

Sachbericht zum Verwendungsnachweis

Teil I: Kurzbericht

Verbundname:

Künstliche Intelligenz für die Hochwasserwarnung

Teilvorhaben:

Künstliche Intelligenz für die Abflussvorhersage und Gewässerbeobachtung

Projektleitung:

Prof. Dr. Niels Schütze
Technische Universität Dresden
Professur Hydrologie
01062 Dresden
Tel: +49 351 463 36380
Niels.Schuetze@tu-dresden.de

Autor:

Dr. Jens Grundmann
jens.grundmann@tu-dresden.de
Tel: +49 351 463 35556

Förderhinweis:

Das Vorhaben wurde im Rahmen der Bekanntmachung „Künstliche Intelligenz in der zivilen Sicherheitsforschung“ vom Bundesministerium für Bildung und Forschung (BMBF) gefördert.

Laufzeit: 01.04.2021 – 31.03.2024

Förderkennzeichen: 13N15542

Hintergrund

Die Bewältigung von Naturkatastrophen, speziell von Starkregen und Hochwasser, stellt besondere Anforderungen an die Einsatzkräfte des Katastrophenschutzes. Diese resultieren aus der Tatsache, dass Vorhersagen der Niederschlagsmengen in ihrer zeitlichen und räumlichen Verteilung nicht exakt möglich sind und somit die Einsatzorte und Maßnahmen der Katastrophenabwehr schnell wechseln können. Deshalb ist aus Sicht von Einsatzleitungen eine ausreichende Vorwarnzeit wünschenswert, um „vor die Lage“ zu kommen und Handlungsoptionen besser abschätzen und bewerten zu können. Speziell in kleinen und schnell reagierenden Flussgebieten können die Auswirkungen der Extremniederschläge auf die Wasserführung der Fließgewässer nur mit Hilfe von Simulationen ermittelt werden. Andererseits sind im Hochwasserfall Beobachtungen der Fließgewässer für ein möglichst genaues Lagebild notwendig, damit geeignete Maßnahmen der Hochwasserabwehr ergriffen bzw. deren Wirksamkeit geprüft werden kann. Überwachungskameras können hierbei unterstützen, wobei neben dem visuellen Eindruck eine Quantifizierung konkreter Messwerte wünschenswert wäre.

Zielstellung

Vor diesem Hintergrund zielte das Teilvorhabenvorhaben der TU Dresden auf die Erforschung und Entwicklung auf Künstlicher Intelligenz (KI) basierender Werkzeuge, um Einsatzkräften und Einsatzleitungen des Katastrophenschutzes bei der Bewältigung von Großschadenslagen zu unterstützen. Zu diesen Werkzeugen zählen datengetriebene Niederschlags-Abfluss-Modelle, die das Verhalten der Einzugsgebiete emulieren und im Ereignisfall Niederschläge aus unterschiedlichen Datenquellen (Ensembleprognosen, Kurzfristvorhersagen, Beobachtungen) schnell und robust für eine frühzeitige Abflussvorhersage und Warnung verarbeiten können. Weiterhin werden KI-basierte Algorithmen für die bildbasierte, robuste Quantifizierung von Wasserständen, Fließgeschwindigkeiten und Durchflüssen aus Kamerabildern und Filmsequenzen zur Beobachtung der Fließgewässer entwickelt, die einen unüberwachten und mobilen Betrieb der Kameras ermöglichen. Die KI's werden im Teilvorhaben des Projektpartners Fraunhofer IVI in einen Demonstrator zur Einsatzführung und Gewässerüberwachung integriert. Durch die Zusammenarbeit mit den assoziierten Partnern aus der Praxis werden deren Anforderungen an den KI-basierten Demonstrator erhoben sowie dessen Akzeptanz geprüft.

Arbeitsablauf

Das Verbundvorhaben war in 4 Arbeitspakete untergliedert. Alle Arbeitspakete wurden gemeinsam mit dem Projektpartner Fraunhofer IVI bearbeitet, wobei das Teilvorhaben der TU Dresden für die Arbeitspakete 2 und 3 die Leitung innehatte. Partner im Teilvorhaben der TU Dresden waren die Professur für Hydrologie (gleichzeitig Verbundkoordinator) und die Juniorprofessur für Geosensorsysteme. Die Arbeitspakete (AP) umfassten folgende Inhalte: AP(1) „Anforderungsanalyse und Datengewinnung“ – Hier wurden die Anforderungen an die Entwicklung der KI's entsprechend des Standes von Wissenschaft und Technik zum Projektstart aktualisiert sowie der Aufbau der erforderlichen technischen Infrastruktur für eine kontinuierliche Datenerhebung während der Projektlaufzeit vorgenommen. In AP(2) „Entwicklung der KI's“ wurden die Methoden entwickelt und in AP(3) „Generalisierung der KI's“ auf ihre Übertragbarkeit, Robustheit und Extrapolationsfähigkeit geprüft und entsprechend verfeinert. In AP(4) „Demonstration und Evaluierung“ erfolgte die Operationalisierung der KI's sowie die Entwicklung von Schnittstellen zur Integration der KI's in einen funktionsfähigen Demonstrator.

Ergebnisse

Im Ergebnis des Teilvorhabens wurde (1) ein KI-basiertes Verfahren für eine vollständig optische Messung von Zeitreihen des Wasserstandes und des Durchflusses aus Einzelbildern und kurzen Videosequenzen entwickelt sowie (2) eine KI für die Vorhersagen von Abflüssen in kleineren und mittleren Einzugsgebieten.

Das KI-basierte Verfahren für die optische Messung (1) beinhaltet mehrere Verfahrensschritte. Grundlage ist die Erarbeitung von hochpräzisen, georeferenzierten 3D-Geländemodellen der Messstellenumgebung und des Flussbettes in Zentimetergenauigkeit. Hierfür wurde die Structure-from-Motion (SfM)-Technik eingesetzt, bei der Kamerabilder der Messstellenumgebung aus verschiedenen Perspektiven zu einem 3D-Modell verarbeitet werden. Gelingen dabei auch Aufnahmen der Gewässersohle, können unter Berücksichtigung der Lichtbrechung auch die Unterwasserbereiche rekonstruiert werden. Für die Wasserstandsmessung aus Kamerabildern wurde eine KI entwickelt, die die Wasserfläche im Bild automatisiert detektiert und segmentiert. Die segmentierte Wasserfläche wird anschließend mit dem 3D-Geländemodell für die Messung des Wasserstandes verschnitten. Der Langzeitbetrieb der Kameras zeigte, dass die Kameras in ihrer äußeren Position und Orientierung und der inneren Geometrie über die Zeit nicht hinreichend stabil sind, was zu zunehmenden Messungenauigkeiten im Vergleich zur Referenz führte. Deshalb wurde ein Algorithmus entwickelt, der ebenfalls KI-basiert Passpunkte in den Kamerabildern automatisiert detektiert, um die Kameraposition für jede Messung neu zu bestimmen. Zur Ermittlung der Durchflussmenge wird zunächst die Fließfläche aus der Verschneidung des Wasserstandes mit dem 3D-Geländemodell abgeleitet. Als weitere Eingangsgröße dient die Oberflächengeschwindigkeit, welche anhand kurzer Videosequenzen mit der FlowVelo-Toolbox und dem darin implementierten Partikel Tracking Verfahren (PTV) bestimmt wird. Die zuvor KI-basiert segmentierte Wasserfläche dient dabei als Suchraum für die Partikeldetektion. Allerdings ist das Vorhandensein verfolgbarer Partikel auf der gesamten Fließbreite des Gewässers nicht zu allen Jahreszeiten, Abflussverhältnissen, Licht- und Sichtbedingungen gegeben, was zu Messlücken führt. Um kontinuierliche Durchflussganglinien aus den PTV-Messungen zu erhalten, wurde der Modellansatz „OptiQ“ entwickelt, ein statistischer Ansatz, der aus zurückliegenden Messungen lernt und Datenlücken schließen kann. Die Methoden wurden an drei Messpegeln des Projektpartners BfUL entwickelt und hinsichtlich ihrer Übertragbarkeit getestet. Die optischen Messwerte zeigen eine sehr gute Übereinstimmung mit den Referenzmesswerten der Messstellen, auch unter schwierigen Beobachtungsbedingungen und auch nachts, unterstützt durch einen Infrarot-Strahler. Anhand des Standortes in Neukirch konnte eine Übertragung der Methoden auf einen bisher unbeobachteten Standort nachgewiesen werden. Ebenso konnte die Eignung der KI für den operationellen Betrieb nachgewiesen werden. Die Kameras liefern jede 15 min ein neues Bild woraus durch die KI in nahe Echtzeit eine Messung des Wasserstandes erfolgt. Diese aktuellen Messdaten werden über eine entwickelte Schnittstelle an das Kamera-Dashboard des Projektpartners Fraunhofer IVI weitergeleitet und den Nutzern zur Verfügung gestellt.

Für die KI-basierte Abflussvorhersage (2) wurde ein regionales KI-Modell zur Transformation des Niederschlags in Abfluss entwickelt. Damit lassen sich die Auswirkungen prognostizierter Extremniederschläge auf die Abflusssituation in den Fließgewässern vorhersagen. Insgesamt wurden 52 Gebiete in Sachsen mit ihren Beobachtungsdaten und Gebietsmerkmalen in die Entwicklung der regionalen KI einbezogen. Eine derartige Vergrößerung des Trainingsdatensatzes führte letztendlich zu robusteren und zuverlässigeren Vorhersagen gegenüber einem gebietsweisen Ansatz. Zudem erwies sich die KI auf hydrologisch ähnliche Gebiete übertragbar, die nicht in den Trainingsdaten enthalten waren. Mit dem aktuellen Setup der regionalen KI werden, basierend auf stündlichen Beobachtungen des Niederschlags und des Durchflusses, Vorhersagen mit einer Vorhersageweite von bis zu 24 Stunden erzielt. Die regionale KI erlaubt zudem die schnelle und robuste Verarbeitung von Ensemble-Niederschlagsvorhersagen, wodurch eine Durchflussvorhersage mit Angabe der Unsicherheit / Zuverlässigkeit möglich wird. Die KI wurde in ein hydrologisches Ensemblevorhersagesystem integriert, das stündlich neue Vorhersagen liefert und von den Nutzern in einem Webdemonstrator „Hochwasserfrühwarnung mit Künstlicher Intelligenz (KI)“ mit verfolgt werden kann (<http://howa-innovativ.hydro.tu-dresden.de/WebDemoKiwa/>). Zudem wurde eine Schnittstelle zur Einsatzführungssoftware Mobikat des Projektpartners Fraunhofer IVI entwickelt, die neben den Vorhersagen von Niederschlag und Abfluss eine Verlinkung zu den zugehörigen Hochwasser-Gefahrenkarten ermöglicht.

Sachbericht zum Verwendungsnachweis

Teil II: Eingehende Darstellung

Verbundname:

Künstliche Intelligenz für die Hochwasserwarnung

Teilvorhaben:

Künstliche Intelligenz für die Abflussvorhersage und Gewässerbeobachtung

Projektleitung:

Prof. Dr. Niels Schütze
Technische Universität Dresden
Professur Hydrologie
01062 Dresden
Tel: +49 351 463 36380
Niels.Schuetze@tu-dresden.de

Autoren:

Dr. Jens Grundmann, JProf. Anette Eltner, Dr. Xabier Blanch, Tanja Morgenstern, André Kutscher
Kontakt: jens.grundmann@tu-dresden.de, Tel: +49 351 463 35556

Förderhinweis:

Das Vorhaben wurde im Rahmen der Bekanntmachung „Künstliche Intelligenz in der zivilen Sicherheitsforschung“ vom Bundesministerium für Bildung und Forschung (BMBF) gefördert.

Laufzeit: 01.04.2021 – 31.03.2024

Förderkennzeichen: 13N15542

Inhalt

| | |
|---|----|
| 1. Zielstellung des Projektes und des Teilvorhabens | 4 |
| 2. Arbeitsplanung des Projektablaufs..... | 5 |
| 3. Ergebnisübersicht des Teilvorhabens | 6 |
| 4. Ausführliche Darstellung der Arbeiten..... | 7 |
| 4.1. Datengewinnung für die Projektbearbeitung | 7 |
| 4.1.1. Daten für die Optische Messung | 7 |
| 4.1.1.1. Messstellenkonzept für die Datenerhebung | 7 |
| 4.1.1.2. Kamerastandorte..... | 7 |
| 4.1.1.3. Erarbeitung von hochauflösten 3D-Geländemodellen | 9 |
| 4.1.1.4. Referenzmessungen | 10 |
| 4.1.2. Daten für die KI zur Vorhersage des Niederschlags-Abfluss Prozesses..... | 11 |
| 4.1.2.1. Auswahl der Einzugsgebiete | 11 |
| 4.1.2.2. Zeitreihendaten | 11 |
| 4.2. Entwicklung der KI's | 12 |
| 4.2.1. Optische Messung des Wasserstandes | 12 |
| 4.2.1.1. Zielstellung | 12 |
| 4.2.1.2. KI für die Segmentierung der Wasserflächen..... | 12 |
| 4.2.1.3. Ermittlung des Wasserstandes | 13 |
| 4.2.1.4. KI für die Passpunkterkennung | 15 |
| 4.2.2. Optische Bestimmung des Durchflusses..... | 16 |
| 4.2.2.1. Zielstellung | 16 |
| 4.2.2.2. Messung der Oberflächengeschwindigkeit mit Particle Tracking Velocimetry | 17 |
| 4.2.2.3. Durchflussermittlung aus Messungen der Oberflächenfließgeschwindigkeit..... | 19 |
| 4.2.2.4. Die OptiQ-Methode zur Durchflussbestimmung | 21 |
| 4.2.3. KI für die Simulation des Niederschlag-Abfluss-Prozesses..... | 24 |
| 4.2.3.1. Zielstellung | 24 |
| 4.2.3.2. Vorverarbeitung der Daten | 24 |
| 4.2.3.3. Methodik für die Entwicklung der KI-NAP..... | 25 |
| 4.2.3.4. Ergebnisse | 27 |
| 4.3. Generalisierung der KI's für den robusten Einsatz..... | 29 |
| 4.3.1. Optische Bestimmung des Wasserstandes..... | 29 |
| 4.3.1.1. Zielstellung | 29 |
| 4.3.1.2. Messung bei Dunkelheit | 30 |

| | | |
|----------|---|----|
| 4.3.1.3. | Ergebnisse für die Messstellen Typ A | 30 |
| 4.3.1.4. | Übertragung und Test an Messstellen Typ B..... | 33 |
| 4.3.1.5. | Fazit | 33 |
| 4.3.2. | Optische Bestimmung des Durchflusses..... | 34 |
| 4.3.2.1. | Zielstellung | 34 |
| 4.3.2.2. | Messung bei Dunkelheit..... | 34 |
| 4.3.2.3. | Wasserstandsabhängiger Geschwindigkeitsindexbeiwert | 34 |
| 4.3.2.4. | Ergebnisse für die Messstellen Typ A (Pegelstandorte) | 35 |
| 4.3.2.5. | Übertragung und Test an Messstellen Typ B..... | 37 |
| 4.3.2.6. | Fazit | 38 |
| 4.3.3. | KI für die Simulation des Niederschlag-Abfluss-Prozesses..... | 38 |
| 4.3.3.1. | Zielstellung | 38 |
| 4.3.3.2. | Datenvorverarbeitung | 38 |
| 4.3.3.3. | Regionale KI-Modelle | 39 |
| 4.3.3.4. | Ergebnisse | 40 |
| 4.3.3.5. | Regionales KI-NAP Vorhersagemodell..... | 42 |
| 4.3.3.6. | Fazit | 43 |
| 4.4. | Demonstration und Evaluierung..... | 44 |
| 4.4.1. | Operationalisierung..... | 44 |
| 4.4.2. | Schnittstellen zum Projektpartner Fraunhofer IVI | 46 |
| 4.4.3. | Workshops, Konsultationen und Austausch mit den Anwendern..... | 48 |
| 5. | Anhang..... | 49 |
| 5.1. | Wichtigste Positionen des zahlenmäßigen Nachweises..... | 49 |
| 5.2. | Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten | 49 |
| 5.3. | Voraussichtlicher Nutzen und Verwertbarkeit des Ergebnisses..... | 49 |
| 5.4. | Während der Durchführung des Vorhabens dem Zuwendungsempfänger bekannt gewordener Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen | 51 |
| 6. | Literatur | 52 |
| 7. | Publikationen | 53 |

1. Zielstellung des Projektes und des Teilvorhabens

Die Bewältigung von Naturkatastrophen, speziell von Starkregen und Hochwasser, stellt besondere Anforderungen an die Einsatzkräfte des Katastrophenschutzes. Diese resultieren aus der Tatsache, dass Vorhersagen der Niederschlagsmengen in ihrer zeitlichen und räumlichen Verteilung nicht exakt möglich sind und somit die Einsatzorte und Maßnahmen der Katastrophenabwehr schnell wechseln können. Deshalb ist aus Sicht von Einsatzleitungen eine ausreichende Vorwarnzeit wünschenswert, um „vor die Lage“ zu kommen und Handlungsoptionen besser abschätzen und bewerten zu können. Andererseits sind im Hochwasserfall Beobachtungen der Fließgewässer für ein möglichst genaues Lagebild notwendig, damit geeignete Maßnahmen der Hochwasserabwehr ergriffen bzw. deren Wirksamkeit geprüft werden kann. Diese Beobachtung sollte möglichst auch eine Messung beinhalten, die von den Einsatzkräften gefahrlos durchgeführt werden kann. Vor diesem Szenario zielte das Vorhaben auf die Entwicklung und Demonstration von KI-basierten Werkzeugen für die Hochwasserwarnung und Beobachtung, um Einsatzleitungen des Katastrophenschutzes beim Bewältigen von Großschadenslagen infolge von Starkregen und Hochwasser zu unterstützen. Im Teilvorhaben der TU Dresden wurden dazu folgende Entwicklungen durchgeführt:

- Die Entwicklung einer KI zur Simulation von Niederschlags-Abfluss-Prozessen (KI-NAP), die das Verhalten der Einzugsgebiete emulieren und im Ereignisfall Niederschläge aus unterschiedlichen Datenquellen (Ensembleprognosen, Kurzfristvorhersagen, Beobachtungen) schnell und robust für eine frühzeitige Durchflussprognose und Warnung verarbeiten können;
- Die Entwicklung einer KI-basierten, automatisierten Wasserstandserkennung aus Kamerabildern (KI-W), die basierend auf der robusten und eindeutigen Unterscheidung von Wasserflächen und Uferbereichen eine Messung des Wasserstandes erlaubt;
- Die Entwicklung eines Verfahrens zur Bestimmung der Durchflussmenge für Fließgewässer mit KI-Unterstützung (KI-Q) aus kurzen Videosequenzen, die auch unter schwierigen Beobachtungsbedingungen funktionieren sollte.

In Zusammenarbeit mit dem Teilvorhaben: „Demonstration und Evaluierung“ des Projektpartners Fraunhofer IVI wurden die KI's in einen Demonstrator zur Einsatzführung und Überwachung integriert. Dieser beinhaltet ein Kamera-Dashboard mit aktuellen Messwerten der KI-(W/Q) und projizierten zukünftigen Wasserständen aus den Vorhersagen (KI-NAP) sowie die Verknüpfung der Vorhersagen (KI-NAP) mit Überschwemmungsflächen aus den Hochwassergefahrenkarten für die Einsatzführung mit dem Fraunhofer-System MobiKat. Durch die Zusammenarbeit mit den assoziierten Partnern aus der Praxis wurden deren Anforderungen an den KIWA-Demonstrator erhoben sowie dessen Akzeptanz geprüft. Das Verbundvorhaben wurde von folgenden assoziierten Partnern unterstützt, denen wir an dieser Stelle nochmals ausdrücklich danken möchten.

- Staatliche Betriebsgesellschaft für Umwelt und Landwirtschaft des Freistaats Sachsen (BfUL)
- Landeshochwasserzentrum Sachsen (LHWZ)
- Landkreise Sächsische Schweiz-Osterzgebirge, Bautzen und Görlitz mit den zuständigen Referaten für Katastrophenschutz (KatS).

2. Arbeitsplanung des Projektablaufs

Das Verbundvorhaben war in 4 Arbeitspakete untergliedert, die in Abbildung 1 dargestellt sind. Alle Arbeitspakete wurden gemeinsam mit dem Projektpartner Fraunhofer IVI bearbeitet, wobei das Teilvorhaben der TU Dresden für die Arbeitspakete 2 und 3 die Leitung innehatte. Partner im Teilvorhaben der TU Dresden waren die Professur für Hydrologie (gleichzeitig Verbundkoordinator) und die Juniorprofessur für Geosensorsysteme.

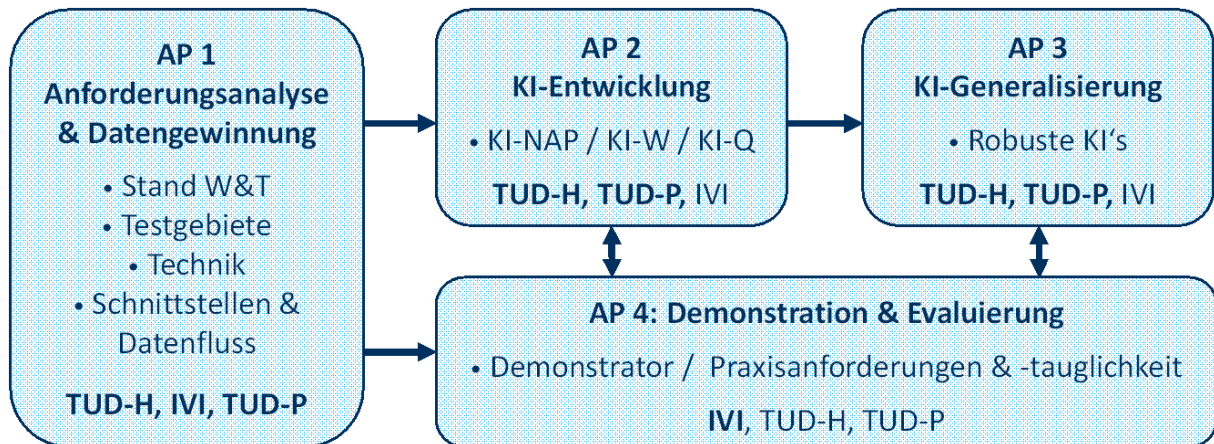


Abbildung 1: Projektstruktur, Verknüpfung der Arbeitspakete und Verantwortlichkeiten

Das Vorhaben war auf eine Laufzeit von 36 Monaten ausgelegt. Ausgehend von einer Anforderungsanalyse und der Schaffung der technischen Voraussetzungen für die Datengewinnung wurden die Methoden für die Entwicklung und Generalisierung der KI's erarbeitet. Abschließend erfolgte die Operationalisierung der KI's sowie die Entwicklung von Schnittstellen zur Integration der KI's in einen funktionsfähigen Demonstrator. Das damit einhergehende Nutzerfeedback führte zu einer weiteren Verfeinerung der Methoden. Für die Projektbearbeitung wurden die Arbeitspakete in Teil-Arbeitspakete untergliedert und entsprechend des Balkenplans in Tabelle 1 abgearbeitet. Die Ergebnisse der Arbeitspakete werden im folgenden Kapitel vorgestellt.

Tabelle 1: Balkenplan des Projektablaufs für das Teilvorhaben

| AP | Aktivitäten /Projektmonat | 3 | 6 | 9 | 12 | 15 | 18 | 21 | 24 | 27 | 30 | 33 | 36 |
|----------|--|---|-----|-----|-----|----|-----|----|----|----|-----|----|------|
| 1 | Anforderungsanalyse und Datengewinnung | ■ | ■ 1 | | | | | | | | | | |
| 1.1 | Revision Stand von Wissenschaft und Technik | ■ | | | | | | | | | | | |
| 1.2 | Standorte und Gebiete | ■ | ■ 2 | | | | | | | | | | |
| 1.3 | Messtechnik und Datenfluss | ■ | | ■ 3 | | | | | | | | | |
| 2 | KI-Entwicklung | | | ■ | ■ | ■ | ■ | | | | | | |
| 2.1 | Datenakquise | | | ■ | ■ | ■ | ■ | | | | | | |
| 2.2 | Datenvorverarbeitung für KI-Entwicklung | | | ■ | ■ 4 | | | | | | | | |
| 2.3 | Training, Validierung und Tests der KI's | | | | ■ | ■ | ■ 5 | | | | | | ■ 11 |
| 3 | KI-Generalisierung | | | | | | | ■ | ■ | ■ | ■ | | |
| 3.1 | Datenakquise | | | | | | | ■ | ■ | ■ | ■ | | |
| 3.2 | Datenvorverarbeitung für KI's | | | | | | | ■ | ■ | ■ | ■ | | |
| 3.3 | Übertragbarkeit & Extrapolationsverhalten KI-NAP | | | | | | | | | | ■ 6 | | |
| 3.4 | Übertragbarkeit & robuste Beobachtung KI-W/Q | | | | | | | | | | ■ 7 | | ■ 11 |
| 4 | Demonstration und Evaluierung | | ■ | ■ | ■ | ■ | ■ | ■ | ■ | ■ | ■ | ■ | ■ |
| 4.1 | Anwenderworkshops | | ■ | ■ | ■ | ■ | ■ | ■ | ■ | ■ | ■ | ■ | ■ |
| 4.2 | technisches Design für Demonstrator | | | ■ | ■ | ■ | ■ | ■ | ■ | ■ | ■ | | |
| 4.4 | Evaluierung und KI-Update-Routinen | | | | | | | ■ | ■ | ■ | ■ | ■ | ■ 11 |

3. Ergebnisübersicht des Teilvorhabens

Im Ergebnis des Teilvorhabens wurde ein KI-basiertes Verfahren für eine vollständig optische Messung von Zeitreihen des Wasserstandes und des Durchflusses aus Einzelbildern und kurzen Videosequenzen entwickelt sowie eine KI für die Vorhersagen von Durchflüssen in kleineren und mittleren Einzugsgebieten. Abbildung 2 illustriert den Arbeitsablauf für die vollständig optische Messung ausgehend von der Topografie der Messstelle bis zur Ermittlung des Durchflusses. Verdeutlicht wird dabei zum einen der Zusammenhang zwischen den einzelnen hydraulisch/hydrologischen Messgrößen und zum anderen die Vernetzung zwischen den KI-Entwicklungen. Einzelheiten können den Kapiteln 4.2.1, 4.2.2, 4.3.1 und 4.3.2 entnommen werden.

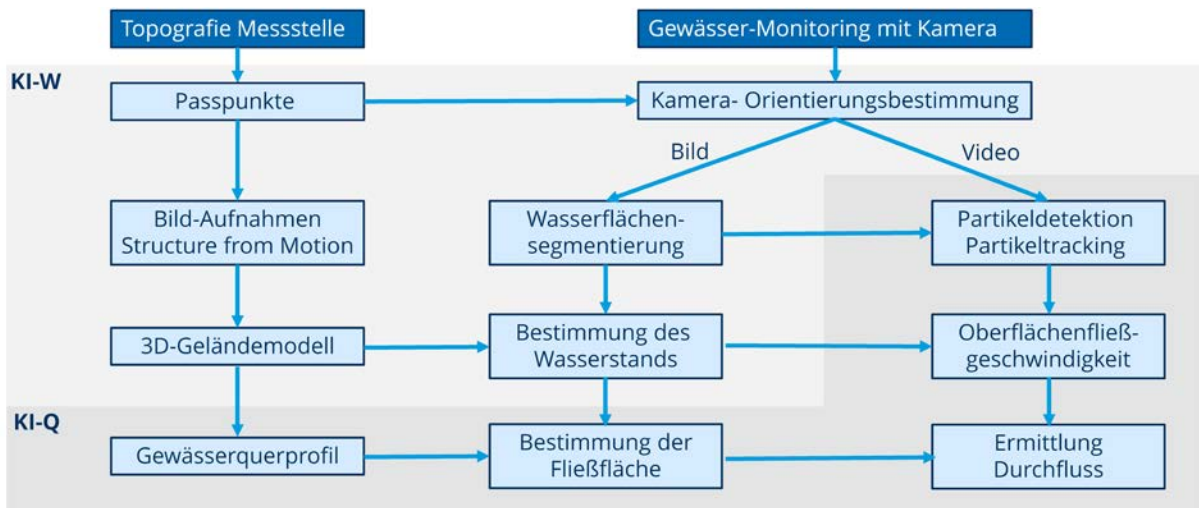


Abbildung 2: Arbeitsablauf für eine vollständig optische Messung

Abbildung 3 zeigt einen Ausschnitt des webbasierten KI-NAP-Demonstrators für die Durchfluss-Ensemblevorhersage inklusive Unsicherheitsangabe (siehe Kapitel 4.4.1). Die Entwicklungsschritte der KI-NAP sind in den Kapiteln 4.2.3 und 4.3.3 beschrieben.

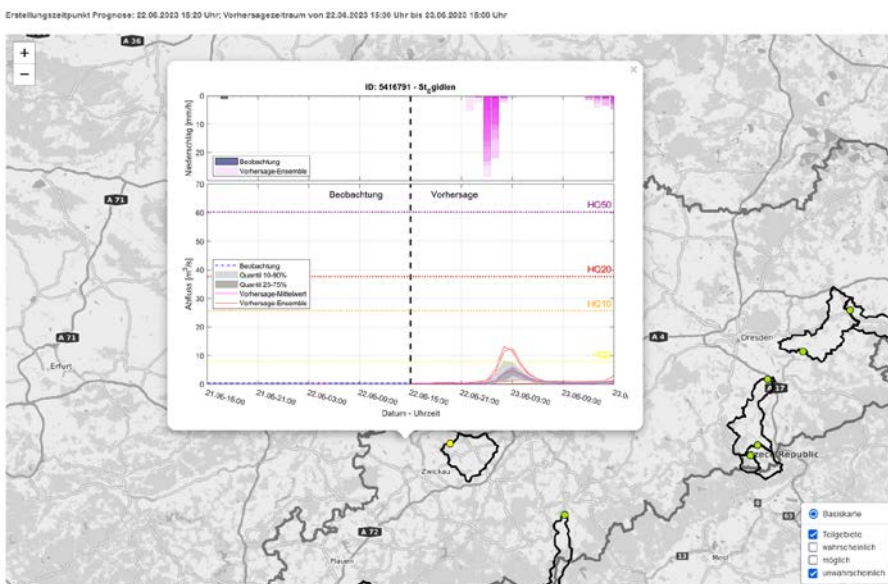


Abbildung 3: Ausschnitt des webbasierten KI-NAP-Demonstrators für die Ensemblevorhersage des Durchflusses inklusive Unsicherheitsangabe

4. Ausführliche Darstellung der Arbeiten

4.1. Datengewinnung für die Projektbearbeitung

4.1.1. Daten für die Optische Messung

4.1.1.1. Messstellenkonzept für die Datenerhebung

Für die Entwicklung und die Generalisierung der KI zur bildbasierten Ableitung hydrologischer Größen (KI-W, KI-Q) werden Einzelbilder und kurze Videosequenzen von Fließgewässern mit Uferlinien zu unterschiedlichen Abflusszuständen benötigt. Weiterhin müssen für die Methodenentwicklung und Verifizierung unabhängige Beobachtungen hydrologischer Messwerte vorliegen. Deshalb wurde für die Entwicklung der KI-W/Q ein Messstellenkonzept verwendet, das den unterschiedlichen Phasen der Projektbearbeitung Rechnung trägt:

Messstelle Typ A: Dabei handelt es sich um Messnetzpegel mit langjährigen Wasserstands- und Durchflussmessungen des assoziierten Projektpartners BfUL. Diese wurden zu Projektbeginn mit Kamerasystemen ergänzt, die jede 15 min ein neues Einzelbild und eine Videosequenz von 10 s aufzeichnen. Zusätzlich wurden ausgewählte Messpegel im Projektverlauf mit Infrarot-(IR-)Strahlern nachgerüstet, um die Nachtsicht zu verbessern. Die Messstellen des Typ A dienen vor allem der Methodenentwicklung der KI's und ersten Tests zu deren Übertragbarkeit.

Messstelle Typ B: Hierbei handelt es sich um ausgewählte Hochwasserkameras des Projektpartners Fraunhofer IVI, die bereits langjährig für lokale Einsatzkräfte des Katastrophenschutzes im Einsatz sind. Diese wurden für die Projektbearbeitung ertüchtigt (Aufzeichnung von Videosequenzen, ggf. zusätzliche Ausrüstung mit Wasserstandsmesssystem) und dienen der Methodenentwicklung der KI's in Bezug auf Übertragbarkeit und Robustheit.

Messstelle Typ C: Diese werden als „Hochwasserkameras KIWA“ bezeichnet und repräsentieren die Entwicklungsarbeiten im Projekt für die Hochwasserbeobachtung mit stationären und mobilen Kameras. Sie wurden für Teststellungen mit unterschiedlichen Einsatzszenarien entwickelt und dienen dem Methodentransfer der KI-W/Q auf neue Standorte.

4.1.1.2. Kamerastandorte

Insgesamt wurden 7 Standorte für die Projektbearbeitung ausgewählt und ertüchtigt, deren Lage Abbildung 4 zu entnehmen ist. An diesen Standorten wurden Überwachungskameras der Firma AXIS installiert, die eine integrierte Lösung für die Aufnahme und Speicherung von Einzelbildern und Videos sowie deren Versendung zu einem Datenserver bieten. Abbildung 5 illustriert den Installationsort an den drei Messpegeln (Messstelle Typ A). Abbildung 6 zeigt den Bildausschnitt, der von den jeweiligen Kameras aufgezeichnet wird. Neben den drei Messpegeln (Messstelle Typ A - rot eingrahmt) wurden vier Messstellen vom Typ B ausgewählt. Tabelle 2 fasst die wesentlichen Daten zu den Kameras und ihren Standorten zusammen.

Tabelle 2: Kameradaten der Standorte

| Standort | Gewässer | Kameratyp | Auflösung | Pixelgröße | Linse | Zoomtyp | IR-Strahler | Typ |
|---------------|-------------|-------------------|-------------|------------|--------------|-------------|-------------|-----|
| Elbersdorf | Wesenitz | AXIS Q1645-LE | 1920 x 1080 | 3.75 µm | 3.9 - 10 mm | automatisch | ja | A |
| Großröhrsdorf | Große Röder | AXIS Q1645-LE | 1920 x 1080 | 3.75 µm | 12 - 50 mm | manuell | nein | B |
| Heidenau | Müglitz | AXIS Q1615 Mk III | 1920 x 1080 | 2.90 µm | 2.8 - 8.5 mm | automatisch | nein | B |
| Neukirch | Wesenitz | AXIS Q1615 Mk III | 1920 x 1080 | 2.90 µm | 2.8 - 8.5 mm | automatisch | ja | B |
| Lauenstein | Müglitz | AXIS Q1645-LE | 1920 x 1080 | 3.75 µm | 3.9 - 10 mm | automatisch | ja | A |
| Großschönau | Mandau | AXIS Q1645-LE | 1920 x 1080 | 3.75 µm | 3.9 - 10 mm | automatisch | nein | A |
| Zittau | Neiße | AXIS Q1615 Mk III | 1920 x 1080 | 2.90 µm | 2.8 - 8.5 mm | automatisch | nein | B |

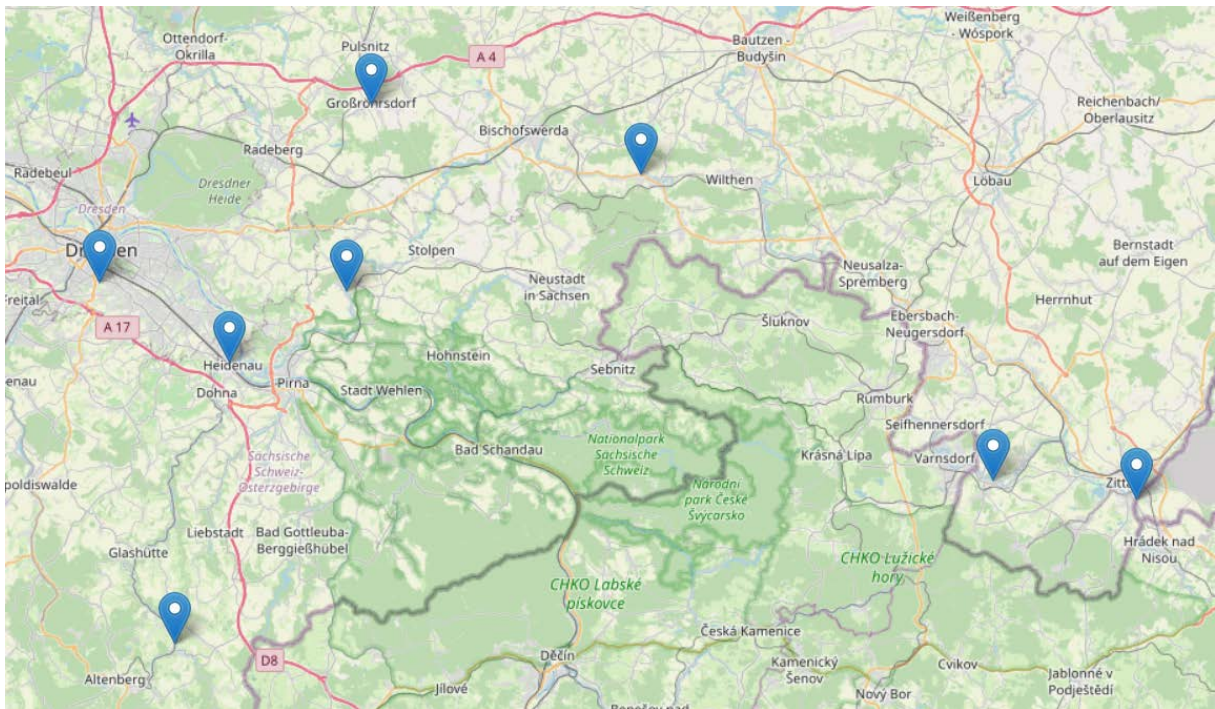


Abbildung 4: Lage der Kamerastandorte



Abbildung 5: Montageorte der Kameras an den Messpegeln (Messstelle Typ A)

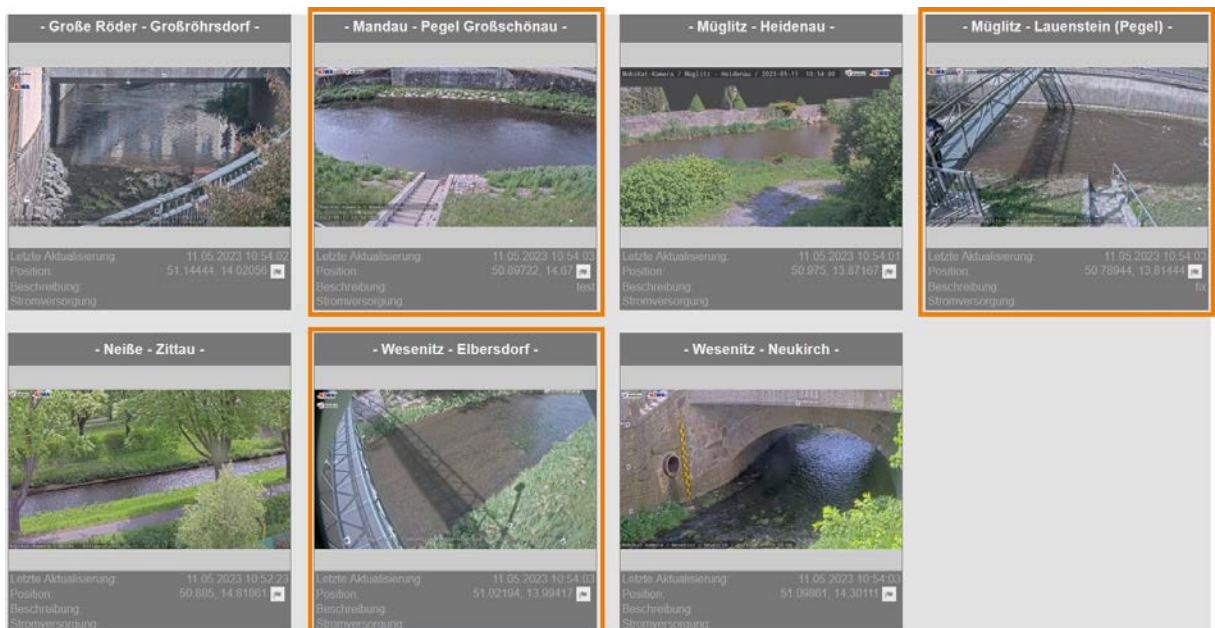


Abbildung 6: Bildausschnitte der Kameras an den Messstellen Typ A (oranger Rahmen) und Typ B

4.1.1.3. Erarbeitung von hochaufgelösten 3D-Geländemodellen

Die Umgebung der Kamerastandorte in Abbildung 6 wurde für die optische Messung vorbereitet. Dazu zählen das Anbringen von Passpunkten, um Bewegungen der Kamera im Bild detektieren zu können, sowie die Erarbeitung von hochpräzisen, georeferenzierten 3D-Geländemodellen der Messstellenumgebungen und der Flussbetten in Zentimetergenauigkeit. Hierfür wurden lediglich eine Fotokamera und ein GNSS-Empfänger eingesetzt, wobei die Aufnahme der Fotos einerseits mit einer Drohne und andererseits zu Fuß durch Umlaufen der Gewässerabschnitte erfolgte. Zur Georeferenzierung der 3D-Modelle wurden zusätzliche Passpunkte, d.h. markierte Punkte mit bekannten 3D-Koordinaten des Zielkoordinatensystems, gesetzt. Die Passpunkte wurden mit cm-Genauigkeit mittels RTK-GNSS vermessen. Zur Berechnung der 3D-Modelle kamen photogrammetrische 3D-Rekonstruktionsalgorithmen zum Einsatz. Konkret wurde das Verfahren Structure-from-Motion (SfM) eingesetzt, das die automatische Bestimmung der Kamerapositionen sowie von 3D-Punkten basierend auf geometrischen Prinzipien erlaubt. Die Bathymetrie der Gewässer wurde mit Hilfe von Mehrmedienphotogrammetrie bestimmt, d.h. der Unterwasserbereich wurde unter Berücksichtigung von Refraktionseinflüssen korrigiert. Um die Güte der erzielten Modellergebnisse über Wasser bewerten zu können, wurde exemplarisch am Pegel Elbersdorf ein digitales Modell mittels terrestrischem Laserscanning (LiDAR) erstellt. Abbildung 7 zeigt im linken Teil den LiDAR-Datensatz und im roten Rechteck die Testfläche zur Untersuchung der Punktabweichung LiDAR – SfM-Modell. Bei der Testfläche handelt es sich um eine senkrechte Mauer, die am Fuß in einen gepflasterten, schrägen Böschungsabschnitt übergeht. Die Differenzen zwischen LiDAR und SfM sind im rechten Teil von Abbildung 7 dargestellt und zusätzlich am rechten Rand in Form eines Histogramms illustriert. Der Mittelwert der Differenzen liegt bei ca. 5 mm, was einer ausreichenden Genauigkeit für hydrologische Fragestellungen entspricht.




Abbildung 7: LiDAR-Datensatz (links) und Differenz zwischen LiDAR und SfM-Modell für die Testfläche am Pegel Elbersdorf

Der Unterwasserbereich wurde mit tachymetrisch oder GNSS-erfassten Querprofilen verglichen. Dabei konnten Ergebnisse von hoher Genauigkeit im cm-Bereich erzielt werden. Da nicht jeder Kamerastandort eine Unterwasserrekonstruktion mit Hilfe von Bildern erlaubte (z.B. aufgrund von Wassertrübung), wurde in diesen Situationen das Überwassermodell mit GNSS-basierten Querprofilen des Unterwasserbereiches kombiniert. Final konnten durch Einhängen der Querprofile („Unterwasserprofile“) in die Geländemodelle und Interpolation vollständige 3D-Geländemodelle generiert werden, die eine Auflösung im cm-Bereich aufweisen und mit geringen Kosten erstellt wurden. Abbildung 8 illustriert die 3D-Geländemodelle für die Messstellen Typ A. Diese bilden die Grundlage für die Bestimmung des Wasserstandes und der Oberflächenfließgeschwindigkeiten (siehe Abbildung 2). Zudem können an beliebigen Stellen im 3D-Modell Querprofile erzeugt werden (Abbildung 8 rechts), die für die Durchflussbestimmung von Relevanz sind.

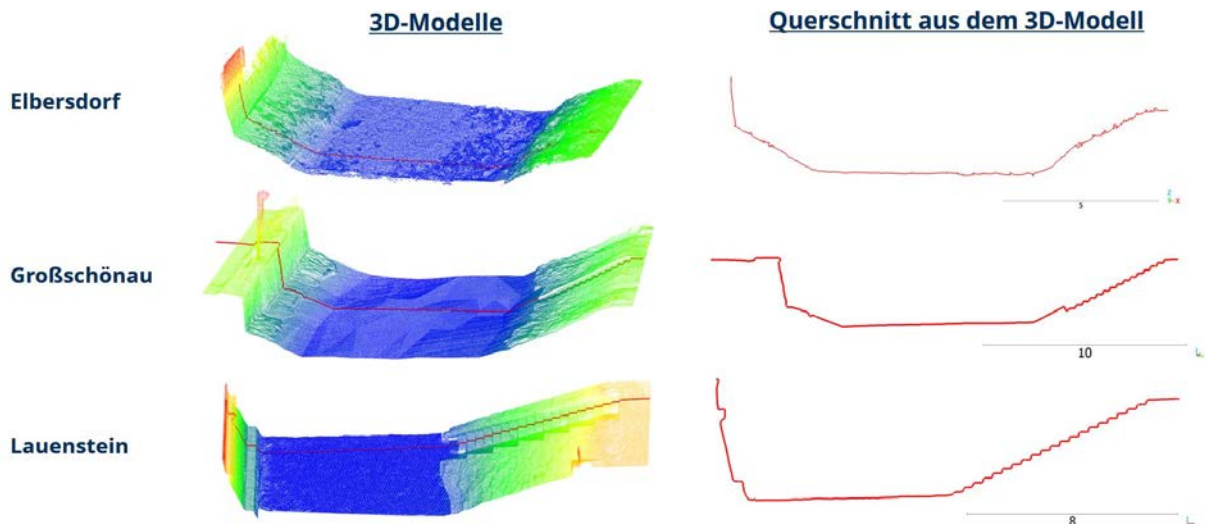


Abbildung 8: 3D-Geländemodelle der Messstellenbereiche und abgeleitete Querschnitte

4.1.1.4. Referenzmessungen

Referenzmessungen werden benötigt, um die Güte und Qualität der optischen Messergebnisse bewerten zu können und so sukzessive zu einer Verbesserung der Methoden beizutragen.

Für die Messstellen vom Typ A standen langjährige Wasserstands und Durchflussmessreihen in 15-minütiger Auflösung zur Verfügung, die über die Datenportale idA und HWIMS bezogen wurden. Zusätzlich wurden durch die BfUL Messprotokolle von Durchflussmessungen sowie die aktuell gültigen WQ-Beziehungen bereitgestellt.

An den Messstellen vom Typ B wurden während der Projektlaufzeit Stichtagsmessungen des Durchflusses und der Oberflächenfließgeschwindigkeit durchgeführt. Dabei wurden unterschiedliche Messgeräte verwendet (ADCP-Boot, hydrometrischer Flügel, MF-Pro), deren Auswahl sich an der jeweiligen Gewässergröße und Abflusssituation orientierte. Zusätzlich wurden eigene Messgeräte für eine kontinuierliche Wasserstandsmessung installiert. Beispielhaft zeigt Abbildung 9 den Mini-Radarsensor am Standort Großröhrsdorf mit zugehöriger Messganglinie.




Abbildung 9: Miniradar mit Ganglinie in Großröhrsdorf

4.1.2. Daten für die KI zur Vorhersage des Niederschlags-Abfluss Prozesses

4.1.2.1. Auswahl der Einzugsgebiete

Für die Entwicklung der KI-NAP wurde ein mehrstufiger Ansatz verfolgt. Zunächst wurden drei Pilot-einzugsgebiete (Pilot-EZG) in Sachsen für die Methodenentwicklung ausgewählt. Diese Gebiete zeichnen sich durch eine geringe Einzugsgebietsfläche (< 250 km²), eine relativ kurze Reaktionszeit (max. 6 h) des Abflusses auf Niederschlag, ein diverses Höhenprofil und stark unterschiedliche Einzugsgebietsformen aus (siehe Abbildung 10 und Tabelle 3). Der anthropogene Einfluss (Talsperren, Bergbau, etc.) wurde in allen drei Gebieten als relativ gering eingestuft. Zu diesen Pilotgebieten zählte u. A. der Pegel Elbersdorf, der auch für die KI-W und KI-Q als Entwicklungsstandort diente. Für den nächsten Schritt, die Generalisierung, wurde der Gebietsdatensatz auf 52 Gebiete in Sachsen erweitert für die Entwicklung eines regional gültigen Modellansatzes. Dieser Gebietsdatensatz enthält auch alle zuvor erwähnten Messstellen Typ A. Abschließend - für den Test der Übertragbarkeit der KI-NAP - wurde das Einzugsgebiet einer Messstelle Typ B (Neukirch) gewählt, um das Zusammenspiel der KI's zu demonstrieren. Abbildung 10 illustriert die Lage der Einzugsgebiete.

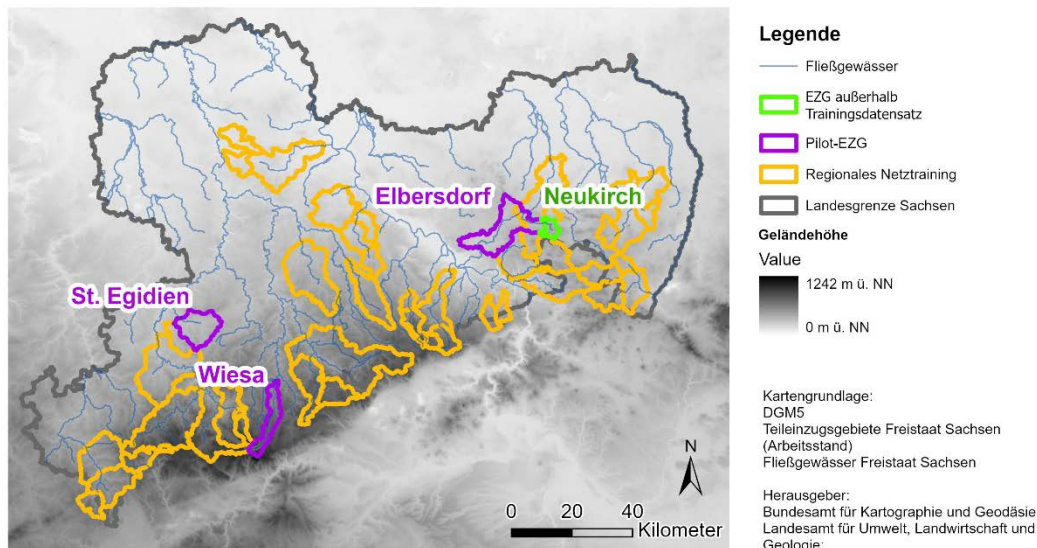


Abbildung 10: Lage der Einzugsgebiete innerhalb Sachsen untergliedert in Pilot-EZG, regionale EZG und das EZG für den Standort Neukirch

Tabelle 3: Eigenschaften der drei Pilot-EZG und deren Pegel

| Pegel | Elbersdorf | St. Egidien | Wiesa |
|----------------------------------|----------------------------|----------------------------|----------------------------|
| Gewässername | Wesenitz | Lungwitzbach | Pöhlbach |
| Gebietsfläche [km ²] | 227.18 | 122.29 | 86.40 |
| Mittlere Reaktionszeit [h] | 6 | 2 | 3 |
| Datenzeitraum Durchfluss | 01.11.2007 – 31.12.2021 | 01.11.2010 – 31.12.2021 | 01.11.2007 – 31.12.2021 |

4.1.2.2. Zeitreihendaten

Die Entwicklung der KI-NAP wurde auf einer stündlichen Datenbasis angestrebt, um den sehr kurzen Reaktionszeiten der sächsischen Einzugsgebiete Rechnung zu tragen. Ursächlich für die Wahl des Stundenzeitschrittes ist auch das Vorhandensein geeigneter Datenprodukte beim Einsatz der KI-NAP für die Hochwasservorhersage. Speziell für die Messung / Schätzung des aktuell gefallenen Niederschlags (P) wird durch den Deutschen Wetterdienst (DWD) das RADOLAN-RW – Produkt operationell bereitgestellt. Dabei handelt es sich um an Bodenmessungen angeeichte Radardaten, die stündliche Messwerte des Niederschlags auf einem Raster liefern und mit einer Verzögerung von

30 min vorliegen. Das RADOLAN-RW Produkt ist seit 2007 zuverlässig verfügbar, was den maximalen Datenzeitraum für die Projektbearbeitung vorgibt. Die Rasterzellen des RADOLAN-RW Produktes wurden mit den Einzugsgebietsgrenzen verschnitten und zu Gebietsniederschlägen aggregiert.

Für die Vorhersage des Niederschlags wurde das ICON-D2 Modell des DWD verwendet. ICON-D2 ist ein numerisches Wettervorhersagemodell für die nächsten 48 Stunden, das in 15-minütiger Zeitauflösung vorliegt und im 3 Stundenrhythmus aktualisiert wird. Das ICON-D2 verfügt über einen Ensemblemodus (EPS), bei dem 20 mögliche Ausprägungen des zukünftigen Niederschlagsverlaufes bereitgestellt werden, um die Unsicherheit in der Niederschlagsvorhersage abzubilden.

Neben dem Niederschlag ist der Durchfluss (Q) die zweite wichtige Eingangsgröße für die KI-NAP. Zeitreihen des Durchflusses wurden als 15 min-Werte für die 52 Pegel dem iDA-Portal des Sächsischen Landesamtes für Umwelt, Landwirtschaft und Geologie (LfULG) entnommen. Die 15-minütigen Durchflussdaten wurden anschließend in stündliche Daten umgerechnet.

4.2. Entwicklung der KI's

4.2.1. Optische Messung des Wasserstandes

4.2.1.1. Zielstellung

Optische Messverfahren mit Hilfe von Kameras bieten in Hochwassersituationen Vorteile, da sie ohne Kontakt mit dem Wasser auskommen und gefahrlos einsetzbar sind. Aufgrund der wissenschaftlich-technischen Entwicklungen in den zurückliegenden Jahren im Hinblick auf Kamerasensoren, Bildauswertungsalgorithmen, Frameworks zur Nutzung künstlicher Intelligenz, PC-Rechenleistung und Mobilfunk besteht ein großes Potential, aktuelle Messwerte der hydrologisch/hydraulischen Kenngrößen in Fließgewässern anhand von Kameraaufnahmen nahezu in Echtzeit ermitteln zu können. Vor diesem Hintergrund war es das Ziel ein Verfahren zur KI-basierten, automatisierten Wasserstandserkennung aus Kamerabildern zu entwickeln. Der Schwerpunkt lag auf der robusten und eindeutigen Unterscheidung von Wasserflächen und Uferbereichen, die in der Verschneidung mit einem präzisen 3D-Geländemodell eine Messung des Wasserstandes erlauben. Es wurden verschiedene neuronale Netztypen getestet und trainiert. Für die KIs wurden große Trainingsdatensätze erzeugt. Die Genauigkeiten der erzielten, kamera-basierten Wasserstandsmessung wurde beurteilt.

4.2.1.2. KI für die Segmentierung der Wasserflächen

In einem ersten Schritt sollen die Wasserflächen in den Bildern automatisch maskiert werden, um die Wasserlinie – also die Grenze zwischen Wasser und Ufer – zu erkennen. Für die entsprechende Wasserflächensegmentierung wurden verschiedene KI trainiert. Für das Training mussten Trainingsdaten erzeugt werden. Es wurde eine Routine entwickelt, um die Bilder von Kamerastandorten des KIWA-Projektes effizient zu annotieren (KIWA-Bilder). Dazu wurde die Software labelme eingesetzt. Darüber hinaus wurden öffentlich zugängliche Trainingsdaten zur Wassererkennung recherchiert (z. B. in Kaggle und früheren TUD-Projekten) und, wenn geeignet, ebenfalls genutzt. Dieser Datensatz umfasst Bilder von Flüssen, die mit Smartphones, Drohnen und DSLR-Kameras aufgenommen und manuell segmentiert wurden, sowie Flussbilder aus dem WaterNet-Datensatz. Im Ergebnis wurden 1337 Bilder verwendet, wobei der Anteil an KIWA-Bildern lediglich bei 11 % lag (siehe Abbildung 11). Dieser erste Trainingsdatensatz wurde dann synthetisch erhöht, indem intelligenten Augmentierungsstrategien angewandt wurden. D. h. die Bilder wurden geometrische (z.B.

Rotation und Verzerrung) und radiometrisch (z. B. Kontrast) verändert, um somit die Größe der Trainingsdaten um eine Magnitude zu erhöhen. Das entwickelte Verfahren zur smarten Annotation von Wasserflächen in Bildern wurde in einer Publikation veröffentlicht (Wagner et al., 2023). Final standen über 10.000 Bilder zur Verfügung.

Kaggle Datensatz + TU Datensatz (89% - 1192 Bilder)



KIWA-Bilder (11% - 145 Bilder)



Abbildung 11: Kamerabilder mit manuell segmentierten Wasserflächen aus dem Trainingsdatensatz für die KI zur automatischen Wasserflächensegmentierung

Nachdem die Trainingsdaten erzeugt waren, konnten verschiedene Faltungsnetzarchitekturen (CNNs) erprobt werden. Insgesamt wurden 32 Architekturen erprobt und die leistungsfähigste Architektur für die KIWA-Anwendung genutzt – UPerNet + ResNeXt50. Die KI-Modelle wurden erfolgreich an den Messstellen des Typs A trainiert und validiert. Zur Verbesserung des Trainingsprozesses wurde der ursprüngliche Bilddatensatz iterativ modifiziert, um Wasserbilder auszuschließen, die sich erheblich von unserem Zielszenario unterschieden, und um mehr Bilder einzubeziehen, die von KIWA-Kameras aufgenommen wurden. Um zu bestimmen, welche KIWA-Bilder aufgenommen werden sollten, wurde ein iterativer Prozess durchgeführt, bei dem Bilder ausgewählt wurden, die in früheren Trainingsläufen schlecht segmentiert wurden. Auf diese Weise wurden schwierige oder sensible Bilder, die zuvor nicht korrekt segmentiert wurden (z. B. schlechtes Wetter, völlig transparentes Wasser, starke Schatten über dem Wasser), in die nachfolgenden Trainingsläufe einbezogen.

Für das für die KIWA-Daten angepasste Training des UPerNet-Netzwerks mit einem ResNeXt50-Backbone wurde die FocalLoss-Kostenfunktion und der Adam-Optimierer mit einer anfänglichen Lernrate von 0,0001, die später mit dem ReduceLRonPlateau-Algorithmus reduziert wurde, verwendet. Das Training wurde auf einer NVIDIA GTX A6000 mit einer Batchgröße von 30 für 1000 Epochen durchgeführt. Zur Bewertung der Trainingsmetriken wurde ein Mini-Datensatz von 30 Bildern verwendet. Das beste Modell hat eine Genauigkeit von 98,9 %.

4.2.1.3. Ermittlung des Wasserstandes

Innerhalb der Messstellenbereiche wurden Passpunkte montiert, um die Position und Orientierung, d. h. die äußeren Orientierungsparameter, der fest installierten Kamera zu ermitteln. Diese Passpunkte müssen sowohl im 3D-Modell als auch in den von den Messkameras aufgenommenen Standbildern sichtbar sein. Darüber hinaus gewährleistet die richtige Verteilung dieser Punkte im




Abbildung 12: Testfeld für die Kamerakalibrierung

Bild (die den äußeren Rahmen des Bildes abdecken) genaue Ergebnisse in den nachfolgenden photogrammetrischen Prozessen und eine genaue Schätzung der Kamerageometrie. Neben den Passpunkten ist eine weitere Voraussetzung für die kamera-basierte Wasserstandsmessung die Bestimmung der Kameraparameter der inneren Orientierung, d. h. u. a. Brennweite und Verzeichnung. Entsprechend wurde ein Kalibrierfeld vor Installation der Kameras, wenn möglich aufgenommen, um damit die Parameter im photogrammetrischen Verfahren der Selbstkalibrierung zu realisieren (Abbildung 12).

Zur Bestimmung des Wasserstands basierend auf der extrahierten Wasserlinie im Bild (Eltner et al., 2021) muss diese Wasserlinie mit dem 3D-Modell verschnitten werden. Dazu müssen die Parameter der äußeren Orientierung berechnet werden, indem der Standort und die Orientierung der Kamera durch Korrelation der 2D-Koordinaten der Passpunkte im Bild mit ihren korrespondierenden 3D-Koordinaten in der realen Welt bestimmt werden. Dies wird erreicht, indem die Kollinearitätsbedingungen berücksichtigt werden, um Punkte aus dem 3D-Raum der realen Welt in den 2D-Raum der Kamera zu transformieren. Dabei wird die 3D-Punktwolke des Untersuchungsgebiets auf die Bildebene reprojiziert, was neben der äußeren Orientierung auch die Kenntnis der inneren Kameraparameter erfordert. Folglich kann jedem Pixel im Bild, das von einem reprojizierten 3D-Punkt getroffen wurde, eine entsprechende 3D-Koordinate aus dem Weltkoordinatensystem zugeordnet werden. Der letzte Schritt besteht darin, die Höhen der 3D-Punkte der verschnittenen Konturlinien der Wassermaske zu extrahieren. Dazu wird der Algorithmus des nächsten Nachbarn verwendet, um die Punkte in der reprojizierten 3D-Punktwolke zu finden, die dieser Linie am nächsten liegen. Mit den ausgewählten Punkten der 3D-Punktwolke, die der Uferlinie am nächsten liegen, wurde eine statistische Berechnung der Z-Koordinaten (Höhenkoordinate) durchgeführt, die zu einer mittleren Z-Koordinate führte, die die Position der Wasseroberfläche bestimmt und so zur Schätzung des Wasserstandes dient. Es erfolgt eine Filterung der Ergebnisse, da der Arbeitsablauf



Abbildung 13: Arbeitsablauf für die Wasserstandsermittlung bestehend aus (1) Datengewinnung, (2) automatische Segmentierung der Wasserfläche mittels KI und (3) der Rückprojektion des 3D-Modells in das segmentierte 2D Bild

vollautomatisch ist und entsprechend Ausreißer zu erwarten sind. Die Ergebnisse wurden anhand eines statistischen Kriteriums gefiltert. Es basiert auf dem Wert der Standardabweichung der Z-Koordinate der Punkte, die sich mit dem 3D-Modell schneiden. Eine hohe Streuung dieses Wertes deutet darauf hin, dass die Segmentierungsgrenze verschiedene Wasserhöhen enthält und daher nicht korrekt ist, da von einer horizontalen Wasserlinie ausgegangen wird. Der gesamte Verfahrensablauf für die Ermittlung des Wasserstandes ist abschließend in Abbildung 13 illustriert und zusammengefasst.

4.2.1.4. KI für die Passpunkterkennung

Obwohl die Kameras fest montiert sind, ist die Stabilität der Kameras und Sensoren während des Beobachtungszeitraums nicht garantiert. Abrupte und gleichmäßige Kamerabewegungen konnten festgestellt werden. Diese Bewegungen, die auf physische und thermische Störungen zurückzuführen sind, hatten Abweichungen bei den 2D-Bildkoordinaten der Passpunkte zur Folge. Daher müssen die Bildmessungen der Passpunkte mit hoher Genauigkeit und Zuverlässigkeit aktualisiert werden, d. h. die Punkte müssen in jedem Bild und zu jeder neuen Aufnahme gemessen werden. Zur automatischen Erkennung wurde das neuronale Netz R-CNN Keypoint Detector (mit dem Backbone ResNet50-FPN) angepasst und neu trainiert. Der Trainingsdatensatz umfasste 75 Bilder mit händisch markierten Passpunkten und es waren letztlich nach der Augmentierung über 2000 Bilder mit Passpunkten verfügbar (Abbildung 14). Diese Methode ermöglichte eine Passpunktidentifizierung mit einer Genauigkeit von weniger als 0,5 Pixel. Mit dem speziell auf KIWA-Bildern trainierten Modell wurde ein robuster Ansatz zur Identifizierung von Passpunkten mit guter Übertragbarkeit entwickelt. Das Verfahren ist zur Veröffentlichung eingereicht (Blanch et al., subm.).

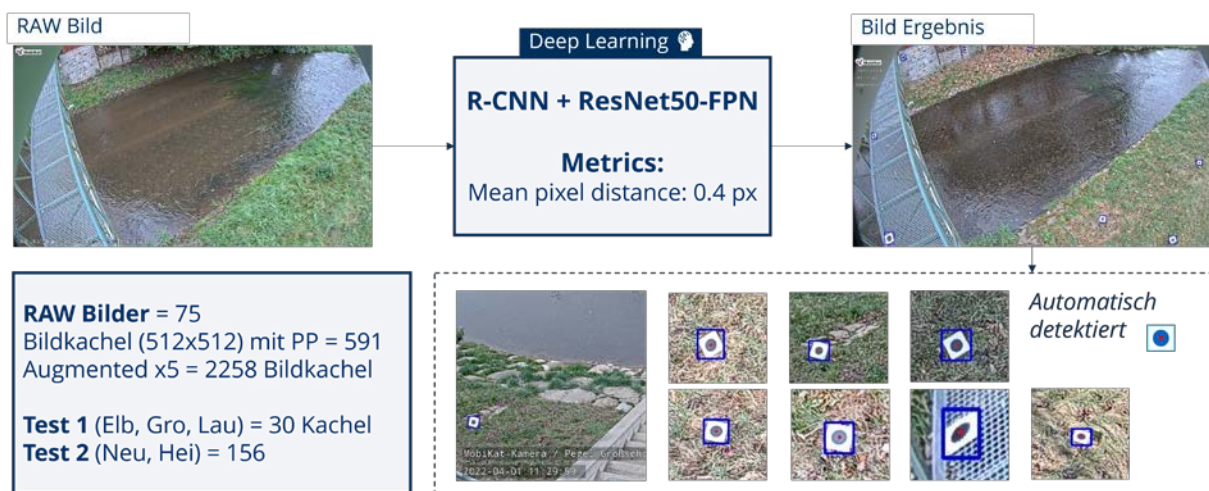


Abbildung 14: Training und Aufbau der KI für die automatisierte Passpunkterkennung

Abbildung 15 illustriert exemplarisch die Funktionsweise der KI am Beispiel der Messstelle Typ 1 in Lauenstein. Der obere Teil der Abbildung 15 zeigt zunehmende Abweichungen zwischen optisch bestimmten Wasserständen und der Referenzmessung mit fortschreitender Zeit vom Zeitpunkt der Installation der Kamera sowie dem Einmessen der Passpunkte. Im unteren Bild ist der gleiche Zeitausschnitt dargestellt. Allerdings erfolgt hier die Detektion und Messung der Passpunkte bei jeder Bildaufnahme der Kamera, was zu einer deutlich verbesserten Genauigkeit der Wasserstandsermittlung führt.

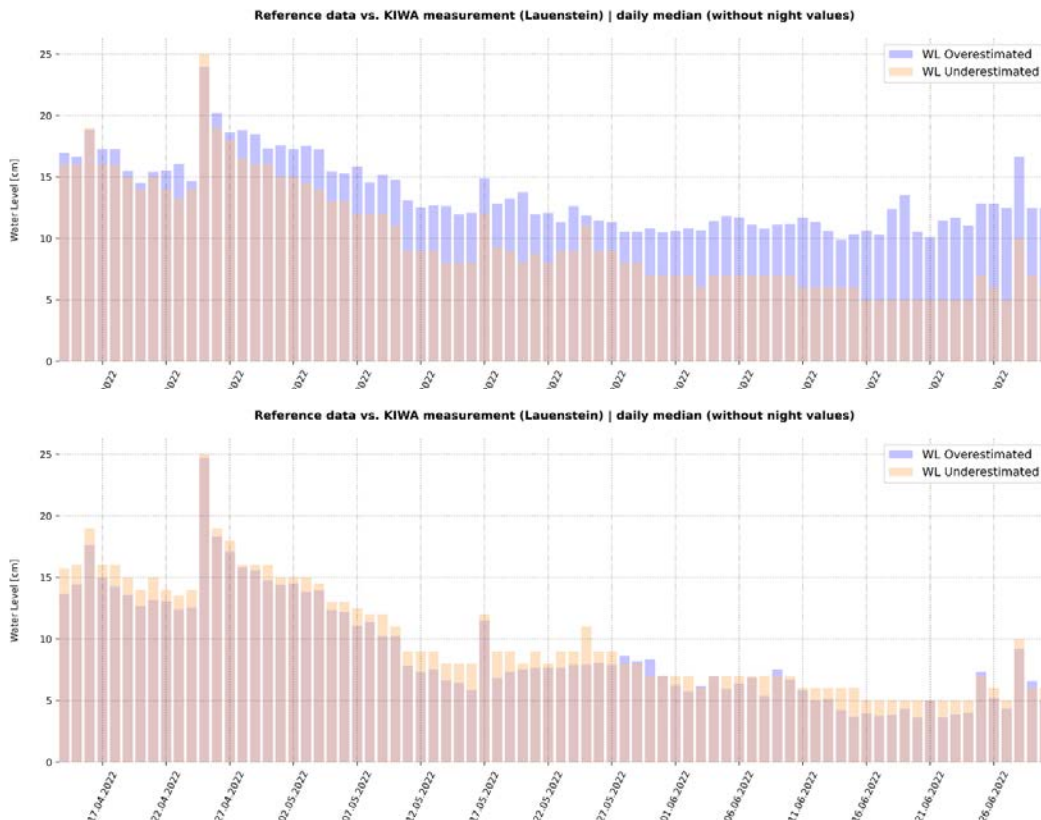


Abbildung 15: Vergleich der Wasserstandsermittlung ohne (oben) und mit (unten) KI-basierter Passpunkterkennung am Beispiel des Pegels Lauenstein

4.2.2. Optische Bestimmung des Durchflusses

4.2.2.1. Zielstellung

Die Durchflussermittlung in offenen Gerinnen ist eine wesentliche Grundlage für Wasserhaushaltsanalysen und Hochwasservorhersagen. Insbesondere in hochwassergefährdeten Gebieten ist die präzise Erfassung des Durchflusses eine wichtige Grundlage für zuverlässige Durchflussvorhersagen und daraus abgeleitete Überflutungsflächen. Traditionelle Messverfahren, wie hydrometrischer Flügel oder Acoustic Doppler Current Profiler (ADCP), sind zwar weit verbreitet, bringen jedoch den Nachteil mit auf direkten Kontakt mit dem Wasser angewiesen zu sein. Ihr Einsatz bei extremen Hochwasserereignissen ist entsprechend problematisch und gefährlich. Berührungslose Messmethoden, wie kamerabasierte, optische Systeme, bieten in solchen Situationen entscheidende Vorteile, da sie Messungen aus sicherer Entfernung ermöglichen und robust, sicher und kontinuierlich Messdaten liefern können, ohne dass Gefahren für das Personal entstehen.

Grundlage für die optische Ermittlung des Durchflusses ist die Messung der Oberflächengeschwindigkeit des Gewässers. Hierfür müssen jedoch Fließgeschwindigkeitsmessung über das gesamte Profil vorhanden sein. Das ist mit optischen Methoden in der Natur nicht immer möglich. Die daraus resultierenden Messlücken in der Geschwindigkeitsverteilung wirken sich negativ auf die Güte der Durchflussbestimmung aus. Da optische Messmethoden relativ neu in der Hydrologie sind, gibt es noch kein standardisiertes Verfahren, mit dem der Durchfluss zuverlässig bestimmt werden kann.

Ein zentrales Ziel war deshalb die Entwicklung einer Methode zur Durchflussbestimmung, die auf optischen Fließgeschwindigkeitsmessungen basiert. Diese Methode soll es ermöglichen, eine kontinuierliche und robuste Messung unter realen, natürlichen, aber auch kritischen Bedingungen durchzuführen. Ausgangspunkt der Entwicklung ist die Datenerfassung an den Messstellen Typ A, deren Kameras jede 15 min kurze Videosequenzen von der Strömung des Flusses aufzeichnen und an einen Datenserver übermitteln. Dabei diente zunächst die Messstelle in Elbersdorf als Entwicklungsstandort für die Erarbeitung und den Test der Methoden, die in einem zweiten Schritt an den Pegelstandorten Lauenstein und Großschönau validiert wurden.

4.2.2.2. Messung der Oberflächengeschwindigkeit mit Particle Tracking Velocimetry

Particle Tracking Velocimetry (PTV) gehört neben Large Scale Particle Image Velocimetry (LSPIV) und Space-Time Image Velocimetry (STIV) zu den am häufigsten angewandten Methoden zur optischen zur Erfassung von Oberflächengeschwindigkeiten. Das Messprinzip aller optischer Verfahren ist ähnlich. Sie nutzen kontinuierliche Bildaufnahmen (Filmsequenzen) von Strömungsvorgängen zur Bestimmung von Fließgeschwindigkeiten. Dabei werden sichtbare Strömungsmuster, wie Wellenbewegungen oder Partikel in Einzelbildern auf der Wasseroberfläche detektiert und über mehrere Sequenzen nachverfolgt. Unter Berücksichtigung der Bildrate und der ermittelten Positionsänderungen der Strömungsmuster in den Sequenzen werden die Geschwindigkeitsvektoren berechnet. Bei PTV werden einzelne Partikel zum Bestimmen der Fließgeschwindigkeiten genutzt. Als Partikel dienen in diesem Zusammenhang Objekte, die auf der Wasseroberfläche treiben/schwimmen, wie beispielsweise Laub, Treibgut oder Schaum.

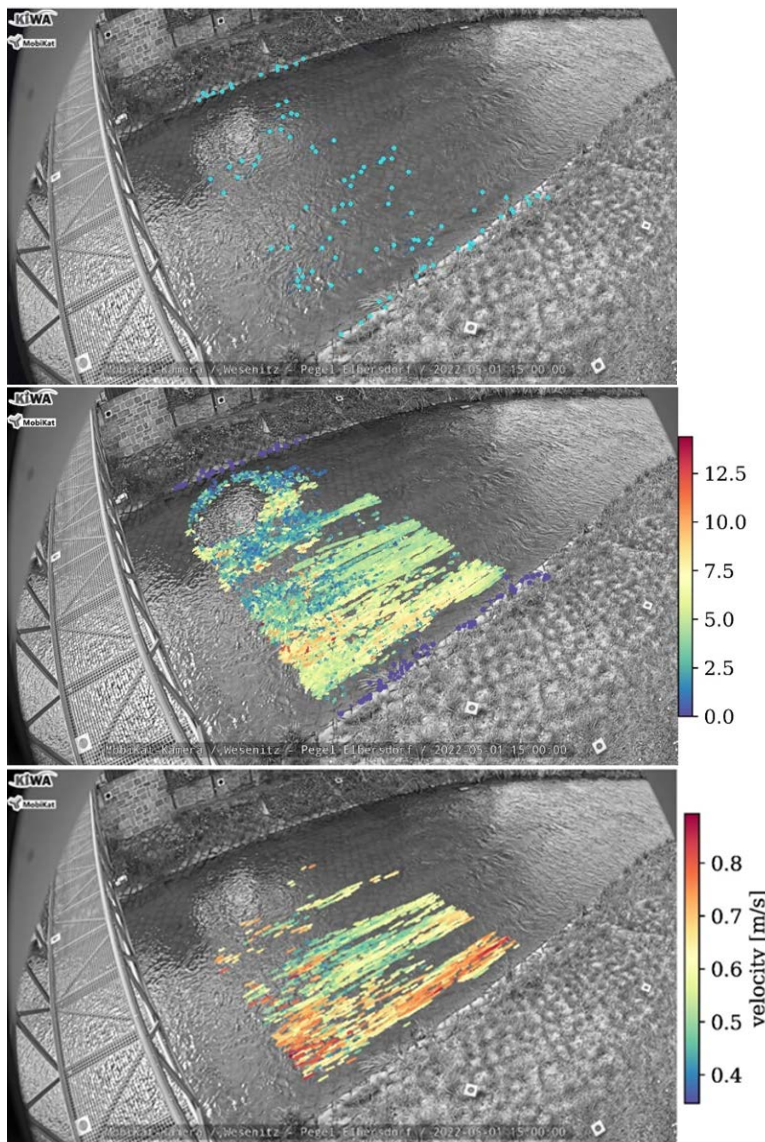


Abbildung 16: Arbeitsschritte bei der Oberflächengeschwindigkeitsmessung mit PTV: Partikeldetektion (oben), Partikel Tracking und Filterung im Bildraum (Mitte) und Geschwindigkeitsbestimmung im Objektraum (unten)

Unter Berücksichtigung der Bildrate und der ermittelten Positionsänderungen der Strömungsmuster in den Sequenzen werden die Geschwindigkeitsvektoren berechnet. Bei PTV werden einzelne Partikel zum Bestimmen der Fließgeschwindigkeiten genutzt. Als Partikel dienen in diesem Zusammenhang Objekte, die auf der Wasseroberfläche treiben/schwimmen, wie beispielsweise Laub, Treibgut oder Schaum.

Die Ermittlung der Oberflächengeschwindigkeiten erfolgte mit PTV unter Verwendung des FlowVeloTool (Eltner et al., 2020), einer Open-Source-Software. Der Arbeitsablauf der Oberflächengeschwindigkeitsbestimmung besteht im Wesentlichen aus vier Teilschritten. Nachdem eine Videosequenz in einzelne Bilder zerlegt wurde, werden in den Einzelbildern mittels Harris-Corner-

Detection (Harris & Stephens, 1988) einzelne Partikel auf der Wasseroberfläche detektiert (hellblau markiert in Abbildung 16, oben). Dabei dient das mit dem Wasserstand verschnittene 3D-Modell des Pegelbereichs (vgl. Kapitel 4.1.1.3) als Suchmaske für die Detektion. Im nächsten Schritt werden die detektierten Partikel über mehrere aufeinander folgende Einzelbilder hinweg nachverfolgt mit dem Lucas-Kanade-Algorithmus (Lucas & Kanade, 1981). Die Bewegung der einzelnen Partikel wird aufgezeichnet und einer Filterung unterzogen. Beim Filtern werden fehlerhafte Detektionen wie stehende Partikel, zu langsame oder zu schnelle, Partikel die sich quer oder entgegengesetzt der Fließrichtung bewegen herausgefiltert. Entsprechend Abbildung 16, Mitte, werden Partikel die violett bis blau und rot bis orange markiert sind herausgefiltert, da diese sich entweder zu wenig/langsam (violett), in die falsche Richtung (Vektorrichtung) oder zu viel zu schnell (rot) bewegen. Abschließend erfolgt die Transformation aus dem Bildraum in den Objektraum, um ein metrisches Messsignal zu erhalten (Abbildung 16, unten). Dies geschieht über die erfassten Passpunkte (vgl. Kapitel 4.1.1.3), die Kameraparameter wie Bildauflösung, Brennweite und Sensorgröße (Tabelle 2), die externe Kameraorientierung und -positionierung und dem Wasserstand (vgl. Kapitel 4.2.1.3).

Die Bestimmung von Fließgeschwindigkeiten mittels der PTV bringt einige Herausforderungen in Bezug auf die Sichtbarkeit und Verfügbarkeit von Partikeln auf der Wasseroberfläche. Die Partikel sind unter natürlichen Bedingungen meist ungleichmäßig über den Fließquerschnitt verteilt. Es kommt häufig vor, dass einige Bereiche der Wasseroberfläche viele Partikel aufweisen, während in anderen Bereichen keine vorhanden sind. In den partikellosen Bereichen können keine Messungen durchgeführt werden, was zu Lücken in den Geschwindigkeitsverteilungen führt und die Qualität der Durchflussbestimmung schwanken lässt. Weiter besonders problematisch sind ungünstige Lichtverhältnisse wie Dunkelheit, Schatten oder Reflexionen, die die Qualität der Messdaten stark beeinträchtigen können. Ebenso erschweren Wetterbedingungen wie dichter Nebel, starker Regen oder Schneefall die Messungen.

Einige häufig beobachteten Messbedingungen sind in Abbildung 17 dargestellt. Unter idealen Messbedingungen (Abbildung 17, i), sind die Partikel gleichmäßig über den gesamten Flussquerschnitt verteilt. Geschwindigkeitsmessungen können über den gesamten Querschnitt durchgeführt werden. Dies tritt oft bei hohen Wasserständen auf, was eine zuverlässige Durchflussbestimmung ermöglicht. In einem anderen häufigen Szenario (Abbildung 17, ii) sind die Partikel jedoch nur in einem Teil des Flusses vorhanden, während in anderen Bereichen nur wenige oder gar keine Partikel erkennbar sind. Dies erschwert die genaue Durchflussbestimmung erheblich. Eine besonders ungünstige Verteilung von Partikeln (Abbildung 17, iii) tritt bei niedrigem Wasserstand auf. Hier sind

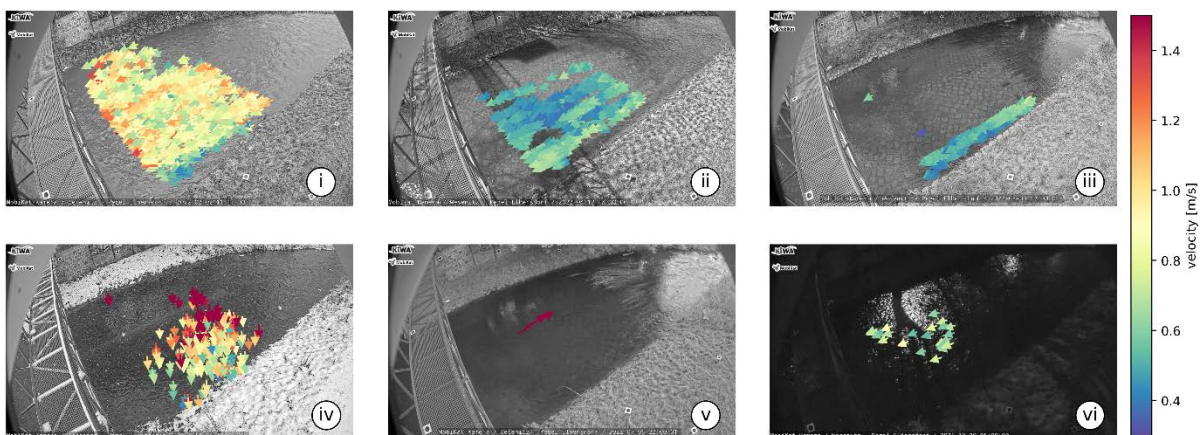


Abbildung 17: PTV-Ergebnisse unter verschiedenen Umweltbedingungen am Pegel Elbersdorf: (i) ideale Partikelverteilung; (ii) häufigste Partikelverteilung; (iii) schlechte Partikelverteilung bei Niedrigwasser; (iv) Detektion von Schneeflocken; (v) fehlgeschlagene Detektion; Partikelbewegung flussaufwärts (vi) Messung bei Nacht im Mondlicht

die Partikel nur in einem kleinen Teil des Fließquerschnitts vorhanden, was eine zuverlässige Durchflussbestimmung fast unmöglich macht. Wie ungünstige Wetterbedingungen die PTV-Messung beeinflussen können, ist in Abbildung 17 (iv) zu sehen. In dem Fall wurden Schneeflocken als Partikel identifiziert, was zu fehlerhaften Ergebnissen führt. Die Auswirkung schlechter Lichtverhältnisse ist in Abbildung 17 (v) dargestellt. Bei unzureichender Beleuchtung können Partikel nicht korrekt verfolgt werden. Dies kann sogar dazu führen, dass die Partikelbewegung entgegen der Fließrichtung erfasst wird, was als Fehlmessung gilt. Ohne zusätzliche Lichtquellen wie Infrarotstrahler oder Lampen sind PTV-Messungen bei Nacht kaum möglich. Bei Vollmond können z.B. Reflexionen des Mondlichts in Kombination mit Wellenbewegung fälschlicherweise als Partikelbewegung interpretiert werden, was zu fehlerhaften Ergebnissen führt, wie in Abbildung 17 (vi) dargestellt.

4.2.2.3. Durchflussermittlung aus Messungen der Oberflächenfließgeschwindigkeit

Für die Bestimmung des Durchflusses mit berührungslosen Methoden wird am häufigsten das Geschwindigkeitsflächenverfahren (DIN EN ISO 748) verwendet (Hauet et al., 2008). Die Methode basiert auf dem Kontinuitätsgesetz, das von zwei Variablen abhängt: der Fließfläche (A), bestimmt z. B. anhand des 3D-Modells (vgl. Kapitel 4.1.1.3) und der mittleren Fließgeschwindigkeit (v_m).

$$Q = v_m \cdot A$$

Die Herausforderung bei der Berechnung des Durchflusses Q besteht in der Bestimmung die mittleren Fließgeschwindigkeit anhand der gemessenen Oberflächengeschwindigkeiten. In der Regel entspricht die Oberflächengeschwindigkeit nicht der mittleren Fließgeschwindigkeit, sodass eine Umrechnung erforderlich ist. Für die Umrechnung wird der so genannte α -Wert (Geschwindigkeitsindexbeiwert) verwendet, wobei α der Quotient aus der gemittelten Oberflächengeschwindigkeit (v_o) und v_m ist. Aus der α -Beziehung lässt sich die Kontinuitätsgleichung gemäß als Funktion des Geschwindigkeitskoeffizienten, der Oberflächengeschwindigkeit und des Fließfläche formulieren:

$$Q = \alpha \cdot v_o \cdot A$$

Der α -Wert kann z. B. aus Messungen der Fließgeschwindigkeit mit ADCP oder dem hydrometrischen Flügel abgeleitet werden. Der Wert ist spezifisch für jeden Untersuchungsstandort und im Allgemeinen abhängig von der Rauheit des Flussbetts, dem Wasserstand, der Form des Messquerschnitts und den Strömungsbedingungen. Die vorliegenden Ergebnisse zahlreicher Experimente lassen den Schluss zu, dass in der Praxis von einem α -Wert von 0,85 für natürliche Gerinne und von 0,90 für künstliche Gerinne ausgegangen werden kann. Aufgrund des Einflusses des Sedimenttransports oder der Gewässerverkrautung können die α -Werte stark variieren und zwischen 0,397 und 1,72 liegen (Johnson & Cowen, 2017). Es wird empfohlen, Referenzmessungen für jeden Untersuchungsstandort durchzuführen, um einen individuellen α -Wert für eine möglichst genaue Durchflussbestimmung abzuleiten (Muste et al., 2011).

Die Skizze in Abbildung 18 veranschaulicht den verwendeten Ansatz zur Durchflussbestimmung unter Verwendung von PTV, für einen Flussabschnitt mit trapezförmigem Profil. Die Wasseroberfläche mit dem Suchbereich ist blau eingerahmt. Alle in dem Suchbereich aufgezeichneten Partikel sind als blaue Kreise dargestellt. Die schwarzen Vektorpfeile geben die Fließrichtung und Geschwindigkeit der Partikel wieder. Die gepunkteten Linien teilen das Profil in Teilflächen, zwischen denen die einzelnen Vektoren gemittelt werden. Diese Bereiche werden Mittelungsfenster genannt. Es wird für jedes Mittelungsfenster eine mittlere Oberflächengeschwindigkeit $v_{o,i}$ gebildet, die im Ergebnis über die Gewässerbreite eine Oberflächengeschwindigkeitsverteilung ergeben.

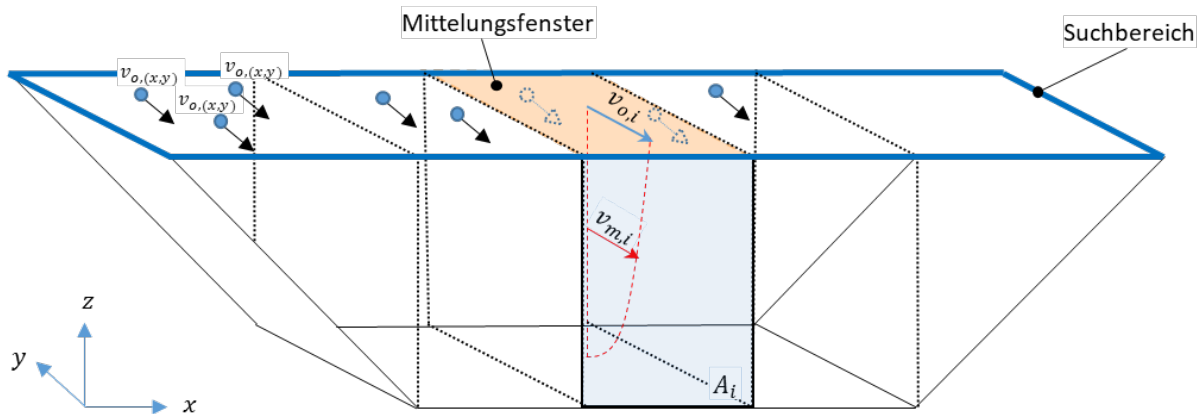


Abbildung 18: Durchflussbestimmung aus Messungen der Oberflächengeschwindigkeit mit PTV

Für die Bestimmung der mittleren Oberflächengeschwindigkeiten wurden drei gängige Methoden wendet. Das arithmetische Mittel, bei dem alle gemessenen Oberflächengeschwindigkeiten einer Messung gemittelt werden, wodurch eine mittlere Geschwindigkeit für das gesamte Profil entsteht. Bei der zweiten Methode wird der Querschnitt in gleiche Abschnitte unterteilt und die Geschwindigkeiten innerhalb der Teilbereiche gemittelt. Dabei handelt es sich um eine Standardmethode nach DIN EN ISO 748. Als dritte Methode wurde der gleitende Mittelwert verwendet. Bei dieser Methode wird ein Mittelungsfenster über den Querschnitt bewegt. Dabei überlappen sich die Teilbereiche des Mittelungsfensters und Ausreißer haben weniger Einfluss.

Die Ergebnisse der Durchflussbestimmung basierend auf den drei Mittelungsmethoden der Oberflächengeschwindigkeit ist in Abbildung 19 im Vergleich zur Referenz dargestellt. Es wird ersichtlich, dass alle drei Methoden Schwierigkeiten aufweisen, den Verlauf der Referenzganglinie adäquat nachzubilden. Von den drei untersuchten Methoden zeigt das arithmetische Mittel die besten Ergebnisse. Die Erfassung der Abflussspitzen gelingt in zufriedenstellender Weise. Die Methode zeigt jedoch Schwächen bei fehlerhaften Detektionen, beispielsweise bei Nacht (grün in Abbildung 19) und bei Schneefall (rot in Abbildung 19). In diesem Fall werden die Durchflüsse erheblich über-

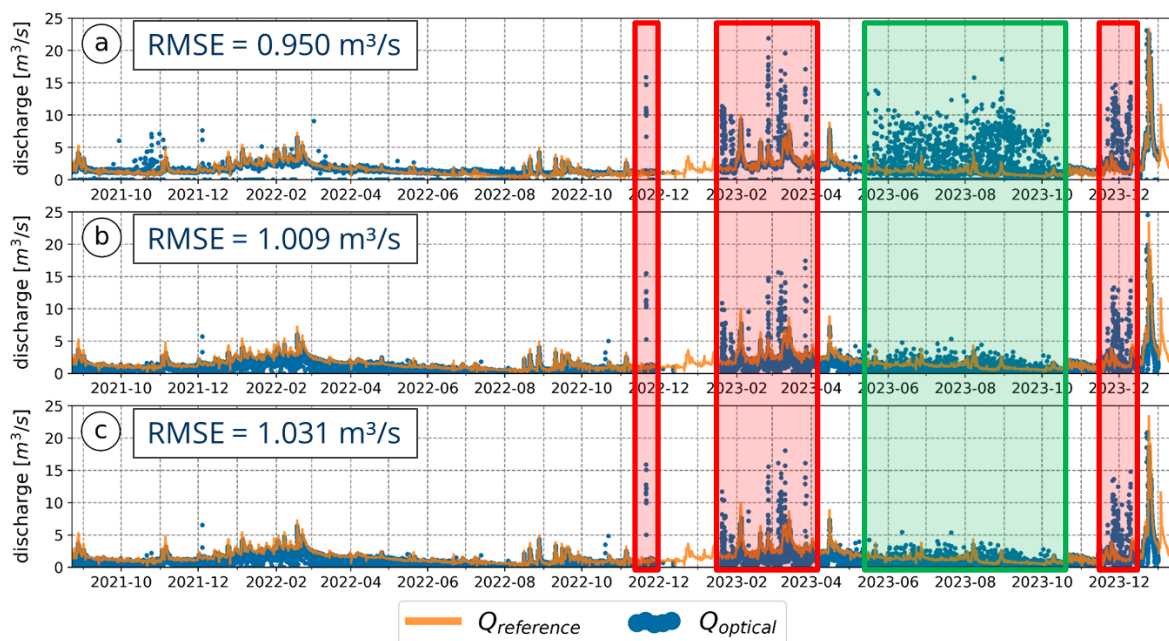


Abbildung 19: Optisch bestimmte Durchflussganglinien mit $\alpha = 0,85$ am Pegel Elbersdorf im Vergleich zur Referenz für drei Methoden der Mittelung der Oberflächengeschwindigkeit: a) arithmetisches Mittel; b) Teilflächenmittelung; c) gleitender Mittelwert

schätzt. Die Durchflüsse der auf Basis der Teilflächenmittelung ermittelten Werte sowie der mit dem gleitenden Mittelwert gewichteten Werte zeigen eine hohe Ähnlichkeit. Auch hier werden die Durchflussspitzen gut erfasst. Dies ist auf eine größere Partikelanzahl bei höheren Durchflüssen zurückzuführen, die zudem eine größere Streuung aufweisen (vgl. Abbildung 17, i). Infolgedessen sind Messlücken kleiner und seltener. Bei niedrigeren Durchflüssen ist die Verfügbarkeit und Streuung der Partikel deutlich geringer, was sich in den Durchflussergebnissen manifestiert. Je nach Ausprägung der Messlücken ist eine signifikante Streuung und Unterschätzung des Durchflusses bei den beiden Methoden erkennbar. Insgesamt sind die erzielten Durchflussergebnisse als nicht zufriedenstellend zu bewerten. Insbesondere die Messlücken in der Geschwindigkeitsverteilung der Einzelmessungen und die Fehldetektionen wirken sich erheblich auf die Ergebnisse aus. Die mittleren Fehler des Gütemaßes RMSE (Seite 27) liegen zwischen 0,950 m³/s, beim arithmetischen Mittel, und 1,031 m³/s beim gleitenden Mittelwert. Um diese Probleme zu beheben, wurde die OptiQ-Methode entwickelt.

4.2.2.4. Die OptiQ-Methode zur Durchflussbestimmung

Die OptiQ-Methode ist ein statistischer Ansatz zur robusten Bestimmung kontinuierlicher Durchflusszeitreihen in natürlichen Fließgewässern, selbst wenn Geschwindigkeitsmessungen fehlen, unvollständig sind oder nur in begrenzter Zahl vorliegen. Die Methode folgt dem Credo „Lernen aus der Vergangenheit“ und basiert auf der Erarbeitung einer wasserstandsabhängigen, mittleren Oberflächengeschwindigkeitsverteilung. Dazu werden optisch aufgezeichnete Zeitreihen der Oberflächengeschwindigkeiten unter vergleichbaren Abflussbedingungen - bei gleichem Wasserstand - verwendet. Diese Geschwindigkeitsverteilungen werden in einer Datenbank gespeichert, gemittelt und zum Ergänzen von Lücken in der Oberflächengeschwindigkeitsverteilung von Einzelmessungen sowie der anschließenden Durchflussbestimmung verwendet. Die OptiQ-Methode ist modular aufgebaut und besteht aus drei Hauptschritten: Datenvorfilterung, Bestimmung der mittleren Oberflächengeschwindigkeitsverteilungen und Berechnung von Durchflusszeitreihen. Der Arbeitsablauf ist in Abbildung 20 schematisch dargestellt und im Folgenden erklärt.

Bei der **Datenvorfilterung** werden die aufgezeichneten Messungen einem Prozess unterzogen, der darauf abzielt, offensichtlich falsche Messungen zu eliminieren. Ziel dieser Filterung ist es, sicherzustellen, dass nur plausible Messungen für die weitere Analyse verwendet werden. Obwohl die Ergebnisse bereits während der Anwendung des FlowVeloTools gefiltert werden, kommt es unter kritischen Messbedingungen gelegentlich zu Fehlmessungen. Ein häufiger Fehler ist die Fehldetektion der Hauptströmungsrichtung der Partikel. Unter schwierigen Bedingungen wie Schneefall, sehr starkem Niederschlag oder erhöhtem Wellengang werden Schneeflocken, Regentropfen oder Wellen als Partikel erfasst und Messungen entsprechend verfälscht. Deshalb werden Einzelmessungen mit stark abweichenden Strömungsrichtungen mit dem Richtungsfilter herausgefiltert.

Messungen während der Nacht sind eine weitere Herausforderung. Oft sind zusätzliche Ausrüstung wie Licht- oder Infrarotstrahler erforderlich, um den Messbereich zu beleuchten. Ohne Beleuchtung können gelegentlich Reflexionen, auch vom Mond oder von Laternen, in Kombination mit Wellenbewegungen als Partikel identifiziert werden. Daher können Messungen, die in der Nacht ohne externe Beleuchtung gemacht wurden, mit einem Zeitfilter herausgefiltert werden. Für die Filterung werden Sonnenauf- und -untergang am jeweiligen Messtag bestimmt. Messungen vor Sonnenaufgang oder nach Sonnenuntergang werden im weiteren Prozess nicht berücksichtigt.

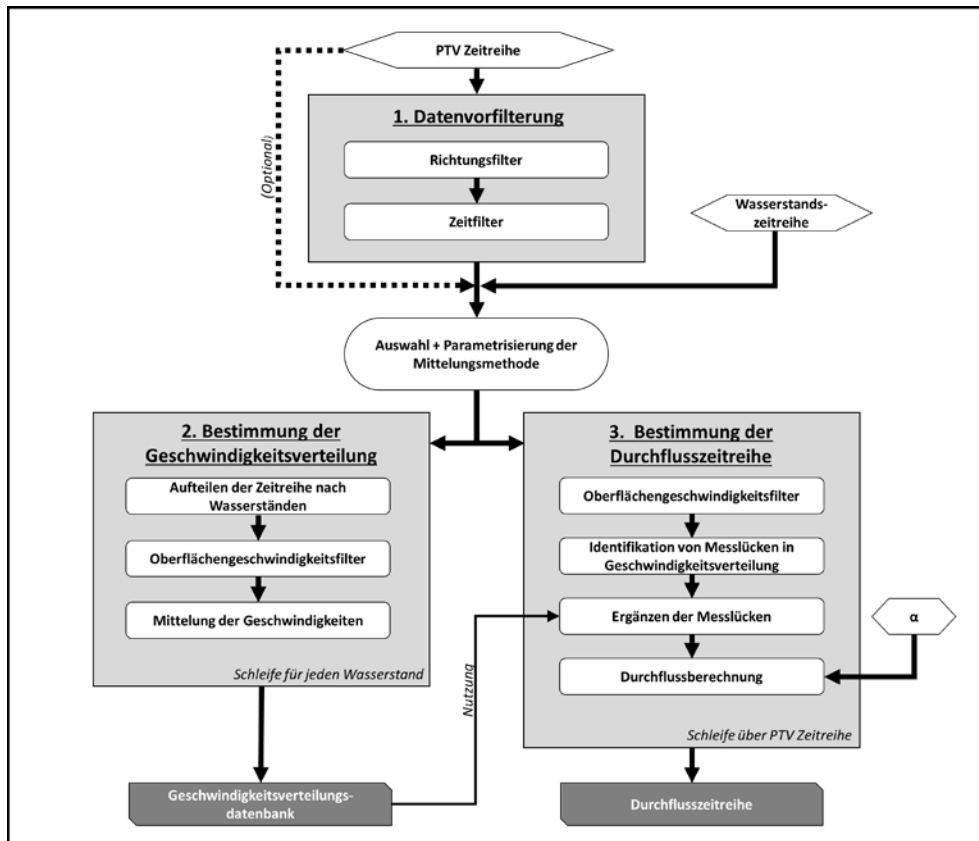


Abbildung 20: Arbeitsablauf bei der OptiQ-Methode zur Bestimmung von Durchflussganglinien aus Oberflächengeschwindigkeitsmessungen mit PTV

Die **Bestimmung der mittleren Oberflächengeschwindigkeitsverteilungen** erfolgt in Abhängigkeit des Wasserstandes und erfordert zunächst die Filterung einzelner Geschwindigkeitsvektoren mit einem Oberflächengeschwindigkeitsfilter. Dies ist erforderlich, um etwaige verbleibende fehlerhafte Werte, die beispielsweise durch windbedingte Beschleunigung bzw. Abbremsung oder durch Fehldetektionen bedingt sein können, zu eliminieren. Dazu werden für die Mittelungsfenster mittlere Oberflächengeschwindigkeiten und Standardabweichungen berechnet aus denen die minimalen und maximalen Grenzen der Geschwindigkeitsbereiche abgeleitet werden. Im Anschluss werden alle Geschwindigkeiten, welche außerhalb der definierten Grenzen liegen, entfernt. Eine Modifikation der Grenzen der Bereiche kann durch Multiplikation der Standardabweichungen mit einem konstanten Wert erfolgen, wodurch eine Anpassung des Messunsicherheitsbereichs möglich ist. Im Anschluss erfolgt eine Mittelung der verbliebenen Geschwindigkeitsvektoren, um die Oberflächengeschwindigkeitsverteilung zu bestimmen. Die Verteilung der Oberflächengeschwindigkeiten wird für jeden Wasserstand separat bestimmt und anschließend in einer Datenbank gespeichert. Die Datenbank wird zum Füllen von Messlücken herangezogen.

Die **Berechnung der Durchflusszeitreihen** erfolgt sequentiell. Dazu werden die einzelnen PTV-Messungen nacheinander eingelesen. Für die Bereinigung der einzelnen Messungen wird der gleiche Oberflächengeschwindigkeitsfilter angewandt, wie bei der Bestimmung der mittleren Oberflächengeschwindigkeitsverteilungen. Mit dem Mittelwert und der Standardabweichung werden fehlerhafte Einzelwerte entfernt. Für die eigentliche Berechnung werden die Mittelwerte innerhalb der Mittelungsfenster, beginnend am linken Flussufer, berechnet. Beim Auftreten eines Fensters ohne Messwerte wird der äquivalente Mittelwert entsprechend dem vorherrschenden Wasserstand und der Position des Mittelungsfensters aus der Datenbank entnommen und zur Lückenfüllung ver-

wendet. Der Durchfluss wird anhand der geschlossenen Geschwindigkeitsverteilung berechnet, indem die Teilflächen mit den mittleren Geschwindigkeiten multipliziert, summiert und schließlich mit α multipliziert werden. Mit dieser Methode erhält man für jeden Zeitschritt einen Durchflusswert und im Endergebnis eine Durchflusszeitreihe für jede gültige Messung.

Abbildung 21 zeigt den Einsatz der OptiQ-Methode für die Durchflussbestimmung. Die mittleren Fehler des Gütemaßes RMSE (Seite 28) konnte um mehr als 50 % reduziert werden. Zudem ist eine signifikante Abnahme der Streuung der optischen Messwerte zu beobachten, was zu einer verbesserten Anpassung der optisch bestimmten Durchflussganglinien an die Referenzwerte für alle drei Mittelungsmethoden führte. Die Erfassung der Durchflussspitzen ist weiterhin gewährleistet. Ein weiterer Vorteil der OptiQ-Methode besteht darin, dass auch ohne Messwerte der Oberflächengeschwindigkeit mithilfe der Datenbank der mittleren Oberflächengeschwindigkeiten Durchflussdaten berechnet werden können. In Abbildung 21 ist ein Bereich grau markiert, in dem die Kamera

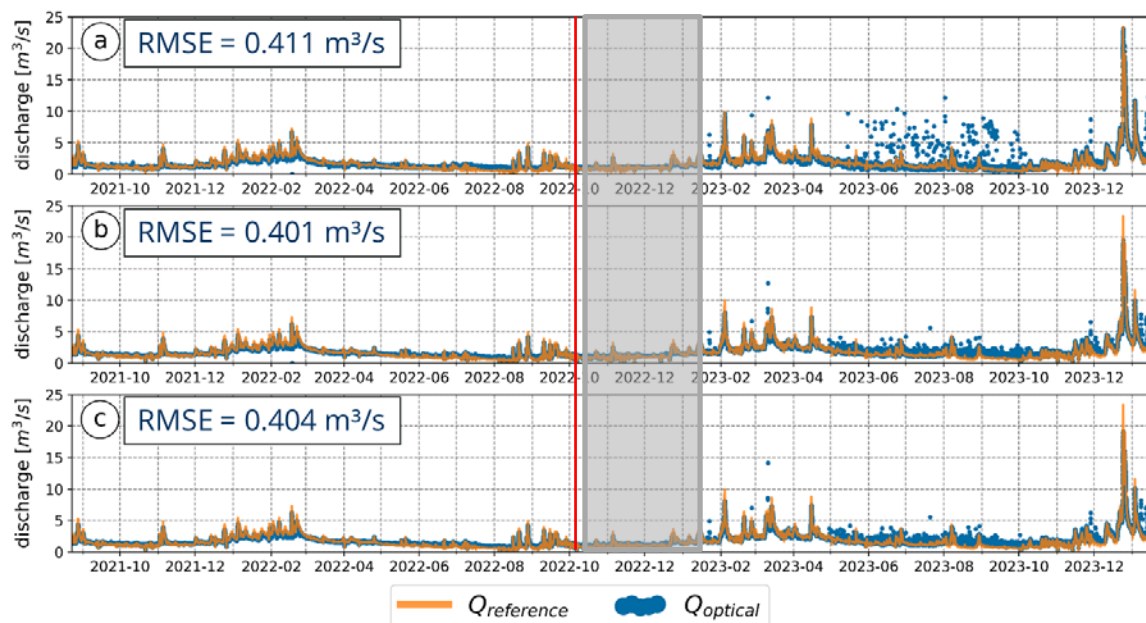


Abbildung 21: Mit der OptiQ-Methode bestimmte Durchflussganglinien für $\alpha = 0,85$ am Pegel Elbersdorf im Vergleich zur Referenz für drei Methoden der Mittelung der Oberflächengeschwindigkeit: a) arithmetisches Mittel; b) Teilflächenmittelung; c) gleitender Mittelwert

nicht funktionsfähig war. Die Wasserstandsmessungen der Referenz ermöglichten hier eine lückenlose Berechnung des Durchflusses in diesem Bereich. Zudem ist in Abbildung 21 der Zeitpunkt markiert, an dem am Pegel ein IR-Strahler installiert wurde (rote Linie). Es lässt sich konstatieren, dass das Tracking der Oberflächengeschwindigkeiten mit dem IR-Strahler ab dem genannten Zeitpunkt eine höhere Fehleranfälligkeit aufweist als bei Tageslicht. Dies wird insbesondere im Zeitraum von Mai 2023 bis Oktober 2023 ersichtlich. Bei der Betrachtung der Videoaufzeichnungen lässt sich eine Aktivität von Insekten, Fledermäusen und Fischen beobachten. Diese Aktivität wird gelegentlich bei PTV miterfasst. Die Filtereinstellungen, die bei Tag eine hohe Effektivität aufweisen, sind jedoch nicht in der Lage, alle Fehldetektionen bei Nacht zu eliminieren. In Bezug auf die drei Mittelungsverfahren zeigt die OptiQ-Methode unterschiedliche Stärken. Die Teilflächenmittelung sowie der gleitende Mittelwert weisen im mittleren und niedrigen Durchflussbereich eine ähnlich gute Funktionsfähigkeit auf tendieren im Hochwasserbereich allerdings zur Unterschätzung des Durchflusses. Dies kann durch eine Erhöhung des α -Wertes korrigiert werden kann. Folglich eignen sich beiden Methoden in besonderem Maße zur kontinuierlichen Erfassung von Zeitreihen. Das arithmetische Mittel hingegen liefert im Hochwasserbereich gute Ergebnisse, zeigt jedoch Schwie-

rigkeiten bei der adäquaten Abbildung des mittleren und niedrigen Durchflussbereichs. Diese Methode eignet sich in erster Linie für grobe Abschätzungen des Durchflusses. Ein besonderes Augenmerk gilt Messungen während der Nacht, insbesondere während der Sommermonate. In diesen Fällen sind verbesserte Filterkriterien erforderlich, um präzisere Ergebnisse zu erzielen.

4.2.3. KI für die Simulation des Niederschlag-Abfluss-Prozesses

4.2.3.1. Zielstellung

Die Vorhersage von Hochwassern, gerade in kleinen Einzugsgebieten (EZG) mit kurzen Gebietsreaktionszeiten ist keine triviale Aufgabe. Sie erfordert den Einsatz von robusten Vorhersagemodellen mit ausreichend großen Vorhersageweiten und hoher Zuverlässigkeit in Bezug auf den Eintrittszeitpunkt des Hochwassers und die Durchflussmenge, speziell im Hochwasserscheitel. Gerade in kleinen Gebieten können große Vorhersageweiten nur durch das Einbeziehen der Niederschlagsbeobachtung und -vorhersage in den Vorhersageprozess erreicht werden. Das Ziel bestand somit in der Entwicklung eines Vorhersagemodells für den Niederschlags-Abfluss-Prozess auf Basis eines Künstlichen Neuronalen Netzes (KNN). Dazu sollten zunächst geeignete, robuste Netz-Architekturen und relevante Eingangs- und Trainingsdaten identifiziert werden. Basierend auf Vorstudien fiel die Entscheidung für die Art des Neuronalen Netzes auf das sogenannte Long Short-Term Memory Netz (LSTM), da dieses durch seine innere Struktur auf die Verarbeitung von Zeitreihen spezialisiert ist (Hochreiter & Schmidhuber, 1997). Auch in der Hydrologie werden LSTM-Netze mittlerweile erfolgreich angewendet, wobei sie oftmals sogar bessere Ergebnisse zeigen als traditionelle konzeptionelle Modelle mit physikalischen Grundlagen oder auch andere Künstliche Neuronale Netze (Kratzert et al., 2018, Pahner et al., 2019). Diese LSTM-Netze bilden die Grundlage für alle in KI-NAP erfolgten Untersuchungen und resultierenden Modelle.

4.2.3.2. Vorverarbeitung der Daten

Für die KI-NAP wurde zunächst eine Vorhersage von niederschlagsgetriebenen Hochwasserereignissen mit einer Vorhersageweite von bis zu 24 Stunden angestrebt. Die Datengrundlage für das Training des KI-Modells wurde im Vorfeld aufbereitet, sodass ausschließlich signifikante und von Schnee möglichst unbeeinflusste Niederschlags-Abfluss-Ereignisse aus den jährlichen Zeitintervallen Ende Mai bis Anfang November dem Modelltraining zur Verfügung standen. Für die Ereignisidentifikation wurde ein Algorithmus erstellt, welcher aus den langjährigen Beobachtungsdaten automatisiert die Hochwasserzeiträume nach vorab festzulegenden Kriterien selektiert. Diese Kriterien stellten sicher, dass ausschließlich unabhängige Hochwasserereignisse über einem bestimmten Durchflussschwellwert und mit ausreichendem zeitlichen Abstand zum nächsten Ereignis für den Trainingsprozess berücksichtigt wurden.

Der Trainingsprozess (überwachtes Training) eines KNN erfordert eine Dreiteilung der zur Verfügung stehenden Datengrundlage in Trainings-, Validierungs- und Testdatensätze. Zuerst wurde ein kleiner Teil der Daten von dem Rest der Datengrundlage separiert und als unabhängige Instanz zur finalen Modellevaluation verwendet (Testdatensatz). Diese Daten waren dem trainierten Netz völlig unbekannt und simulierten dadurch potenzielle zukünftig auftretenden Niederschlags-Abfluss-Ereignisse. Für die Auswahl der Testereignisse wurden folgenden Kriterien zu Grunde gelegt: (1) das Ereignis mit dem zweithöchsten Scheiteldurchfluss aus dem Pool aller Ereignisse; (2) ein Ereignis mit einer räumlich relativ homogenen Niederschlagsverteilung und (3) ein Ereignis mit einer räumlich heterogenen Niederschlagsverteilung. Das Ergebnis war eine Kombination von je drei Testereignissen pro Pilot-Einzugsgebiet.

Das Training von KNN erfolgte in zwei in Schleife geschalteten Phasen: Zuerst führte das KNN eine Simulation für alle der Trainingsphase zugewiesenen Daten durch und korrigierte seine internen Parameter basierend auf den Differenzen zur Zielgröße. Anschließend führte das Modell mit seiner neuen Parametrisierung eine Validierung mithilfe eines anderen, von der Trainingsphase unabhängigen Datensatzes durch. Die Trainings- und Validierungsphase wurden in einem steten Wechsel wiederholt (jede Iteration wird Epoche genannt), sodass sich das Modell langsam seinem Optimum annäherte. Sobald sich die Modellgüte mit dem Validierungsdatsatz verschlechterte während sie sich mit dem Trainingsdatsatz weiterhin verbesserte, konnte von einer beginnenden Überanpassung an die Trainingsdaten ausgegangen werden und das Training wurde beendet. Die Aufteilung des Datensatzes in Trainingsdatsatz und Validierungsdatsatz erfolgte im Verhältnis 80 % / 20 %.

Die Zuordnung der Daten zu dem einen oder dem anderen Datensatz birgt jedoch eine gewisse Unsicherheit, da im Vorfeld nur schwer gesagt werden kann, von welchen Daten das Modell die beste Parametrisierung erhält. Deshalb wurde eine ereignisbasierte 5-fache (bzw. 5-faltige) Kreuzvalidierung durchgeführt. Das bedeutet, dass der Gesamtdatsatz an Ereignissen nach Abzug der Testereignisse zufällig in fünf etwa gleich große Gruppen unterteilt wurde. Jede Gruppe wurde einmal als Validierungsdatsatz genutzt und vier Mal im Trainingsdatsatz verwendet. Dadurch wurden fünf verschiedene Modelle mit derselben Konfiguration trainiert. Aus einer Mittelung ihrer Modellgüte konnte die „wahre“ Güte der Modellkonfiguration, unabhängig vom Einfluss der Zusammensetzung des Trainingsdatsatzes, abgeleitet werden. Die Bestimmung der Güte der Modellkonfigurationen diente der Auswahl der finalen, besten Modellkonfiguration für das operationelle Vorhersagemodell, welches am Ende mit allen zur Verfügung stehenden Daten, ohne Ausgliederung von Validierungs- und Testdatsätzen, trainiert wurde.

Bevor die Ereigniszeitreihen von Durchfluss und Niederschlag an den Trainingsprozess übergeben wurden, mussten vorhandene Fehlwerte bereinigt und die Daten über den z-Wert standardisiert werden:

$$z = \frac{x - \mu}{\sigma}$$

Der Wert bzw. die Zeitreihe z ist das standardisierte Ergebnis, x ist der zu standardisierende Ausgangswert bzw. die Ausgangszeitreihe, μ ist das arithmetische Mittel und σ die Standardabweichung der gesamten Zeitreihe des jeweiligen Einzugsgebiets. Standardisierung des Inputs hilft, KNN effizienter und robuster zu trainieren.

4.2.3.3. Methodik für die Entwicklung der KI-NAP

Die Entwicklung der KI-NAP erfolgte in der Programmiersprache Python unter Nutzung der Bibliotheken Tensorflow / Keras und wurde auf einer Workstation der Professur Hydrologie sowie dem HPC-System der TU Dresden durchgeführt. Als Ausgangs- und Vergleichsbasis für alle Modellentwicklungen, -erweiterungen und -optimierungen wurde ein Referenzmodell erstellt, das entsprechend dem Stand der Technik einem einfachen, einschichtigen LSTM Netz entspricht (Pahner et al., 2019). Tabelle 4 zeigt die Hyperparameter des Netzaufbaus und des Netztrainings. Das Referenzmodell besteht aus einem einschichtigen LSTM-Netz mit zwei Inputvariablen, auch Features genannt, die als Zeitreihen Schritt für Schritt von 30 LSTM-Neuronen, LSTM-Units genannt, prozessiert werden. Das Netz gibt parallel zu jedem Zeitschritt einen einzelnen Wert aus. Diese Ausgabewerte bilden so wieder eine Zeitreihe, welche der Zielvariable „Durchflussvorhersage mit Vorhersageweite y “ entspricht. Für jede Vorhersageweite wurde also ein separates Netz trainiert.

Tabelle 4: Hyperparameter für das Training des Referenzmodells von KI-NAP

| Hyperparameter | Wert |
|---------------------------------|---|
| LSTM-Schichten (LSTM-Units) | 1 (30) |
| Dropout-Rate der LSTM-Schichten | 0,2 |
| Maximale Epochenanzahl | 2000 |
| Early Stopping | Patience = 200, monitor = „val_loss“, mode = „min“ |
| Lernrate ReduceLRonPlateau | Start bei 0,005 monitor = „val_loss“; factor = 0,2; patience = 20; min_lr = 0,00001 |
| Optimierer | Adam |
| Zielfunktion | RMSE (Root Mean Square Error) |

Ausgehend von dem Referenzmodell wurden mehrere Experimente durchgeführt mit dem Ziel der Auswahl und Optimierung der Modellstruktur, der Eingangsdaten und des Trainingsprozesses. Tabelle 5 gibt einen Überblick zum Versuchsaufbau der durchgeführten Experimente und der damit einhergehenden Modellkonfigurationen. Mit (x) sind die durchgeführten Experimente markiert. Eine Aufschlüsselung der Farb- und Zeichenkodierung befindet sich in Tabelle 6.

Tabelle 5: Experimente für die Entwicklung der KI-NAP

| Modell | | | Daten | | | | | |
|--------|---|---|-------|---|---|---|-----|-----|
| | | | 0 | 1 | 2 | | | |
| | | | 0 | 0 | 0 | 1 | 1+2 | 1+3 |
| R | r | 0 | x | x | x | x | | |
| | a | 0 | x | x | | x | x | X |
| | | 1 | | | | x | | |
| | | 2 | | | | x | | |
| A | a | 0 | x | x | | x | | X |

Tabelle 6: Erläuterungen zu den Experimenten für die Entwicklung der KI-NAP

| | | |
|-----------------------|---|---|
| Modell-Architekturen | R | Referenzmodell (1-schichtiges LSTM-Netz, 30 Units) |
| | A | LSTM Encoder-Decoder Netz |
| Modell-Hyperparameter | r | Hyperparameter-Konfiguration des Referenzmodells |
| | a | Optimierung der Anzahl der LSTM-Units |
| Modell-Zielfunktion | 0 | RMSE (Root Mean Square Error) |
| | 1 | MSE-HW und PSE (Gewicht auf Scheiteldurchflussbereich und Timing) |
| | 2 | MSE-HW (Gewicht auf Scheiteldurchflussbereich) |
| Daten-Quellen | 0 | Voll-synthetischer Datensatz (Sinus-Schwingungen) |
| | 1 | Halb-synthetischer Datensatz (Deterministisches NA-Modell) |
| | 2 | Beobachtungsdaten aus Pilot-Einzugsgebieten |
| Daten-Erweiterung | 0 | Keine Erweiterung |
| | 1 | Erweiterung des Datenzeitraums von 2007-2015 zu 2007-2021 |
| | 2 | Weiterer Input: räumlich-statistische Niederschlagsinformationen |
| | 3 | Weiterer Input: ideale Niederschlagsvorhersage aus Beobachtung |

Ein einzelnes trainiertes Netz wird als Modellinstanz bezeichnet. Da das Netztraining einer gewissen Zufälligkeit unterliegt, z. B. bei der Initialisierung seiner Parameter, wurde jede Modellkonfiguration mehrmals trainiert. Jede getestete Modellkonfiguration besitzt demnach mehrere zugehörige Modellinstanzen, hervorgerufen durch die Trainingswiederholungen und die 5-faltige Kreuzvalidierung. Durch diese Vielzahl an Modellinstanzen von einer Modellkonfiguration konnte die Güte der Konfiguration statistisch evaluiert werden.

Die Auswertung erfolgte anhand der vom Training unabhängigen Testereignisse sowohl über eine Auswahl an Gütemaßen als auch visuell. Die zur Evaluierung ausgewählten Gütemaße sind der NSE (Nash-Sutcliffe Effizienz), der MSE-HW (Mean Square Error für Hochwasser), der PSE (Phase Shift Error, deutsch: Phasenfehler) und der Peak Error.

Der NSE ist ein in der Hydrologie häufig verwendetes Gütemaß für Durchflussganglinien:

$$NSE = 1 - \frac{\sum_{t=1}^n (Q_{obs}(t) - Q_{sim}(t))^2}{\sum_{t=1}^n (Q_{obs}(t) - \bar{Q}_{obs})^2}$$

Q_{obs} und Q_{sim} sind der beobachtete und der simulierte Durchfluss, t repräsentiert den jeweiligen Zeitschritt und n stellt die Gesamtanzahl der Zeitschritte dar. \bar{Q}_{obs} ist der Mittelwert der beobachteten Durchflusszeitreihe. Ein NSE-Wert von 1 weist auf eine perfekte Übereinstimmung hin, während ein NSE-Wert kleiner gleich 0 dem Modell keine bessere Genauigkeit bescheinigt als dem mittleren Durchfluss. Ein Vorteil des NSE ist seine inhärente Normierung der Fehlerwerte, sodass ein direkter Vergleich zwischen Datensätzen, z. B. unterschiedlichen EZG, möglich ist.

Der MSE-HW ist ein Mean Square Error mit besonderem Gewicht auf dem Ganglinienbereich um den Scheiteldurchfluss der beobachteten Ganglinie. Der MSE des Ganglinienbereichs, welcher oberhalb von 90 % des Scheiteldurchflusswertes liegt, nimmt 50 % der MSE-HW-Wertes ein. Dasselbe Gewicht erhält der MSE des Rests der gesamten Ganglinie. Der Optimalwert des MSE-HW liegt bei 0.

$$MSE = \frac{\sum_{t=1}^n (Q_{obs}(t) - Q_{sim}(t))^2}{n}$$

$$MSE-HW = 0.5 MSE_{peak} + 0.5 MSE_{no\ peak}$$

Der PSE ist ein Gütemaß für das Timing der gesamten Vorhersagezeitreihe. Dabei wird die gesamte simulierte Zeitreihe gegen die beobachtete Zeitreihe verschoben und die Verschiebungsdistanz, die den kleinsten RMSE-Wert hervorbringt, wird PSE genannt. Je näher der PSE bei 0 liegt (Einheit äquivalent zum Zeitschritt der Zeitreihe, hier Stunden), desto besser stimmt das Timing der Modellvorhersage mit der Beobachtung überein. Der zugrundeliegende RMSE berechnet sich folgendermaßen:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Q_{obs}(t) - Q_{sim}(t))^2}{n}}$$

Der Peak Error bezieht sich auf den Scheiteldurchfluss der beobachteten und simulierten Ganglinie. Er ist also der Amplitudenfehler des Hochwasserscheitels und hat sein Optimum bei 0:

$$Peak\ Error = \max(Q_{sim}) - \max(Q_{obs})$$

4.2.3.4. Ergebnisse

Die finale Modellkonfiguration (violett hinterlegtes (x) in Tabelle 5) besteht aus einem LSTM mit Encoder-Decoder-Architektur und 180 LSTM-Units, trainiert mit der Zielfunktion RMSE und mit realen Ereigniszeitreihen aus den Pilot-Einzugsgebieten aus dem Zeitraum 2007 bis 2021. Die zwei

Inputvariablen P und Q wurden durch 24 weitere Inputvariablen ergänzt: die ideale Niederschlagsvorhersage von 24 Stunden Dauer. Jede Vorhersageweite wurde dem Netz als eigenständige Variable, auch Feature genannt, übergeben, sodass das Netz am Ende 24 zusätzliche Zeitreihen im Input erhielt. Diese Modellkonfiguration wurde in jedem Einzugsgebiet separat trainiert, sodass nach dem Training ein sogenanntes lokales Modell für das jeweilige Gebiet vorlag.




Abbildung 22: Vergleich der mittleren Güte für lokales Modell vs. Referenzmodell

keinen Vorteil aus der Niederschlagsvorhersage zieht. Die Unterschiede zwischen lokalem Modell und Referenzmodell bestehen in der Erweiterung des Datenzeitraums, der Verwendung eines Encoder-Decoder Architektur für das LSTM-Netz und der Erhöhung der LSTM-Neuronen von 30 auf 180 Units, also einer Vergrößerung des Parameterraums des Modells. In den Vorangegangenen Experimenten haben diese Veränderungen nur minimale Verbesserungen gebracht. Die größte Auswirkung hatte die Nutzung der idealen Niederschlagsvorhersage.

Der Grund für die Nutzung der Encoder-Decoder Architektur für das LSTM war die erhöhte Flexibilität in der Integration von zusätzlichen Inputvariablen und der einfachen Möglichkeit, mit einer einzigen Modellinstanz den Durchfluss für alle Vorhersageweiten zu berechnen. Ohne die Encoder-Decoder Architektur würde für jede Vorhersageweite ein separates Modell benötigt werden.

Abbildung 22 zeigt eine Übersicht über die mittlere Vorhersagegüte des lokalen Modells im Vergleich zum Referenzmodell und zum Persistenzmodell. Das Persistenzmodell emuliert eine Durchflussvorhersage allein auf Basis des letzten beobachteten Durchflusswertes. Das lokale Modell erzielt im Schnitt eine deutlich bessere Vorhersagegüte (bezogen auf alle Gütemaße) in den EZG St. Egidien und Wiesa, während es in Elbersdorf im Schnitt zu keinem besseren Ergebnis führt. Abbildung 23 bestätigt diese Beobachtung anhand der exemplarisch besten Modellinstanzen für die Vorhersageweite von 6 h, besonders für die Gebiete St. Egidien und Wiesa.

Das deutet darauf hin, dass gerade St. Egidien und Wiesa stark von Niederschlagsvorhersagen im Input abhängig sind, wohingegen Elbersdorf, welches von den drei Gebieten die längste Reaktionszeit besitzt, bis zu einer Vorwarnzeit von 6 h

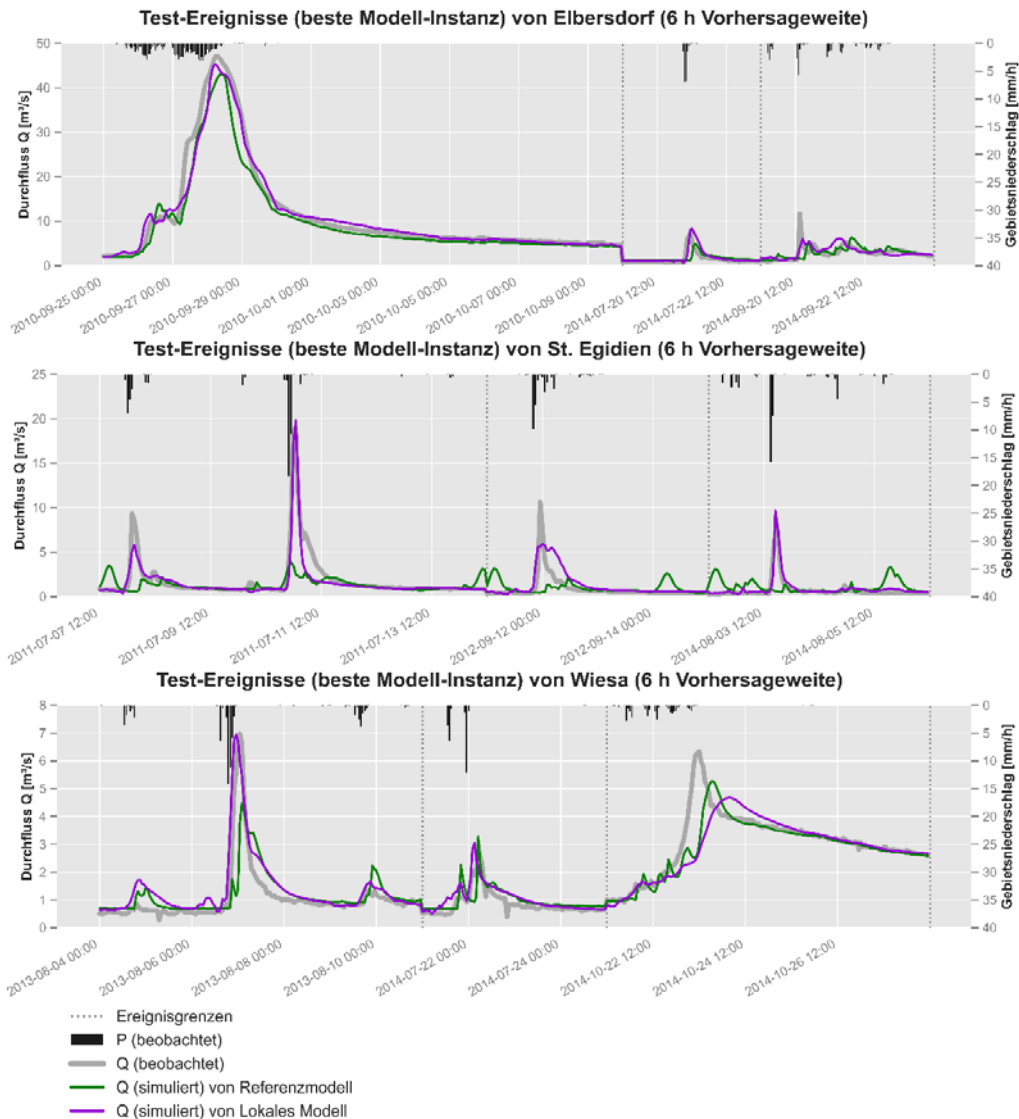


Abbildung 23: Ganglinien der Durchflussvorhersage von lokalem Modell vs. Referenzmodell für die Vorhersageweite von 6 h

4.3. Generalisierung der KI's für den robusten Einsatz

4.3.1. Optische Bestimmung des Wasserstandes

4.3.1.1. Zielstellung

Die Generalisierung der KI für den Wasserstand zielte auf die Weiterentwicklung der KI-W hin zu möglichst robusten und übertragbaren Lösungen. Insofern lag der Schwerpunkt der Arbeiten auf Datensätzen mit schwierigeren Beobachtungsbedingungen (u. a. Regen und Schnee, Nebel, Nacht) und einer entsprechenden Erweiterung des Trainingsdatensatzes sowie der Erprobung von Methoden zum „Nachtrainieren“ existierender Netze. Ein besonderer Fokus lag auf der Messung bei Nacht sowie die Erprobung der KI's und des photogrammetrischen Verfahrens auf bisher unbeobachtete Standorte, speziell den Messstellen Typ B. Im Ergebnis sollte ein operationell einsetzbares, KI-basiertes Verfahren entwickelt werden.

4.3.1.2. Messung bei Dunkelheit

In ähnlicher Weise zu den Tagesdaten wurde ein Trainingsdatensatz für Bilder erstellt, die mit dem Nahinfrarotsensor aufgenommen wurden. Da in diesem Fall keine öffentlich zugänglichen Infrarotbilder zur Verfügung standen, war die Erstellung eines allgemeineren und übertragbaren Datensatzes nur begrenzt möglich. Deshalb wurde ein eigener Datensatz mit 146 KIWA-Bildern erstellt, der verschiedene Wetterbedingungen und Wasserstände abdeckt. Danach wurde ein eigenes Netz für die Segmentierung der Wasserflächen aus den Nachtbildern trainiert. Hierbei wurde der gleiche Netztyp wie bei den Tagesbildern verwendet - das UperNet+ResNeXt50 - und eine Genauigkeit von 99,1 % erzielt. Abbildung 24 zeigt ausgewählte Nachtaufnahmen des Trainingsdatensatzes mit manuell segmentierten Wasserflächen und gibt einen Überblick über die Herkunft der Bilder. Mit Hilfe dieses Netzes war es nun möglich, den Wasserstand entsprechend dem Vorgehen in Abbildung 13 auch für Nachtbilder zu ermitteln. Im Ergebnis konnten somit komplette Zeitreihen des Wasserstands prozessiert werden.




Abbildung 24: Training der KI zur Segmentierung der Wasserflächen für Nachtbilder

4.3.1.3. Ergebnisse für die Messstellen Typ A

Für eine Bewertung der Güte der kamera-basierten Wasserstandsmesswerte wurden diese an den Pegelstandorten mit den Referenzmessungen verglichen (siehe Kapitel 4.1.1.4.). Die Referenz wurde durch Mittelwertbildung der in 15-Minuten-Zeitfenstern gemessenen Werte berechnet. Da diese Werte im Gegensatz zum Kamerapegel keiner Momentaufnahme des Wasserstandes entsprechen, sondern einem 15-minütigen Mittelwert, wurden die Vergleiche zur Bestimmung der Genauigkeit der Methode auf aggregierter Basis durchgeführt, wobei die kamera-basierten Werte entsprechend dem Vergleichszeitbasis alle 24 Stunden, Tag oder Nacht gemittelt wurden. Mit dieser Strategie lassen sich potenzielle Fehler beim Vergleich ausschließen, da die Referenzdaten nicht exakt denselben Wasserstand im Fluss repräsentieren.

Im Projektzeitraum hat das kamera-basierte Wasserstandsmesssystem Daten zwischen 660 Tagen (22 Monate) und 946 Tagen (31,5 Monate) je nach Installationszeitpunkt der Kamera am Messpegel verarbeitet. Insgesamt wurden 219.720 Bilder automatisch prozessiert, wovon die meisten Bilder während des gesamten Beobachtungszeitraums kontinuierlich aufgenommen wurden. Dabei konnte eine Nutzungsrate (erfasste Bilder im Verhältnis zu gültigen Wasserstandsmessungen) von 86,9 % bis 99,2 % erzielt werden. Bei der Analyse der einzelnen Bildverarbeitungsschritte zeigte sich, dass ein Filter von entscheidender Bedeutung ist, um Bilder auszuschließen, die in der Regel beschädigt sind oder nicht segmentiert werden können. Dies ist in der Regel auf eine schlechte Bildqualität zurückzuführen, die durch ungünstige Wetterbedingungen (z. B. Nebel, starker

Schneefall) oder schlechte Lichtverhältnisse (z. B. Sonnenuntergang, Sonnenaufgang oder starke Reflexionen) verursacht wird. Der auf der Bildqualität basierende Filter sorgte für eine Erfolgsquote des Arbeitsablaufs (gültige Bilder gegenüber Wasserstandsmessungen) von über 99 % an allen Standorten.

Die aus dem Arbeitsablauf erhaltenen Wasserstandswerte wurden auf der Grundlage der Standardabweichung der ermittelten Z-Koordinaten gefiltert, wobei der Prozentsatz der Ergebnisse, die diesen Filter passieren, von 96,2 % bis 99,9 % reicht. Die in diesem Stadium herausgefilterten Dateien sind hauptsächlich auf eine fehlerhafte Wassersegmentierung im Bild oder auf sehr niedrige Wasserstände zurückzuführen, die zu Überschneidungen der Wasserlinie mit Teilen des Modells führten, die nicht gut rekonstruiert wurden (z. B. der Kontakt zwischen dem Flussbett und den Uferböschungen). In beiden Fällen kam es zu unregelmäßigen Schnittpunkthöhen mit dem 3D-Modell.

Tabelle 7 zeigt den Vergleich zwischen Referenz und Kamerapegel an den Standorten Elbersdorf, Lauenstein und Großschönau separiert nach Messungen am Tag (TAG), in der Nacht (NIR) und der gesamten Reihe (TOTAL) für die Mittelwerte über die Zeitbasis und den direkten Vergleich zum Aufnahmezeitpunkt mit den oben beschriebenen Einschränkungen. Der Wert „Genauigkeit“ stellt den Mittelwert aller absoluten Differenzen dar und wird zur Schätzung der Abweichung der optischen Messung von der Referenz verwendet. *Std* beschreibt die Standardabweichung der Differenzen und ρ die Korrelation zwischen den Messwerten. Die für den gesamten Zeitraum gemessenen Genauigkeitswerte liegen zwischen 1,0 - 2,3 cm bei einer Standardabweichung von $\leq 3,0$ cm. Die besten Ergebnisse wurden für den Pegel Lauenstein erzielt. Aufgrund des Kamerastandortes mit Blick auf eine senkrechte Ufermauer (siehe Abbildung 6) lagen hier nahezu ideale Beobachtungsbedingungen vor. Größere Unterschiede verzeichnete der Standort in Elbersdorf, die u. A. aus einer Zunahme der Vegetation entlang der Uferlinie resultieren, die eine Segmentierung der Wasserfläche erschwerte. Weiterhin befindet sich oberhalb des Pegels eine Wasserkraftanlage, deren Schwall- und Sunk-Betrieb zu größeren Abweichungen mit den Referenzwerten führte. Der Standort in Großschönau ordnet sich bezüglich der Genauigkeit zwischen den anderen Standorten ein. Hier bestand die Herausforderung in der verwendeten Weitwinkeloptik, deren Verzeichnungen an den Bildrändern Einfluss auf die exakte Positionsbestimmung der Passpunkte hat.

Tabelle 7: Güte der kamera-basierten Wasserstandsmessung für die Messstellen Typ A (Elbersdorf – ELB, Lauenstein – LAU, Großschönau – GRO)

| Standort | Optische Wasserstandsmessung | | | | | |
|------------------|----------------------------------|--------|--------|-------------|--------|--------|
| | Direkter Bild-Referenz Vergleich | | | Mittelwert | | |
| | Genauigkeit | Std | ρ | Genauigkeit | Std | ρ |
| ELB TAG | 2,4 cm | 3,2 cm | 0,93 | 2,3 cm | 3,0 cm | 0,95 |
| ELB NIR | 3,3 cm | 3,9 cm | 0,95 | 3,1 cm | 3,7 cm | 0,93 |
| ELB TOTAL | 2,7 cm | 3,4 cm | 0,94 | 2,3 cm | 3,0 cm | 0,95 |
| LAU TAG | 1,3 cm | 1,7 cm | 0,97 | 1,0 cm | 1,3 cm | 0,99 |
| LAU NIR | 1,3 cm | 1,4 cm | 0,98 | 1,2 cm | 1,3 cm | 0,97 |
| LAU TOTAL | 1,3 cm | 1,6 cm | 0,97 | 1,0 cm | 1,3 cm | 0,99 |
| GRO | 1,9 cm | 2,3 cm | 0,97 | 1,7 cm | 2,1 cm | 0,98 |

Abbildung 25 zeigt exemplarisch bis zum Januar 2024 den täglichen Vergleich zwischen Referenzmesswert und optischer Messung der Kamerapegel für die gesamten Zeitreihen. Die Verwendung von Farben zeigt an, ob der Referenzwert im Vergleich zur optischen Messung unter- oder überschätzt wird, um die Identifikation von Clustern oder Perioden der Abweichung zu erleichtern.



Abbildung 25: Vergleich der Tagesmittelwerte des Wasserstandes der optischen Messung mit der Referenz für die Messstellen Elbersdorf (oben), Lauenstein (Mitte) und Großschönau (unten)

4.3.1.4. Übertragung und Test an Messstellen Typ B

Ein Test der Übertragbarkeit auf unbekannte, neue Standorte erfolgte anhand der Messstelle Typ B in Neukirch. Abbildung 26 zeigt beispielhaft die Wasserstandsmessung entlang der roten Linie in der Verschneidung mit dem 3D-Modell. Als Referenz kann hier lediglich die manuelle Ablesung am Lattenpegel dienen. Insgesamt funktioniert die Übertragbarkeit auf neue Standorte mit dem entwickelten Verfahren sehr gut. Für die gezeigte Bildaufnahme konnte eine nahezu identische Messung von ca. 41 cm durch die beiden Messsysteme erzielt werden. Die kleine Abbildung rechts illustriert die Auswertung der Kamerabilder über einen längeren Zeitraum und die damit einhergehende Messzeitreihe der optischen Messung. Eine weitere Erhöhung der Genauigkeit und Robustheit der optischen Messung kann erzielt werden, wenn noch ein paar sehr wenige (max. 10) Bilder vom neuen Standort genutzt werden können, um KI zur Wasserflächensegmentierung zu aktualisieren. Für die weiteren Messstellen Typ B (Abbildung 6) liegen noch keine Ergebnisse vor, da an diesen Standorten unterschiedliche Herausforderungen auftraten (z. B. stark wechselnder Vegetationsbewuchs, große Beobachtungsentfernung, Kamerakalibrierung an fest montierten Kameras, etc.). Allerdings liefern diese Standorte wichtige Erkenntnisse in Bezug auf die idealen Mess- und Beobachtungsbedingungen für zukünftig einzurichtende Standorte.



Abbildung 26: Optische Wasserstandsmessung an der Messstelle Typ B in Neukirch mit zugehöriger Ganglinie

4.3.1.5. Fazit

Ein effizientes und robustes KI-gestütztes Kamera-Messsystem für die langfristige Überwachung von Wasserständen in nahezu Echtzeit konnte im Rahmen des Vorhabens entwickelt werden. Über einen Zeitraum von 2,5 Jahren hat unser Ansatz bewiesen, dass er in der Lage ist, Wasserstände mit cm-Genauigkeit Tag und Nacht zu messen. Die Integration von neuronalen Netzen zur Segmentierung von Wasserflächen und zur Identifizierung von Passpunkten in Verbindung mit photogrammetrischen Techniken ermöglicht die automatische Verarbeitung der Bilder, auch unter ungünstigen Beobachtungsbedingungen. Wenn wenige Bilder unter ungünstigen Wetterbedingungen und von neuen Standorten im Training ergänzt werden, ergibt sich eine gute Übertragbarkeit des Kamerapegels auf unbeobachtete Standorte. Die Ergebnisse zeigen jedoch auch, dass die

Ungenauigkeiten mit der Beobachtungszeit zunehmen, was die Notwendigkeit einer angemessenen Wartung sowohl der Umgebung (z. B. Vegetation) als auch der Kameras (z. B. Kalibrierung) verdeutlicht. Zukünftige Arbeiten zur Minimierung dieses Wartungsaufwands (z. B. Einsatz von Stereosystemen für die regelmäßige Aktualisierung der 3D-Modelle zur Anpassung an Geländeänderungen und zur automatischen Kalibrierung der Kameras) können zu weiteren Verbesserungen der Messqualität und Robustheit führen.

4.3.2. Optische Bestimmung des Durchflusses

4.3.2.1. Zielstellung

Auch für die optische Bestimmung des Durchflusses bestand das Ziel der Generalisierung in der Weiterentwicklung der Methoden hin zu möglichst robusten und übertragbaren Lösungen. Dies betraf die Messungen bei schwierigeren Beobachtungsbedingungen (u. a. Regen und Schnee, Nebel) mit einem besonderen Schwerpunkt auf der Messung bei Nacht. Zudem wurden Methoden zur Bestimmung des Geschwindigkeitsindexbeiwertes für eine verbesserte Durchflussbestimmung untersucht. Für einen Test der Übertragbarkeit und Robustheit der Methode, wurde diese an bisher unbeobachteten Standorten erprobt. Hierbei wurde der komplette Arbeitsablauf für eine vollständige, optische Messung (Abbildung 2) auf seine Eignung überprüft.

4.3.2.2. Messung bei Dunkelheit

Zur Erfassung von optischen Messwerten auch während der Nachtstunden wurden an den Messstellen in Elbersdorf und Lauenstein Infrarot(IR)-Strahler installiert. Dies ermöglichte die kontinuierliche Messung der Oberflächenfließgeschwindigkeiten mit PTV über den gesamten Tageszyklus. Allerdings wurde festgestellt, dass die für den Tag optimierten Trackingparameter der PTV-Methode nicht ohne weiteres auf die Nachtmessungen übertragbar sind. Die resultierenden Trackingergebnisse wiesen signifikante Abweichungen auf, insbesondere in Bezug auf die Anzahl der nachverfolgten Partikel und die berechneten Geschwindigkeiten. Um diese Diskrepanz zu beheben, wurden die Trackingparameter tageszeitabhängig optimiert. Die neuen, für die Nacht angepassten Parameter, ermöglichen eine deutlich genauere Erfassung der Partikelanzahl und verhindern eine Überschätzung der Geschwindigkeiten.




Abbildung 27: Geschwindigkeitsmessung mit PTV bei Nachtaufnahmen am Beispiel des Pegels Elbersdorf mit Parameterinstellungen für Tageaufzeichnungen (links) und mit optimierten Parameterinstellungen für die Nacht (rechts)

4.3.2.3. Wasserstandsabhängiger Geschwindigkeitsindexbeiwert

Die Erkenntnisse aus der Fachliteratur (Kapitel 4.2.2.3) und den Ergebnissen der Methodenentwicklung (Kapitel 4.2.2.4) zeigen, dass der Geschwindigkeitsindexbeiwert α keine Konstante ist,

sondern vielmehr ein Verhalten in Abhängigkeit des Wasserstandes aufweist. Liegen Referenzmesswerte vor (W und Q), so kann mit Hilfe der Gleichung für die Durchflussbestimmung (Seite 19) die Charakteristik der Abhängigkeit $\alpha(W)$ ermittelt werden unter Verwendung der Datenbank der optisch gemessenen, mittleren Oberflächenfließgeschwindigkeiten. Der derart bestimmte α -Wert entspricht dabei eher einem Korrekturfaktor, um Fehler in der optischen Messung der Fließgeschwindigkeiten zu korrigieren und die optisch ermittelten Durchflüsse in Bezug auf die Referenz zu korrigieren. Abbildung 28 visualisiert das wasserstandsabhängige Verhalten des α -Wertes für die Messstellen Typ A. Die blaue Kurve zeigt den angepassten Funktionsverlauf $\alpha(W)$, der letztendlich für die Bestimmung des Durchflusses in Abhängigkeit vom Wasserstand aus den Messwerten der Oberflächengeschwindigkeit verwendet wird




Abbildung 28: Geschwindigkeitsindexbeiwert α in Abhängigkeit vom Wasserstand sowie angepasste Funktion $\alpha(W)$ für die Pegelstandorte Elbersdorf (links), Großschönau (Mitte) und Lauenstein (rechts)

4.3.2.4. Ergebnisse für die Messstellen Typ A (Pegelstandorte)

Die Ergebnisse optisch bestimmten Durchflüsse mit der OptiQ-Methode und wasserstandsabhängigem α -Wert sind in Abbildung 29 für die Messstellen Typ A (Pegelstandorte) illustriert. Dargestellt ist der zeitliche Verlauf des optisch bestimmten Durchflusses ausgehend vom Installationszeitpunkt der Kamera bis Anfang Januar 2024 im Vergleich zur Referenz, sowie im kleinen Bild, die jeweilige WQ -Beziehung der Referenz im Vergleich zu den optischen Messwerten. Dabei liegt der Anwendung der OptiQ-Methode das Verfahren der Teilflächenmittelung zur Bestimmung der Oberflächengeschwindigkeitsverteilung zu Grunde, was anhand des Pegels Elbersdorf (Abbildung 29 oben) einen direkten Vergleich zu Abbildung 21 b erlaubt. Hier wird ersichtlich, dass die Anwendung der $\alpha(W)$ -Funktion und der tageszeitabhängigen Trackingparameter zu einer verbesserten Anpassung an die Referenzmesswerte führte, insbesondere in den mittleren und niedrigen Durchflussbereichen. Für höhere Durchflüsse lässt sich eine leichte Überschätzung der Durchflüsse beobachten. Die Übertragbarkeit der Methode auf andere Standorte wurde anhand der Messstellen in Großschönau und Lauenstein geprüft (Abbildung 29 Mitte und unten). Dabei stellte der Pegel Lauenstein eine besondere Herausforderung dar, da an diesem Pegel im Mittel- und Niedrigwasserbereich kaum Partikel für die Anwendung des PTV-Verfahrens vorhanden sind. Dieses Problem tritt vor allem in den Sommermonaten auf (Abbildung 30 links und Mitte) und resultiert in einer besonders starken Unterschätzung und großen Streuung des Durchflusses. Im Hochwasserbereich (Abbildung 30 rechts) sind, wie auch in Elbersdorf und Großschönau, viele Partikel über das gesamte Profil für die Messung der Oberflächenfließgeschwindigkeit vorhanden. Durch den Einsatz der OptiQ-Methode mit $\alpha(W)$ -Funktion konnte eine signifikante Verbesserung der Messergebnisse in allen Durchflussbereichen erzielt werden. Diese Erkenntnis belegt auch Tabelle 8, die einen Vergleich des Gütekriteriums RMSE zeigt. Der Einsatz der OptiQ-Methode mit ihrer Fähigkeit zum

Schließen von Datenlücken führte für alle Messstellen Typ A zu einer signifikanten Reduktion des Fehlers gegenüber der bisherigen Praxis der Durchflussbestimmung (vgl. Kapitel 4.2.2.3).

Tabelle 8: Vergleich der Gütemaße für die optische Durchflussbestimmung basierend auf PTV

| Optische Durchflussbestimmung basierend auf PTV | | |
|---|--------------------------------------|-------------------------|
| Standort | Bisherige Praxis mit $\alpha = 0,85$ | OptiQ mit $\alpha(W)$ |
| | RMSE | RMSE |
| Elbersdorf | 1,009 m ³ /s | 0,237 m ³ /s |
| Großschönau | 1,106 m ³ /s | 0,349 m ³ /s |
| Lauenstein | 0,815 m ³ /s | 0,105 m ³ /s |

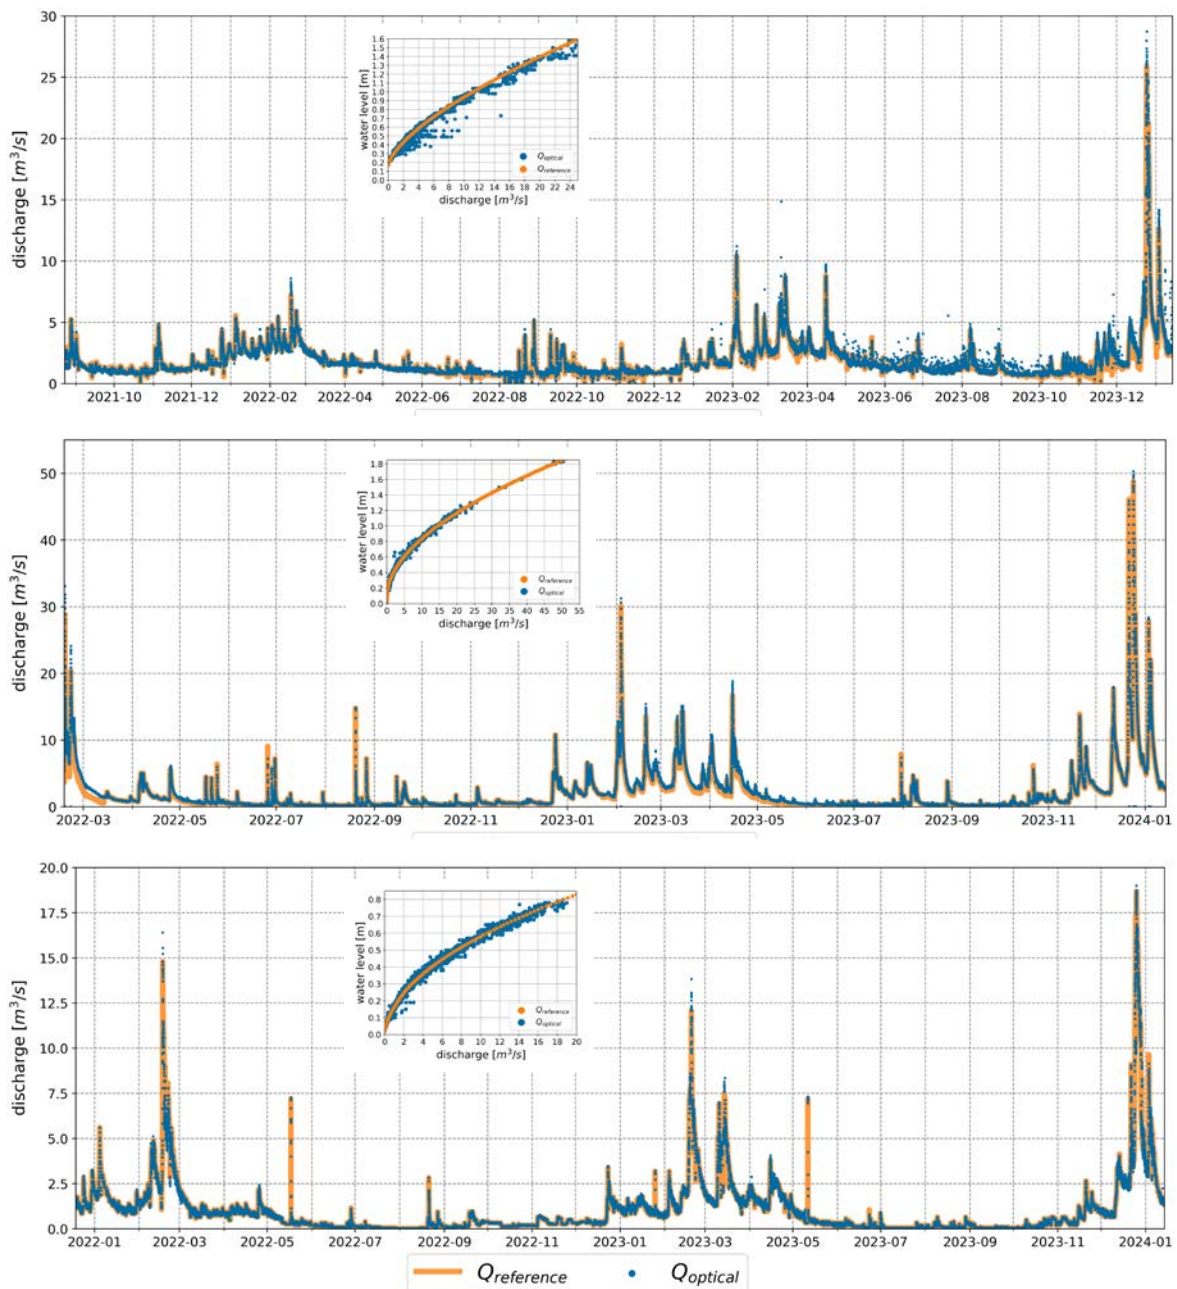


Abbildung 29: Optisch bestimmte Durchflussganglinien mit wasserstandsabhängigem α -Wert im Vergleich zur Referenz für die Messstellen Typ A in Elbersdorf (oben), Großschönau (Mitte) und Lauenstein (unten)




Abbildung 30: Messbedingungen für das Partikeltracking am Standort Lauenstein bei niedrigem Durchfluss (links), mittlerem Durchfluss (Mitte) und erhöhtem Durchfluss (rechts)

4.3.2.5. Übertragung und Test an Messstellen Typ B

Ein Test der Übertragbarkeit auf unbekannte, neue Standorte erfolgte anhand der Messstelle Typ B in Neukirch. Sämtliche zuvor erzielte, kamerabasierte Messergebnisse wurden für die Durchflussbestimmung entsprechend des Arbeitsablaufes in Abbildung 2 verwendet. Konkret betrifft dies das 3D-Geländemodell für die Ableitung des Querprofils (Kapitel 4.1.1.3), die mittels KI segmentierte Wasserfläche für den Suchbereich des Partikeltrackings (Kapitel 4.2.1.2 und 4.3.1.4, Abbildung 26) und der ermittelte Wasserstand für die Bestimmung der Fließfläche und des Durchflusses (Kapitel 4.2.1.3 und 4.3.1.4, Abbildung 26). Um möglichst plausible Durchflussergebnisse mit der OptiQ-Methode zu erhalten, wurden lediglich Wasserstandsmessungen mit einer Standardabweichung von 5 cm oder weniger verwendet. Ähnlich wie an den Messstellen Typ A zeigte sich die Problematik, dass bei niedrigen Wasserständen eine geringe Anzahl an Partikeln detektiert und nachverfolgt werden konnte (Abbildung 32, links). Infolgedessen sind signifikante Schwankungen der Messwerte im niedrigen Durchflussbereich zu beobachten (Abbildung 31). Die Ergebnisse der Oberflächengeschwindigkeit im höheren Durchflussbereich weisen eine ausreichende Anzahl an Partikeln auf (Abbildung 32, rechts), womit der Durchflussverlauf im Anstieg und Rückgang von




Abbildung 32: Messergebnisse der Oberflächengeschwindigkeit mit PTV bei niedrigem Wasserstand (9 cm - links) und bei erhöhtem Wasserstand (41 cm - rechts)




Abbildung 31: Durchflussganglinie für den Standort Neukirch, ausschließlich basierend auf optischen Messungen und einem α -Wert von 0,85

Hochwasserereignissen adäquat erfasst werden kann (Abbildung 31). Für die Durchflussbestimmung mit der OptiQ-Methode wurde das Verfahren der Teilflächenmittelung zur Bestimmung der Oberflächengeschwindigkeitsverteilung verwendet sowie ein α -Wert von 0,85 angenommen, da keine Referenzmessungen vorlagen. Aus der Durchfluss- und Wasserstandsganglinie kann die WQ-Beziehung abgeleitet werden (kleines Bild in Abbildung 31), mit deren Hilfe die Bestimmung des Durchflusses allein auf Basis der optischen Wasserstandsmessung möglich wird, sofern keine Partikel detektiert werden können.

4.3.2.6. Fazit

Die OptiQ-Methode stellt eine universell anwendbare Methode dar, die die Bestimmung kontinuierlicher und lückenfreier Durchflussganglinien aus optisch erfassten Fließgeschwindigkeiten mit PTV ermöglicht. Die durchgeführten Untersuchungen zeigten, dass der Einsatz der Methode hauptsächlich in niedrigen und mittleren Durchflussbereichen als wertvoll zu erachten ist. Im Bereich erhöhter Durchflüsse kann die PTV-Methode ohne Lückenfüllung angewendet werden, sofern eine hinreichende Anzahl an Partikeln detektiert und deren Verteilung über den gesamten Gewässerquerschnitt gewährleistet ist. Eine Herausforderung stellen jedoch weiterhin erschwerte Messbedingungen wie z. B. Schnee und Messungen bei Nacht dar. Zudem hat die Kenntnis des korrekten α -Wertes einen erheblichen Einfluss auf die Qualität der Durchflussergebnisse. Die Auswertung hat gezeigt, dass der α -Wert in Abhängigkeit des Wasserstandes zu wählen ist. Während im mittleren Wasserstandsbereich ein Wert von 0,85 gute Durchflussergebnisse erzielt, ist für höhere Wasserstände ein Wert um 1 vorzuziehen. Für die Erarbeitung dieser Charakteristik sind aktuell Referenzmessungen mit herkömmlichen Messmethoden unabdingbar.

4.3.3. KI für die Simulation des Niederschlag-Abfluss-Prozesses

4.3.3.1. Zielstellung

Das Ziel der Generalisierung der KI-NAP war einerseits, die Übertragbarkeit der entwickelten Netzkonfiguration auf weitere Gebiete und Ereignisse zu testen. Andererseits sollte auch ein Modell entwickelt werden, das auf eine solche Übertragbarkeit spezialisiert ist und potenziell ein „generelles Verständnis von Niederschlags-Abfluss-Prozessen“ in einer Region erlernen kann. Dafür war es notwendig, die Datengrundlage deutlich zu vergrößern sowie zu diversifizieren, damit das Modell im Training möglichst viele hydrologische Zustände und Verhaltensmuster von EZG's kennen lernt. Mit einem solchen regionalen Modell werden theoretisch auch Vorhersagen für EZG möglich, die durch zu kurze Zeitreihen oder fehlende beobachtete Hochwasserereignisse in der Vergangenheit nicht für ein lokales Netztraining infrage kommen. Beispiele für derartige EZG sind z.B. die im KIWA-Projekt eingerichteten Messstellen Typ B, die über keine langjährigen Messdaten verfügen. Basierend auf einem geeigneten, regionalen KI-Modell sollte abschließend das finale KI-NAP Vorhersagemodell erarbeitet werden.

4.3.3.2. Datenvorverarbeitung

Grundlage für die Generalisierung bilden die in Abbildung 10 dargestellten 52 EZG in Sachsen. Die hydro-meteorologischen Zeitreihen der Gebiete wurden auf dieselbe Weise vorverarbeitet wie in Abschnitt 4.2.3.2 beschrieben. Zusätzlich wurde die Durchflusszeitreihe jedes Gebiets in eine Abflussspende (mm/h) transformiert, also über die Gebietsfläche normiert.

Damit das regionale Modell beim regionalen Netztraining lernen kann zwischen den einzelnen EZG zu unterscheiden und auf Basis ihrer Eigenschaften die Gebietsantwort anzupassen, wurden dem Netz neben den hydro-meteorologischen Ereigniszeitreihen auch eine Anzahl von EZG-Attributen als zusätzliche Eingangsgrößen übergeben. Durch diese Attribute sollte das Netz während des Trainings die Zusammenhänge und Abhängigkeiten der Gebietsantwort von diesen Gebietscharakteristika lernen. Das erhoffte Resultat ist ein KI-Modell mit potenziell „universellem“ Verständnis von Niederschlags-Abfluss-Prozessen in einer Region, das auch auf bisher unbekannte Gebiete innerhalb der Region anwendbar ist.

Insgesamt wurden 25 Gebiets-Attribute verwendet die verschiedene Aspekte des EZG wider spiegeln, wie z. B. das Klima, die Topografie und die Landnutzung. Konkret handelt es sich um die EZG-Fläche, die Geländehöhe (Minimum, Maximum, arithmetisches Mittel, Median, 25 %- und 75 % Perzentil), die Hangneigung (Maximum, arithmetisches Mittel, Median, 25 %- und 75 % Perzentil), die mittlere jährliche Verdunstung, der mittlere Jahresniederschlag und die Aridität, sowie um die Flächenanteile von folgenden Landnutzungen: Nadelwald, Laubwald, Mischwald, Landwirtschaft, Grasland, Brachland, mittelhohe Vegetation, urbanisierte Flächen, Feuchtgebiete und Wasserflächen. Die Attribute wurden den bereit gestellten GIS-Daten entnommen.

Abschließend wurden die Zeitreihen jedes EZG über den jeweiligen z-Wert standardisiert und die EZG-Attribute über alle EZG hinweg ebenfalls mit ihrem z-Wert standardisiert. Für die abschließende Auswertung wurde die Abflussspende wieder in den Durchfluss (m³/s) transformiert.

4.3.3.3. Regionale KI-Modelle

Erneut wurden mehrere Experimente durchgeführt mit dem Ziel der Auswahl und Optimierung der Modellstruktur, der Eingangsdaten und des Trainingsprozesses. Tabelle 9 gibt einen Überblick zum Versuchsaufbau der durchgeführten Experimente und der damit einhergehenden Modellkonfigurationen. Mit (x) sind die durchgeführten Experimente markiert, wobei die für das regionale Netztraining durchgeführten Experimente gelb hinterlegt sind. Eine Aufschlüsselung der Farb- und Zeichenkodierung befindet sich in Tabelle 10. Das regionale Netztraining wurde durch Kratzert et al. (2019) inspiriert, die basierend auf der Vergrößerung der Trainingsdatenmenge ein robusteres regionales KI-Modell auf Tagesbasis entwickelten. Für die KI-NAP bedeutet die Vergrößerung der Trainingsdatenmenge im regionalen Ansatz, dass dem Netztraining eine deutlich größere Anzahl von Ereignissen insbesondere auch extrem seltenen großen Hochwassern zur Verfügung steht.

Tabelle 9: Experimente für die Generalisierung der KI-NAP (gelb hinterlegt)

| Modell | | | Daten | | | | | | | | | | | | | |
|--------|---|---|-------|---|---|---|-----|-----|-----|-------|-----|-------|---------|---------|---|---|
| | | | 0 | 1 | 2 | | | | | | | | | | | |
| | | | 0 | 0 | 0 | 1 | 1+2 | 1+3 | 1+4 | 1+3+4 | 1+5 | 1+3+5 | 1+3+4b0 | 1+3+4b1 | | |
| | | | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 1+2 | 1 | 1 | 1+2 | 1 | 1 |
| R | r | 0 | x | x | x | x | | | | | | | | | | |
| | a | 0 | x | x | | x | x | x | | | | | | | | |
| | | 1 | | | | x | | | | | | | | | | |
| | | 2 | | | | x | | | | | | | | | | |
| A | a | 0 | x | x | | x | | x | x | x | x | x | x | x | x | |

Tabelle 10: Erläuterungen zu den Experimenten für die Generalisierung der KI-NAP

| | | |
|----------------------|-----|--|
| Daten-Erweiterung | 0 | Keine Erweiterung |
| | 1 | Erweiterung der Datenzeitraums von 2007-2015 zu 2007-2021 |
| | 2 | Weiterer Input: räumlich-statistische Niederschlagsinformationen |
| | 3 | Weiterer Input: ideale Niederschlagsvorhersage aus Beobachtung |
| | 4 | Regionales Netztraining: 1 Modell, 52 EZG, 25 Attribute |
| | 5 | Regionales Netztraining: 1 Modell, 49 EZG (ohne Pilot-EZG), 25 Attribute |
| | 4b0 | Wie Nr. 4, ohne EZG-Attribute |
| | 4b1 | Wie Nr. 4, mit ausgewählten einzelnen EZG-Attributen |
| Daten-Transformation | 0 | Keine Transformation |
| | 1 | Durchfluss zu Abflusssspende konvertiert ($m^3/s \rightarrow mm/h$) |
| | 2 | Differenzenganglinie im Output statt absoluter Durchflusswerte |

Ein zusätzlicher Verarbeitungsschritt wurde mit Daten-Transformation Nr. 2 in Bezug auf die Zielgröße des Modells, also die Durchflussvorhersage, unternommen. Anstelle der absoluten Abflusssspende wurde die Differenz zum vorhergehenden Zeitschritt als Zielgröße ausgewählt. Diese Differenzenganglinie sollte einerseits für jeden Wert der Zielgröße (hier die Abflusssspendendifferenz) eine größere Trainingsdatenbasis zu schaffen, da sich theoretisch die einem seltenen Extremereignis zugrundeliegenden Abflusssspendendifferenzen häufiger in der Datengrundlage wiederfinden als die absoluten Extremwerte. Zum anderen ermöglicht eine solche Differenzenganglinie einen nahtlosen Übergang vom letzten Beobachtungswert der Abflusssspende in den Vorhersagebereich.

4.3.3.4. Ergebnisse

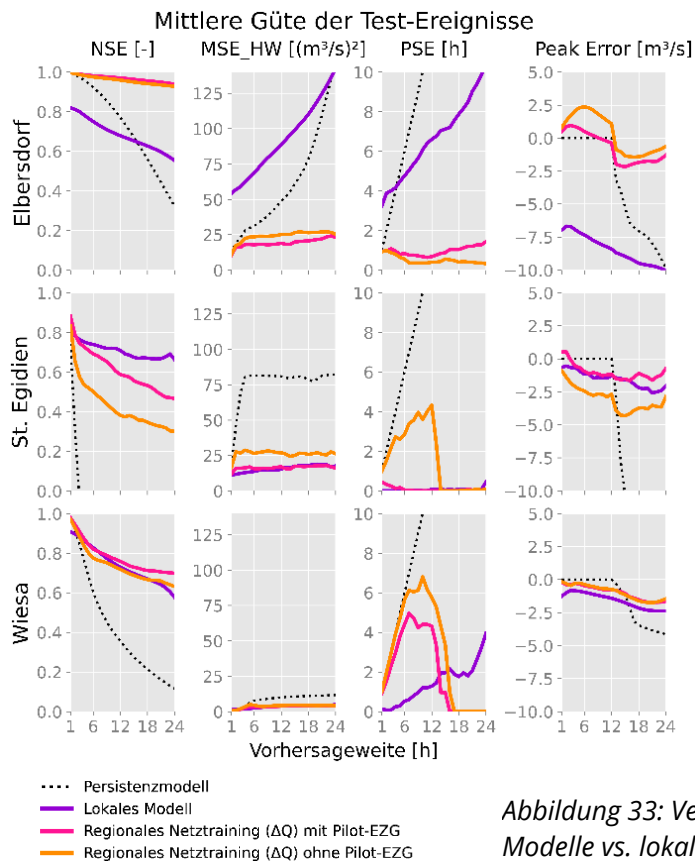


Abbildung 33 zeigt die mittlere Vorhersagegüte der regionalen Modelle im Vergleich zu den lokalen Modellen und dem Persistenzmodell für die Pilot-EZG. Das regionale Modell mit Pilot-EZG (magenta) enthielt im Trainingsdatensatz alle 52 EZG. Im Gegensatz dazu wurden dem Trainingsdatensatz für das regionale Modell ohne Pilot-EZG (gelb), die drei Pilot-EZG vorenthalten, um die Übertragbarkeit des regionalen Modellansatzes zu prüfen. Dargestellt ist in diesem Fall die Modellanwendung der regionalen KI-NAP auf unbekannte Gebiete - den drei Pilot-EZG.

Der Vergleich dieser Modelle zeigt, dass das regionale Modell mit allen EZG im Training (magenta) in Elbersdorf besonders gut funktioniert und,

Abbildung 33: Vergleich der mittleren Güte der regionalen Modelle vs. lokalen Modelle

abgesehen von dem Phasenfehler in Wiesa, eine bessere Güte aufweist als das lokale Modell. Darüber hinaus beweist das regionale Modell ohne die Pilot-EZG im Training, dass das regionale Modell großes Potenzial für den Transfer auf dem Netz unbekannte Gebiete besitzt. Nicht überall funktioniert dies jedoch gleichermaßen gut, was die Güte dieses regionalen Modells für St. Egidien zeigt. Der Unterschied der Güte dieses regionalen Modells zwischen den EZG weist darauf hin, dass das Modellverhalten von verschiedenen, noch zu untersuchenden, Faktoren abhängen kann, wie z. B. der Ausprägung der Gebietsattribute in Bezug auf die Spannweite der Attribute aller EZG im Datensatz, der Ausprägung der Extremereignisse in einem Gebiet, der Anzahl ähnlicher Gebiete und Ereignisse im gesamten Trainingsdatensatz, eventuell noch fehlende Schlüsselattribute im Netinput oder der fehlenden Informationen zur räumlichen Verteilung der Niederschläge im EZG, die zum einen ein besseres Timing (Phasenfehler) ermöglichen könnten und zum anderen auch die Wellenform des Niederschlags-Abfluss-Ereignisses beeinflussen können.

In Abbildung 34 sind Ganglinien der Testereignisse der jeweils besten Modellinstanzen für die Vorhersageweiten 1 h, 12 h und 24 h am Beispiel des EZG Elbersdorf dargestellt. Auch hier wird deutlich, dass die regionalen Modelle eine bessere Performance aufweisen als das lokalen Modell, ins-

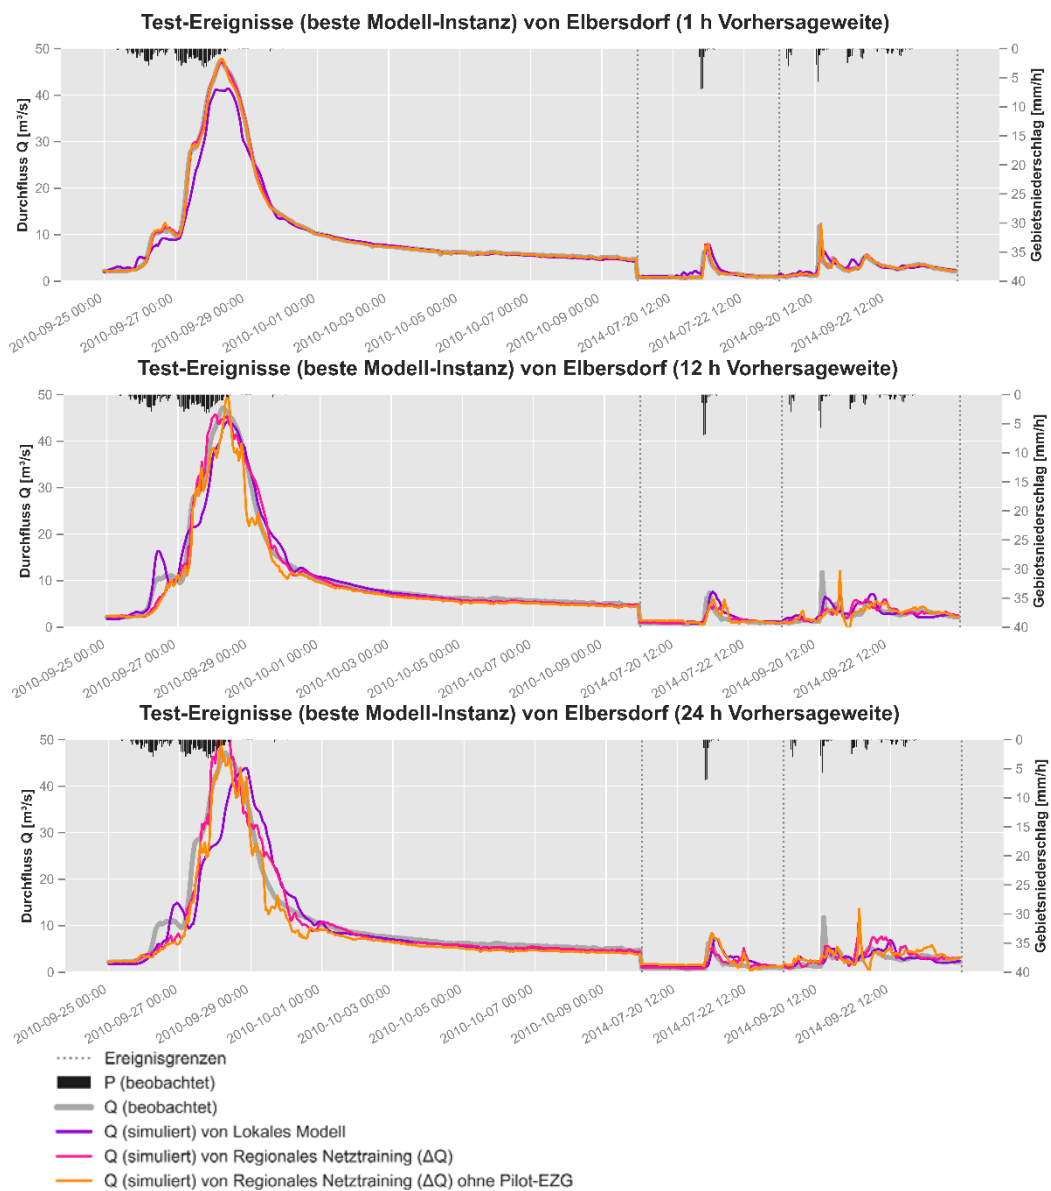


Abbildung 34: Ganglinien der Durchflussvorhersagen der regionalen Modelle vs. lokalen Modelle für Elbersdorf und die Vorhersageweiten 1 h, 12 h und 24 h

besondere bei großen Vorhersageweiten. Darüber hinaus zeigt die Modellanwendung der regionalen KI ohne Pilot-EZG eine erstaunlich gute Übereinstimmung mit dem regionalen Modellansatz insbesondere in Bezug auf die wesentlichen Hochwassermerkmale, den Hochwasserscheitel und die Eintrittszeit. Dies lässt auf eine sehr gute Übertragbarkeit des regionalen Ansatzes schließen, auch wenn die Ganglinienverläufe nicht ganz so glatt sind wie im KI-Modell mit Pilot-EZG. Aufgrund dessen wurde diese Modellkonfiguration für das KI-NAP Vorhersagemodell verwendet.

4.3.3.5. Regionales KI-NAP Vorhersagemodell

Auf Basis der Erkenntnisse aus den regionalen Modellen (cyanfarbene hinterlegtes Experiment in Tabelle 9) und unter der Prämisse, dass ein größerer Trainingsdatensatz mit relevanten Trainingsdaten KI-Modelle verbessert, wurde ein finales regionales Vorhersagemodell entwickelt, das im Folgenden als KI-NAP-Demonstrator-Modell bezeichnet wird. Es sollte ein KI-Modell trainiert werden, das ausnahmslos alle Niederschlags-Abfluss-Ereignisse im Trainingsdatensatz enthält. Die Aufteilung in Trainings-, Validierungs- und Testdatensatz entfällt.

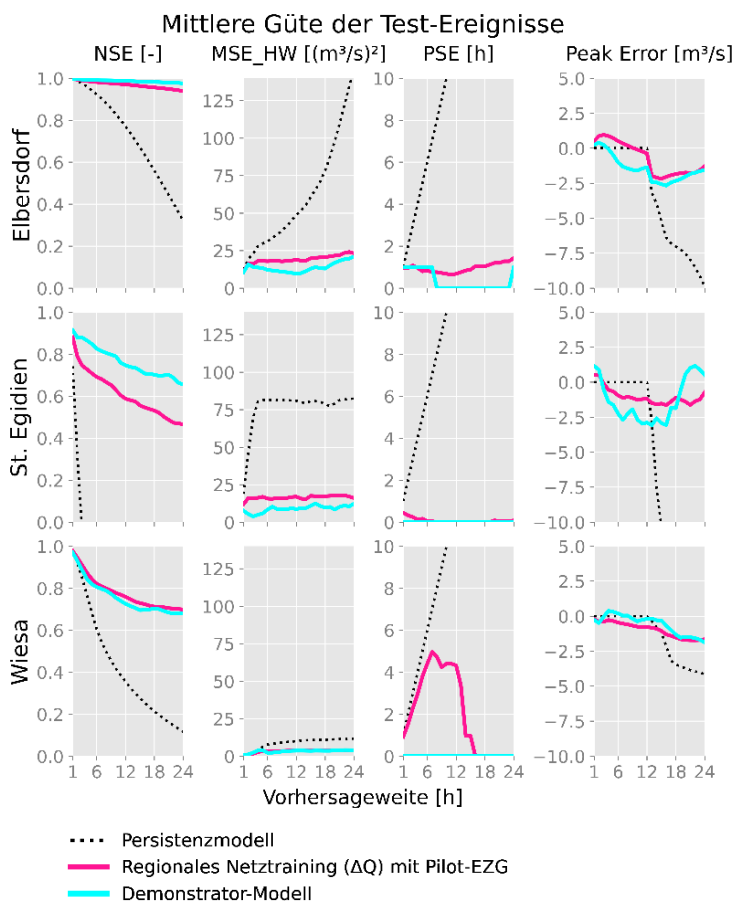


Abbildung 35: Vergleich der mittleren Güte des regionalen Modells vs. KI-NAP-Demonstrator-Modell

Um mit dem regional trainierten Demonstrator-Modell Vorhersagen für Neukirch durchführen zu können, mussten zuerst folgende Schritte ausgeführt werden: (1) Das Einzugsgebiet des Pegels und seine Gebietsattribute mussten bestimmt werden; (2) die meteorologische Zeitreihe musste über die Gebietsfläche aggregiert werden und (3) die optisch bestimmte Durchflusszeitreihe (siehe Abbildung 31) musste für das Demonstrator-Modell von Fehlwerten bereinigt werden. Aus den so gewonnenen Datenreihen wurden manuell Niederschlags-Abfluss-Ereignisse als Testereignisse

Um eine Überanpassung an die Trainingsdaten zu verhindern, wozu zuvor der Validierungsdatensatz genutzt wurde, wurden für das Demonstrator-Modell zuerst die Hyperparameter Lernrate und Epochenanzahl systematisch optimiert. Mit der finalen Modellkonfiguration wurden 30 Modellinstanzen trainiert, von denen die beste anhand einer Auswahl von Testereignissen der Pilot-EZG ausgewählt wurde. Abbildung 35 zeigt die Gütemaße des KI-NAP-Demonstrator-Modells im Vergleich zum regionalen Modell mit den Pilot-EZG im Trainingsdatensatz. Das KI-NAP-Demonstrator-Modell weist hier für alle drei Pilot-EZG eine überwiegend bessere Vorhersagegüte auf.

Die Anwendbarkeit des KI-NAP-Demonstrator-Modells wurde anhand der Messstelle Typ B in Neukirch demonstriert. Die Messstelle zeichnet sich durch eine besonders kurze Zeitreihe aus, mit der kein lokales Netztraining bewältigt werden kann.

markiert. Für diese wurden mit dem KI-NAP-Demonstrator-Modell Durchflussvorhersagen erstellt, deren Güte in Abbildung 36 zu sehen ist. Abbildung 37 zeigt wiederum exemplarisch mit dem Demonstrator-Modell generierte Durchflussganglinien für diese Testereignisse anhand der Vorhersageweite von 6 h.

Die Auswertung zeigt, dass das KI-NAP-Demonstrator-Modell im Rahmen der bisher beobachteten Durchflüsse erfolgreich die Gebietsreaktion des EZG Neukirch simulieren und vorhersagen kann, trotz der Tatsache, dass dieses Gebiet ihm unbekannt ist.

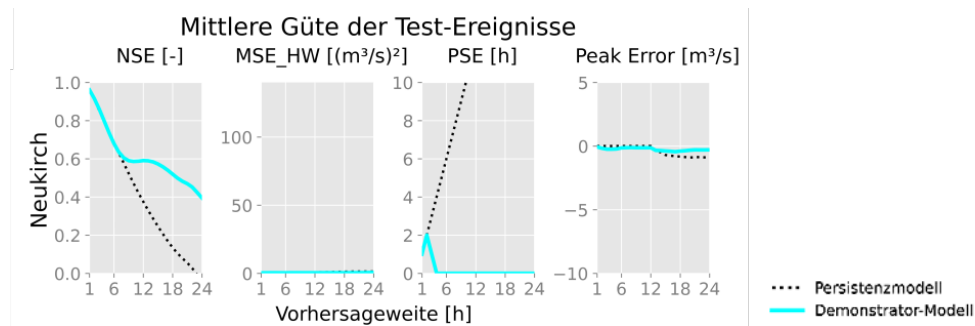


Abbildung 36: Auswertung der mittleren Güte des KI-NAP-Demonstrator-Modells für das EZG Neukirch




Abbildung 37: Ganglinien der Durchflussvorhersage des KI-NAP-Demonstrator-Modells für Neukirch und die Vorhersageweite von 6 h

4.3.3.6. Fazit

Neben allen gezeigten Erfolgen und Potenzialen der Modelle, vor allem des KI-NAP-Demonstrator-Modells, dürfen bestehende Limitierungen und Verbesserungsmöglichkeiten nicht unerwähnt bleiben.

Die im KI-NAP-Demonstrator-Modell verwendeten Gebiets-Attribute und deren Effekt auf die Vorhersage wurden zum Stand der Demonstrator-Modell-Entwicklung noch keiner detaillierten, systematischen Analyse unterzogen. Die Untersuchungen zur Relevanz von einzelnen Attributen, den Synergien in Kombinationen und möglichen weiteren vielversprechenden Attributen wurden zum aktuellen Stand noch nicht abgeschlossen. Das Demonstrator-Modell ist in dieser Hinsicht also noch nicht optimiert.

Des Weiteren wurden alle gezeigten Modelle nicht mit schneebeeinflussten Ereignissen trainiert und können daher nicht sicher für diese angewandt werden. Zur Berücksichtigung von schneebeeinflussten Ereignissen sollten die KI-Modelle weiteren Entwicklungen und Untersuchungen bezüglich der Integration von relevanten Faktoren wie Temperaturzeitreihen, kontinuierlichen Zeitreihen etc. unterzogen werden.

Generell ist die Nutzung des KI-NAP-Demonstrator-Modells in EZG außerhalb des Trainingsdatensatzes nur unter Vorbehalt zu empfehlen. Die Zuverlässigkeit des KI-NAP-Demonstrator-Modells für ein solches Gebiet muss im Einzelfall betrachtet werden. Weiterhin wurde das Demonstrator-Modell basierend auf der mittleren Güte über alle 52 EZG und Trainingsereignisse ausgewählt. Eine schwankende Güte dieses Modells zwischen den EZG und Ereignissen ist anzunehmen und eine Untersuchung, unter welchen Bedingungen das Modell gut oder weniger gut vorhersagt, ist empfehlenswert. Daraus ergibt sich nicht nur die potenzielle Notwendigkeit von verschiedenen Modellen je nach EZG- oder Ereignistyp, sondern auch die generelle Empfehlung eines Modell-Ensembles aus den Modellinstanzen für Vorhersagen mit Berücksichtigung der Modellunsicherheit. Parallel dazu ist die Erstellung von Vorhersage-Ensembles aus verschiedenen Niederschlagsvorhersagen sinnvoll, was bereits durch die Verwendung von Vorhersagen des ICON-D2-EPS Produktes umgesetzt wird. Die Performance des KI-NAP-Demonstrator-Modells wird an den Pegeln der EZG im laufenden Betrieb der operationellen Vorhersage (vgl. Kapitel 4.4.1) evaluiert, sobald neue, unbekannte Hochwasserereignisse auftreten.

In einigen Fällen konnte in den Experimenten und mit dem KI-NAP-Demonstrator-Modell das Timing der Hochwasserwellen oder die Wellenform nicht korrekt vorhergesagt werden. Grund dafür können fehlende Informationen zur räumlichen Verteilung des Niederschlags im EZG sein. Eine Integration von räumlichen verteilten Niederschlägen und räumlich aufgeschlüsselten Attributen in das KI-Modell könnte diese Unzulänglichkeiten möglicherweise beheben.

4.4. Demonstration und Evaluierung

4.4.1. Operationalisierung

Ziel des Verbundvorhabens KIWA war die Entwicklung eines Demonstrators für ein KI-basiertes, integriertes System für die Hochwasserwarnung und Beobachtung, um Einsatzkräften und Einsatzleitungen des Katastrophenschutzes bei der Bewältigung von Großschadenslagen zu unterstützen. Abbildung 38 illustriert den KIWA-Demonstrator und die Verknüpfung der zuvor beschriebenen Entwicklungen in einem integrierten System sowie die einzelnen Elemente, aus denen sich der KIWA-Demonstrator zusammensetzt.

Voraussetzung für ein Warnsystem ist die Operationalisierung der Komponenten für die Beobachtung / Messung sowie die Vorhersage. Dies bedeutet, dass sobald neue Informationen vorliegen, die Prozesse der Datenverarbeitung automatisiert gestartet und den Anwendern möglichst zeitnah aussagefähige Warnprodukte bereitgestellt werden.

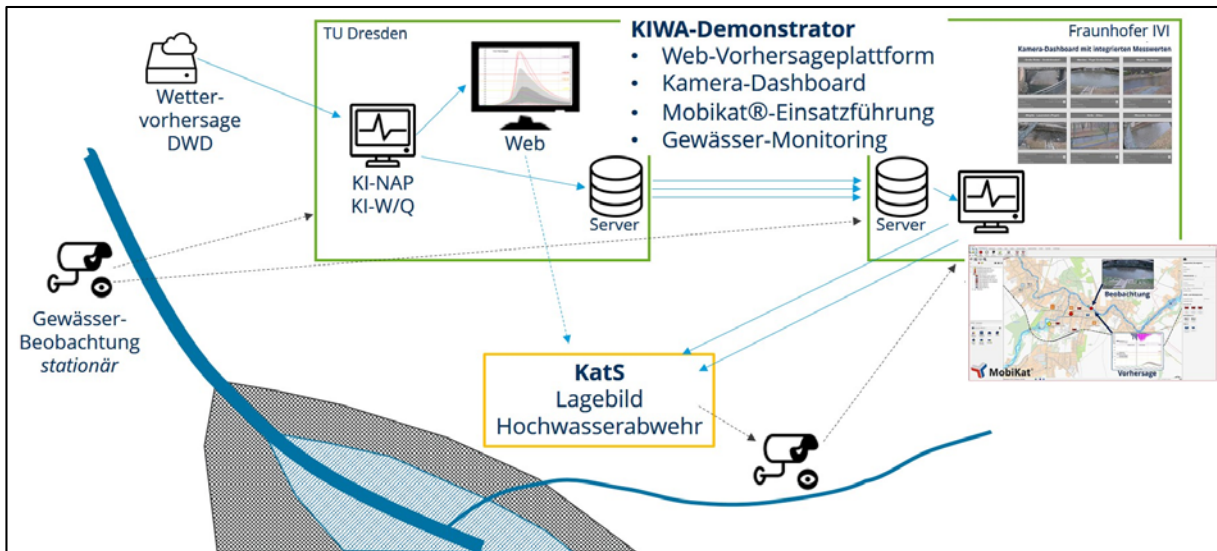


Abbildung 38: KIWA-Demonstrator für ein KI-basiertes, integriertes System für die Hochwasserwarnung und Beobachtung

Im Fall der kamerabasierten, optischen Messung erfolgt der Einsatz der KI-W für die Messung des Wasserstandes, sobald die Kameras neue Bilder und Videosequenzen an den Datenserver der TU Dresden senden. Dies geschieht aktuell jede 15 min und wird auch nach Ablauf der Projektlaufzeit weiter betrieben. Die in den Kapiteln zuvor beschriebenen Methoden der KI-basierten Wasserflächensegmentierung und KI-basierten Passpunktdetektion sowie die Wasserstandsbestimmung werden in einem Skript automatisiert gestartet und liefern den aktuell gemessenen Wasserstand inkl. Messgenauigkeit (die Standardabweichung) sowie das prozessierte Bild für die nachfolgenden Prozesse aus. Abbildung 39 illustriert beispielhaft das Messergebnis für die Messstellen in Lauenstein und Großschönau am Tag vor Abgabe des Berichtes.



Abbildung 39: Operationell ermittelte Wasserstände der KI-W für die Messstellen in Lauenstein (links, 9 cm) und Großschönau (rechts, 29 cm) am 29.09.2024, 12:00Uhr

Im Fall der Durchflussvorhersage wurde das in Kapitel 4.3.3.5 vorgestellte KI-NAP-Demonstrator Modell im Rahmen eines hydrologischen Ensemblevorhersagesystems operationalisiert. Hierfür wurde eine Technologie verwendet, die im Projekt HoWa-PRO (<https://www.wasser.sachsen.de/howa-pro.html>) durch die Professur für Hydrologie der TU Dresden entwickelt wurde. Ausgangspunkt der Vorhersagen sind die Niederschlagsbeobachtung mit dem RADOLAN-RW Produkt des DWD sowie die Durchflussbeobachtungen an den Messpegeln des regionalen Datensatzes, bereit gestellt über das LHWZ. Für die Niederschlagsvorhersage wird das numerische Wettervorhersagemodell ICON-D2-EPS des DWD verwendet, das jede drei Stunden 20 Realisationen (Ensembles) des Wetterverlaufs in den nächsten 48 Stunden bereitstellt. Dabei beschreiben die Ensembles

die Unsicherheit in der Niederschlagsvorhersage. Diese werden mit dem KI-NAP-Demonstrator Modell in Durchflüsse umgerechnet und ermöglichen eine Durchflussvorhersage mit Angabe der Unsicherheit. Die Durchflussvorhersagen werden aktuell jede Stunde neu berechnet, sobald die meteorologische Vorhersage das Überschreiten kritischer Schwellwerte der Niederschlagsmenge und Intensität in Sachsen vorhersagt. Aufgrund des Setups des KI-NAP-Demonstrator Modells werden die hydrologischen Ensemblevorhersagen mit einem stündlichen Zeitschritt und einer Vorhersageweite von 24 Stunden berechnet. Die Vorhersagen der KI-NAP werden in einem Web-Demonstrator visualisiert, dem unter dem Link: <http://howa-innovativ.hydro.tu-dresden.de/WebDemoKiwa/> gefolgt werden kann. Der Link führt auf den Live-Modus der KIWA-Vorhersage Webpage. Sobald neue Vorhersagen vorliegen, verweisen diese auf die KI-NAP-Demonstrator Webpage, die folgende Inhalte aufweist:

- Kartendarstellung der Überschreitungswahrscheinlichkeit der vorhergesagten 24 Stunden Niederschlagssumme für 30, 50, 80 mm
- Kartendarstellung der vorhergesagten 24 Stunden Niederschlagssumme für das 10%, 50% 90% Quantil, sowie den Maximalwert (worst case)
- Zeitlicher Verlauf der Niederschlagsintensität und der Niederschlagssumme für den Gebietsniederschlag der Einzugsgebiete der 52 Pegel beginnend 24 Stunden vor der Vorhersage mit einem Vorhersagehorizont von 24 Stunden
- Ampelkarte der 52 Pegel, dessen Farbgebung die Überschreitung eines Hochwassers mit definierter Jährlichkeit signalisiert (z.B. HQ2, HQ10, HQ20, HQ50)
- Zeitlicher Verlauf der Niederschlagsintensität und des Abflusses der Einzugsgebiete der 52 Pegel beginnend 24 Stunden vor der Vorhersage mit einem Vorhersagehorizont von 24 Stunden (vgl. Abbildung 3)
- Kartendarstellung der zurückliegenden, gemessenen 24 Stunden Niederschlagssumme.

Abbildung 40 illustriert das webbasierte KIWA-Vorhersagesystem für die 52 Einzugsgebiete in Sachsen. Ein Erklär-Video zur Funktionalität der Demonstrator-Webpage ist unter folgendem Link zu finden: <https://www.howa-innovativ.sachsen.de/download/howa-WebDemo.mpg>.

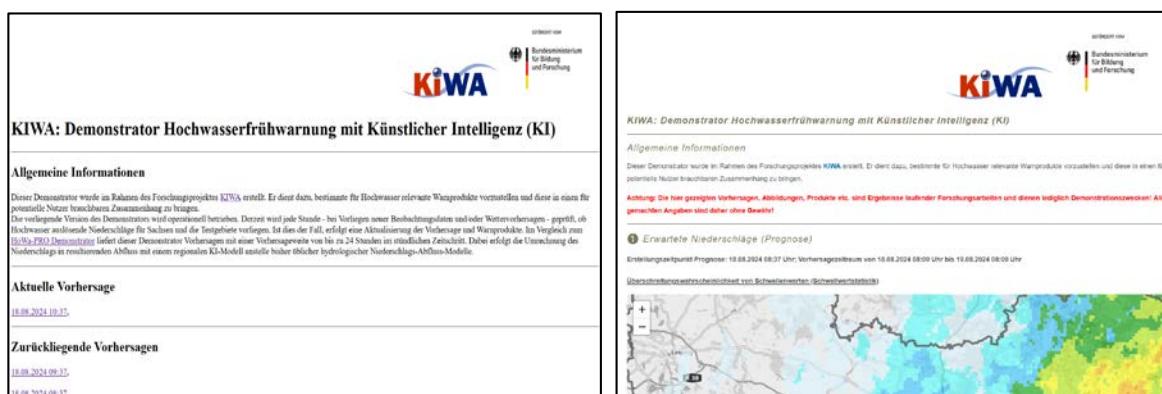


Abbildung 40: Webansicht der KIWA-Vorhersage Webpage (links) und der KI-NAP-Demonstrator Webpage (rechts)

4.4.2. Schnittstellen zum Projektpartner Fraunhofer IVI

Um die operationell erhobenen Daten an die Systeme des Projektpartners Fraunhofer IVI zu übermitteln (siehe Abbildung 38), wurden entsprechende Schnittstellen und Datenstandards erarbeitet. Die optisch bestimmten Wasserstände und die mit Hilfe der WQ-Beziehungen abgeleiteten Durchflüsse werden über das Datenformat „json“ an das Kameradashboard des Fraunhofer IVI übermittelt Abbildung 41. Für die Vorhersagen wurde eine Schnittstelle zum Mobikat-System zur

Einsatzführung basierend auf dem „NetCDF“-Format erstellt. Darin werden dem Projektpartner die Beobachtungen und Vorhersagen für Niederschlag, Wasserstand und Durchfluss, sowie die erwartete Überschreitung eines Hochwassers mit definierter Jährlichkeit übermittelt. In Mobikat werden diese Informationen mit den Überflutungsflächen der zugehörigen Gefahrenkarten verknüpft und stehen so für die Einsatzführung zur Verfügung (Abbildung 42).



Abbildung 41: Kameradashboard des Projektpartners Fraunhofer IVI mit integrierten Messwerten

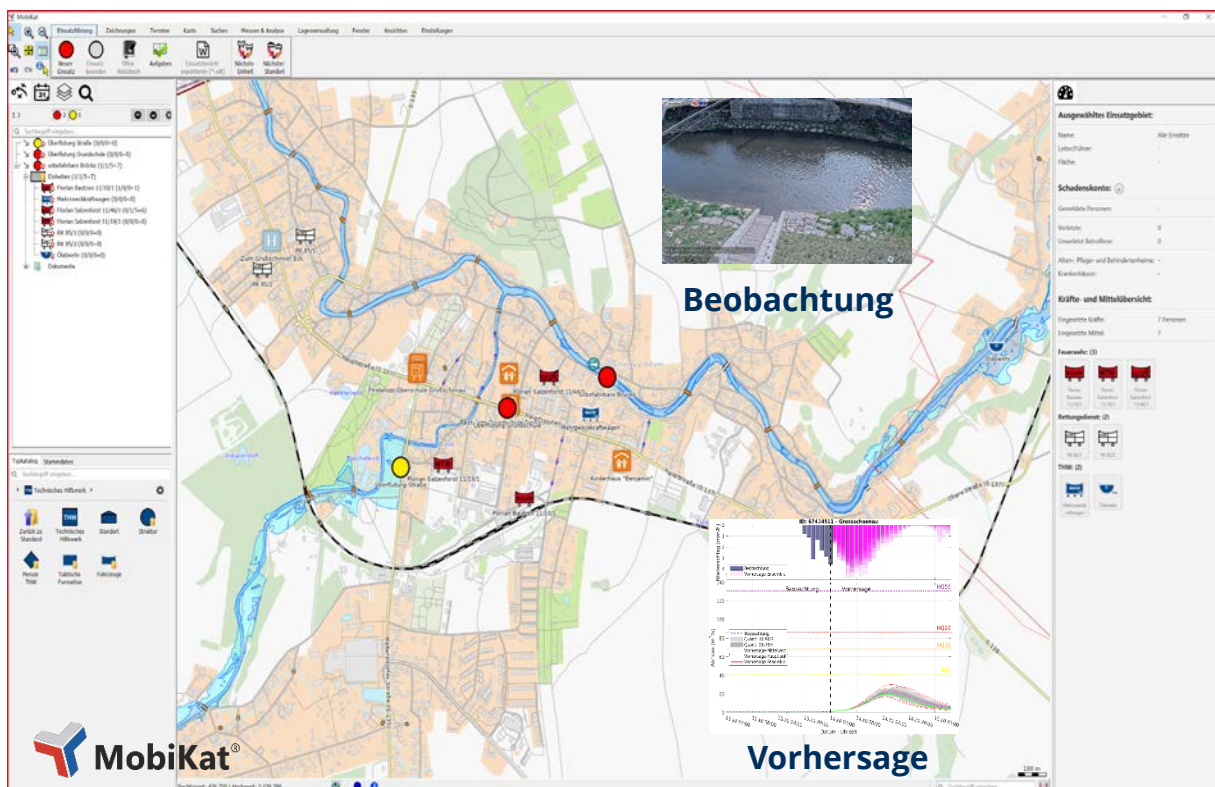


Abbildung 42: MobiKat-System des Projektpartners Fraunhofer IVI zur Einsatzführung mit integrierter Vorhersage und Beobachtung

4.4.3. Workshops, Konsultationen und Austausch mit den Anwendern

Das Teilvorhaben der TU Dresden unterstützte den Projektpartner Fraunhofer IVI während der Projektlaufzeit und brachte seine wissenschaftliche Expertise in Bezug auf folgende Arbeiten ein: (1) die wissenschaftliche Begleitung in der Vorbereitung und Durchführung der Anwender- und Nutzerworkshops; (2) die Entwicklung und Ausgestaltung von Veranstaltungsformaten mit praktischem Anwendungsbezug und (3) die Erstellung inhaltlicher Zuarbeiten für die Anwenderworkshops und Teilnahme an selbigen.



Abbildung 43: Anwenderworkshop zur Vertiefung der Nutzeranforderungen mit Vertretern des LK Sächsische Schweiz-Osterzgebirge

Im Ergebnis wurden die Hinweise und Empfehlungen der Praxispartner rückgespiegelt, so dass ein weitestgehend iteratives Arbeiten bei der Entwicklung des KIWA-Demonstrators (Abbildung 38) stattfand. Im Zuge des Austauschs mit den Praxispartnern erfolgte u. A. die Teilnahme an der Stabsrahmenübung des Kat-Schutzes im Landkreis Bautzen in Kamenz, der Fachmesse „FLORIAN“ in Dresden, dem Digitaler Katastrophenschutzkongress und dem BMBF-Symposium zur europäischen zivilen Sicherheitsforschung in Brüssel.

5. Anhang

5.1. Wichtigste Positionen des zahlenmäßigen Nachweises

Die Bearbeitung des Teilvorhabens erfolgte vom 01.04.2021 – 31.03.2024. Für die Projektbearbeitung wurde eine Zuwendung von 930.780,00 € gewährt. Die wichtigsten Positionen des zahlenmäßigen Nachweises sind:

| | |
|-------------------|--------------|
| Personalkosten: | 745.213,01 € |
| Sachmittel: | 1.896,50 € |
| Dienstreisen: | 15.863,55 € |
| Investitionen: | 8.543,81 € |
| Projektpauschale: | 154.303,37 € |

5.2. Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten

Die Bearbeitung des Teilvorhabens gehörte nicht zu den unmittelbaren Aufgaben der TU Dresden. Eine eigene personelle und finanzielle Ausstattung zur Bearbeitung des Teilvorhabens waren nicht vorhanden. Zudem war die Umsetzung dieses Vorhabens mit technischen und wirtschaftlichen Risiken verbunden, da es sich um Forschungsarbeiten handelt. Ohne die beantragten Projektmittel war die Bearbeitung des Teilvorhabens nicht möglich.

Die Bearbeitung der Aufgabenstellung erforderte umfangreiche Spezialkenntnisse und Erfahrungen auf dem Gebiet der Photogrammetrie, der künstlichen Intelligenz, der hydrologischen Modellierung, der Analyse und Bestimmung von Unsicherheiten, dem Umgang mit großen Datenmengen, der Nutzung von HPC-Systemen und ausgewiesene Programmierkenntnisse sowie dem Projektmanagement. Hierfür war der Einsatz hochqualifizierter Wissenschaftler erforderlich. Die Investitionen erfolgten in Messtechnik für Referenzmessungen an den Messstellen Typ B sowie in Spezialsoftware für die Verarbeitung von Kamerabildern für die Erarbeitung von hochaufgelösten 3D-Geländemodellen sowie die Prozessierung von Durchflussdaten der Vergleichsmessungen. Die Dienstreisen waren erforderlich für das Einrichten der Messstellen und deren Pflege und Wartung sowie zur Durchführung von Vergleichsmessungen, die Teilnahme an Workshops mit den Anwendern und Nutzern sowie zur Präsentation der Ergebnisse auf nationalen und internationalen wissenschaftlichen Konferenzen und dem Innovationsforum des BMBF.

5.3. Voraussichtlicher Nutzen und Verwertbarkeit des Ergebnisses

Im Rahmen der Projektbearbeitung des Teilvorhabens wurden Entwicklungsergebnisse erzielt, die teilweise deutlich über den Erwartungen liegen. Dies gilt insbesondere für die KI-basierte, optische Wasserstandsmessung, bei der Genauigkeiten im Zentimeterbereich erzielt wurden. Die Anforderungen des Kat-Schutzes liegen hier eher im Dezimeterbereich. Mit der Integration in den kompletten, optischen Arbeitsablauf zur Bestimmung von Wasserstand und Durchfluss konnte ein rein kamerabasiertes Messsystem entwickelt werden, das ohne zusätzliche Sensoren auskommt. Damit ergibt sich ein potentielles Anwendungsspektrum, das über den Katastrophenschutz hinausgeht und auch für andere Anwender, wie z. B. Messdienste, Wasserbehörden, etc., für die Erfassung,

Bewertung und Überwachung der Wasserressourcen im Zuge des Klimawandels insbesondere an bisher unbeobachteten Gewässern von Interesse ist. Daraus ergibt sich ein hohes Potential für die Weiterentwicklung und wirtschaftliche Verwertung durch Industriepartner, wie z. B. durch Hersteller von Messtechnik. Eine direkte wirtschaftliche Verwertung seitens der TU Dresden ist nicht geplant. Die entwickelten Methoden der KI-W/Q können an ähnlichen Fließgewässern in Deutschland und im Ausland eingesetzt werden.

Die Übertragbarkeit auf unbeobachtete Fließgewässer konnte auch anhand der KI für die Niederschlags-Abfluss-Prozesse (KI-NAP) demonstriert werden. Der Testbetrieb des KI-NAP-Demonstrators zur Hochwasserfrühwarnung zeigt den Nutzen hydrologischer Ensemblevorhersagen auch in kleinen Einzugsgebieten. Deshalb wird der KI-NAP-Demonstrator über die Projektlaufzeit hinaus weiter betrieben, um zusätzliche Erkenntnisse und Erfahrungen hinsichtlich der Systemperformance und der Genauigkeit und Zuverlässigkeit der KI zur Simulation von Niederschlags-Abfluss-Prozessen in der Vorhersage zu gewinnen. Dies trifft in gleichem Maße auf den operationellen Betrieb der KIWA-Kameras zu.

In der Kombination KI-basierte, optische Messung und KI-basierte Vorhersage kann, wie an der Messstelle Typ B in Neukirch demonstriert, ein komplett KI-basiertes Mess- und Warnsystem bereitgestellt werden. Mit der Verknüpfung zu den Systemen des Projektpartners Fraunhofer IVI können diese Information direkt den Einsatzkräften für die Hochwasserabwehr zur Verfügung gestellt werden und so einen wesentlichen Beitrag zum Schutz von Menschenleben und anderen Werten leisten. Das große Interesse der Praxispartner und Anwender beim KIWA-Abschlusskolloquium unterstreicht die Bedeutung der KIWA-Ergebnisse und den Praxisbedarf für die erzielten Lösungen. Die entwickelten Systeme sind dabei als Produktvorstufen aufzufassen, die weitere Entwicklungsschritte für einen robusten Einsatz in der Praxis bedürfen. Auch hier sind die Methoden prinzipiell in andere Regionen Deutschlands und in das Ausland übertragbar

Für die Operationalisierung der KI-NAP wurde im Projekt KIWA bereits Technologie aus dem SiFo-Projekt HoWa-PRO eingesetzt. Hier ergeben sich weitere Ansatzpunkte für den gegenseitigen Austausch, die weitere Verknüpfung und Nachnutzung in Folgeprojekten, insbesondere im Hinblick auf die erarbeiteten Schulungsinhalte zum Umgang mit Unsicherheiten in der Vorhersage, die Nutzung neuartiger Beobachtungs- und Vorhersageprodukte des Niederschlags und die kamerabasierte Messung und Beobachtung.

Darüber hinaus erweitern die Projektergebnisse das wissenschaftliche Know-how an der Professur für Hydrologie und der Juniorprofessur für Geosensorsysteme der TU Dresden. Die Ergebnisse werden weiterhin auf wissenschaftlichen Konferenzen vorgestellt (z. B. EGU 2024). Publikationen in hochrangigen internationalen Fachzeitschriften sind in Vorbereitung. Daraus können weitergehende Kontakte zur nationalen und internationalen Forschergruppen und Praxispartnern erwachsen, die weitere Forschungsprojekte initiieren. Zudem bereichern die Projektergebnisse bereits jetzt die akademische Ausbildung durch best-practise Beispiele im Rahmen von Vorlesungen und bilden die Grundlage für weiterführende Bachelor- und Masterarbeiten.

5.4. Während der Durchführung des Vorhabens dem Zuwendungsempfänger bekannt gewordener Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen

Im Zuge der Projektbearbeitung wurde bekannt, dass die Firma Google KI-basierte Vorhersagen des Durchflusses auch für ausgewählte Standorte in Deutschland und Sachsen anbietet (<https://sites.research.google/floods/I/0/0/3?layers>). Anfänglich waren hier auch kleinere Gebiete, wie der Pegel in Elbersdorf gelistet, so dass ein Vergleich zu den KI-NAP-Vorhersagen möglich wurde (Abbildung 44). Hier zeigte sich, dass das KI-NAP Vorhersagemodell gegenüber dem Google Floodhub aufgrund seiner höheren zeitlichen Auflösung im Vergleich zur Beobachtung deutlich bessere Ergebnisse liefert. Google hat mittlerweile darauf reagiert und veröffentlicht nur noch Vorhersagen für große Einzugsgebiete. Mit der KI-NAP Technologie schließen wir somit aktuell eine Lücke, die große globale Player nicht bedienen und haben die Technologie für die Weiterentwicklung und regionale Anpassung selbst in der Hand.




Abbildung 44: Vergleich der Durchflussvorhersagen des KI-NAP-Demonstrator-Modells mit Google Floodhub und der Durchflussbeobachtung am Pegel Elbersdorf

6. Literatur

Blanch, X., Jäschke, A., Elias, M., Eltner, A. (subm.): Automatic Ground Control Point detection in images using Deep Learning, IEEE Transactions Geosciences, 2024

DIN EN ISO 748: Hydrometry - Measurement of liquid flow in open channels - Velocity area methods using point velocity measurements, International Organization for Standardization, 2021.

Eltner, A., Sardemann, H. & Grundmann, J.: Technical Note: Flow velocity and discharge measurement in rivers using terrestrial and unmanned-aerial-vehicle imagery. Hydrology and Earth System Sciences, March (Volume 24, p. 1429–1445), <https://doi.org/10.5194/hess-24-1429-2020>, 2020.

Eltner, A., Bressan, P. O., Akiyama, T., Gonçalves, W. N., & Marcato Junior, J.: Using deep learning for automatic water stage measurements. Water Resources Research, 57, e2020WR027608. <https://doi.org/10.1029/2020WR027608>, 2021

Harris, C., and Stephens, M.: A combined corner and edge detector. Alvey vision conference (Vol. 15, No. 50, pp. 10-5244), August 1988.

Hauet, A. et al: Experimental System for Real-Time Discharge Estimation Using an Image-Based Method. Journal of Hydrologic Engineering (Volume 13, pp. 105-110), [https://doi.org/10.1061/\(ASCE\)1084-0699\(2008\)13:2\(105\)](https://doi.org/10.1061/(ASCE)1084-0699(2008)13:2(105)), 2008.

Hochreiter, S. and Schmidhuber, J.: Long short-term memory, Neural computation (Vol. 9, No. 8, p. 1735-1780), <https://doi.org/10.1162/neco.1997.9.8.1735>, 1997

Johnson, E. D. and Cowen, E. A.: Remote determination of the velocity index and mean streamwise velocity profiles. Water Resources Research (Volume 53, p. 7521–7535), <https://doi.org/10.1002/2017WR020504>, September, 2017.

Kratzert, F., Klotz, D., Brenner, C., Schulz, K. and Herrnegger, M.: Rainfall-runoff modelling using Long Short-Term Memory (LSTM) networks, Hydrology and Earth System Sciences (Vol. 22, No. 11, p. 6005-6022), <https://doi.org/10.5194/hess-22-6005-2018>, 2018.

Kratzert, F., Klotz, D., Shalev, G., Klambauer, G., Hochreiter, S. and Nearing, Grey: Towards Learning Universal, Regional, and Local Hydrological Behaviors via Machine-Learning Applied to Large-Sample Datasets, Hydrology and Earth System Sciences (Vol. 23, No. 12, p. 5089-5110), <https://doi.org/10.5194/hess-23-5089-2019>, 2019.

Lucas, B. and Kanade, T.: An Iterative Image Registration Technique with an Application to Stereo Vision, IJCAI'81: Proceedings of the 7th international joint conference on Artificial intelligence (Volume 2 p. 674–679), 1981.

Muste, M., Fujita, I. and Hauet, A.: Large-scale particle image velocimetry for measurements in riverine environments. Water Resources Research (Volume 44), <https://doi.org/10.1029/2008WR006950>, 2008.

Pahner, S., Mietrach, R. and Schütze, N.: Flood forecasting in small catchments: A comparative application of Long Short-Term Memory networks and artificial neural networks, EGU General Assembly 2019, Vienna, Austria, 7–12 Apr 2019, EGU2019-8536, 2019

Wagner, F., Eltner, A., and Maas, H.-G.: River water segmentation in surveillance camera images: A comparative study of offline and online augmentation using 32 CNNs, Int. J. Appl. Earth Obs. Geoinformation (Volume 119, p.103305), <https://doi.org/10.1016/j.jag.2023.103305>, 2023.

7. Publikationen

Artikel

Blanch, X., Jäschke, A., Elias, M., Eltner, A. (subm.): Automatic Ground Control Point detection in images using Deep Learning, IEEE Transactions Geosciences, 2024

Grundmann, J., Eltner, A., Blanch, X., Kutscher, A., and Hedel, R.: Zum Einsatz künstlicher Intelligenz für die optische Bestimmung von Wasserstand und Durchfluss in natürlichen Fließgewässern, 47. Dresdner Wasserbaukolloquium, <https://hdl.handle.net/20.500.11970/113721>, 2024.

Morgenstern, T., Grundmann, J., and Schütze, N.: Hochwasservorhersage mit Deep Learning LSTM-Netzen: Relevanz von Gebietseigenschaften im regionalen Netztraining, Forum für Hydrologie und Wasserbewirtschaftung (Heft 45.24, pp. 159-168), doi: 10.14617/for.hydrol.wasbew.45.24, 2024

Hedel, R., Brausewetter, P., Kunzmann, S., Grundmann, J., Eltner, A., Kutscher, A., Morgenstern, T., and Blanch, X.: KIWA - Künstliche Intelligenz für die Hochwasserwarnung, Tage der Sicherheitsforschung – 112 Rescue (pp. 85-93), ISBN 978-3-949115-16-5, 2023

Wagner, F., Eltner, A., and Maas, H.-G.: River water segmentation in surveillance camera images: A comparative study of offline and online augmentation using 32 CNNs, Int. J. Appl. Earth Obs. Geoinformation, 119, 103305, <https://doi.org/10.1016/j.jag.2023.103305>, 2023.

Blanch, X., Wagner, F., and Eltner, A.: River Water Segmentation Dataset (RIWA), <https://doi.org/10.34740/kaggle/dsv/4901781>, 2023.

Eltner, A., Bressan, P. O., Akiyama, T., Gonçalves, W. N., & Marcato Junior, J.: Using deep learning for automatic water stage measurements. Water Resources Research, 57, e2020WR027608. <https://doi.org/10.1029/2020WR027608>, 2021

Konferenzbeiträge:

Grundmann, J., Blanch, X., Kutscher, A., Hedel, R., and Eltner, A.: Towards a comprehensive optical workflow for monitoring and estimation of water levels and discharge in watercourses, EGU General Assembly 2024, Vienna, Austria, 14–19 Apr 2024, EGU24-12507, <https://doi.org/10.5194/egusphere-egu24-12507>, 2024.

Morgenstern, T., Grundmann, J., and Schütze, N.: Flood Forecasting with Deep Learning LSTM-Networks: Relevance of Catchment Attributes in Regional Network Training, EGU General Assembly 2024, Vienna, Austria, 14–19 Apr 2024, EGU24-17807, <https://doi.org/10.5194/egusphere-egu24-17807>, 2024.

Kutscher, A., Grundmann, J., Eltner, A., Blanch, X., and Hedel, R.: Partikel Tracking Velocimetry (PTV) zur Bestimmung von Durchflussganglinien unter schwierigen Messbedingungen, Tag der Hydrologie, Berlin, 20-21. March 2024

Morgenstern, T., Grundmann, J., and Schütze, N.: Hochwasservorhersage mit Deep Learning LSTM-Netzen: Relevanz von Gebietseigenschaften im regionalen Netztraining, Tag der Hydrologie, Berlin, 20-21. March 2024

Grundmann, J., Schütze, N., Eltner, A., Hedel, R., Brausewetter, P., Morgenstern, T., Blanch, X., Kutscher, A.: Artificial Intelligence for Flood Warning. BMBF-Symposium zur europäischen zivilen Sicherheitsforschung, Brüssel, 5.-6.12.2023, 2023

Grundmann, J., Schütze, N., Eltner, A., Hedel, R., Brausewetter, P., Kunzmann, S. Morgenstern, T., Blanch, X., Kutscher, A.: Künstliche Intelligenz für die Hochwasserwarnung, Digitaler Katastrophenschutz-Kongress 2023, online, 24.-25. October 2023, 2023

Blanch, X., Elias, M., Jäschke, A., Grothum, O., Grundmann, J. and Eltner, A.: Automated Ground Control Point Identification using Deep Learning Techniques, 5th Virtual Geoscience Conference, Dresden, 21.-22. September 2023, <https://doi.org/10.25368/2023.194>, 2023.

Hedel, R., Brausewetter, P., Kunzmann, S., Grundmann, J., Eltner, A., Kutscher, A., Morgenstern, T., and Blanch, X.: KIWA - Künstliche Intelligenz für die Hochwasserwarnung, Tage der Sicherheitsforschung – 112 Rescue, Dortmund, 14.-16.06.2023, ISBN 978-3-949115-16-5, 2023

Eltner, A., Zamboni, P., Hedel, R., Grundmann, J., and Blanch, X.: Image-based methods for real-time water level estimation, EGU General Assembly 2023, Vienna, Austria, 24–28 Apr 2023, EGU23-6745, <https://doi.org/10.5194/egusphere-egu23-6745>, 2023.

Kutscher, A., Grundmann, J., Eltner, A., Blanch, X., and Hedel, R.: Application of optical Particle Tracking Velocimetry (PTV) to determine continuous discharge time series, EGU General Assembly 2023, Vienna, Austria, 23–28 Apr 2023, EGU23-9946, <https://doi.org/10.5194/egusphere-egu23-9946>, 2023.

Morgenstern, T., Grundmann, J., and Schütze, N.: Flood Forecasting with Deep Learning LSTM Networks: Local vs. Regional Network Training Based on Hourly Data, EGU General Assembly 2023, Vienna, Austria, 23–28 Apr 2023, EGU23-9726, <https://doi.org/10.5194/egusphere-egu23-9726>, 2023.

Grundmann, J., Eltner, A., Blanch, X., Kutscher, A., and Hedel, R.: Optische Bestimmung von Wasserstand und Durchfluss in natürlichen Fließgewässern mit KI-basierten und statistischen Verfahren, Tag der Hydrologie, Bochum, 22-23. March 2023, 2023

Kutscher, A., Grundmann, J., Eltner, A., Blanch, X., and Hedel, R.: Anwendung von Partikel Tracking Velocimetry (PTV) zur Bestimmung von Durchflussganglinien, Tag der Hydrologie, Bochum, 22-23. March 2023

Morgenstern, T., Grundmann, J., and Schütze, N.: Hochwasservorhersage mit Deep Learning LSTM-Netzten: lokales vs. regionales Netztraining auf Basis stündlicher Daten, Tag der Hydrologie, Bochum, 22-23. March 2023

Blanch, X., Wagner, F., and Eltner, A.: Image-based methods for water level estimation, 42. Wissenschaftlich-Technische Jahrestagung der Deutschen Gesellschaft für Photogrammetrie, Fernerkundung und Geoinformation, Dresden, 5-6. October 2022, doi: 10.13140/RG.2.2.12624.99841, 2022.

Hedel, R., Schütze, N., Grundmann, J., Eltner, A., Morgenstern, T., Blanch Gorriz, X., Kutscher, A.: Künstliche Intelligenz für die Hochwasserwarnung. BMBF Innovationsforum "Zivile Sicherheit", Berlin, 3.-4. Mai 2022, 2022

Blanch, X., Wagner, F., Hedel, R., Grundmann, J., and Eltner, A.: Towards automatic real-time water level estimation using surveillance cameras, EGU General Assembly 2022, Vienna, Austria, 23–27 May 2022, EGU22-3225, <https://doi.org/10.5194/egusphere-egu22-3225>, 2022.

Kutscher, A., Grundmann, J., Eltner, A., Blanch, X., and Hedel, R.: Determination of continuous discharge time series based on the optical Particle Tracking Velocity (PTV), EGU General Assembly 2022, Vienna, Austria, 23–27 May 2022, EGU22-5967, <https://doi.org/10.5194/egusphere-egu22-5967>, 2022.

Morgenstern, T., Grundmann, J., and Schütze, N.: Flood Forecasting With LSTM Networks: Enhancing the Input Data With Statistical Precipitation Information, EGU General Assembly 2022, Vienna, Austria, 23–27 May 2022, EGU22-6362, <https://doi.org/10.5194/egusphere-egu22-6362>, 2022.

Kutscher, A., Grundmann, J., Eltner, A., Blanch, X., and Hedel, R.: Ermittlung kontinuierlicher Durchflusszeitreihen basieren auf dem optischen Partikel Tracking Velocity (PTV) Verfahren, Tag der Hydrologie, München, 22-23. March 2022, 2022.

Morgenstern, T., Grundmann, J., and Schütze, N.: Hochwasservorhersage mit LSTM-Netzen: Erweiterung der Inputdaten um statistische Niederschlagsinformationen, Tag der Hydrologie, München, 22-23. March 2022, 2022.

Morgenstern, T., Pahner, S., Mietrach, R., and Schütze, N.: Flood forecasting in small catchments using deep learning LSTM networks, EGU General Assembly 2021, online, 19–30 Apr 2021, EGU21-15072, <https://doi.org/10.5194/egusphere-egu21-15072>, 2021.