



Pumpwerkswarnung für Starkregen und Hochwasser im urbanen Raum (PuwaSTAR)



Teil II: eingehende Darstellung Universität Siegen

Verbundkoordinator:

Lippeverband (LV)
Kronprinzenstr. 24
45128 Essen

Auftrag vom:

10/2023

Förderkennzeichen:

13N16802

Aufgestellt von:

Univ.-Prof. Dr. phil. habil. Jorge Leandro
Sebastian Ramsauer M.Sc.

Forschungsinstitut Wasser und Umwelt (fwu)
der Universität Siegen

Siegen, den 12.06.2026

Inhaltsverzeichnis

1	Stand der Forschung & Aufgabenstellung	1
2	Vorhabensbeschreibung	3
3	Ablauf und Methodik	4
3.1	AP2 - Pumpenausfallvorhersage	4
3.1.1	Datenerhebung	4
3.1.2	Ausfallwahrscheinlichkeiten mittels Bayesisches Netzwerk	4
3.1.3	Ableitung von Ausfallszenarien	5
3.2	AP3 - 2D Überflutungsvorhersage für Pumpenausfälle	5
3.2.1	Datenerhebung	5
3.2.2	1D/2D Modell	6
3.2.3	Datengetriebene Vorhersage mittels Echtzeit-Aufzeichnung	7
3.3	AP4 - Integration in Delft-FEWS	9
4	Ergebnisse	11
4.1	AP2 - Pumpenausfallvorhersage	11
4.1.1	Bayes'sche Netzwerk	11
4.1.2	Ausfallszenarien	12
4.2	AP3 - 2D Überflutungsvorhersage für Pumpenausfälle	12
4.2.1	1D/2D Modell	12
4.2.2	Datengetriebene Vorhersage mittels Echtzeit-Aufzeichnung	13
4.3	AP4 - Integration in Delft-FEWS	18
4.4	Dissemination	19
5	Zuwendungsergänzende Informationen	21
6	Literaturverzeichnis	23

Abbildungsverzeichnis

Abbildung 2-1: Arbeitspakete innerhalb des Verbundprojektes PuwaSTAR	3
Abbildung 3-1: Architektur des datengetriebenen Modells basierend auf einem ResNet mit geospezifischem Trainingsansatz (Ramsauer et al. 2026)	7
Abbildung 3-2: Dynamische Vorhersagemethode für die maximale Wassertiefe der nächsten 24 Stunden (Ramsauer et al. 2026)	8
Abbildung 3-3: Eingangsdaten für das datengetriebene Modell (Ramsauer et al. 2026)	8
Abbildung 4-1: Bayes'sche Netzwerk zur Bestimmung der Ausfallwahrscheinlichkeiten einer einzelnen Pumpe mit den Eingangsvariablen (blau), den abhängigen Variablen (orange) und den Ausfallvariablen (rot) (Ramsauer et al. 2025)	11
Abbildung 4-2: Betrachtetes Einzugsgebiet für die hydraulischen Simulationen und die späteren Überflutungsvorhersagen mittels datengetrieben Modell	13

Abbildung 4-3: Durchschnittliche RMSE-Werte jeder Zelle für alle Szenarien 1-8 (Ramsauer et al. 2026)	14
Abbildung 4-4: Ergebnisse der Metriken RMSE und CSI für die qualitative Bewertung der Modellgüte (Ramsauer et al. 2026)	15
Abbildung 4-5: Testevent mit einem max. kumulierten Abfluss von ca. 27 m ³ /s und einer Dauer von 162 Stunden mit RMSE und CSI-Werten für jeden Zeitschritt und alle Szenarien (Ramsauer et al. 2026)	16
Abbildung 4-6: Überflutungsvorhersage für das Szenario 5 bei 90 Stunden des datengetriebenen Modells (oben links), des hydraulischen Modells (oben rechts), die Differenzenkarte (unten links) und das jeweils betrachtete Vorhersagefenster (unten rechts) (Ramsauer et al. 2026)	16
Abbildung 4-7: Überflutungsvorhersage für das Szenario 5 bei 126 Stunden des datengetriebenen Modells (oben links), des hydraulischen Modells (oben rechts), die Differenzenkarte (unten links) und das jeweils betrachtete Vorhersagefenster (unten rechts) (Ramsauer et al. 2026)	17
Abbildung 4-8: Überflutungsvorhersage für das Szenario 8 bei 78 Stunden des datengetriebenen Modells (oben links), des hydraulischen Modells (oben rechts), die Differenzenkarte (unten links) und das jeweils betrachtete Vorhersagefenster (unten rechts) (Ramsauer et al. 2026)	18
Abbildung 4-9: Flussdiagramm der zwei Varianten für die Integration des Vorhersagesystems in Delf-FEWS	18

Tabellenverzeichnis

Tabelle 1: Bewertungsmetriken zur Beurteilung der Vorhersagequalität des datengetriebenen Modells	9
Tabelle 2: Abgeleitete Ausfallszenarien anhand der verbleibenden Restpumpkapazität des Pumpwerkes	12
Tabelle 3: Veröffentlichungen und Präsentation im Rahmen des Projektes PuwaSTAR	19

1 Stand der Forschung & Aufgabenstellung

Die operative Hochwasservorhersage basiert gegenwärtig auf Niederschlag-Abfluss-Modellen, die auf Grundlage gemessener und prognostizierter atmosphärischer Parameter (Niederschlag, Temperatur, potenzielle Verdunstung) basieren (Alfieri et al. 2012). Diese konzeptionellen Modelle ermöglichen zwar eine zeitnahe Berechnung von Abflüssen und deren Umrechnung in Wasserstände über konstante Abfluss-Wasserstand-Beziehungen, jedoch fehlt die Darstellung resultierender Überflutungsflächen und Wassertiefen (Leandro et al. 2025). Für die Bereitstellung dieser Informationen werden i.d.R. gekoppelte ein- und zweidimensionale hydrodynamische Modelle (1D/2D) eingesetzt (Leandro und Martins 2016). Diese Modelle ermöglichen eine detaillierte Abbildung der Wasserausbreitung im urbanen Raum, sind aufgrund ihrer Rechenintensität nicht für zeitkritische, operative Vorhersagen nutzbar. Aus diesem Grund ist nach derzeitigem Stand der Technik keine zielgerichtete Maßnahmenplanung für Echtzeit-Ereignisse möglich, was im Fall eines Hochwassers ein enormes Risiko für Mensch und Gut bedeuten kann. Der mögliche Ausfall oder die Überlastung von Pumpwerken mit erheblichen Auswirkungen auf die Überflutungsflächen verschärfen die Problematik zudem.

Datengetriebene Modelle wie künstliche neuronale Netze (KNN) zeichnen sich durch eine deutlich höhere Recheneffizienz aus und haben daher in den vergangenen Jahren zunehmend an Bedeutung gewonnen. Im Gegensatz zu klassischen 1D/2D-Modellen können KNN-Berechnungen innerhalb von nur wenigen Sekunden bis Minuten aussagekräftige Überflutungskarten liefern, die im Ereignisfall eine zeitnahe fundierte Entscheidung auf Grundlage aktueller Überflutungskarten ermöglichen (Schmid und Leandro 2023). Im hydrologischen und hydraulischen Bereich werden künstliche neuronale Netze bereits vielfältig eingesetzt (Natel de Moura et al. 2022; Cho und Kim 2022). Bei eindimensionalen Vorhersagen dienen sie der Modellierung von Niederschlag-Abfluss-Beziehungen (Van et al. 2020). Derartige Modelle dienen zur Vorhersage von Fluss- oder Kanalnetzabflüssen (Chen et al. 2013; Chang et al. 2014) im Rahmen des Flussgebietsmanagements oder der Kanalnetzuntersuchungen. Bei zweidimensionalen Vorhersagen werden KNN zur Prognose von Überflutungsflächen und Wasserständen infolge von Starkregen verwendet, wobei Regenzeitreihen als Eingabe und Überflutungskarten als Ausgabe dienen (Berkhahn et al. 2019). Studien haben zwar zum Zeitpunkt des Projektantrages das Potenzial von KI-Modellen bewiesen (Löwe et al. 2021; Lin et al. 2020; Li et al. 2022; Bentivoglio et al. 2023; Guo et al. 2021), jedoch wurde eine Integration in operative Vorhersagesysteme noch nicht untersucht. Zudem wurde ausschließlich die Abhängigkeit von Regen- oder Abflussmengen betrachtet. Die Einbeziehung von Pumpwerken und deren Ausfallszenarien in die Vorhersage ist bislang nicht untersucht worden.

Folglich hat das Verbundvorhaben PuwaSTAR zum Ziel, ein Vorhersagesystem von Überflutungsflächen und -tiefen für Pumpwerke und deren Poldergebiete im Hochwasserfall zu entwickeln, um eine Überflutungswarnung zu realisieren, die für das Management im Ereignisfall bereitgestellt werden kann.

Die zu entwickelnde Echtzeitvorhersage basiert dabei auf künstlicher Intelligenz und soll neben Niederschlags- und Abflussvorhersagen auch die aktuelle Leistungskapazität des Pumpwerks sowie potenzielle Ausfallszenarien berücksichtigen. Damit sollen zeitaufwendige hydraulische Berechnungen, die für die operative Vorhersage nicht bzw. nur eingeschränkt nutzbar sind, ersetzt und ereignisbezogene Überflutungsflächen innerhalb weniger Minuten bereitgestellt werden.

Ziel ist es, die funktionsfähige KI-Anwendung in das bei EGLV bereits vorhandene und operativ betriebene Hochwasservorhersagesystem Delft-FEWS zu integrieren und nutzbar zu machen. Damit soll das Vorhersagesystem um eine Echtzeitvorhersage von Überflutungsgebieten unter Berücksichtigung des aktuellen Zustands des Pumpwerks erweitert werden. Die auswirkungsbasierten Vorhersagen sollen im Ereignisfall bei der Einschätzung und Bewertung der Lage bei drohender Systemüberlastung oder dem Ausfall des Pumpwerks unterstützen und eine frühzeitige, zielgerichtete und situative Warnung und Maßnahmeninitiierung ermöglichen. Dazu sollen die Vorhersagen auch den Endnutzern zugänglich gemacht werden und gemeinsam mit den Behörden und Organisationen mit Sicherheitsaufgaben (BOS) und kommunalen Mitarbeiter*innen konkrete Handlungsoptionen und Vorsorgestrategien, entwickelt und abgestimmt werden. Dabei steht v.a. der Schutz (und die Rettung) von Menschen vor Überflutung im Umfeld von Pumpwerken in bergbaulichen Senkungsgebieten im Fokus. Durch eine verbesserte Vorhersage sollen die Gefahrenabwehr und der Schutz kritischer Infrastruktur gestärkt werden und so die Versorgungssicherheit der Bevölkerung erhöht beziehungsweise Großschadenslagen vermieden werden. Das Pumpwerk Dorsten-Hamm bach und das umgebende Poldergebiet dienen als Pilotgebiet zur Erforschung und Realisierung des Vorhersagesystems. Eine mögliche Übertragbarkeit der entwickelten Methodik auf weitere (Pumpwerks-)Einzugsgebiete und weitere Versagenssituationen soll ebenfalls bedacht und bewertet werden.

2 Vorhabensbeschreibung

Das Verbundprojekt PuwaSTAR wurde in Kooperation mit den Projektpartnern Lippeverband (LV) und der Ingenieurgesellschaft Hydrotec durchgeführt. Die Arbeiten des Verbundvorhabens gliederten sich in insgesamt sechs Arbeitspakete (AP), die teilweise aufeinander aufbauen. Eine Übersicht ist in Abbildung 2-1 gegeben.




Abbildung 2-1: Arbeitspakete innerhalb des Verbundprojektes PuwaSTAR

AP 1 umfasst die Aufbereitung der Niederschlags-Abflussszenarien aus dem hydrologischen Modell als Eingangsdaten für die 1D/2D-Überflutungsmodellierung sowie für das KI-Training. In AP 2 werden die Pumpenausfalls-szenarien definiert und die zugehörigen Ausfallwahrscheinlichkeiten ermittelt. AP 3 beinhaltet die Entwicklung und das Training eines KI-Modells zur zweidimensionalen Überflutungsvorhersage unter Einbeziehung der in AP 2 definierten Pumpenausfalls-szenarien. Gegenstand von AP 4 war die Integration des in AP 3 entwickelten Moduls in das Delft-FEWS-System. AP 5 widmete sich der Anwendung im Bereich der Katastrophenvorhersage. Dies umfasste die Erhebung von Endnutzeranforderungen sowie die Erarbeitung von Vorsorgestrategien und Organisationskonzepten gemeinsam mit den assoziierten Partnern. AP 6 deckt die Projektkoordination sowie die Dissemination der Ergebnisse ab.

Das FWU war an allen Arbeitspaketen beteiligt. Neben der Generierung und Aufarbeitung der Abflussdatenbank in AP 1, wurden im anschließenden AP 2 die Pumpenausfallmechanismen in einem Entscheidungsbaum abgebildet und Ausfalls-szenarien abgeleitet. Den inhaltlichen Kern bildete AP 3, in dem ein gekoppeltes 1D/2D-Modell (SWMM und P-DWave) die Trainingsszenarien simuliert und für jedes Ausfalls-szenario ein separates KNN trainiert wurde. In den aufbauenden AP 4-5 war die FWU unterstützend beteiligt. Abschließend wurden die Ergebnisse über Konferenzbeiträge, Fachartikel sowie die universitäre Lehre disseminiert.

3 Ablauf und Methodik

3.1 AP2 - Pumpenausfallvorhersage

In diesem Abschnitt wird die Methodik des entwickelten Tools zur Erkennung von Pumpenausfällen und der Ableitung der Ausfallszenarien beschrieben. Weitere Informationen finden sich in der Publikation von Ramsauer et al. (2025).

3.1.1 Datenerhebung

Die Grundlage der Methodik bildet eine systematische Datenerhebung zur Identifikation der relevanten Versagensmechanismen von Hochwasserpumpen. Hierzu wurden zwei komplementäre Ansätze verfolgt: eine Literaturrecherche sowie eine Befragung zu Pumpwerksstandorten im Einzugsgebiet der Emscher/Lippe.

Die Literaturrecherche dient der Ermittlung bekannter und dokumentierter Versagensmechanismen technischer Pumpensysteme (Dutta et al. 2022; Fan et al. 2023; Korving und Ottenhoff 2008; Ogie et al. 2017; Piri et al. 2021). Auf dieser Basis wurde ein Fragebogen mit 17 Fragen entwickelt, der die Häufigkeit und die Umstände vergangener Pumpausfälle erfasst. Der Fragebogen deckt dabei sowohl anlagenspezifische Eigenschaften der Pumpstationen wie Alter, Stromversorgungstyp, Bauweise, Schutzmaßnahmen und Wartungsintervall, als auch die konkreten Auslöser und Begleitumstände aufgetretener Ausfälle ab. Befragt wurden die zur Verfügung stehenden zehn Betreiber großer Pumpstationen im Emscher/Lippe-Gebiet, die in Konstruktion und Betriebsbedingungen mit der betrachteten Fallstudie in Dorsten vergleichbar sind. Aus den Befragungsdaten werden die empirischen Wahrscheinlichkeiten der Versagensmechanismen statistisch abgeleitet. Für unabhängige Ereignisse gilt die empirische Häufigkeit (Roscoe et al. 2020):

$$P(A) = n(A)/n \quad (1)$$

wobei n die Gesamtzahl der Beobachtungen und $n(A)$ die Anzahl der Fälle darstellt, in denen Ereignis A eingetreten ist. Bedingte Wahrscheinlichkeiten für abhängige Ereignisse werden nach Gleichung 2 bestimmt (Jensen 2009):

$$P(B|A) = P(A \cap B)/P(A) \quad (2)$$

3.1.2 Ausfallwahrscheinlichkeiten mittels Bayesisches Netzwerk

Die ermittelten Versagensmechanismen und ihre empirischen Wahrscheinlichkeiten werden in ein Bayesisches Netz (BN) überführt, das als gerichteter azyklischer Graph (Directed Acyclic Graph, DAG) strukturiert ist (Torres-Toledano und Sucar 1998). Das Netz ermöglicht die explizite Berücksichtigung von Abhängigkeiten zwischen Versagensmechanismen und erlaubt die individuelle Berechnung der Ausfallwahrscheinlichkeit jeder einzelnen Pumpe.

Das Netz gliedert sich in drei Knotentypen. Unabhängige Eingangsgrößen (sog. Wurzelknoten) repräsentieren das a-priori-Wissen und werden manuell gesetzt. Abhängige Variablen werden durch bedingte Wahrscheinlichkeitstabellen beschrieben, die den Einfluss ihrer jeweiligen Elternknoten quantifizieren. Die Endknoten des Netzes repräsentieren die konkreten Versagensszenarien und liefern die Gesamtausfallwahrscheinlichkeit je Pumpe über die Kettenregel (Khakzad et al. 2011):

$$P(X_1, X_2, \dots, X_n) = \prod P(X_i | Pa(X_i)) \quad (3)$$

Liegen neue Informationen zum aktuellen Betriebszustand vor, können die a-priori-Wahrscheinlichkeiten aller Variablen mittels des Bayes-Theorems aktualisiert werden (Kabir und Papadopoulos 2019):

$$\Pr(A|B) = \Pr(B|A) \cdot \Pr(A) / \Pr(B) \quad (4)$$

Dieses Vorgehen wird iterativ für jede Pumpe separat durchgeführt. Die individuellen Ausfallwahrscheinlichkeiten werden anschließend über die Kettenregel zur Gesamtausfallwahrscheinlichkeit der Pumpstation aggregiert.

3.1.3 Ableitung von Ausfallszenarien

Die Gesamtzahl der möglichen Ausfallszenarien ergibt sich aus der Anzahl der Pumpen n nach der Formel (Ramsauer et al. 2025):

$$FS = 2^n - 1 \quad (5)$$

Da mehrere dieser Szenarien dieselbe verbleibende Gesamt-Förderkapazität aufweisen, erzeugen sie identische Überflutungsausdehnungen. Sie werden daher zu einem gemeinsamen Szenario zusammengefasst, wobei ihre Einzelwahrscheinlichkeiten addiert werden.

Die Eintrittswahrscheinlichkeit eines jeden kombinierten Ausfallszenarios wird über die Kettenregel aus den in 3.1.2 abgeleiteten individuellen Pump-Ausfallwahrscheinlichkeiten berechnet (Kabir und Papadopoulos 2019):

$$\Pr(s_1, s_2, \dots, s_n) = \prod (p_i)^{s_i} \cdot (1 - p_i)^{(1-s_i)} \quad (6)$$

Dabei beschreibt $s_i \in \{0,1\}$ den Zustand jeder Pumpe (1 = ausgefallen, 0 = in Betrieb) und p_i ihre Ausfallwahrscheinlichkeit.

3.2 AP3 - 2D Überflutungsvorhersage für Pumpenausfälle

In diesem Abschnitt wird die Methodik des entwickelten datengetriebenen Modells beschrieben. Weitere Informationen finden sich in der Publikation von Ramsauer et al. (2026).

3.2.1 Datenerhebung

Für das Training des datengetriebenen Modells werden Niederschläge aus drei Kategorien in einer zeitlichen Auflösung von fünf Minuten verwendet und bilden gemeinsam ein repräsentatives Spektrum me-

teorologischer und hydrologischer Randbedingungen. Die erste Kategorie beinhaltet 73 historische Einzelereignisse aus Langzeitmessungen, die anhand von gemessenen Niederschlagsereignissen innerhalb des Zeitraums 1950–2023 an stationären Niederschlagsmessstationen im Einzugsgebiet Dorsten erhoben wurden. Diese empirischen Beobachtungsdaten stellen die natürliche hydrologische Variabilität des Standorts dar. Die zweite Kategorie umfasst synthetische Niederschläge mit Wiederkehrintervallen von 5 bis 200 Jahren und Dauerstufen von 3 bis 96 Stunden, die auf Basis einer statistischen Auswertung von Stationsdaten nach DWA A 531 abgeleitet werden. Für jede Wiederkehrzeit und Dauerstufe werden drei Niederschlagsverteilungen berücksichtigt (gleichmäßig, anfangsbetont und endbetont). Somit ergeben sich insgesamt 168 synthetische Ereignisse. Die dritte Kategorie bilden disaggregierte Klimaprojektionen des Deutschen Wetterdienstes, die für den Zeitraum 1971–2100 für das Untersuchungsgebiet vom Leichtweiß Institut für Wasserbau der Technischen Universität Braunschweig für die RCP 4.5 und 8.5 disaggregiert und zur Verfügung gestellt wurden (Ebers et al. 2024; Müller und Haberlandt 2018), was in einem Datensatz von 375 Ereignissen mit insgesamt 134 Klimaszenarien resultiert. Zum Zeitpunkt der Antragstellung waren die Klimaszenarien nicht Teil der Datenerhebung, aufgrund dessen die Skalierung von historischen Abflussereignissen vorgesehen war. Da die Klimaprojektionen vergleichbar realistische Abflussereignisse wie die Langzeitmessungen mit plausiblen Niederschlagsmengen darstellen, konnte auf die Skalierung verzichtet werden.

3.2.2 1D/2D Modell

Das hydrodynamische Referenzmodell dient als physikalisch basiertes Simulationswerkzeug zur Erzeugung der für das datengetriebene Modell benötigten Trainingsdaten. Eingesetzt wird das gekoppelte 1D/2D-Modell P-DWave/SWMM nach (Leandro und Martins 2016), das sowohl den Oberflächenabfluss, als auch das Kanalnetz abbildet und damit eine realitätsnahe Abbildung des betrachteten Einzugsgebietes ermöglicht. Das 2D-Oberflächenmodell P-DWave ist ein parallelisiertes Diffusionswellenmodell, das auf einer vereinfachten Form der zweidimensionalen Flachwassergleichungen basiert (Leandro et al. 2014). Das eindimensionale Modell SWMM wird für die hydraulische Berechnung des Kanalnetzes einschließlich der Pumpstation mittels der St.-Venant-Gleichungen verwendet (Gironás et al. 2010). Die Kopplung beider Modelle erfolgt über Austauschknöten, an denen der Abflussaustausch in Abhängigkeit der hydraulischen Druckhöhendifferenz entweder als Wehr- oder als Gleichung für Durchlassöffnungen berechnet wird. Das Modell wird anhand folgender Bedingungen validiert:

- Realistisches Kanalnetz: Kein Überstau bei fünf Jahren ($T = 5$ a) gemäß DWA A 118
- Abgleich der Pumpenleistung im Modell mit gemessenen Fördermengen für 5 Ereignisse
- Keine relevanten Überflutungsflächen ausgehenden vom Pumpwerk bei Ereignissen unterhalb der Bemessung
- Relevante Überflutungsflächen bei Überlastung des Pumpwerkes
- Realistische Starkregengefahrenkarte: Abgleich mit der offiziellen Starkregengefahrenkarte

Das Modell wird für das reduzierte Untersuchungsgebiet der Stadt Dorsten mit einer räumlichen Auflösung von 5 m aufgestellt.

3.2.3 Datengetriebene Vorhersage mittels Echtzeit-Aufzeichnung

Das Vorhersagesystem basiert auf einem Convolutional Neural Network (CNN), das als Surrogat-Modell das rechenintensive hydrodynamische Modell ersetzt und eine räumlich-zeitlich aufgelöste Echtzeit-Vorhersage der maximalen Überflutungstiefen für sämtliche Ausfallszenarien innerhalb von Sekunden ermöglicht. Die Netzwerkarchitektur basiert auf einem ResNet18 nach (He et al. 2015), die durch einen merkmalsinformaten Trainingsansatz nach Schmid und Leandro (2023) erweitert wird. Residualverbindungen (Skip Connections) in jedem Residualblock gemäß $y = F(x, \{W_i\}) + x$ stabilisieren den Gradientenfluss bei tieferen Netzwerkstrukturen und verhindern das Verschwinden des Gradienten während des Trainingsprozesses. Die Modellarchitektur ist in Abbildung 3-1 abgebildet:




Abbildung 3-1: Architektur des datengetriebenen Modells basierend auf einem ResNet mit geospezifischem Trainingsansatz (Ramsauer et al. 2026)

Das Modell verarbeitet Niederschlags- und Abflussdaten in zwei parallelen Verarbeitungspfaden, die eine separate Extraktion raum-zeitlicher Muster aus beiden Eingangsgrößen ermöglichen. Die Eingangsdaten werden mittels Min-Max-Normalisierung auf den Wertebereich $[0, 1]$ skaliert und als Tensoren der Dimension $(n, 17, 17, 2)$ für Niederschlag und $(n, 17, 17, 4)$ für Abfluss in ein 17×17 -Bild überführt, das den 24-Stunden-Vorhersagehorizont zeitlich codiert. Die Ausgaben beider paralleler Backbone-Strukturen werden elementweise addiert und in klassenspezifischen Layern mit 256, 512 und n Neuronen weiterverarbeitet, wobei n der Anzahl der Ausgabezellen der jeweiligen Klassen in Bezug auf die relative Höhe zum Pumpwerk entspricht (Klasse 1 < 7 m, Klasse 2, 7 -11 m, Klasse 3 > 11 m, Klasse 4 = stehende Gewässer (z.B. See)).

In Abstimmung mit den örtlichen Einsatzkräften wird ein Vorhersagezeitraum von 24 Stunden festgesetzt, der eine rechtzeitige Einleitung von Maßnahmen ermöglicht. Da sich die betrachteten Abflussereignisse durch mehrere aufeinanderfolgende, abflusswirksame Niederschlagsereignisse auszeichnen, die zu kritischen Abflussganglinien von mehreren Tagen führen, wird ein dynamischer Ansatz gewählt, bei dem die Vorhersage auf die nächsten 24 Stunden begrenzt ist und mit einem zeitlichen Versatz von 6 Stunden dynamisch fortgeführt werden kann. Der Prozess ist in Abbildung 3-2 veranschaulicht.




Abbildung 3-2: Dynamische Vorhersagemethode für die maximale Wassertiefe der nächsten 24 Stunden (Ramsauer et al. 2026)

Jeder Pfad erhält sowohl das aktuelle Vorhersagefenster als auch die kumulierten Werte des vorangegangenen Fensters als eigenständige Eingangskanäle. Die kumulierten Werte fungieren als implizites temporales Gedächtnis, womit eine typische Fehlerakkumulation über lange Vorhersagehorizonte verglichen mit autoregressiven Modellen vermieden werden kann. Als Zielgröße für das Training dient die maximale Wassertiefe jeder Zelle innerhalb des jeweiligen Vorhersagefensters. Die Eingangsdaten eines Zeitschrittes für das Training sind illustrativ in Abbildung 3-3 dargestellt.




Abbildung 3-3: Eingangsdaten für das datengetriebene Modell (Ramsauer et al. 2026)

Zur Validierung des datengetriebenen Vorhersagemodells werden vier Bewertungsmetriken betrachtet. Der Root Mean Square Error (RMSE) und der Mean Absolute Error (MAE) bewerten die Wassertiefenvorhersage. Der Critical Success Index (CSI) bewertet die räumliche Überschwemmungsausdehnung anhand eines Schwellenwertes von 0,05 m und setzt korrekt identifizierte überflutete Zellen in Relation zu falsch positiven und falsch negativen Klassifikationen. Der Relative Volume Error (RVE) ergänzt diese zellbezogenen Metriken um eine volumetrische Perspektive und quantifiziert die relative Abweichung des vorhergesagten Gesamtüberflutungsvolumens gegenüber dem hydrodynamischen Referenzmodell, wodurch systematische Über- oder Unterschätzungstendenzen auf Einzugsgebietsebene identifiziert werden können. Eine Übersicht der Metriken ist in Tabelle 1 gegeben.

Tabelle 1: Bewertungsmetriken zur Beurteilung der Vorhersagequalität des datengetriebenen Modells

Evaluation metric	Equation	Range	Optimal Score
RMSE [m]	$\sqrt{\frac{1}{n} * \sum_{i,j} (\hat{y}_{i,j} - y_{i,j})^2}$	$[0, \infty]$	0
Mean RMSE [m]	$\frac{1}{N} * \sum_{i=1}^N \sqrt{\frac{1}{n} * \sum_{i,j=1}^n (\hat{y}_{i,j} - y_{i,j})^2}$	$[0, \infty]$	0
MAE [m]	$\frac{1}{n} \sum_{i,j=1}^n \hat{y}_{i,j} - y_{i,j} $	$[0, \infty]$	0
CSI [%]	$\frac{TP}{TP + FN + FP}$	0 -100	100
RVE [%]	$\frac{\sum (\hat{y}_{i,j} - y_{i,j}) * A}{\sum y_{i,j} * A}$	$[-100, 100]$	0

3.3 AP4 - Integration in Delft-FEWS

Die Berücksichtigung des Betriebszustandes der Pumpen innerhalb der Vorhersage erfolgt über zwei Varianten: Die erste Variante leitet das resultierende Ausfallszenario anhand des aktuellen Betriebszustandes (An/Aus) jeder Pumpe aus der Echtzeitaufzeichnung ab. Die zweite Variante bestimmt mit Hilfe des entwickelten probabilistischen Ansatzes die Ausfallwahrscheinlichkeit jeder Pumpe auf Basis aktueller Eingangsdaten, leitet daraus die Wahrscheinlichkeit des jeweiligen Ausfallszenarios ab und wählt das entsprechende datengetriebene Modell für die Überflutungsvorhersage aus. Beide Varianten sind in Python implementiert und ermöglichen eine effiziente Kommunikation mit dem datengetriebenen Modell. Die Integration in das Vorhersagesystem Delft-FEWS erfolgt über eine definierte Schnittstelle, die eine automatisierte Datenübertragung nach jeder Vorhersage gewährleistet. Als Schnittstellenformat für Eingangs- und Ausgangsdaten werden NumPy-Arrays verwendet, während der Betriebszustand der Pumpen sowie die Eingangsparameter für das Bayes'sche Netz über JSON-Dateien übergeben werden.

Die Inferenz des datengetriebenen Modells erfolgt CPU-basiert, da die verfügbare Rechenzeit für den operativen Betrieb ausreichend ist.

4 Ergebnisse

4.1 AP2 - Pumpenausfallvorhersage

In diesem Abschnitt werden die Ergebnisse des entwickelten Tools zur Erkennung von Pumpenausfällen und der Ableitung der Ausfallszenarien beschrieben. Weitere Informationen finden sich in der Publikation von Ramsauer et al. (2025).

4.1.1 Bayes'sche Netzwerk

Im Rahmen der Untersuchung zu Ausfallmechanismen für die betrachteten Pumpwerke konnten mehrere signifikante Ausfallmechanismen abgeleitet werden. Die kausalen Interdependenzen zwischen mehreren Mechanismen wurden mittels der Betreiberbefragung identifiziert. Anhand der identifizierten Mechanismen wurde das in Abbildung 4-1 dargestellte Bayes'sche Netzwerk aufgestellt und die empirischen Wahrscheinlichkeiten aus der Betreiberbefragung in dieses integriert.




Abbildung 4-1: Bayes'sche Netzwerk zur Bestimmung der Ausfallwahrscheinlichkeiten einer einzelnen Pumpe mit den Eingangsvariablen (blau), den abhängigen Variablen (orange) und den Ausfallvariablen (rot) (Ramsauer et al. 2025)

Die Ausfallmechanismen untergliedern sich in externe und interne Ursachenkategorien und sind teilweise voneinander abhängig. Zu den externen Ausfallmechanismen zählen Stromausfall, Pumpwerksüberflutung und Sedimenteintrag. Die Wahrscheinlichkeit eines Stromausfalls wird durch die Art der Versorgungsinfrastruktur bestimmt, wobei Doppelstromversorgung und Notstromaggregat die Ausfallwahrscheinlichkeit gegenüber einer Einfachversorgung erheblich reduzieren (Bold und Pfeiffer 2004). Eine Überflutung des Pumpwerksgebäudes bei Überschreitung des Bemessungsabflusses kann zu schwerwiegenden Schäden an technischen Komponenten führen, wobei wasserdichte Bauweise und die Höhe des einlaufenden Abflusses die maßgeblichen Einflussfaktoren darstellen (Bold und Pfeiffer 2004; Information und Technik NRW, Geschäftsbereich Statistik). Erhöhte Abflüsse fördern zudem den Sedimenteintrag, der zu einer Blockierung von Pumpeneinlässen führen kann. Sedimentschutzsysteme wie Spüldüsen reduzieren dieses Risiko sowohl während als auch nach Hochwasserereignissen

Zu den internen Ausfallmechanismen zählen Materialversagen durch mechanische Abrasion und Ermüdung sowie das Versagen elektronischer Steuerungs- und Sensorkomponenten (Information und Technik NRW, Geschäftsbereich Statistik; Korving und Ottenhoff 2008; Dutta et al. 2022; Piri et al. 2021). Beide Mechanismen unterliegen einer begrenzten Lebensdauer und können im Fehlerfall zu einem vollständigen Pumpenstillstand führen. Da sie durch regelmäßige Wartungsmaßnahmen direkt beeinflussbar sind, stellen sie einen zentralen organisatorischen Steuerungsparameter dar.

4.1.2 Ausfallszenarien

Die möglichen Ausfallszenarien für das Pumpwerk Dorsten-Hammach wurden systematisch hergeleitet. Das betrachtete Pumpwerk umfasst vier Hochwasserpumpen mit einer Gesamtförderkapazität von 15,5 m³/s, wobei Pumpe 1 eine Nennkapazität von 2,0 m³/s und die Pumpen 2 bis 4 jeweils 4,5 m³/s aufweisen. Somit ergeben sich insgesamt 15 potenzielle Ausfallszenarien, die sämtliche möglichen Kombinationen von Einzelausfällen bis hin zum Totalausfall umfassen. Unter Einbeziehung kapazitätsäquivalenter Szenarien lassen sich diese auf insgesamt 8 Szenarien reduzieren. Mit Betrachtung des regulären Betriebs ergeben sich somit 8 signifikante Szenarien, die betrachtet werden müssen. Diese sind in Tabelle 2 dargestellt.

Tabelle 2: Abgeleitete Ausfallszenarien anhand der verbleibenden Restpumpkapazität des Pumpwerkes

Ausfallszenarien	Gesamtförderkapazität [m ³ /s]
1	15,5
2	13,5
3	11
4	9
5	6,5
6	4,5
7	2
8	0

4.2 AP3 - 2D Überflutungsvorhersage für Pumpenausfälle

In diesem Abschnitt werden die Ergebnisse des entwickelten datengetriebenen Modells dargestellt. Weitere Informationen zu den Ergebnissen finden sich in der Publikation von Ramsauer et al. (2026).

4.2.1 1D/2D Modell

Das hydraulische Modell wird für eine effiziente Rechenleistung auf das wesentliche Stadtgebiet reduziert, das durch drei Zuflüsse, den Hammach, Wienbach und einen kleineren Zufluss zum Hammach charakterisiert ist. Das Einzugsgebiet ist in Abbildung 4-2 dargestellt. Für die Bewertung des Modells werden die in Kapitel 3.2.2 beschriebenen Validierungspunkte untersucht. Die Modellierungsergebnisse zeigen, dass ein Überstau im Untersuchungsgebiet erst ab einem Niederschlagsereignis mit einem Wiederkehrintervall von fünf Jahren ($T = 5$ a) auftritt. Unterhalb dieser Bemessungsgrenze werden keine relevanten Überflutungsflächen verzeichnet, was anhand des historischen Ereignisses aus dem Jahr 2011 mit einem gemessenen Abfluss von $Q = 8$ m³/s exemplarisch belegt werden konnte. Die Validierung des

hydraulischen Modells ergibt eine hohe Übereinstimmung mit den beobachteten Systemzuständen. Die Fördermengen des Pumpwerkes sind in Teilen bis zu 97 % reproduzierbar, was die Güte der Modellabbildung des Pumpbetriebs bestätigt. Darüber hinaus konnte die offizielle Starkregengefahrenkarte durch das entwickelte Modell nachgebildet werden und ein Auftreten von relevanten Überflutungsflächen erst mit einer Überlastung des Pumpwerkes festgestellt werden. Durch die erreichten Validierungspunkte kann von einer Plausibilität und Anwendbarkeit des Modellansatzes für eine realitätsnahe Gefährdungsabschätzung ausgegangen werden.

Einzugsgebiet:




Abbildung 4-2: Betrachtetes Einzugsgebiet für die hydraulischen Simulationen und die späteren Überflutungsvorhersagen mittels datengetriebenen Modell

4.2.2 Datengetriebene Vorhersage mittels Echtzeit-Aufzeichnung

Die Modelgüte des datengetriebenen Modells wurde anhand von insgesamt 56 Testevents getestet, die sich in 1111 Vorhersagefenster untergliedern. Zusätzlich wurden noch einzelne Ereignisse mit unterschiedlichen Abflusscharakteristiken untersucht. Die Ergebnisse zeigen, dass sich die Güte für alle Szenarien im Durchschnitt zwischen 0,024 m und 0,044 m für den RMSE und zwischen 0,007 m und 0,010 m für den MAE bewegt. Der CSI übersteigt in allen Szenarien den Wert von 0,95 und erreicht ein Maximum von 0,967 für das Szenario, wenn alle Pumpen laufen. Die relativen Volumenabweichungen (RVE) liegen im Bereich von 0,002 bis 0,011 und indizieren somit eine genaue Vorhersage des Überflutungsvolumens mit nur einer sehr geringen Tendenz zur Unterschätzung.

Die räumliche Vorhersagequalität wird anhand des zellweisen mittleren RMSE über alle Testereignisse und Ausfallszenarien bewertet. Die Ergebnisse für alle Szenarien sind in Abbildung 4-3 dargestellt.




Abbildung 4-3: Durchschnittliche RMSE-Werte jeder Zelle für alle Szenarien 1-8 (Ramsauer et al. 2026)

Für den überwiegenden Teil des Einzugsgebiets bleibt der mittlere RMSE in nahezu allen Szenarien unter 0,05 m. Die räumlich konzentrierten Bereiche erhöhter Fehler liegen Szenario abhängig vornehmlich am Pumpwerk, dem topografisch tiefsten Punkt des Einzugsgebiets, wo RMSE-Werte zwischen 0,20 m und 0,25 m auftreten. Lediglich in Szenario 3 treten in einem kleinen Bereich nahe des Pumpwerks Fehler von mehr als 0,25 m auf. Von Szenario 1 bis Szenario 6 steigt der RMSE im Bereich des Pumpwerks und des Flussbetts auf 0,20 m bis 0,25 m an und nimmt von Szenario 6 bis Szenario 8 wieder ab. Insgesamt zeigt sich eine geringe räumliche Vorhersageabweichung, die eine akkurate Einschätzung der Hochwassergefährdung erlaubt.

Die zeitliche Modellgüte wird anhand des mittleren RMSE und des Critical Success Index (CSI) für jeden Vorhersagezeitschritt über alle Testereignisse quantifiziert. Die Ergebnisse sind in Abbildung 4-4 veranschaulicht.




Abbildung 4-4: Ergebnisse der Metriken RMSE und CSI für die qualitative Bewertung der Modellgüte (Ramsauer et al. 2026)

Der über alle Szenarien gemittelte RMSE überschreitet zu keinem Zeitschritt den Wert von 0,1 m und bleibt für die meisten Zeitschritte unter 0,05 m, mit einem leichten Anstieg bei längeren Vorhersagezeiträumen und lokalen Maxima im Bereich von 144 bis 192 h. Die beste zeitliche Modellgüte wird für Szenario 8 mit einem maximalen mittleren RMSE von etwa 0,04 m bei Zeitschritt 180 h erreicht. Szenario 6 weist ab Zeitschritt 138 h die größten Fehler auf und erreicht ein Gesamtmaximum von 0,08 m bei 252 h. Der mittlere CSI über alle Szenarien beträgt etwa 0,96 und ist über den gesamten Vorhersagezeitraum stabil, mit einer leicht erhöhten Abweichung im ersten Zeitschritt (CSI = 0,93).

Für eine individuelle Bewertung des Modells werden zusätzlich Einzelevents betrachtet. Abbildung 4-5 zeigt ein Ereignis, das durch einen sehr hohen Abfluss und eine Dauer charakterisiert ist.




Abbildung 4-5: Testevent mit einem max. kumulierten Abfluss von ca. 27 m³/s und einer Dauer von 162 Stunden mit RMSE und CSI-Werten für jeden Zeitschritt und alle Szenarien (Ramsauer et al. 2026)

Wie in Abbildung 4-5 demonstriert, zeichnet sich das entwickelte Modell durch eine besonders hohe Güte in der Anstiegsphase der Ereignisse aus, die für die operationelle Entscheidungsfindung die kritischste Phase darstellt. Ein Beispiel für die Vorhersagequalität ist in Abbildung 4-6 dargestellt.




Abbildung 4-6: Überflutungsvorhersage für das Szenario 5 bei 90 Stunden des datengetriebenen Modells (oben links), des hydraulischen Modells (oben rechts), die Differenzenkarte (unten links) und das jeweils betrachtete Vorhersagefenster (unten rechts) (Ramsauer et al. 2026)

Die Abbildung zeigt, dass sowohl pluviale als auch fluviale Überflutungen um den Abflussscheitel herum zuverlässig erfasst werden. Nur der See zeigt eine höhere Abweichung, der aber auf die Hochwasserentwicklung im Stadtgebiet keinen Einfluss hat. Somit liefert das Modell v.a. um den Peak akkurate Vorhersagen, auf denen Entscheidungen zu Schutzmaßnahmen getroffen werden können.

Die Vorhersagequalität bleibt für die meisten Szenarien auch in der Rezessionsphase auf einem aussagekräftigen Niveau, wie in Abbildung 4-7 dargestellt. Jedoch zeigen die Ergebnisse, dass das Modell im abklingenden Ereignis teilweise deutlich höhere Abweichung aufzeigt, wie für das Szenario 5 zu sehen ist. Die beobachteten erhöhten Fehler in der Rezessionsphase sind auf das gegenläufige Verhalten von kontinuierlich steigenden Akkumulationswerten bei gleichzeitig abnehmendem Abfluss zurückzuführen, das ein komplexes Lernmuster erfordert und sich sowohl in der Wassertiefenvorhersage als auch in der Überflutungsausdehnung widerspiegelt. In dieser Phase befinden sich Maßnahmen bereits in der Durchführung, so dass die möglichen höheren Abweichungen in dieser Phase nicht mehr signifikant für die örtlichen Behörden sind.




Abbildung 4-7: Überflutungsvorhersage für das Szenario 5 bei 126 Stunden des datengetriebenen Modells (oben links), des hydraulischen Modells (oben rechts), die Differenzkarte (unten links) und das jeweils betrachtete Vorhersagefenster (unten rechts) (Ramsauer et al. 2026)

Darüber hinaus sind größere Abweichungen v.a. in Gebieten zu beobachten, die nur bei sehr starken Niederschlagsereignissen und insbesondere Überflutungsflächen in Kombination mit einer geringen Förderleistung bzw. dem Ausfall des PWK aufweisen. Solche Extremereignisse sind aufgrund ihrer seltenen Häufigkeit in Daten unterrepräsentiert, was die Vorhersagequalität für selten überflutete Bereiche einschränkt. Ein Beispiel hierfür ist in Abbildung 4-8 aufgezeigt.




Abbildung 4-8: Überflutungsvorhersage für das Szenario 8 bei 78 Stunden des datengetriebenen Modells (oben links), des hydraulischen Modells (oben rechts), die Differenzkarte (unten links) und das jeweils betrachtete Vorhersagefenster (unten rechts) (Ramsauer et al. 2026)

Ungeachtet dessen sind die höheren RMSE-Werte relativ zu den lokal auftretenden Wassertiefen mit teilweise über 4 m als vergleichbar gering einzustufen, so dass die Vorhersage dennoch aussagekräftige Beurteilungen der Hochwassergefährdung erlaubt. Folglich lässt sich festhalten, dass das entwickelte, datengetriebene Modell sehr gute Vorhersagen der maximalen Wassertiefen für die entscheidenden Phasen der Hochwasserentwicklung liefert und somit für den operativen Dienst akkurate Ergebnisse erzielt.

4.3 AP4 - Integration in Delft-FEWS

Für die Integration des datengetriebenen Vorhersagesystems in Delft-FEWS wurden zwei Varianten entwickelt. Die erste Variante wurde in das bestehende Delft-FEWS-System integriert und liefert anhand der aktuellen Niederschlags- und Abflussvorhersagen und des Echtzeit-Betriebszustandes der Pumpen die Vorhersage des aktuellen Ausfallszenarios. Der Ablauf für beide Varianten ist schematisch in Abbildung 4-9 dargestellt.




Abbildung 4-9: Flussdiagramm der zwei Varianten für die Integration des Vorhersagesystems in Delft-FEWS

Da das datengetriebene Modell immer mit kompletten Ereignissen trainiert ist, wird ein Schwellenwert für die Initialisierung des Vorhersagesystems definiert. Dieser richtet sich nach dem minimalen kumulierten Abfluss, der für das erste Vorhersagefenster im Training verwendet wird. Somit wird sichergestellt, dass die initiale Vorhersage innerhalb des Trainingsdatensatzes erfolgt. Für eine automatisierte Implementierung muss ein zweiter Schwellenwert betrachtet werden, der die Initialisierung an sich steuert. Hierfür wird ein kritischer Abflusswert gewählt, der mit einer wahrscheinlichen Hochwasserentwicklung einhergeht. Sobald beide Schwellenwerte erreicht sind, wird anhand der aktuellen Betriebsaufzeichnungen der Pumpe, eine Vorhersage anhand der aktuellen Niederschlags- und Abflussvorhersagen der nächsten 24 Stunden und der akkumulierten Abflüsse der letzten 24 Stunden gemacht.

Die zweite Variante verfolgt den gleichen Ansatz unter Einbeziehung der Ausfallwahrscheinlichkeiten. Anstatt der Echtzeit-Aufzeichnungen des Betriebszustandes werden die Eingangsparameter des Bayes'sche Netzwerks für jede Pumpe (vgl. Abbildung 4-1) bestimmt und mittels des Jason-Files in das in Python übertragene Modell überführt. Dieses ermittelt für jede Pumpe die Ausfallwahrscheinlichkeit und bestimmt das resultierende Ausfallszenario, für das eine Vorhersage gestartet wird.

4.4 Dissemination

Um die neu erforschten Kenntnisse für Forscher und Fachkreise zugänglich zu machen, wurden die Ergebnisse auf mehreren Fachkonferenzen präsentiert und diskutiert und in Fachmagazinen und wissenschaftlichen Journals veröffentlicht. Eine Auflistung der Veröffentlichungen ist in Tabelle 3 gegeben.

Tabelle 3: Veröffentlichungen und Präsentation im Rahmen des Projektes PuwaSTAR

Titel	Ort der Veröffentlichung	Art/Status
Daniela Falter, et al: Pumpwerkswarnung für Starkregen und Hochwasser im urbanen Raum: Das Projekt PuwaSTAR.	Tag der Hydrologie 2024	Vortrag
Zur Entwicklung hinsichtlich der Übertragbarkeit eines datengetriebenen Überflutungsvorhersagemodells auf unbekannte Einzugsgebiete	Tag der Hydrologie 2024	Vortrag
Entwicklung eines neuartigen datengetriebenen Vorhersagemodells für Pumpwerke	Tag der Hydrologie 2025	Poster
Vorhersagesystem für Pumpwerke bei Hochwassergefahr	WWT – Wasserwirtschaft Wassertechnik	Veröffentlichung (1.2.2025)

Leonie Müller: Ein 1D/2D gekoppeltes Überflutungsmodell vom Einzugsgebiet des Pumpwerks Dorsten-Hamm bach unter Verwendung von P-DWave und SWMM	Universität Siegen	Studienarbeit
Hannah Eckers, et al.: Flood forecasting and pumping station warning in urban areas to improve flood-resilience: The project PuwaSTAR	European Geoscience Union (EGU)	Vortrag
A Novel Data-Driven Approach for the Dynamic Prediction of Maximum Flood Inundation Considering Pump Station Failures	Urban Drainage Modelling Conference Innsbruck	Vortrag
Bayesian Analysis of Stormwater Pump Failures and Flood Inundation Extents	MDPI Water	Veröffentlichung (22.09.2025)
Fail or Not to Fail: AI-Driven Flood Forecasting in the event of Pump Failures	Dutch-German Workshop in Essen	Vortrag
A physically informed domain-independent data-driven inundation forecast model	Water Research	Veröffentlichung (15.10.2025)
Juliana Berrio Uribe & Gifty Mary Mathew: A Composite Flood Resilience Index (CRI) for Dorsten, Germany	Universität Siegen	Studienarbeit
Deep learning approach for real-time flood forecasting considering critical infrastructure failure: A case study for stormwater pumps	Journal of Hydrology (ausstehend)	Veröffentlichung (ausstehend)
Datengetriebenes Vorhersagesystem zur Abschätzung von Hochwassergefahren bei Pumpwerksausfällen im urbanen Raum	Tag der Hydrologie 2026	Vortrag

Neben der Veröffentlichung werden die Erkenntnisse v.a. in Bezug auf den datengetriebenen Ansatz auch in den Lehrveranstaltungen der Universität Siegen integriert und den Studierenden in den Fächern [Hochwasserrisiko und Resilienz im Wasserbau](#) (M.Sc.) und [Urbane Hochwassermodellierung](#) (M.Sc.) zugänglich gemacht. Der Code für das datengetriebene Modell und den FEWS-Adapter wurde auf Github unter folgendem Link veröffentlicht: <https://github.com/FWUSiegen/PuwaSTAR->

5 Zuwendungsergänzende Informationen

Die maßgebenden Positionen in Bezug auf die Finanzierung des Projektes stellen in erster Linie die Personalkosten (Pos. 0812 und 0822) der Beschäftigten dar, die für die Entwicklung und Implementierung des Pumpenausfalltools und datengetriebenen Modells nötig waren. Aufgrund der hohen Rechenleistung mussten zudem die technischen Voraussetzungen für das Training des datengetriebenen Modells geschaffen werden, weswegen ein neuer Rechencomputer angeschafft werden musste (Pos. 0850).

Die Notwendigkeit der geleisteten Arbeit basiert auf der zunehmenden Bedeutung von datengetriebenen Ansätzen für die Vorhersage von Naturkatastrophen in der Wissenschaft. Gegenüber etablierten hydrodynamischen Modellen versprechen datengetriebene Verfahren deutlich schnellere zweidimensionale Überflutungsvorhersagen, was ihren Nutzen für Echtzeitanwendungen erheblich steigert. Durch die öffentliche Förderung konnte das Projekt in Verbindung mit den Projektpartnern realisiert und die offenen Forschungsfragen zur Integration von Ausfallszenarien von Pumpen in die Vorhersage, sowie die hinreichende Anzahl von Trainingsszenarien, als auch die Übertragbarkeit auf andere Pumpstationen untersucht werden.

Durch das Vorhaben wurde ein Vorhersagesystem entwickelt, das in Echtzeit auf mögliche Ausfälle von Pumpen reagieren und die Auswirkungen auf ein potenzielles Hochwasser bestimmen kann. Das entwickelte datengetriebene Modell liefert einen erheblichen Mehrwert für den operativen Dienst. Durch die schnelle Berechnungszeit von nur Sekunden bis maximal wenigen Minuten, ist eine Einschätzung von aktuellen Niederschlagsvorhersagen möglich. Zudem lassen sich die Auswirkungen von maßgebenden Pumpenausfällen auf die Hochwasserentwicklung schnell ableiten, wodurch eine Einschätzung von möglichen Gefährdungen möglich ist, die davor aufgrund der hohen Rechenzeit nicht machbar waren. Zudem wurden die erlangten Kenntnisse in dem Projekt über Veröffentlichungen in wissenschaftlichen Journals und Konferenzen zugänglich gemacht und der Code für das datengetriebene Modell auf GitHub veröffentlicht.

Das Forschungsvorhaben hat gezeigt, dass vor allem hinsichtlich der Übertragbarkeit auf andere Pumpstationen noch viel Potenzial ist. Mit der entwickelten Methode konnte ein zuverlässiges Vorhersagesystem aufgebaut werden, das auch auf weitere Gebiete übertragen werden kann, jedoch ist eine schnelle und einfache Übertragbarkeit noch nicht möglich. Derzeit liefert das Modell akkurate, aber gebietspezifische Ergebnisse und kann nicht auf andere Einzugsgebiete angewandt werden. Für weitere Einzugsgebiete müsste ein neues hydraulisches Modell aufgestellt werden und gebietscharakteristische Überflutungen simuliert werden. Die Ergebnisse haben gezeigt, dass nicht nur eine ausreichende Menge, sondern auch die Qualität der Daten eine maßgebende Rolle spielen und somit eine sehr hohe Anzahl abhängig von der Länge der Ereignisse und den möglichen Ausfallszenarien notwendig ist. Hier wären weitere Forschungen sinnvoll, die eine effiziente Übertragbarkeit über neue Transfer- oder Generalisierungsansätze untersuchen. Die Übertragbarkeit auf andere Versagenssituationen, wie Deichbrüche oder

Rückhaltebecken, ist zudem eine weitere Forschungsfrage, die auf Basis der gewonnenen Erkenntnisse untersucht werden kann. Hier wird aber von notwendigen Anpassungen für spezifische Versagensmuster ausgegangen.

6 Literaturverzeichnis

- Alfieri, Lorenzo; Salamon, Peter; Pappenberger, Florian; Wetterhall, Fredrik; Thielen, Jutta (2012): Operational early warning systems for water-related hazards in Europe. In: *Environmental Science & Policy* 21, S. 35–49. DOI: 10.1016/j.envsci.2012.01.008.
- Bentivoglio, Roberto; Isufi, Elvin; Jonkman, Sebastiaan Nicolas; Taormina, Riccardo (2023): Rapid spatio-temporal flood modelling via hydraulics-based graph neural networks. In: *Hydrol. Earth Syst. Sci.* 27 (23), S. 4227–4246. DOI: 10.5194/hess-27-4227-2023.
- Berkhahn, Simon; Fuchs, Lothar; Neuweiler, Insa (2019): An ensemble neural network model for real-time prediction of urban floods. In: *Journal of Hydrology* 575, S. 743–754. DOI: 10.1016/j.jhydrol.2019.05.066.
- Bold, Steffen; Pfeiffer, Ekkehard (2004): Analyse und Management des Hochwasserrisikos im Em-schergebiet. In: *Risiken bei der Bemessung und Bewirtschaftung von Fließgewässern und Stauanlagen, Dresden; Technische Universität Dresden, Institut für Wasserbau und Technische Hydromechanik: Dresden, Germany*, S. 191–206.
- Chang, Fi-John; Chen, Pin-An; Lu, Ying-Ray; Huang, Eric; Chang, Kai-Yao (2014): Real-time multi-step-ahead water level forecasting by recurrent neural networks for urban flood control. In: *Journal of Hydrology* 517, S. 836–846. DOI: 10.1016/j.jhydrol.2014.06.013.
- Chen, Pin-An; Chang, Li-Chiu; Chang, Fi-John (2013): Reinforced recurrent neural networks for multi-step-ahead flood forecasts. In: *Journal of Hydrology* 497, S. 71–79. DOI: 10.1016/j.jhydrol.2013.05.038.
- Cho, Kyeungwoo; Kim, Yeonjoo (2022): Improving streamflow prediction in the WRF-Hydro model with LSTM networks. In: *Journal of Hydrology* 605, S. 127297. DOI: 10.1016/j.jhydrol.2021.127297.
- Dutta, Nabanita; Kaliannan, Palanisamy; Paramasivam, Shanmugam (2022): A comprehensive review on fault detection and analysis in the pumping system. In: *International Journal of Ambient Energy* 43 (1), S. 6878–6898. DOI: 10.1080/01430750.2022.2056917.
- Ebers, Niklas; Schröter, Kai; Müller-Thomy, Hannes (2024): Estimation of future rainfall extreme values by temperature-dependent disaggregation of climate model data. In: *Nat. Hazards Earth Syst. Sci.* 24 (6), S. 2025–2043. DOI: 10.5194/nhess-24-2025-2024.
- Fan, Xudong; Zhang, Xijin; Yu, Allen; Speitel, Matthew; Yu, Xiong (2023): Assessment of the impacts of climate change on water supply system pipe failures. In: *Scientific Reports* 13 (1), S. 7349. DOI: 10.1038/s41598-023-33548-7.

Gironás, Jorge; Roesner, Larry A.; Rossman, Lewis A.; Davis, Jennifer (2010): A new applications manual for the Storm Water Management Model (SWMM). In: *Environmental Modelling & Software* 25 (6), S. 813–814. DOI: 10.1016/j.envsoft.2009.11.009.

Guo, Zifeng; Leitão, João P.; Simões, Nuno E.; Moosavi, Vahid (2021): Data-driven flood emulation: Speeding up urban flood predictions by deep convolutional neural networks. In: *J Flood Risk Management* 14 (1), Artikel e12684. DOI: 10.1111/jfr3.12684.

He, Kaiming; Zhang, Xiangyu; Ren, Shaoqing; Sun, Jian (2015): Deep Residual Learning for Image Recognition.

Information und Technik NRW, Geschäftsbereich Statistik: Kommunalprofil - Langfassung.

Jensen, Finn V. (2009): Bayesian networks. In: *WIREs Comp Stat* 1 (3), S. 307–315. DOI: 10.1002/wics.48.

Kabir, Sohag; Papadopoulos, Yiannis (2019): Applications of Bayesian networks and Petri nets in safety, reliability, and risk assessments: A review. In: *Safety Science* 115, S. 154–175. DOI: 10.1016/j.ssci.2019.02.009.

Khakzad, Nima; Khan, Faisal; Amyotte, Paul (2011): Safety analysis in process facilities: Comparison of fault tree and Bayesian network approaches. In: *Reliability Engineering & System Safety* 96 (8), S. 925–932. DOI: 10.1016/j.ress.2011.03.012.

Korving, H.; Ottenhoff, E. C. (2008): Analysis of the causes of pump failure and differences of failure characteristics. In: *Water science and technology : a journal of the International Association on Water Pollution Research* 57 (8), S. 1271–1276. DOI: 10.2166/wst.2008.304.

Leandro, J.; Chen, A. S.; Schumann, A. (2014): A 2D parallel diffusive wave model for floodplain inundation with variable time step (P-DWave). In: *Journal of Hydrology* 517, S. 250–259. DOI: 10.1016/j.jhydrol.2014.05.020.

Leandro, Jorge; Althoff, Ingrid; Fischer, Svenja; Mudersbach, Christoph; Lesny, Kerstin (2025): Requirements for Flood-Driven Forecasting Systems for Small and Medium-Sized Catchments in Germany. In: *Water* 17 (22). DOI: 10.3390/w17223283.

Leandro, Jorge; Martins, Ricardo (2016): A methodology for linking 2D overland flow models with the sewer network model SWMM 5.1 based on dynamic link libraries. In: *Water science and technology : a journal of the International Association on Water Pollution Research* 73 (12), S. 3017–3026. DOI: 10.2166/wst.2016.171.

Li, Zewen; Liu, Fan; Yang, Wenjie; Peng, Shouheng; Zhou, Jun (2022): A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. In: *IEEE transactions on neural networks and learning systems* 33 (12), S. 6999–7019. DOI: 10.1109/TNNLS.2021.3084827.

- Lin, Qing; Leandro, Jorge; Wu, Wenrong; Bhola, Punit; Disse, Markus (2020): Prediction of Maximum Flood Inundation Extents With Resilient Backpropagation Neural Network: Case Study of Kulmbach. In: *Front. Earth Sci.* 8, Artikel 332. DOI: 10.3389/feart.2020.00332.
- Löwe, Roland; Böhm, Julian; Jensen, David Getreuer; Leandro, Jorge; Rasmussen, Søren Højmark (2021): U-FLOOD – Topographic deep learning for predicting urban pluvial flood water depth. In: *Journal of Hydrology* 603, S. 126898. DOI: 10.1016/j.jhydrol.2021.126898.
- Müller, H.; Haberlandt, U. (2018): Temporal rainfall disaggregation using a multiplicative cascade model for spatial application in urban hydrology. In: *Journal of Hydrology* 556, S. 847–864. DOI: 10.1016/j.jhydrol.2016.01.031.
- Natel de Moura, Carolina; Seibert, Jan; Detzel, Daniel Henrique Marco (2022): Evaluating the long short-term memory (LSTM) network for discharge prediction under changing climate conditions. In: *Hydrology Research* 53 (5), S. 657–667. DOI: 10.2166/nh.2022.044.
- Ogie, R. I.; Dunn, S.; Holderness, T.; Turpin, E. (2017): Assessing the vulnerability of pumping stations to trash blockage in coastal mega-cities of developing nations. In: *Sustainable Cities and Society* 28, S. 53–66. DOI: 10.1016/j.scs.2016.08.022.
- Piri, Jamshid; Pirzadeh, Bahareh; Keshtegar, Behrooz; Givehchi, Mohammad (2021): Reliability analysis of pumping station for sewage network using hybrid neural networks - genetic algorithm and method of moment. In: *Process Safety and Environmental Protection* 145, S. 39–51. DOI: 10.1016/j.psep.2020.07.045.
- Ramsauer, Sebastian; Schmid, Felix; Johann, Georg; Falter, Daniela; Eckers, Hannah; Leandro, Jorge (2025): Bayesian Analysis of Stormwater Pump Failures and Flood Inundation Extents. In: *Water* 17 (19), S. 2876. DOI: 10.3390/w17192876.
- Ramsauer, Sebastian; Schmid, Felix; Johann, Georg; Falter, Daniela; Eckers, Hannah; Müller-Thomy, Hannes; Leandro, Jorge (2026): Deep learning approach for real-time flood forecasting considering critical infrastructure failure: A case study for stormwater pumps. DOI: 10.2139/ssrn.6845377.
- Roscoe, Kathryn; Hanea, Anca; Jongejan, Ruben; Vrouwenvelder, Ton (2020): Levee System Reliability Modeling: The Length Effect and Bayesian Updating. In: *Safety* 6 (1), S. 7. DOI: 10.3390/safety6010007.
- Schmid, Felix; Leandro, Jorge (2023): A Feature-Informed Data-Driven Approach for Predicting Maximum Flood Inundation Extends. In: *Geosciences* 13 (12), S. 384. DOI: 10.3390/geosciences13120384.
- Torres-Toledano, José Gerardo; Sucar, Luis Enrique (1998): Bayesian Networks for Reliability Analysis of Complex Systems. In: Helder Coelho (Hg.): Progress in Artificial Intelligence — IBERAMIA 98. Berlin, Heidelberg, 1998. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 195–206.

Van, Song Pham; Le, Hoang Minh; Thanh, Dat Vi; Dang, Thanh Duc; Loc, Ho Huu; Anh, Duong Tran (2020): Deep learning convolutional neural network in rainfall–runoff modelling. In: *Journal of Hydroinformatics* 22 (3), S. 541–561. DOI: 10.2166/hydro.2020.095.