

Energieforschungsprogramm

Publizierbarer Endbericht

Programmsteuerung:

Klima- und Energiefonds

Programmabwicklung:

Österreichische Forschungsförderungsgesellschaft mbH (FFG)

Endbericht

erstellt am

23/05/2024

Projekttitlel:

X-AMINOR - Cross Sensor Platform for Lifecycle-Monitoring of Transformers

Projektnummer: 881186

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Ausschreibung	Energieforschungsprogramm 6. Ausschreibung
Projektstart	01/02/2021
Projektende	31/01/2024
Gesamtprojektdauer (in Monaten)	36 Monate
ProjektnehmerIn (Institution)	JOANNEUM RESEARCH Forschungsgesellschaft mbH
AnsprechpartnerIn	Dr. Ferdinand Fuhrmann
Postadresse	Leonhardstraße 59, 8010 Graz
Telefon	0316 87601309
Fax	-
E-mail	ferdinand.fuhrmann@joanneum.at
Website	www.joanneum.at

X-AMINOR

Cross Sensor Platform for Lifecycle-Monitoring of Transformers

AutorInnen:

Dr. Ferdinand Fuhrmann

1 Inhaltsverzeichnis

1	Inhaltsverzeichnis	4
2	Einleitung	6
3	Inhaltliche Darstellung	7
3.1	Anforderungen, Use-Cases und Systemdesign	8
3.1.1	Anwendungsfälle und Requirements	8
3.1.2	Systemarchitektur X-AMINOR	9
3.2	Hardwareentwicklungen	11
3.2.1	Hardware Plattform	11
3.2.2	Sensorik	12
3.2.3	Integration	15
3.2.4	Kalibrierung	15
3.2.5	Design und Konstruktion Mikrofonarray	18
3.3	Softwareentwicklungen	22
3.3.1	Digitalisierung des Transformators	22
3.3.2	Überlagerte Thermalinformation	29
3.3.3	Akustische 3D-Heatmaps	33
3.3.4	Akustische Datenaufzeichnung und Analysen	35
3.3.5	Visuelle Datenaufzeichnung und Diagnostik	42
3.3.6	Framework	54
3.4	Messungen	59
3.4.1	Szenario Vorbereitung Evaluierung	59
3.4.2	Durchführung der Testszenarien	61
4	Ergebnisse und Schlussfolgerungen	66
4.1	Evaluation	66
4.2	Dissemination	67
4.2.1	Wissenschaftliche Konferenzen	67
4.2.2	Nationale Technologie Plattformen	68
4.3	Schlussfolgerungen	68
5	Ausblick und Empfehlungen	69
6	Literaturverzeichnis	69
7	Kontaktdaten	71

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

2 Einleitung

Das übergeordnete Ziel von X-AMINOR ist die Entwicklung einer multi-sensorisch dynamischen Zustandserfassung und -bewertung von Transformatoren über ihren gesamten Lebenszyklus. Dazu sollen bestehende Monitoringsysteme mit neuen Datenmodalitäten und Modellierungsmethoden ergänzt werden, die bis dato nicht maschinell erfasst werden können.

Im Laufe des Projekts wurde ein voll funktionaler Prototyp entwickelt, welcher zur Überwachung von Transformatoren eingesetzt werden kann. Das implementierte Messsystem wurde im Projekt erfolgreich evaluiert (inkl. Langzeittests) und in mehreren Anwendungsfällen getestet. Die Ergebnisse des Projekts wurden und werden in wissenschaftlichen Beiträgen veröffentlicht und auf nationalen Technologie-Plattformen vorgestellt. Weiters wurde eine Roadmap für die weitere Verwertungsstrategie erstellt, die Verwertung der Ergebnisse durch die Industriepartner hat bereits begonnen.

Im nachfolgenden Abschnitt sind die Schwerpunkte des Projekts dargestellt:

Maßgeschneiderte kontinuierliche Datenerfassung: *Entwicklung einer neuartigen mobilen Datenerfassungslösung für Transformatoren in verschiedenen Phasen ihres Lebenszyklus zur autonomen Aufnahme (d.h. ohne menschliche Unterstützung) von derzeit noch nicht maschinell erfassten Datenmodalitäten.*

Neuartige Analyseverfahren: *Erforschung und Entwicklung neuartiger Analyseverfahren für die Anomalie- und Veränderungsdetektion an Transformatoren sowohl im visuellen als auch im akustischen Bereich.*

Innovative Datenmodelle: *Ganzheitliche Modellierung des Transformators auf Basis multi-sensorischer Daten sowie Untersuchung der Nutzung der gewonnenen Informationen für ein optimiertes Transformator-Monitoring, ein verbessertes Transformator-Lastmanagement, eine vorausschauende Wartung und eine laufende Produktqualitätsverbesserung.*

Erfolgreiche Evaluierung: *Qualitative und quantitative Evaluierung von X-AMINOR anhand von definierten Kriterien für zwei Phasen: Endprüfung des Transformators in der Produktion („Prüffeld“) und laufender Betrieb des Transformators im Umspannwerk.*

Die im Projekt untersuchten Transformatoren sind ein wesentlicher Bestandteil des Energieversorgungssystems, deren Verfügbarkeit und Lebensdauer stellen wesentliche Zielgrößen im Sinne der Versorgungssicherheit dar. Die im Projekt behandelten Inhalte treffen daher die Programmausrichtung der Energieforschung durch die Entwicklung von Technologien und Komponenten sowie deren Systemintegration. Außerdem verursachen Ausfälle von Transformatoren hohe Reparatur- und Nebenkosten. Das Projekt untersucht dementsprechend Innovationen im Sinne des gesellschaftlichen Nutzens bzw. eine Verringerung des technologischen und ökonomischen Risikos.

Weiters wird mit dem Projekt der Schwerpunkt 1 der Ausschreibung, „Datenerzeugung, -bereitstellung und -auswertung“ behandelt. Im Projekt werden neuartige Sensorik und Datenmodelle für Echtzeitanalyse und -datenverarbeitung entwickelt, um präventive Wartung, Lebensdaueroptimierung und kontinuierliche Produktverbesserung von Transformatoren zu ermöglichen.

Um die Ziele im Projekt zu erreichen wird ein inklusiver Monitoring Ansatz verfolgt, welcher bestehende Lösungen miteinschließt und diese mit neuen Analysedaten und -ergebnissen erweitert. Dabei wird ein neuer Modellierungsansatz entwickelt, welcher es ermöglicht, sämtliche Daten für das Monitoring in einem digitalen Zwilling des Transformators abzubilden. Hierfür wird ein hochauflösendes 3D Modell des Transformators verwendet, welches als Basis für Visualisierung, Inspektion und Wartung dient. Weiters wird über die im Projekt entwickelte, multisensorale sowie autonome Plattform die Möglichkeit geschaffen, bisher nicht berücksichtigte Daten automatisiert zu erfassen. Neuartige Analysemethoden basierend auf maschinellem Lernen werten die Daten der visuellen, akustischen und thermischen Sensoren vollautomatisch aus und verschneiden die Ergebnisse auf dem digitalen Zwilling des Transformators. So werden thermische Analysen, Rost- und Leckagedetektionen, Detektionen zu akustischen Emissionen sowie allgemeine unbekannte Anomalien mit den Daten aus der Leittechnik des Betreibers miteinander verbunden. Das entwickelte System wird unter realen Bedingungen in einer Messkampagne evaluiert, um die nächsten Entwicklungsschritte zu erfassen.

Im nächsten Kapitel werden die wichtigsten inhaltlichen Schritte, welche zur erfolgreichen Projektdurchführung notwendig waren, beschrieben. Kapitel 4 beinhaltet die Projektergebnisse im Sinne der Evaluation, der Dissemination und von Schlussfolgerungen. Kapitel 5 gibt schließlich einen Ausblick in die nächsten geplanten Schritte.

3 Inhaltliche Darstellung

Die Arbeiten im Projekt erfolgten entlang mehrerer Phasen, welche grob in die Anforderungserhebung, Entwicklung der Datenmodelle und Analyseverfahren, Konstruktion der Hardwareelemente und in die Evaluation unterteilt werden können. Während dieser Phasen fanden jeweils verschiedene Workshops und Messungen bei den verschiedenen Projektpartnern statt. *Abbildung 1* zeigt einen Überblick über den zeitlichen Verlauf mit den wichtigsten Ereignissen im Projekt. Im Folgenden sind die einzelnen Phasen näher ausgeführt.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

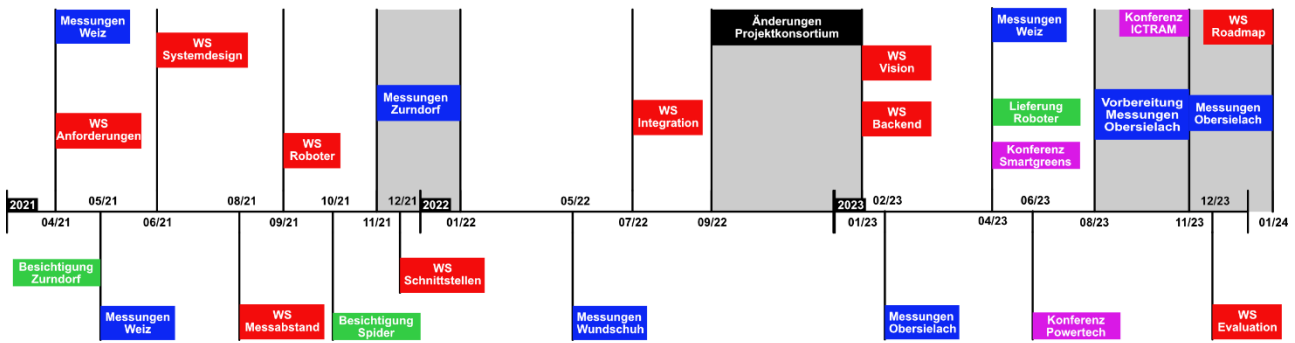


Abbildung 1: Timeline des Projekts mit wichtigen Ereignissen.

3.1 Anforderungen, Use-Cases und Systemdesign

3.1.1 Anwendungsfälle und Requirements

In X-AMINOR wird ein neuartiges technisches System zur autonomen Überwachung von Transformatoren entwickelt. Unter Berücksichtigung der im Antrag definierten Projektziele wurden anhand von im Expertenkreis entwickelten Anwendungsfällen die Anforderungen an dieses technische System entwickelt.

X-AMINOR liegt die Vision zugrunde, einen Transformator sein ganzes Leben lang zu begleiten und zu überwachen. Beginnend in der Assemblierungsphase im Werk über die Endprüfung, Inbetriebnahme und den eigentlichen Betrieb des Transformators sollen auch nach seiner altersbedingten Ausmusterung Daten gesammelt und ausgewertet werden. Die dabei gesammelten multi-sensorischen Daten beschreiben also den gesamten Lebenszyklus des Transformators und können somit für das Transformatormonitoring, die Steuerung der Netzauslastung sowie die Planung und Entwicklung neuer Transformatoren verwendet werden.

In diesem Projekt wird ein erster Prototyp zur oben beschriebenen Vision entwickelt. Dabei sollen von Sensorik aufgenommene akustische und bildgebende Daten mit bereits vorhandenen Daten aus der Prozessleittechnik verwendet werden, um das bestehende Transformatormonitoring zu verbessern. Die Datenaufzeichnung und Verarbeitung erfolgt dabei jeweils autonom und ohne menschlichen Input.

In mehreren Expertenworkshops wurden Szenarien für die 3 Anwendungsfälle Endprüfung, Inbetriebnahme und Betrieb entwickelt. Alle 3 Anwendungsfälle werden mit demselben technischen System bearbeitet, wobei je nach Anwendungsfall unterschiedliche Datenauswertungen erfolgen. Auf Basis dieser Anwendungsfälle wurden Anforderungen an das Gesamtsystem sowie seine Teilkomponenten erhoben. Generelle Anforderungen beinhalten die autonome Datenaufzeichnung sowie die automatische Datenweiterverarbeitung, die Integration verschiedener Datenquellen und die Ausgabemodalitäten der Ergebnisse. Die Anforderungen an die akustischen Analysen beschreiben die akustischen HeatMaps, die Schallpegelmessung, die akustischen Fingerprints, die Überwachung der Kühlanlagen des Transformators sowie die Detektion von Sternpunktströmen. Anforderungen an die visuellen Komponenten betreffen die Erstellung des 3D Modells des Transformators, die Thermalinspektion, das Ablesen von analogen Anzeigeelementen sowie die Detektion von

Oberflächenveränderungen mit bildgebender Sensorik. Außerdem wurde das Transformator Fingerprinting spezifiziert, welches über die Auswertung von multi-modalen analytischen Modellen Anomalien erkennen kann. Schließlich wurden die Anforderungen an die mobile Plattform definiert, die die autonome Datenaufzeichnung ermöglicht.

3.1.2 Systemarchitektur X-AMINOR

Auf Basis der identifizierten Anforderungen und Szenarien erfolgte die Entwicklung einer X-AMINOR Systemarchitektur. Eine Skizze der Architektur ist *Abbildung 2* dargestellt.




Abbildung 2: X-AMINOR high-level System Architektur.

Das X-AMINOR System besteht aus 2 Komponenten, einem Backend und einer oder mehreren X-AMINOR Nodes (Devices), welche an unterschiedlichen Transformatoren instanziiert werden können. Generell wird zwischen dem Operator und dem Feld unterscheiden. Das X-AMINOR-Backend wird On-Premises beim Betreiber gehostet und ist für die Nachbearbeitung, die Integration von X-AMINOR in den Betrieb und das Gerätemanagement verantwortlich. Im Feld (bspw. in einem Umspannungswerk) werden eine oder mehrere X-AMINOR-Instanzen an bestimmten Transformatorstandorten gehostet. Die Rollen innerhalb des Systems werden nun anhand eines Einsatzszenarios erläutert (Abbildung 3). In einem ersten Schritt wird die X-AMINOR-Geräteinstanz vom Betreiber in Abhängigkeit von seiner Anwendungsumgebung und Informationen konzipiert, die vom System selbst bewertet werden sollen. Dies erfordert eine Auswahl von Anwendungen/Funktionalität und den entsprechenden Sensormodulen, die in der X-AMINOR-Geräteinstanz (eine sogenannte X-AMINOR-Node) integriert werden müssen. Die Node wird von einem Techniker vor Ort bereitgestellt, was die Zusammenstellung des Systems und die Bereitstellung der Basisanwendungen umfasst. Sobald die Node installiert und bereit ist, wird der Betreiber benachrichtigt. Anschließend kann dieser die Node verwalten und betreiben, indem er dedizierte Anwendungen installiert und Messkampagnen startet/stoppt. Die Rolle des Knotens ist auf die Vorverarbeitung und Bewertung eingehender Sensordaten und deren Aufbereitung für das Backend beschränkt, es werden keine Betriebsinformationen (z. B. SCADA-Informationen) verwendet. Das Zusammenführen von Sensordaten mit Betriebsinformationen ist auf die Nachbearbeitungs- und Analyseprozesse beschränkt, die im Backend (welches durch den Betreiber gehostet wird) durchgeführt werden, um Sicherheitsrisiken zu minimieren. Darüber hinaus bietet das Backend eine Schnittstelle für Anwendungsentwickler (nur in der Nähe des Betreibers), um neue Anwendungen sowohl für die Nachbearbeitung / Analyse (am Backend) als auch für die Vorverarbeitung / Bewertung auf der Geräteinstanz zu entwickeln und zu verfeinern.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

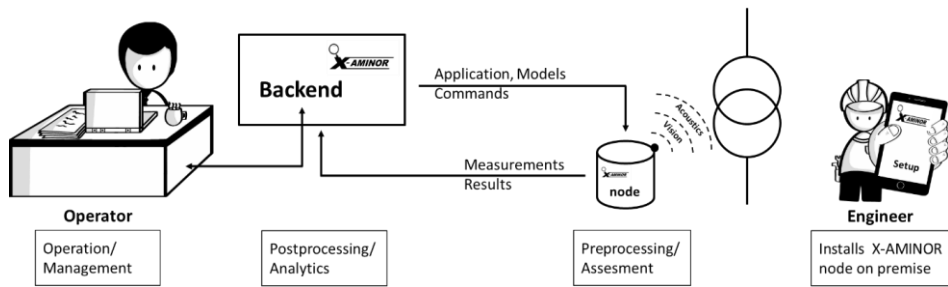


Abbildung 3: Rollen in X-AMINOR.

Die resultierende Systemarchitektur ist in Abbildung 4 dargestellt, wobei eine Festlegung/Spezifikation der Komponenten und Software im Rahmen des Arbeitspakets 5 erfolgt bzw. erfolgte.

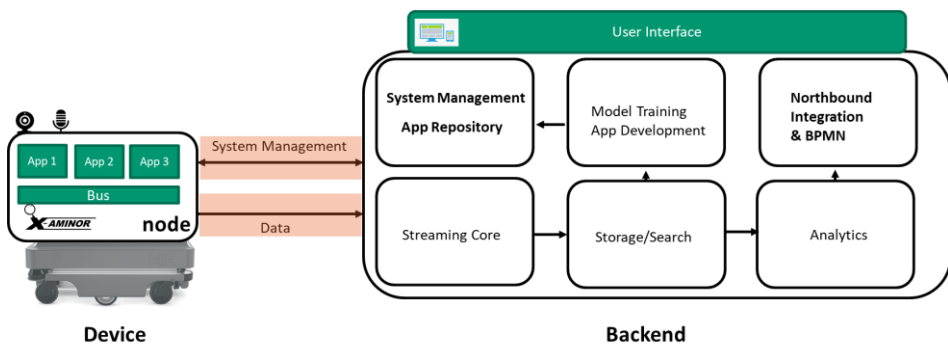


Abbildung 4: X-AMINOR Systemarchitektur

Die X-AMINOR Node besteht aus einer Computing-Node sowie Sensorik die auf einem Roboter montiert sind. Die Node hostet Applikationen, wie beispielsweise Sensordatenerfassung für visuelle und/oder akustische Zustandserfassung und Applikationen zur Vorverarbeitung von Sensorinformationen. Applikationen auf der Node kommunizieren über ein Bus-System. Northbound existieren 2 Schnittstellen zum X-AMINOR Backend. Eine Schnittstelle zum Management einer X-AMINOR Node, also zur Verwaltung/Installation der Applikationen und zum Starten und Stoppen von Messkampagnen. Und eine weitere Schnittstelle zur Übertragung von Daten von der Node in das Backend. Um IT/OT Sicherheit zu gewährleisten erfolgt keine Übertragung von Betriebsdaten vom Backend an die X-AMINOR Node. Das Backend entspricht einem klassische IoT-Cloud backend. Eingehende Daten (durch die Nodes) werden via Streaming Core auf überlagerte Applikationen (Zustandserfassung) und Datenbanken verteilt um eine Skalierbarkeit des Systems sicherzustellen und stehen dem Nutzer zum Training neuer Modelle bzw. zur Entwicklung neuer X-AMINOR Node Applikationen zur Verfügung. Das Management der Nodes erfolgt über ein „System Management“ Service mittels dessen die aktiven X-AMINOR Instanzen verwaltet werden können.

3.2 Hardwareentwicklungen

3.2.1 Hardware Plattform

Auf Basis der Anforderungen an die mobile Plattform wurde eine initiale Marktrecherche durchgeführt. Durch mehrere Evaluierungen der potentiellen Lösungen konnten 3 Systeme identifiziert werden, welche für die im Projekt vorgesehenen Entwicklungen passend erschienen. Anschließend wurde in direkten Gesprächen mit den Herstellern die speziellen Anforderungen erörtert und für die jeweilige Lösung definiert. Am Ende des Prozesses wurde die Husky Plattform des kanadischen Herstellers Clearpath Robotics¹ ausgewählt. Diese Plattform überzeugte durch die Kombination von Funktionalität, Preis/Leistungs-Verhältnis sowie der Erfahrung des Herstellers mit Robotersystemen. *Abbildung 5* zeigt die Plattform direkt nach der Lieferung im ursprünglichen Zustand. *Abbildung 7* zeigt die technischen Spezifikationen wie vom Hersteller angegeben.




Abbildung 5: Roboterplattform im ursprünglichen Zustand.



Abbildung 6: Kalibrationsmessungen mit dem Mikrofonarray und einem Referenzlautsprecher in Obersielach.

¹ <https://clearpathrobotics.com>

TECH SPECS



SIZE AND WEIGHT		SPEED AND PERFORMANCE	
EXTERNAL DIMENSIONS	990 x 670 x 390 mm [39 x 26.4 x 14.6 in]	MAX SPEED	1.0 m/s [2.2 mph]
INTERNAL DIMENSIONS	296 x 411 x 155 mm [11.7 x 16.2 x 6.1 in]	RUN TIME (TYPICAL USE)	3 hours
WEIGHT	50 kg [110 lbs]	USER POWER	5V, 12V and 24V fused at 5A each
MAX PAYLOAD	75 kg [165 lbs]	DRIVERS AND APIS	ROS Melodic, ROS Kinetic, C++ Library, Mathworks

Abbildung 7: Technische Spezifikationen der autonomen Plattform wie vom Hersteller angegeben.

Der Husky wurde herstellerseitig mit Lidar Scannern bestückt (siehe Abbildung 5) um einen autonomen Betrieb zu ermöglichen. Dadurch konnte ein SLAM-basierender Navigationsalgorithmus für die Anwendung in den Evaluierungsszenarien verwendet werden. Die Navigationssoftware wurde als Webapplikation vom Hersteller mitgeliefert. Weiters wurde die Plattform mit einer induktiven Ladelösung von Wibotic² ausgestattet.

3.2.2 Sensorik

Die mobile Plattform wurde mit visueller und akustischer Sensorik bestückt. Im Folgenden wird das Multi-Kamerasystem näher beschrieben, das Mikrofonarray wird im darauffolgenden Abschnitt behandelt.

Anforderungen an das Kamerasystem

Um die notwendige Datenqualität bereitzustellen, müssen die gewählten Sensoren den Anforderungen unserer speziellen Anwendung gerecht werden. Da die Sensoren in einer Außenumgebung zum Einsatz kommen, müssen sie mit sich verändernden Lichtverhältnissen und Sonneneinstrahlung klarkommen. Viele auf dem Markt erhältliche Tiefenkameras sind jedoch für den Innenbereich konzipiert und können daher aufgrund von durch Sonnenlicht verursachten Verzerrungen oder Datenverlusten nicht für dieses Projekt verwendet werden. Daher ist es wichtig, bei der Auswahl besonders auf die Eignung der Tiefenkamera für wechselnde und sonnige Lichtverhältnisse zu achten.

Ein weiteres Auswahlkriterium ist eine hohe Bildauflösung und die Fähigkeit, detaillierte Aufnahmen aus einer größeren Entfernung zu erstellen. Aufnahmen aus unmittelbarer Nähe zum Transformator sind aufgrund baulicher Gegebenheiten nicht möglich. Darüber hinaus ist es aufgrund der Selbstähnlichkeit des Objekts notwendig, größere Bereiche des Objekts in derselben Aufnahme darzustellen, um

² <https://www.wibotic.com>

eindeutige Referenzpunkte in den Bildern zu finden. Die RGB-Kamera muss daher aus einer Entfernung von mehreren Metern ein hochauflösendes Bild liefern, sodass auch beispielsweise Nadeln von Anzeigengeräten gut erkennbar bleiben. Die Tiefenkamera muss in derselben Entfernung Messungen durchführen können und die Tiefenwerte auch bei Sonnenschein sicher ermitteln können. Die Anforderungen an die Wärmebildkamera ergeben sich aus ihrem Verwendungszweck. Typischerweise haben Wärmebildkameras aufgrund ihrer Funktionsweise deutlich niedrigere Auflösungen als beispielsweise RGB-Kameras. Dennoch ist es für die Erkennung von Heistellen notwendig, eine ausreichende Auflösung der Wärmebildaufnahme bereitzustellen, damit Heistellen zuverlässig erkannt werden können. Wenn kleine Bereiche der Transformatoroberfläche aus größerer Entfernung mit einer niedrig auflösenden Wärmebildkamera aufgenommen werden, würde dieser Bereich mit den umliegenden, kühleren Bereichen in einem Pixel verschmelzen. Die daraus resultierende Wärmeinformation des Pixels würde dann fälschlicherweise eine deutlich niedrigere Temperatur anzeigen.

Da die Bilder der RGB- und Thermal-Kameras zur Färbung der Punktwolke verwendet werden, muss darüber hinaus berücksichtigt werden, dass der Öffnungswinkel der Kameras den Öffnungswinkel der Tiefenkamera überschreitet.

Sensorauswahl Kamerasystem

Für die Erstellung des Referenzmodells und für die Echtzeitdaten werden unterschiedliche Sensoren verwendet:

Das Referenzmodell wird mit einem LiDAR-Scanner der Type Leica BLK360 aufgenommen. Der Leica BLK360 LiDAR-Scanner erfasst seine Umgebung in einem 360° Winkel mit einem LiDAR (Light Detection And Ranging) Scanner und drei RGB-Kameras. Mehrere Aufnahmen von unterschiedlichen Positionen um den Transformator können anschließend zu einer Gesamtpunktwolke verschmolzen werden. Im Gegensatz zu üblicherweise in Robotik verwendeten Laser-Scannern, liefert dieser 360° Scanner eine kontinuierliche und dichte Punktwolke, welche an den Echtzeitaufnahmen der Tiefenkamera deutlich näher liegt als in der Robotik übliche LiDAR-Aufnahmen in Linienform.

Für die **Echtzeitaufnahmen** wird ein geometrisch kalibriertes Set aus jeweils einer Tiefen-, RGB- und Wärmebildkamera verwendet. Als Tiefenkamera wurde eine Basler Blaze-101 Time-of-Flight (ToF) Kamera gewählt. Der Output der Blaze Tiefenkamera liefert eine Punktwolke mit zugehörigen Intensitätswerten in einer Auflösung von 640x480px, das Sichtfeld beträgt 67° x 51°. Zusätzlich liegt die von der Kamera verwendete Wellenlänge von 940nm in einem Bereich, welcher eine robuste Funktion auch bei Sonnenlicht ermöglicht. Der vom Hersteller angegebene Aufnahmebereich liegt zwischen 0m und 10m. Unsere Erfahrungen haben jedoch gezeigt, dass die ideale Entfernung zum Objekt bei etwa 5-8m liegt, wenn die Kamera in einer Outdoor-Umgebung eingesetzt wird.

Für die Färbung der Punktwolke und die Analyse der Transformatoroberfläche ist auch der Einsatz einer RGB-Kamera erforderlich. Die ausgewählte RGB-Kamera des Typs Basler Ace 2 ist eine zuverlässige Industriekamera mit Fernsteuermöglichkeiten mittels verfügbarem Software-Development Kit (SDK). Dieses Modell hat eine Auflösung von 16,1 Megapixel, was eine detaillierte 2D-Bildaufnahme sowohl für die Objekt- als auch für die Anomalie-Erkennung ermöglicht. Das Sensormodul, bestehend aus dem

Objektiv und der RGB-Kamera, liefert in einem Abstand von 5m eine Auflösung des Bildbereichs von 1,62mm pro Pixel. Diese Auflösung ermöglicht es, auch kleinere Zeiger von Analoginstrumenten korrekt abzubilden.

Bei der Wärmebildkamera wurde entsprechend den Anforderungen die Thermalkamera Optris PI450 ausgewählt. Diese Kamera liefert in einer Entfernung von 5m eine Auflösung von 4,6mm pro Pixel, was als ausreichend für die Detektion von Hotspots erachtet wird. Die thermische Auflösung der Kamera beträgt 40mK und der Messbereich -20°C bis 900°C. Der Spektralbereich der Kamera liegt im Bereich von 8 – 14 μm , was im Bereich der höchsten thermischen Emissivität liegt und somit für Thermografie geeignet ist. Die Kamera ist zudem vom Werk aus radiometrisch kalibriert.

Zusammenfassung der Kameras zu einem Sensorsystem

Für die spätere Abbildung der Kamerawerte auf eine Punktwolke, sowie die Nutzung der Punktwolkenregistrierung der Aufnahmen auf die Referenzpunktwolke, ist es notwendig, dass die Kameras zueinander, sowie zum Roboter örtlich unveränderlich befestigt sind. Diese Anordnung wird später kalibriert und die örtlichen Posen des Roboters und der Sensoren zueinander ermittelt. Weiters müssen die Kameras vor Witterungseinflüssen geschützt werden.

Dies wurde mittels eines Gehäuses bewerkstelligt, mit dem die Kameras fest verbunden wurden. Die Anforderungen an das Gehäuse sind dabei folgende:

- Schutz vor Witterungseinflüssen
- Unveränderliche Pose der Sensoren zueinander und zum Roboter
- Druck- und Feuchtigkeitsausgleich mit der Außenumgebung, um Kondensation zu verhindern
- Transmissivität in der Wellenlänge der Sensoren (Kameras)

Dazu wurde ein wetterfestes Gehäuse mit Dichtungen rund um die Verbindungskabel und das Sichtfenster konstruiert, wobei eine GORE-Tex-Membran einen Luftaustausch ermöglichte ohne Feuchtigkeit in das Gehäuse hineinzulassen. Zudem wurde das Sichtfenster so gestaltet, dass die Kameras in ihren Wellenbereichen nicht abgeschattet wurden. Für die Thermalkamera wurde daher ein Kaliumbromid-Fenster eingebaut, welches im Wellenbereich der Thermalkamera eine Transmissivität von >95% besitzt. Für die Tiefenkamera wurde das Sichtfenster ausgenommen, da diese Kamera ohnehin eine Schutzklasse von IP67 besitzt und von Acrylglas abgeschattet ist. Die Farbkamera wurde hinter eine Acrylglasscheibe platziert, da diese für sichtbares Licht transparent ist und die Kamera vor Witterungseinflüssen schützt, siehe *Abbildung 8*.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG



Abbildung 8: Kameras fest verbunden zu einem Sensorsystem

3.2.3 Integration

Abbildung 9 zeigt die schematische Darstellung der integrierten Hardware. Als Kommunikationsbasis kam ein LTE-Router mit SIM-Karte zum Einsatz, dieser verknüpfte die einzelnen Komponenten des Systems untereinander via Ethernet und stellte die Verbindung nach außen über die LTE Anbindung her. Das Kamerasystem war über einen eigenen Netzwerkschwitch untereinander verbunden, als Recheneinheit kam ein Nvidia Jetson zum Einsatz. Das Mikrofonarray war über eine USB Verbindung mit einem Intel NUC als Analyserechner verbunden. Die für die Audiohardware notwendigen 220V wurden über einen DC/AC Konverter bereitgestellt.

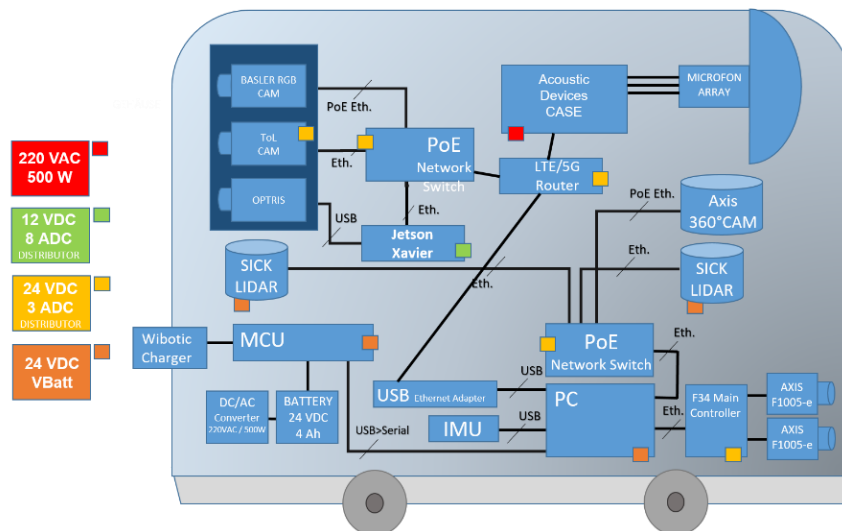


Abbildung 9: Schematische Darstellung der Hardware Integration von Sensorik und Roboterplattform.

3.2.4 Kalibrierung

Für ein Mapping der Farb- und Thermalwerte der Kameras auf die von der Tiefenkamera aufgenommenen Punktwolken, sowie die Verortung von 3D Positionen aus der Referenzpunktwolke auf die Bildaufnahmen ist eine Bestimmung der intrinsischen und extrinsischen Kameraparameter des Sensorsystems notwendig. Die intrinsischen Kameraparameter dienen dazu die Bildverzerrung rauszurechnen und die Beziehung von Objekten im 3D-Raum zur Darstellung auf der Bildebene

darzustellen. Die extrinsischen Kameraparameter stellen die geometrische Beziehung der unterschiedlichen Kameras zueinander dar.

Die intrinsischen und extrinsischen Kameraparameter werden dadurch geschätzt, indem ein Gleichungssystem optimiert wird, welches den Fehler der vorhergesagten Positionen der Schachbrettkanten zu den tatsächlichen Positionen minimiert. Dafür sind Aufnahmen des Schachbrettmusters mit allen Kameras notwendig, wobei die Ecken der Rechtecke gut erkennbar sein müssen. Die Herausforderung lag hierbei darin, dass das Schachbrett in allen Kameras sichtbar sein musste. Für die RGB-Kamera war die Verwendung eines schwarz-weißen Schachbrettes naheliegend. Dieses konnte auch mit der Tiefenkamera erkannt werden, wenn der Intensitätskanal des Tiefenwertes verwendet wurde. Für die Thermalkamera wurden unterschiedliche Versuche mit verschiedenen Materialien unternommen. Das beste Ergebnis lieferte ein Kalibriertarget (Schachbrettmuster) aus Glas, beschichtet mit einer Kunststoffolie in unterschiedlichen Farben, wobei dieses Target für die Kalibrierung aufgeheizt werden musste (beispielsweise durch Sonneneinstrahlung), da ansonsten das Schachbrettmuster auf den Bildern nicht erkennbar ist (es gibt keine unterschiedliche Emission von Infrarotstrahlung zwischen den weißen und schwarzen Feldern des Schachbrettes, siehe *Abbildung 10*).



Aufnahme eines nicht erhitzten Kalibriertargets mit RGB-Kamera



Aufnahme derselben Szene mit einer Thermalkamera (Schachbrettmuster ist nicht erkennbar)

Abbildung 10: Aufnahme eines nicht-erhitzten Kalibriertargets mittels einer RGB und Thermalkamera


Bei der Kalibrierung der Thermalkamera zu den übrigen Kameras musste zudem berücksichtigt werden, dass die Kamerawerte invertiert werden, da die schwarzen Felder eine hohe thermische Emissivität besitzen und daher in den Thermal-Bildern hell ("weiß") erscheinen, wogegen die weißen Bilder des Schachbrettes eine niedrige Emissivität besitzen und daher in den Thermal-Bildern dunkel ("schwarz") erscheinen, siehe *Abbildung 11*.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG




Aufnahme eines erhitzten Kalibriertargets mit RGB-Kamera




Aufnahme derselben Szene mit einer Thermalkamera (Schachbrettmuster ist erkennbar, jedoch invertiert)

Abbildung 11: Aufnahme eines erhitzten Kalibriertargets mittels einer RGB und Thermalkamera

Nachdem die Kameras im Gehäuse fest verbaut wurden, wurden Aufnahmen des erhitzten Kalibriertargets mit allen dreien Kameras durchgeführt, wobei auf eine ausreichende Abdeckung des gesamten Aufnahmebereichs und unterschiedlichen Entfernungen und Orientierungen des Kalibriertargets geachtet wurde, sodass die Kameraparameter ausreichend gut geschätzt werden konnten um eine niedrige Abweichung der geschätzten zu tatsächlichen Positionen zwischen 3D Positionen und Kamerawerten erreicht werden konnte. *Abbildung 12* zeigt das Ergebnis der Kamerakalibrierung, wobei gut erkennbar ist, dass die thermischen und Farbwerte sehr genau auf die Punktwolke abgebildet werden konnten.



Thermalwerte auf Punktwolke gemappt



Farbwerte auf Punktwolke gemappt

Abbildung 12: Ergebnis der Kamerakalibrierung

Das Mikrofonarray wurde mithilfe einer externen Schallquelle mit dem visuellen System kalibriert. Dazu wurde ein genormter Lautsprecher direkt vor dem Objekt platziert und an mehreren Positionen vermessen. Durch die bekannten geometrischen Beziehungen der Systeme zueinander können die 3D-Punkte des Tiefenbildes identifiziert werden, welche mit dem Lautsprecher korrespondieren. So kann schließlich die gesamte akustische Heatmap auf die 3D-Punktwolke übertragen werden. *Abbildung 6* zeigt Kalibrationsmessungen mit der autonomen Plattform und Referenzlautsprecher in Obersielach.

3.2.5 Design und Konstruktion Mikrofonarray

In X-AMINOR soll ein Mikrofonarray verwendet werden, welches die akustischen Eigenschaften des Schallfeldes eines Transformators bestmöglich abbilden kann. Dabei sind folgende Punkte zu berücksichtigen:

- **Frequenzbereich:** Wie aus den ersten Messungen im Projekt ersichtlich, befinden sich die für den Transformator relevanten Frequenzkomponenten hauptsächlich zwischen 100Hz und 1kHz. Die äußeren Abmessungen des Arrays sowie die Abstände und die Anzahl der verbauten Mikrofone bestimmen grundsätzlich die Frequenzcharakteristik eines Mikrofonarrays. Für tiefe Frequenzen um 100Hz sind Mikrofonabstände bis zu 2m notwendig, um diese Frequenzen hinreichend genau lokalisieren zu können. Für die Lokalisierung von Frequenzkomponenten von 1kHz sind Mikrofonabstände von max. 17 cm notwendig. Je mehr Mikrofone im Array verbaut sind, desto besser wird der Signal-Rausch-Abstand des Beamformings.
- **Beamforming:** Je nach Bauart des Arrays lassen sich bestimmte Eigenschaften des Beamformings realisieren. Sind die Mikrofone in einer Ebene als 2D Array angeordnet, kann mit dem Array zwischen Schalleinfallrichtungen von vorne und hinten nicht unterschieden werden. Erst eine 3-dimensionale Anordnung der Mikrofone ermöglicht ein eindeutiges Referenzieren eines Punktes im Raum mit dem Beamformer.
- **Mobile Anwendung:** Für die Montage des Arrays auf der mobilen Plattform sind sowohl den äußeren Abmessungen als auch dem Gewicht des Arrays mit seinen Peripheriegeräten gewisse Grenzen gesetzt.
- **Robustheit gegenüber Umwelteinflüssen:** Für einen Einsatz im Außenbetrieb muss das Mikrofonarray gegen Wettereinflüsse geschützt werden. Eine dementsprechende Schutzverbauung soll einen 24/7 Außenbetrieb ermöglichen, darf aber die akustischen Eigenschaften der Sensorik nicht beeinträchtigen.

Aufgrund der oben angeführten Bedingungen und Einschränkungen wurden im Projektverlauf mehrere Mikrofonarrays entwickelt und hinsichtlich ihrer Anwendbarkeit getestet.

BigGrid16 und SmallGrid16

Diese beiden Arrays verwenden das UMIK-X³ Mikrofonarraysystem als akustische Sensorik. Das UMIK-X besteht aus 4-Kanal SMD Elementen, welche zu einem 16-Kanal Array verbunden werden können. Die Einzelmodule besitzen 4 MEMS Mikrofone, die in einem 17 x 13 cm Rechteck angeordnet sind. Je nach Anordnung der 4 4-Kanal Elemente zueinander entstehen in der Folge unterschiedliche

³ <https://www.minidsp.com/products/acoustic-measurement/umik-x-multichannel-mic>

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Frequenzbereiche, die das Array abdecken kann. Das gesamte Arraysystem kann mittels USB an einen PC angeschlossen werden, es ist ein ASIO Treiber für die Windows Plattform verfügbar.

Das BigGrid16 ist eine Rahmenkonstruktion aus Profilelementen, auf welchen die einzelnen Arraykomponenten entlang der verschiedenen Verstreibungen beliebig montiert werden können. Die äußeren Abmessungen betragen 2x2 m, um einen Beamformer für 100 Hz zu ermöglichen. Das BigGrid16 wurde für die stationären Langzeitaufzeichnungen in Zurndorf verwendet. *Abbildung 13* zeigt den Aufbau des BigGrid16 Arrays im Labor mit den 4 UMIK-X Elementen.

Das SmallGrid16 ist sehr ähnlich dem BigGrid16, allerdings mit Außenabmessungen von 0,95 x 0,95m. Dadurch konnte das Array auf der mobilen Plattform montiert und bei der Evaluation in Obersielach eingesetzt werden. Durch die geringeren Außenabmessungen konnten mit diesem Array aussagekräftiges Beamforming erst ab 200Hz ermöglicht werden. *Abbildung 14* zeigt das SmallGrid16 mit der mobilen Plattform in Obersielach.

Für die UMIK-X Elemente mussten wetterfeste Gehäuse angefertigt werden. Dazu wurden Verschaltungen mit einem 3D-Drucker gedruckt, welche mit Silikon verschlossen wurden. Anschließend wurden diese Gehäuse mit Akustikschaumstoff und Akustikstoff überzogen.



Abbildung 13: BigGrid16 Array im Laboraufbau.



Abbildung 14: SmallGrid16 montiert auf der autonomen Plattform in Obersielach.

IcoDome32L

Das Mikrofonarray IcoDome32L basiert auf einem maßgeschneiderten 3D-Design, das aufgrund der gewünschten Eigenschaften in Bezug auf die Schallabstrahlung des Transformators sowie die mechanische Stabilität und Haltbarkeit entwickelt wurde. Grundlage der Geometrie des Arrays ist eine Ikosaeder-Kuppel V2^{4,5} mit einem Radius von 135 cm und 26 Scheitelpunkten, die auf einer Grundplatte mit 6 Löchern montiert ist. Daraus ergeben sich 32 Sensorpositionen für ICP-Elektretmikrofone in einem IP67-geschützten Gehäuse. Die Array-Geometrie wurde auf der Grundlage numerischer Beamforming-Simulationen gewählt, um einen geeigneten Kompromiss zwischen Hauptkeulenbreite und maximalen

⁴ <https://en.wikipedia.org/wiki/Icosahedron>

⁵ https://simplydifferently.org/Geodesic_Dome_Notes?page=3#2V/L2%20Icosahedron%20Dome

Nebenkeulenpegeln für Terzmittelfrequenzen innerhalb von 100 Hz und 20 kHz zu erzielen, was zu einem Richtwirkungsindex von mehr als 10 dB für Frequenzen über 200 Hz und mehr als 15 dB für Frequenzen über 800 Hz führt. Der effektive aliasingfreie Frequenzbereich beträgt 130 Hz bis 15 kHz. *Abbildung 15* zeigt das Array im Labor, *Abbildung 16* auf der mobilen Plattform in Obersielach.




Abbildung 15: IcoDome32L im Laboraufbau mit zugehörigem Hardware Case. Darin enthalten ist die notwendige Wandlerelektronik und sowie ein Rechner.




Abbildung 16: IcoDome32L montiert auf die autonome Plattform in Obersielach.

Sunflower16

Ein weiteres Array wurde mit MEMS Mikrofonen entwickelt, um das Gewicht auf die mobile Plattform zu reduzieren. Grundlage des Arrays bildet das UMA-XL Mikrofonsystem von miniDSP⁶. Dieses besteht aus 16 Einzel-MEMS Mikrofonen, welche über mehrere Signalsammelboxen in ein USB-Signal zusammengeführt werden. Auch hier wird ein ASIO Treiber für die Windows Plattform zur Verfügung gestellt. Die Mikrofone wurden auf einer Vollkunststoffplatte anhand eines Spiralmusters (Sunflower) angeordnet [21]. Diese Anordnung bietet die bestmöglichen Eigenschaften des Beamformers über den gesamten Frequenzbereich von 200-1000Hz in dieser Array-Größenordnung. Für die einzelnen Mikrofonelemente mussten auch hier wetterfeste Gehäuse angefertigt werden. Die notwendigen Verschaltungen wurden mit einem 3D-Drucker gedruckt und mit Silikon verschlossen. *Abbildung 17* zeigt das Array im Labor, *Abbildung 18* auf der mobilen Plattform in Obersielach.

⁶ <https://www.minidsp.com/products/acoustic-measurement/umik-x-multichannel-mic>

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG




Abbildung 17: Sunflower16 Array im Laboraufbau.



Abbildung 18: Sunflower16 montiert auf die mobile Plattform mit Windschutz in Obersielach.

Vergleich und Fazit

Jedes der oben angeführten Arrays wurde aufgrund von unterschiedlichen Anforderungen entwickelt. Um die einzelnen Arrays vergleichen zu können, sollen hier nochmal ihre speziellen Beamforming Eigenschaften gegenübergestellt werden.

Abbildung 19 zeigt die Beamforming Patterns aller 3 in Obersielach eingesetzten Arrays bei verschiedenen Frequenzen anhand einer Simulation am 3D-Modell des Transformators. Bei dieser Simulation wird eine punktförmige Schallquelle an einer Stelle des Transformators platziert und der Ausgang des Beamformers dargestellt. Man erkennt deutlich die unterschiedlichen Charakteristika im Beamforming Output der verschiedenen Arrays (Spalten) in Abhängigkeit von der Frequenz (Reihen). Das SmallGrid16 (rechte Spalte) bildet die tiefste Frequenz von 100Hz (erste Reihe) am besten ab (schmalste Hauptkeule). Zu höheren Frequenzen (200 Hz, 300 Hz, 400 Hz und 500Hz, Reihen 2-5) sind allerdings deutlich Spiegelquellen aufgrund der Unterabtastung zu erkennen. Diese Spiegelquellen sind beim Sunflower16 (rechte Spalte) nicht vorhanden, da hier durch die verteilte Anordnung der Mikrofone eine bessere Abtastung der Frequenzen für das Beamforming zwischen 200Hz und 1kHz erreicht wird. Die besten Beamforming Eigenschaften ermöglicht der IcoDome32L, aufgrund der 32 Mikrofone und der größten Abmessungen der Apertur ist das Array den anderen überlegen.






Abbildung 19: Vergleich der verwendeten Array Geometrien. In den Spalten sind die Arrays SmallGrid16 (links), IcoDome32L (mitte) und Sunflower16 (rechts) dargestellt. Die Reihen enthalten die verschiedenen Frequenzen, von oben nach unten, 100 Hz, 200 Hz, 300 Hz, 400 Hz und 500Hz.

Abschließend soll darauf hingewiesen werden, dass im Projekt noch keine optimale Lösung für ein Mikrofonarray zur Überwachung von Transformatoren gefunden wurde. Aufgrund der sehr tiefen Frequenzen, welche beobachtet werden müssen, sind sehr große Abmessungen notwendig, welche für den Betrieb auf einer mobilen Plattform ungeeignet sind. Außerdem können keine Elektretmikrofone in den Arrays verbaut werden, da die dazugehörige Wandlerelektronik und Zusatzhardware zu schwer für eine mobile Lösung ist. Weiters konnte keine gute Lösung mit handelsüblichen MEMS entwickelt werden. Die verwendeten Module von miniDSP können zwar für prototypische Installationen verwendet werden, sind aber für einen professionellen Einsatz nicht robust (Wetter) und flexibel (Montage) genug. Es bedarf also noch weiterer Forschung auf diesem Gebiet, um ein optimales Design mit der dazugehörigen Hardware zu entwickeln.

3.3 Softwareentwicklungen

3.3.1 Digitalisierung des Transformators

Die Erstellung und Verwendung des digitalen Referenzmodells bilden das Fundament für alle nachfolgenden Analyseprozesse und sind daher für die Funktionalität des Gesamtprojektes unerlässlich. Die Daten des multimodalen Sensors werden kombiniert und mit zusätzlichen Offline-Daten

angereichert, um einen digitalen Zwilling des Transformators zu erstellen. Nachfolgende Analysemodelle können dann die Messwerte ihrer Sensoren mit dem digitalisierten Modell abgleichen, um Abweichungen zu identifizieren. Das Modell dient schließlich der Auswertung und Konsolidierung der Ergebnisse. Die 3D-Verortung von Unregelmäßigkeiten sowie der Vergleich zwischen mehreren Messungen innerhalb einer Messfahrt oder der Vergleich mit historischen Daten ermöglichen eine Beurteilung der Plausibilität der erkannten Unregelmäßigkeiten.

As-built 3D Modell des Transformators (Referenzmodell)

Ein Modell des ausgewählten Transformators wurde mittels eines LiDAR-Scanners erstellt. Die einzelnen Scans aus 23 unterschiedlichen Positionen wurden registriert und zu einer Punktwolke mit über 95 Millionen Punkten zusammengefügt. Rauschen und irrelevante Bereiche der Aufnahmen wurden entfernt. Anschließend wurde das Referenzmodell nach Transformatorteilen und in Absprache mit Transformator-Experten auch nach thermisch interessanten Bereichen segmentiert. Aus diesen Daten wurden ein Referenzmodell für die Registrierungspipeline und das Beamforming erstellt, wie in *Abbildung 20* dargestellt.




Abbildung 20: Referenzmodell des ausgewählten Transformators in Obersielach (links mit Farbinformation, rechts mit Segmentierung nach Transformatorteilen)

Ein zusätzliches Modell eines Transformators in der Fertigungshalle in Weiz wurde für das Transformer Fingerprinting erstellt. Dieses dient dem Vergleich des Zustands des Transformators bei Auslieferung und nach Aufbau im Umspannwerk.

Registrierung von Roboteraufnahmen auf das Referenzmodell

Das as-built Referenzmodell bildet nun die Grundlage für eine weitere Anreicherung des digitalen Transformator-Zwillings mit zusätzlichen Daten. Um diese jedoch auf das Referenzmodell zu projizieren, müssen die Daten aus den Roboteraufnahmen entsprechend verortet werden. Hierzu wurde eine Registrierungspipeline entwickelt, die die Pose (Position und Orientierung) des Roboters in Relation zum Referenzmodell schätzt und die geometrische Beziehung der niedrigdimensionalen Messgrößen der Sensoren (wie z.B. 2D-Bilder) auf das 3D-Referenzmodell abbildet.

Dies erfolgt in den folgenden Schritten:

- Aufnahme eines Tiefenbildes mittels Time-of-Flight (ToF) Kamera
- Umwandlung des Tiefenbildes in eine Punktwolke mithilfe der intrinsischen Kameraparameter und der Tiefenwerte der Pixel

- Extraktion von geometrischen Merkmalen aus dem Tiefenbild und dem Referenzmodell
- Vergleich und Zuordnung (Matching) der Merkmale zueinander
- Berechnung der Transformationsmatrix zwischen Aufnahme und Referenzmodell
- Projektion der Sensordaten auf das Referenzmodell mithilfe der Transformationsmatrix und weiterer Berechnungen (z.B. unter Verwendung von extrinsischen und intrinsischen Kameraparametern)

Die Aufnahme des Tiefenbildes erfolgt mit einer gegen Sonnenlicht robusten Tiefenkamera. Die Tiefeninformationen der einzelnen Pixel sowie die aus der Kamerakalibrierung gewonnenen intrinsischen Kameraparameter werden verwendet, um das Tiefenbild in eine Punktwolke zu konvertieren.

Für die Extraktion von geometrischen Merkmalen wurden verschiedene Ansätze evaluiert. Bei 3D-Daten sind sogenannte "handgefertigte" (nicht gelernte) Merkmale nach wie vor weit verbreitet. Hierbei werden geometrische Eigenschaften der Umgebung durch Werte beschrieben (z.B. Hauptachsenausrichtung, Dichte, Oberflächenform etc.) und in einem Merkmalsvektor gespeichert. Diese Vektoren sollen den Ort in der Punktwolke möglichst gut beschreiben. Dem gegenüber stehen gelernte Merkmale, die aus der Punktwolke mittels eines statistischen Modells extrahiert und in einem Merkmalsvektor gespeichert werden. Sie beschreiben eine latente Repräsentation des Ortes, die intrinsische Strukturen und Muster in den Daten aufgreift, die möglicherweise nicht sofort erkennbar oder durch handgefertigte Merkmale erfasst sind. Gelernte Merkmale können durch den Einsatz von maschinellem Lernen, insbesondere Deep Learning und neuronalen Netzwerken, erzeugt werden. Feature-Extraktionsmodelle für Punktwolken sind dabei in der Lage, direkt aus den rohen 3D-Daten eine effektive und informative Repräsentation zu lernen.

Es ist zu berücksichtigen, dass das Referenzmodell mittels LiDAR und die Roboteraufnahmen mittels einer ToF-Kamera aufgenommen wurden. Die unterschiedlichen Sensoren liefern dabei Punktwolken mit unterschiedlichen Eigenschaften (Dichte, Anordnung der Punkte, usw.).

Darüber hinaus stellt die geometrische Form des Transformators besondere Herausforderungen für die Registrierung. Der Transformator ist grundsätzlich symmetrisch entlang seiner kurzen und langen Achse aufgebaut, oder zumindest sind Teile des Transformators symmetrisch, wie in *Abbildung 21* dargestellt. Darüber hinaus sind die langen Seiten des Transformators selbstähnlich, was bedeutet, dass sich ähnliche Muster an verschiedenen Stellen des Transformators wiederholen, wie *Abbildung 22* dargestellt.

Dies bedeutet, dass es aufgrund der allein vom Roboter aufgenommenen Geometrie allein schwierig oder sogar unmöglich ist, eindeutig auf die Position am Transformator zu schließen.




Abbildung 21: Veranschaulichung von Symmetrien am Transformator. Die Bildausschnitte repräsentieren alle unterschiedlichen Bereiche des Transformators. Die Ausschnitte sehen durch die Symmetrie jedoch sehr ähnlich aus.




Abbildung 22: Veranschaulichung von Selbstähnlichkeiten an der langen Seite des Transformators

Diesen Herausforderungen wurde mit unterschiedlichen Lösungsansätzen begegnet:

Unterschiedliche Punktwolkencharakteristiken aufgrund unterschiedlicher Sensortechnologien (cross-sensor registration)

Die aufgenommenen 3D-Daten, in diesem Fall Punktwolken, bilden die Grundlage für die Registrierung. Die Registrierung von Punktwolken bezeichnet hier das Überführen mehrerer Punktwolken in ein gemeinsames Koordinatensystem, sodass verschiedene Aufnahmen derselben Stelle übereinandergelegt und miteinander ausgerichtet werden können.

Die Herausforderung bei der Registrierung der aufgenommenen 3D-Daten liegt in der Verwendung unterschiedlicher Sensoren für die Aufnahme. Dieser Unterschied konnte bereits durch die Auswahl des Sensors für die Aufnahme des Referenzmodells verringert werden. Statt der in der Robotik üblichen LiDAR-Scanner wurde für die Aufnahme des Referenzmodells ein 360° LiDAR-Scanner verwendet, der eine ähnliche Scancharakteristik zur ToF-Kamera aufweist. Trotzdem unterscheiden sich die Punktwolken in ihrer Charakteristik, was es für das Feature-Extraction-Modell schwieriger macht, ähnliche Feature-Vektoren für denselben Ort in den jeweiligen Punktwolken zu erstellen. Dies wurde

insbesondere durch die Voxelisierung der Referenzpunktwolke und nach jeder Aufnahme auch der vom Roboter aufgenommenen Punktwolke adressiert. Eine Voxelgröße wurde gewählt, die größer ist als die geringere Auflösung der beiden Sensoren, um sicherzustellen, dass dasselbe aufgenommene Objekt von beiden Sensoren durch eine möglichst ähnliche Anzahl von Punkten repräsentiert wird.

Feature-Extraction

Die Anforderungen an die Feature-Extraction sind hauptsächlich eine möglichst genaue und eindeutige Beschreibung eines Ortes in der Punktwolke. Die Herausforderungen hierbei sind die unterschiedlichen Daten aufgrund der Verwendung unterschiedlicher Sensoren (LiDAR und ToF-Kamera), die unterschiedlichen Bedingungen während der Aufnahme (Licht, möglicherweise Nässe, unterschiedliche Aufnahmewinkel usw.) und die Selbstähnlichkeit in der Geometrie des Transformators, beispielsweise sind geraden Paneele der Transformatorseiten geometrisch auf ihrer Oberfläche sehr einheitlich. Eine weitere Anforderung aus der Verwendung am Roboter ist eine nicht allzu hohe Anforderung an die Rechenleistung (das Modell wird lokal auf einem Rechner am Roboter ausgeführt) und eine niedrige Laufzeit (die Registrierung soll direkt nach der Aufnahme – "in Echtzeit" - verwendet werden). Es wurden verschiedene Modelle und Algorithmen verglichen, sowohl mit "handcrafted features" als auch mit gelernten Features. Die besten Ergebnisse wurden mit einem 3D Convolution Neural Network erzielt. Insbesondere lieferten 3DSmoothNet und FCGF (ähnlich) gute Registrierungsergebnisse, jedoch war die Performance von 3DSmoothNet in Bezug auf die Laufzeit im Vergleich zu FCGF um einen Faktor von 25 schlechter. Eine durchschnittliche Feature-Extraction mit FCGF dauerte etwa 0,3 Sekunden, während derselbe Schritt bei 3DSmoothNet etwa 13 Sekunden dauerte. Da die Registrierungsergebnisse der beiden Modelle nahezu identisch waren, wurde letztendlich FCGF als Feature-Extraktor gewählt.

Feature-Matching

Die Anforderungen an das Feature-Matching sind einerseits eine gute Zuordnung ähnlicher Features zueinander, andererseits eine niedrige Laufzeit und Ressourcenanforderung, um in Echtzeit auf dem Roboter ausgeführt zu werden. Eine Herausforderung hierbei ist die Selbstähnlichkeit des Objekts sowie die gleichmäßige lokale geometrische Struktur einiger Teile/Oberflächen des Transformators. Beispielsweise sehen auf einer glatten Fläche entlang der Seitenpaneele des Transformators die Punktwolken lokal sehr ähnlich aus (glatte, ebene Fläche), sodass die Feature-Vektoren, die diese Fläche beschreiben, alle sehr ähnlich sein werden. Untersuchungen haben ergeben, dass gute Ergebnisse erzielt werden können, wenn nicht nur jeweils das ähnlichste Paar zueinander zugeordnet wird, sondern wenn die ähnlichsten n Paare zueinander zugeordnet werden. Hier ist die Wahrscheinlichkeit höher, dass der tatsächlich gleiche Ort erfolgreich gematcht wurde. Der damit verbundene Nachteil ist, dass es hier für den gleichen Ort in der Punktwolke gleich mehrere Feature-Paare gibt. Dies muss anschließend vom Posen-Schätzungs-Algorithmus berücksichtigt werden.

Posen-Schätzung

Die Schätzung der Transformationsmatrix zwischen der Referenzpunktwolke und der Punktwolke aus der Roboter-Aufnahme wird zur Berechnung der Pose des Roboters verwendet. Die Herausforderung bei der Posenschätzung liegt wieder in der Selbstähnlichkeit des Objekts bzw. der einheitlichen

geometrischen Oberfläche an bestimmten Teilen des Transformators. Dies führt dazu, dass relativ viele Feature-Paare falsch sind (die Paare der Feature-Vektoren repräsentieren nicht den gleichen Ort in der Punktwolke). Dies bedeutet, dass der Input für die Transformationsschätzung sehr viel Rauschen (Noise) beinhaltet. Daher muss für die Schätzung der Transformationsmatrix ein robuster Algorithmus verwendet werden, der mit wenigen korrekten Feature-Paaren und vielen falschen Feature-Paaren ein korrektes Ergebnis liefert. Üblicherweise werden für solche Aufgaben RANSAC (Random Sample Consensus) oder ähnliche Algorithmen verwendet. In diesem Projekt wurde die Leistung von RANSAC und anderen ähnlichen Algorithmen verglichen und schließlich wurde TEASER++ als ein State-of-the-Art-Algorithmus mit bester Leistung ausgewählt. Dieser Algorithmus kann mit bis zu 90% Rauschen und kurzer Laufzeit immer noch korrekte Ergebnisse liefern.

Verwendung der probabilistischen Roboter-Pose aus der Roboternavigation

Um den durch Selbstähnlichkeit und Symmetrie verursachten Herausforderungen zu begegnen, wurde die probabilistische Roboter-Pose als Vorwissen in die Registrierungs-Pipeline integriert. Dies erlaubt den Vergleich und die Registrierung der aufgenommenen Punktwolke mit nur einer Teilmenge der Referenzpunktwolke. Dadurch können potenzielle ähnliche Merkmale von symmetrischen und selbstähnlichen Teilen, die jedoch weiter vom Roboter entfernt sind (beispielsweise auf der gegenüberliegenden Seite des Transformators), aus der Menge an Merkmalen für das Feature-Matching und die nachfolgende Pose-Schätzung herausgefiltert werden. Dies erhöht die Wahrscheinlichkeit, dass korrekte Merkmale gematcht werden, und reduziert gleichzeitig falsche Zuordnungen (Rauschen), was die Aufgabe der Pose-Schätzung vereinfacht. *Abbildung 23* veranschaulicht die Auswahl der Punkte aus der Referenzpunktwolke, die auf der groben Roboterpose basiert. Hierbei werden jene Punkte aus der Referenzpunktwolke gewählt, die sich innerhalb eines bestimmten Radius um die ungefähre Roboterpose befinden. Der Radius wird so gewählt, dass selbst bei einer Ungenauigkeit der Positionsangabe aus der Roboternavigation ein ausreichend großer Bereich für die Registrierung zur Verfügung steht.

Es ist wichtig zu beachten, dass die Roboterpose aus der Navigation des Roboters nicht direkt anstelle der Registrierungs-Pipeline verwendet werden kann. Dies liegt daran, dass die Roboterpose einerseits lediglich eine 2D-Pose auf der Roboterkarte repräsentiert und andererseits zu ungenau ist. Obwohl die Umgebung des Transformators relativ flach ist und sowohl die Z-Koordinate als auch die Ausrichtung aus der Position und Ausrichtung der Kamera auf dem Roboter berechnet werden können, würde dies dennoch zu einem mittleren Fehler der 3D-Roboterposen von 28 cm führen. Für die Anwendung im Projekt ist dies nicht ausreichend, da beispielsweise eine um 28 cm falsche Position eines Messinstruments bereits auf der Position eines anderen Messinstruments liegen würde.




Abbildung 23: Auswahl der Teilmenge von Punkten der Referenzpunktswolke für die Registrierung anhand der ungefähren Roboterpose

Ergebnisse der Registrierungspipeline

Die Registrierungsleistung wurde evaluiert, indem die Aufnahmeregistrierungen manuell überprüft und nach Bedarf korrigiert wurden. Mit dem Einsatz des Iterative Closest Point (ICP) Verfahrens konnte eine präzise Transformationsmatrix berechnet werden. Die Evaluierung wurde auf realen Daten durchgeführt und beinhaltete Aufnahmen unter verschiedenen Bedingungen, einschließlich unterschiedlicher Wetterbedingungen, Uhrzeiten und Lichtverhältnisse.

Verwendung der ungefähren Roboterposition	Art/Anzahl der nächsten Nachbarn	Durchschnittliche Registrierungszeit in s	Durchschnittliche Translationsfehler in m	Durchschnittliche Rotationsfehler in Grad	Übereinstimmungsrate der Frames in %
Nein	Gegenseitig	0.54	0.09	1.02	91.4
Nein	1	0.7	0.11	1.32	93.1
Nein	2	0.8	0.14	1.43	93.1
Ja	Gegenseitig	0.59	0.1	1.17	96.6
Ja	1	0.55	0.08	1.06	98.3
Ja	2	0.49	0.06	0.77	98.3

Tabelle 1: Ergebnisse der Registrierungsevaluierung mit unterschiedlichen Registrierungsparametern

Tabelle 1 vergleicht die Ergebnisse der Registrierung mit verschiedenen Parameter-Einstellungen der Registrierungspipeline. Die ersten beiden Spalten der Tabelle repräsentieren die Parameter:

- Die erste Spalte zeigt an, ob die approximative Roboterposition im Prozess verwendet wurde oder nicht.
- Die zweite Spalte gibt die Art oder Anzahl der nächsten Nachbarn (nearest neighbors) an. Ein "Gegenseitig" bedeutet hier, dass ausschließlich Merkmalspaare berücksichtigt wurden, die in der gegenseitigen Betrachtung jeweils die nächsten Nachbarn im Merkmalsraum bildeten. Wenn eine numerische Angabe vorliegt, gibt diese die Anzahl der berücksichtigten nächsten Nachbarn an.
- Die übrigen Spalten der Tabelle enthalten Messwerte zur Registrierungsleistung, darunter die durchschnittliche Registrierungszeit, der durchschnittliche Translations- und Rotationsfehler

sowie die Übereinstimmungsrate der Frames.


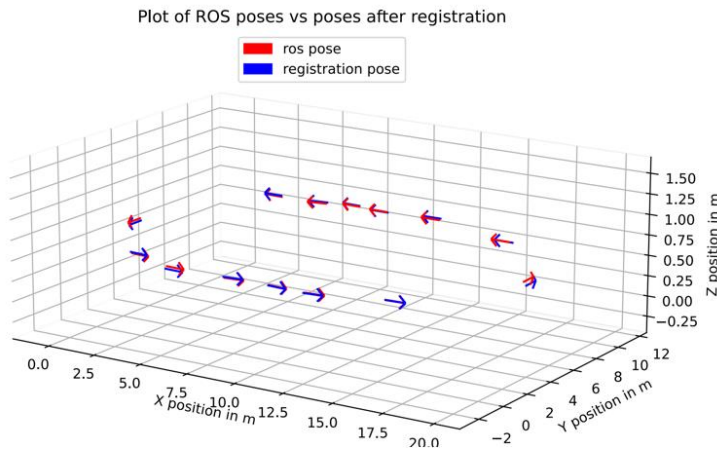


Abbildung 24: Vergleich der Roboterposen aus der Roboternavigation in rot (ros pose) mit den Ergebnissen der Registrierungs pipeline in blau (registration pose). Links als Diagramm von Posen dargestellt als Pfeile im 3D-Raum. Rechts jeweils eine Aufnahme und die Ausrichtung zur Referenz (rot mittels Roboterpose, blau mittels Registrierung)

Die ausgewerteten Ergebnisse zeigen, dass eine Registrierungs erfolgsquote von 98,3% erreicht wurde. Der durchschnittliche translatorische Fehler betrug dabei 6 cm und der Winkel fehler 0,77°. Im Vergleich dazu lag der mittlere translatorische Fehler bei der Nutzung der Roboterpose bei 28 cm. Wie bereits in Abschnitt 1.3 festgestellt wurde, erweist sich die Roboterpose für die Anforderungen dieses Projekts als nicht ausreichend genau. Die Ergebnisse bestätigen daher die Effektivität der angewandten Methode im Vergleich zur Verwendung der Roboterpose.

3.3.2 Überlagerte Thermalinformation

Ein weiterer Aspekt dieses Forschungsprojekts war die Verwendung von Thermalsensordaten und ihre Integration in den digitalen Zwilling. Hierfür wurde die in Abschnitt 1 beschriebene Registrierungs pipeline sowie die geometrische Kalibrierung des multimodalen Sensorsystems genutzt, um die Thermalinformationen auf das Modell des Transformators zu überlagern.

Stationäre Untersuchung des Transformators in Zurndorf

Ursprünglich war geplant, im Rahmen dieses Projekts ein analytisches Thermalmodell des Transformators zu erstellen und diese Daten mit den aus den Thermalsensoren gewonnenen Daten zu vergleichen. Hierfür wurde ein stationärer Versuch mit einer Thermalkamera durchgeführt, bei dem über einen Zeitraum von etwa zwei Monaten alle 15 Minuten Aufnahmen des Transformators angefertigt wurden. Diese Daten wurden anschließend mit Daten aus einer Wetterstation sowie SCADA-Daten verglichen und ausgewertet.

Die Analyse dieser Daten zeigte eine gute Korrelation zwischen den Oberflächentemperaturen und der Wicklungs- und Öltemperatur, wie in *Abbildung 25* dargestellt, welche eine stationäre Thermalaufnahme des Transformators mit Einteilung in unterschiedliche Bereiche von Interesse zeigt. Trotz dieser Korrelation ist es jedoch nicht möglich, Rückschlüsse auf den genauen inneren Zustand des Transformators zu ziehen. Da die Wicklungs- und Öltemperatur für den Betreiber des Transformators ohnehin bekannt sind und im SCADA-System hinterlegt werden, wurde der ursprüngliche Ansatz als nicht zielführend eingestuft. Stattdessen wurde ein neuer Ansatz gewählt, bei dem die

Thermalinformationen am Transformator miteinander und gegen festgelegte Grenzwerte verglichen werden.

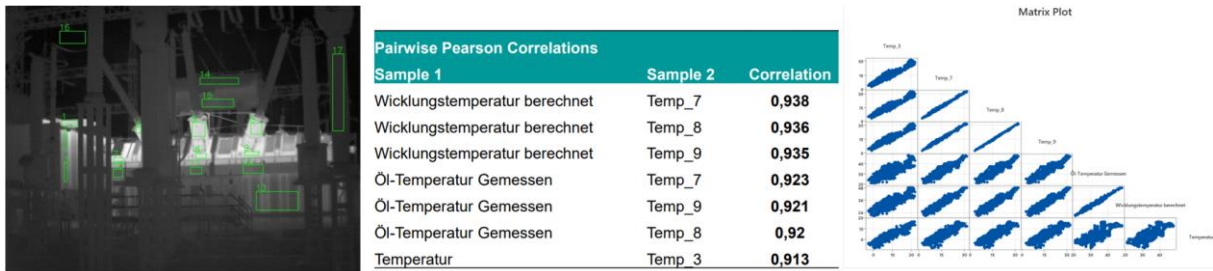


Abbildung 25: Stationäre Thermalaufnahme des Transformators mit Einteilung in unterschiedliche Bereiche von Interesse. Die dazugehörige statistische Auswertung wird im Vergleich zu Daten aus dem SCADA-System dargestellt.

Überlagerung der Thermalinformationen auf den digitalisierten Transformator

Die Thermalinformationen wurden mithilfe einer Thermalkamera (Modell Optris 450) aufgenommen. Diese Kamera liefert jedoch nur ein 2D-Bild mit Thermalinformationen. Um diese Informationen nutzbar zu machen, müssen sie zunächst auf das digitale Modell des Transformators abgebildet werden. Dieser Prozess wird durch die Verwendung einer Transformationsmatrix ermöglicht, die aus der Registrierungspipeline zwischen der Tiefenkamera-Aufnahme und dem Referenzmodell des Transformators erhalten wird. Zusätzlich werden die extrinsischen Kameraparameter der Thermalkamera im Bezug zur Tiefenkamera benötigt, um die Position und Orientierung der Kamera im Raum im Bezug zur Tiefenkamera zu beschreiben. Die Kombination dieser beiden Transformationen erlaubt es schließlich den räumlichen Bezug zwischen der Thermalkamera und dem Referenzmodell herzustellen.

Für die anschließende Abbildung der Thermalinformationen auf das digitale Modell des Transformators sind die intrinsischen Kameraparameter der Thermalkamera benötigt, welche die projektive Abbildung von 3D-Weltpunkten in das 2D-Bild beschreiben.

Das Ergebnis der Abbildung einer 2D Thermalaufnahme auf das Referenzmodell ist in *Abbildung 26* dargestellt.




Abbildung 26: 2D Bild einer Thermalaufnahme und die dazugehörige Überlagerung auf das Referenzmodell

Um die Daten weiter zu verarbeiten und anschließende Analysen durchzuführen, wird dieser Prozess für jede Roboterposition wiederholt und die einzelnen Aufnahmen werden zusammengefügt. Dies resultiert in einem vollständigen Thermalmodell des Transformators, wie in *Abbildung 27* zu sehen ist.




Abbildung 27: Vollständiges Thermalmodell eines Transformators erstellt aus Aufnahmen einer Roboterfahrt

Jede Fahrt des Roboters erzeugt ein individuelles Thermalmodell, das eine zeitpunktbezogene Thermalaufnahme des Transformators darstellt. Diese gewonnenen Informationen können nun ausgewertet und mit anderen, vorherigen Modellen verglichen werden.

Erkennung von Hotspots und Übertemperaturen

Der erste Schritt in der Auswertung besteht darin, das erstellte Modell zu nutzen, um zu prüfen, ob die Temperaturwerte festgelegte Grenzwerte überschreiten. Diese Grenzwerte werden im Vorfeld in Zusammenarbeit mit Experten für Transformatoren definiert. Da diese Grenzwerte für unterschiedliche Teile des Transformators variieren können, ermöglicht dies eine genauere und spezifischere Überwachung im Vergleich zu einem allgemeingültigen Temperaturlimit.

In einem weiteren Schritt wird das erstellte Modell zusätzlich auf mögliche Hotspots untersucht. Hierfür wird die erste Ableitung der Temperaturen entlang der drei Raumachsen berechnet, welche die Temperaturveränderungen in den jeweiligen Bereichen aufzeigt. Diese resultierenden Werte werden dann hinsichtlich bekannter Zonen mit hohen Temperaturänderungen gefiltert, wie etwa an der Schnittstelle zwischen dem Wärmetauschgitter und dem Wärmetauschergehäuse. Das verbleibende Feld wird daraufhin auf signifikante Temperaturänderungen in kleinen Bereichen untersucht. Sollte eine lokale Überhitzung in einem unerwarteten Bereich des Transformators auftreten, wird diese als Anomalie registriert.

Zeitlicher und Räumlicher Vergleich von Temperaturen in interessanten Bereichen

Ein weiterer Schritt in der Analyse der Thermalinformationen beinhaltet die Untersuchung der gemessenen Werte in zeitlicher und räumlicher Hinsicht. Ein Beispiel dafür ist der Vergleich der Temperaturen der vier Wärmetauscher sowohl untereinander als auch im zeitlichen Verlauf. *Abbildung 28* illustriert die Entwicklung der Wärmetauschertemperaturen über einen Zeitraum von etwa einem Monat, wobei die Aufnahmen zweimal täglich erfolgten. Die Temperaturverläufe offenbaren unterschiedliche Ereignisse. So zeigen beispielsweise die Messungen vom 17.11.2023 um 09:45 Uhr bei zwei Wärmetauschern eine Temperatur von etwa 25°C, während die beiden anderen Wärmetauscher etwa 38°C aufweisen. Diese Auffälligkeit wurde mit den Betreibern des Transformators abgeklärt und

stellte sich als typische Abweichung heraus, die durch einen speziellen Betriebszustand verursacht wurde, in dem nur die Pumpen und Lüftungen der Hälfte der Wärmetauscher aktiv waren.

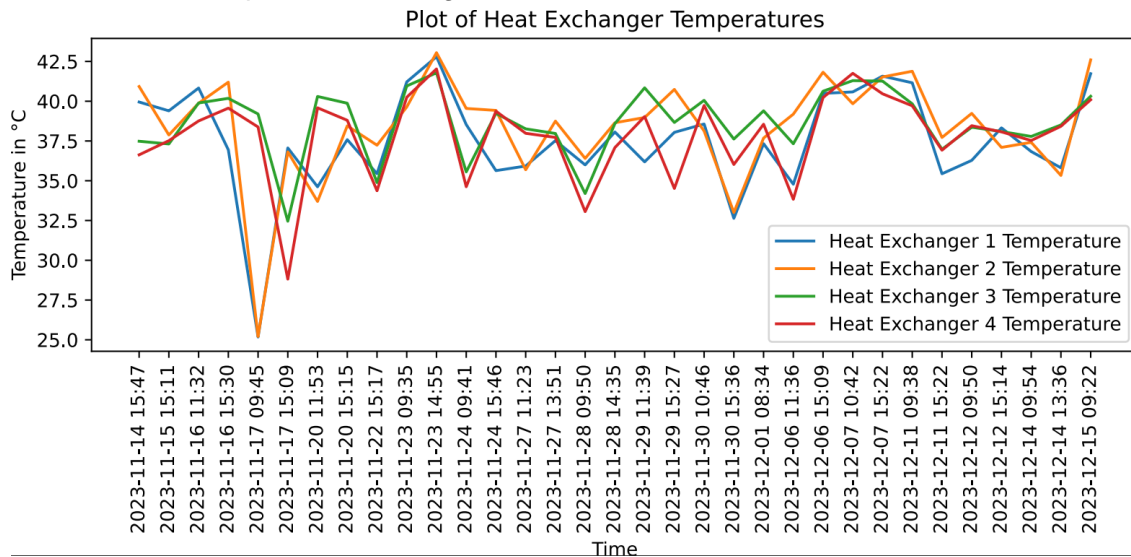


Abbildung 28: Temperaturverlauf der vier Wärmetauschertemperaturen über einen Zeitraum von etwa einem Monat

In diesem Fall war die Abweichung also eine korrekte Wiedergabe des Betriebszustands des Transformators. Ähnliche Analysen können jedoch auch zur Aufdeckung thermischer Anomalien am Transformator genutzt werden. Beispielsweise sollten Temperaturänderungen an den Anschlüssen zu den Zuleitungen und Abgängen am Transformator keine signifikanten Unterschiede aufweisen. Andernfalls könnte dies auf eine schlechte Verbindung (möglicherweise durch Korrosion oder Lockerung der Anschlüsse durch Witterungseinflüsse) oder eine ungleichmäßige Belastung des Transformators hindeuten. Auch bei Wärmetauschern können Ereignisse wie das oben beschriebene auftreten, beispielsweise durch eine Verunreinigung des Wärmetauschergitters oder den Ausfall eines Ventilators.

Inspektion des Transformators während Prüffeldtests und Erstinbetriebnahme

Im Gespräch mit Transformatorexperten wurde deutlich, dass sowohl während der Prüffeldtests (im Transformatorenwerk) als auch bei der Erstinbetriebnahme eine thermische Inspektion des Transformators stattfindet. Diese umfasst eine manuelle Überprüfung der Transformatortemperaturen mittels einer Wärmebildkamera. Besonderes Augenmerk liegt dabei auf thermischen Auffälligkeiten oder spezifischen Eigenschaften des Transformators. Beispielsweise können an Kreuzungspunkten von Leitungen erhöhte Temperaturen an der Transformatorhülle auftreten, was in diesem Fall normal ist. Es muss jedoch überprüft werden, ob die beobachtete Temperatur tatsächlich mit der Lage dieser Kreuzungspunkte übereinstimmt.

Diese Inspektionen könnten jedoch auch durch den Roboter durchgeführt werden. Ein vollständiges thermisches 3D-Modell liefert eine weitaus detailliertere und umfassendere Darstellung der thermischen Gegebenheiten am Transformator. Zudem wird der Zustand des Transformators in einer Weise gespeichert, die eine spätere Betrachtung ermöglicht, falls Unklarheiten auftreten sollten - eine Option, die bei manueller Inspektion mit einer Wärmebildkamera nicht gegeben ist. Die im Rahmen dieser Prüfungen gewonnenen Informationen können zudem direkt zur Festlegung der thermischen Grenzwerte genutzt werden. So kann beispielsweise an den Kreuzungspunkten ein höheres Temperaturlimit als in anderen Bereichen des Transformators festgelegt werden.

3.3.3 Akustische 3D-Heatmaps

Die hier entwickelte Methode stellt einen neuartigen Ansatz zur Messung und Visualisierung der Schallemissionen von Objekten dar. Der verwendete Begriff akustische 3D-Heatmap bezieht sich auf die dargestellte Verteilung der Schallemissionen über die gesamte Oberfläche des Objektes, in unserem Fall des Transformators.

Grundlage der akustischen 3D-Heatmap ist die Verbindung eines 3D-Modells mit dem Output eines akustischen Beamforming-Algorithmus. Im Speziellen besteht das hier verwendete 3D-Modell des Transformators aus gleichmäßig verteilten Voxeln. Ein akustischer Beamforming Algorithmus berechnet aus den Signalen eines Mikrofonarrays für einen definierten Referenzpunkt (hier die Position des Sensorarrays) für unterschiedliche räumliche Einfallsrichtungen die resultierende Schallabstrahlung des Objekts. In Verbindung der beiden Systeme weist der Beamforming-Algorithmus jedem Voxel des 3D-Modells eine gerichtete Schallabstrahlung zu. Die Werte dieser gerichteten Schallabstrahlung ergeben nun eine akustische 3D-Heatmap für jede gewünschte Frequenz. Die akustischen 3D-Heatmaps beinhalten also verschiedene Informationen, darunter den abgegebenen Schalldruckpegel sowie lokalisierte Schallquellen bei charakteristischen Frequenzen. Anhand dieser Informationen können leistungsstarke Visualisierungs-, Inspektions- und Prognosemodelle entwickelt werden, um den Zustand des Transformators zu beurteilen.

Schallausbreitungsmodell

Durch die Verwendung einer Tiefenkamera ist der Abstand zu jedem Voxel bekannt, es ist daher möglich, aus Sicht des Beamforming Algorithmus jeden Voxel des 3D-Modells als mögliche Schallquelle zu betrachten. In typischen akustischen Beamforming Anwendungen geht man außerdem davon aus, dass die Größe eines Mikrofonarrays klein ist im Vergleich zum Abstand zur Schallquelle, und eine Schallausbreitung in Form einer ebenen Welle wird als Grundlage für die Berechnungen des Beamforming Algorithmus verwendet. Im Fall des Transformators und der Größe der hier-verwendeten Arrays ist der Fehler durch die angenommene ebene Wellenausbreitung nicht mehr vernachlässigbar.

Abbildung 29 zeigt den Fehler der angenommenen ebenen Welle. Der Schall wandert von der Schallquelle über r_1 und r_2 zu zwei Mikrofonen, die durch den Abstand d getrennt sind. Wird das erste Mikrofon als Referenzmikrofon betrachtet, verläuft die ebene Welle orthogonal zu r_1 . Weiters stellt φ den Schalleinfallswinkel am Referenzmikrofon dar. Aus der Abbildung ist der Unterschied in der Berechnung der verzögerten Ankunftszeit des Schalles (DOA, Difference of Arrival) am Mikrofon 2 der beiden

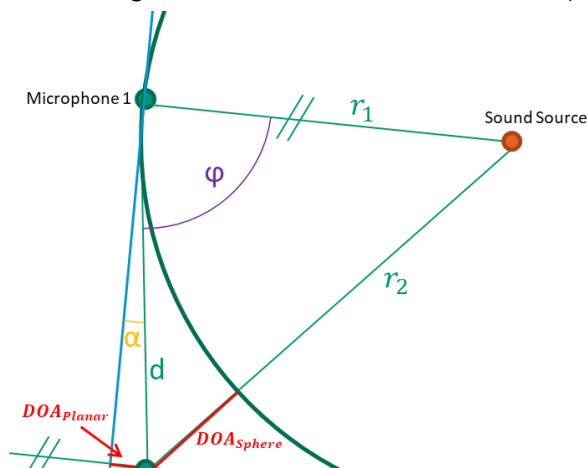


Abbildung 29: Fehler durch die Annahme einer ebenen Schallwellenausbreitung.

Modelle zur Schallausbreitung ersichtlich. Im Speziellen ist $DOA_{Sphere} = r_2 - r_1$, während $DOA_{Planar} = d \cos \varphi$ ist. Unter Berücksichtigung der Kosinusregel hängt der Fehler, der sich aus der Annahme einer ebenen Welle ergibt, von drei Parametern ab, nämlich φ , r_1 und d .

Abbildung 30 zeigt den DOA-Fehler bei verschiedenen Schallquellenabständen und verschiedenen Mikrofonabständen bei einem Schalleinfallswinkel von

80°. *Abbildung 31* zeigt den DOA-Fehler bei verschiedenen Schallquellenabständen und Ankwrtswinkeln bei einem Mikrofonabstand von 1 m. Je größer der Schallquellenabstand, desto kleiner der Fehler. Außerdem ist der Einfluss des Fehlers frequenzabhängig: bei Frequenzen mit großen Wellenlängen im Vergleich zum DOA-Fehler ist der Effekt der Annahme einer ebenen Schallwellenausbreitung geringer als bei Frequenzen mit kleinen Wellenlängen, d. h. hohe Frequenzen sind stärker betroffen als niedrige Frequenzen. Ein Mikrofonarray mit einer Aperturgröße von etwa 1 m, einem gemeinsamen r_1 von 5 m und einem Schalleinfallswinkel von etwa 70° hat einen Fehler bei der Annahme einer ebenen Welle von etwa 0,1 m. Bei 500 Hz wird daraus ein Wellenlängenfehler von etwa 52°, wobei 180° eine vollständige negative Interferenz darstellt.

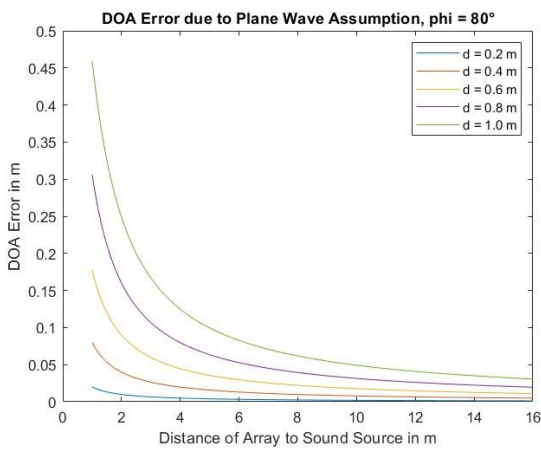


Abbildung 30: Fehler bei einer Schalleinfallrichtung von 80°.

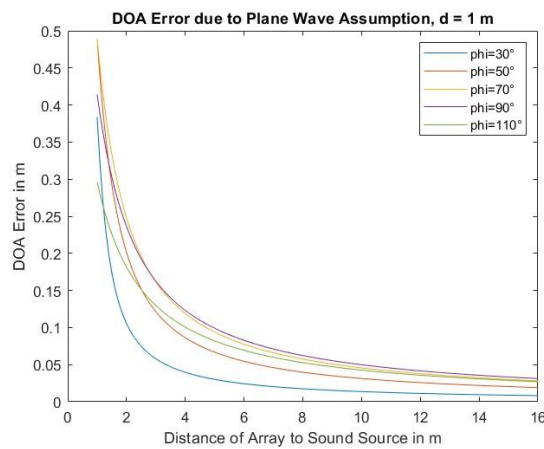


Abbildung 31: Fehler bei einem Mikrofonabstand von 1m.

Bei Verwendung einer Punktwolke als mögliche Schallquellenpunkte kann über die vorhandenen Abstandsinformationen aller Voxel zu den Mikrofonen (d.h. r_1 und r_2 in **Fehler! Verweisquelle konnte nicht gefunden werden.** sind bekannt) die sphärische Schallwellenausbreitung verwendet werden. Dadurch wird der Fehler, welcher üblicherweise durch die Annahme einer ebenen Schallwellenausbreitung induziert wird, minimiert und die resultierenden Heatmaps liefern aussagekräftigere Daten.

Implementierung

Als Ausgangspunkt dient das 3D-Modell des Transformators, das aus mehreren omnidirektionalen LIDAR-Scans erstellt wurde (vgl. Abschnitt 3.3.1). Mit Hilfe eines RGB-D-Bildes, aufgenommen mit dem kombinierten visuellen Sensor (RGB und Tiefe), wird die tatsächliche Position des Mikrofonarrays in Bezug auf das 3D-Modell ermittelt. Auf diese Weise wird ein optimaler Abgleich der verschiedenen Sensormodalitäten zueinander garantiert, und ermöglicht die bestmögliche Zuordnung der Audiodaten zur Punktwolke.

Für das akustische Beamforming wird der Delay-and-Sum (DAS) verwendet [1], um den aus einer bestimmten Richtung einfallenden Schall zu berechnen. DAS garantiert Artefakt-freie Ausgangssignale, welche zur Modelbildung verwendet werden können. Darüber hinaus bewahrt DAS die Amplitudenverhältnisse in Bezug auf die Eingangssignale, was für die Berechnung der resultierenden

absoluten Schalldruckwerte unerlässlich ist. Die Verwendung der 3D-Punktwolke verbessert den Beamformer Output im Vergleich zur der üblicherweise angenommene ebenen Schallwellenausbreitung, insbesondere bei kurzen Abständen zwischen dem Mikrofonarray und dem Transformator (siehe oben). Das resultierende Beamforming-Pattern stellt die Schallabstrahlung des Transformators von der Position des Mikrofonarrays aus gesehen dar. Für das gesamte 3D-Modell werden mehrere Messungen zusammengefasst, wobei für jede Seite des Transformators eine Messung herangezogen wird. Ein etwaiges anisotropisches Abstrahlverhalten des Transformators wird in diesem Modell noch nicht berücksichtigt, ist aber als zukünftiger Forschungsinhalt zu sehen. *Abbildung 32* und *Abbildung 33* zeigen akustische Wärmebilder eines Transformators für den gesamten Frequenzbereich als 3D-Heatmap bzw. für eine einzelne Frequenz als 2D-Heatmap.




Abbildung 32: 3D-Heatmap der gesamten Schallemissionen des Transformators.




Abbildung 33: Schallabstrahlung einer Seite des Transformators bei 600 Hz.

Die hier-entwickelten akustischen Modelle des Transformators können zur Visualisierung, Inspektion oder Modellierung seines Zustandes verwendet werden. Die räumliche Zuordnung der Schallabstrahlung ermöglicht damit eine direkte Lokalisation von Schallereignissen an der Oberfläche des Transformators. Weiters können auf dieser Datenbasis Vorhersagemodelle erstellen werden, indem Techniken der statistischen Analyse oder des maschinellen Lernens auf akustische 3D-Heatmaps angewandt werden. Solchen Modellen können automatisch Anomalien und daraus folgende potenzielle Ausfälle vorhersagen.

3.3.4 Akustische Datenaufzeichnung und Analysen

Schallfeld des Transformators

Ein Transformator emittiert aufgrund des elektromagnetischen Schwingungsverhaltens verschiedener interner Komponenten sowie seiner Peripherieanlagen ein sehr charakteristisches Geräusch [2]. Den größten Anteil an seinem Geräusch haben die Schwingungen des Kerns und der Hauptwicklung. Weiters tragen externe Komponenten wie z.B. Kühl- und Lüfteranlagen zum Schallfeld eines Transformators bei. Darüber hinaus erzeugen Teilentladungen in der Wicklungsisolierung und in den Isolierbürsten einen geringeren Teil der Geräuschemissionen [3]. Außerdem können geomagnetisch induzierte Ströme und andere Gleichstromkomponenten des Kerns zusätzliche Geräuschquellen erzeugen [4]. Durch die Kombination der genannten Faktoren entsteht ein komplexes Schallfeld, das

zusätzlich durch das Alter des Transformators, seine Belastung und mögliche Anomalien beeinflusst wird [5].

In diesem Projekt wurden hauptsächlich die 3 Hauptkomponenten der Geräuschemissionen des Transformators berücksichtigt. Diese sind 1) die Emissionen des Kerns, 2) die Emissionen der Wicklung und 3) die Geräusche der Kühl- und Lüfteranlage. Schließlich wurden auch die Komponenten, welche durch die DC Ströme erzeugt werden, in Betracht gezogen.

Modellierung des Normalzustandes

Messergebnisse

Das Geräusch des Transformators setzt sich hauptsächlich aus der Schwingung des Kerns und der Wicklung zusammen [2]. Der Kern erzeugt eine harmonische Schwingung mit einer Grundfrequenz von der doppelten Anregungsfrequenz, d.h. 100 Hz. Dazu kommen die harmonischen Teiltöne, welche bis 1 kHz stark vertreten sind. Dieses sehr charakteristische Geräusch („Brummen“) ist unabhängig von der Belastung des Transformators und wird konstant emittiert. Im Gegensatz dazu ist das Geräusch der Wicklung lastabhängig, d.h. es wird stärker je höher der Transformator belastet wird. Außerdem bildet es fast ausschließlich eine spektrale Komponente bei 100 Hz. Im Betrieb setzt sich das Geräusch des Transformators selber also aus einem relativ konstanten harmonischen Anteil sowie einem lastabhängigen Anteil bei 100Hz zusammen. Abbildung 34 zeigt die beiden Komponenten des Transformatorgeräusches gemessen während der Endprüfung bei Siemens Energy in Weiz. Links ist der lastunabhängige Anteil mit den harmonischen Komponenten während der Leerlaufmessung zu sehen. Rechts sieht man die überlagerte 100Hz Komponente bei Belastung.




Abbildung 34: Darstellung der spektralen Energie über die Zeit während der Prüfmessungen im Leerlauf (links) und unter Last (rechts). Gut zu erkennen die Überlagerung der beiden Komponenten während des Lastbetriebs.

Während der Endprüfung wird der Transformator auch bzgl. seiner Schallemissionen vermessen. Dabei wird überprüft, ob die vorgeschriebenen Grenzwerte nicht übertreten werden. Über die Mittelung einer kontinuierlichen Schallintensitätsmessung um den ganzen Transformator herum werden die resultierenden Werte bestimmt. Diese Messung wird manuell in 2 verschiedenen Höhen in einem Abstand von 30 cm während eines Rundgangs um den Transformator durchgeführt. Im Zuge des Projekts wurde versucht, diese Messung mit dem entwickelten Mikrofonarray durchzuführen und die resultierenden Werte mit denen der manuellen Messung zu vergleichen. Dabei wurde das Array vor

jeder Seite des Transformators in einem fixen Abstand positioniert und die Schallemissionen gemessen. *Abbildung 35* zeigt den Vergleich der beiden Messungen, rechts das Ergebnis der manuellen Messung, links das Ergebnis der Messung mit dem Mikrofonarray.

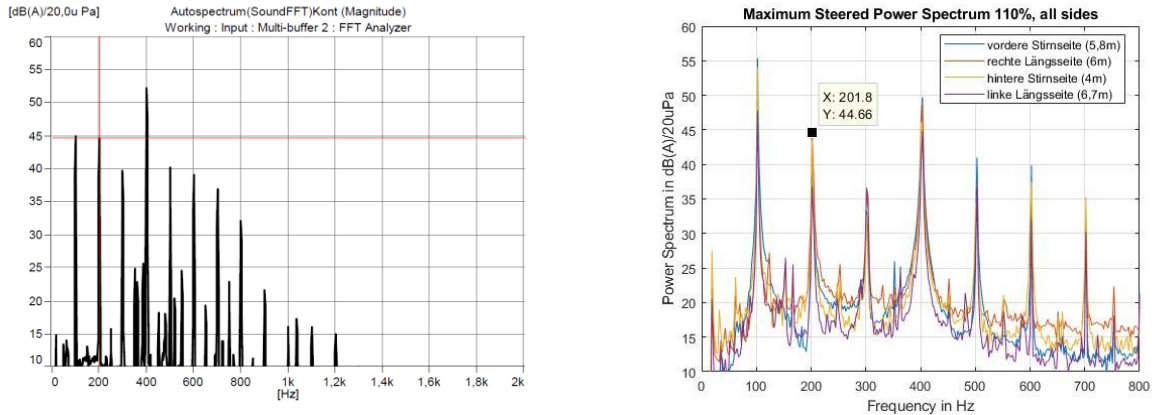


Abbildung 35: Vergleich der Pegelmessungen bei der Endprüfung des Transformators. Links sieht man das Spektrum als Resultat der gängigen Methode über die Mittelung der Schallintensitätsmessungen in einem Abstand von 0.3 m. Rechts sind die Spektren der Einzelmessungen mit dem Mikrofonarray der 4 Seiten des Transformators übereinandergelegt abgebildet. Man sieht trotz der sehr unterschiedlichen Messverfahren die deutliche Übereinstimmung der absoluten Pegelwerte für die einzelnen charakteristischen Frequenzen.

Aus *Abbildung 35* ist die sehr gute Übereinstimmung der Werte der beiden unterschiedlichen Messverfahren ersichtlich. Daraus kann geschlossen werden, dass die manuelle Methode ohne qualitative Einbußen durch eine automatisierte Lösung ersetzt werden könnte.

Die Messungen in Zurndorf mit der stationären Sensorik (BigGrid16) wurden dazu verwendet, um das Prinzip der Berechnung der akustischen Heatmaps (Verbindung des 3D-Modells mit dem Beamformer) zu testen und die Lokalisation von Schallereignissen über die Heatmaps zu überprüfen. Dafür wurde der Beamformer für die 100 Hz Komponente verwendet und diese am Transformator lokalisiert.




Abbildung 36: Ergebnisse aus den Messungen in Zurndorf. Links eine Heatmap für die Frequenz von 100 Hz, es werden nur die obersten 10% der Schallpegel angezeigt. Rechts die Ergebnisse der Korrelation der akustischen Daten einer Woche mit den Lastdaten aus demselben Zeitraum. Man erkennt eine sehr gute Korrelation in den Regionen des Transformators, wo sich die Wicklung befindet.

Abbildung 36 links zeigt eine Heatmap der 100Hz Emissionen des Transformators in Zurndorf, wobei hier nur die höchsten 10% der Schallpegel angezeigt werden. Um die Lokalisation von Schallereignissen mit der Heatmap zu demonstrieren, wurde eine Korrelationsanalyse der akustischen Signale mit den aus dem SCADA System ausgelesenen Werten zur Belastung des Transformators durchgeführt. Da die Lastabhängigkeit der akustischen Emissionen hauptsächlich über die Schwingung der Wicklung mit 100 Hz abgebildet ist, ist hier eine Übereinstimmung der beiden Zeitreihen im Bereich der Transformatormitte zu erwarten. Insgesamt wurden Daten innerhalb einer Woche in einem Intervall von 15 Minuten für die

Analyse verwendet. Die Ergebnisse sind in *Abbildung 36* rechts zu sehen. Man erkennt deutlich die sehr guten Korrelationswerte für den Mittenbereich des Transformators, wohingegen an den Rändern (Kühlsystem und Stufenschalter) sehr schlechte und mitunter auch negative Korrelationen zu beobachten sind.

Modellierung

Um Veränderungen in den Schallemissionen des Transformators detektieren zu können, wurde ein Modell mithilfe der akustischen Heatmaps entwickelt. Dabei wurden die akustischen Daten aus der Messkampagne in Obersielach verwendet, um ein statistisches Modell zu erzeugen, welches aktuelle Messungen analysiert und Aussagen über Abweichungen vom Normalzustand ausgibt. *Abbildung 37* zeigt ein Spektrogramm von allen in Obersielach aufgenommenen Daten.




Abbildung 37: Spektrogramm mit allen in Obersielach aufgenommenen akustischen Daten.

Abbildung 37 beschreibt die Frequenzverteilung über alle Messungen aus Obersielach. Deutlich zu erkennen sind die charakteristischen Frequenzen des Transformators bei Vielfachen seiner Grundfrequenz (100Hz), welche relative konstant über alle Messungen sind. Weiters sind leichte Schwankungen der Amplitudenwerte bei allen Frequenzen zu erkennen, welche auf die unterschiedliche Belastung des Transformators über die Zeit zurückzuführen sind.

Um die Abweichungen zu modellieren wurden in den akustischen Heat-Maps des Transformators jeder Voxel mit einer Gaußverteilung dargestellt. Die Parameter der Verteilung (Mittelwert und Standardabweichung) ergeben sich aus den Werten aller Messungen im betreffenden Zeitintervall. Für eine neue Messung kann somit für jeden Voxel eine Wahrscheinlichkeit ermittelt werden, mit der der jeweilige Wert durch die zugrundeliegende Normalverteilung repräsentiert werden kann. Niedrige Wahrscheinlichkeiten deuten daher auf Abweichungen vom Normalzustand hin bzw. können auf Veränderungen hinweisen. Durch die Verwendung der akustischen Heat-Maps als Grundlage des Modells lassen sich die Detektionen außerdem auf dem Trafo lokalisieren. So kann direkt auf die Ursache der Veränderung geschlossen werden.

Abbildung 38 zeigt die Frequenzverteilung einer Messung (alle 4 Seiten des Transformators aus Obersielach) mit zugehörigen Werten für Mittelwert und Standardabweichung. Die beiden grauen Linien beziehen sich auf das Intervall Mittelwert plus minus Standardabweichung. Für die hier vorgestellte Methode zur Erkennung von Veränderungen wurden alle Werte als Abweichung detektiert, welche außerhalb dieses Intervalls fallen.




Abbildung 38: Messungen am Transformator mit Intervall zur Detektion von Veränderungen.

Da der Transformator in Obersielach während der Messkampagne in der Regel nur sehr gering belastet wurde, lassen sich Veränderungen in den Schallemissionen am ehesten für Messpunkte detektieren, an denen der Transformator unter höherer Last betrieben wurde. Abbildung 39 zeigt den Output des Modells für eine Messung mit höherer Last (27%) bei 100 Hz. Die hellroten Voxel zeigen keine Veränderung vom Normalzustand, die gelb bis lila gefärbten beschreiben den Bereich am Transformator, wo Änderungen aufgrund der höheren Belastung bei 100Hz detektiert wurden.




Abbildung 39: Abweichungen vom Normalzustand bei 100Hz für eine Messung bei höherer Belastung.

Ein weiteres Beispiel des entwickelten Modells zeigt Abbildung 40. Hier sind die einzelnen Schritte der Modellierung dargestellt, die analysierte Messung beschreibt 810Hz bei höherer Belastung. Diese Frequenz kann den Lüftern zugeordnet werden, es sind also hauptsächlich Bereiche an den beiden Seiten des Transformators gekennzeichnet. Die linke Abbildung zeigt die aktuelle Messung bei 810 Hz, man erkennt deutlich die eingefärbten Bereiche an den Seiten, wo die Lüfter montiert sind. Die mittlere Abbildung zeigt das Modell des Transformators bei 810 Hz, hier beschreibt jeder Voxel seinen Mittelwert über alle Messungen der Messkampagne. Die rechte Abbildung zeigt nun die Abweichung der aktuellen Messung vom Modell, man erkennt die eingefärbten Bereiche bei den Lüftern, welche die Veränderung darstellen.




Abbildung 40: Die einzelnen Schritte der Veränderungsdetektion anhand einer Messung bei 810 Hz. Links ist die aktuelle Messung zu sehen, in der Mitte das Modell mit Mittelwerten für jeden Voxel, rechts ist die Abweichung der aktuellen Messung vom Normalzustand dargestellt.

Zur Verifizierung des Modells wurde eine Veränderung in den Emissionen des Transformators durch eine zusätzlich aufgestellte Störquelle simuliert. Dazu wurde über einen Lautsprecher, welcher direkt vor dem Transformator aufgestellt wurde, ein weißes Rauschen abgespielt. Dieses sollte sowohl bei den charakteristischen Frequenzen des Transformators als auch dazwischen deutlich erkennbar und detektierbar sein. Abbildung 41 zeigt die Messaufstellung und den dazugehörigen Output des Modells. Das rechte Bild zeigt die Summe über alle Frequenzen.

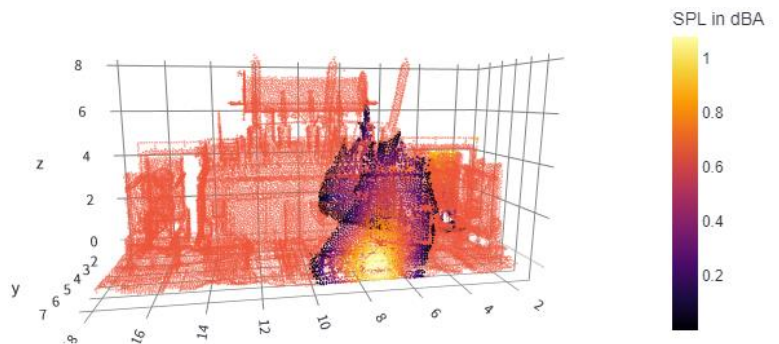



Abbildung 41: Messaufstellung mit Störquelle (links) und Output des Modells zur Veränderungsdetektion für den gesamten Frequenzbereich.

Modellierung von Fehlerzuständen

Vorhersehbare Fehlerfälle treten meistens an den Peripherieanlagen eines Transformators auf. Im Speziellen werden hier die Kühlsysteme untersucht, welche direkt an den Transformator gekoppelt sind. Diese bestehen einerseits aus Pumpen, die die Kühlflüssigkeit über passive Wärmetauscher in einem Kreislauf halten. Andererseits sind auf den Kühlkörpern Ventilatoren angebracht, um den Temperaturaustausch im Bedarfsfall zu erhöhen. Sowohl Pumpen als auch Ventilatoren können fehlerhaft sein bzw. ausfallen, was zu einem Schadensfall am Transformator führen kann. Während der Messungen in Kainachtal konnten die Kühlanlagen eines Transformators akustisch vermessen werden. Dabei wurden die Emissionen des Transformators ohne Kühlanlage, mit aktiven Pumpen aber ohne Ventilatoren, sowie mit aktiven Pumpen und Ventilatoren aufgezeichnet.






Abbildung 42: Vergleich der Emissionen des Transformators für unterschiedliche Konfigurationen des Kühlsystems. Links oben das Spektrogramm der Transformatoremissionen ohne Lüfter und Pumpen. Rechts oben dasselbe Geräusch, wobei die harmonischen Komponenten des Transformatorgeräusches über Filterung entfernt wurden. Links unten die Schallemissionen des Transformators mit Lüfter, ohne harmonische Komponenten. Rechts unten das Geräusch mit Lüfter und Pumpen, ohne harmonische Komponenten.

Abbildung 42 zeigt die Spektrogramme der verschiedenen Zustände des Kühlsystems. Um die Geräusche der Kühlanlage besser zu visualisieren, wurden die harmonischen Komponenten des Transformatorgeräusches durch Filterung entfernt. Das Residual besteht somit hauptsächlich aus den Geräuschen des Kühlsystems. Aus der Abbildung ist deutlich erkennbar, dass die Kühlsysteme zusätzliche breitbandige Komponenten in das Schallfeld des Transformators hinzufügen (links unten in *Abbildung 42*). Das „Rauschen“ nimmt zwischen 200 Hz und 1kHz deutlich zu. Durch die zugeschalteten Pumpen kommen weitere harmonische Komponenten zwischen 700 Hz und 1kHz hinzu (rechts unten in *Abbildung 42*).

Diese Beobachtungen legen nahe, dass die Zustände der Kühlanlage separat modelliert werden können. Über die statistische Modellierung der Spektrogramme ist es möglich, ein System zu trainieren, das die verschiedenen Zustände automatisch erkennen kann. Ein einfaches System wurde im Labor mit einem RandomForest Klassifikator gelernt und validiert.

Da es im Projekt nicht möglich war, Daten von fehlerhaften Kühlanlagen aufzunehmen, muss ein System entwickelt werden, welches aufbauend auf Daten des Normalzustandes der Kühlanlagen Anomalien automatisch erkennt. Dazu wurde der Ansatz der Outlier Exposure Methode verwendet [6]. Dieses Verfahren verwendet einen Auxiliary Classification Task um Fehler oder Ausreißer in den Daten zu erkennen und wurde bereits in ähnlichen Bereichen erfolgreich eingesetzt [7]. Dabei werden alle Zustände, die das System annehmen kann, in einem Klassifizierungsmodell abgebildet. Für die Detektion von Fehlern oder Anomalien wird der Zustand des Systems (hier die Kühlanlage) klassifiziert und mit den Soll-Werten (hier die Leittechnik bzw. SCADA) abgeglichen. Können die Daten nicht erfolgreich abgeglichen werden, d.h. der Output der automatischen Klassifikation stimmt nicht mit dem Wert aus der Leittechnik überein, liegt ein Fehler oder eine Anomalie vor.

Für die Erstellung des Modells wurden die Daten aus der Langzeitmessung in Obersielach verwendet. Bei dem dort vermessenen Transformator besteht die Kühlanlage aus permanent aktiven Pumpen sowie Ventilatoren, welche bei Bedarf automatisch zugeschaltet werden. Da die Messungen in den Wintermonaten (November-Jänner) durchgeführt wurden, konnten keine zusätzlichen Daten mit aktiven Ventilatoren beobachtet werden. Ein Training eines Klassifikationsmodells mit einer aussagekräftigen Evaluierung war daher nicht möglich.

Messung DC-Ströme

Die Messung der DC-Ströme erfolgt über eine bei Siemens Energy entwickelte Software-Applikation. Diese sollte in das X-AMINOR System eingebunden werden und so die Daten der DC-Strom Analyse liefern. Allerdings war es nicht möglich, zur Projektlaufzeit eine robust funktionierende Version dieser Anwendung in das System zu integrieren. Daher muss dieser Teil der akustischen Analyse auf ein Folgeprojekt verschoben werden.

Fazit

Die Ergebnisse der akustischen Analysen durch X-AMINOR sowie die entwickelten Werkzeuge legen nahe, dass die Informationen welche über die akustischen Emissionen des Transformators transportiert werden, für die Bewertung seines Zustandes hilfreich sein können. Jedoch konnten im Projektzeitraum nicht die erforderliche Menge an Daten untersucht werden, die es erlaubt, belastbare Aussagen zu treffen bzw. robuste Modelle zu trainieren. Um valide Aussagen zum Zustand des Transformators anhand seines emittierten Schallfeldes machen zu können, ist ein sehr viel größerer Beobachtungszeitraum notwendig. Der Zustand eines Transformators ändert sich sehr langsam, daher benötigt ein robustes akustisches Zustandsmodell einen Datensatz als Grundlage, der über mehrere Jahre gesammelt wird.

3.3.5 Visuelle Datenaufzeichnung und Diagnostik

Erkennung bekannter Fehler - Erkennung und Segmentierung von Korrosionsflächen

Methodik

In diesem Projekt verwenden wir Deep Learning, insbesondere die YOLO-Architektur, für eine bildbasierte Echtzeit-Erkennung. Verschiedene Datensätze werden auf ihre Effektivität bei der Erkennung von Oberflächenanomalien untersucht, darunter auch open-source Datensätze, die Oberflächenfehler enthalten. Die Bilder werden unter verschiedenen Bedingungen und von verschiedenen visuellen Quellen gesammelt, während Augmentationstechniken angewendet werden, um die Robustheit des Modells zu erhöhen. Zunächst haben wir einige Bilder mit Defekten aus den verschiedenen Klassen kommentiert und diese Daten verwendet, um ein individuelles Training mit dem Yolo-Modell durchzuführen. Die Bounding-Box-Vorhersagen des Yolo-Modells wurden dann als Eingabe für ein weiteres Modell, SAM (Segment Anything Model), verwendet. Das SAM-Modell gibt Segmentierungsmasken innerhalb eines bestimmten Begrenzungsrahmens aus, wobei jedem Pixel in der Maske ein Label zugewiesen wird, das dem Objekt oder der Klasse entspricht, zu der es gehört. Die Ausgabe wird von einem Skript weiterverarbeitet, um binäre Segmentierungsmasken in Annotationen umzuwandeln, die von einem Annotationstool gelesen werden können, in dem die Benutzer mit den vorhandenen Labels interagieren und die annotierten Daten verifizieren oder ändern können. Diese annotierten Daten werden dann zur manuellen Kontrolle durch einen Menschen verwendet und können als zusätzliche Trainingsdaten zur Verbesserung des bestehenden Modells genutzt werden. Die Pipeline ist in *Abbildung 43* dargestellt.

Roadmap of Semi-Auto Annotator

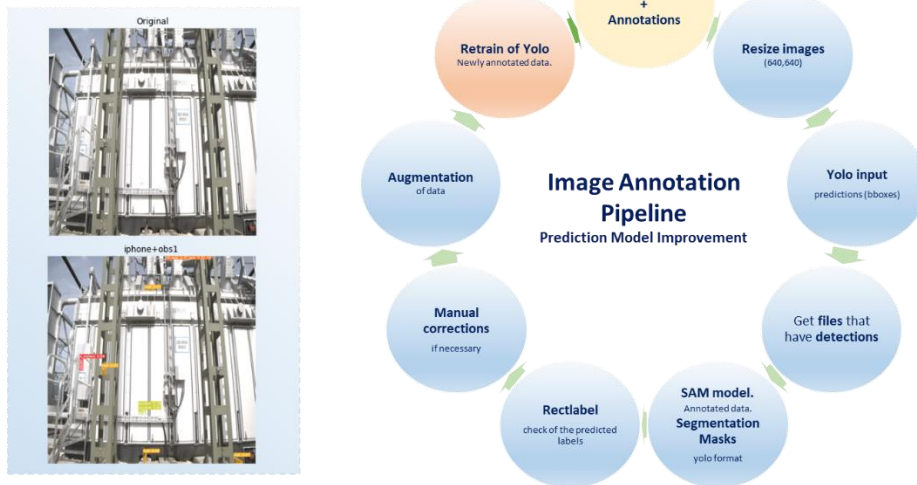


Abbildung 43: Die für das Projekt entwickelte Pipeline zur Bildkommentierung. Auf der linken Seite des Bildes sieht man das Originalbild und darunter die Vorhersagen unserer Architektur bezüglich der Defekte auf den Oberflächen des Transformators. Auf der rechten Seite des Bildes sind die verschiedenen Phasen der Pipeline zu sehen, die zur Erstellung eines Modells verwendet wurden, dessen Zustand kontinuierlich und aktiv verbessert wird.

Custom Model Training

Das YOLO-Modell durchläuft ein Transfer-Learning, z. B. Segmentierung, das die genaue Identifizierung und Segmentierung von Defekten oder Objekten von Interesse, wie z. B. den analogen Zählern, ermöglicht. Das Training beinhaltet eine iterative Optimierung unter Berücksichtigung verschiedener Einflussfaktoren. Die Leistung des Modells wird anhand von Metriken wie mAP, IoU-Schwellenwerte, Recall, Präzision und Verluste streng bewertet.

Custom Model Ergebnisse

Abbildung 44 zeigt die Ergebnisse der Evaluierung des entwickelten Modells. Die linke Abbildung zeigt, dass das Modell in der Lage ist, kategorie-übergreifende Anomalien zu erkennen, wie in Verlust- und Metrikvisualisierungen dargestellt. Die Analyse der Konfusionsmatrix (rechte Seite) zeigt eine starke Leistung bei der Identifizierung spezifischer Fehlerkategorien und gewährleistet Zuverlässigkeit in praktischen Szenarien.

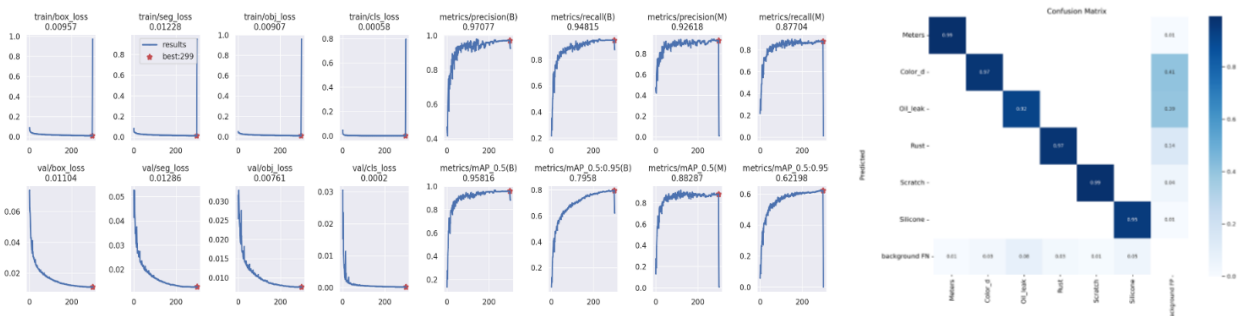


Abbildung 44: Links die Metriken des Modells und rechts die Konfusionsmatrix für einen der leistungsfähigsten Datensätze, die in der Studie zur Vorhersage von Anomalien auf der Oberfläche von Transformatoren als Teil der Pipeline verwendet wurden.

Anwendungen

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Die Effektivität des Modells wird in realen Szenarien validiert, die durchweg eine hohe Genauigkeit seiner Ausgaben aufrechterhalten. Das Experiment begann mit der Erkennung einer einzigen Primärklasse, nämlich Rost. Durch die Ausweitung des Anwendungsbereichs auf zusätzliche Klassen wie "analoge Zähler", "Farberkennung" und "Öllecks" erweist sich das Modell als vielseitig und effektiv bei der Bewältigung eines Spektrums von unterschiedlichen Defekten unter realen Bedingungen. Die Überlagerung von segmentierten Masken auf Bildern von Leistungstransformatoren erhöht die Sichtbarkeit von potenziellen Oberflächenanomalien und hilft bei der proaktiven Wartung, um kostspielige Schäden zu vermeiden (Abbildung 45).




Abbildung 45: Vier Beispielbilder aus einer realen Anlage, die die Identifizierung der sechs Klassen veranschaulichen, wobei jede Farbe für eine Klasse steht. Jedes Bild zeigt eine andere Seite des in unserem Experiment verwendeten Transformators. Die Erkennungen werden zusammen mit der Genauigkeit des Modells visualisiert.

Bestehende Herausforderungen

Die Parameter, die die Vorhersagen des Modells beeinflussen, spielen eine wichtige Rolle, wobei besonders die Notwendigkeit einer sorgfältigen Interpretation auf der Grundlage der Umweltbedingungen und der Bildqualität betont wird. Zukünftige Arbeiten umfassen die Evaluierung des Modells an einem größeren und vielfältigeren Datensatz und die Verbesserung des Modells unter Verwendung der implementierten Semi-Annotation-Pipeline, um durch kontinuierliche Verbesserung größere Robustheit zu erreichen.

Fazit

Hier wurde ein effizienter Ansatz für die Erkennung von Anomalien und die Bewertung von Korrosion auf Transformatoroberflächen vorgestellt, der auf Deep Learning basiert. Die identifizierten Anomalien aus den Modellen können in Bezug auf das erfasste 3D-Modell des spezifischen Transformators beobachtet und lokalisiert werden. Das entwickelte Modell zeichnet sich durch Echtzeitfähigkeit, Anpassungsfähigkeit an unterschiedliche Bedingungen und eine Pipeline für kontinuierliche Verbesserungen aus. Die frühzeitige Erkennung von Defekten und die kontinuierliche Verbesserung des Modells ermöglichen effiziente und rechtzeitige Wartungseingriffe, die die Langlebigkeit und Zuverlässigkeit elektrischer Transformatoren gewährleisten.

Ablesen analoger Messinstrumente

Transformatorwicklungen sind in der Regel in ein Isolieröl getaucht, dessen Temperatur zusammen mit der Temperatur der Wicklungen ein Indikator für die Gesamtbelastung und den Gesundheitszustand des Transformators ist [8-10]. Temperaturmessgeräte können inkonsistente Messwerte anzeigen, z. B. eine niedrigere Höchsttemperatur als die aktuelle Temperatur. Die Inspektoren sind mit der visuellen Überprüfung der Zähler beauftragt, da oft nicht alle Zähler an das Transformatorüberwachungssystem angeschlossen sind. Zum Beispiel sind von den 6 Zählern an unserem Testtransformator im Umspannwerk nur zwei an das SCADA-System angeschlossen (siehe *Abbildung 46*).



Abbildung 46: An das SCADA angeschlossene Zähler: Beide Zähler messen immer ungefähr den gleichen Punkt.

Geräte und Stahlstege, die den Transformator umgeben, können die Sicht auf die Zähler behindern. Aus diesem Grund muss der Roboter in einer gewissen Entfernung positioniert werden, und die aufgenommenen Bilder enthalten die Zähler in kleinen Bildbereichen, was zu geneigten Bildern mit geringer Auflösung führt. Der Zweck unserer Software ist das Auslesen der analogen Zähler aus den besagten niedrig aufgelösten und geneigten Bildern.

Methode

Hier wird die in *Abbildung 47* gezeigte Vision-Based Analog Meter Reading Pipeline (VBAMR-Pipeline) vorgestellt, um die Zählerstände genau abzulesen unter den Bedingungen einer geringen Auflösung und der Neigung aus den aufgenommenen Bildern des Transformators (*Abbildung 47*, Schritt 1).

Vorverarbeitung des Bildes und der Maske

Die analogen Temperaturmesser enthalten zwei Zeiger: einen roten für die Höchsttemperatur und einen weißen für die aktuelle Temperatur. Unter den Bedingungen einer geringen Auflösung und eines ungünstigen Kamerawinkels haben wir eine Reihe von Vorverarbeitungsschritten durchgeführt, die es uns ermöglichen, Masken für die Zeigernadeln zu extrahieren. Die geschätzten Winkel dieser Masken werden später zum Ablesen der gemessenen Temperaturwerte verwendet. Die Vorverarbeitungspipeline, die in *Abbildung 47* unter den Schritten 1 bis 5 aufgeführt ist, lässt sich wie folgt zusammenfassen:

- Homographie: Das zuvor erstellte RGB-LiDAR wird für die Erstellung virtueller Kamerastandorte für jeden der 6 Anzeigen mittels homografischer Bild-zu-Bild-Zuordnung genutzt (*Abbildung 47*, Schritt 2). Dadurch werden die Auswirkungen von Neigungen minimiert und die Genauigkeit verbessert.
- Segmentierung und Bereinigung der Zähler: Entweder mit Hilfe eines fein abgestimmten YOLO-Modells [11] oder manuell (zum Benchmarking unabhängiger Teile der Software) segmentieren wir das Zifferblatt des Messgeräts und entfernen unnötige Elemente wie Referenzaufkleber, die die Segmentierung der Nadelmaske stören können (*Abbildung 47*, Schritt 3).
- Extraktion der Nadelmaske: Zur Segmentierung der Nadelmasken wird ein Farbschwellenwertverfahren zusammen mit einer automatischen Änderung der Farbwertbereiche angewendet, die durch einen iterativen Vergleich der Anzahl der segmentierten Pixel mit der erwarteten durchschnittlichen Pixelzahl der Nadel gesteuert wird (*Abbildung 47*, Schritt 4).
- Ausrichtung der Nadelmaske: Aufgrund kleiner Posenschätzungsfehler verfeinern wir die Ausrichtung der extrahierten Nadelmasken, indem wir ihre Zentren finden und sie auf eine einheitliche Position ausrichten (*Abbildung 47*, Schritt 5). Die Zentrumsfindung erfolgt entweder durch das Segment Anything Model ("SAM"-Methode) oder durch die Ermittlung des Zentrums des begrenzenden Rechtecks ("RECT"-Methode).

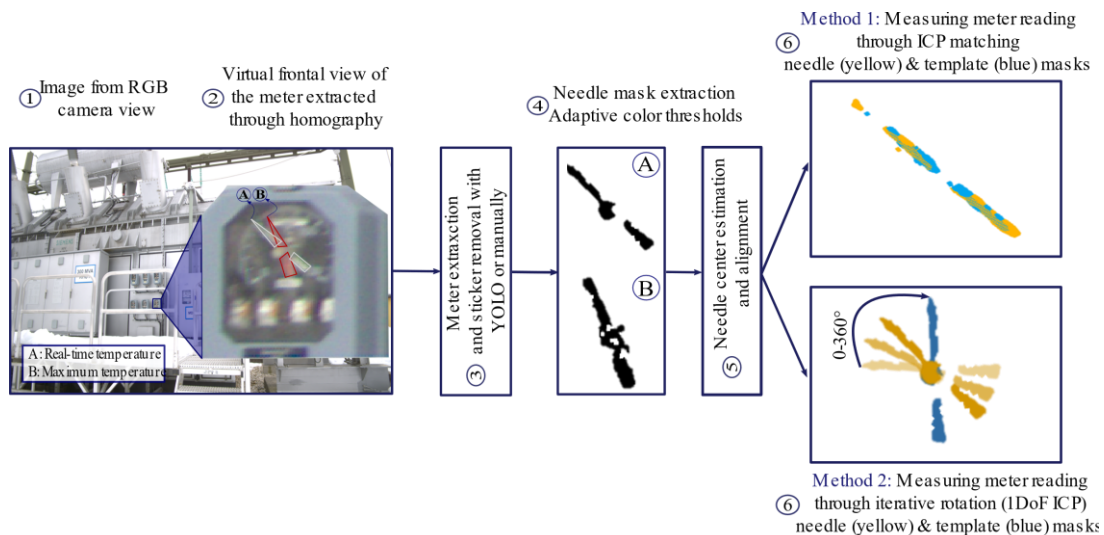


Abbildung 47: Vision-Based Analog Meter Reading Pipeline (VBAMR-Pipeline), Schritte: Homographie, Nadelmasken-

Extraktion, Identifizierung des Nadelzentrums und Messung des Zählerstands durch ICP-Matching.

Ablezen des Wertes der Nadelanzeige

Nach dem Abrufen der Nadelmasken und ihrer Drehpunkte verwenden wir 2 Methoden, um die angezeigten Werte mit Hilfe von Winkelschätzungsalgorithmen zu messen:

Iterative Closest Points: Ein Algorithmus für die Ausrichtung der Nadelmaske mit einer vordefinierten Schablone, deren Ausrichtung bekannt ist (*Abbildung 47*, Schritt 6.1). Er beruht auf dem iterativen Abgleich der entsprechenden Punkte und der Berechnung der starren Transformation, deren Matrix den Drehwinkel zwischen Nadelmaske und Vorlage liefert.

Iterative Closest Points mit einem Freiheitsgrad: Ein eher problemspezifischer Ansatz, der sich auf die reine Suche nach der besten Nadelrotation für das erfasste Bild stützt. Dies wird als iterative Rotationen oder 1DoF ICP bezeichnet. Eine Nadelmaske wird um den geschätzten Zählermittelpunkt gedreht, um jede mögliche Position der Nadel zu testen, wobei eine Bewertungsmetrik die Qualität der Übereinstimmung mit einer Nadelvorlage schätzt (*Abbildung 47*, Schritt 6.2).

Evaluation und Ergebnisse

Die Ergebnisse auf der Grundlage von 66 Messwerten bzw. 132 Stichproben jeder Nadel (aktuelle und maximale Temperatur), die während der ersten Messkampagne des Roboters erfasst wurden, sind in Tabelle 2 dargestellt. Um die Leistung unseres Algorithmus zu bewerten, haben wir die Winkelgrundwahrheit manuell aus den Bildern der virtuellen Vorderansicht des Messgeräts oder den Bildern des Homographiemessgeräts abgerufen.

Tabelle 2 fasst die Genauigkeit unseres Ansatzes für jeden Winkelmessalgorithmus („generic ICP“ und „1DoF ICP“) zusammen. Es werden nur die Ergebnisse der SAM-Methode dargestellt, da sie die besten Ergebnisse lieferte. Einzelheiten über den Leistungsvergleich zwischen den Methoden "SAM" und "RECT" finden sich in [12].

Tabelle 2: Leistungsmetriken der Vision-basierten analogen Zählerablesung: SAM"-Ansatz. Der mittlere absolute Fehler (Mean Absolute Error, MAE) wird als Genauigkeitsmaß für den Nadelwinkel in Grad (°) und die entsprechende Temperatur in Grad Celsius (°C) verwendet. Die Temperaturmesswerte des Messgeräts reichen von 0 bis 150 °C.

	Red needle		White needle	
	generic ICP	1DoF ICP	generic ICP	1DoF ICP
Overall Result, MAE	8.87° (4.90°C)	16.31° (9.01°C)	3.70° (2.23°C)	6.06° (3.39°C)
Inlier Result (error<3σ), MAE	6.04° (3.34°C)	9.07° (5.01°C)	3.32° (1.86°C)	5.05° (2.83°C)
Success Rate	99.12%	97.37%	94.70%	93.18%

Einige Ausreißer beeinträchtigen die Genauigkeit unverhältnismäßig stark. Aus diesem Grund werden die Ergebnisse für Gesamt- und Ausreißerstichproben angegeben. Die Gesamtstichproben enthalten alle Zähler, und die Ausreißerstichproben enthalten diejenigen, die weniger als 3σ von der Grundwahrheit abweichen, wobei σ die Standardabweichung der entsprechenden Methode ist. Wir definieren eine bildverarbeitungs-basierte Ablesung als erfolgreich, wenn ihr Fehler unter 3σ liegt.

Der geringere Fehler, den die Messungen mit der weißen Nadel aufweisen, ist auf sauberere Masken zurückzuführen, die durch die adaptiven Schwellenwerte des Algorithmus entstehen (*Abbildung 47*, Schritt 4). Die Gültigkeit unserer Ergebnisse wird anschließend anhand der verfügbaren SCADA-Messungen für die Zähler 1 und 2 überprüft (siehe *Abbildung 46*). Das 1DoF ICP 'SAM' zeigt für beide Zähler einen geringeren Fehler im Vergleich zu seinem generischen ICP-Gegenstück [12].




Abbildung 48: Zeitreihe, die die von der SCADA erhaltene Ground-Truth im Vergleich zu den von den getesteten Algorithmen erzeugten übereinstimmenden Werten anzeigt. Man beachte, dass die Wiederholungsperiode der SCADA 15 Minuten beträgt, was zu einem Versatz von 7 bis 8 Minuten zwischen den Robotermessungen und den SCADA-Daten führen kann.

Die Zeitreihe der Öltemperatur, die über 1DoF ICP 'SAM', SCADA und manuell beschriftete Daten berechnet wurde (siehe *Abbildung 48*), zeigt den geringen Fehler des Algorithmus für beide Messgeräte, und wir stellen fest, dass unser Algorithmus besser abschneidet als die manuell beschriftete Ground-Truth, die anfällig für menschliche Fehler ist. Dies macht 1DoF ICP 'SAM' zu einer Option für die Nachrüstung oder für den Fall, dass das SCADA System abgeschaltet oder nicht vorhanden ist.

Verbleibende Herausforderungen

Die gesammelte Literatur enthüllt eine Reihe von Entwicklungsmöglichkeiten für die analoge Zählerablesung:

- Das Fehlen eines allumfassenden und von Zählern verschiedenen Datensatzes macht es ziemlich schwierig, Modelle für die Zählererkennung oder -ablesung zu trainieren. Verfügbare Datensätze enthalten selten mehr als 2 oder 3 Zählertypen und weisen einen erheblichen Mangel an Beschriftungen auf.
- Ähnlich wie in [13] soll der implementierte Algorithmus mit anderen Methoden des Stands der Technik für unterschiedliche Bildauflösungen, genauer gesagt, Abtastabstände auf der Oberfläche des Zählers, verglichen werden.

Unser Ziel ist es, die Lösung so zu verbessern, dass der Benutzer den Algorithmus für das Auslesen anderer Zählertypen und -modelle konfigurieren kann. Der Benutzer kann einige Beispielbilder verwenden, um den neuen Zählertyp in die besagte Lösung zu integrieren.

Fazit

Die vorgestellte visuelle Diagnostik von Analoggeräten wurde mit zwei Hauptzielen entwickelt: (1) die Bereitstellung neuer Fähigkeiten zur automatischen visuellen Inspektion des Transformators und (2) die Umrüstung alter Geräte, damit sie digitalisiert werden können, ohne die vorhandene Hardware zu ändern. Durch die Verwendung von Vorverarbeitung (Homographie-Meter-Segmentierung-Maskenextraktion-Maskenausrichtung), ICP (generisch und 1DoF) und durch den Vergleich mit sowohl manuell gekennzeichneten als auch SCADA-basierten Daten haben wir einen geeigneten Algorithmus für die visuelle Messwertablesung für die X-AMINOR-Roboterplattform entwickelt.

1DoF ICP "SAM" wird als die bevorzugte Lesemethode für zukünftige Messkampagnen übernommen, und wir beabsichtigen, sie durch die Erweiterung auf verschiedene Messgerätetypen weiterzuentwickeln. Die Auflösung wird auch ein wichtiges Thema unserer zukünftigen Forschung sein, und wir beabsichtigen, ihre Auswirkungen sowohl auf die Messwertablesung als auch auf andere visionäre Algorithmen zu bewerten.

Erkennung unbekannter Fehler

In den vorangegangenen Abschnitten wurde über Erfolge bei bestimmten Prüfkriterien berichtet. Die Vielfalt der Defekte ist jedoch groß und es ist oft schwierig, Stichprobendaten für sie zu sammeln. Im Gegensatz zu einer solchen automatischen überwachten Inspektion und als Vereinfachung der manuellen Inspektion, wird das Paradigma der automatischen Veränderungserkennung betrachtet. Die Idee ist, dass ein Roboter regelmäßig Inspektionsfahrten durchführt, wiederholt Bilder von ungefähr denselben Blickpunkten aufnimmt und ein automatisiertes System das jüngste Erscheinungsbild mit früheren Beobachtungen vergleicht. Bei diesem Vergleich müssen Variationen des Blickwinkels, der Beleuchtung und saisonale Veränderungen ignoriert werden, während relevante Veränderungen für eine manuelle Überarbeitung gemeldet werden sollten. Zusätzliche Defekte, die bei der Entwicklung automatischer Inspektionswerkzeuge nicht vorhergesehen wurden, können dann identifiziert und für die künftige Entwicklung genutzt werden, während gleichzeitig unveränderte Bereiche automatisch gefiltert werden und der gesamte manuelle Inspektionsaufwand reduziert wird.

State-of-the-Art

In der Literatur gibt es eine Vielzahl von Forschungsarbeiten zur Erkennung von Veränderungen. Eine Reihe von Arbeiten wie [14] gehen von einer statischen Kamera aus und konzentrieren sich auf die Erkennung relevanter bzw. irrelevanter Veränderungen, was für einen mobilen Inspektionsroboter, der einen viel größeren Bereich abdeckt, aber bei den sich wiederholenden Fahrten nicht genau denselben Blickpunkt aufsuchen kann, nicht gut geeignet ist. Andere Arbeiten, wie z. B. die in [15] zusammengefassten, stützen sich überwiegend oder ausschließlich auf 3D-Daten, womit sie weitgehend die Blickpunkt-Invarianz liefern, aber nicht in der Lage sind, Veränderungen der Oberflächenstruktur, wie Öllecks oder Rost, zu erkennen. Eine andere Forschungsrichtung, zu der auch [16] gehört, reduziert die Erkennung von Veränderungen auf die Objektdetektion in Einzelbildern und den Abgleich von Detektionen im Zeitverlauf, was wiederum nur eine Teilmenge der Veränderungen abdeckt, die für Inspektionsaufgaben relevant sind.

Unter den Methoden, die sich für ein mobiles Inspektionssystem eignen, gibt es zwei Hauptlinien von Arbeiten. Methoden wie [17,18] sagen Segmentierungsmasken für die Veränderungen voraus, die eine pixelweise Identifizierung von hinzugefügten, entfernten und veränderten Objekten ermöglichen. Das Training und das Feintuning solcher Methoden erfordern pixelweise Annotationen, deren Erstellung zeitaufwendig und fehleranfällig ist. Zur Bewältigung des Annotationsaufwands schlagen die Arbeiten in [19,20] einen Weg zur automatischen Generierung eines Veränderungsdatensatzes aus Objekterkennungsdatensätzen und eine Methode zur Vorhersage von Bounding Boxes um die veränderten Bereiche in Bildpaaren vor.

Die folgenden Abschnitte konzentrieren sich auf die Evaluierung der Veränderungserkennungsmethode von [19] in der durch X-AMINOR definierten Anwendung. Anschließend werden offene Fragen und Ideen für weitere Arbeiten diskutiert.

Evaluation

Zur Evaluierung der Bounding-Box-basierten Veränderungserkennungsansätze in einem realistischen Anwendungsszenario wurde einen Datensatz aufgenommen. Qualitative und quantitative Auswertungen folgen, außerdem wird kurz über Experimente zum Feintuning eines generischen Ansatzes zur Erkennung von Veränderungen auf unseren Datensatz berichtet. Wie bei der quantitativen Bewertung und dem Feintuning erörtert wird, gibt es mehrere Nachteile, die sich aus der Verwendung von Bounding Boxes ergeben.

Datensatz

Um einen aussagekräftigen Datensatz zu erhalten, wurde ein Umspannwerk mit sechs verschiedenen Stromtransformatoren über den Zeitraum eines Jahres mehrmals besucht. Die Bilder wurden mit verschiedenen tragbaren Handykameras aufgenommen. Aus diesen Daten wurden 295 Bildpaare ausgewählt, die in etwa denselben Inhalt zeigen. Aufgrund der Aufnahmebedingungen werden keine zwei Bilder von genau demselben Standpunkt aus aufgenommen, und Veränderungen aufgrund von Bewegungen und Kameracharakteristika sind in dem Datensatz allgegenwärtig. Von allen Paaren zeigen 199 außerdem unterschiedliche Inhalte wie symmetrische oder sich wiederholende Teile desselben Transformators oder übereinstimmende Teile von fast identischen Transformatoren. Hier sind weitere Veränderungen zu erwarten, die auf unterschiedliche Alterungsmerkmale, leichte Bauabweichungen oder unterschiedliche Hintergründe zurückzuführen sind. Weitere 96 Paare zeigen den gleichen Inhalt zu verschiedenen Zeiten, wobei die meisten von ihnen Veränderungen aufgrund von hinzugefügten oder entfernten Teilen, Zifferblättern und analogen Anzeigen, gedrehten Schrauben oder Verwitterungseffekten aufweisen. Von den insgesamt 295 Paaren wurden bei 125 Paaren beide Bilder am selben Tag aufgenommen, während sie bei 170 Paaren an verschiedenen Tagen aufgenommen wurden. Zwischen den Aufnahmesitzungen gibt es jahreszeitliche Veränderungen, in einigen Fällen einschließlich Schneebedeckung sowie Veränderungen in der Vegetation, aber auch wetterbedingte Veränderungen und Änderungen in der Beleuchtung. Beispiele für den Datensatz und die festgestellten Veränderungen sind in *Abbildung 49* dargestellt.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG



Abbildung 49: Beispiele für automatisch erkannte Veränderungen im Datensatz für Leistungstransformatoren. Wie im Text beschrieben, zeigen diese Beispiele ein passendes Paar fast identischer Leistungstransformatoren (ganz oben), einen symmetrischen Teil desselben Transformators (zweites von oben), und zwei Stellen, die zu zwei verschiedenen Zeiten überprüft wurden (unten).

Qualitative Auswertung

Für eine erste qualitative Bewertung der Leistung aktueller Methoden zur Erkennung von Veränderungen in unserem industriellen Anwendungsszenario wird das vortrainierte Modell aus [19] auf unseren Datensatz angewendet. Beispielhafte Ergebnisse sind in *Abbildung 49* dargestellt. Obwohl einige Fehlalarme auftreten, zeigen die meisten der hervorgehobenen Bildbereiche eindeutig tatsächliche Veränderungen in den Bildern. Die offensichtlichen Fässer, die in zwei Beispielen hinzugefügt und entfernt wurden, werden durch den evaluierten Ansatz gut erkannt. Im dritten Beispiel

wurden einige Schrauben identifiziert, die zwischen den beiden Besuchen eingedreht wurden, was ein menschlicher Betrachter kaum erkannt hätte. Insgesamt scheint der Ansatz recht empfindlich oder sogar überempfindlich zu sein, aber die Ergebnisse scheinen plausibel und hilfreich zu sein, um die tatsächlichen Veränderungen in großen Datensätzen zu bestimmen.

Tabelle 3: Übersicht über annotierte Boxpaare.

Klasse	Anzahl
Hinzugefügter Inhalt	236
Hinzugefügter Inhalt (Parallaxe)	34
Veränderung	511
Verschiebung	11
Entfernter Inhalt	270
Entfernter Inhalt (Parallaxe)	39
Oberflächenveränderung	586
Saisonale Veränderung (Schnee, ...)	47
Änderung in der Beleuchtung	180
Änderung in der Vegetation	43
Insgesamt	1957

Quantitative Auswertung

Um unseren Datensatz quantitativ auswerten zu können, wurden die Bildpaare mit entsprechenden Bounding Boxes annotiert. Dabei wurden die in *Tabelle 3* gezeigten Klassen verwendet, um die annotierten Boxen zu spezifizieren und zu filtern, z.B. für Veränderungen aufgrund von Parallaxe, die Methoden mit 3D-Szenenbewusstsein erfordern [20]. Während der Annotation und auch bei der qualitativen Auswertung wird deutlich, dass eine objektive Auswertung der Erkennungsleistung von Veränderungserkennung, die ausschließlich auf 2D Bounding Boxen basiert, schwierig ist. Im Einzelnen können drei Herausforderungen für automatische Auswertungen identifiziert werden: a) fehlende Korrespondenzen, b) mehrdeutige Boxgrößen und c) mehrdeutige Anzahl von Boxen.

a) Fehlende Korrespondenzen

Die Methode in [19] soll zwar übereinstimmende Paare von Boxen erkennen, aber nicht alle entsprechenden Boxen werden immer in beiden Bildern identifiziert. Da in der Praxis ohnehin ein menschlicher Bediener die Ergebnisse der Veränderungserkennung überwachen muss, wird das Bewertungskriterium dahingehend geändert, dass eine Veränderung als erkannt gilt, wenn sie in mindestens einem Bild eines Paares identifiziert wird.

b) Mehrdeutige Boxgrößen

Es ist auch festzustellen, dass die Größe der erkannten Bounding Boxes stark variiert und die Bestimmung des genauen Ausmaßes einer Veränderung oft nicht eindeutig ist. Um dies in den Bewertungskriterien widerzuspiegeln, wird der erforderliche Intersection-over-Union Schwellwert auf 0,1 gesetzt.

c) Mehrdeutige Anzahl von Boxen

Schließlich ist festzustellen, dass größere Veränderungen manchmal als mehrere kleinere Boxen erkannt werden oder umgekehrt. Ein Beispiel dafür ist auch in *Abbildung 49* unten zu sehen. Abhängig von der Annotation werden solche Fälle als mehrfache Falsch-Positive oder -Negative gewertet, und es ist nicht klar, wie solche Situationen gehandhabt werden können, wenn nur Bounding-Box-Annotationen gegeben sind.

Aus diesen Gründen ist die typische Bewertung mit der Metrik Average Precision (AP) notwendigerweise in ihrer Genauigkeit eingeschränkt. Die Ergebnisse, die mit verschiedenen Einstellungen erzielt werden, sind in Table 3 dargestellt. Dabei wurde mit verschiedenen Auflösungen experimentiert, indem das Fully-Convolutional-Backbone des Netzes auf 512x512 skaliert wurde, das Doppelte der Trainingsauflösung. Dabei zeigt es sich aber, dass die Leistung abnimmt, was auf die Tendenz zurückzuführen ist, große Veränderungen als mehrere kleinere Boxen zu erkennen. Auch die 3D-fähige Methode von [20] wurde intern evaluiert. Es zeigte sich jedoch, dass diese im Allgemeinen schlechter abschneidet, vermutlich, weil die Tiefenvorhersagen nicht auf unsere Industrieszenen abgestimmt sind.

Tabelle 4: Evaluationsergebnisse hinsichtlich Average Precision (AP) für verschiedene Einstellungen.

	256x256	512x512
Vortrainiert	16.70	9.59
Finetuning	14.07	6.89

Finetuning

Um das vortrainierte Netzwerk an den spezifischen Annotationsstil im vorliegenden Datensatz anzupassen, wurde ein Finetuning durchgeführt. Für das Finetuning wurden 232 Bildpaare von vier Transformatoren und für die Auswertung 63 Bildpaare von zwei weiteren Transformatoren verwendet. Die Ergebnisse sind ebenfalls in Table 3 dargestellt. Es zeigt sich, dass das Modell sich zu stark an die Trainingsdaten anpasst (overfitting), was zu einer leichten Verringerung der Leistung in der Auswertungsmenge führt. Dies ist auf den relativ kleinen Trainingsdatensatz und die Deaktivierung der meisten geometrischen Transformationen bei der Datenaugmentierung zurückzuführen. Das ursprüngliche Training verwendet Instanzsegmentierungsmasken und kann daher auch affine und perspektivische Transformationen zur Datenaugmentierung verwenden. Da für unseren Datensatz jedoch nur Bounding-Box-Annotationen verfügbar sind, können solche Transformationen nicht durchgeführt werden.

Schlussfolgerungen

Veränderungserkennung stellt eine ergänzende Strategie zu gezielten Prüfroutinen dar, die auf überwachte Weise trainiert und generiert werden. Der grundsätzlich orthogonale Ansatz der Veränderungserkennung ermöglicht es im Rahmen einer automatisierten Inspektion, Defekte zu identifizieren, die nicht vorhergesehen und trainiert wurden, und somit den typischen Mangel an Trainingsdaten für echte Defekte zu umgehen. Die Herausforderungen der Blickwinkel- und Beleuchtungsinvarianz wurden in der jüngsten Forschung angegangen, und unsere qualitativen Auswertungen zeigen, dass hochrelevante Veränderungen mit der evaluierten Methode zuverlässig erkannt werden.

Eine quantitative Bewertung sowie Training und Finetuning bleiben jedoch eine Herausforderung. Während arbeitsintensive und fehleranfällige pixelweise Annotationen in neueren Arbeiten nicht unbedingt erforderlich sind, sind Annotationen mit Bounding Boxen nur von begrenztem Wert. Bei der Auswertung stellt die Mehrdeutigkeit in der Annotation einer Veränderung mit mehreren kleineren Boxen oder weniger größeren Boxen eine Herausforderung für die traditionellen Bewertungskriterien dar. Auch für das Training bleibt die Datenaugmentierung ohne pixelweise Annotationen eine Herausforderung.

3.3.6 Framework

Einleitung

Zu den Anforderungen an die Plattform gehören die Unterstützung einer Flotte von Clients, die Verwaltung der Clients, die Remote-Bereitstellung von Anwendungen, die schnelle Entwicklung von Anwendungen, die sichere Kommunikation zwischen dem Client und dem Backend, der effiziente Datenfluss und die Handhabung innerhalb des Backends, die Erweiterbarkeit des Backend-Systems und eine cloudbasierte Entwicklungsumgebung.

Client Management

Auf dem Roboter laufen ROS2 (Robot Operating System) basierte Anwendungen. Über den ROS-Bus können Anwendungen miteinander kommunizieren und sind funktional modular erweiterbar. Die Client-Management-Plattform ist für die Verwaltung der Clients über ein Web-Interface zuständig. Über eine REST-API können neue Anwendungen remote auf den Clients deployed werden. Eine Datenbank im Backend speichert die Informationen über die Clients und deren aktuell installierte Anwendungen und Hardware. Der Client stellt ROS2-Anwendungen in Docker-Containern bereit, die aus der Ferne von einer privaten Docker-Registry abgerufen werden.

Backend

Das Backend ist in zwei Teile unterteilt. Der anfängliche Dateneingabepunkt, der mit dem Client kommuniziert, ist durch eine DMZ (demilitarisierte Zone) vom Teil der Datenverarbeitung und -speicherung getrennt. Der Roboter kommuniziert nur mit einem MQTT-Server innerhalb der DMZ. Dadurch wird sichergestellt, dass der Client nicht auf gespeicherte Daten aus dem Backend zugreifen kann. Dies entspricht der Empfehlung des National Institute of Standards and Technology (NIST) Cybersecurity Framework.⁷

⁷ Joint Task Force Interagency Working Group, "Security and privacy controls for information systems and organizations (revision 5)," *National Institute of Standards and Technology*.
<https://doi.org/10.6028/NIST.SP.800-53r5>

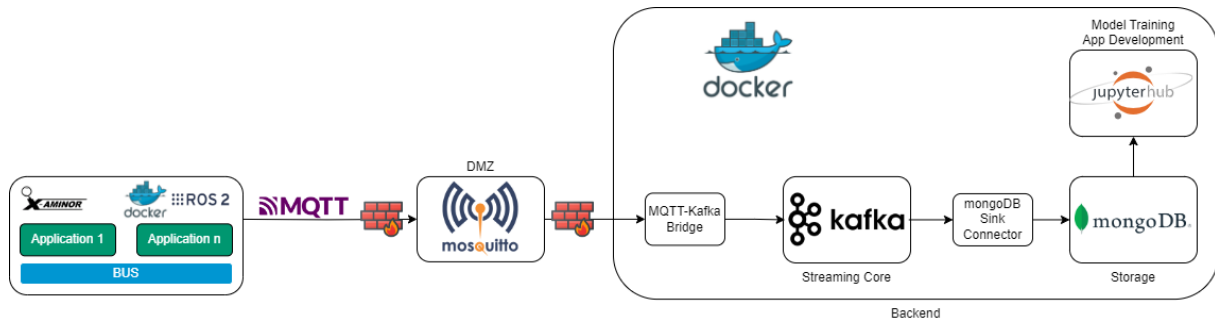


Abbildung 50: Diagramm der Softwareplattform mit Darstellung der DMZ-Struktur.

Der MQTT-Server leitet die empfangenen Daten aus der DMZ an Apache Kafka im Backend weiter. Kafka fungiert als Puffer, um die Daten an mehrere Backend-Dienste zu verteilen. MongoDB wird für die dauerhafte Speicherung der Daten verwendet. MongoDB erlaubt die Speicherung der Daten in BSON (binary JSON), was es ermöglicht, z.B. Bild- und Audiodaten in die Dateneingabe aufzunehmen. MongoDB erlaubt jedoch nur die Speicherung von Daten bis zu 16 MB. Für größere Daten, z. B. Videodaten, werden die Daten in MongoDBs GridFS gespeichert. GridFS speichert die Binärdaten in einer separaten Sammlung, die in der Hauptsammlung referenziert wird. Auf diese Weise lassen sich Daten beliebiger Größe speichern. Ein weiterer Vorteil von MongoDB ist die Möglichkeit der effizienten Speicherung von Zeitreihendaten für kleine Aktualisierungsnachrichten vom Client. Das Backend basiert auf mehreren Docker-Containern, die in Docker-Compose-Dateien definiert sind. Zusätzlich zur Datenspeicherung enthält das Backend einen JupyterHub-Server, der es ermöglicht, mit den gesammelten Daten direkt auf dem Server zu arbeiten, anstatt die Daten lokal herunterzuladen. Kafka ermöglicht den Zugriff auf alle neu eingehenden Daten, ohne dass das bestehende System verändert werden muss, was beispielsweise die Erweiterung des Backends um ein produktives maschinelles Lernmodell ermöglicht.

Software Plattform Implementierung

Der Backend-Teil, einschließlich der DMZ, war während der Projektlaufzeit vollständig implementiert und einsatzbereit, jedoch führten geänderte Spezifikationen der Kundendaten zu einer Änderung der Backend-Architektur. Darüber hinaus wurde die Client-Management-Plattform während der Projektlaufzeit teilweise implementiert und umgestaltet. Die endgültige Implementierung der Plattform wird in den folgenden Abschnitten beschrieben.

Easy App Entwicklung

Ein funktionierender Prototyp der Client-Verwaltungsplattform wurde unter Verwendung einer REST-API für die Fernverwaltung von Clients implementiert. Der Entwurf umfasst eine ROS2-Vorlagenknotenanzugung für die Entwicklung neuer Anwendungen. Geänderte Anforderungen für die Ausführung von Anwendungen auf dem Client führten jedoch zu einer Neugestaltung des Client-Verwaltungs- und Einsatzsystems. Der ursprüngliche Prototyp wurde verworfen und ein neuer, ausgefeilterer Ansatz mit GitLab-Runnern und Kubernetes entwickelt.

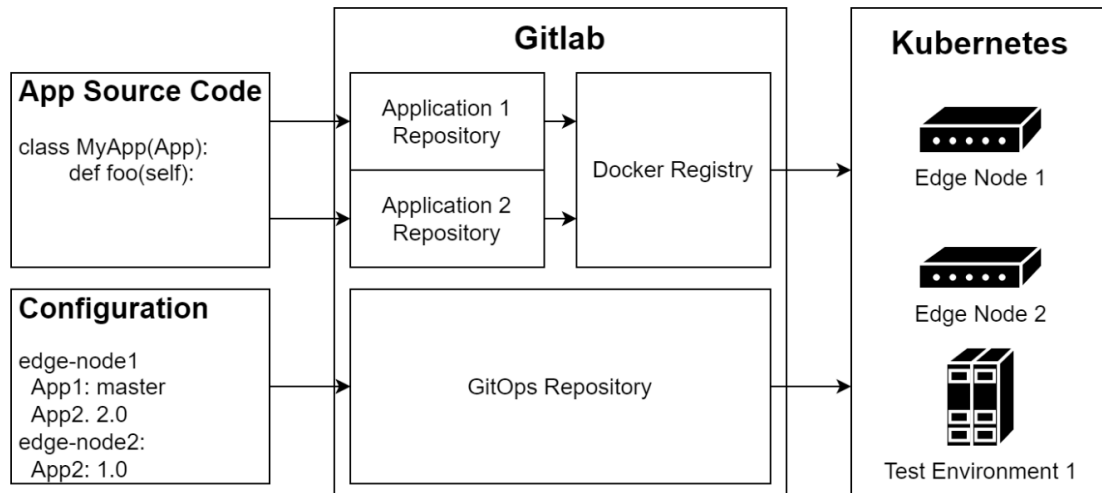


Abbildung 51: Framework für Entwicklung und Deployment

Das neue Design bietet eine Unterstützungsbibliothek für die Entwicklung neuer Anwendungen, ohne dass der Entwickler mit dem zugrunde liegenden ROS2-System vertraut sein muss. Ein Python-Framework bietet eine einfache Handhabung von Nachrichtenveröffentlichungen und -abonnements mithilfe von Decorators. Eine optimierte Entwicklungsumgebung, die den Entwicklungscontainer von Visual Studio Code nutzt, ermöglicht es neuen Entwicklern, mit der Entwicklung neuer Anwendungen zu beginnen, ohne dass sie Softwareabhängigkeiten auf ihrem lokalen Rechner installieren müssen. Mit diesem schlanken Ansatz ist eine Microservice-Architektur für alle ROS2-Anwendungen möglich. Um den Bereitstellungsprozess auf den Clients zu automatisieren, wird ein GitLab Kubernetes-Runner verwendet. Eine benutzerdefinierte Spezifikationskonfiguration ermöglicht eine Änderung der Deployment-Konfiguration über die Anzahl der Clients und deren jeweils installierten Anwendungen. Dieser Ansatz der kontinuierlichen Integration von GitLab stellt sicher, dass alle Anwendungen auf dem neuesten Stand gehalten werden. Zusätzlich wird für die kontinuierliche Integration der Clients ein Test-Runner für die automatische Ausführung von Unit-Tests und Code-Linting der entwickelten Anwendungen hinzugefügt.

Backend

Wie schon vorab beschrieben, wurde das Backend mit Docker-Containern implementiert. Das gesamte System ist in zwei Docker-Kompositionsdateien aufgeteilt. Diese Trennung ermöglicht die Bereitstellung der DMZ und des Backends auf zwei separaten Servern. Die anfängliche Implementierung konzentrierte sich auf den Empfang von primär kleinen Datennachrichten vom Client, ermöglichte aber gleichzeitig große Datennachrichten unter Verwendung des GridFS von MongoDB. Diese Anforderung änderte sich zu einem eher objektorientierten Ansatz, was zu einem Redesign des Backends führte. Die ursprüngliche Implementierung umfasste eine DMZ, die später aufgrund der veränderten Anforderungen verworfen wurde. Die endgültige Implementierung des Backends wird in den folgenden Abschnitten beschrieben.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

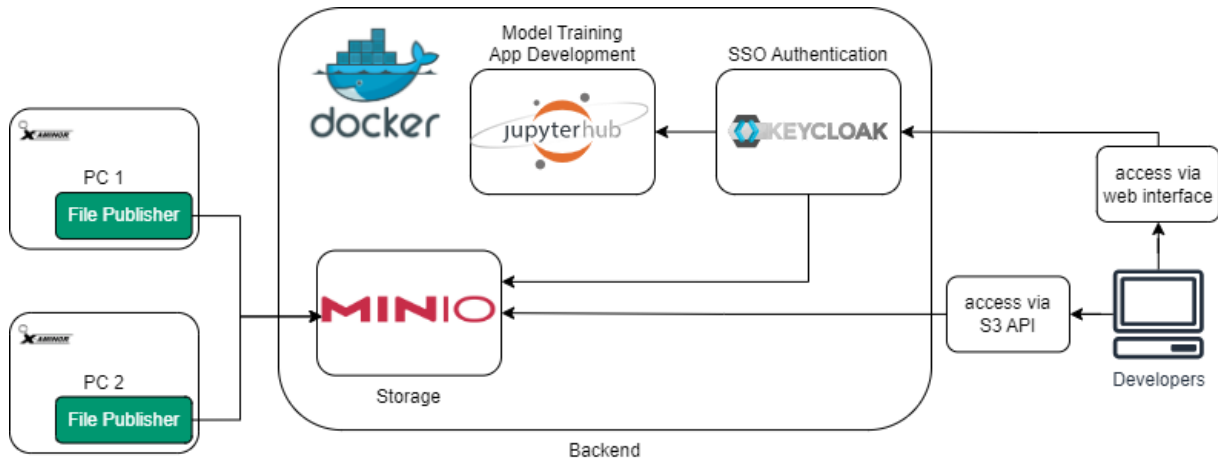


Abbildung 52: Neues Software Plattform Design.

Die Arbeit mit MongoDB für Primärdateien erwies sich als weniger benutzerfreundlich als gewünscht. Um MongoDB als primären Datenspeicher zu ersetzen, wurde MinIO gewählt. MinIO ist ein AWS S3-kompatibler Objektspeicher, der die Speicherung von Dateien mit Versionskontrolle und detaillierten Zugriffsberechtigungen ermöglicht. Über die mitgelieferte Weboberfläche können die Benutzer einfach auf die gespeicherten Daten zugreifen. Das S3-Protokoll ermöglicht eine breite Kompatibilität mit anderen Anwendungen. Mit MinIO entfällt die Notwendigkeit einer DMZ mit einem MQTT-Server. Die S3-API ermöglicht den direkten und sicheren Upload von Dateien in den Speicher über verschlüsseltes HTTPS.

Um die Benutzerverwaltung und -authentifizierung zu vereinfachen, wurde Keycloak zum Backend hinzugefügt. Keycloak ist eine Open-Source-Lösung für das Identitäts- und Zugriffsmanagement. Keycloak ermöglicht die Verwaltung von Benutzern und deren Zugriff auf die Backend-Dienste. Die Benutzerverwaltung erfolgt über ein Webinterface, das es erlaubt, neue Benutzer anzulegen und sie Gruppen zuzuordnen. Die Keycloak-Authentifizierung ist in MinIO und JupyterHub integriert. Dies ermöglicht den Zugriff auf die Dienste mit denselben Anmeldedaten und SSO (Single Sign-On) zwischen den Diensten.

Client Software

Die Software zur Datenerfassung und –vorverarbeitung auf den Clients (i.e. Roboterplattform) wurde mit Python implementiert. Da mehrere Rechner mit unterschiedlichen Betriebssystemen und Softwareframeworks zum Einsatz kamen, konnte in Python mithilfe von ROS und MQTT Schnittstellen ein Prozess abgebildet werden, der die zeitabhängige Verarbeitung der verschiedenen Daten steuert und die Kommunikation mit dem Backend übernimmt.

Abbildung 53 zeigt die Architektur und den Ablauf der entwickelten Software. Damit war es möglich, die Applikation zur Navigation des Roboters mit den Messroutinen zu integrieren. Die unterschiedlichen Komponenten der Software kommunizieren mittels ROS und MQTT Nachrichten miteinander, auch die Daten werden über die MQTT Schnittstelle zur Verfügung gestellt. Nach Beendigung einer Messfahrt, bestehend aus mehreren Einzelmessungen, werden die Daten gesammelt in das Backend verschoben.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

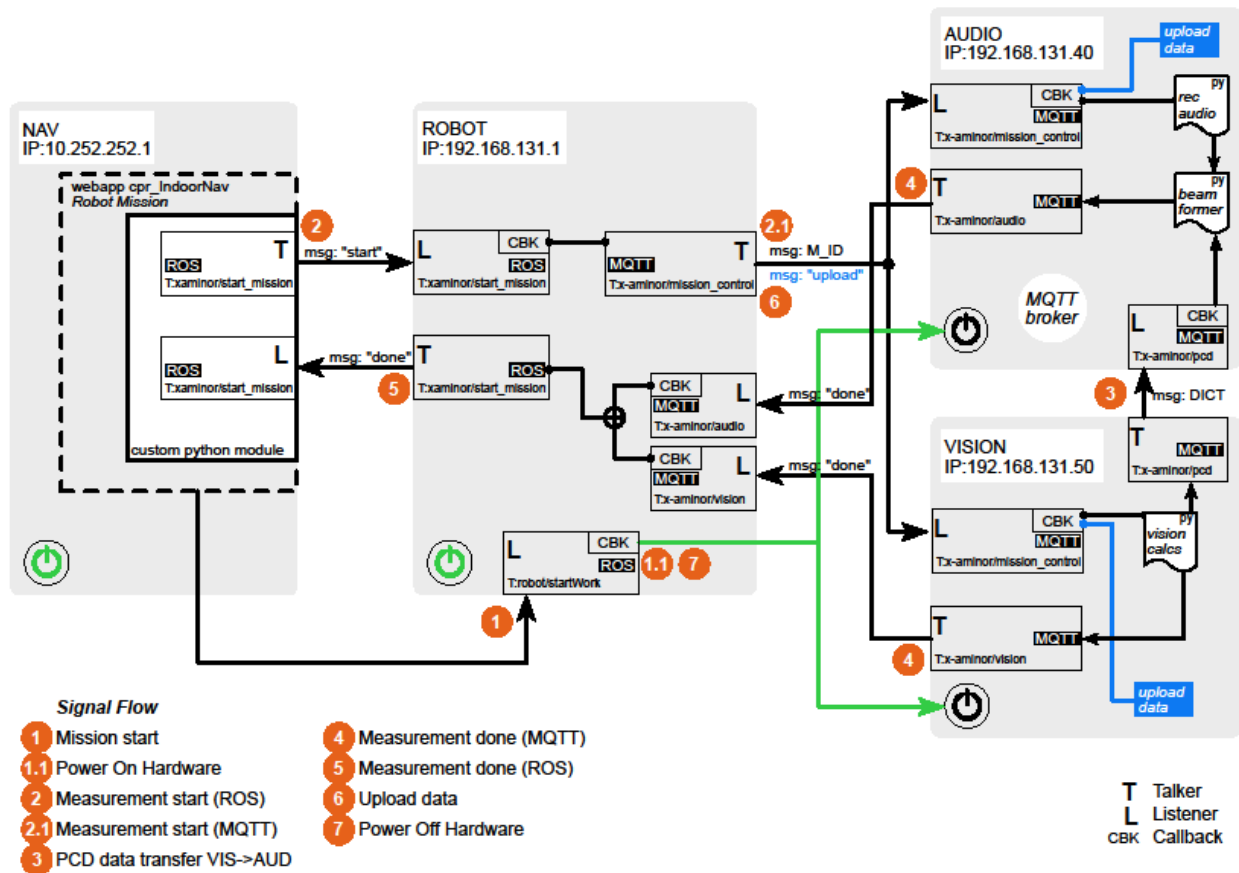


Abbildung 53: Architektur und Ablauf der Software auf den Clients.

Automatisches PDF Reporting

Wenn die Client-Anwendungen laufen und Daten an das Backend senden, besteht der nächste Schritt darin, die Daten in ein für den Menschen lesbares Format zu bringen. Die folgende Testpipeline wurde implementiert, um die Datenverarbeitung und Berichterstattung zu testen.

Ein Skript lädt die erforderlichen Daten von MinIO über die S3-API herunter und startet die entsprechenden maschinellen Lernmodelle, um beispielsweise die visuell basierte Rosterkennung auszuführen. Die 2-dimensionalen Daten werden dann auf die 3-dimensionale Referenzpunktswolke des Transformators abgebildet. Mit Cloud Compare werden die Ergebnisse visualisiert, z. B. 3-dimensionale Punkte, an denen Rost erkannt wurde. Solche Erkennungen können in einer Erkennungsdatenbank gespeichert werden, die nur "konsolidierte", d. h. wiederholte, Erkennungen enthält. Dies geschieht durch den Vergleich der Ergebnisse mit früheren Inspektionsrunden des Roboters. Das resultierende Bild mit der Erkennung wird dann wieder in den MinIO-Speicher hochgeladen.

Da alle erforderlichen Berichtsdaten in MinIO verfügbar sind, wird automatisch ein PDF-Bericht mit allen Informationen erstellt. Dazu wird ein LaTeX-basierter Ansatz verwendet. Es wurde eine LaTeX-Vorlage erstellt, die mit den erforderlichen Daten gefüllt, und zu einem PDF-Bericht kompiliert wird. Die Kompilierung des LaTeX-Dokuments erfolgt mit Hilfe eines Docker-Containers, der es ermöglicht, das Dokument zu kompilieren, ohne LaTeX manuell installieren zu müssen.

Integrationstests Gesamtsystem

Die Backend-Plattform wird auf einem Server bei Pro2Future gehostet. Der Client-Roboter kann mit dem Server über die S3-API kommunizieren. Benutzer können sich mit ihren Keycloak-Zugangsdaten am System anmelden. Daten können über die MinIO-Webschnittstelle hoch- und heruntergeladen werden. Der JupyterHub-Server ermöglicht die Arbeit mit den Daten direkt auf dem Server.

Die Verwendung von Keycloak erwies sich als eine gute Wahl für die Fehlersuche. Bei den Benutzern traten Probleme mit den MinIO-Berechtigungen auf, aber mit Keycloak konnte sich ein Administrator bei Keycloak anmelden, um sich als ein beliebiges Konto auszugeben und das Problem zu beheben, ohne dass sensible Anmeldedaten preisgegeben wurden.

Insgesamt konnten alle am Projekt beteiligten Parteien mit der S3-API arbeiten, um auf den Datenspeicher zuzugreifen. Jeder Benutzer kann bei Bedarf seine eigenen S3-Zugangsschlüssel mit benutzerdefinierten Berechtigungen erstellen. Außerdem sind zwei gemeinsame Zugriffsschlüssel für alle Benutzer vorgegeben. Einer erlaubt dem Client nur den Schreibzugriff, der andere bietet nur Leseberechtigung. Der Nur-Lese-Schlüssel wird in einer Cyberduck-Konfigurationsdatei angegeben. Cyberduck ermöglicht die Interaktion mit dem S3-Speicher über eine grafische Schnittstelle. Der Hauptunterschied zur MinIO-Weboberfläche besteht in der Möglichkeit, mehrere Dateien für Massendownloads per Drag & Drop zu übertragen.

3.4 Messungen

Das im Projekt entwickelte Monitoringsystem für Großtransformatoren soll in verschiedenen Szenarien getestet und evaluiert werden. Dabei werden in einem ersten Schritt die Kriterien für die Durchführung einer aussagekräftigen Evaluierung definiert sowie die Szenarien, in denen das System evaluiert werden soll, festgelegt. In einem zweiten Schritt wird die Durchführung der Evaluation begutachtet und darauf relevante Einflussfaktoren beschrieben. Im letzten Schritt wird das System mithilfe der Erkenntnisse aus den unterschiedlichen Szenarien qualitativ evaluiert.

3.4.1 Szenario Vorbereitung Evaluierung

Als erster Schritt werden die Rahmenbedingungen definiert, welche Voraussetzung für eine aussagekräftige Evaluierung in verschiedenen Testumgebungen sind. Dabei wurden folgende Punkte definiert:

- **Homogenes technisches System und Funktionalität:** Die verschiedenen Szenarien dürfen keine Änderungen auf technischer Systemebene notwendig machen. Die Evaluierungen sollen mit derselben Sensorik und Analysemethoden durchgeführt werden können, auch wenn unterschiedliche Ergebnisse zu erwarten sind. Dadurch wird Kontinuität und Vergleichbarkeit der Daten für eine quantitative und qualitative Evaluation gewährleistet.
- **Ungestörter Ablauf der Messfahrten:** Die Messfahrten der autonomen Plattform dürfen durch den normalen Betrieb in der Anlage nicht gestört oder unterbrochen werden. Dadurch wird die Qualität

der aufgenommenen Daten gesichert, welche Grundlage für die quantitativen Analysen der einzelnen Algorithmen sind.

- **Anwesenheit von Betriebspersonal:** Während der Messfahrten soll garantiert sein, dass im Falle einer Betriebsstörung die autonome Plattform von einem Menschen rückgesetzt und neu initiiert werden kann. Da es sich um ein prototypisches System handelt, kann nicht ausgeschlossen werden, dass Fehlerzustände auftreten können.
- **Personensicherheit:** Die Sicherheit aller anwesenden Personen muss während der Messfahrten gesichert sein. Die Messfahrten müssen dem anwesenden Personal angekündigt werden, außerdem muss die Durchführung während des Betriebes gut erkennbar sein. Wenn notwendig sollen spezielle Maßnahmen wie z.B. örtliche Abtrennung und Videoüberwachung die Sicherheit garantieren.
- **geeignete Behausung:** Für Messfahrten im Freien muss die autonome Plattform wettergeschützt untergebracht werden. Dies gilt vor allem für Schutz vor starkem Regen und Schnee, aber auch vor starkem Wind.

Folgende Szenarien wurden für die Evaluation des prototypischen Systems entwickelt:

- **Szenario Endprüfung:** Während der Abnahmemessungen in der Fertigung in Weiz (Factory Acceptance Test – FAT) wird der Transformator vermessen und ein Fingerprint erstellt. Dabei wird zuerst ein 3D Modell des Transformators mit einem hochauflösenden Lidar Scanner erstellt. Danach werden in speziellen Testläufen des Transformators (Leerlauf, Kurzschluss, Belastung) Daten der unterschiedlichen Sensormodalitäten aufgezeichnet und auf dem 3D Modell des Transformators registriert. Dadurch entsteht der akustische, visuelle und thermische Fingerprint des Transformators.
- **Szenario Inbetriebnahme:** während des sogenannten Site Acceptance Test (SAT) wird analog zum Szenario Endprüfung der Transformator vermessen und ein Fingerprint erstellt. Der SAT wird direkt nach der Assemblierung des Transformators im Umspannwerk durchgeführt und ist die Voraussetzung für die Inbetriebnahme. Auch hier werden während der Testläufe des Transformators die Daten der unterschiedlichen Sensoren aufgezeichnet und ein Fingerprint erstellt. Durch Abgleich der Fingerprints aus FAT und SAT kann auf eine korrekte Funktionalität des Transformators rückgeschlossen werden.
- **Szenario Betrieb:** Das entwickelte Monitoringsystem überwacht während des Betriebs eines Transformators im Umspannwerk seinen Zustand. Dabei sollen in wiederkehrenden Messfahrten Daten von den unterschiedlichen Sensoren gesammelt werden und über die entwickelten Analysemodelle ausgewertet werden. Danach werden die Ergebnisse der Analysen mit den externen Daten aus den SCADA Systemen und anderen Quellsystemen (z.B. Wetter) verschnitten und der Zustand des Transformators bewertet.

3.4.2 Durchführung der Testszenarien

In diesem Kapitel wird die Durchführung der einzelnen Szenarien bewertet. Speziell soll auf die spezifisch aufgetretenen Probleme mit externen Faktoren eingegangen werden, sowie die Fähigkeiten des Systems bewertet werden, Änderungen zu detektieren. Schließlich soll das Zusammenspiel mit anderen, bereits bestehenden Monitoringsystemen untersucht werden.

Szenario Endprüfung

Messumgebung und Messaufbau

Das autonome System wurde im Rahmen einer Endprüfung eines Transformators in Weiz eingesetzt. Ziel war die sensorale Vermessung des Transformators sowie die Aufnahme des FAT Fingerprints. Weiters wurden die Schallemissionen gemessen und bewertet und mit den manuellen Messungen der Experten von Siemens Energy verglichen (siehe AP4). *Abbildung 54* zeigt den Roboter in der Prüfhalle bei Siemens Energy.



Abbildung 54: X-AMINOR Prototyp bei der Endprüfung in Weiz.

Einfluss externer Faktoren

Für den Einsatz der autonomen Plattform während der Endprüfung waren folgende Punkte problematisch:

- **Veränderte Umgebungen:** Nachdem jeder Transformator andere Abmessungen und Eigenschaften besitzt, sind die räumlichen Gegebenheiten für jede Messfahrt unterschiedlich. Es

kann also keine vorab aufgezeichnete Karte für die autonome Navigation verwendet werden, sodass die Plattform bei jeder Messung dieselbe Route verwendet. Trotzdem ist eine autonome Navigation in der Halle möglich, nachdem die Plattform auch mithilfe der aktuellen Sensordaten navigieren kann. Solange die Kollisionsvermeidung zuverlässig funktioniert, ist eine autonome Navigation auch in der Halle möglich, wenn die Route vor jeder Fahrt neu definiert wird. Dies ist mit der verwendeten Applikation leicht möglich.

- **Hindernisse am Boden:** Problematisch für die autonome Plattform waren außerdem große Hindernisse wie z.B. Schläuche am Boden. Diese müssen entweder großräumig umfahren werden oder mithilfe einer kleinen Brücke für die Plattform überbrückbar gemacht werden.
- **Datenverbindung:** Nachdem die Prüfhalle nach außen elektrisch abgeschirmt ist (Faradayscher Käfig), ist eine mobile Internetverbindung zur autonomen Plattform nicht möglich. Es kann also nur über eine Kabelverbindung oder mittels WIFI in der Halle mit der Plattform kommuniziert werden.

Szenario Inbetriebnahme

Dieses Szenario konnte im Projekt nicht umgesetzt werden, da während der Projektlaufzeit kein Transformator vom Projektpartner APG sowohl in Weiz in der Endprüfung noch in einem Umspannwerk in Österreich vor seiner Inbetriebnahme vermessen werden konnte. Alle Transformatoren, welche in Weiz vermessen wurden, wurden während der Projektlaufzeit nicht in Betrieb genommen.

Da die äußeren Umgebungsbedingungen im Szenario Inbetriebnahme jenen des Szenarios Betrieb ähneln, kann von äquivalenten Beobachtungen und Schlussfolgerungen in Bezug auf den Einfluss von externen Faktoren ausgegangen werden.

Szenario Betrieb

Messumgebung und Messaufbau

Das im Projekt entwickelte Monitoringsystem wurde in einer 3-monatigen Messkampagne im Umspannwerk Obersielach für Langzeittests eingesetzt. Von November 2023 bis Jänner 2024 wurde ein Transformator vermessen und sein Zustand überwacht. Dabei wurden an Werktagen jeweils 2 autonome Messfahrten mit 14 Messpunkten durchgeführt. Die Messfahrten fanden bei akzeptabler Witterung und Tageslicht statt, an wenigen Tagen konnte aufgrund von starkem Regen oder zu viel Schnee am Boden nicht gefahren werden. Insgesamt konnten 994 Messungen in 71 Messfahrten durchgeführt werden. Als wetterfeste Behausung für die autonome Plattform diente ein Container, welcher direkt neben dem zu überwachenden Transformator positioniert wurde. Über eine eigens angefertigte Rampe konnte der Roboter ein- und ausfahren. Im Inneren des Containers war die Ladestation positioniert, sodass der Roboter außerhalb der Messfahrten durchgehend geladen wurde. Abbildung 55 zeigt den Container mit Rampe und Ladestation im Inneren.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Da die Roboterplattform nicht selbstständig an die Ladestation andocken kann, musste sie vor und nach der Messfahrt über eine Remoteverbindung manuell aus bzw. in den Container gefahren werden. Der Rest der Messfahrt konnte autonom erfolgen.

Die autonomen Messungen wurden mit der Webapplikation gesteuert. Im Vorfeld der Messungen wurde die Karte der Umgebung durch mehrmaliges Abfahren mit dem Roboter aufgenommen. Anschließend wurden auf der Karte die Punkte definiert, an denen gemessen werden soll. Ein Workflow wurde in der Webapplikation erstellt, der sequentiell alle Messpunkte abfährt und anschließend zur vorgesehenen Endposition führt. Bei jedem Messpunkt wurde über einen *CustomWaypoint* ein Python Skript abgerufen, welches über ein ROS Interface die Messung startet. Sobald die Messung beendet wurde, erhält das Python Skript eine ROS Nachricht und die autonome Plattform fährt zum nächsten Messpunkt weiter. *Abbildung 57* zeigt die Karte des Transformators mit den eingezeichneten Messpunkten.

Um die Personensicherheit zu garantieren, wurde das Gebiet, in dem die autonome Plattform fährt, mit einem Signalzaun abgetrennt. Dadurch konnten keine Personen in das Areal eindringen und der Roboter konnte ungestört fahren. *Abbildung 56* zeigt den verwendeten Sicherheitszaun zur Abgrenzung des Bereichs der autonomen Plattform.



Abbildung 55: Container mit Ladestation als wetterfeste Behausung für die entwickelte autonome Plattform.



Abbildung 56: Sicherheitszaun zur Abgrenzung des Bereichs der autonomen Plattform.



Abbildung 57: Karte zur autonomen Navigation der Plattform. Die grauen Abbildungen stellen bereits bekannte Objekte dar, die grünen Punkte sind die aktuellen Sensorinformationen. Die kleinen Kreise sind die Punkte, an denen die Messungen durchgeführt werden

Einfluss externer Faktoren

Im Folgenden sind die einzelnen Faktoren, welche einen beobachtbaren Einfluss auf die Messungen während des Betriebs des Transformators hatten, aufgelistet.

Temperatur: Sowohl sehr tiefe als auch sehr hohe Temperaturen beeinflussen das Messverhalten des Systems. Da die Messfahrten im Winter stattfanden, konnte vor allem der Einfluss von tiefen Temperaturen beobachtet werden. Hier wurde festgestellt, dass die Tiefenkamera, welche für die Registrierung der Messungen am 3D Modell verwendet wurde, bei Temperaturen unter ca. -2°C unzuverlässig wurde und öfters keine Bilder lieferte. Daher wurden die Messungen bei solchen Temperaturen automatisch auf die Mittagszeit verlegt, als die Temperaturen um 0°C lagen und die Sonneneinstrahlung die Hardware aufwärmen konnte.

Auf der anderen Seite können zu hohe Temperaturen die Batterie des Roboters sowie das Ladeverhalten über die induktive Ladestation beeinflussen. Laut Herstellerangaben ist ein störungsfreies Laden nur unter einer Temperatur von 40°C garantiert. Dieses Verhalten konnte im Projekt allerdings nicht überprüft werden, da die Messfahrten hauptsächlich im Winter bei tiefen Temperaturen stattfanden.


Sonnenlicht: Direktes Sonnenlicht beeinflusst alle bildgebenden Sensoren. Insbesondere beeinträchtigt Sonnenlicht bei üblicherweise auf dem Markt erhältlichen Tiefenkameras die maximale Reichweite der Aufnahmen sehr stark. Für dieses Projekt wurde eine Tiefenkamera ausgewählt, welche aufgrund des Wellenbereichs, in dem sie arbeitet, robust gegen Sonneneinstrahlung ist. Bei starker, direkter Sonneneinstrahlung auf das aufgenommene Objekt (tiefstehende Sonne aus der Aufnahmerichtung) kommt es dennoch zu einer Verschlechterung des Ergebnisses (Siehe Abbildung 58), jedoch konnte auch in diesen Fällen eine Registrierung mit den aufgenommenen Daten erfolgreich durchgeführt werden.

Energieforschungsprogramm - 6. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG




Farbaufnahme bei starker, tiefstehender Sonne, die direkt auf den Transformator scheint



Resultierende Punktwolke mit fehlenden Punkten im Bereich der stärksten Einstrahlung



Farbaufnahme bei diffusem Licht (Sonne strahlt durch Wolkendecke)



Resultierende Punktwolke mit guter Abdeckung des gesamten Bereichs

Abbildung 58: Auswirkungen starker, direkter Sonneneinstrahlung auf das abzubildende Objekt auf die Herstellung einer Punktwolke mittels Tiefenkamera

Regen und Schnee: Da die autonome Plattform eine Outdoor Zertifizierung von IP44 besitzt, wurden Messfahrten bei starkem Regen nicht durchgeführt. Außerdem waren bei einer Schneemenge von mehr als 15cm am Boden keine Messfahrten möglich, da die Sensorik für die Navigation dadurch beeinträchtigt wäre. Es konnten allerdings Messfahrten bei leichtem Regen sowie schneebedecktem Boden durchgeführt werden.

Wind: Es konnte keine Beeinträchtigung der Messergebnisse durch normalen Wind beobachtet werden. Starke Winde waren im Zeitraum der Messungen nicht aufgetreten.

Zusammenspiel mit bestehenden Monitoringsystemen

Im Rahmen des Projekts wurde lediglich das Zusammenspiel mit dem APG SACDA System getestet. Die ursprüngliche geplante direkte Anbindung an das Leitsystem konnte aufgrund der Auflagen bzgl. IT/OT Security seitens APG nicht implementiert werden. Stattdessen wurde eine halbautomatische Lösung via automatisiertem Datenexport gewählt. Dabei wurden die relevanten Daten aus dem APG SCADA System in definierten Intervallen automatisch exportiert und auf das X-AMINOR Backend übermittelt. Dort konnten die Daten automatisiert verknüpft und für die Analysemodelle vorbereitet werden.

Durch die Verknüpfung der Daten können bessere Voraussagen über den Zustand des Transformators getroffen werden. So können über den Soll/Ist Vergleich im thermischen Bereich des Modells die Werte

im System automatisch validiert werden. Außerdem können die lastabhängigen Schallemissionen korrekt bewertet werden und auf Abweichungen vom Normalzustand überprüft werden.

4 Ergebnisse und Schlussfolgerungen

4.1 Evaluation

Das entwickelte System wurde anhand von mehreren Dimensionen bewertet. Diese wurden in einem Workshop vor der Durchführung der Evaluierungsszenarien bestimmt. Folgende Dimensionen wurden bewertet:

Autonomes System: Durch die erfolgreiche Durchführung von zwei Szenarien wurde diese Dimension als erreicht evaluiert. Das System funktioniert nach den in den Anforderungen definierten Kriterien, und ist in verschiedenen Use-Cases eingesetzt worden. Außerdem lässt es sich durch einen Laien bedienen. Eine kurze Einschulung wäre notwendig, und die Betreuung des autonomen Monitoringsystems kann von einem APG Mitarbeiter übernommen werden.

Als potentielle Probleme für das autonome System wurden folgende Punkte identifiziert:

- **Laufzeit der Batterie:** das implementierte System lässt Messfahrten von bis zu 2 Stunden zu, sollen längere Rundfahrten geplant sein, muss die Kapazität der Batterie erhöht werden oder eine Ladeunterbrechung eingefügt werden.
- **Gewicht und Größe:** Der ursprünglich konzipierte Sensorkopf war zu schwer (75kg) für die autonome Plattform und führte zur Beschädigung der Antriebseinheit. Daher musste auf ein suboptimales Mikrofonarray zurückgegriffen werden. Für die Integration der originalen Hardware ist eine autonome Plattform mit weit mehr Nutzlast notwendig (> 100kg)
- **Wartung:** Durch die Beschädigung der Antriebseinheit musste viel Aufwand in die Reparatur und die Wartung der autonomen Plattform investiert werden. Um diesen Aufwand zu minimieren, muss auf robustere und stärkere Hardware zurückgegriffen werden.
- **Safety bzw. Personensicherheit:** Wurde in diesem Projekt umgangen, da eine räumliche Abtrennung der autonomen Plattform durch einen Sicherheitszaun erfolgte. Für die zukünftige Anwendung müssen allerdings die Regularien bzgl. Safety berücksichtigt und in das System implementiert werden.

Integration: Die Integration fand in diesem Projekt in mehreren Stufen statt. Erstens wurden erfolgreich unterschiedliche, multi-modale Daten gemeinsam mit daraus resultierenden statistischen Analysen in einem einheitlichen Modell des Transformators integriert. Zweitens wurden externe Daten mit diesen Modelldaten verknüpft und integriert (SCADA, Wetter, usw.). Drittens kann das Modell mit seinen verknüpften Daten in einen Digital Twin eines Umspannwerks integriert werden. Einzig die direkte Anbindung der SCADA Daten konnte in dem Projekt nicht realisiert werden und wurde über einen

Umweg implementiert (siehe Kapitel 0). Die Integration wurde daher im Allgemeinen als erfolgreich evaluiert.

Datenanalyse: Hier werden einerseits die Analyse der individuellen Sensordaten als auch deren Integration in das Transformator Fingerprinting untersucht. Im Bereich der Auswertung der individuellen Sensordaten mit Modellen des maschinellen Lernens wurden in AP4 bereits sehr gute Ergebnisse dargestellt. Einzig in der Analyse der akustischen Sensordaten und Modelle konnten keine Aussagen aufgrund der fehlenden Daten von abnormalen Ereignissen getroffen werden. Im Allgemeinen wurde die Analyse der individuellen Sensordaten als erfolgreich evaluiert, obwohl für aussagekräftige Modelle noch viel mehr Daten notwendig sind.

Das Fingerprinting wurde als Konzept als sehr erfolgreich evaluiert. Hier ist herauszustreichen, dass über den Vergleich der Sensordaten und Modellanalysen von FAT und SAT Fingerprint ein erheblicher Mehrwert für den Betreiber der Anlage entstehen wird. Allerdings konnte das Konzept im Projekt nicht evaluiert werden, da das Szenario aufgrund der fehlenden Transformatoren nicht durchgeführt wurde (siehe Kapitel **Fehler! Verweisquelle konnte nicht gefunden werden.**).

Output: Als Output wurden die dem User zur Verfügung gestellten Informationen bezeichnet. Hier wurden 3 verschiedene Granularitäten für den Output gewählt. Erstens werden durch das Monitoringsystem Zeitintervall-basierende Reports für Dokumentation angelegt. Die Speicherung erfolgt automatisch im Backend des Systems. Zweitens können die Daten vom Benutzer gefiltert werden und so Reports-on-demand erstellt werden. Je nach Bedarf kann der Benutzer also die Informationen aus dem System abfragen, die er benötigt. Drittens erfolgt eine automatische Benachrichtigung des Benutzers bei einer Detektion einer Anomalie. Aufgrund der Granularität und Redundanz der Informationen im Output wurde diese Dimension auch als erfolgreich evaluiert.

Mensch-Maschine-Schnittstelle (HMI): Da keine Implementierung einer direkten Schnittstelle für den Benutzer erfolgte, muss dieser Punkt als nicht erfolgreich evaluiert werden. Das fehlende HMI soll in einem Nachfolgeprojekt entwickelt werden.

4.2 Dissemination

4.2.1 Wissenschaftliche Konferenzen

In Summe wurde im Projekt X-AMINOR 8 wissenschaftliche Veröffentlichungen getätigt. Davon waren 5 auf internationalen Konferenzen vertreten [22-26], 2 Artikel in internationalen Journalen [12][27], sowie 1 Artikel in einem nationalen Wissenschaftsmagazin [28].

4.2.2 Nationale Technologie Plattformen

Das Projekt wurde im Rahmen der Grazer Zukunftskonferenz⁸ dem nationalen Expertenpublikum in einem Fachvortrag vorgestellt. Weiters wurde eine Success-Story der FFG publiziert⁹.

Im April 2024 wurde das Projekt in der CIGRE¹⁰ Working Group Transformer Digital Twin präsentiert. Es folgen weiterführende Präsentationen und Ausstellungen bei der CIGRE Paris Session im August 2024, im APG DigiTalk und dem Let's Innovate der Siemens Energy.

4.3 Schlussfolgerungen

In diesem Projekt wurde ein Prototyp eines Multisensor-Roboters und einer Cloud-Backend-Lösung für die Lebenszyklus- und Zustandsüberwachung von Transformatoren sowie für die Erkennung von Anomalien vorgestellt. Der Schwerpunkt des Projekts lag auf der minimalinvasiven Überwachung und Diagnose von Transformatoren und darauf, dass das System zusätzlich zu bestehenden Lösungen zur Überwachung von Transformatoren eingesetzt werden kann. Für die Datenerfassung sammelt die Roboterplattform Daten von bestimmten Messpunkten rund um den Transformator, während sie Hindernissen ausweicht oder bei Bedarf anhält. Dies erfolgt automatisiert, präzise und zuverlässig. Die erfassten Daten werden im Cloud-Backend gespeichert, während die Datenverarbeitung zwischen der Sensorplattform und dem Backend aufgeteilt ist. Um die Erkennungen und Analysen bestimmten Stellen des Transformators zuzuordnen, wurden ein genauer Verortungs- und ein Mappingmechanismus basierend auf Deep Learning implementiert. Dies ermöglicht die automatische Messung und Lokalisierung der folgenden Parameter des Transformators: (1) die Temperatur bestimmter Elemente, (2) Geräuschquellen, (3) Korrosion, Rost und andere Oberflächenerkennungen, (4) das Auslesen analoger Messgeräte und (5) das Erkennen von Veränderungen. Darüber hinaus ermöglicht die systematische automatische Protokollierung der vom System erzeugten Daten die Entwicklung leistungsfähiger Algorithmen für die Lebenszyklusüberwachung von Leistungstransformatoren. Das Ziel ist die frühzeitige Erkennung von Anomalien am Transformator, um rechtzeitige Wartungseingriffe zu ermöglichen und dadurch das Auftreten von teuren Transformatorausfällen und Betriebsunterbrechungen zu vermindern.

Im Projekt wurde ein erster Prototyp des oben beschriebenen Systems realisiert und erfolgreich evaluiert. Das System konnte vollautonom Daten in einem Umspannwerk sammeln und Hinweise zum Gesundheitszustand des Transformators liefern. Da Transformatoren äußerst langlebige Maschinen sind, sind für eine Weiterentwicklung des Systems vor allem Daten aus Langzeitbeobachtungen notwendig. Die Modelle zur Überwachung der einzelnen Komponenten des Transformators wurden im Projekt zwar konzipiert, initialisiert, implementiert und teilweise evaluiert, belastbare Aussagen werden jedoch erst möglich, wenn die dafür notwendige Datengrundlage geschaffen ist. Damit können die

⁸ <https://zukunftskonferenz.joanneum.at>

⁹ https://www.pro2future.at/wp-content/uploads/2024/05/2024-03-27_X-AMINOR_SuccessStory_de.pdf

¹⁰ <https://cigre.org>

Machine Learning Modelle mit aussagekräftigen Statistiken arbeiten, welche zuverlässige Voraussagen ermöglichen. Ein Zeitrahmen für derartige Datenaufnahmen liegt bei mehreren Jahren an dutzenden Objekten. Trotzdem konnte im Projekt gezeigt werden, dass unter Zuhilfenahme von bisher nicht genutzten Sensormodalitäten neue und gegebenenfalls bessere Aussagen zum Gesundheitszustand des Transformators gemacht werden können.

5 Ausblick und Empfehlungen

Durch das Erkennen von Anomalien, die mit seltenen Transformatoranomalien, z. B. mechanischen Störungen, zusammenhängen können, kann das System dazu beitragen, die Lebensdauer und Effizienz von Transformatoren zu verlängern. Um dafür aussagekräftige Vorhersagen zu erzielen, sollen als nächster Schritt zeitlich ausgedehnte Messkampagnen zur Datenaquisition durchgeführt werden. Die so gewonnenen Daten werden zum Training der im Projekt entwickelten Modelle verwendet. Weiters werden im Rahmen künftiger Arbeiten die Leistung des Systems im Vergleich zu Vor-Ort-Inspektionen und anderen Qualitätskontrollen bewertet. Dabei soll vor allem der Einfluss der Analyse der Sensordaten (RGB, Tiefe, Thermik (IR)/Thermik und Akustik) auf die Ergebnisse des Monitorings in quantitativen und qualitativen Analysen untersucht werden.

6 Literaturverzeichnis

- [1] Elko, Gary W., and Jens Meyer. "Microphone arrays." Springer handbook of speech processing (2008): 1021-1041.
- [2] Jingzhu, Hu, et al. "Electromagnetic vibration noise analysis of transformer windings and core." IET Electric Power Applications 10.4 (2016): 251-257.
- [3] Bartoletti, Cipriano, et al. "Vibro-acoustic techniques to diagnose power transformers." IEEE Transactions on Power Delivery 19.1 (2004): 221-229.
- [4] Bailey, Rachel L., et al. "Modelling geomagnetically induced currents in midlatitude Central Europe using a thin-sheet approach." Annales Geophysicae. Vol. 35. No. 3. Göttingen, Germany: Copernicus Publications, 2017.
- [5] Tenbohlen, Stefan, et al. "Diagnostic measurements for power transformers." Energies 9.5 (2016): 347.
- [6] Hendrycks, D., Mazeika, M., & Dietterich, T. (2018). Deep anomaly detection with outlier exposure. arXiv preprint arXiv:1812.04606.
- [7] Wilkinghoff, K. (2022). An outlier exposed anomalous sound detection system for domain generalization in machine condition monitoring. DCASE2022 Challenge, Tech. Rep.
- [8] Adapa, R.; Douglass, D.A. Dynamic thermal ratings: monitors and calculation methods. In Proceedings of the 2005 IEEE power 675 engineering society inaugural conference and exposition in Africa. IEEE, 2005, pp. 163–167.
- [9] Lai, W.; Li, W.; Meng, H.; Ding, R.; Wang, Y.; Fang, S. Research on the relation between load coefficient and hot spot temperature 677 of oil-immersed power transformer. In Proceedings of the 2019

- IEEE International Conference on Power, Intelligent Computing 678 and Systems (ICPICS). IEEE, 2019, pp. 393–396.
- [10] Daminov, I.; Rigo-Mariani, R.; Caire, R.; Prokhorov, A.; Alvarez-Hérault, M.C. Demand Response coupled with Dynamic Thermal 680 Rating for increased transformer reserve and lifetime. *Energies* 2021, 14, 1378.
- [11] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).
- [12] Waikat, J.; Jelidi, A.; Lic, S.; Sopidis, G.; Kähler, O.; Maly, A.; Pestana, J.; Fuhrmann, F.; Belavic, F. 2024. First Measurement Campaign by a Multi-Sensor Robot for the Lifecycle Monitoring of Transformers. In *MDPI Energies, special issue 6th International Colloquium "Transformer Research and Asset Management"*, in press.
- [13] L. Meng and J. Cheng, "Research on the Visual Recognition Method of Pointer Water Meter Reading," 2021 IEEE 5th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), Chongqing, China, 2021, pp. 909-914, doi: 10.1109/IAEAC50856.2021.9390735.
- [14] Ali Atghaei, Ehsan Rahnama, Kiavash Azimi, and Hassan Shahbazi. Industrial scene change detection using deep convolutional neural networks. *arXiv preprint arXiv:2212.14278*, 2022.
- [15] Uwe Stilla and Yusheng Xu. Change detection of urban objects using 3d point clouds: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 197:228–255, 2023. ISSN 0924-2716.
- [16] Kento Doi, Ryuhei Hamaguchi, Yusuke Iwasawa, Masaki Onishi, Yutaka Matsuo, and Ken Sakurada. Detecting object-level scene changes in images with viewpoint differences using graph matching. *Remote Sensing*, 14(17), 2022.
- [17] Pablo F. Alcantarilla, Simon Stent, Germán Ros, Roberto Arroyo, and Riccardo Gherardi. Street-view change detection with deconvolutional networks. *Autonomous Robots*, 42:1301–1322, 2018.
- [18] Ken Sakurada, Mikiya Shibuya, and Weimin Wang. Weakly supervised silhouette-based semantic scene change detection. In *Proceedings of the International Conference on Robotics and Automation (ICRA)*, pages 6861–6867, 2020.
- [19] Ragav Sachdeva and Andrew Zisserman. The change you want to see. In *Proceedings of the Winter Conference on Applications of Computer Vision (WACV)*, 2023.
- [20] Ragav Sachdeva and Andrew Zisserman. The change you want to see (now in 3d). In *Proceedings of the International Conference on Computer Vision (ICCV)*, 2023.
- [21] Sarradj, E. (2015). Optimal planar microphone array arrangements. *Fortschritte der Akustik, DAGA*.
- [22] Fuhrmann, F., Diwold, K., Waikat, J., Gaugl, J., Belavic, F., and Graf, F. (2023). X-AMINOR: A Mobile Multi-Sensor Platform for Lifecycle-Monitoring of Transformers. In *Proceedings of the 12th International Conference on Smart Cities and Green ICT Systems - SMARTGREENS*, ISBN 978-989-758-651-4; ISSN 2184-4968, SciTePress, pages 121-128. DOI: 10.5220/0011968800003491.
- [23] Fuhrmann, F., Diwold, K., Waikat, J., Gaugl, J., Belavic, F., and Graf, F. (2023). Cross-Sensor Platform for Transformer Monitoring Applications. In *Proceedings of the 15th IEEE PowerTech Conference*, 2023, Belgrade, Serbia.
- [24] Fuhrmann, F., Maly, A., Blass, M., Waikat, J., Belavic, F., and Graf, F. (2023). 3D Acoustic Heat Maps for Transformer Monitoring Applications. In *Proceedings of the 6th International Colloquium on Transformer Research and Asset Management (ICTRAM)*, Split, Croatia.

[25] Waikat, J., Jelidi, A., Lic, S., Sopidis, G., Kaehler, O., Maly, A., Pestana, J., Fuhrmann, F., Belavic, F. (2023). Preliminary Results by a Multi-Sensor Robot for the Lifecycle Monitoring of Transformers. In Proceedings of the 6th International Colloquium on Transformer Research and Asset Management (ICTRAM), Split, Croatia.

[26] Kaehler, O., et al. (2024) Visual Change Detection in Industrial Environments. In Proceedings of the 1st Austrian Symposium on AI, Robotics, and Vision.

[27] Fuhrmann, F., Maly, A., Blass, M., Waikat, J., Belavic, F., and Graf, F. (2024). 3D Acoustic Heat Maps for Transformer Monitoring Applications. Journal of Energy - Energija, Vol. 72 (3), in print.

[28] Roboterüberwachung für Großtrafos (2023) <https://www.just-magazin.com/science/roboterueberwachung-fuer-grosstrafos/>

7 Kontaktdaten

Dr. Ferdinand Fuhrmann

JOANNEUM RESEARCH Forschungsgesellschaft mbH
DIGITAL – Institut für Digitale Technologien
Steyrergasse 17, 8010 Graz, Austria

Tel.: +43 316 876-1309

E-Mail: ferdinand.fuhrmann@joanneum.at

Web: www.joanneum.at/digital

Partner:

Austrian Power Grid AG

Siemens AG Österreich

Siemens Energy Austria GmbH

Pro2Future GmbH