Gefördert durch:

Bundesministerium
für Forschung, Technologie
und Raumfahrt

Universität Rostock

OTC-Tracker

Remote Mission Tracking and Reporting

Laufzeit des Vorhabens: [*01.01.2022*] – [*30.11.2024*]

Torben Globisch, Uwe Freiherr von Lukas

03ZU1107JD

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt unter dem Förderkennzeichen ... gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei der Autorin/beim Autor.

OCEAN
TECHNOLOGY
CAMPUS ROSTOCK

Teil I: Kurzbericht

Teil II Ausführlicher Bericht

AP 1 Anforderungen und Spezifikation

Die Gesamtheit des Arbeitspaketes beschäftigt sich in erster Linie mit dem Missionsprozess von ROV-Missionen.

In diesem Arbeitspaket geht es um die Erfassung von:

1. Die Anforderungen
    a. Primär durch Auftragnehmer und Auftraggeber von Piloten, Schulungskräften und Wissenschaftlern
    b. Sekundär durch Literatur
2. Konzepten
    a. Des Missionsprozesses mit technischen Randbedingungen
    b. Konzept für Modellierung von Prozess und Umgebung für einen automatisierten Abgleich von Modell und sensorisch erfasster Realität
    c. Konzeption des KI- Moduls zur Auswertung

Anforderungserfassung

Die wissenschaftliche Literatur sowie bisherige Planungssoftware, die sich mit ROVs (Remotely Operated Vehicles) und AUVs (Autonomous Underwater Vehicles) befasst, konzentriert sich auf die Steuerung und Regelung dieser Unterwasserfahrzeuge (Huang und Yang 2022). In dieser Hinsicht gibt es zahlreiche Ansätze und Entwicklungen, die darauf abzielen, die Kontrolle und das Situationsbewusstsein von ROVs zu verbessern und zu automatisieren (Gao et al. 2020; Sahoo et al. 2023). Ein weiterer wichtiger Aspekt ist die Wegpunktplanung (Guo et al. 2022; Hua et al. 2022), die bei vielen Anwendungen verwendet wird. Hier gibt es zwar bereits einige gute Ansätze (Chowdhury und Subramani 2022), allerdings sind die Informationen über die Umgebung oft nur begrenzt verfügbar und ungenau, was die Planung erschwert und in vielen Fällen eine genaue Wegpunktplanung unmöglich macht.

In der Praxis haben ROV-Piloten und Mitarbeiter von Unternehmen wie RS Diving sowie Auftraggeber von ROV-Missionen wertvolles Feedback gegeben, das bei der Weiterentwicklung von ROV-Missionen als Prozess berücksichtigt werden sollte. Zum Beispiel wurde festgestellt, dass die bisherige Wegpunktplanung aufgrund der ungenauen Informationen über die Umgebung nicht anwendbar ist. Eine aufgabenbasierte Planung, die auf den spezifischen Anforderungen der Mission basiert, könnte hier vielversprechender sein. Da eine ROV-Mission in unserem Fall als eine Auftragsproduktion von Daten betrachtet werden kann, könnte es Ansätze aus der Produktionsorganisation geben welche helfen können Prozesse zu verstehen, zu

digitalisieren und zu augmentieren. Ein wichtiger Unterschied zur Produktionsorganisation besteht jedoch darin, dass die Position, an der die Aufgabe erledigt werden soll, oft ungewiss ist. Des Weiteren sind die auftretenden Ereignisse während einer ROV-Mission im Vergleich zu klassischen Produktionsprozessen vielfältiger und unklarer definiert. Hier ist also ein hohes Maß an Kontrolle für den Menschen wichtig.

Wir sind zu der Erkenntnis gelangt, dass eine ROV-Mission als Gesamtprozess von der Entgegennahme der Anforderungen bis zur auswertenden Berichterstattung verstanden werden sollte. Im Zusammenhang mit ROV-Missionen sind vier Stakeholder beteiligt: Die auftraggebende, die missionsplanende, die missionsausführende und die missionsdokumentierende Instanz. Während der Anforderungserfassung haben wir mit allen Stakeholdern am Gesamtprozess formelle oder informelle Interviews geführt.

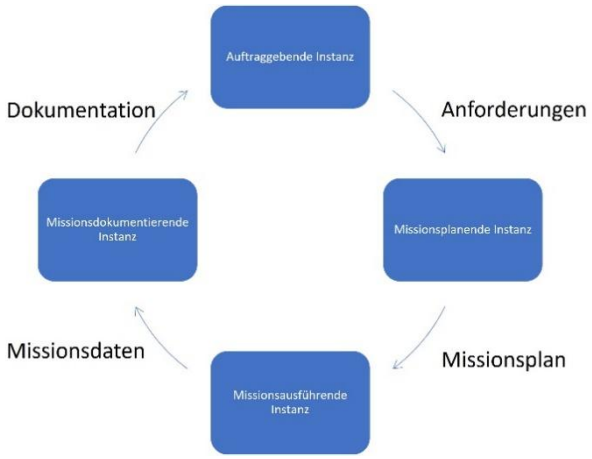

Abbildung 4: Gesamtprozess einer ROV-Mission

Besonderheit hier ist, dass zwischen den einzelnen Stakeholdern des Prozesses werden stets einzig und allein Daten ausgetauscht werden. Die einzelnen User Stories lassen sich wie folgt beschreiben:

Der Planungsprozess für ROV-Missionen ist in der Regel sehr manuell, da der Zustandsraum der Inputs vom Auftraggeber sehr groß ist. Hier ist eine Systematisierung des Inputs von Vorteil, da dies die Wiederverwendbarkeit von einmal getätigten Planungen ermöglicht, die Prozessüberwachung vorbereitet und die automatische Verarbeitung von zu sammelnden Informationen erleichtert. Die Missionsplanung fungiert als vereinigende Instanz für Informationsinput von Auftraggeber und externen Informationenquellen über das Missionsgebiet. In der Missionsplanung wird Feedback aus Vorgängermissionen bisher kaum berücksichtigt.

Die auftraggebende Instanz wird in erster Linie durch Risikominimierung und regulatorische Anforderungen motiviert Missionen zu beauftragen. Hier besteht Interesse an Missionsvisualisierung und an der Augmentation der bisher gesammelten Informationen, um ein besseres Verständnis über das Missionsgebiet zu gewinnen.

Der ROV-Pilot als Missionsausführende Instanz ist an der Verbesserung des Situationsbewusstseins interessiert, um seine eigenen Aufgaben effiziente und bei geringerer kognitiver Last abzuarbeiten.

Die Missionsdokumentierende bzw. Nachbereitende Instanz hat ein großes Interesse an der Automatisierung der Dokumentation arbeiten. Langwierige, sich wiederholende hochmanuelle Prozessschritte geprägt von vielen Medienbrüchen ist derzeit die Norm im Dokumentationsprozess. Hier gibt es großes Interesse und großes Potential an der Automatisierung der Auswertung mittels Datenpipelines mit KI-Tools.

Konzeption

In der Phase der Konzeption gilt es im ersten Schritt eine Aufnahme des ist Prozesses

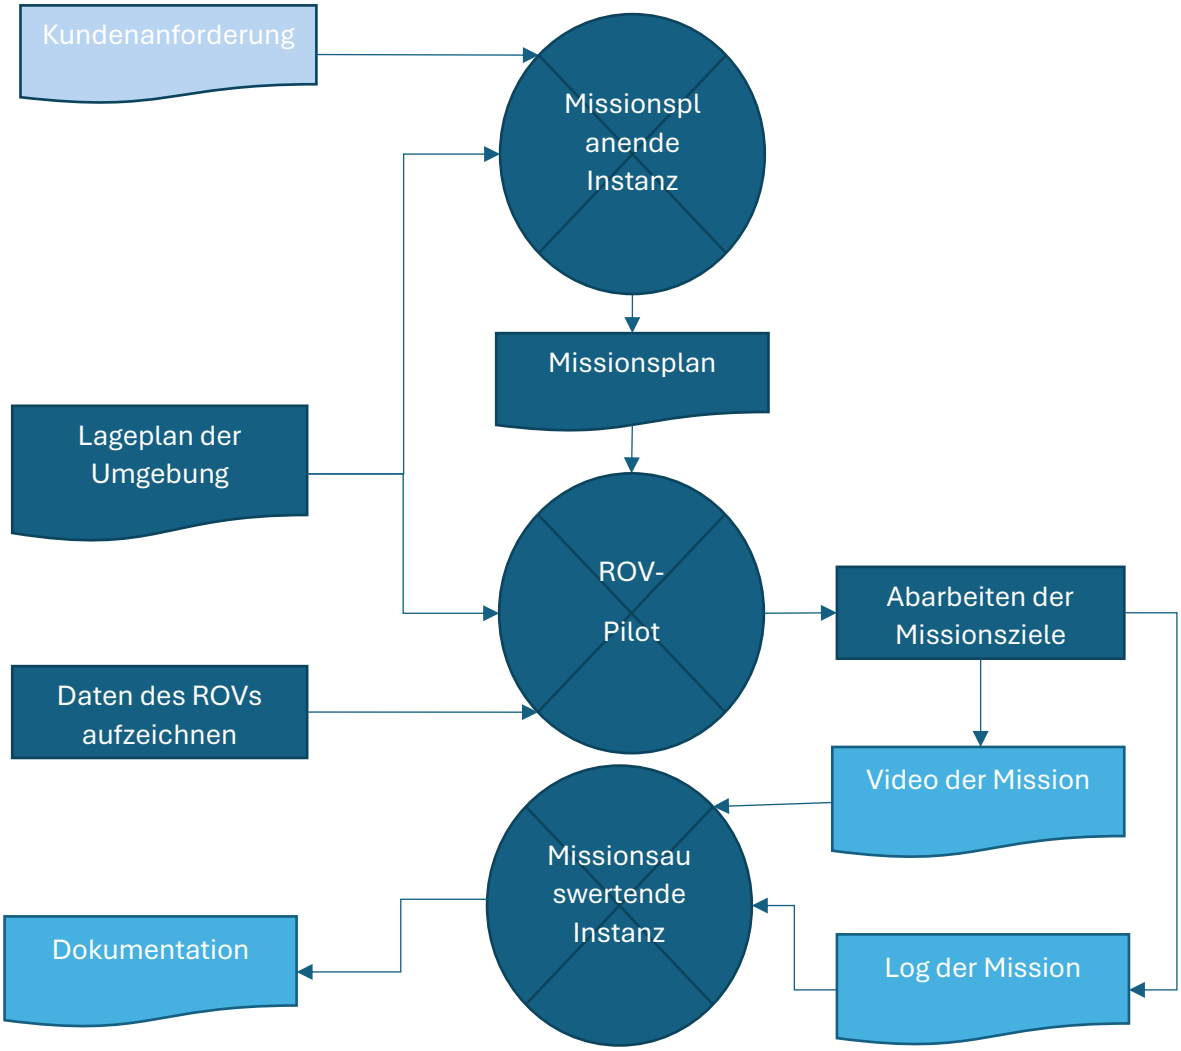

Abbildung 5: Vereinfachter Missionsprozess

vorzunehmen welcher in Abbildung 5: Vereinfachter MissionsprozessAbbildung 5 vereinfacht dargestellt ist. Hier sehen wir, dass der Prozess menschliche Akteure in den Mittelpunkt stellt und diese als vereinigter von Informationen verwendet. Dies bedeutet eine hohe kognitive Last während der gesamten Mission auf die beteiligten Personen.

Im Rahmen der Planung und Durchführung von ROV-Missionen stellt sich die Frage, welche Daten von dem ROV erfasst werden und welche Daten aus der Umgebung verfügbar sind, um eine erfolgreiche Auswertung durchzuführen. Die verfügbaren Daten umfassen in unserem Fall

Streamdaten vom ROV wie Positionsstream, Kamerastream. Weitere serielle Messdaten werden von der Datentonne ebenfalls als Stream zur Verfügung gestellt. Zusätzlich ist der Zugang zu bathymetrischen Daten und den ungefähren Positionen der Anlagen möglich.

Da wir die technischen Randbedingungen also den Dateninput in unser System kennen gilt es 2 Schritte zu erledigen:

a) Entwicklung eines Modells für den Prozess
b) Entwicklung eines Modells für die Umgebung

Die Entwicklung des Prozesses ist für uns eng an den Use Case, welchen wir betrachten, geknüpft. Wir wollen die Wartungsmission bei Offshore Windenergieanlagen begleiten. Dementsprechend brauchen wir ein Modell, um diese Wartungsmission darzustellen. Hierfür bietet sich dies hier empirisch bestimmte Entity Relation Model an wie in Abbildung 6

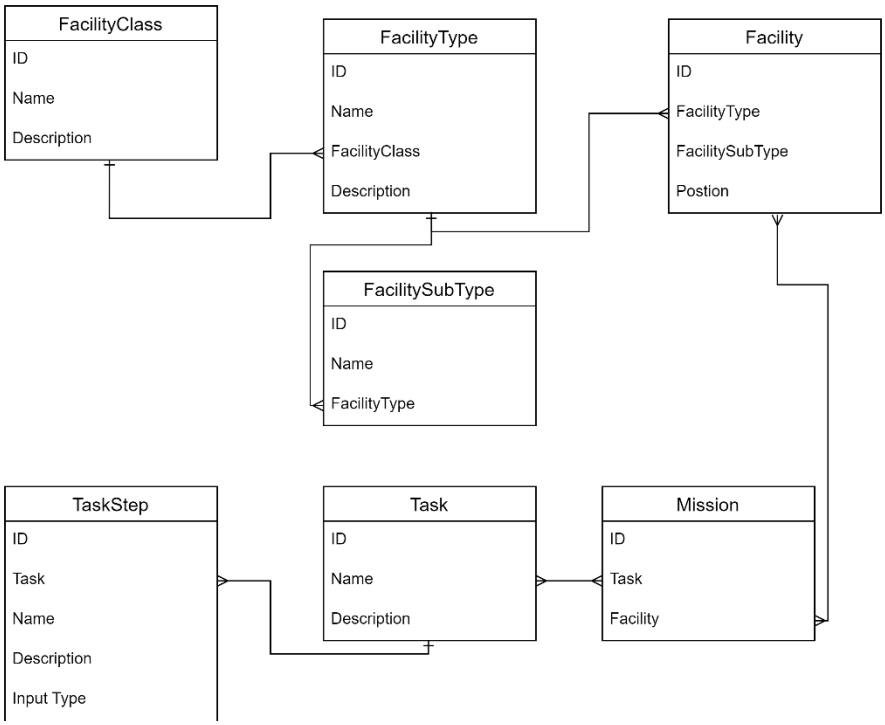

Abbildung 6: Entity Relation Model Missionsprozess

dargestellt.

Wir erkennen hier, dass eine Mission aus Aufgaben besteht, die weiter in Aufgabenschritte unterteilt sind, besteht. Für diese Aufgaben sind vorkonfigurierte Anlagen relevant welche der Missionsplanung hinzugefügt werden. Dieses Modell sollte in der Planung berücksichtigt werden, in der Durchführung mit Informationen angereichert und letztlich in der Auswertung zur Verarbeitung der gesammelten Daten verwendet werden.

Wir benötigen Weiterhin ein Konzept zur Modellierung der Umgebung, optimalerweise in Zusammenhang mit einer Modellierung des Prozesses einer ROV- Mission. Dies soll die Basis für einen automatischen Abgleich von Model mit sensorisch erfasster Realität darstellen. Wir brauchen also für das Training und den Test unserer Algorithmen sowie unserer Software ein System, aus dem wir die Sensor Daten mit einer Ground Truth vergleichen können.

Die sich beim Sammeln von Daten für KI-Algorithmen stellende Herausforderung ist, dass bei echten ROV-Missionen nur die sensorisch erfasste Realität ohne Ground Truth gemessen werden kann. Dies basiert darauf, dass erstens keine exakten Umgebungsinformationen der

Missionsgebiete verfügbar sind und zweitens sich die Umgebungsparameter unter realen Einsatzbedingungen nicht kontrollieren lassen. Es wird also ein Konzept für eine kontrollierbare Simulationsumgebung erstellt, welche zugleich die Sammlung von Sensordaten und der den Daten zugrundeliegenden Zustände ermöglicht.

Hierfür wird als Basis ein bereits implementiertes Simulationstool namens HoloOcean (Potokar et al.) herangezogen. Es handelt sich bei HoloOcean um ein fork der Open Source Simulationsumgebung HoloDeck welche ursprünglich an der Brigham Young University entwickelt wurde.

In HoloOcean enthalten sind verschiedene Umgebungsmodelle sowie verschiedene Unterwasserfahrzeuge wie die für unseren Fall relevanten ROVs. In den Umgebungsmodellen gibt es vorgefertigte Umgebungen mit menschengemachten Unterwasserstrukturen welche als Simulationsbasis genutzt werden können.

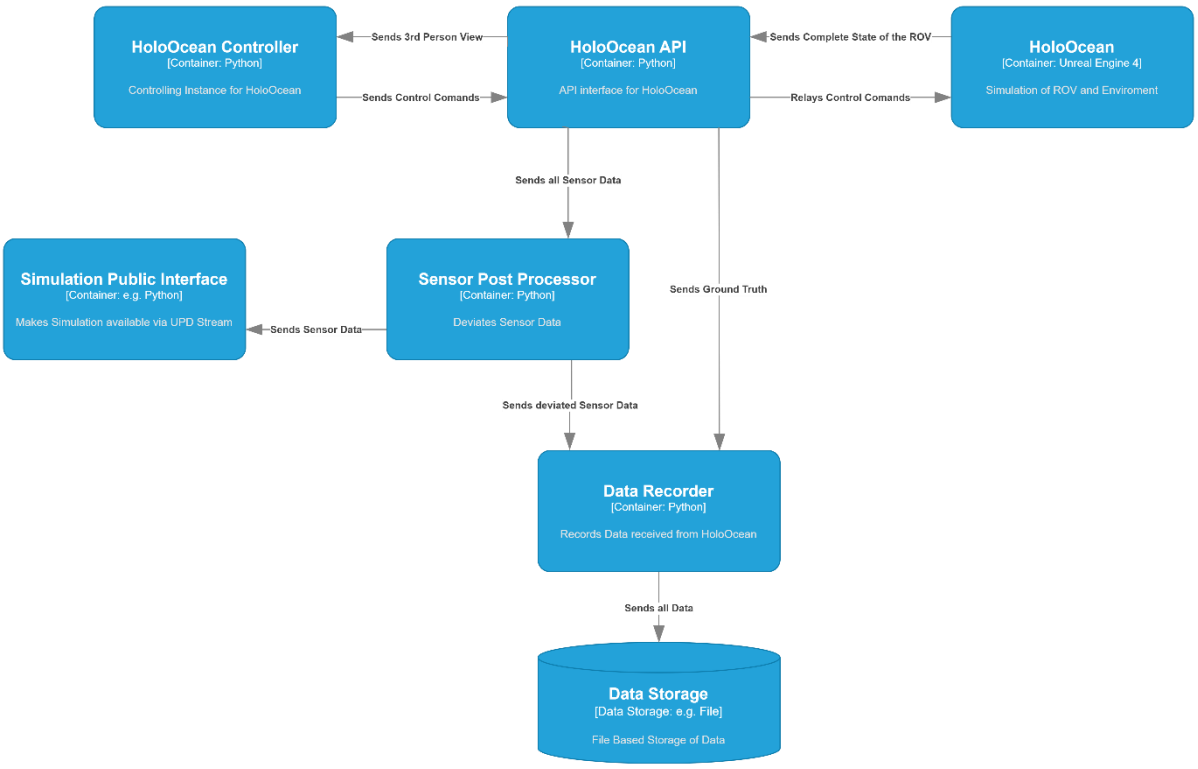

Abbildung 7: Simulationsumgebung für ROV-Missionen

In Abbildung 7 ist das Konzept für die Simulation der Umgebung mit Abgebildet. HoloOcean wird hier mit seiner selbst entwickelten API-Schnittstelle gehostet und überträgt jeden Tick der Simulation den gesamten State des ROVs sowie wichtige Umgebungsparameter an das System. Im State des ROVs sind die von den Sensoren erfassten Daten sowie diesen die zugrundeliegenden Zustände der Simulation enthalten. Die Sensordaten enthalten dabei bereits ein vordefiniertes Black-Box-Fehlermodell, welches lediglich in seiner Varianz in der Simulation angepasst werden kann. Die Kontrolle über das System hat der Controller welcher menschlichen Input, vordefinierte Steuerungsbefehle oder vorgeplante Trajektorien an die API übermittelt, welche wiederum die Befehle an HoloOcean weiterleitet.

Die im State bereitgestellten Sensordaten und zugrundeliegenden Zustände werden über 2 Pipelines dem Data Recorder zur Verfügung gestellt. Sensordaten werden dabei in einem Post Processing schritt noch einmal verarbeitet. Dieser Post Processing schritt wird dazu verwendet

die Sensordaten so zu transformieren, dass diese realen Daten aus einem ROV entsprechen. Dazu gehört zum Beispiel die Übertragung der Koordinaten aus der von der Unreal Engine generierten Welt in ein beliebiges, reales Koordinatensystem. Hier kann man gleich eine Vergleichbarkeit mit dem realen ROV schaffen in dem man das Koordinaten System verwendet, welches später vom ROV erwartet wird. Des Weiteren kann man im Post Processing allen Sensordaten beliebige eigene Fehlermodelle hinzufügen um eventuelle Fehlerquellen gezielt zu simulieren. Die so weiterverarbeiteten Sensordaten werden dem Data Recorder und dem Public Interface zur Verfügung gestellt. Das Public Interface dient dabei als Schnittstelle für alle Labortestes der zu entwickelnden Algorithmen und Systeme.

Der im State des ROVs enthaltende zugrundeliegende Zustand wird ebenso wie das verarbeitete Sensorsignal an den Data Recorder gesendet. Dieser Speichert die Rohdaten in unkomprimierter Form auf einem File-Based System ab. Diese so gesammelten Daten stellen die Grundlage für das Training von KI und den Test von Auswerte-Pipelines da.

Abschließend gilt es mit den gesammelten Konzepten und Ist-Prozessen KI-Gestützte Module zur Auswertung zu Konzeptionieren. Aus dem Ist Prozess lässt sich die zentrale Bedeutung des Videomaterials für die Erstellung der Dokumentation ableiten. Dieses Videosignal lässt sich mit Hilfe des Positionssignals des ROVs Augmentieren, um dem Optical Flow des Videos noch die sensorisch erfasste Bewegung der ROVs hinzuzufügen. Für die Missionsauswertung ist ersten Schritt relevant zu welchem Zeitpunkt in den Sensordaten eine Unterwasserstruktur präsent war. Des Weiteren ist relevant an welchen Orten sich das ROV längerfristig aufgehalten hat. Dies sind relevante Kandidaten für Point of Interests (PoI) in der Mission. Hieraus lassen sich 2 relvante KI Module für die Auswertung ableiten: Eine Point of Interest Detection und eine Structureness Detection

Diese beiden KI-Module können während der Missionsdurchführung mitlaufen und live auf gesampelte Daten des Gesamtsystems zugreifen, um diese Daten live während der Mission zu annotieren.

Aus der Planung des Prozesses ergibt sich, dass es für Verschiedene Aufgaben eine Bandbreite an Relevanten Informationen aus den Datenströmen des ROVs gibt. Hierbei gilt es sich verschiedene Aufgabentypen im Detail zu Betrachten und nach Möglichkeit die Auswertung zu automatisieren. Hierbei bietet sich die Möglichkeit die gesammelten Informationen des ROVs mit den Daten aus Datentonne zu Augmentieren welche bei der späteren Missionsvisualisierung genutzt werden können.

Wir sehen also eine Unterteilung der Auswertemodule in

a) Monitoring Module (Module die live in der Mission mitlaufen
b) Retrospektive Module (Module die nach Missionsende Datengenerieren)

Für die Monitoring Module ist in Abbildung 8 die Pipeline dargestellt. Es handelt sich hierbei um ein Feedback System welche Informationen aus dem Gesamtsystem entgegen nimmt, um

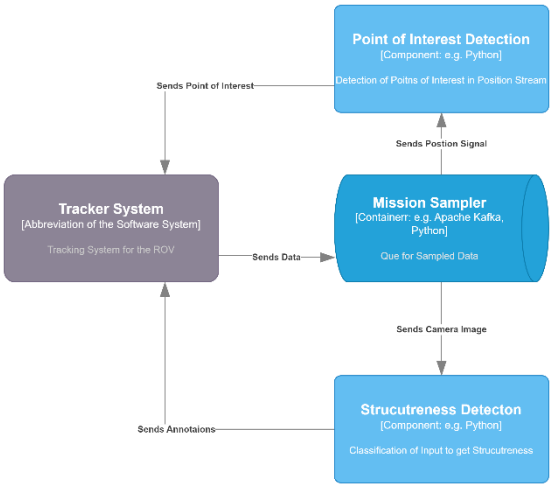

Abbildung 8: Prototyp Monitoring Module

Feedback in Form von Annotationen dem Gesamtsystem zur Verfügung zu stellen. Die Auswertepipeline ist Aufgabentyp spezifischer. Hier werden die gesammelten Daten zusammen mit den erstellten Annotationen abgerufen. Das Retrospektiv Modul wird in Abbildung 9 prototypisch dargestellt.

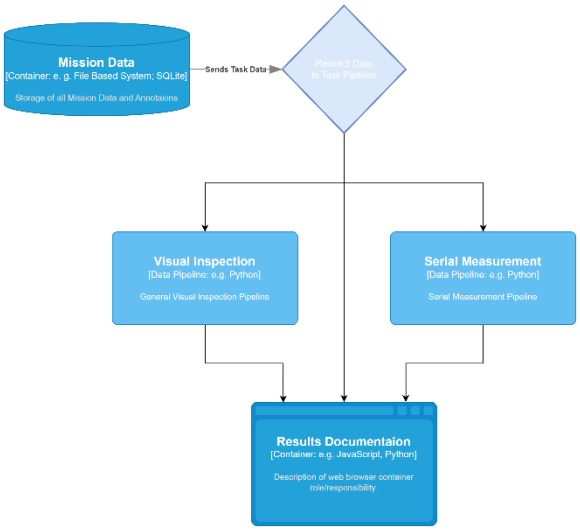

Abbildung 9: Referenzarchitektur Retrospektiv Modul

Das Konzept basiert darauf Datenpipelines Task abhängig zu erstellen und die Ergebnisse dem Gesamtsystem zur weiteren Verarbeitung zur Verfügung zu stellen. Hier ist es wichtig eng mit RS Diving abzustimmen welche der gesammelten Informationen des ROVs sowie der Datentonne einen Mehrwert bieten und wie diese am besten visualisiert werden sollen.

Arbeitspaket Status: in Bearbeitung

AP 3 Implementierung Software Prototyp

AP3.1 Prototypisches KI-System

Im ersten Schritt werden die vorhandenen Daten analysiert und für die Verarbeitung in Formate, welche für das Training der neuronalen Netzte vorgesehen ist, gebracht.

Hierbei wird derzeit verschiede Ansätze zum labeln von Datensätzen evaluiert, um ein Benchmarking verschiedener Neuronaler Netze vorzubereiten.

Da KI-Module gerade im Bereich Deep Learning sehr datenintensiv in der Lernphase sind wird hier stets neue Daten generiert und gelabelt. Aus der Verwendung von teils synthetischen Daten in Kombination ergibt sich derzeit die wissenschaftlich spannende Frage, inwieweit die Fusion von künstlichen und natürlichen Daten einen Vorteil für das Training der neuronalen Netze in der Domäne der Unterwasserobjekterkennung bietet.

Erste Neuronale Netze werden derzeit getestet und die erzeugten Ergebnisse miteinander vergleichen. Prototypische Implementierung einer „strucutreness Detection“ wurden mittels Imagenet und dem K – Means Clustering Verfahren vorgenommen und getestet. Weitere Ansätze basierend auf verschiedenen Neuronalen Netzen, welche alle die gleiche Kernfunktionalität erfüllen werden, derzeit evaluiert.

AP 3.2 Entwicklung Konfigurierbares Gesamtsystem

Die Implementierung der Hardware-Beschleunigung mittels GPUs ist bei der Verwendung von Windows System wie auf Schiffen üblich problematisch, da die Verwendung von Bibliotheken wie Tensorflow auf eine lauffähige CUDA-Umgebung, welche ab Version TF 2.11 nicht mehr nativ unter Windows unterstützt wird. Das Problem wurde mittels des Erstellens einer Docker-Container Umgebung, welche die entwickelte Software hosten kann, gelöst. Dies Ermöglicht maximale Portabilität und Skalierbarkeit auf verschiedenste Systeme.

Das Gesamtsystem wird durch Feedback von RS-Diving kontinuierlich verbessert. Eine Frontend Komponente wurde entwickelt welche die Folgenden Architekturentscheidungen vereinigt:

Die Datenquelle muss konfigurierbar sein, um verschiedenste Datenquellen innerhalb des Tracker Systems und externen Quellen zugreifen zu können.

Es müssen Medienbrüche bei der Arbeit des Users vermieden werden.

Auswerte Informationen, die vom Piloten geloggt werden müssen, digitalisiert und leicht übertragbar vorliegen um Semi-Automatisch berichte zu schreiben zu können.

In dieses Frontend wurde ein Missionszeitstrahl mit Event Visualisierung eingebaut wie in Abbildung 1 dargestellt.

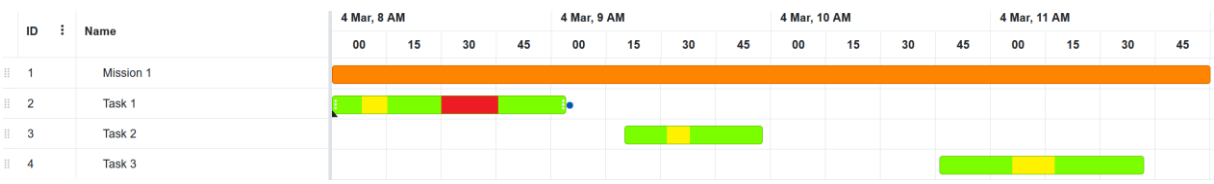

Abbildung 1: Timeline der Auswerte Komponente

Des Weiteren wurde eine prototypische Bildverbesserung integriert, um die Qualität der Berichte zu verbessern.

M1 Labortest

Die Entwickelten Prototypen für die KI und das Missionsauswertungssystem wurde mittels Daten, welche in HoloOcean generiert wurden, getestet und erste Evaluation wurde vorgenommen. Bei HoloOcean handelt es sich um eine ROV simulationsplattform welche dazu dient die Signalsignatur eines echten ROVs nachzunahmen.

Alle Komponenten sowie der Labortest wurde von RS Diving und dem Fraunhofer IGD Rostock regemäßig evaluiert.

AP 4 Integration und Optimierung

Optimierung der Netztopologie für die Zielhardware

Die Architektur wurde als verteiltes System konzipiert, das auf schiffsbasierten Rechnern eingesetzt werden kann. Durch die Verwendung von Containern und standardisierten Schnittstellen (z. B. REST APIs) wurde eine modulare Kommunikation und optimale Netzwerkauslastung sichergestellt. Für die Integration wurden die Systeme so konstruiert, dass sie als Docker Container verteilt integriert werden können.

Dabei wurde auf die Optimimale Verteilung des System geachtet.

AP 5 Erprobung und Validierung im Seegebiet

Evaluierungskonzept und Dokumentation Test-Prozess

Die Tests wurden mit Daten aus der HoloOcean-Simulation sowie realen Aufnahmen durchgeführt. Die Evaluierung der Prototypen erfolgte iterativ mit Feedback durch RS Diving und Fraunhofer IGD. Die Resultate flossen kontinuierlich in Verbesserungen ein. Ein Finaler Test des Systems stand zum Abschluss des Projektzeitraumes noch aus. Grund hierfür war ein defekt am ROV in Kombination mit langen Lieferzeiten für Ersatzzeiten.

Auswertung Datenbasis und darauf getroffene KI-Entscheidungen des Systems

Die Auswertung berücksichtigte sowohl die Detektionsleistung der CNNs (z. B. Clusterqualität) als auch die Plausibilität der automatisch erkannten Point of Interests. Eine manuelle Gegenüberstellung mit Ground Truth ermöglichte eine präzise Bewertung der KI-Entscheidungen. Für die Videoanalyse erreichten wir ein F1-Score von 0.91. Ein Ergebniss welches zu einer wissenschaftlichen Veröffentlichung (Globisch et al. 2024) geführt hat.

Identifikation Optimierungspotenzial der KI-Methoden

Zentrale Herausforderungen betrafen verrauschte und unscharfe Bilder sowie geringe Lichtverhältnisse. Als zukünftiges Arbeitsfeld wurde die Integration self-supervised Lernverfahren und datenschutzkonformes KI-Training identifiziert.

Chowdhury, Rohit; Subramani, Deepak (2022): Optimal Path Planning of Autonomous Marine Vehicles in Stochastic Dynamic Ocean Flows Using a GPU-Accelerated Algorithm. In: *IEEE J. Oceanic Eng.* 47 (4), S. 864–879. DOI: 10.1109/JOE.2022.3152514.

Gao, Fan; Moltu, Signe B.; Vollan, Erlend R.; Shen, Shuyuan; Ludvigsen, Martin (2020): Increased Autonomy and Situation Awareness for ROV Operations. In: Global Oceans 2020: Singapore – U.S. Gulf Coast. Global Oceans 2020: Singapore - U.S. Gulf Coast. Biloxi, MS, USA, 05.10.2020 - 30.10.2020: IEEE, S. 1–8.

Guo, Jia; Hou, Yuanhang; Liang, Xiao; Yang, Hongyu; Xiong, Yeping (2022): Mission-driven path planning and design of submersible unmanned ship with multiple navigation states. In: *Ocean Engineering* 263, S. 112363. DOI: 10.1016/j.oceaneng.2022.112363.

Hua, Chenhua; Wu, Nailong; Yuan, Haodong; Chen, Xinyuan; Dong, Yuqin; Zeng, Xianhui (2022): Time-Optimal Path Planning of a Hybrid Autonomous Underwater Vehicle Based on Ocean Current Neural Point Grid. In: *JMSE* 10 (7), S. 977. DOI: 10.3390/jmse10070977.

Huang, Bolun; Yang, Qi (2022): Disturbance Observer-Based Double-Loop Sliding-Mode Control for Trajectory Tracking of Work-Class ROVs. In: *JMSE* 10 (5), S. 601. DOI: 10.3390/jmse10050601.

Potokar, Easton; Ashford, Spencer; Kaess, Michael; Mangelson, Joshua G.: HoloOcean: An Underwater Robotics Simulator. In: 2022 International Conference on Robotics and Automation (ICRA). 2022 IEEE International Conference on Robotics and Automation (ICRA). Philadelphia, PA, USA, 5/23/2022 - 5/27/2022: IEEE, S. 3040–3046.

Sahoo, Sarada Prasanna; Das, Bikramaditya; Pati, Bibhuti Bhusan; Dash, Rudra Narayan (2023): Obstacle Avoidance for a Swarm of AUVs. In: Rudra Narayan Dash, Akshay Kumar Rathore, Vinod Khadkikar, Ranjeeta Patel und Manoj Debnath (Hg.): Smart technologies for power and green energy. Proceedings of STPGE 2022, Bd. 443. Singapore: Springer (Lecture Notes in Networks and Systems, 443), S. 415–421.

T. Globisch, A. Umlauft, S. Lüdtke and U. F. Von Lukas, "sMarT RCI - Unsupervised Double K-Means Ensemble Clustering Tool for Remotely Operated Vehicle Camera Images," *OCEANS 2024 - Halifax*, Halifax, NS, Canada, 2024, pp. 1-10, doi: 10.1109/OCEANS55160.2024.10754492