25 cm Abstand vom Schimmelmotiv entfernt aufgebaut und ausgerichtet. Das Sensormodul hängt nur runter, weil es hier nur um einen Funktionstest am Objekt geht und noch nicht um exakte Messungen.

*Abbildung 63 Kamera auf Stativ montiert 2021©  
iXtronics-Hajuveda*

Der Gesamtaufbau ist in Abbildung 64 gezeigt:



Nach Scharfstellung wird über Tastatur und Maus das Aufnahmeprogramm gestartet, welches jede Stunde das Licht einschaltet und ein Foto macht. Nach dem Programmstart werden alle Kabel und Geräte abmontiert und die Kamera ist von nun autark. Jede Stunde wird ein Bild gemacht und dann über LTE in die Cloud gefunkt.

*Abbildung 64 Gesamtaufbau für den  
Funktionstest 2021© iXtronics-Hajuveda*

Abbildung 65 zeigt Kamera und Stativ ohne Zusatzgeräte:





*Abbildung 65 Gesamtaufbau ohne Zusatzgeräte 2021© iXtronics-Hajuveda*

Abbildung 66 zeigt ein Foto der Kamera vom Objekt etwa gegen Mitternacht. Die Fotos, die jede Stunde gemacht wurden, sind sehr ähnlich und ändern sich erst mit dem Anbrechen von Tageslicht.



*Abbildung 66 Kameraaufnahme vom Objekt um Mitternacht 2021© iXtronics-Hajuveda*

Der Funktionstest wurde erfolgreich abgeschlossen.



## **2.10 Bestimmung der Foto-Wiederholrate**

Um die Akku-Laufzeit nicht unnötig zu verkürzen, sollen die Bildwiederholraten möglichst so eingestellt werden, daß die Schimmelfeststellung zeitlich rechtzeitig erfasst werden kann, die Zahl der Bilder pro Zeiteinheit aber möglichst gering sein soll. Leider gibt es sehr wenig Informationen dazu, wie schnell der Schimmel in Kirchen wächst.

Da Temperatur und relative Feuchte im Nahfeld der Objekte gemessen werden, wäre es bei bekannter Schimmelart und zugehöriger Isoplethen möglich, die Zeiträume des Schimmelwachstums abzuschätzen und daraus die Wiederholfrequenz von Fotos abzuleiten. Dies war der erste Ansatz, der in den ersten beiden Kapiteln beschrieben wird. Ein weiterer Ansatz hat sich erst viel später ergeben. In St. Laurentius in Erwitte fand binnen eines Jahres eine Schimmelfeststellung statt. Hieraus lässt sich ein weiterer Ansatz für die Häufigkeit der Fotos machen. Beide Ansätze kommen annähernd zum gleichen Ergebnis.

### **2.10.1 Erfassung der vorliegenden Schimmelarten**

Bekannt sind 2 Gutachten zur Art des Schimmels aus Münster und St. Sebald in Nürnberg.

Das Gutachten aus St. Sebald /Drewello 2019/ identifiziert am Reliquienschrein des St. Sebald im Innenbereich Aspergillen aus dem *Aspergillus glaucus*-Komplex. Sie kommen ubiquitär vor und

können unter den unterschiedlichsten klimatischen Bedingungen überleben. Das gilt nicht nur für den Temperaturbereich (4°C bis 37°C; Optimum bei 24°C bis 25°C), sondern auch für die relative Feuchte. *A. glaucus* kann in trockener Umgebung nicht nur überleben, sondern auch wachsen. Ein weiteres Kennzeichen ist die Osmo Toleranz und die Verwertung verschiedenster Nährstoffquellen.

In Münster wurde der punktuell auftretenden Schimmelfeststellung der Astronomischen Uhr und des Hochaltars untersucht /Petersen 2011/. Es handelt sich um eine Besiedlung durch Vertreter der *Aspergillus glaucus* Gruppe. Diese Arten lassen sich in vielen Kirchenräumen als dominante Besiedlungsanteile feststellen. Da diese Vertreter zu den xerophilen Schimmelpilzen zu rechnen sind, sie sich also bei eher geringem Feuchteangebot entwickeln können, lässt ihr Vorkommen auch darauf schließen, dass die Lebensbedingungen für andere Pilze eher im Hinblick auf die verfügbare Feuchtigkeit noch nicht ausreichend sind. *Aspergillus glaucus* ist in der Lage auch auf sehr trockenen Substraten zu siedeln und zählt zu den xerophilen (trockenheitsliebenden) Schimmelpilzarten. Sie können bereits bei einem Aw-Wert von 0,65 bis 0,75 wachsen. Das Temperaturoptimum des Pilzes liegt zwischen 25 und 35°C; bei Temperaturen über und unter diesem Wert benötigt der Pilz höhere Materialfeuchten zum Wachsen. Pilze der *Aspergillus glaucus* Gruppe tolerieren laut Literatur bei entsprechendem aw – Wert Temperaturen zwischen 8 und 43°C. Als Substrat dienen den Pilzen an den Objekten in aller Regel Überzüge, Fassungen oder Pflegemittel oder häufig auch die organischen Bestandteile von Stäuben.

Im DBU-Abschlußbericht /DBU AZ 31242-45 Ursachen des Schimmelfestfalls an Orgeln 2018/ wurden detaillierte Untersuchungen zur vorkommenden Schimmelart in 50 verschiedenen Kirchen aus Mitteldeutschland durchgeführt. Dabei haben sich Schwerpunkte herauskristallisiert bei den folgenden Arten:

## Aspergillus Restrictus

Aus der Aspergillus Glaucus-Gruppe:

Eurotium amstelodamii

Eurotium herbariorum

Eurotium rubrum

Kulturen wurden hierfür angelegt, die im Bereich von 6 bis 26 Grad Celsius für bis zu 113 Tage Versuchsdauer in entsprechend eingestellten Klimaschränken durchgeführt wurden. Diese Arten entwickeln sich bereits bei geringem Feuchteangebot.

Die folgenden Bilder sind dem DBU-Bericht entnommen und zeigen die Koloniedurchmesser nach 28 Versuchs Tagen im Klimaschrank in Abhängigkeit vom aw-Wert (\*100=relative Feuchte) und der Temperatur, haben also ähnliche Aussagekraft wie die Isoplethen von Sedlbauer:




Abb. 18 Wachstumsintensität in Abhängigkeit von der Wasseraktivität




Abb. 19 Wachstumsintensität in Abhängigkeit von der Wasseraktivität




Abb. 20 Wachstumsintensität in Abhängigkeit von der Wasseraktivität




Abb. 21 optimale Wachstumstemperatur bei höheren Wasseraktivität




Abb. 22 Ausbildung unterschiedlicher Entwicklungsstadien in Abhängigkeit von Temperatur und Feuchte



Temperatur von 2 Grad Celsius erheblichen Einfluss auf das Wachstum des Schimmels haben. Insbesondere liegt selbst bei Temperaturen von 6 Grad Celsius bei entsprechender Feuchte Schimmelwachstum vor.

## 2.10.2 Untersuchung des Klimas im Xantener Dom

Beim Vergleich dieser Laborwerte mit Messwerten für die relative Luftfeuchte und der Temperatur fällt auf, daß in vielen Kirchen die erforderliche Mindestfeuchte von 75% nicht erreicht wird, aber trotzdem Schimmelprobleme vorliegen.

So ist es auch in Xanten. Glücklicherweise lagen hier Messdaten über einen Zeitraum von knapp 2 Jahren an der Rückseite des schimmelbefallenen Helena-Altars im Nahfeld des Altars vor. In Abbildung 67 sind fast 14000 Stunden Messdaten für die Temperatur und relativen Feuchte gezeigt.




Abbildung 67 Helenaaltar mit 14000 Stunden Messdaten für die Temperatur und relativen Feuchte 2021©  
iXtronics-Hajuveda

Um diese Daten auszuwerten, wurde ein Skript programmiert, mit dem diese Messdaten in Klassen zerlegt werden konnten. Für jede einzelne Klasse wurden dann die Zeiten bestimmt, für die die Klassenwerte eingenommen wurden. Somit konnte hier aufgezeigt werden, wieviele Stunden sich die Rückseite des Altars in einer bestimmten Klimazone befunden hat. Das Skript wurde so aufgebaut, daß in 10er, 5er oder 1er-Schritten ausgewertet wurde, d.h. die Temperatur wurde ausgehend von einem Basiswert um 10 Grad erhöht und dann wurde die relative Feuchte bei dieser Temperaturklasse um jeweils 10 % erhöht und die Zeitdauern für die jeweilige Klasse berechnet.

Abbildung 68 zeigt das Ergebnis für die 10er Schrittweite:

	A	B	C	D
1		Temperature [°C]	rel. Humidity [%]	Hours
2	0	10.0	30.0	154.98
3	1	10.0	40.0	652.15
4	2	10.0	50.0	1338.56
5	3	10.0	60.0	544.57
6	4	10.0	70.0	141.84
7	5	10.0	80.0	8.97
8	6	20.0	20.0	8.77
9	7	20.0	30.0	320.11
10	8	20.0	40.0	1626.97
11	9	20.0	50.0	3244.1
12	10	20.0	60.0	4731.86
13	11	20.0	70.0	626.51
14	12	30.0	60.0	134.95
15				

Eine relative Luftfeuchte von 80% bei einer Temperatur von 10 Grad C wird für knapp 9 Stunden eingenommen. Eine Luftfeuchte von 70% bei einer Temperatur von 10 Grad wird knapp 142 Stunden eingenommen und eine Luftfeuchte von 70% bei einer Temperatur von 20 Grad bei 627 Stunden. Vergleicht man dies nun mit den Wachstumsaktivitäten im Klimaschrank aus dem DBU-Projekt, so ergibt sich folgende Tabelle:

Abbildung 68 Aufenthaltsdauer in bestimmten Klimaklassen am Helenaaltar 2021 © iXtronics-Hajuveda

	Relative Feuchte	Temperatur	Stunden	Tage	Höhe nach 28 Tagen Klimaschrank in mm	Rückgerechnete Höhe in Xanten in mm	Fotofrequenz-Empfehlung
Aspergillus Restrictus	80%	10 Grad	9	0,4	Nicht ablesbar		Nicht möglich
	70%	10 Grad	142	6	Nicht ablesbar		Nicht möglich
	70%	20 Grad	627	26	Nicht ablesbar		Nicht möglich
Eurotium rubrum	80%	10 Grad	9	0,4	Nicht ablesbar		Nicht möglich
	70%	10 Grad	142	6	Nicht ablesbar		Nicht möglich
	70%	20 Grad	627	26	Nicht ablesbar		Nicht möglich

Um eine genaueres Bild zu bekommen, wurde die Auswertung in 1er Schritten durchgeführt. Es gibt nur 2 Werte mit einer relativen Luftfeuchte von 76% und 77% bei einer Temperatur von 13 Grad mit einer Gesamtdauer von 0,5 Stunden. Mit sehr viel gutem Willen kann man aus den Labordaten hierfür einen Koloniedurchmesser von 1 mm ablesen. Dies gilt aber für 28 Tage, so daß sich hieraus ein Koloniedurchmesser in der Kirche von 1/1000 mm bei einer Dauer von 0,5 Stunden (oder 2 µm/h) errechnen lässt. Die Kamera erfasst im besten Fall bei einem Bildausschnitt von 50x50cm einen

Koloniedurchmesser von 150 µm. Daraus ergibt sich eine Dauer von 75 Stunden bis ein erkennbarer Schimmel vorliegt.

Dies entspricht rein rechnerisch einer Taktzeit von ca 3 Tagen.

Daten aus dem DBU-Abschlußbericht /DBU AZ 31242-45 Ursachen des Schimmelbefalls an Orgeln 2018/ zeigen aber, daß die Laborbedingungen in den Kirchen nicht oder nur kurzzeitig erfüllt werden. Trotzdem schimmelt es. Dies wird plausibel mit Sorptionsphänomenen erklärt. Gerade Gegenstände wie Holz können in Phasen längerer hoher relativer Luftfeuchte Wasser aufnehmen und speichern. Erhöht sich dann plötzlich die Temperatur, so senkt sich die relative Feuchte in Objektnähe nicht ab, sondern steigt. Das bedeutet, daß in dieser Situation hohe Luftfeuchte und hohe Temperatur auf der Holzoberfläche oder im klimatischen Nahfeld vorliegen, was das Schimmelwachstum begünstigt. Dies wurde eindrücklich mit einem wassergetränkten Fichten-Holzstück im Projekt nachgewiesen. Eine genauere Betrachtung der Situation in Xanten lässt diesen Effekt in der Übergangsphase von Sommer zur beginnenden Heizperiode auch erkennen. Abbildung 69 zeigt das vermutete Sorptionsverhalten.




Abbildung 69 Vermutung von Sorptionseffekten nach Beginn der Heizperiode 2021© iXtronics-Hajuveda

Die Luftfeuchte sinkt nach Einschalten der Heizung und steigt dann nach 2 Heizzyklen plötzlich und überraschend an. Wahrscheinlich ist dies auf das sorptive Verhalten der umgebenden Baumaterialien (Stein, Holz, Mörtel, Putz, usw.) zurückzuführen, die über den Sommer bei der hohen Luftfeuchte Wasser eingelagert haben. Die Luft wird nach Einschalten der Heizung schlagartig trockener, aber die umgebenden Bauteile machen das nicht mit. Sie geben ihre Feuchte dann langsam an die Umgebung ab. In diesem Moment liegen hohe Luftfeuchte und hohe Temperatur gleichzeitig am Altar an.

Die Hysterese der Heizung ist gut zu sehen. Der ständige Wechsel der Temperaturen im Heizungszyklus (Haifischzähne) von knapp 10 Grad und nach Abschalten von knapp 20 Grad und der relativen Feuchten von jeweils 10% bzw. knapp 20% sind für die Kulturgüter

alles andere als vorteilhaft. Ihre Wirkung auf Schimmel ist unbekannt.

Darüber hinaus hängt das Schimmelwachstum von weiteren Faktoren ab:

Bei einem pH-Wert von 5 haben die meisten Schimmelpilze ein Wachstumsoptimum /Meider, 2020/. Staub ist ein Wachstumsbeschleuniger wegen des organischen Gehalts und wegen der Möglichkeit Wasser zu binden. Manche Oberflächenbeschichtungen mit oder ohne Staubanhaftung können Wasser binden.

Aus all diesen Gründen sollte die rechnerische Taktzeit auf 1 - 3 Tagen festgelegt werden, da die Summe der Einflussgrößen unbekannt ist.

### **2.10.3 Abschätzung des Schimmelwachstums am Beispiel von St.Laurentius in Erwitte**

Das LWL in Münster macht regelmäßige Inspektionsbesuche bei gefährdeten Kirchen und hat es dem Projekt ermöglicht, daran teilzunehmen. Besonders interessant in diesem Zusammenhang sind Schimmel-Aufnahmen die auf der ersten Tour am 23.09.2020 und auf der zweiten Tour am 21.09.2021 gewonnen wurden.


In dieser Zeit ist das Schimmelwachstum in St. Laurentius in Erwitte explosionsartig gestiegen. Allein schon die Anzahl der Bilder spricht für sich: Während auf der ersten Tour 43 Fotos mit Schimmel gemacht wurden, sind es auf der Tour 2021 bereits 280 Fotos.

Abbildung 70 zeigt beispielhaft das Wachstum. Dabei war es etwas aufwendig, Bilder aus beiden Touren mit annähernd demselben Motiv zu finden. Das würde allerdings signifikant beim Einsatz eines stationären CustosMucoris-Systems verbessert. Auf der linken Seite befinden sich die Bilder aus 2020 und auf der rechten Seite die Bilder aus 2021. Mit dem bloßen Auge erkennt man den starken Anstieg der Flächen mit Schimmel.



Schimmel-Check vom 23.09.2020

Schimmel-Check vom 21.09.2021




### St. Laurentius in Erwitte - Schimmelexplosion in einem Jahr

Abbildung 70 Schimmelexplosion in einem Jahr in St.Laurentius in Erwitte 2021© iXtronics-Hajuveda Hajuveda



Abbildung 71 zeigt einige Beispiele, welche in 2020 noch keinen erkennbaren Schimmel hatten, in 2021 jedoch deutlichen Schimmelfall aufwiesen.

### **Am 21.09.2021 neu entdeckter Schimmel in St. Laurentius - Erwitte**



*Abbildung 71 Neu entdeckter Schimmel in St.Laurentius in Erwitte 2021© iXtronics-Hajuveda*

Diese Bilder legen auch nahe, im täglichen bzw. höchstens 3-Tages-Takt Aufnahmen zu machen. Im letzteren Fall kommen dann 120 Fotos zusammen. Zunächst wurde mit einer Taktzeit von 1 Tag gearbeitet. Gegen Ende des Projektes wurde die Taktzeit auf alle 3 Tage um Mitternacht geändert. Dieses ist hinreichend für die Analyse des Schimmelwachstums.

## Objektivierung des Schimmelwachstums

Das Verfahren wird in Kapitel 2.15 näher erläutert, aber hier vorab schon einmal angewandt.

Dabei wurde aus Abbildung 70 die 3. Zeile mit dem hölzernen Hintergrund ausgewählt. Beide Bilder alt und neu – also mit Bezug auf das Beobachtungsjahr 2020 und mit einem Jahr Abstand 2021 – wurden geschnitten und in das Prediction-Skript geladen.

Für die Auswertung erhält man vom Programm das Ergebnis der Gesamtzahl der geschnittenen Bilder und die Zahl der Bilder, auf denen Schimmel erkannt wurde. Daraus lässt sich ein Flächenprozentanteil berechnen, der angibt auf wieviel Prozent der Fläche Schimmel vorliegt.

Das Ergebnis ist in Abbildung 72 zu sehen:

### St.Laurentius in Erwitte Schimmelaufkommen

**23.09.2020**



**21.09.2021**



**Flächenprozentanteil**

**Schimmel = 5 %**

**Flächenprozentanteil**

**Schimmel = 28 %**

*Abbildung 72 Flächenprozentanteil zur Quantifizierung des Schimmelwachstums 1 Jahr 2021© iXtronics-Hajuveda*

Diese Auswertung zeigt, daß es möglich ist, den Flächenanteil, der mit Schimmel vorliegt, zu quantifizieren. Die Zahlen werden noch nicht ganz stimmen, weil die Ausleuchtung unterschiedlich ist (Überstrahlte Flächen sind immer Fehlerquellen), weil die Ausschnitte nicht exakt dieselben sind und geometrischen Abstände nicht dieselben sind. Bei solch einem positiven Ergebnis wäre es jedoch wünschenswert, eine stationäre Kamera zu installieren, um reproduzierbare geometrische und Lichtbedingungen zu haben und dann die Ergebnisse zusammen mit dem LWL und deren Lumitester Analysen zu korrelieren.



## 2.11 Feldtest in Xanten

Für den Feldtest wurde ein Altar ausgesucht, der vor kurzem gesäubert worden ist, wo aber noch abgewaschene Schimmelspuren zu sehen sind. Es bestand die Hoffnung, noch während der Projektlaufzeit einen Schimmel darauf erkennen zu können.

Die Kamera wurde hier über Gewindestangen an einer Dachlatte aufgehängt, die oben auf den Altar aufgelegt wurde und auf der anderen Seite in die Säule verkeilt war. Der Sensor wurde über eine Kabel-Verlängerung mit einem Klebepad direkt an der Rückseite des Altars positioniert. Es ist in ca. 5 m Höhe montiert. Abbildung 73 zeigt den Aufbau.

Das System liefert jeden Tag um Mitternacht ein Bild und die zugehörigen Thermodaten.



Abbildung 73 Feldtest System Xanten 2021© iXtronics-Hajuveda

Abbildung 74 zeigt eines der vielen Kamerabilder, auf dem auch die Abwischspuren deutlich erkannt werden.



*Abbildung 74 Kamerabild aus Feldtest System Xanten 2021© iXtronics-Hajuveda*

Mit den Kamerabildern aus dem Feld wurde dann ein Nachtraining der CNN-Algorithmen gestartet. Abbildung 75 zeigt dabei ein sehr gutes Ergebnis:




Abbildung 75 Nachtraining CNN mit Kamerabildern 2021© iXtronics-Hajuveda

Die Gewichtsfunktion wurde dann für eine Vorhersage gespeichert. Dann wurden Bilder zusammengestellt, die das Prediction Skript erkennen sollte.

Die Bilder sind in Abbildung 76 zu sehen und Abbildung 77 zeigt dann die 100%ige Erkennungsrate.



Abbildung 76 Kontrolle des Prediction Skripts aus Feldtest Xanten 2021© iXtronics-Hajuveda






Abbildung 77 Ergebnis der Kontrolle Prediction Script 2021© iXtronics-Hajuveda

Das Label 0 steht für Schimmel und das Label 1 für o.k.  
 Alle Bilder wurden richtig erkannt.

Bei einem Test mit dem Kamerabild Nr. 1359 ohne Schimmel (das ist das Bild aus  
 Abbildung 74) wurden alle Teilbilder mit Label 1 richtig erkannt.

Während der Laufzeit des Projektes entstand kein Schimmel in Xanten. Daher wurden 3  
 Schimmelbilder in das Kamerabild per Bildbearbeitung eingebaut. Ein Ausschnitt aus den  
 geschnittenen Bildern ist in Abbildung 78 gezeigt.




Abbildung 78 Xanten montierter Schimmel Ausschnitt 2021© iXtronics-Hajuveda

In Abbildung 79 ist das Ergebnis des Prediction Skriptes gezeigt.




Abbildung 79 Xanten Ergebnis Prediction Skript 2021© iXtronics-Hajuveda

Insgesamt wurde auf 6 Bildern Schimmel erkannt. Es wurden zwar nur 3 Bilder montiert, aber durch das Schneiden erscheinen dann kleine Randbereiche noch in anderen geschnittenen Bildern. Daher wurde 6-mal Schimmel erkannt. Letztendlich spielt es aber keine Rolle, denn sobald einmal Schimmel auf einem der Bilder erkannt wird, erfolgt eine Meldung an den Benutzer.

## 2.12 Feldtest in Münster

Im Münsteraner St-Paulus-Dom war die Hans-Klais Orgel vor einigen Jahren bereits Gegenstand einer Schimmelsanierung. Der Aufstellungsort scheint ungünstig zu sein. Dort wurde für den Feldtest ebenfalls eine Schimmelkamera installiert. Wegen neuem Schimmel im Umfeld des Aufstellungsortes wurde eine Position gewählt, die auf unverschimmeltes Holz ausgerichtet ist.

Abbildung 80 zeigt die sehr staubige Umgebung des Aufstellungsortes. Staub ist ein idealer Träger für Schimmel.




Abbildung 80 Feldtest System Münster 2021© iXtronics-Hajuveda

Abbildung 81 zeigt dann ein Bild der Kamera vom Versuchsobjekt.




Abbildung 81 Kamerabild aus Feldtest System Münster 2021© iXtronics-Hajuveda

Mit einer Serie von Bildern, die jede Nacht um Mitternacht aufgenommen wurden, konnte dann ein Nachtraining der CNN auf diese Oberfläche stattfinden. Das gute Ergebnis ist in Abbildung 82 gezeigt.




Abbildung 82 Erkennungsrate mit Nachtraining der Münsteraner Oberfläche 2021© iXtronics-Hajuveda

Es fand eine Kontrolle mit dem Prediction Skript statt, welches zu 100 % richtig war.

Im Umfeld des Aufstellungsortes waren bereits Schimmelspuren auf gleichem Träger zu



sehen. Abbildung 83 zeigt ein Foto hiervon.



*Abbildung 83 Münster Feldtest benachbarte Platte mit Schimmel 2021© iXtronics-Hajuveda*

Das Bild wurde in die Datenbank eingelesen und geschnitten. Abbildung 84 zeigt die

geschnittenen Bilder.



Abbildung 84 Münster Feldtest Geschnittene Bilder für benachbarte Holzplatte 2021© iXtronics-Hajuveda

Abbildung 85 zeigt die erkannten Bilder mit Schimmel.




Abbildung 85 Münster Feldtest Erkennung Schimmel Prediction Skript Nachbarwand 2021© iXtronics-Hajuveda

Schimmel befindet sich beim Wert 0. Damit werden die letzten 4 Bilder als Schimmel erkannt und das erste und letzte Bild in der 2. Reihe. Die Erkennung ist 100% korrekt. Bei

den letzten beiden Bildern handelt es sich um Schimmel in der Kontaktnaht.

## **2.13 Schimmeluntersuchung im Kölner Dom**

Zunächst möchte das Projekt großen Dank an die Leitung des Kölner Doms und der Glaswerkstatt ausdrücken und für die Unterstützung des Projektes sehr danken.

Die erste Begehung fand am 06.07.2020 statt, um einen Eindruck von der Schimmel-Lage im Kölner Dom zu bekommen. Dabei lag der Fokus auf den Chor und den Chorumgang.

Abbildung 86 zeigt den Klaren Altar.



*Abbildung 86 Kölner\_Dom\_Klaren\_Altar\_2020© iXtronics-Hajuveda*

Im unteren Bereich wurden Flecken gesehen, die auf Schimmel hindeuten könnten. Abbildung 87 zeigt einen Einblick.





*Abbildung 87 Kölner\_Dom\_Klaren\_Altar Schimmel\_2020© iXtronics-Hajuveda*

Das Bild wurde geschnitten und im Prediction Skript verarbeitet. Die Flecken wurden nicht als Schimmel erkannt.

Abbildung 88 zeigt den 3-Königen-Altar.





Abbildung 88 Kölner\_Dom\_Drei\_Königen\_Altar 2020© iXtronics-Hajuveda

Im Gefach unter den Figuren wurden auf blauem Hintergrund Flecken entdeckt, die in Abbildung 89 gezeigt sind.



*Abbildung 89 eventuell Schimmel auf blau gefärbten Träger 2020© iXtronics-Hajuveda*

Auch diese Flecken konnten nicht als Schimmel im Prediction Script erkannt werden. Abbildung 90 zeigt ungefähr den gleichen Ausschnitt ein Jahr später.




*Abbildung 90 eventuell Schimmel auf blau gefärbten Träger 2021© iXtronics-Hajuveda*



Es haben sich keine wesentlichen Änderungen ergeben. Für spätere Vergleichszwecke wurden mehrere Bilder entlang des ganzen Altars gemacht.

Abbildungen 91 und 92 zeigen Fotos von Kreuzgang-Stationen. Auf den Figuren sind Flecken zu sehen, die sehr gut Schimmel sein könnten.



*Abbildung 91 Kölner Dom Kreuzgang Station 1 2021© iXtronics-Hajuveda*



*Abbildung 92 Kölner Dom Kreuzgang Station 2 2021© iXtronics-Hajuveda*

Beide Bilder wurden geschnitten und in das Prediction Skript übertragen. Es wurde kein Schimmel erkannt. Es sind daher tatsächlich Flecken unbekannter Herkunft.

Abbildung 93 zeigt eines der vielen Bilder einer Orgelbegehung im Oktober 2020.





Abbildung 93 Kölner Dom Orgel 2021© iXtronics-Hajuveda

Die Bilder ergaben viel Staub, aber keinen Schimmel. Trotzdem haben die Bilder für das Training der neuronalen Netze sehr geholfen.

Abbildung 94 zeigt ein mittelalterliches Ornamentglas, das in einem Depot des Nordturmes in einer verschlossenen Holzkiste aufbewahrt wurde. Die Glasrestaurierungswerkstatt hat eine Schadenanalyse vorgenommen. Dies geschah mit der Absicht, eventuell das hier entwickelte Verfahren auch oft Schadenbilder mittelalterlicher Gläser anzuwenden.

Allerdings wird die Situation als zu komplex erachtet, um diesen Weg zumindest im Rahmen dieses Projektes weiterzuverfolgen.



Abbildung 94 Kölner Dom mittelalterliches Ornamentglas 2020© KölnerDom

Tatsächlich konnte mithilfe des Prediction Skriptes der Schimmel erkannt werden. Dies wurde bereits in Abbildung 62 gezeigt.

Insgesamt gesehen konnten nach 3 Begehungen des Kölner Doms noch kein Schimmel erkannt werden.

## 2.14 Kleinste erkennbare Schimmelgröße

Aus dem Kreis der Unterstützer kamen mehrere Nachfragen nach dem kleinsten Schimmeldurchmesser, den die CNN erkennen können. Bei der Ermittlung der kleinsten erkennbaren Schimmelgröße hat das Schimmellabor Urbanus unter Leitung von Judith Meider starke Unterstützung geleistet.

Hier wurden Schimmelpilze der Gattung *Penicillium* und *Aspergillus Versicolor* für eine Züchtung vorbereitet. Von dort kamen im Laufe von 3 Tagen 3 Päckchen mit den 2 Schimmelpilzarten auf einer Nährlösung. Diese konnten dann für Wachstumsstudien benutzt werden.

Abbildung 95 zeigt eine Petrischale mit dem Schimmelpilz *Penicillium* nach 2 oder 3 Tagen Wachstum.






Abbildung 95 Schimmelpilz *Penicillium* in der Wachstumsphase 2021© iXtronics-Hajuveda

Zunächst wurden das Pilzwachstum mit Kamera und Handy ca. alle 2-4 Stunden fotografiert. Dabei konnten die Bilder mit der Schimmelkamera aussortiert werden, weil die VIS-Dioden starke Reflexe in den Petrischalen auslösten und daher nicht zu gebrauchen waren. Alle verwertbaren Fotos wurden mit dem Handy gemacht. Diese Fotos wurden dann geschnitten und in ein Training der CNN gegeben. Allerdings stand nur eine begrenzte Zahl von Fotos zur Verfügung, so daß die Auswertung nicht so gut wurde, wie mit den Fotos aus Kirchen.

Abbildung 96 zeigt das Trainingsergebnis immerhin mit einer Güte von 98/97% Erkennungsrate.




Abbildung 96 Training CNN mit Schimmelpilz *Penicillium* auf Nährlösung 2021© iXtronics-Hajuveda

Für die Erkennung der kleinsten möglichen Schimmelgröße wurden dann alle Bilder in ein Bildverarbeitungsprogramm geladen und dort vermessen, ausgeschnitten und in 1mm Klassen abgespeichert. Die erste untersuchte Klasse waren Schimmel mit 1mm Durchmesser. Abbildung 97 zeigt die geschnittene Bildfolge.




Abbildung 97 Erkennung der minimalen erkennbaren Schimmelgröße 2021© iXtronics-Hajuveda

Bild Nr. 1317 war bereits so klein ausgeschnitten, daß der Schneidealgorithmus nicht erforderlich war. Bild Nr. 1318 wurde geschnitten. Diese Bildsequenz wurde dann in das Prediction Skript geladen und brachte das Ergebnis in Abbildung 98.






Abbildung 98 Erkennung im Prediction Skript 2021© iXtronics-Hajuveda

Bild 1, 3 und 6 wurden als Schimmel erkannt. Bild 3 zeigt die Peripherie eines Schimmels. Dies wurde so auch trainiert. Daher kann die minimal erkennbare Schimmelgröße mit 1mm angegeben werden. Die Bilder mit größerem Durchmesser aus den Klassen 2 – 10 wurden dann logischerweise nicht mehr untersucht.

## 2.15 Quantifizierung des Schimmelwachstums

Dieses Modell wurde nun auch benutzt, um einen Versuch zu wagen, das Schimmelwachstum zu quantifizieren. Hierfür wurden Bilder an 4 aufeinanderfolgenden Tagen in das Prediction Skript eingeladen. Abbildung 99 zeigt diese Bildsequenz:



Abbildung 99 Bilder zum Schimmelwachstum in Tagen 2021© iXtronics-Hajuveda

Dann wurde die Zahl der Bilder mit erkanntem Schimmel in Bezug gesetzt auf die Gesamtzahl der geschnittenen Bilder pro Tag. Dabei wurde eine Grenze von 20% auf beiden Seiten definiert, d.h. daß alle Ergebnisse zwischen 0 und 0,2 als Schimmel bewertet wurden und alle Ergebnisse zwischen 0,8 und 1 als o.k. bewertet wurden.

Die folgende Tabelle zeigt das Ergebnis nach Schneiden der Bilder:

	<b>Bilder gesamt</b>	<b>Bilder Schimmel (&lt;0,2)</b>	<b>Bilder ok (&gt;0,8)</b>	<b>Bilder weder Schimmel noch ok</b>	<b>Prozentanteil Schimmel</b>
Tag 1	621	4	602	15	1
Tag 2	480	14	457	9	3
Tag 3	1181	213	915	53	18
Tag 4	506	141	345	20	28

Auch wenn der Algorithmus wegen ungenügender Zahl an Trainingsbildern noch nicht optimal ist, so kann doch hiermit nachgewiesen werden, daß eine Quantifizierung des Schimmelwachstums möglich ist.

## **2.16 Vorgehen nach Erkennen eines Schimmels mit der Kamera**

Ist der Betreiber dann vom System gewarnt worden, so kann er im ersten Schritt den Lumitester /PCE 20/ einsetzen, um sehr schnell eine Aussage zum Ausmaß des Schimmelbefalls zu machen.

### **2.16.1 Biolumineszenz-Schnelltest**

Ein wichtiges Hilfsmittel für einen Schnelltest ist der Lumitester, der in /Meier-Wolff 11/ beschrieben wird. Dieser Test macht sich die Biolumineszenz von Luciferin-Luziferase (Leuchtkäfer) zunutze. Mit Hilfe dieses Substrat-Enzym-Systems lässt sich das AMP und ATP aus Bakterien und Schimmelpilzen und anderen Mikroorganismen bestimmen. Luciferin wird durch das Enzym Luziferase unter ATP-Verbrauch zu AMP, Oxyluciferin und Kohlendioxid abgebaut. Das bereits vorhandene AMP wird durch das ebenfalls beigemischte Pyruvat vorab zu ATP umgewandelt. Die Stärke der Biolumineszenz ist dann ein Maß für die Gesamtzahl der lebenden und abgestorbenen Schimmelpilze. Dieser Test, der ursprünglich für das Gesundheitswesen und die Lebensmittelindustrie entwickelt wurde, fand ca. 2011 Eingang in den Bereich Kulturgut /Meier-Wolff 11/. Der Referenzwert, ab dem eine Oberfläche als sauber/nicht sauber zu bezeichnen ist, liegt hier natürlich höher und beruht auf Untersuchungen und Einschätzungen von Meier-Wolf.

In /Hammer 14/ werden anhand von Lumitester-Werten weitere Klassifikationen der Befalls Stärke und -beurteilung beschrieben. Diesen sind eine große Anzahl an Untersuchungen und Parallelmessungen mit anderen Methoden vorausgegangen. Mit diesem Verfahren kann der aktuelle Befall der Objekte und Räume und die Wirksamkeit von Maßnahmen zum Schutz der Kulturgüter nachgewiesen werden. Ausführliche Beispiele sind hier ebenfalls dokumentiert. Eine Bedienungsanleitung des Lumitesters adaptiert für den Bereich Kulturgut findet sich in /Hammer 15/. Wichtig bei diesem Verfahren ist, daß in wenigen Minuten ein Ergebnis vor Ort gewonnen wird. Mit einem

trockenen Teststäbchen (Swab) wird über eine definierte Fläche von 10 cm<sup>2</sup> gestrichen. Alles darauf vorhandene ATP (in lebenden Keimen) und AMP (in ruhenden und toten Keimen) wird mittels des Leuchtkäfer-Enzyms in flüssiger Lösung in Licht umgewandelt, welches innerhalb von 10 s am Lumitester in RLU (= relative light Units) ablesbar und quantifizierbar wird.

Anschließend steht dann die genaue Untersuchung in der Schimmelpilzanalytik an.

### **2.16.2 Schimmelpilzanalytik nach Judith Meider**

In der mikrobiologischen Analytik können grundsätzlich 2 Prinzipien unterschieden werden, die sehr gut in dem Buch von Judith Meider dargestellt werden /Meider 16/:

Mikroskopische Analysen und die Anzüchtung von Mikroorganismen auf Nährmedien.

Die mikroskopischen Analysen haben den Vorteil schnell zu einem Ergebnis zu kommen, können aber nicht alle Schimmelpilze namentlich benennen. Die Anzüchtung von Mikroorganismen auf Nährmedien hat den Vorteil, dass die einzelnen gewachsenen Arten taxonomisch (namentlich) bestimmt werden können. Nachteilig ist die längere Laborzeit für die Anzüchtung.

Proben können mit 3 Analysemethoden untersucht werden:

- Bestimmung der Gesamtzellzahl (GZ)
- Bestimmung der biochemischen Aktivität oder Stoffwechselaktivität (BA)
- Anzüchtung Kolonie bildender Einheiten (KBE)

Für die Bestimmung der Gesamtzellzahl (GZ) ist die Anfärbung der Mikroorganismen mit einem speziellen Farbstoff erforderlich. Dieser Farbstoff setzt sich an die DNA einer Zelle und markiert diese. Sie werden durch Fluoreszenz im Mikroskop sichtbar. Hierdurch können Schimmelpilzsporen, Myzel und Bakterien getrennt gezählt werden.

Für die Bestimmung der biochemischen Aktivität (BA) oder Stoffwechselaktivität wird die Einfärbung mit Fluoresceindiacetat (FDA) durchgeführt. Diese Methode gibt Auskunft darüber, ob lebende Zellen in der Probe vorhanden sind, also der Schimmel aktiv ist. Diese Untersuchung wird wiederum im Fluoreszenzmikroskop durchgeführt. Absorptions- und Emissionsspektrum von FDA sind in Abbildung 90 gezeigt.

## Fluoreszenzspektrum




Abbildung 100 Fluoreszenzspektrum Quelle Thermofisher

Für die Anzucht koloniebildender Einheiten (KBE) werden die Mikroorganismen auf einem Nährmedium (Agar) angezchtet. Schimmelpilze haben unterschiedliche Anforderungen an das Agar. Die keimfähigen Schimmelpilze, Sporen, Myzel Stücke keimen aus und bilden ein Myzel, welches wächst und für das menschliche Auge sichtbar wird. Das gewachsene Myzel wird als Kolonie bezeichnet. Sie werden nach einer Woche Wachstum ausgezählt und differenziert, um die Art des Schimmels zu bestimmen. KBE liefert der Analytik die besten Möglichkeiten, Schimmelpilze taxonomisch zu differenzieren. Auf dem Agar wachstumsunwillige Schimmelpilze werden aber nicht erkannt. Nachteilig ist, dass Ergebnisse erst eine Woche später vorliegen.

GZ, BA und KBE erfordern eine Verarbeitung des Schimmels in wässrigen Lösungen und auf Nährböden.

### 2.16.3 Reinigung von schimmelbefallenen Oberflächen

Vorgehensweise, Praxisbeispiele, Sanierungsvorschläge und Überwachung der Sanierung sind sehr gut in /Meider 16/ für Gebäude beschrieben.

Die Reinigung von schimmelbefallenen Oberflächen von Kulturobjekten wird detailliert von Astrid Hammer beschrieben /Hammer 17/, die in Ihrer Veröffentlichung auch konkrete Handlungsanweisungen für das Vorgehen gibt:

1. Erkennen
2. Handeln
3. Kontrolle



#### 4. Nachsorge / Prävention

### **2.17 Schlußwort und Ausblick**

Nach Abschluss des geförderten Projekts soll die Sensorplattform vermarktet und als Standardlösung für die Überwachung von Schimmelbildung im Markt etabliert werden. Potentielle Kunden sind neben Kirchen und Museen auch Architektur- und Ingenieurbüros, die im Umfeld der Bauphysik tätig sind.

Für die Vermarktung sind eine technische und eine kommerzielle Herangehensweise erforderlich:

Technisch muß das Hardwaresystem produktreif gemacht werden, was Maßnahmen zur professionellen Serienfertigung beinhaltet. Die Software ist so zu Ende zu entwickeln, daß benutzerorientierte Oberflächen entstehen. Als Zeithorizont hierfür wird das laufende Jahr für die Fertigstellung avisiert.

In dieser Zeit sind umfangreiche Marketingmaßnahmen erforderlich, um die Ergebnisse bzw. die Plattform in die Praxis zu überführen.

Hierzu gehört zuallererst die Konfiguration von Hard- und Software auf Produkt- und Dienstleistungsebene. So ist z.B. darzustellen, daß die Schimmelkamera mit WLAN-, Ethernet- oder LTE-Stick, mit oder ohne Akkus, mit oder ohne Montageelemente bestellt werden kann.

Auf der Dienstleistungsseite kann Unterstützung bei Installation und Einweisung, kann die Vermietung der Plattform oder eine komplette Dienstleistung von der Installation bis zur fachmännischen Begleitung der Ergebnisse über die Schimmelerkennung hinaus für den Nutzer dargestellt werden. Es ist auch möglich, eine Dienstleistung auf Basis von vom Kunden selbstgemachten Bildern und die nachfolgende Auswertung der Bilder mit dem Prediction-Skript anzubieten. Ganz wichtig dabei ist die Preisermittlung für die einzelnen Optionen, da der Preis und der Nutzen des Produktes über die Kaufneigung des Kunden entscheiden. Dies alles ist in einem ersten Schritt durchzuführen und soll dann auf einer eigenen Webseite dargestellt und mit Flyern/Prospekten und Preislisten begleitet werden.

Liegt das Basismaterial für die Produktdarstellung vor, können im nächsten Schritt noch während der Fertigstellungsphase von Hard- und Software noch in diesem Jahr konkrete Maßnahmen für die Breitenkommerzialisierung ergriffen werden.

Hier sind zunächst die Dome von Münster, Xanten und Köln als mögliche Leuchtturmprojekte zu nennen. Aber auch aus Reihen der Unterstützer können weitere Vorzeigeprojekte eine Breitenwirkung erzeugen. Die Unterstützer haben nicht nur wichtige Fotos zum Gelingen des Projektes beigetragen, sondern auch aktiven Input geleistet:

So ist z.B. Thomas Löther vom IDK-Dresden sehr interessiert an der Anwendung der Technologie im Umkreis von Dresden.

Für das LWL wäre ein Pilotprojekt für die objektive Darstellung von Schimmelwachstum interessant.

Eine Zusammenarbeit mit Daniel Röseler vom Photolifter wäre sinnvoll, da beide Systeme direkt zusammenpassen.

Für St. Sebald wäre eine Kamera im Schrein zur Überwachung von Schimmelbildung sinnvoll.

Mit dem Schimmellabor Urbanus wäre eine breitere Vermarktung auch im nichtkulturellen Bereich für Wohn- und Geschäftsgebäude denkbar.

Diese o.g. Projekte sollen nun unmittelbar aktiv angegangen werden.

Neben diesen konkreten Projekten ist allerdings auch eine marktbreite Informationswelle erforderlich. Hierzu gehören direkte Mailingaktionen an über 2000 Adressen mit der Nennung von Links zu den selbst gestalteten Blogs, Webseiten und Präsentationen.

Videokonferenzen mit den Unterstützern in etwa 2 Wochen und Präsenzveranstaltungen im Sommer in Xanten sollen die neuen Möglichkeiten zur Schimmelerkennung verbreiten. Workshops für interessierte Nutzer sollen bei den Pilotprojekten noch in diesem Jahr stattfinden.

Falls Messen wieder stattfinden können, so ist eventuell auch an eine Beteiligung auf der „Monumento“ in Salzburg oder der Messe „Denkmal“ in Leipzig denkbar. Darüber hinaus finden 2 Vorträge auf dem „11. Forum for the Conservation and Technology of Historic Stained Glas 2022“ in Barcelona statt. Hier gibt es hervorragende Möglichkeiten des persönlichen Austauschs. Weitere Vorträge auf internationalen Kongressen sind sehr erwünscht, falls wieder Präsenzveranstaltungen stattfinden können.

Durch all diese Maßnahmen ist es beabsichtigt, im Laufe der nächsten Jahre bis zu 500 Systeme oder Dienstleistungen zu verkaufen.

Bzgl. der Verwertung sieht iXtronics auch große Chancen in der Anpassung und dem Vertrieb der Sensorplattformen für IoT-Projekte in der Industrie bei bestehenden und potenziellen Neukunden im Bereich „Predictive Maintenance“. Neben der Vermarktung der Projektergebnisse wird iXtronics durch das im Projekt weiterentwickelte KI-Know-how für neue Mitarbeiter aus dem akademischen Umfeld als Arbeitgeber noch interessanter und erlangt somit noch größere Möglichkeiten, hochqualifizierte Mitarbeiter für das weitere Wachstum des Unternehmens gewinnen zu können.

Perspektivisch werden die Chancen für eine Vermarktung des Produktes als sehr hoch eingeschätzt.

### **3 Anhang**

#### **3.1 Technische Daten des Raspberry Pi 4**

Der Raspberry Pi 4 verfügt über eine QuadCore Cortex-A72 CPU mit 4 Threads, 64-bit

SoC. Die Taktrate der CPU liegt bei 1,5 GHz und basiert auf der ARM v8 Architektur. Als Hauptspeicher kommen 4GB LPDDR4-3200 SDRAM zum Einsatz. Das System verfügt über alle benötigten Schnittstellen wie 2.4 GHz and 5.0 GHz IEEE 802.11ac Wireless Lan, Bluetooth 5.0, BLE sowie Gigabit Ethernet. Des Weiteren gibt es 2 USB 3.0 Ports sowie 2 USB 2.0 Ports zum Anschluss von Maus, Tastatur, LTE-Stick, weitere Peripherie Geräte. Einer der 4 USB-Ports wird benutzt, um einen externen Monitor zum Einstellen der Kamera-Schärfe am Objekt vor Ort mit Strom zu versorgen. Weiterhin besitzt der Raspberry Pi 4 einen 40Pin GPIO Header. Dieser wird benötigt, um zum Beispiel den Zeitschaltautomat anzuschließen. Der Temperatur und Luftfeuchtesensor wird auch an dem GPIO Header angeschlossen. Auch die LED-Sticks werden über diesen 40Pin Header angesteuert.

Weitere Bauteile können dann zukünftig auch von dem 40Pin Header angesteuert werden. Zum Anschluss von Monitoren verfügt er auch noch über 2 micro-HDMI Ports, die Übertragungen bis zu 4K bei 60Hz unterstützen. Unterstützte Codecs H.265 (4kp60 decode), H264 (1080p60 decode, 1080p30 encode).

Es werden auch Grafikprogrammierschnittstellen zur Verfügung gestellt. In diese Fall OpenGL ES 3.1, welches eine vereinfachte Version für eingebettete Systeme darstellt. Sowie die Vulkan 1.0 Schnittstelle, welche für die Entwicklung plattformübergreifender Anwendungen in 2D- und 3D-Grafik gedacht ist.

Für die ausgewählte HQ Kamera steht ein spezieller 2-lane MIPI CSI Camera Port zur Verfügung. Außerdem gibt es noch einen weiteren 2-lane MIPI DSI Anschluss, an dem ein Display eingesetzt werden kann.


Zum Installieren des Betriebssystems und zum Abspeichern von Daten steht ein micro-SD Slot zur Verfügung.

Zur Stromversorgung stehen verschiedene Möglichkeiten zur Verfügung. Erstens kann ein USB-C Netzteil verwendet werde. Zweitens kann auch über den GPIO Header das System mit Strom versorgt werden. Zu guter Letzt ist es auch noch möglich das System mit Power Over Ethernet (POE) zu versorgen. POE wird aber in den meisten Objekten nicht zur Verfügung stehen, so dass hauptsächlich auf die Stromversorgung per USB-C Netzteil bzw. Batteriepack zurückgegriffen wird.

## 3.2 Einrichten und Bedienen des Schimmel-Controllers

### 3.2.1 Einrichten des Schimmel-Controllers

Zur Inbetriebnahme des Schimmel-Controllers mit Kamera und Sensormodul muß das System zunächst vollständig verdrahtet werden. Dies ist in folgendem Bild dargestellt.



Tastatur und Maus werden über die USB-Schnittstellen angeschlossen. Für den späteren Betrieb im Dom Xanten und Münster wurde eine Tastatur/Maus mit Bluetooth Übertragung angeschafft, um das Kabelwarr zu vermindern. Der Monitor wird über USB-Schnittstelle mit Strom versorgt und über ein weiteres Kabel an das Controller-Modul angeschlossen. Hinzu kommt eine Stromversorgung per Netz oder Akku.


Anschließend wird das System über den Schalter eingeschaltet. Auf dem Monitor erscheint folgendes Bild:






In der Kopfzeile sind alle wichtigen Funktionen dargestellt, die im Folgenden auch näher erläutert werden. Auf dem Desktop sind dann mehrere Ordner dargestellt mit unterschiedlichen Funktionen.

In der Kopfzeile links befindet sich von links nach rechts das Symbol für An/Aus, Internet-Explorer, Ordneranzeige, Terminal und FileZilla für die Datenübertragung an den Server.



Auf der rechten Seite befinden sich von links nach rechts die Anzeigen für den VNC-Viewer und dem Teamviewer, um über VPN-Tunnel Zugriff vom Office auf das Controller-Modul zu bekommen. Das nächste Symbol steht für eine Bluetooth-Verbindung und dann eine WLAN/Ethernet-Verbindung. Anklicken der Symbole erlaubt die Auswahl verfügbarer Bluetooth und WLAN/Ethernet-Netzwerke mit der Möglichkeit der Kopplung. Das Lautsprechersymbol wird nicht gebraucht. Die Uhrzeit zeigt die im System gültige Uhr, anschließend folgen die Temperaturanzeige und anschließend noch Statusanzeigen für die CPU.



### **Einrichten des Internet-Zugangs:**

Auf das WLAN-Symbol in der rechten Menueleiste klicken (Symbol hinter dem Bluetooth-Symbol und vor dem Lautsprechersymbol).

Hier werden dann die verfügbaren WLAN/Ethernet-Verbindungen angezeigt. Dann das gewünschte WLAN-Netz aussuchen und das zugehörige Netz-Kennwort eingeben. Falls die Kamera über einen LTE-Stick verbunden werden soll, so simulieren neuere Sticks ein WLAN-Netzwerk, wofür dann das LTE\_Passwort eingegeben werden muß. Ältere Sticks simulieren eine Ethernet-Schnittstelle. Hier müssen dann keine weiteren Schritte vorgenommen werden.

### **Test der Internet-Verbindung:**

Durch Anklicken des „Weltsymbols“ in der linken Menueleiste wird der Internetbrowser geöffnet. Hier bitte einen beliebigen Suchbegriff eingeben und prüfen, ob das Internet funktioniert. Bei einem erneuten Versuch bitte immer einen neuen Suchbegriff eingeben.

## **3.2.2 Bedienen des Schimmelcontrollers**

Nach dem Start des Systems über den Startknopf sieht man folgendes Bild:



Auf dem Desktop sieht man das Bild für den Papierkorb.

Es folgt ein Ordner für Hajuveda-spezifische Informationen

anschließend folgt ein Ordner für die Skripte,

ein Startprogramm,

ein Ordner für die Bilder, die dann in den Server hochgeladen werden,

ein Ordner für den Zugriff auf das Power-Management

und ein Ordner, der für die Scharfeinstellung der Kamera benötigt wird.

Wenn das System über den Power-On-Schalter eingeschaltet wird, dann läuft ein Startprogramm mit folgenden Schritten:

Der Mikrocontroller wird gestartet.

Alle Schnittstellen werden aktiviert.

Es wird ein Bild gemacht ohne Beleuchtung (abschaltbar).

Es wird ein Bild gemacht mit Beleuchtung.

Es werden die Thermodaten und Akkudaten (falls eingebaut) abgerufen.

Alle Bilder und Thermodaten/Akkudaten werden über die Schnittstelle an die Cloud übertragen.

Für die Konfiguration der Kamera sind die Ordner Skripte, Systemuploader und Scharfstellen erforderlich. Alle anderen haben interne Bedeutung.

### **Scharfstellen der Kamera:**

Vor der Scharfstellung muß die Apertur der Kamera ganz aufgedreht werden. Das geschieht, indem man von vorne in das Objektiv hineinschaut und den hinteren Ring der Kamera so lange dreht, bis die Blende voll geöffnet ist. Dann den hinteren Pin zudrehen, bis die Einstellung nicht mehr verdreht werden kann.

Nach Scharfstellung muß der vorderste Pin zuggedreht werden, damit sich die Position des Rings nicht mehr ändern kann.

## **3.3 Systematisierung des Anlernprozesses**

Im Skript gibt es mehrere Parameter, die individuell angepasst werden können. Daher ist es wichtig herauszufinden, welcher Parametersatz die besten Ergebnisse ergibt. Dabei sollen die folgenden Parameter in mehreren Läufen modifiziert werden, um deren Einfluss auf das Erkennungsergebnis zu untersuchen:

### **Zunächst feststehende Parameter:**

Bilddatensatz 1: Dieser Bilddatensatz besteht aus einer ersten Auswahl an Bildern mit Schimmel oder Staub, die aus dem vorhandenen Bilderpool so selektiert wurden, dass die Schadenmerkmale möglichst ausgeprägt waren. Der Bilddatensatz besteht aus den Ordnern für das Training (Train), für die Validierung des Trainings (Validate) und für komplett neue Bilder (Test).

- Pixel: Die Größe der zerschnittenen Bilder wurde auf 200x200 Pixel festgelegt.
- Train=2000 Das Training wurde mit 2000 Bildern je von Schimmel und je von Staub gemacht
- Validate=100 Die Validierung wurde mit 100 Bildern je von Schimmel und je von Staub gemacht
- Test=100 Der Test für das komplette Training wurde mit 100 ganz neuen und dem neuronalen Netz unbekanntem Bildern gemacht. Dafür wurden je 100 Schimmel und je 100 Staubbilder ausgesucht

Die folgenden Parameter wurden variiert:

- Batch Size Train gibt die Zahl der Bilder an, die aus dem Bildpool auf einmal geladen und trainiert werden
- Batch Size Validate gibt die Zahl der Bilder an, die aus dem Bildpool auf einmal geladen und trainiert werden
- Val Loss Patience ist ein Abbruchkriterium und gibt die Zahl der Epochen vor, in denen sich die Korrektheitsrate nicht mehr ändern darf. Ist dies der Fall, bricht die weitere Berechnung ab und es werden keine neuen Epochen mehr berechnet.

Der Ablauf des Trainings ist dann wie folgt:

- Bei der ersten Epoche ergibt sich eine Korrektheitsrate für das Training und für die Validierung.
- Von Epoche zu Epoche werden die Bilder aus dem Ordner Train neu gemischt. Die bis dahin berechnete Gewichte werden nach jeder Epoche gespeichert (Custos\_InceptionV3\_weights.h5) und für die nächsten Epoche wieder eingelesen, um vom bisherigen Lernzyklus zu profitieren.
- Von Epoche zu Epoche werden die Validierungsbilder nicht neu gemischt und bleiben immer gleich.
- Nach Erreichen des Abbruchkriteriums wird der Gewichtungssatz, der die höchste Korrektheitsrate für die Validierung hatte ausgewählt.
- Damit wird dann der Testlauf mit den unbekanntem Bildern gemacht.

Die nächsten Seiten zeigen die spannenden Ergebnisse des Trainings, können aber ermüdend sein. Sie sind aber notwendig, um den Arbeitsfortschritt und die Logik dahinter zu dokumentieren. Am Schluß eines jeden Kapitels ist immer eine Ergebniszusammenfassung gezeigt. Für den Schlußbericht ist es vielleicht sinnvoll die ganzen Trainingsergebnisse in einen Anhang zu verbannen und nur noch das Endergebnis des Trainings zu zeigen.

### **3.3.1 Bilddatensatz 1: Schimmel/Staub mit 2000 Trainings-Bildern und Löschen der Gewichtsfunktion bei jedem Lauf**

Die Bilddatensätze beinhalten alle ausgewählten Bilder für das Training (Train), für die Validierung (Validate) und für den Test mit komplett neuen Bildern, die weder im Train noch im Validate verwendet wurden. Die Bilder wurden aus dem vorhandenen Bilderpool so selektiert, dass die Schadenmerkmale möglichst ausgeprägt waren. Die Pixelgröße ist immer 200x200. Train, Validate und Test wurden während der Parameter-Variation nicht verändert:

- Train = 2000 Das Training wurde mit je 2000 Bildern von Schimmel und Staub gemacht
- Validate = 100 Die Validierung wurde mit je 100 Bildern von Schimmel und Staub gemacht
- Test = 100 Der Test für das komplette Training wurde mit 100 ganz neuen und dem neuronalen Netz unbekanntem Bilder gemacht. Dafür wurden je 100 Schimmel und je 100 Staubbilder ausgesucht.

Die folgenden Parameter wurden variiert:











- Batch Size Train gibt die Zahl der Bilder an, die aus dem Bild Pool auf einmal geladen und trainiert werden
- Batch Size Validate gibt die Zahl der Bilder an, die aus dem Bild Pool auf einmal geladen und trainiert werden
- Val Loss Patience ist ein Abbruchkriterium und gibt die Zahl der Epochen vor, in denen sich die Korrektheitsrate innerhalb einer Grenze nicht mehr ändern darf. Ist dies der Fall, bricht die weitere Berechnung ab und es werden keine neuen Epochen mehr berechnet.

Der Ablauf des Trainings ist dann wie folgt:

- Bei der ersten Epoche ergibt sich eine Korrektheitsrate für das Training und für die Validierung.
- Von Epoche zu Epoche werden die Bilder aus dem Ordner Train neu gemischt. Die bis dahin berechneten Gewichte werden nach jeder Epoche gespeichert (Custos\_InceptionV3\_weights.h5) und für die nächsten Epoche wieder eingelesen, um vom bisherigen Lernzyklus zu profitieren.
- Von Epoche zu Epoche werden die Validierungsbilder nicht neu gemischt und bleiben immer gleich.
- Nach Erreichen des Abbruchkriteriums wird der Gewichtungssatz, der die höchste Korrektheitsrate für die Validierung hatte, ausgewählt.
- Damit wird dann der Testlauf mit den unbekanntem Bildern gemacht.

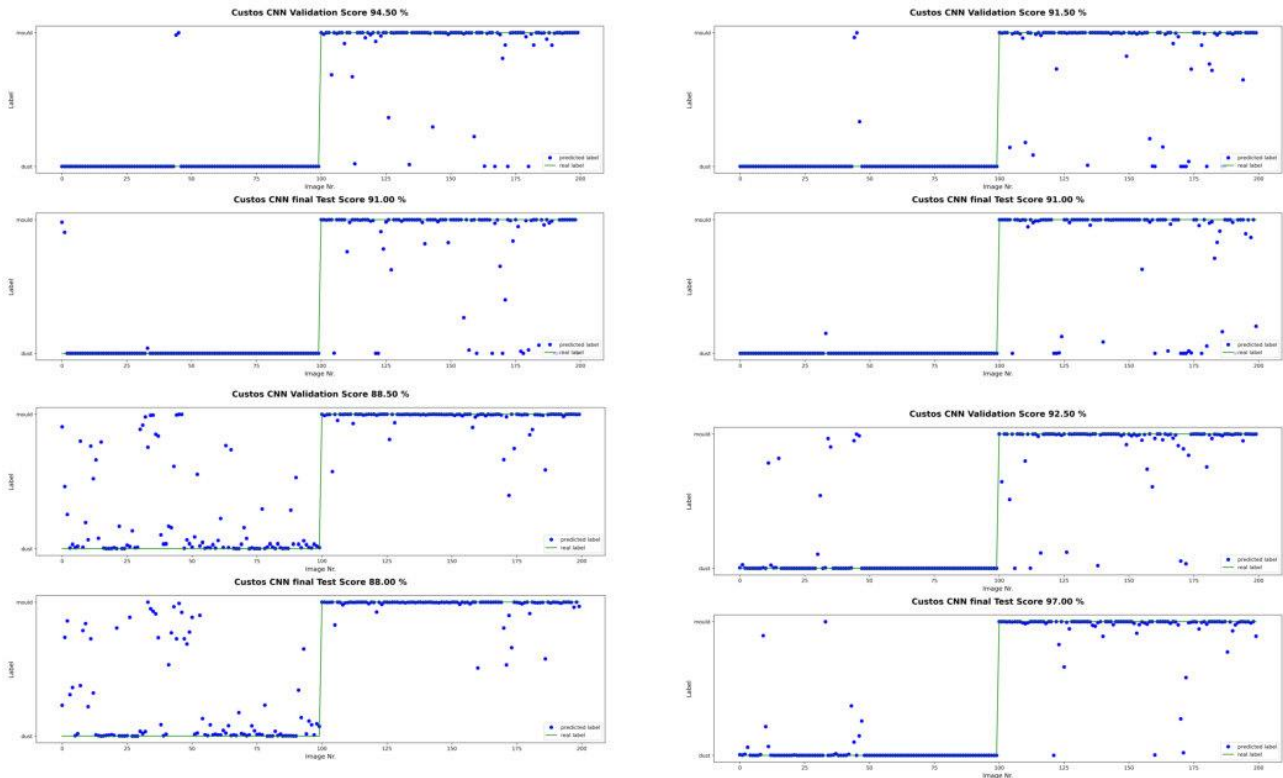
Insgesamt wurden 4 Trainingsläufe mit Variation der Parameter gemacht. Für jeden Parametersatz wurden 4 Durchläufe (run) gemacht, wobei der Gewichtsdatensatz nach jedem Durchlauf gelöscht wurde. Das bewirkt, daß für jeden Durchlauf am Anfang der Gewichtsdatensatz neu und zufällig besetzt wird. Es gilt zu untersuchen, wie stabil das Ergebnis für jeden Durchlauf trotz zufälligem Initial-Gewichtsdatensatz ist. Das Ergebnis für den ersten Trainingslauf mit Batch Size Train=16, Batch Size Validate=16 und Val Loss Patience=10 ist wie folgt:

Picture Set=1, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=16, Batch Size Validate=16, Val Loss Patience=10, weights=deleted



Die Korrektheitsrate ist die Zahl der richtig erkannten Bilder aus dem Validation-Pool zur Gesamtzahl der Bilder im Validation Pool und die Loss Function ist ein Maß für die Vorhersage-Abweichung. Sie wird benutzt, um über „Backpropagation“ die Gewichtsänderungen neu zu bestimmen. Korrektheitsrate und Loss-Funktion sind Kontrollwerte für das Training des neuronalen Netzes und daher intern. Im hier gezeigten Bild kommt die Korrektheitsrate in keinem Fall in die Nähe der 100 und die Verlustfunktion schwankt stark. Nach nur 19 Epochen wird die Berechnung beendet. Da diese Berechnungen eher intern sind und für die Steuerung der Algorithmen benutzt werden, werden im Folgenden nur noch Bilder mit Bewertungspunktzahlen gezeigt. Sie sind für den Anwender interessanter. Je näher diese an 100% kommen, desto besser werden die einzelnen Merkmale (hier Schimmel gegenüber Staub) richtig erkannt. Diese sind im nächsten Diagramm gezeigt:

Picture Set=1, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=16, Batch Size Validate=16, Val Loss Patience=10, weights=deleted

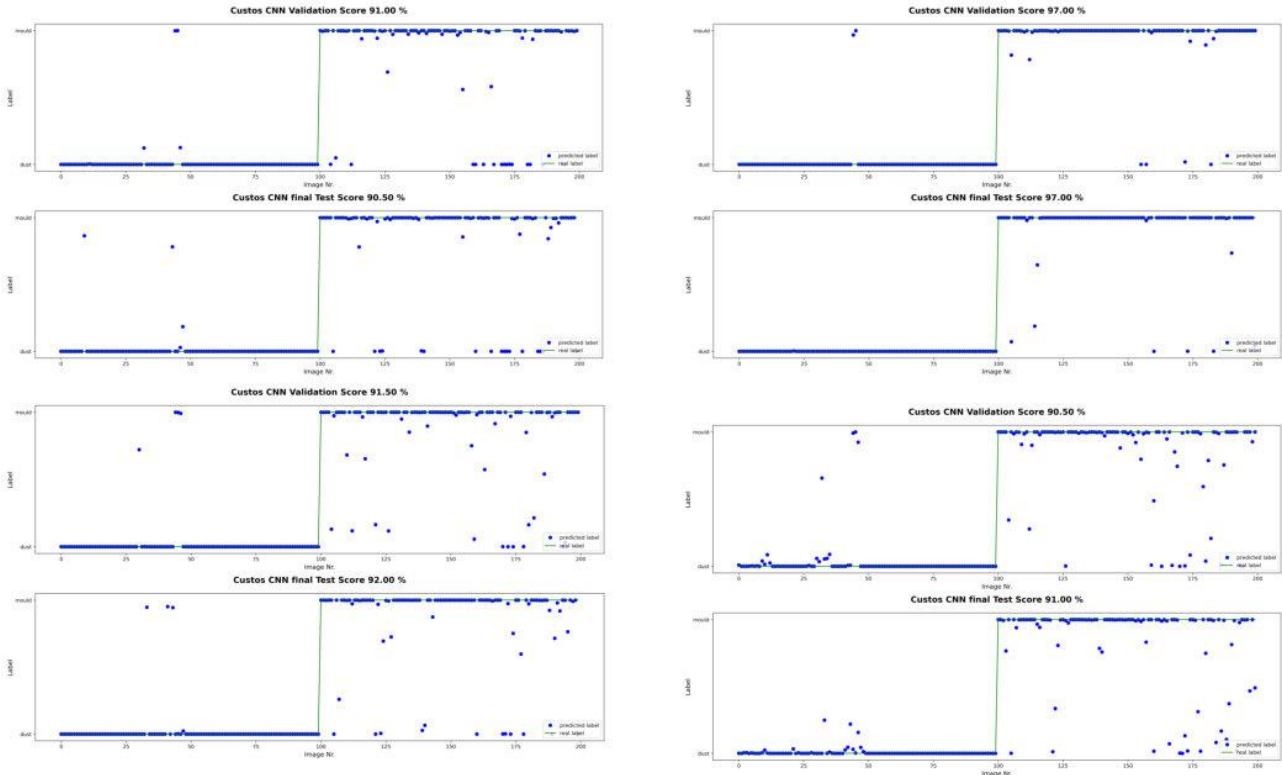


In der Abbildung werden 2 Niveaus auf der linken Abszisse dargestellt. Das Niveau liegt für Staub ganz unten und für Schimmel ganz oben. Beim ersten Lauf werden beim Staub 2 Bilder nicht richtig erkannt, sondern Schimmel zugeordnet. Die Zahl der falsch zugeordneten Bilder ist bei Schimmel viel größer. Hier werden 6 Bilder dem Staub zugeordnet und 14 Bilder liegen irgendwo zwischen Schimmel und Staub. Beim 2. Lauf werden – wie gesagt – vor dem Start die Gewichtungsfunktionen gelöscht und neu zufällig besetzt. Das Ergebnis unterscheidet sich ziemlich vom 1. Lauf. Beim 3. Lauf ist es katastrophal anders und beim 4. Lauf deutlich anders.

Die Bewertungspunktezahlliegt zwischen 88 und 92,5 % für die Validierung und zwischen 88 und 97% für das Testergebnis. Pro Durchlauf sind die Punktwolken in den Diagrammen nicht konsistent zueinander.

Eine mögliche Ursache könnte die recht kleine Zahl von Val Loss Patience sein. Im nächsten Schritt wird diese Zahl auf 25 gesetzt, d.h. erst nachdem sich 25-mal keine Änderung der Korrektheit-Klassifizierungsrate ergeben hat, wird die Berechnung gestoppt. Das Ergebnis für das Training nach 68 Epochen ist wie folgt:

Picture Set=1, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=16, Batch Size Validate=16, Val Loss Patience=25, weights=deleted

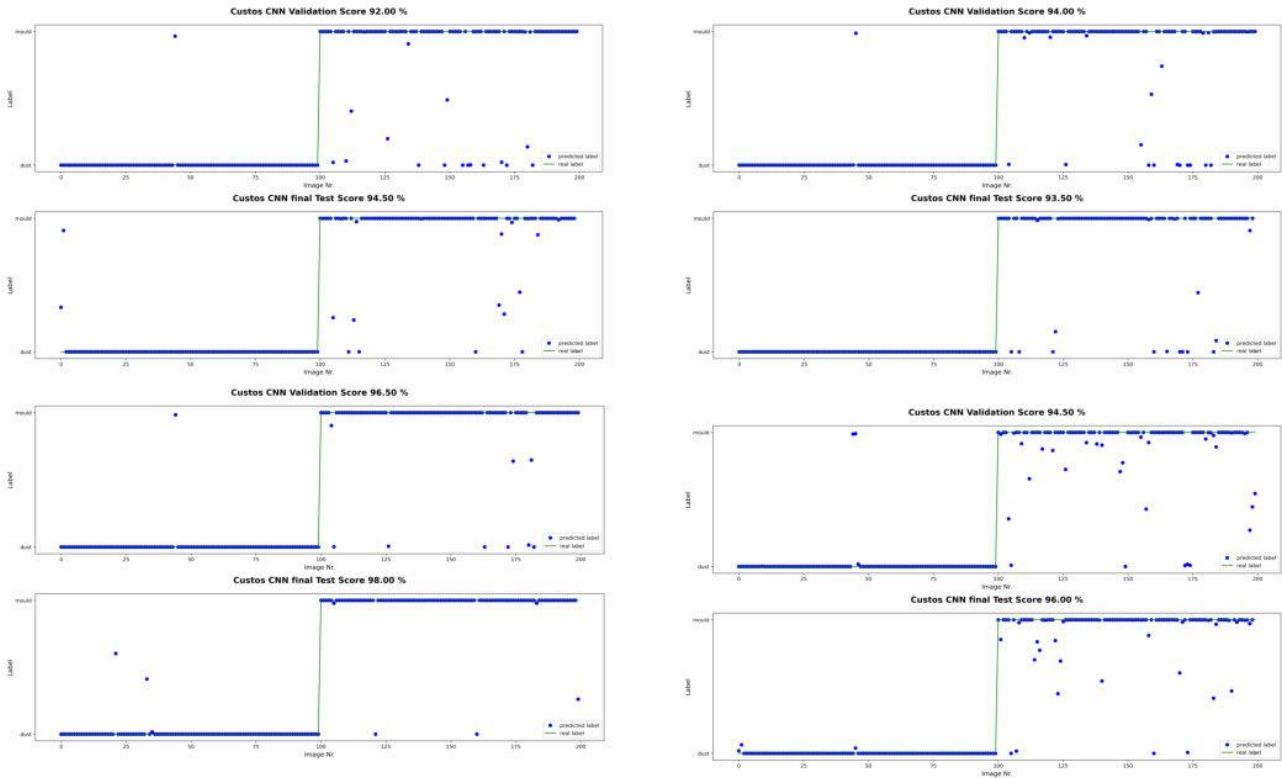


Die Ergebnisse liegen bei 90,5 bis 97% bei den Validierungsbildern und bei 90,5 bis 97% bei den Testbildern. Das ist viel besser, als der Abbruch der Berechnungen bereits nach 16 unveränderten Werten. Durchlauf 2 zeigt eine Punktzahl von 97 % für beide und ergibt auch optisch das beste Bild. Nach wie vor sind die Ergebnisse von Durchlauf zu Durchlauf viel zu verschieden, weil die Zahl der richtig und falsch erkannten Bilder stark variieren. Damit hängt die Qualität des Ergebnisses vom Durchlauf ab. Das geht nicht.

Der nächste Versuch wird mit einem noch höheren Wert der Val Loss Patience von nun 50 gemacht. Es werden bis zu 120 Epochen berechnet, bis das Abbruchkriterium erreicht ist.



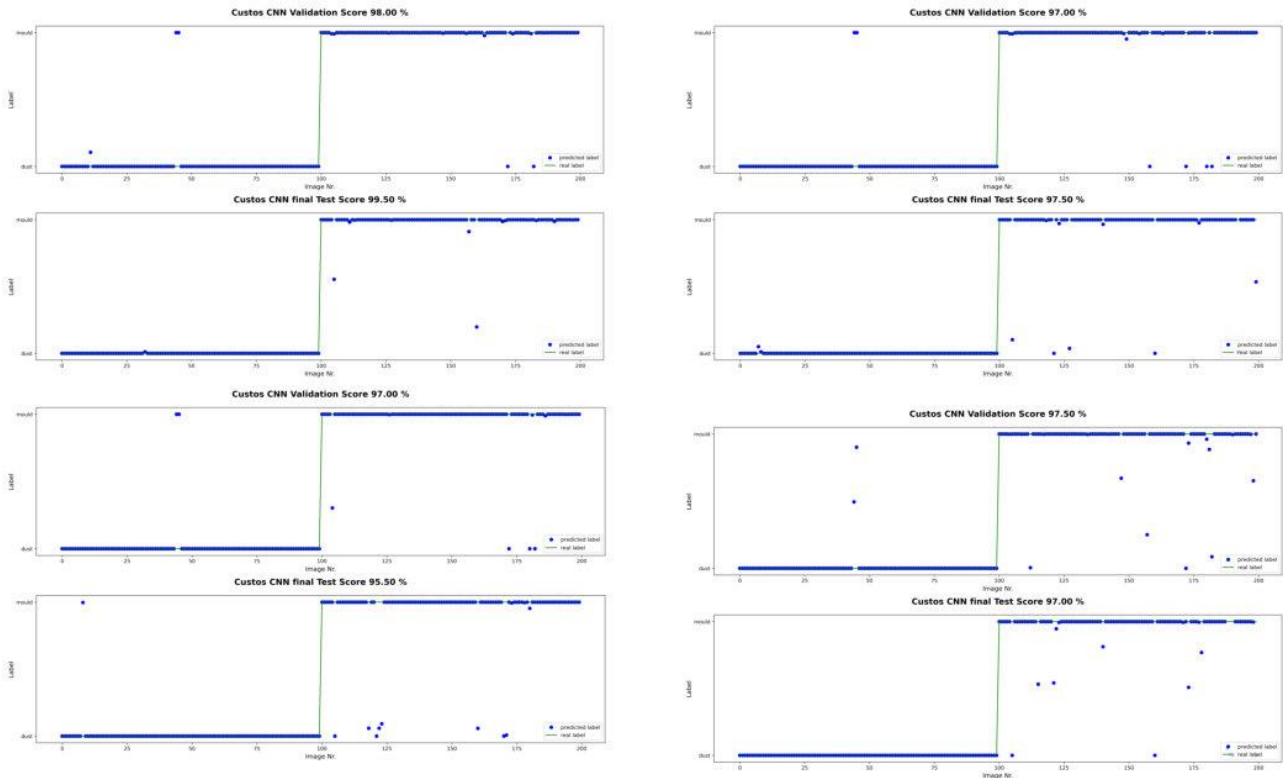
Picture Set=1, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=16, Batch Size Validate=16, Val Loss Patience=50, weights=deleted



Nach wie vor streuen die Endergebnisse eines jeden Durchlaufs zu stark, auch wenn Durchlauf 3 mit 96,5% und 98% schon sehr gut aussieht.

Im nächsten Schritt wird der Einfluss des Batch Size Trains untersucht und der Wert wird auf 32 bei einem Val Loss Patience von 25 gesetzt:

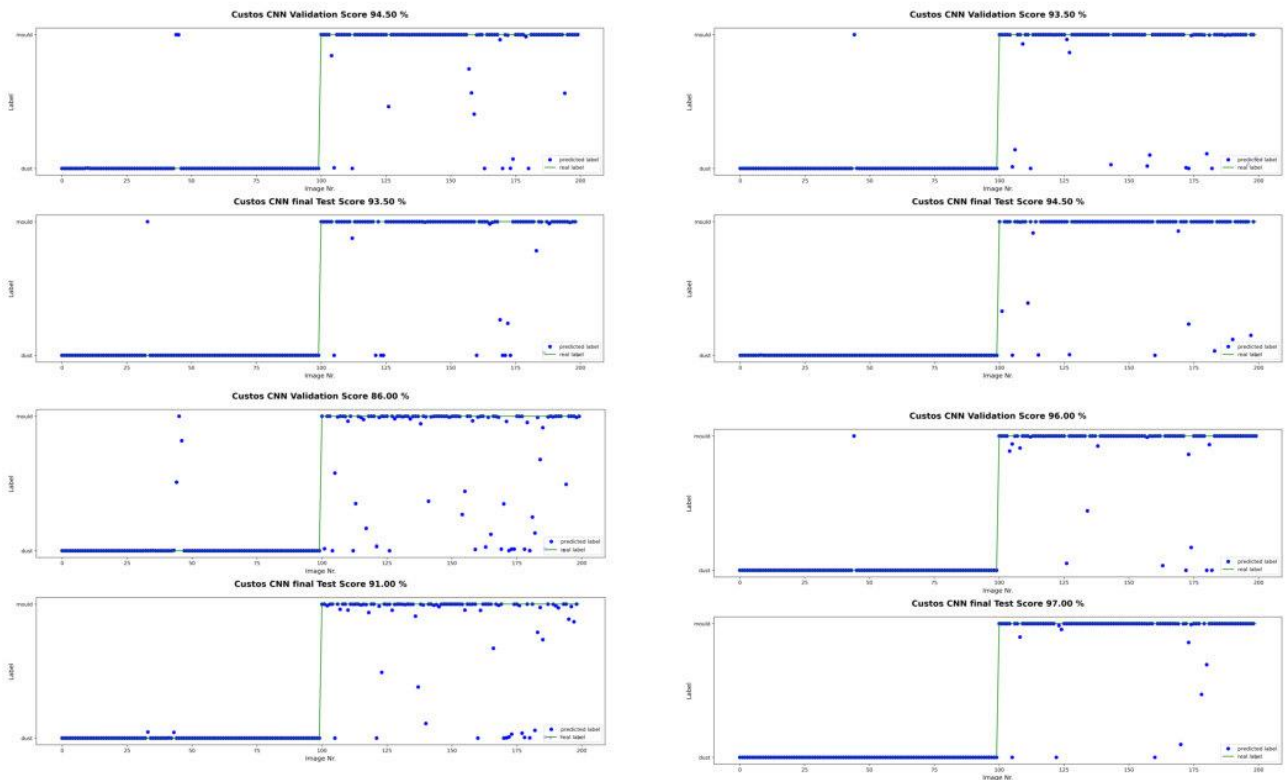
Picture Set=1, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=32, Batch Size Validate=16, Val Loss Patience=25, weights=deleted



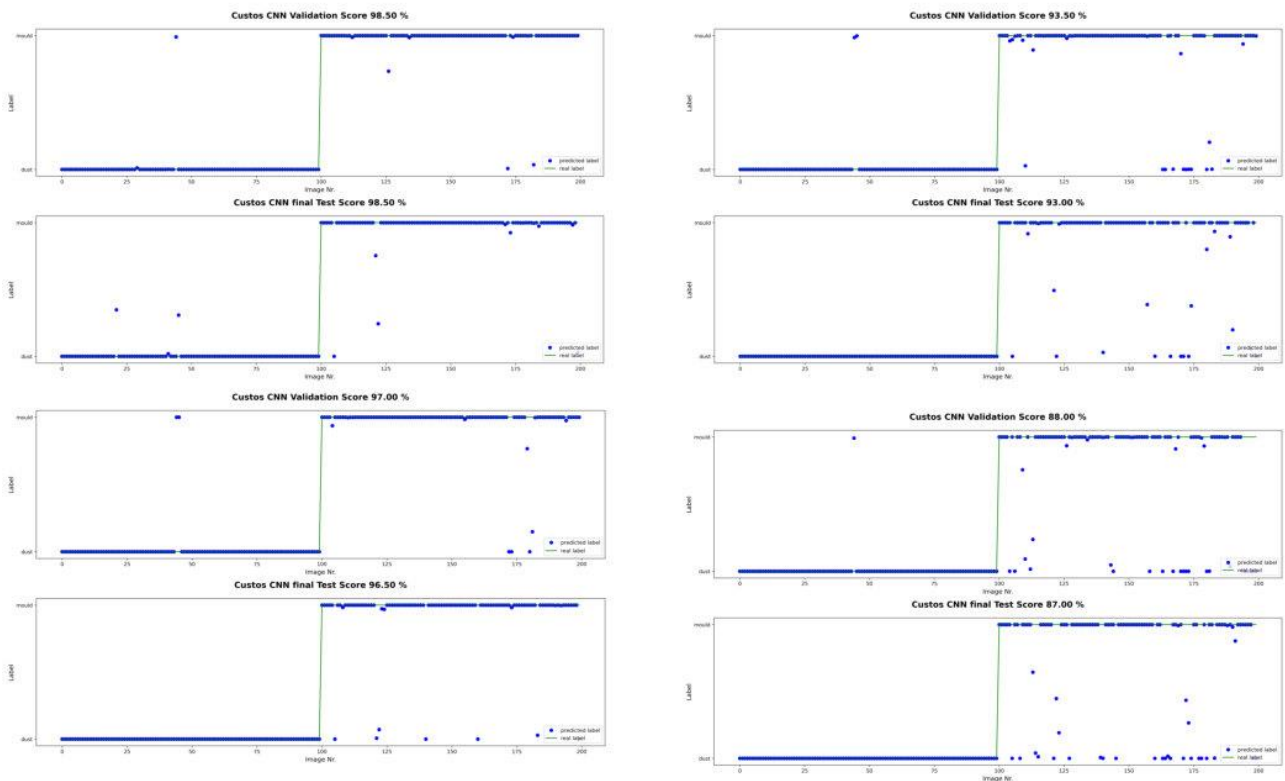
Diese Ergebnisse sehen bereits sehr gut aus. Bei der Validierung werden fast immer die Bilder 45 und 46 für den Staub falsch einsortiert und beim Schimmel sind es (immer nur die komplett falschen betrachtet) die Bilder 105,173,183,191. Beim Test sind alle Bilder bis auf eine Ausnahme bei Nr. 9 für den Staub o.k. und Bild 106 und 161 kommen beim Schimmel nicht gut an.

Die Bilder mit weiteren Parameter-Variationen sind wie folgt:

Picture Set=1, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=32, Batch Size Validate=16, Val Loss Patience=50, weights=deleted



Picture Set=1, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=48, Batch Size Validate=16, Val Loss Patience=25, weights=deleted



Die folgende Tabelle zeigt die Ergebnisse in einer Übersicht. Das beste Ergebnis pro  
 DBU-Projekt Aktenzeichen 35604/01 –  
 Schlußbericht – Hajurveda Heritage und iXtronics GmbH – Seite 101

Durchlauf ist grün markiert und der file mit der Besten gemittelten Bewertungszahl für Validation und Test ist File Nr. 4.

file No	Batch Size train	Batch Size Validate	Val Loss Patience	weights	run No.	Validation Score	Test Score	wrong Validation dust	wrong validation mould	wrong test dust	wrong test mould
1	16	16	10	deleted	1	94,5	91,0	45,46		1,2	
					2	91,5	91,0				
					3	88,5	88,0				
					4	92,5	97,0				
					average	91,8	91,8		standard deviation	2,5	3,8
2	16	16	25	deleted	1	91,0	90,5	45,46		10,44	
					2	97,0	97,0	45,46	156,158,173,183	0	106,161,174,184
					3	91,5	92,0	31,45,46,47		34,42,44	
					4	90,5	91,0	33,45,46,47			0
					average	92,5	92,6		standard deviation	3,0	3,0
3	16	16	50	deleted	1	92,0	94,5	45		45	
					2	94,0	93,5	45		0	
					3	96,5	98,0	45	106,127,164,173,181,183	22,34	122,161,200
					4	94,5	96,0	45		0	
					average	94,3	95,5		standard deviation	1,8	2,0
4	32	16	25	deleted	1	98,0	99,5	45,46	173,183	0	106,161
					2	97,0	97,5				
					3	97,0	95,5	45,46	105,173,191,183		9
					4	97,5	97,0				
					average	97,4	97,4		standard deviation	0,5	1,7
5	32	16	50	deleted	1	94,5	93,5				
					2	93,5	94,5				
					3	86,0	91,0				
					4	96,0	97,0	45	127,164,173,175,181,183	0	106,123,161,171
					average	92,5	94,0		standard deviation	4,5	2,5
6	48	16	25	deleted	1	98,5	98,5	45	127,173,183	0	106,123
					2	93,5	93,0				
					3	97,0	96,5				
					4	88,0	87,0				
					average						

**ERGEBNIS der Untersuchung bester Einstellparameter bei Löschen der Gewichtsfunktion:**

Die besten Ergebnisse für die korrekte Erkennung der Bilder ergibt sich die folgende Parameter-Konstellation:

Batch Size Train: 32

Batch Size Validate: 16

Val Loss Patience: 25

Für diese Konstellation liegt die Bewertungszahl für Validierung und Test über 97. Gleichzeitig ist auch die Standardabweichung für alle 6 Durchläufe mit gelöschter Gewichtsfunktion am kleinsten mit 0,5 für den Staub und 1,7 für den Schimmel.

Ergebnisse mit Bewertungszahlen unter 97 werden in Zukunft verworfen.

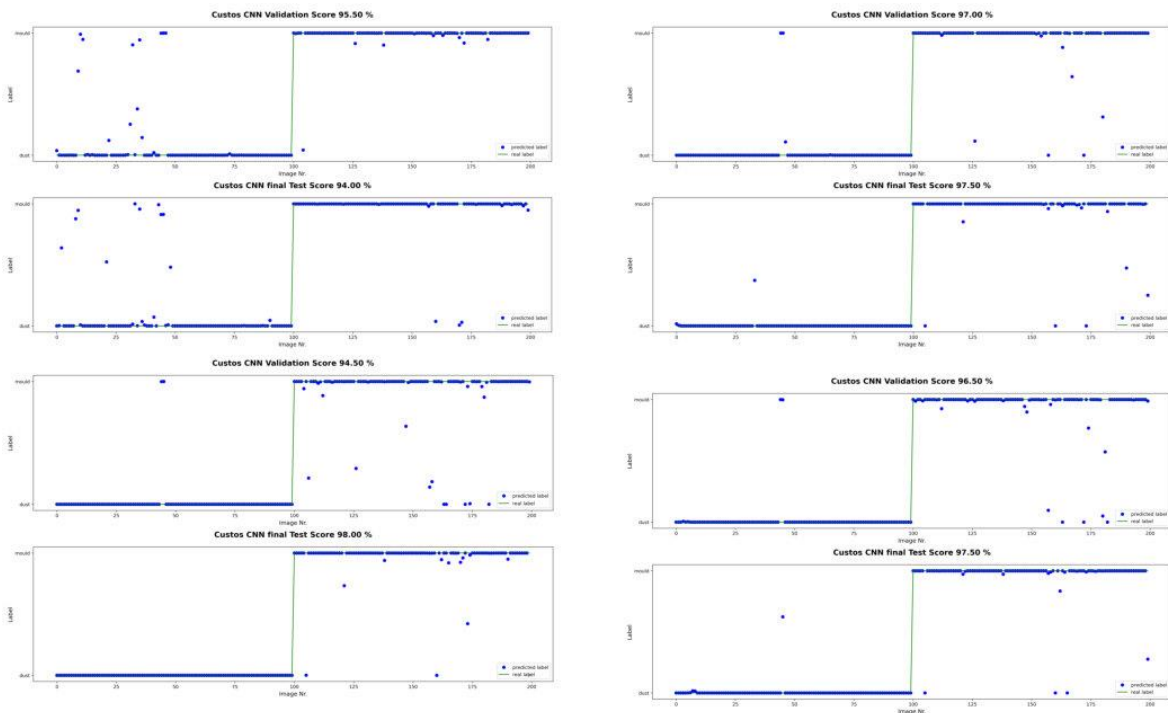
**3.3.2 Bilddatensatz 1: Schimmel/Staub mit 2000 Trainings-Bildern und Akumulieren der Gewichtsfunktion bei jedem Lauf**



Im nächsten Schritt wurde untersucht, welche Verbesserung sich ergibt, wenn man bei den 4 Durchläufen pro Parametersatz den Gewichtungssatz nicht löscht. Batch Size Train wurde auf 32 und Val Loss Patience auf 30 gesetzt, letzteres um ein etwas stabileres Ergebnis ohne erhebliche Verlängerung der Rechenzeit zu erhalten:

Die folgenden 4 Bilder zeigen die Validierungspunktzahlen von 4 Versuchen mit 4 Durchläufen, wobei die Gewichtungsfunktionen akkumuliert werden:

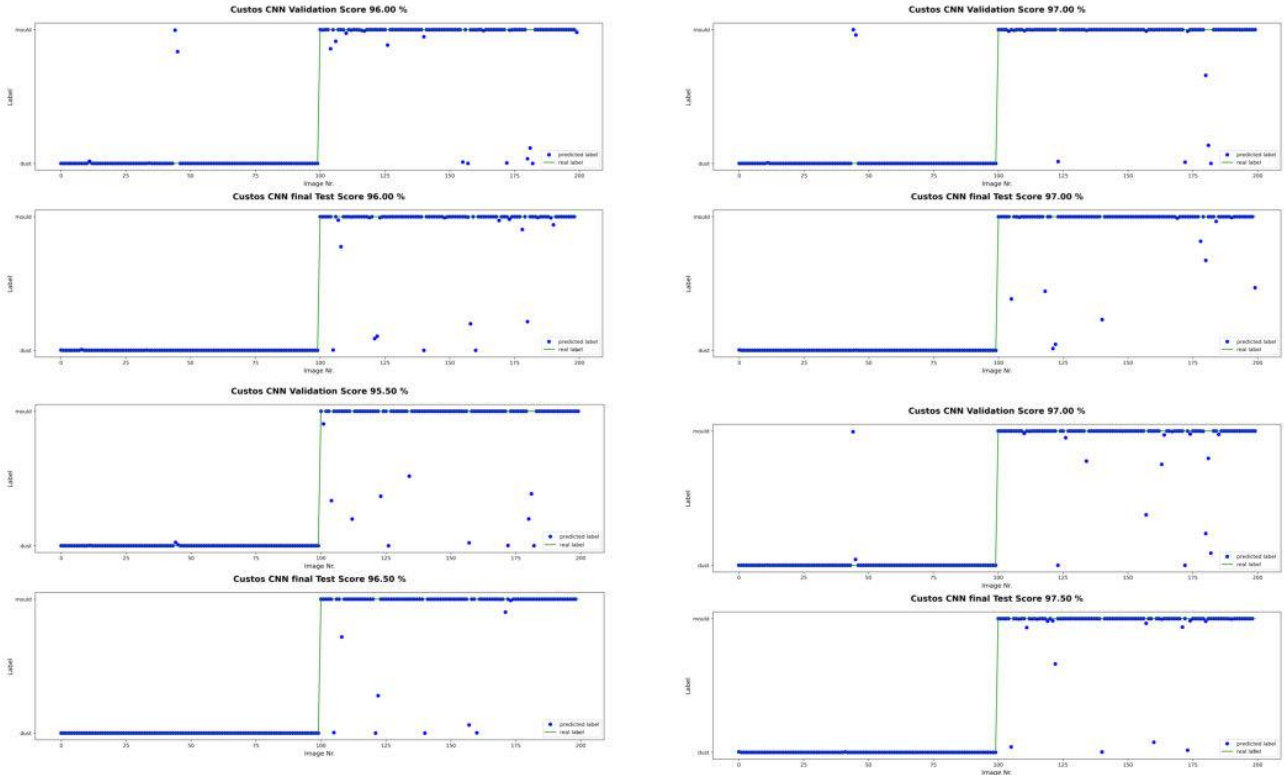
Picture Set=1, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
Batch Size Train=32, Batch Size Validate=16, Val Loss Patience=30, weights not deleted, run 1, repeat 1-4



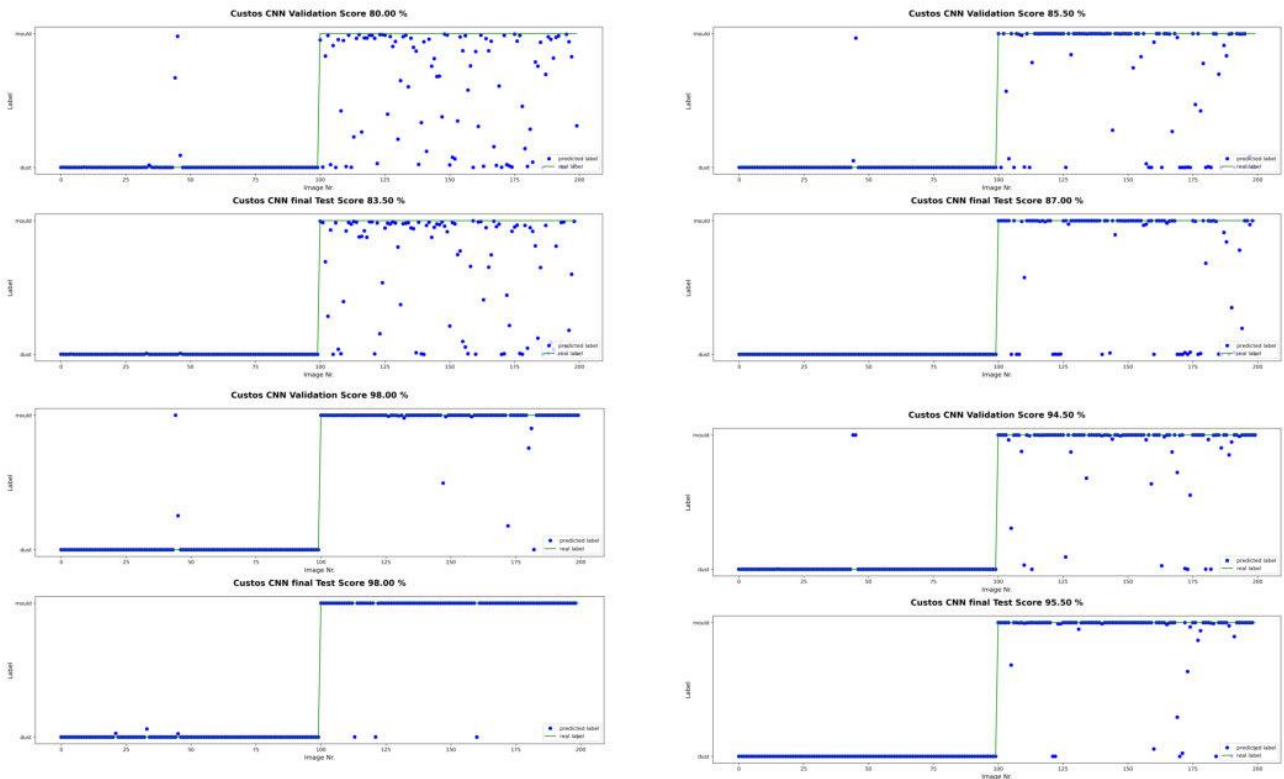
Der 4. Durchlauf sollte der Beste für die Validation Punktzahl sein. Man sieht aber, daß die Akkumulation der Gewichtungsfunktion nicht immer zu einem besseren Ergebnis führt, denn der 2. Durchlauf ist noch ein wenig besser. Bild 45 und 46 sind beim Staub nicht o.k. und Bild 127,158,173 sind beim Schimmel nicht o.k..

Nun folgen die 3 weitere Läufe ohne Kommentar:

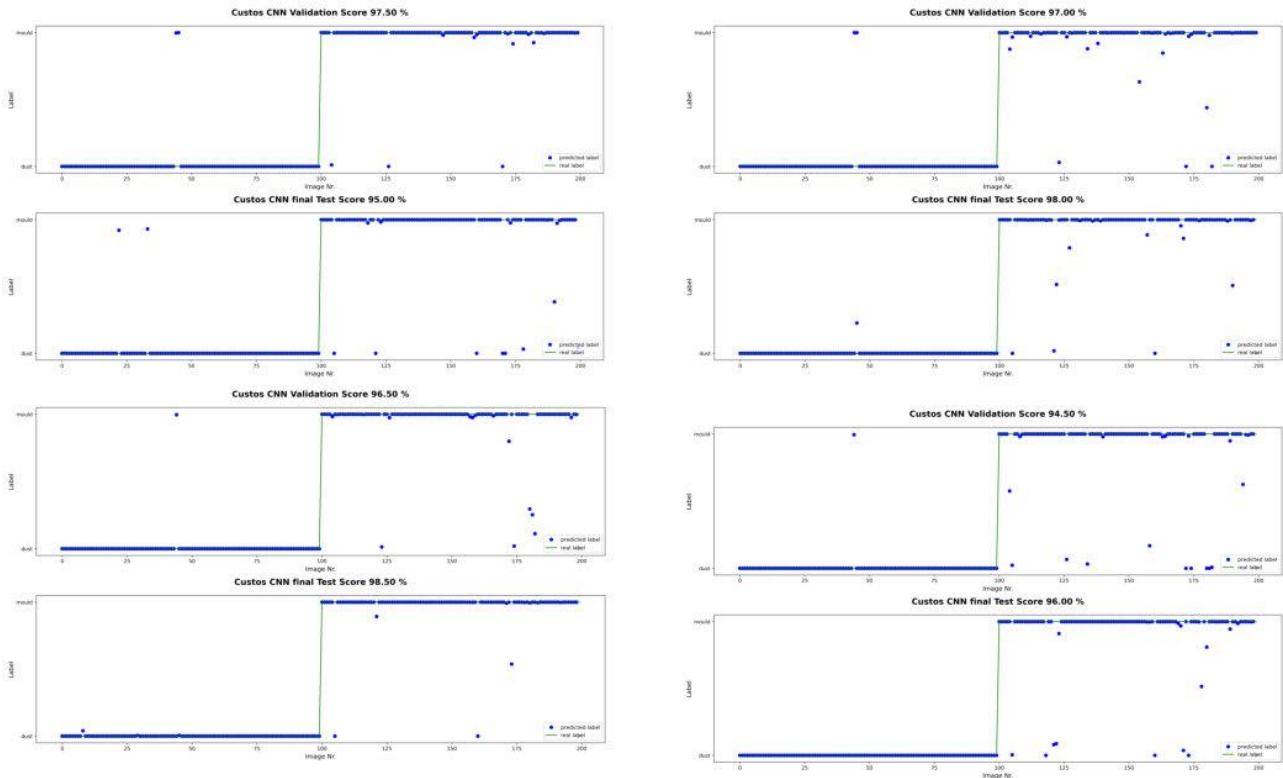
Picture Set=1, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=32, Batch Size Validate=16, Val Loss Patience=30, weights not deleted, run 2, repeat 1-4



Picture Set=1, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=32, Batch Size Validate=16, Val Loss Patience=30, weights not deleted, run 3, repeat 1-4



Picture Set=1, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=32, Batch Size Validate=16, Val Loss Patience=30, weights not deleted, run 4, repeat 1-4



Die folgende Tabelle macht die Stoßrichtung noch etwas deutlicher:

file No	Batch Size train	Batch Size Validate	Val Loss Patience	weights	run No.	Validation Score	Test Score	wrong Validation dust	wrong validation mould	wrong test dust	wrong test mould
					average	94,3	93,8		standard deviation	4,7	5,0
7	32	16	30	accumulated	1	95,5	94,0				
					2	97,0	97,5	45,46	127,158,173	34	106,161,174
					3	94,5	98,0				
					4	96,5	97,5				
					average	95,9	96,8		standard deviation	1,1	1,8
8	32	16	30	accumulated	1	96,0	96,0				
					2	97,0	97,0				
					3	95,5	96,5				
					4	97,0	97,5	45	124,173,181,183	0	106,141,161,174
					average	96,4	96,8		standard deviation	0,8	0,6
9	32	16	30	accumulated	1	80,0	83,5				
					2	85,5	87,0				
					3	98,0	98,0	45,46	148,173,183		
					4	94,5	95,5				
					average	89,5	91,0		standard deviation	8,2	6,9
10	32	16	30	accumulated	1	97,5	95,0	45,46	124,173,183	46	106,122,161
					2	97,0	98,0				
					3	96,5	98,5				
					4	94,5	96,0				
					average	96,4	96,9		standard deviation	1,3	1,7
					ungeeignete Bilder			45,46	124,127,173,183	34,44	106,122,161,174

Die Akkumulation führt nicht immer zu besseren Ergebnissen. Wenn man aber zusätzlich die Einschränkung macht, daß keine sinkenden Punktzahlen bei der Validierung stattfinden dürfen und daß eine minimale Bewertungszahl von 97 erreicht werden muß,

dann ist bei file 7 der zweite Durchlauf am besten, in file 8 der vierte, in file 9 der dritte und in file 10 der zweite am besten.

Das Sortierergebnis ist dann konvergent.

### ERGEBNIS der Untersuchung bester Einstellparameter bei Akkumulieren der Gewichtsfunktion:

Wenn man bei Akkumulation der Gewichtsfunktionen jeden Lauf speichert und immer nur den Lauf mit der höchsten Punktzahl in der Validierung und beim Test berücksichtigt, die gleichzeitig mindestens 97 erreichen, dann kommen stabile Ergebnisse heraus unabhängig von den Zufallswerten der Gewichtsfunktion in der Startphase.

Die Analyse zeigt aber auch, daß wiederholt in allen Läufen falsch zugeordnete Bilder wie folgt auftreten:

Staub: 45, 46 Diese Bilder wurden als Schimmel interpretiert und das System hat Recht. Bilder 45,46 und 47 werden im nächsten Durchgang durch bessere Staubbilder ersetzt.



Die falsch angezeigten Schimmelbilder sind wie folgt:





124



127



173



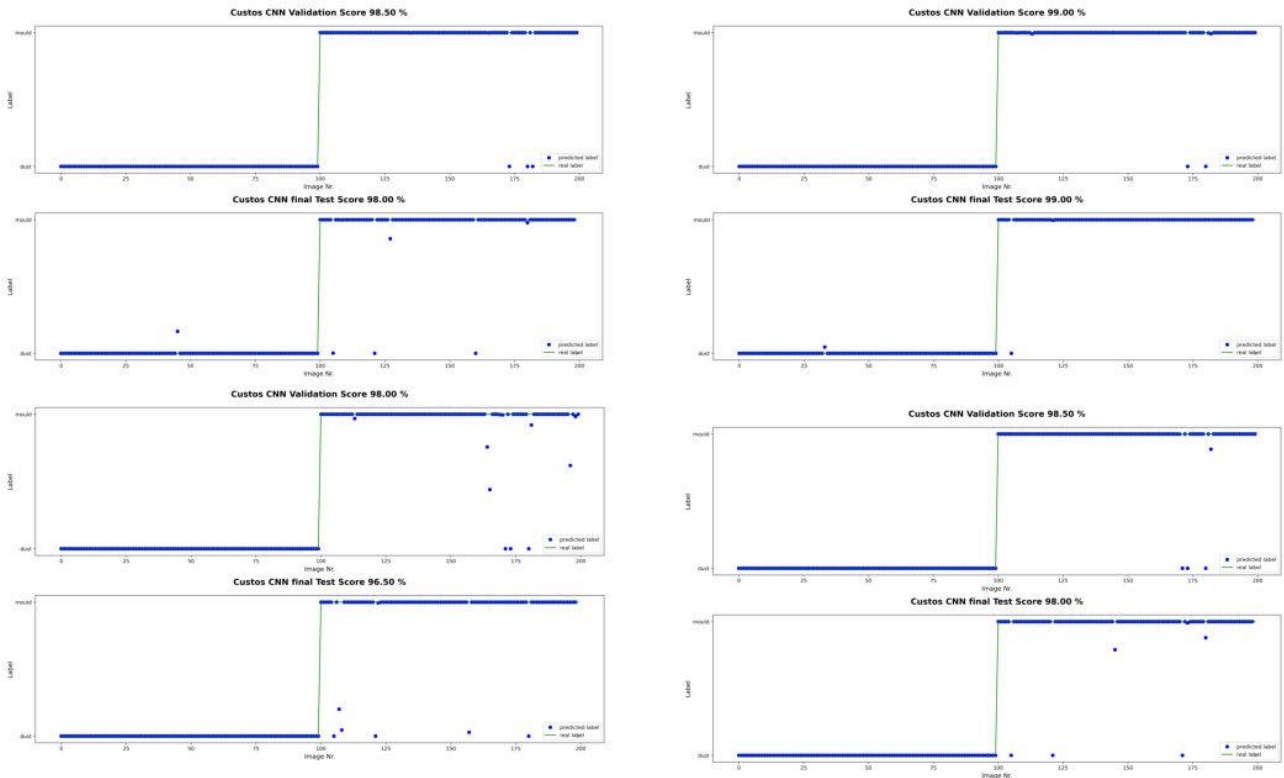
183

Die 124 ist etwas verwunderlich. Das darauffolgende Bild mit Textil als Träger wird aussortiert. Textilien werden später neu untersucht. Die anderen erscheinen doch plausibel und werden nicht aussortiert. Der Trainingsdatensatz wird nicht geändert. Die weiteren Untersuchungen finden nun mit Bilddatensatz 2 statt, um die Verbesserung durch die Auswahl der Bilder zu beurteilen.

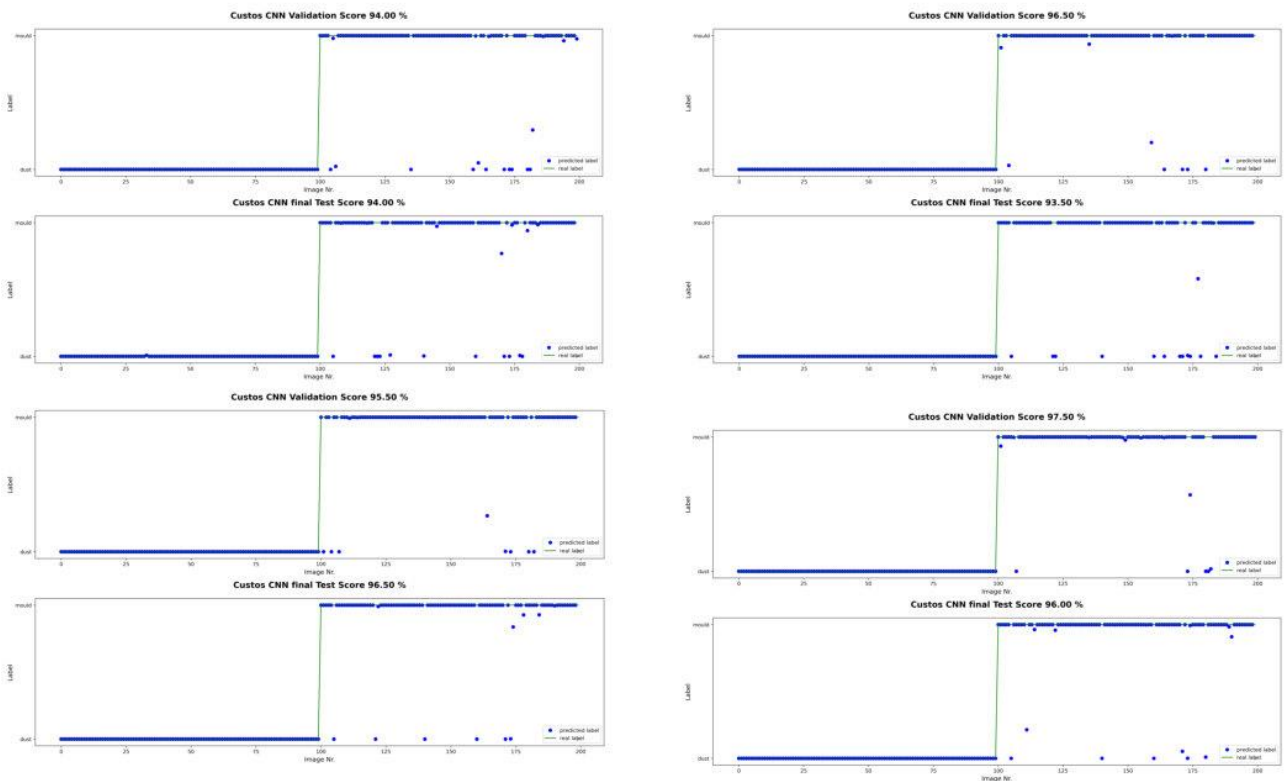
### **3.3.3 Bilddatensatz 2: Schimmel/Staub mit 2000 Trainings-Bildern und Akkumulieren der Gewichtsfunktion bei jedem Lauf**

Gleichzeitig mit den neuen Bildern im Test- und Validation-Pool werden die Parameter Batch Size Train und ValLossPatience geändert, um die beste Konfiguration zu finden:

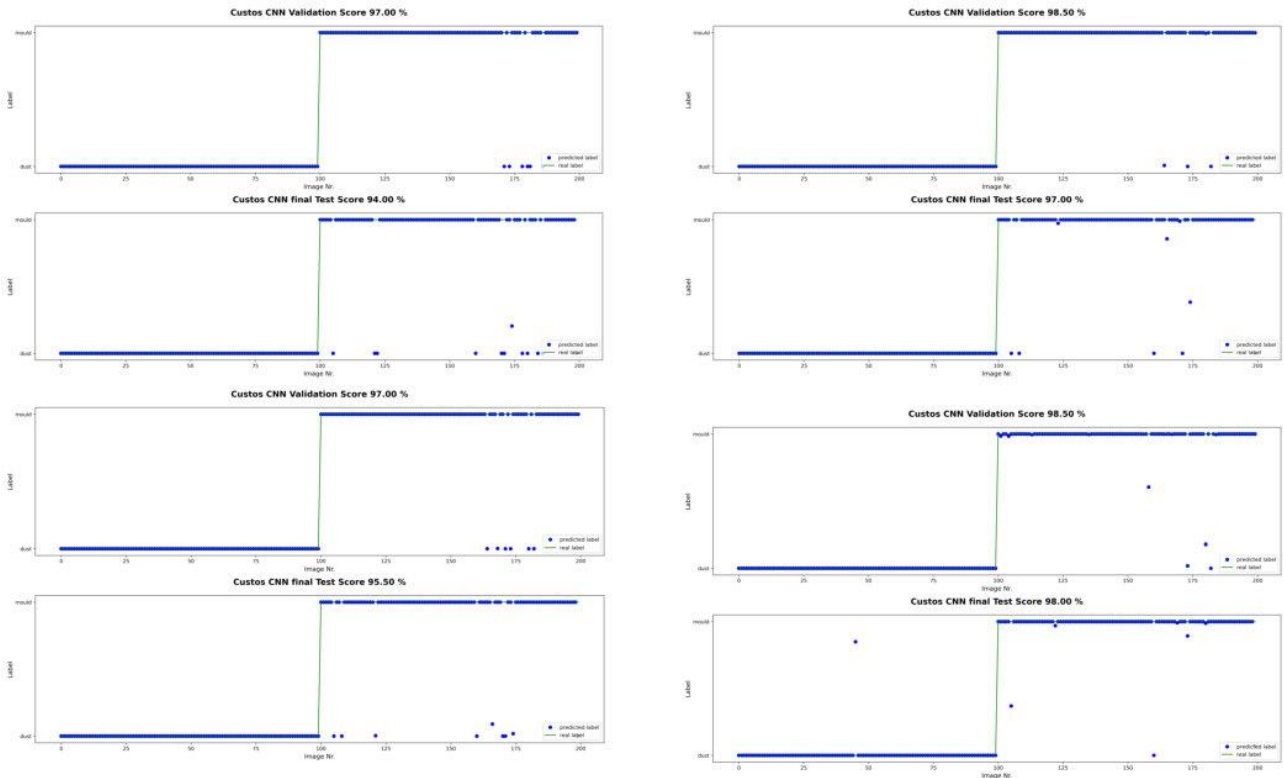
Picture Set=2, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=32, Batch Size Validate=16, Val Loss Patience=30, weights=accumulated



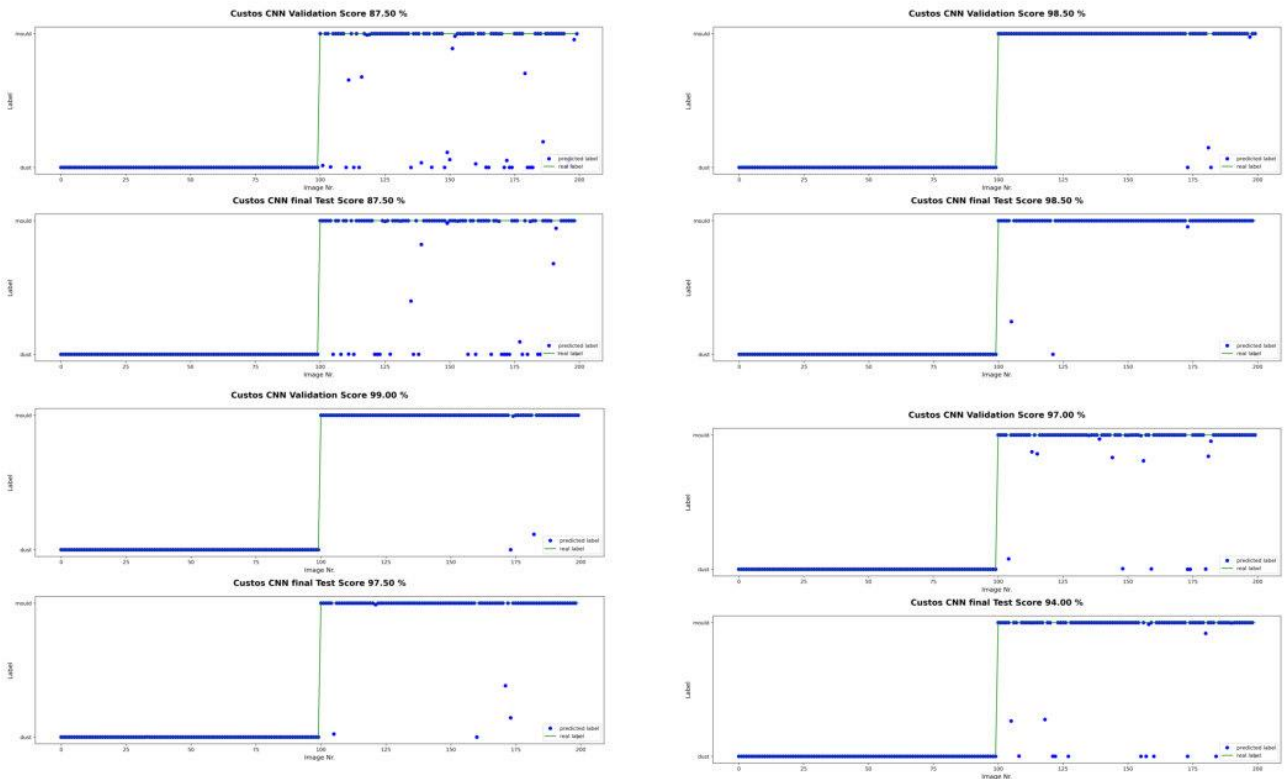
Picture Set=2, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=48, Batch Size Validate=16, Val Loss Patience=30, weights=accumulated



Picture Set=2, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=48, Batch Size Validate=16, Val Loss Patience=25, weights=accumulated



Picture Set=2, Pixel 200x200, mould/dust, Train=2000, Validate=100, Test=100,  
 Batch Size Train=32, Batch Size Validate=16, Val Loss Patience=25, weights=accumulated





Die folgende Tabelle zeigt die Ergebnisse in Übersicht:

file No	Batch Size train	Batch Size Validate	Val Loss Patience	weighths	run No.	Validation Score	Test Score	wrong Validation dust	wrong validation mould	wrong test dust	wrong test mould
1	32	16	30	accumulated	1	98,5	98,0	0	174,181,183	46	106,122,128,161
					2	99,0	99,0	0	174,183	0	6
					3	98,0	96,5	0	many	0	many
					4	98,5	98,0	0	many	0	many
					average	98,5	97,9		standard deviation	0,4	1,0
2	48	16	30	accumulated	1	94,0	94,0	0	many	0	many
					2	96,5	93,5	0	many	0	many
					3	95,5	96,5	0	many	0	many
					4	97,5	96,0	0	many	0	many
					average	95,9	95,0		standard deviation	1,5	1,5
3	48	16	25	accumulated	1	97,0	94,0	0	many	0	many
					2	98,5	97,0	0	165,174,183	0	6,9,162,173
					3	97,0	95,5	0	many	0	many
					4	98,5	98,0	0	175,181,183	46	106,161
					average	97,8	96,1		standard deviation	0,9	1,8
4	32	16	25	accumulated	1	87,5	87,5	0	many	0	many
					2	98,5	98,5	0	174,182,183	0	106,122
					3	99,0	97,5	0	174,183	0	106,161,172,174
					4	97,0	94,0	0	many	0	many
					average	95,5	94,4		standard deviation	5,4	5,0
ungeeignete Bilder								0	174,181,183	0	106,122,161

ERGEBNIS des Trainings mit Akkumulation für die Bildpools mit ausgetauschten Bildern im Validation- und Test-Pool:

Die besten Ergebnisse werden mit

Batch Size Train: 32

ValLossPatience: 30

Diese Einstellungen werden für die kommenden Untersuchungen nicht mehr geändert. Die Bilder werden nicht ausgetauscht, um zu untersuchen, wie ein Anstieg von 2000 auf 4000 Bildern die Situation beeinflusst.

### 3.3.4 Training bei festen Einstellparametern: Hier Wiederholungsprüfung für Bilddatensatz 3 für Schimmel und ok

Die Bilder für Schimmel und ok werden in den Bildpool für Train, Validation und Test geladen. Die Bilder werden nun nicht mehr gezeigt, sondern nur noch die tabellarische Auswertung. Die Bilder sind jederzeit abrufbar:

repetition run	run No.	Validation Score	Test Score	Sum of Scores	wrong pictures validation	wrong pictures test
1	1	92,0	91,5	183,5		
	2	93,0	93,5	186,5		
	3	95,5	95,0	190,5		
	4	98,0	96,5	194,5	102,114,126,129	113,115,147,161,172
	5	92,5	93,0	185,5		
	6	95,5	97,0	192,5	114,116, 126,129	70, 74, 113
	7	96,0	97,0	193,0		
	8	95,5	95,0	190,5		
2	1	95,5	96,0	191,5		
	2	90,5	93,5	184,0		
	3	98,0	97,5	195,5		
	4	93,5	94,0	187,5		
	5	97,0	98,5	195,5		
	6	98,0	98,5	196,5	114,116, 126,129	70, 74, 113
	7	97,0	98,5	195,5		
	8	96,5	98,0	194,5		
3	1	94,5	91,5	186,0		
	2	93,5	92,0	185,5		
	3	97,0	96,0	193,0		
	4	97,0	98,0	195,0		
	5	97,5	97,5	195,0	114,116, 126,138	113,115,147,161
	6	97,5	95,0	192,5		
	7	96,0	98,0	194,0		
	8	97,5	98,0	195,5		

Im Wiederhollauf 1 ergibt run 4 das beste Ergebnis, in Wiederhollauf 2 ist es run 6 und in Wiederhollauf 3 run 5. Das beste Ergebnis von allen hat Wiederhollauf 2 mit run 6.

Damit liefern die drei Läufe sehr reproduzierbare Ergebnisse in der falschen Erkennung:

Für Validation:

Nr. 114 wird 3x falsch erkannt

Nr. 116 wird 2x falsch erkannt

Nr. 126 wird 3x falsch erkannt

Nr. 129 wird 2x falsch erkannt

Für Test:


Nr. 113 wird 3x falsch erkannt

Nr. 116 wird 3x falsch erkannt

Nr. 147 wird 2x falsch erkannt

Nr. 161 wird 2x falsch erkannt

Das Bild für das beste Ergebnis ist:




Die fehlerhaften Bilder werden nicht ausgetauscht, um die Wirkung einer höheren Anzahl von Bildern zu bewerten.

Das weitere Training findet nun ohne Wiederholung und ohne Parametermodifikation statt. Es werden nur die Übersichtstabellen gezeigt, keine falschen Bilder mehr gezählt und es wird das Bild des besten Ergebnisses gezeigt.

### 3.3.5 Picture Set 4, Staub gegen ok bei 2000 Trainingsbildern

run No.	Validatio n Score	Test Score	Sum of Scores
1	98,0	96,5	194,5
2	95,0	94,0	189,0
3	96,5	96,5	193,0
4	97,5	96,5	194,0
5	99,5	99,5	199,0
6	99,5	99,0	198,5
7	99,5	99,5	199,0
8	98,5	98,5	197,0





### 3.3.6 Picture Set 5 Schimmel gegen ok bei 4000 Bildern

Die 2000 Bilder werden ergänzt, Validation- und Test-Bildpool unverändert.



run No.	Validation Score	Test Score	Sum of Scores
1	83,0	81,0	164,0
2	89,0	87,5	176,5
3	97,0	96,0	193,0
4	98,0	98,0	196,0
5	97,0	98,0	195,0
6	93,5	94,0	187,5
7	95,5	95,0	190,5
8	98,0	100,0	198,0







### 3.3.7 Picture Set 6 Staub gegen ok bei 4000 Bildern

run No.	Valida- tion Score	Test Score	Sum of Scores
1	98,5	98,0	196,5
2	99,0	99,5	198,5
3	99,5	100,0	199,5
4	99,5	100,0	199,5




### 3.3.8 Picture Set 7 Schimmel gegen Staub bei 4000 Bildern

run No.	Validation Score	Test Score	Sum of Scores
1	100,0	99,5	199,5
2	100,0	98,0	198,0
3	98,0	97,0	195,0
4	98,5	97,5	196,0





### 3.3.9 Picture Set 8 Schimmel gegen ok mit 6000 Bildern

run No.	Validation Score	Test Score	Sum of Scores
1	97,5	95,5	193,0
2	94,0	95,5	189,5
3	94,5	94,0	188,5
4	96,5	99,0	195,5



### 3.3.10 Picture Set 9 Staub gegen ok mit 6000 Bildern


run No.	Validation Score	Test Score	Sum of Scores
1	96,0	95,0	191,0
2	98,0	98,5	196,5
3	98,5	99,5	198,0
4	98,5	98,0	196,5



### 3.3.11 Picture Set 10 Schimmel gegen Staub mit 6000 Bildern

run No.	Validation Score	Test Score	Sum of Scores
1	100,0	97,5	197,5
2	99,5	98,0	197,5
3	100,0	99,5	199,5
4			





### ERGEBNIS des Trainings bis 6000 Bilder:

Schimmel gegen Staub wird mit Zunahme der Bilder immer schneller und auch sehr gut erkannt.

Staub gegen o.k. wird bei 4000 Bildern viel besser erkannt als bei 2000 Bildern, bei 6000 Bildern lässt die Erkennungsrate etwas nach.

Schimmel gegen o.k. wird gut erkannt bei 2000 Bildern, bei 4000 Bildern wird Schimmel leicht diffus erkannt und bei 6000 Bildern wird ok leicht diffus erkannt.

Die Erkennungsraten liegen bis auf eine Ausnahme oberhalb von 98 %.

### **3.4 (Gedächtnis-)Protokoll der Beiratssitzung**

Systemplattform zur automatischen Detektion von Schimmelbildung an Kulturgütern  
mittels künstlicher Intelligenz

Termin: 17. Juni 2020

Uhrzeit: 10:00 Uhr bis ca. 13:00 Uhr, ab ca. 12:30 Videoschaltung für alle Interessierte

Ort: Kapitelsaal der Dombauhütte Xanten

Teilnehmer: Johannes Schubert, Leiter der Xantener Dombauhütte  
Hans-Jürgen Daams, Hajuveda-Heritage

weitere 3 Personen der Xantener Dombauhütte  
Judith Meider, Geschäftsführer Schimmellabor-Urbanus, Düsseldorf  
Vesa Klumpp, Geschäftsführer Knowtion UG, Karlsruhe  
Michael Robrecht, iXtronics GmbH

Teilnehmer per Video:

Marc Peez, LVR-Amt für Denkmalpflege im Rheinland

#### Tagesordnung:

10:00 – 10:10      Vorstellungsrunde und Einführung in den Xantener Dom von  
Johannes Schubert  
10:10 – 10:25      Kurze Projektvorstellung von Hans-Jürgen Daams  
10:25 – 11:00      Rundführung im Xantener Dom  
11:00 – 12:30      Vorstellung der bisherigen Arbeiten von Michael Robrecht und Hans-  
Jürgen Daams  
12:30 – 13:00      Schluß-Diskussion als Videokonferenz  
Ab 13:00      belegte Brötchen und Ausklang

#### Präsentation:

Die Präsentation fand mithilfe der bereits verteilten PowerPoint:

„Präsentation Systemplattform zur Schimmeldetektion\_V6.0\_2020\_06\_15\_Stand der  
Arbeiten“

statt und wurde eingehend von den Beteiligten diskutiert. Aktuelle Vorfälle von Schimmel konnten im Xantener Dom betrachtet werden. Es entstand eine Diskussion darüber, wie es zu Schimmel an den Altären kommen kann, obwohl die Sensoren in der Schutzverglasung ein eher geringeres Risiko anzeigen.

Nach der Präsentation waren sich alle Beteiligten einig, dass der im Projekt verfolgte Ansatz zur Schadensdetektion sehr wichtig und sinnvoll ist!

#### Empfehlungen des Beirates:

Es schloß sich eine Diskussion an, wie man den Dom von Xanten weiter unterstützen kann.

Dort ist es insbesondere in den Sommermonaten zu feucht, wie eine Messung es ergeben hat.

Um die Einflüsse von Heizung, Klima, Strömung, Turbulenzen, Kirchenbesucher besser einschätzen zu können, wurde im Rahmen eines DigiPro-geförderten Projektes eine Vielzahl von Sensoren in der Kirche dauerhaft montiert. Die Sensoren erfassen Messgrößen wie insbesondere die Lufttemperatur, relative Feuchte und die Strömungsgeschwindigkeit.

Bei 12 Messorten und 3 Messgrößen kommen damit alle 2 Minuten 72 Messdaten und damit gut 18.000.000 Daten pro Jahr an, die zu interpretieren sind. Nicht nur die Interpretation der Messdaten ist bei dieser großen Menge für den Menschen sehr schwierig, sondern auch die Korrelation aller Daten untereinander und mit externen Ereignissen, z.B. Sonneneinstrahlung, Besucher in der Kirche, Messen, offene Türen,

Durchzug, Heizung schaltet ein und aus und z.B. drohende klimatische Schnell-Änderungen.

Eine Möglichkeit zur Lösung dieses Problems ist der Einsatz neuerer Methoden der künstlichen Intelligenz im Rahmen der „Sensor Fusion“. Der Beirat hat empfohlen, diese neuen Methoden im Hinblick auf Anwendbarkeit im Xantener Dom zu untersuchen.

Des Weiteren wurde darauf hingewiesen, daß Schimmel auch auf den Vorderseiten der Altäre entsteht und dort keine der geplanten Sensoren installiert werden können, weil sie im Gesichtsfeld der Besucher sind. Herr Schubert hat den Einsatz von Drohnen hier vorgeschlagen und empfohlen, dieses Thema auf Machbarkeit hin zu überprüfen.

Zum besseren Verständnis der Entstehung des Aspergillus Glaucus wurden Simulationen im Klimaschrank vorgeschlagen. Auch hier hat der Beirat den Antragstellern empfohlen, eine Machbarkeit zu überprüfen.

### **3.5 Unterstützer des Projektes**

Die Unterstützer des Projektes haben aktiv zum Gelingen des Projektes beigetragen und wurden 3-mal über den Projektfortschritt informiert. Ohne deren Unterstützung wäre das Projekt nicht so erfolgreich gewesen. Ihnen allen sei herzlich gedankt.

<b>Person</b>	<b>Organisation</b>	<b>Ort</b>
Dr. Birte Graue	LWL	Münster
Prof. Erwin Stadlbauer	Landeskirche Hannover	Celle
Constanze Roth	Innovent Jena	Jena
Thomas Löther	IDK	Dresden
Prof. Rainer Drewello	Kompetenzzentrums für Denkmalwissenschaften und Denkmaltechnologien	Bamberg
Dr. Irmgard Hunecke	Archäologie und Denkmalpflege	Lübeck
Werner Lemke	EVLKA	
Dr. Astrid Hammer	Biologin und MA in Präventiver Konservierung, Österreichisches Museum für Volkskunde, Präventive Konservierung und Sammlungsbetreuung	Wien
Jochen Jarzombek	Diözesanbaumeister Bistum Passau	Passau
Dr. Norbert Jocher	Erzbischöfliches Ordinariat München	München
Prof. Sebastian Strobl	FH Erfurt - Bauingenieurwesen, Konservierung, Restaurierung	Erfurt
Lutz Peter	Restaurator Kirche Gollwitz bei Brandenburg	Schwielowsee
Andra-Lisa Hoyt	Dissertation Uni-Konstanz	Konstanz
Judith Fritz	Restaurator	Bretten

Dirk Sturfels Steffi Wirsing-Nolte	Präsidium VDR Restauratorin	Pinneberg Breitenworbis
Prof. Alexandra Jeberin	HTW Berlin	Berlin
Prof. Rüdell	HTW Berlin	Berlin
Patrizia Brozio	Referentin Pressearbeit Präsidium VDR	Bonn
Manfred Torge	BAM	Berlin
Björn Seewald	Bayrisches Landesamt für Denkmalpflege Berlin-Brandenburgische Akademie der Wissenschaften, Corpus Vitrearum Medii Aevi	München Potsdam
Beate Skasa-Linder- meir	Stein- und Wand-Restauratorin	Wolfenbüttel
Anne Heckenbücker	LVR Amt für Denkmalpflege, Restauratorin	Pulheim
Mark Peez	LVR Amt für Denkmalpflege	Pulheim
Johanna Thenert	KI-NRW	St. Augustin
Silvia Wagner	Stiftung Thüringer Schlösser und Gärten	Rudolstadt
Iris Herpers	Landesmuseum Hannover	Hannover
Hagn, Cornelia	BLfD, Restauratorin Gemälde/Skulptur	München
Petra Schwärzel	Restauratorin Kiosterkirche Gars am Inn Staatliche Schlösser, Gärten und Kunst- sammlungen Mecklenburg-Vorpommern	Wasserburg
Barbara Nagel	Kunsthistorikerin und Restauratorin	Schwerin
Julia Feldtkeller	Mayersche Hofkunst	Tübingen
Walter Uptmoor		München
Iris Henke		
Barbare Wapler		
Stefan Muck	<a href="http://www.muck-restaurierung.de/">http://www.muck-restaurierung.de/</a>	Dießen am Am- mersee
Andreas Franz	<a href="https://divisual.com/info/about">https://divisual.com/info/about</a>	Zürich
Charlotte Höpker	Bayrisches Landesamt für Denkmalpflege	München
Alexandra Schmauch	Restauratorin Glasmalerei Derix	Taunusstein
Jürgen Frick	MPA Stuttgart	Stuttgart
Katrin Schmitt	FG für physikalische Messtechnik	Freiburg
Stefanie Scheerer	Biophil	Stuttgart
Bellendorf		Bamberg
Camilla Bonita	Architekt Kulturgüter in Santiago di Chile	Chile
Pfarrerin M. Glöckner	Kirchengemeinde Herold	Herold
Herr Reuther	Kirchengemeinde Herold	Herold
Magdalena.Herbst	Kirchengemeinde Hilbersdorf	Hilbersdorf

Kantor Schilling	Kirchengemeinde Hilbersdorf	Hilbersdorf
Irmtraud Weiß	Kirchengemeinde Glösa und Ebersdorf	Glösa und Ebersdorf
Ulrike Brinkmann	Dombauhütte Köln	Köln
Albert Distelrath	Dombauhütte Köln	Köln
Prof. Bönig	Organist Kölner Dom	Köln
Katrin Wittstadt	Dombauhütte Köln	Köln
Alexandra Fritsch	Fritsch, Knodt, Klug + Partner mbB Architekten	Nürnberg

**Insgesamt konnten folgende Fotos beigesteuert werden:**

Kölner Dom, Altäre, 22 Fotos

Nürnberg St. Sebald, Reliquienschein, 3 Fotos

Blaibach, Glasmalerei, 13 Fotos

Eschlkam-Warzenried, Glasmalerei, 5 Fotos

Velden, Glasmalerei, 31 Fotos

Wiener Orient-Bibliothek, 2 Fotos

Wien, Blaselgasse Wohnung, 7 Fotos

Kärntner Landesmuseum, 6 Fotos

Wien, Institut für Kultur und Sozialanthropologie , 2 Fotos

Wien-Marchegg, Wohnung, 7 Fotos

Wien, neues Instituts-Gebäude, 5 Fotos,

Mühldorf-Frauenkirche, Figur, 3 Fotos

Neuötting-Christuskirche, Altar, 3 Fotos

NN, Chorgestühl, 4 Fotos

Ottobeuren-Benediktinerabtei, Gemälde, 4 Fotos

Xantener Dom, Altäre, 1748 Fotos

Herscheid-Apostelkirche, Kanzel und Altar, 15 Fotos

Erwitte-St. Laurentius, Altäre, 272 Fotos

Herdecke-Kirchende, Orgelkanzelaltar, 8 Fotos

Lichtenau-Atteln, St. Achatius, 114 Fotos

Werl, St. Walburga, 225 Fotos

Euskirchen-Frauenberg, 7 Fotos

Kalkar-Grieth, 6 Fotos

Kalkar-St. Nicolai, 1 Foto,

Kalkar-Wissel St. Clemens, 16 Fotos

Kleve, Stiftskirche, 14 Fotos,



LVR, 11 Fotos,  
Pulheim-Brauweiler, St. Nikolaus, 15 Fotos  
Münster, St. Paulus-Dom, 61 Fotos  
Gars-am-Inn, Klosterkirche, 23 Fotos  
München 3 Fotos  
NN, Glas, 4 Fotos  
Ebersdorf, Stiftskirche, Orgel, 18 Fotos  
Glösa, St. Jodokus, Orgel, 35 Fotos  
Herold, Heiligkreuz, Orgel, 350 Fotos,  
Hilbersdorf, Trinitatis, Orgel, 27 Fotos,  
Obergrafendorf, Putz, 9 Fotos  
Kölner Dom, Glas-Ornamentscheibe, 77 Fotos,  
Kölner Dom, Orgel, 194 Fotos

In der Zwischenzeit wurde diese Liste nochmals deutlich erweitert.

### **3.6 Veröffentlichungen**

Rundschreiben an die Unterstützer im frühen Sommer 2020, Herbst 2020 und Herbst 2021 mit ausführlichen Informationen zum Fortschritt des Projektes als Power-Point-Format.

2 Veröffentlichungen im VDR

7 Veröffentlichungen im Blog:

<https://custosaeris-d.blogspot.com/search/label/Custos%20Mucoris>

9 Veröffentlichungen in LinkedIn:

<https://www.linkedin.com/in/hajuveda-heritage-dr-hans-juergen-daams/detail/recent-activity/shares/>

7 Veröffentlichungen in Xing unter <https://www.xing.com/home>

1 Veröffentlichung für das „11. Forum for the conservation and technology of historic stained glass 2022“ in Barcelona:

“Method for the automatic determination of damage to cultural objects with the aid of artificial intelligence.”

### **3.7 Abbildungsverzeichnis**

Abbildung 1 Raspberry PI 4 Funktionsschaltbild 2020 © iXtronics-Hajuveda ..... 6

Abbildung 2 Zeit- und Energiemanagement mit WittyPi3 2020 © Raspberry.....	7
Abbildung 3 HQ-Kamera mit 12.3 MPixel Auflösung 2020 © Sony .....	7
Abbildung 4 HQ-Kamera mit SONY IMX477R Sensor 2020 © SONY.....	8
Abbildung 5 Weitwinkelobjektiv mit 6mm Brennweite 2020 © Raspberry .....	8
Abbildung 6 LED-Stäbe mit tageslichtnahem Licht 2020 © Adafruit.....	8
Abbildung 7 hochgenauer I <sup>2</sup> C-Temperatur & Luftfeuchte-Senso 2020 © seedGrove.....	9
Abbildung 8 Kunststoffgehäuse Schimmelkamera mit PI 4 und Witty 2021© iXtronics-Hajuveda .....	10
Abbildung 9 Schimmelkamera mit Objektiv und VIS-Dioden 2021© iXtronics-Hajuveda.....	10
Abbildung 10 Schimmelkamera mit Sensoranschluß 2021© iXtronics-Hajuveda .....	11
Abbildung 11 Schimmelkamera Rückwand 2021© iXtronics-Hajuveda.png.....	11
Abbildung 12 Schimmelkamera Seitenwand 2021© iXtronics-Hajuveda.....	11
Abbildung 13 Schimmelkamera Seitenwand für Schalter 2021© iXtronics-Hajuveda .....	12
Abbildung 14 Schimmelkamera mit eingebautem Akku an der Oberseite 2021© iXtronics-Hajuveda .....	12
Abbildung 15 Schimmelkamera Oberseite mit Anschlüssen über Stativ und Aufhängung 2021© iXtronics-Hajuveda...	13
Abbildung 16 Schimmelkamera Oberseite mit Anschlüssen .....	14
Abbildung 17 Schimmelstativ mit allen notwendigen Komponenten und Beleuchtungen 2020© iXtronics-Hajuveda ..	15
Abbildung 18 Schimmelstativ auch für knifflige Ecken 2020© iXtronics-Hajuveda .....	15
Abbildung 19 Sichtbarkeit von Schimmel bei VIS- und UV-Beleuchtung 2020© iXtronics-Hajuveda .....	17
Abbildung 20 Sichtbarkeit des Schimmels bei UV-C und IR-Beleuchtung 2020© iXtronics-Hajuveda .....	17
Abbildung 21 Vergleich Sichtbarkeit Schimmel für alle 4 Beleuchtungsquellen 2020© iXtronics-Hajuveda.....	18
Abbildung 22 Beispiel für ein besseres Ergebnis bei UV-Beleuchtung 2020© iXtronics-Hajuveda.png.....	18
Abbildung 23 Vergleich der Sichtbarkeit bei allen 4 Beleuchtungsquellen mit Verbesserung bei UV 2020© iXtronics-Hajuveda.....	19
Abbildung 24 Fluoreszenz von Staub auf Steinsockel 2020© iXtronics-Hajuveda .....	20
Abbildung 25 Fluoreszenz im Mörtel 2020© iXtronics-Hajuveda .....	21
Abbildung 26 Fluoreszenz von Lötstellen 2020© iXtronics-Hajuveda.....	21
Abbildung 27 Benötigte Materialien für die Rapp-Methode 2021© iXtronics-Hajuveda .....	23
Abbildung 28 Manueller Weißabgleich nach der Rapp-Methode 2021© iXtronics-Hajuveda.....	23
Abbildung 29 Helena-Altars mit Schimmel für Erprobung Rapp-Methode 2021© iXtronics-Hajuveda.....	24
Abbildung 30 Helena-Altars Figur mit Schimmel für Erprobung Rapp-Methode 2021© iXtronics-Hajuveda.....	24
Abbildung 31 Rückseite des Altars mit Schimmel für Erprobung Rapp-Methode 2021© iXtronics-Hajuveda .....	25
Abbildung 32 Ordnerstruktur auf dem FTP-Server .....	26
Abbildung 33 Definition der Feldgrößen im Skript 2020© iXtronics-Hajuveda .....	27
Abbildung 34 Datenbankprogrammablaufplan 2020© iXtronics-Hajuveda.....	28
Abbildung 35 Ablauf der automatisierten Erstellung der Bilddatenbank 2020© iXtronics-Hajuveda .....	29
Abbildung 36 Datenbanktabelle mit aktuellen Inhalten 2020© iXtronics-Hajuveda .....	29
Abbildung 37 Foto aus dem Xantener Dom mit mehreren Schadenmerkmalen 2020© iXtronics-Hajuveda .....	30
Abbildung 38 Beispiele geschnittener Bilder 2020© iXtronics-Hajuveda .....	31
Abbildung 39 Oberfläche des Programms zur Schadenseinteilung 2020© iXtronics-Hajuveda .....	32
Abbildung 40 Baby in der Lernphase 2020© Pixabay.....	33
Abbildung 41 Netzhaut mit über 1 Millionen Pixeln 2020© Pixabay .....	33
Abbildung 42 Überwachtes Lernen 2020© Pixabay .....	34
Abbildung 43 Von den Neuronen zur Simulation 2020© Ertl .....	34
Abbildung 44 Synapsen verbinden Neuronen miteinander 2020© Ertl.....	35
Abbildung 45 Struktur eines formalen Neurons 2020© Ertl .....	35
Abbildung 46 Von der Biologie zur Computersimulation 2020© Rashid .....	36
Abbildung 47 Darstellung des CNN im Schimmelprojekt 2020© Rashid-iXtronics-Hajuveda .....	36
Abbildung 48 Struktur von CNN 2020© NN .....	37
Abbildung 49 Ergebnisse der Validierungs- und Testphase des CNNs 2021© iXtronics-Hajuveda.....	38
Abbildung 50 Bilder für das Prediction Skript 2021© iXtronics-Hajuveda .....	39
Abbildung 51 Ergebnisplot aus dem Prediction Skript 2021© iXtronics-Hajuveda.....	40
Abbildung 52 Bilder in Merkmalklasse Schimmel 2021© iXtronics-Hajuveda .....	42
Abbildung 53 Bilder in Merkmalklasse Staub 2021© iXtronics-Hajuveda.....	43

Abbildung 54 Custos CNN Korrektheitsrate für die Klassifizierung 2021© iXtronics-Hajuveda .....	44
Abbildung 55 Custos CNN finales Testergebnis in Prozent 2021© iXtronics-Hajuveda .....	45
Abbildung 56 mould_ok_32_30 6000 run_3_0125 2021© iXtronics-Hajuveda.....	46
Abbildung 57 dust_ok_32_30 6000 run_4_0118 2021© iXtronics-Hajuveda .....	47
Abbildung 58 dust_mould_32_30 6000 run_3_0212 2021© iXtronics-Hajuveda .....	48
Abbildung 59 Bilder für den Prediction Test 2021© iXtronics-Hajuveda .....	48
Abbildung 60 Ergebnis des Prediction Tests 2021© iXtronics-Hajuveda .....	49
Abbildung 61 Erprobung des Prediction Skriptes bei Schimmel auf Glas 2021© iXtronics-Hajuveda .....	50
Abbildung 62 Funktionstest in Xanten am Barbara Altar 2021© iXtronics-Hajuveda .....	50
Abbildung 63 Kamera auf Stativ montiert 2021© iXtronics-Hajuveda.....	51
Abbildung 64 Gesamtaufbau für den Funktionstest 2021© iXtronics-Hajuveda .....	51
Abbildung 65 Gesamtaufbau ohne Zusatzgeräte 2021© iXtronics-Hajuveda.....	52
Abbildung 66 Kameraaufnahme vom Objekt um Mitternacht 2021© iXtronics-Hajuveda .....	52
Abbildung 67 Helenaaltar mit 14000 Stunden Messdaten für die Temperatur und relativen Feuchte 2021© iXtronics-Hajuveda.....	57
Abbildung 68 Aufenthaltsdauer in bestimmten Klimaklassen am Helenaaltar 2021© iXtronics-Hajuveda .....	58
Abbildung 69 Vermutung von Sorptionseffekten nach Beginn der Heizperiode 2021© iXtronics-Hajuveda .....	59
Abbildung 70 Schimmelexplosion in einem Jahr in St.Laurentius in Erwitte 2021© iXtronics-Hajuveda .....	61
Abbildung 71 Neu entdeckter Schimmel in St.Laurentius in Erwitte 2021© iXtronics-Hajuveda .....	62
Abbildung 72 Flächenprozentanteil zur Quantifizierung des Schimmelwachstums 1 Jahr 2021© iXtronics-Hajuveda...	63
Abbildung 73 Feldtest System Xanten 2021© iXtronics-Hajuveda .....	64
Abbildung 74 Kamerabild aus Feldtest System Xanten 2021© iXtronics-Hajuveda.....	65
Abbildung 75 Nachtraining CNN mit Kamerabildern 2021© iXtronics-Hajuveda .....	66
Abbildung 76 Kontrolle des Prediction Skripts aus Feldtest Xanten 2021© iXtronics-Hajuveda .....	66
Abbildung 77 Ergebnis der Kontrolle Prediction Script 2021© iXtronics-Hajuveda .....	67
Abbildung 78 Xanten montierter Schimmel Ausschnitt 2021© iXtronics-Hajuveda.....	68
Abbildung 79 Xanten Ergebnis Prediction Skript 2021© iXtronics-Hajuveda .....	68
Abbildung 80 Feldtest System Münster 2021© iXtronics-Hajuveda .....	69
Abbildung 81 Kamerabild aus Feldtest System Münster 2021© iXtronics-Hajuveda .....	70
Abbildung 82 Erkennungsrate mit Nachtraining der Münsteraner Oberfläche 2021© iXtronics-Hajuveda.....	70
Abbildung 83 Münster Feldtest benachbarte Platte mit Schimmel 2021© iXtronics-Hajuveda .....	71
Abbildung 84 Münster Feldtest Geschnittene Bilder für benachbarte Holzplatte 2021© iXtronics-Hajuveda .....	72
Abbildung 85 Münster Feldtest Erkennung Schimmel Prediction Skript Nachbarwand 2021© iXtronics-Hajuveda.....	72
Abbildung 86 Kölner_Dom_Klaren_Altar_2020© iXtronics-Hajuveda .....	73
Abbildung 87 Kölner_Dom_Klaren_Altar Schimmel_2020© iXtronics-Hajuveda .....	74
Abbildung 88 Kölner_Dom_Drei_Königen_Altar 2020© iXtronics-Hajuveda.....	75
Abbildung 89 eventuell Schimmel auf blau gefärbten Träger 2020© iXtronics-Hajuveda.....	76
Abbildung 90 eventuell Schimmel auf blau gefärbten Träger 2021© iXtronics-Hajuveda.....	76
Abbildung 91 Kölner Dom Kreuzgang Station 1 2021© iXtronics-Hajuveda .....	77
Abbildung 92 Kölner Dom Kreuzgang Station 2 2021© iXtronics-Hajuveda .....	78
Abbildung 93 Kölner Dom Orgel 2021© iXtronics-Hajuveda.....	79
Abbildung 94 Kölner Dom mittelalterliches Ornamentglas 2020© KölnerDom .....	80
Abbildung 95 Schimmelpilz Penicillium in der Wachstumsphase 2021© iXtronics-Hajuveda .....	81
Abbildung 96 Training CNN mit Schimmelpilz Penicillium auf Nährlösung 2021© iXtronics-Hajuveda.....	82
Abbildung 97 Erkennung der minimalen erkennbaren Schimmelgröße 2021© iXtronics-Hajuveda .....	82
Abbildung 98 Erkennung im Prediction Skript 2021© iXtronics-Hajuveda .....	83
Abbildung 99 Bilder zum Schimmelwachstum in Tagen 2021© iXtronics-Hajuveda .....	83
Abbildung 100 Fluoreszenzspektrum Quelle Thermofisher .....	86

## 4 Literaturverzeichnis

(EKM), E. K. (2021). *Schimmelbefall an Orgeln in Kirchenräumen - Entwicklung und modellhafte*

*Erprobung von innovativen Strategien zur Prävention und Bekämpfung am Beispiel national wertvoller Kulturgüter.* Erfurt: DBU 34554/01.

- Abdelhak Belhi, A. B. (2018). *Leveraging Known Data for Missing Label Prediction in Cultural Heritage Context.* Appl. Sci. 2018, 8(10), 1768; <https://doi.org/10.3390/app8101768>.
- Becca. (2012). *Using UV-fluorescence to Detect Grey Mold (Botrytis cinerea) Infections: Possible Implications for Field Detection Technologies.* <http://www.academicwino.com/2012/05/using-uv-fluorescence-to-detect-grey.html/>.
- BioChip. (2018-2020). *Entwicklung und modellhafte Anwendung einer innovativen multiparametrischen Sensoriklösung für eine kostengünstige und flächendeckende Überwachung der durch anthropogene Umwelteinflüsse hervorgerufenen VOC-Belastung von national wertvollem Kulturgut.* München: [https://www.dbu.de/projekt\\_34671/01\\_db\\_2848.html](https://www.dbu.de/projekt_34671/01_db_2848.html).
- Bundesregierung. (2018). *Künstliche Intelligenz hat in den letzten Jahren eine neue Reifephase erreicht und entwickelt.* Berlin: Bundesregierung.
- Burmester, A., & Eibl, M. u.-S. (2013). *Climate for Collections: standards and uncertainties.* München: Postprints of the Munich Climate Conference.
- Burmester, M. E. (2013). *climate for Collections: standards and uncertainties.* München: Archetype Publications Ltd.
- Chaiyasarn. (2018). *Crack Detection in historical Structures based on convolutional neural networks.* Japan: International Journal of GEOMATE, Nov., 2018 Vol.15, Issue 51, pp.240-251.
- Degand, M. (2020). *Fluoreszierende Schimmelpilze.* Weimar: [https://www.uni-weimar.de/kunst-und-gestaltung/wiki/GMU:Art\\_out\\_of\\_living\\_matter/Maria\\_Degand](https://www.uni-weimar.de/kunst-und-gestaltung/wiki/GMU:Art_out_of_living_matter/Maria_Degand).
- DFKI, B. u. (2017). *Künstliche Intelligenz: Wirtschaftliche Bedeutung, gesellschaftliche Herausforderungen, menschliche Verantwortung.* Berlin: BitCom 2017.
- DIW. (2019). *Künstliche Intelligenz – Deutsche Unternehmen zwischen Risiko und Chance.* Köln: IW-Trends 4/2019.
- Drewello. (2019). *Analyse Nürnberg, St. Sebald, Reliquenschrein innen.* Nürnberg: ArchitektInnen Fritsch+Knodt&Klug.
- Florian, M.-L. (1997). *Heritage Eaters - Insects and Funghi in Heritage Collections.* Malta: Interprint Limited, <https://open.library.ubc.ca/cIRcle/collections/ubccommunityandpartnerspublicati/52387/items/1.0342857>.
- Floyd, A. (2016). *What If Aflatoxin Glowed? New Technology Makes Toxin Visible for No-Cost Testing.* Georgia: <https://www.agrilinks.org/blog/what-if-aflatoxin-glowed-new-technology-makes-toxin-visible-no-cost-testing>.
- Gram. (2000). *The Use Of Ultraviolet Induced Visible-Fluorescence In The Examination of Museum Objects Part II.* Conserve O Gram.
- Gustaf Leijonhufvud, E. K. (2012). *Uncertainties in damage assessments of future indoor climates.* München: Climate for Culture Conference Proceedings.
- Hammer, A. (2014). *Einsatz des Lumitesters zur Quantifizierung des Schimmelbefalls an Kulturgut.* Wien: interne Mitteilungen.
- Hammer, A. (2015). *Bedienungsanleitung Lumitester PD-20.* Wien: interne Mitteilung.
- Hammer, A. (2017). *Reinigung von Schimmelbefallenen Oberflächen.* München: Eipper, P.-B.: Handbuch der Oberflächenreinigung. München 2017.
- Harald Garrecht, D. J. (2017). *Raumklimastabilisierung zum Erhalt der durch anthropogene Umwelteinflüsse im Bestand gefährdeten Wandmalereien in der Kirche St. Georg (UNESCO - Weltkulturerbe Klosterinsel Reichenau).* Materialprüfungsanstalt Universität Stuttgart (MPA Stuttgart, Otto-Graf-Institut (FMPIA). Stuttgart: DBU Abschlußbericht 32712/01.
- HAWK. (2019). *Klimazone Kirche: Präventive Konservierung der Ausstattung.* Hildesheim: Abstracts der Vorträge Interdisziplinäre Tagung 16. bis 18. Januar 2019.
- Henning, I. C. (2018). *Ursache des Schimmelbefalls an Orgeln.* Sachsen: DBU Abschlußbericht AZ 31242-45.
- Hentschel, B. (2001). *Die Wandmalereien von Adolf Quensen im Chor der St. Lorenzkirche in Schöningen - Entwicklung eines Konzepts zur Konservierung/Restaurierung.* Hildesheim: Diplomarbeit.
- Holl, C. (2012). *Comparison of indoor climate analysis according to current climate guidelines with the conservational investigation using the example of Linderhof Palace.* München: Climate for Culture

Conference Proceedings.

- IBP, F. (2019). *Wufi-Software*. Valley: <https://wufi.de/de/software/produktuebersicht/>.
- IBP, F. (2019). *Wufi-Software*. Stuttgart: <https://wufi.de/de/software/produktuebersicht/>.
- Ioannides, M. F. (2018). *Digital Heritage. Progress in Cultural Heritage: Documentation, Preservation, and Protection*. Nicosia: Springer, 7th International Conference, EuroMed 2018, Nicosia,.
- Johanna Leissner, C. F. (2014). *Climate change impact on historic houses and collections – the EU project Climate for Culture*. München: [www.climateforculture.eu](http://www.climateforculture.eu) Grant agreement No. 22 6973 (2009 - 2014).
- Jose Llamas, P. M. (2017). *Classification of Architectural Heritage Images Using Deep Learning Techniques*. Valladolid, Spain: Appl. Sci. 2017, 7, 992; doi:10.3390/app7100992.
- Kappel, J. (2018). *Xantener Dom hat ein Schimmel-Problem – Kunstschatze bedroht*. Xanten: <https://www.kirche-und-leben.de/artikel/xantener-dom-hat-ein-schimmel-problem-kunstschaetze-bedroht/>.
- Kilian, R. (2014). *Historische Gebäude im Wandel von Zeit und Klima*. Stuttgart: [https://www.ibp.fraunhofer.de/de/presse-medien/presseinformationen/pi\\_2014-07\\_climate-culture.html](https://www.ibp.fraunhofer.de/de/presse-medien/presseinformationen/pi_2014-07_climate-culture.html).
- Kilian, R. (2019). *Kulturreise durch Raum und Zeit*. Valley: <https://www.ibp.fraunhofer.de/de/projekte-referenzen/kulturreise-durch-raum-und-zeit.html>.
- Klemm, L. (2012). *Passively conditioned zero-energy storage for cultural properties and archival material*. München: Climate for Culture Conference Proceedings.
- Köhler, W. (2018). *Entwicklung zerstörungsfreier Untersuchungsmethoden anthropo-gen bedingter biogener Oberflächenveränderungen von Mar-morskulpturen am Beispiel von ausgewählten Objekten der Park-anlagen von Schloss Sanssouci und Schloss Rheinsberg (AZ 32866/01)*. Potsdam: DBU AZ 32866.
- Kraus-Johnsen, I. H. (2018). *Schimmelpilz-Handbuch*. Köln: Bundesanzeiger-Verlag.
- Kwon, D. (2019). *AUTOMATIC DAMAGE DETECTION OF STONE CULTURAL PROPERTY BASED ON DEEP LEARNING ALGORITHM*. Avila, Spain: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-2/W15, 2019.
- Leijonhufvud, K. B. (2012). *Uncertainties in damage assessments of future indoor climates*. München: Climate for Culture Conference Proceedings.
- Leissner, F. K. (2014). *Climate change impact on historic houses and collections – the EU project Climate for Culture*. München: [www.climateforculture.eu](http://www.climateforculture.eu) Grant agreement No. 22 6973 (2009 - 2014).
- Leissner, J. u. (2018). *Kulturerbe und Klimawandel - sind wir an einem Wendepunkt?* In: Cartaditalia IX (2018), pp. 220-234.
- Leissner, J., & Fuhrmann, C. (2018). *Kulturerbe und Klimawandel - sind wir an einem Wendepunkt?* In: Cartaditalia IX (2018), pp. 220-234.
- Leissner, R. K. (2014). *The „Climate for Culture“ approach: From global climate to works of art*. München: Fraunhofer IBP.
- LZ. (2019). *Brake tauscht die Orgel ein*. Lemgo: [https://www.lz.de/lippe/lemgo/22610625\\_Brake-tauscht-die-Orgel-ein.html](https://www.lz.de/lippe/lemgo/22610625_Brake-tauscht-die-Orgel-ein.html).
- M. Paolanti, R. P. (2019). *DEEP CONVOLUTIONAL NEURAL NETWORKS FOR SENTIMENT ANALYSIS OF CULTURAL HERITAGE*. Avila, Spain: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-2/W15, 2019.
- Marijana 'Cosovi', A. A. (2019). *Classification Methods in Cultural Heritage*. Sarajevo: CEUR-CS.org/Vol. 2320.
- Matthia Sabatelli, M. K. (2018). *Improving the Training of Deep Convolutional Neural Networks for Art Classification: from Transfer Learning to Multi-Task Learning*. Belgium.
- Measday, D. (2017). *A summary of ultra-violet fluorescent materials relevant to Conservation*. Victoria: <https://aiccm.org.au/national-news/summary-ultra-violet-fluorescent-materials-relevant-conservation>.
- Meider, J. (2014). *Untersuchung der Wirksamkeit von Desinfektionsmitteln auf die Biomasse und Keimfähigkeit von Schimmelpilzen*. Würzburg: 4. Würzburger Schimmelpilz-Forum 21./22. März 2014.
- Meier-Wolff, C. (2011). *Biolumineszenz –Biomonitoring bei Schimmelpilzbefall und Dekontamination*. Berlin:



[http://www.microconservation.de/fileadmin/data/Links/Biolumineszenz\\_in\\_der\\_Schimmelpilzbehandlung.pdf](http://www.microconservation.de/fileadmin/data/Links/Biolumineszenz_in_der_Schimmelpilzbehandlung.pdf).

- Neuhaus, E. (2012). *A critical look at the use of HVAC systems in the museum environment*. München: Climate for Collections Conference Proceedings.
- Palmgren, J. M. (2011). *Case Study: Determination of moisture damages on items of art in exhibitions by the use of microbial analysis*. New York: Fungal Research Group Inc.,
- PCE-Instruments. (2020). *Luminometer Lumitester PD-20*. Meschede: <https://www.warensortiment.de/datenblatt/datenblatt-luminometer-lumitester-pd-20.pdf>.
- Pedro Santosa, M. R. (2017). *3D MASS DIGITIZATION: A MILESTONE FOR ARCHAEOLOGICAL*. Darmstadt: *Virtual Archaeology Review*, 8(16): 1-11, 2017.
- Petersen, K. (2011). *Untersuchungsbericht zur mikrobiellen Belastung im St. Paulus Dom zu Münster*. Münster: Architekturbüro Hülsmann.
- R. Brumana a, M. I. (2019). *HOLISTIC HERITAGE BUILDING INFORMATION MODELLING (HHBIM): FROM NODES to HUB NETWORKING, VOCABULARIES AND REPOSITORIES*. Milan: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-2/W11, 2019.
- Rapp, A. (2019). *Optische Bauforensik zur Aufklärung von Bauschäden*. Graz: 10. Grazer Pilztagung.
- Rome, B. S. (2019). *Artificial Intelligence, machine learning and deep learning in archaeology*. Rom: BSR und ESA.
- Sachsen, I. (2013). *Modellhafte Beseitigung von Umweltschäden und denkmalgerechte, nachhaltige Sanierung einer Carl Eduard Jehmlich - Orgel von 1878 im Raumkontext*. Ostritz: DBU Abschlußbericht Projekt AZ 30200-45.
- Sander, C. (2017). *Entwicklung und modellhafte Anwendung eines neuwertigen Sensorsystems zur Überwachung der nachhaltigen Wirksamkeit von Schutzverglasungen für durch anthropogene Umwelteinflüsse gefährdete Glasmalereien am Beispiel der Wiesenkirche in Soest*. Glasmalerei Peters GmbH. Paderborn: DBU 30751 / 45.
- Sander, C. (2017). *Entwicklung und modellhafte Anwendung eines neuwertigen Sensorsystems zur Überwachung der nachhaltigen Wirksamkeit von Schutzverglasungen für durch anthropogene Umwelteinflüsse gefährdete Glasmalereien am Beispiel der Wiesenkirche in Soest*. Glasmalerei Peters GmbH. Paderborn: DBU Aktenzeichen 30751 / 45.
- Schulze, A. (2012). *How the usual museum climate recommendations endanger our cultural heritage*. München: Climate for collections conference proceedings.
- Sedlbauer, K. (2001). *Vorhersage von Schimmelpilzbildung*. Stuttgart: Dissertation.
- Sedlbauer, K. Z. (2003). *Vorhersagemodell zur Schimmelpilzbildung bei instationärem Klima - praktische Beispiele*.
- Sedlbauer, K., Krus, M., & Zillig, W. (2003). *Vorhersagemodell zur Schimmelpilzbildung bei instationärem Klima - praktische Beispiele*.
- Studie, F. (2018). *Maschinelles Lernen: Eine Analyse zu Kompetenzen, Forschung und Anwendung*. Fraunhofer.
- Systems, B. (2018-2020). *Entwicklung und modellhafte Anwendung einer innovativen multiparametrischen Sensoriklösung für eine kostengünstige und flächendeckende Überwachung der durch anthropogene Umwelteinflüsse hervorgerufenen VOC-Belastung von national wertvollem Kulturgut*. München: [https://www.dbu.de/projekt\\_34671/01\\_db\\_2848.html](https://www.dbu.de/projekt_34671/01_db_2848.html).
- Tiebe, C. (2010). *Detektion leicht flüchtiger organischer Verbindungen mikrobiellen Ursprungs (MVOC) mittels Ionenmobilitätsspektrometrie (IMS)*. Ilmenau: Dissertation.
- Umweltbundesamt. (2019). *Künstliche Intelligenz im Umweltbereich: Anwendungsbeispiele und Zukunftsperspektiven im Sinne der Nachhaltigkeit*. Berlin: TEXTE 56/2019.
- Umweltbundesamt. (2019). *Umwelt in die Algorithmen: Eckpunkte für eine umweltpolitische Digitalagenda des BMU*. Berlin: BMU.
- Walde, C. S. (2014). *Orgel im Dom wird geputzt*. Münster: <https://www.wn.de/Muenster/Kultur/2014/07/1645001-Orgel-im-Dom-wird-geputzt-Neuer-Spieltisch>.
- Weyer, A. (2019). *Abstracts Klimazone Kirche, Präventive Konservierung der Ausstattung*. Hildesheim: HAWK.
- Weyer, A. (2019). *Tagungsbericht zur interdisziplinären Denkmalpflegetagung „Klimazone Kirche“*. DBU-Projekt Aktenzeichen 35604/01 –

Hildesheim: HAWK.

Wooley, A. (2018). *How To Detect Mold With A Blacklight*. <https://enviroklenz.com/how-to-detect-mold-with-blacklight/>.