

KI-basierte Prognose der Überflutungsgefährdung und Zuordnung von Gefahrenklassen als Entscheidungsunterstützung für die Kanalnetzsteuerung

Luisa-Bianca Thiele^{1,2}, Alexander Verworn¹, Pauline Ullrich¹, Markus Wallner², Gerret Lose², Jorin Kleimann², Albrecht Meißner²

¹ BPI Hannover · Verworn, Beratende Ingenieure, Hannover, Deutschland

² Ostfalia Hochschule für angewandte Wissenschaften, CHH, Suderburg, Deutschland

Kurzfassung: Starkregenereignisse stellen ein erhebliches Risikopotenzial für die städtische Regenentwässerung dar. Besonders betroffen sind dicht besiedelte und urbane Flächen. Im Rahmen des Projekts KI-Kanal wird eine KI-Anwendung zur Prognose der Überflutungsgefährdung als Echtzeit-Entscheidungsunterstützung für die Kanalnetzsteuerung entwickelt. Die Ergebnisse der Validierung der KI-gestützten Vorhersagen zeigt eine gute Übereinstimmung zwischen den vorhergesagten Gefahrenklassen der Überflutungsgefährdung durch die KI-Anwendung und den simulierten Gefahrenklassen mit dem 1D-Kanalnetzmodell. Die KI-Anwendung zeigt eine hohe Trefferquote bei der Vorhersage von Gefahrenklasse 0 (keine Überflutungsgefährdung) mit einer Häufigkeit von 99,6 % und Gefahrenklasse 3 (hohe Überflutungsgefährdung) mit einer Häufigkeit von 88,8 %. Allerdings weist die KI-Anwendung Schwächen bei der Vorhersage von Gefahrenklassen 1 und 2 (geringe und mittlere Überflutungsgefährdung) auf, die nur bei 9,1 % bzw. 36,5 % der Teilereignisse richtig vorhergesagt werden.

Key-Words: Entscheidungsunterstützung, Kanalnetzsteuerung, Künstliche Neuronale Netze (KNN), Überflutungsgefährdung

1 Einleitung

Der Klimawandel führt zu einer Zunahme extremer Starkregenereignisse, die die städtische Regenentwässerung vor erhebliche Herausforderungen stellen. Um die Auswirkungen solcher Ereignisse zu minimieren, ist eine verbesserte Vorhersage für die betriebliche Optimierung der Kanalnetzsteuerung sowie für die Gefahrenabwehr in der Regenwasserkanalisation von entscheidender Bedeutung. Hydraulische Modelle mit hoch aufgelösten Niederschlagsdaten ermöglichen eine präzise Berechnung des Überflutungsverhaltens von Entwässerungsnetzen. Gekoppelte Berechnungen können durch lange Rechenzeiten limitiert sein, die die Zeitskala einer Prognose

überschreiten können. Insbesondere bei der Berücksichtigung verschiedener Steuerungsmöglichkeiten können lange Rechenzeiten die Echtzeit-Anwendung behindern. Modifikationen im Kanalnetz machen in der Regel eine Modellanpassung erforderlich und können bei geringer Adaptierbarkeit der Echtzeitanwendung mit einem hohen Implementierungsaufwand verbunden sein.

Dieser Beitrag stellt einen Ansatz zur Entscheidungsunterstützung bei der Kanalnetzsteuerung durch den Einsatz künstlicher neuronaler Netze (KNN) vor. Auf Basis aktueller Niederschlagsmessungen analysiert das KNN räumlich-zeitliche Regenmuster, um die Überflutungsgefährdung vorherzusagen. Durch die direkte Nutzung von Niederschlagsmessungen als Eingabe für das KNN wird eine Unabhängigkeit von Niederschlagsvorhersagen erreicht, was zu einer robusteren Prognose zur optimierten Steuerung der Abflüsse im Kanalnetz führt. Die Ergebnisse werden in Form von Gefahrenklassen visualisiert, die die Überflutungsgefährdung für den IST-Zustand und drei alternative Steuerungsszenarien darstellen. Zur Validierung der KI-gestützten Vorhersagegenauigkeit werden die Ergebnisse des KNN mit Ergebnissen der hydrodynamischen Kanalnetzsimulation verglichen. Die Stadt Osnabrück in Niedersachsen, Deutschland, ist dabei das Pilotgebiet für die Entwicklung und Anwendung des hier beschriebenen Ansatzes.

2 Daten und Methodik

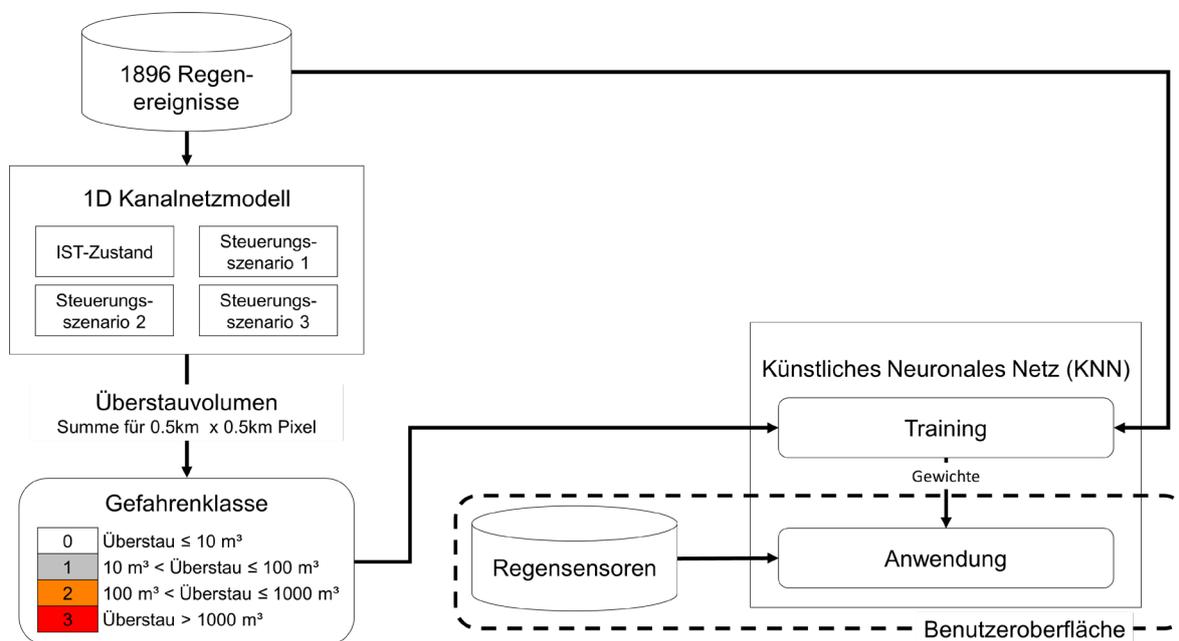


Abbildung 1: KI-Anwendung zur Prognose der Überflutungsgefährdung.

Abbildung 1 zeigt die verschiedenen Komponenten der KI-Anwendung zur Prognose der Überflutungsgefährdung. Die Eingabedaten bestehen aus räumlich-zeitlich hochaufgelösten Regensensordaten (Abschnitt 2.1) und Regenereignissen (Abschnitt

2.2). Die Daten werden verwendet, um das Überstauvolumen des Kanalnetzes für verschiedene Steuerungsszenarien mit einem 1D-Kanalnetzmodell (Abschnitt 2.3) zu simulieren. Das Überstauvolumen wird pixelweise aufsummiert und einer Gefahrenklasse (Abschnitt 2.4) zugeordnet. Die kombinierten Regenereignisse und Gefahrenklassen bilden eine Datenbank, die als Grundlage für das Training des künstlichen neuronalen Netzes (KNN) (Abschnitt 2.5) dient. Im Folgenden werden die einzelnen Komponenten der KI-Anwendung detailliert beschrieben.

2.1 Regensensoren

Um eine Unabhängigkeit von unsicheren Starkregenvorhersagen zu erreichen, werden real vor Ort gemessene Niederschläge als Eingangsdaten für die KI-Anwendung verwendet. Jede neue Messung von Niederschlag wird als Eingabe für die KI-Anwendung genutzt. Im Stadtgebiet Osnabrück wurden 16 Sensoren installiert und über die Einbindung in einem auf Long Range Wide Area Network (LoRaWAN; Ahmad et al., 2019) basierten Internet of Floods (IoF) mit der KI-Anwendung verknüpft. Durch inverse Distanzwichtung werden die Punktdaten auf ein gleichmäßiges Raster mit einer Kantenlänge von 1 km interpoliert.

2.2 Regenereignisse

Für das Training des KI-Modells und die Validierung der KI-Anwendung werden ortsgültige, hochauflösende Regenreihen für die Sensorstandorte generiert. Diese basieren auf radargestützten Niederschlagsdaten und Bodenmessungen des Deutschen Wetterdienstes (DWD), die für den Zeitraum 2005–2023 ausgewertet werden. Die Regenreihen werden auf dasselbe Raster wie die Sensordaten interpoliert, um eine konsistente räumliche Auflösung zu gewährleisten. Um einen ausreichend großen und repräsentativen Trainingsdatensatz zu erstellen, werden zusätzlich synthetische Niederschlagsereignisse generiert, die verschiedene Wiederkehrzeiten, Dauerstufen und Intensitätsverläufe abdecken. Insgesamt werden 1896 räumlich verteilte Regenereignisse mit Jährlichkeiten ≥ 5 a (nach KOSTRA-DWD-2020) aus realen Regenreihen und synthetischen Modellregen für die Entwicklung des KI-Modells berücksichtigt.

2.3 1D-Kanalnetzmodell

Für die eindimensionale Kanalnetzmodellierung wird das von BPI Hannover · Verworn entwickelte Kanalnetzmodell HHK verwendet. Für die Kanalnetzsteuerung wurden sieben potenzielle Steuerstellen mit Hilfe von Durchfluss- und Pegelmessungen identifiziert. Auf Basis dieser Steuerstellen wurden drei Steuerungsszenarien entwickelt, um die Überflutungsgefahr durch Kanalüberstau bei unterschiedlichen räumlichen Niederschlagsbelastungen zu minimieren. Die Steuerungsszenarien berücksichtigen jeweils eine starke Niederschlagsbelastung in einem bestimmten Bereich des Einzugsgebiets: Szenario 1 im nördlichen, Szenario 2 im südlichen und Szenario 3 im östlichen Bereich. Der IST-Zustand sowie jedes Steuerungsszenario

werden mit den 1896 räumlich verteilten Regenereignissen simuliert, was zu insgesamt 7584 Simulationen führt. Diese werden anhand des Überstauvolumens ausgewertet.

2.4 Gefahrenklassen

Eine Echtzeitüberwachung und -auswertung des Überstaus von mehreren hundert Schächten und verschiedenen Steuerungsszenarien ist aufgrund der Komplexität schwierig. Um eine bessere Übersichtlichkeit zu erreichen, wird das Untersuchungsgebiet in Pixel mit einer Kantenlänge von 0,5 km unterteilt. Das Überstauvolumen wird in jedem Pixel aufsummiert und zur Einordnung der Überflutungsgefährdung in vier Gefahrenklassen eingeteilt:

- Klasse 0: 0 bis 10 m³ (keine Überflutungsgefährdung)
- Klasse 1: 10 bis 100 m³ (geringe Überflutungsgefährdung)
- Klasse 2: 100 bis 1000 m³ (mittlere Überflutungsgefährdung)
- Klasse 3: ≥ 1000 m³ (hohe Überflutungsgefährdung)

2.5 Künstliches Neuronales Netz (KNN)

Aufgrund vorangegangener Untersuchungen wird eine Dense-Layer-Architektur mit 5 Hidden Layern für das KNN ausgewählt. Die Realisierung und das Training des KNN erfolgen mit Hilfe von TensorFlow (Abadi et al., 2016) und Keras (Chollet et al., 2015). Das Training wird über 100 Epochen durchgeführt. Die Regenereignisse werden in drei Teilmengen aufgeteilt, wobei 60 % für das Training, 20 % für das Testen und 20 % für die Validierung des KNN verwendet werden. Neben den Regenereignissen werden die Gefahrenklassen der verschiedenen Steuerungsszenarien als Eingangsdaten für das Training des KNN verwendet. Das KNN wird so konzipiert, dass die vergangenen 12 Zeitschritte ($t - 55$ min bis $t - 0$ min) der Regendaten als Eingangsdaten für die Vorhersage der Gefahrenklasse verwendet werden. Die Vorhersage umfasst vier Zeitschritte ($t - 0$ min, $t + 5$ min, $t + 10$ min, $t + 15$ min). Durch die Verwendung von 12 Zeitschritten Niederschlag als Eingangsdaten werden die Regenereignisse für das Training und die Validierung des KNN in weitere Teilereignisse unterteilt, die jeweils 12 Zeitschritte Regen enthalten. Zur Vervollständigung der Teilereignisse werden zu Beginn und am Ende jedes Regenereignisses Nullwerte eingefügt.

2.6 Validierung der Vorhersagegenauigkeit

Für die Validierung der Vorhersagegenauigkeit werden die simulierten Gefahrenklassen, die mit dem 1D-Kanalnetzmodell als Referenz berechnet wurden, mit den prognostizierten Gefahrenklassen, die mit der KI-Anwendung vorhergesagt wurden, verglichen. Die Validierung erfolgt sowohl über alle Teilereignisse als auch über die verschiedenen Steuerungsszenarien (IST-Zustand, Steuerungsszenario 1-3) und Vorhersagezeitschritte ($t - 0$ min, $t + 5$ min, $t + 10$ min, $t + 15$ min) getrennt. Für die Validierung werden 20 % zufällig ausgewählte Regenereignisse aus der

Datenbank berücksichtigt. Um die Abweichungen zwischen den simulierten und den vorhergesagten Gefahrenklassen zu quantifizieren, wird die Konfusionsmatrix berechnet. Die Konfusionsmatrix gibt an, mit welcher Häufigkeit der simulierte Wert getroffen wird und welche Fehler gemacht werden. Zusätzlich werden der Root Mean Square Error (RMSE) und der Critical Success Index (CSI) als Fehlerkriterium betrachtet, um die Güte der Vorhersagen zu bewerten.

Der RMSE berechnet sich aus:

$$RMSE = \sqrt{\frac{1}{N} \cdot \sum_{i,j,t,k} (sim_{i,j,t,k} - pred_{i,j,t,k})^2} \quad (1)$$

wobei $sim_{i,j,t,k}$ die simulierte Gefahrenklasse mit dem 1D-Kanalnetzmodell und $pred_{i,j,t,k}$ die vorhergesagte Gefahrenklasse mit dem KNN für das Teilereignis i , das Szenario j , den Vorhersagezeitschritt t und den Pixel k ist.

Der CSI bewertet die Güte von Vorhersagen, indem die Anzahl korrekt vorhergesagter Ereignisse $hits$ ins Verhältnis zur Gesamtzahl der Ereignisse $hits + false\ alarms + misses$ gesetzt wird:

$$CSI = \frac{hits}{hits + false\ alarms + misses} \quad (2)$$

Als korrekt vorhergesagtes Ereignis hit wird hier angenommen, dass eine mittlere bis hohe Überflutungsgefährdung, also Gefahrenklasse 2 oder 3 vorhergesagt wird. Bei $false\ alarm$ wird angenommen, dass die Gefahrenklasse 2 oder 3 vorhergesagt wird, die simulierte Gefahrenklasse aber kleiner als 2 ist. Bei $miss$ wird angenommen, dass die simulierte Gefahrenklasse 2 oder 3 vorliegt, die vorhergesagte Gefahrenklasse aber kleiner als 2 ist.

3 Ergebnisse

Abbildung 2 zeigt die Niederschlagseingangsdaten für das Teilereignis 212, ein beispielhaft ausgewähltes Regenereignis aus den Validierungsdaten. Die Niederschlagsbelastung variiert zwischen 0 mm/5min und 6,82 mm/5min mit 1,73 mm/5min im Mittel, während die Niederschlagssumme zwischen 1,56 mm/60min und 29,77 mm/60min liegt. Der Mittelwert aller Pixel beträgt 16,89 mm/60min. Die höchste Niederschlagsbelastung tritt im nördlichen Teil des Einzugsgebiets auf.

Abbildung 3 zeigt die vorhergesagten Gefahrenklassen für das Teilereignis 212. Die Prognose umfasst den aktuellen Zeitschritt ($t + 0$ min) sowie drei zukünftige Zeitschritte ($t + 5$ min, $t + 10$ min und $t + 15$ min), die in der Abbildung von links nach rechts dargestellt sind. Darüber hinaus werden der IST-Zustand und die drei Steuerungsszenarien (Szenario 1, Szenario 2 und Szenario 3) in der Abbildung von oben nach unten dargestellt. Bei diesem Teilereignis werden alle vier Gefahrenklassen

vorhergesagt. Die Ergebnisse zeigen, dass die Überflutungsgefahr im nördlichen Bereich und teilweise in im Osten in einzelnen Pixeln hoch ist. Im aktuellen Zeitschritt zeigt Szenario 1 die geringste Überflutungsgefährdung, während der IST-Zustand für die zukünftigen Zeitschritte die geringste Überflutungsgefährdung aufweist. Im Gegensatz dazu zeigt Szenario 3 über alle vorhergesagten Zeitschritte die größte Überflutungsgefährdung.

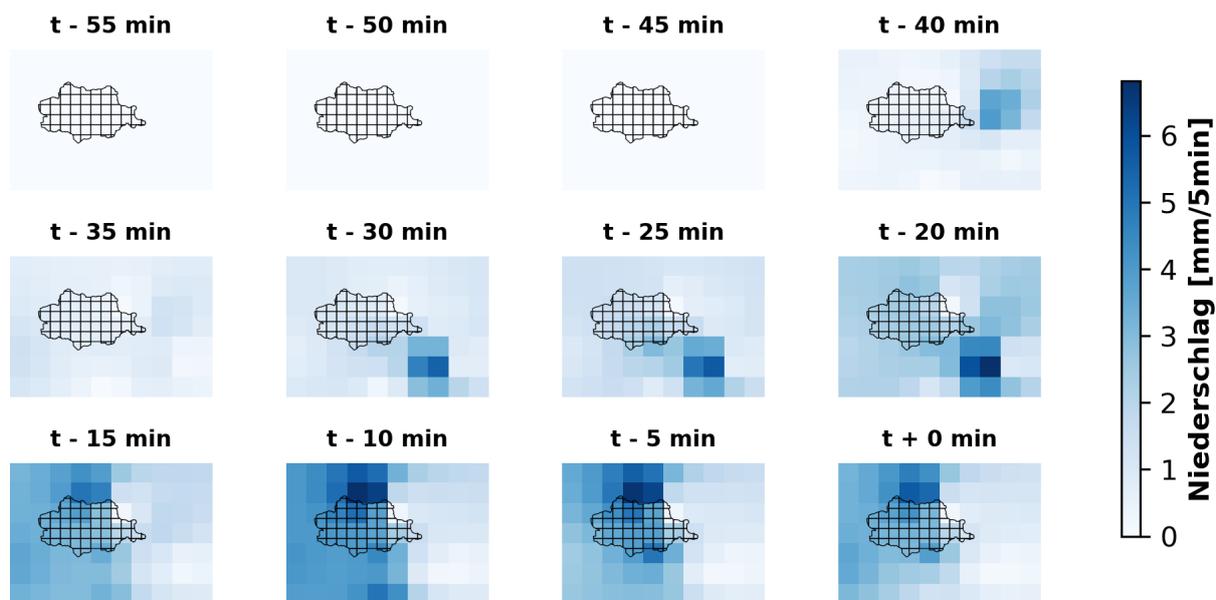


Abbildung 2: Niederschlagsbelastung des Teilereignisses 212. Das Einzugsgebiet mit der Unterteilung in Pixel ist in schwarz dargestellt.

Abbildung 4 zeigt die Abweichung zwischen den vorhergesagten und simulierten Gefahrenklassen. Die Farben in der Abbildung zeigen die Richtung und Größe der Abweichung: Blau zeigt eine Überschätzung der simulierten Gefahrenklasse, während magenta eine Unterschätzung zeigt. Die Intensität der Farbe zeigt die Größe der Abweichung: Je dunkler die Farbe, desto größer ist die Abweichung. Die Ergebnisse zeigen, dass für den IST-Zustand die Überflutungsgefährdung in drei Pixeln des Untersuchungsgebietes im aktuellen Zeitschritt überschätzt wird. In den folgenden Zeitschritten wird die Überflutungsgefährdung jedoch unterschätzt. In einem Pixel im nördlichen Teil des Einzugsgebiets wird keine Überflutungsgefährdung vorhergesagt, während in diesem Pixel eine hohe Überflutungsgefährdung (Gefahrenklasse 3) simuliert wurde (Zeitschritt t + 5 min). Im Gegensatz dazu stimmen die Gefahrenklassen für Szenario 1 bis auf einen Pixel im letzten Zeitschritt gut überein. Die größeren Abweichungen beim IST-Zustand im Vergleich zu Szenario 1 könnten dadurch erklärt werden, dass Szenario 1 für eine erhöhte Niederschlagsbelastung im Norden des Untersuchungsgebiets optimiert ist, was zu einer geringeren Überflutungsgefährdung in der Simulation führt. Für Szenario 3 sind die Abweichungen zwischen

der Vorhersage und der Simulation am geringsten. Insgesamt zeigen die simulierten und vorhergesagten Gefahrenklassen ein übereinstimmendes Bild.

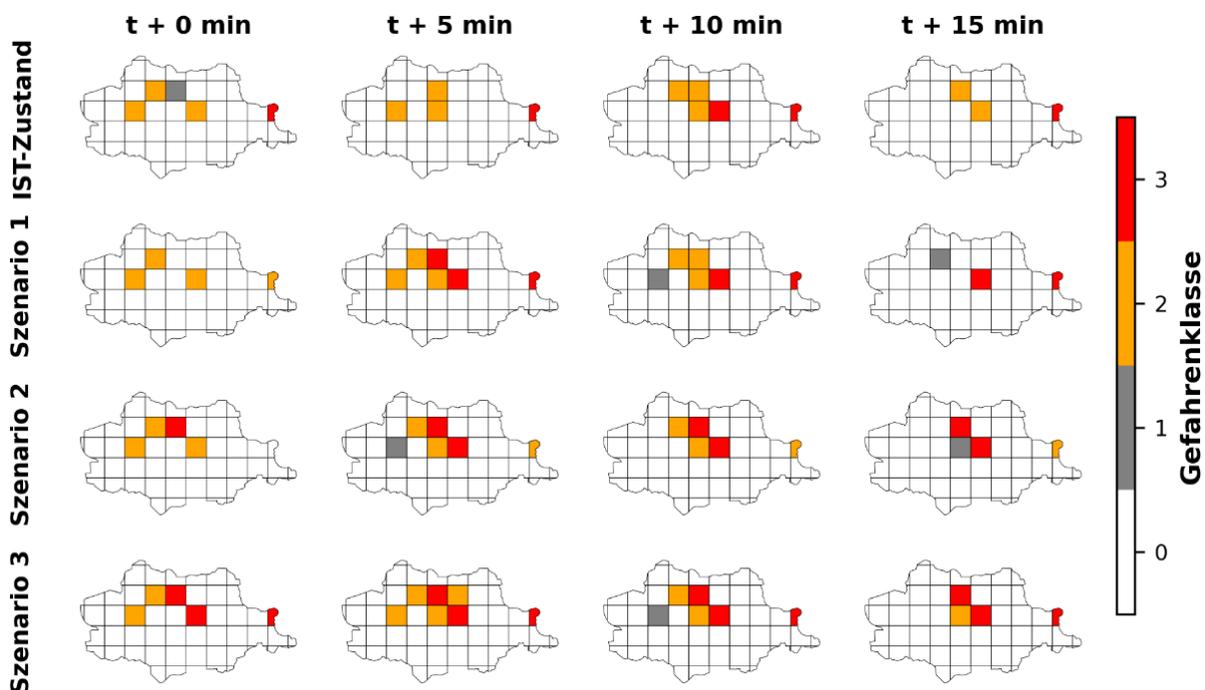


Abbildung 3: Mit der KI-Anwendung vorhergesagte Gefahrenklassen für das Teilereignis 212.

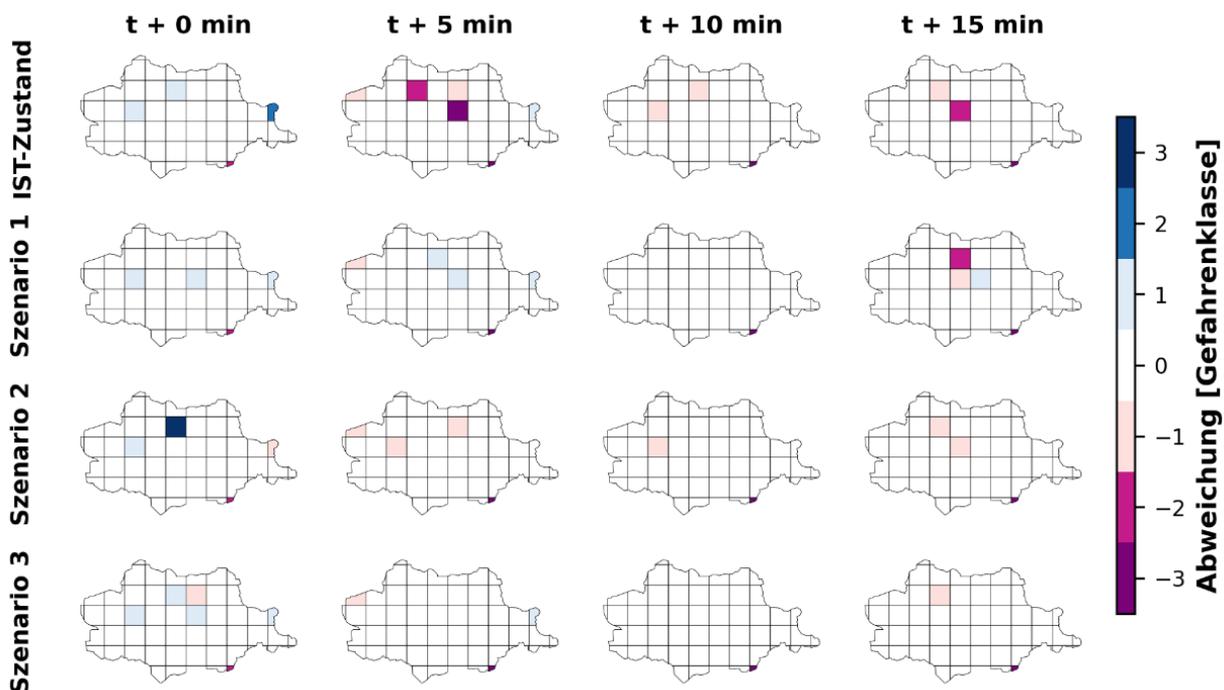


Abbildung 4: Abweichungen der vorhergesagte Gefahrenklassen von den simulierten Gefahrenklassen für das Teilereignis 212.

Die quantitative Bewertung der Abweichungen zeigt, dass der Root Mean Square Error (RMSE) für Teilereignis 212 0,47 beträgt. Dies bedeutet, dass die vorhergesagte Gefahrenklasse im Mittel über alle Szenarien und Zeitschritte um etwa eine halbe Gefahrenklasse von der simulierten Gefahrenklasse abweicht. Der Critical Index of Success (CSI) beträgt 0,68, was zeigt, dass die Vorhersage eine gute Qualität hat. Je näher der CSI an 1 ist, desto besser kann die Vorhersage eingeordnet werden.

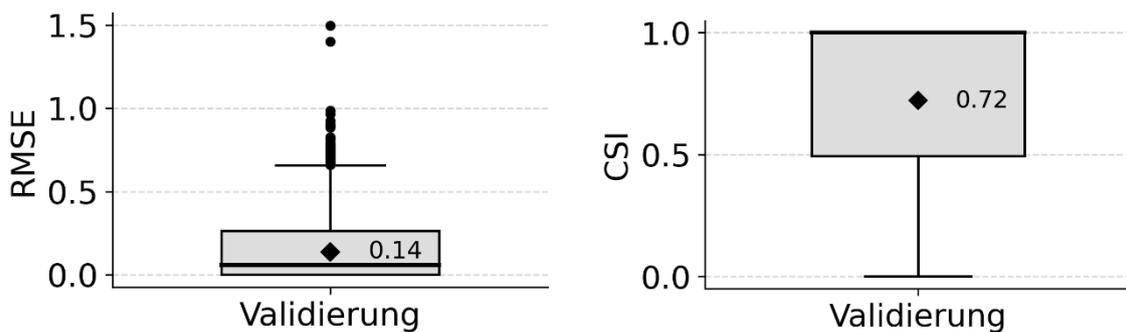


Abbildung 5: Boxplots über alle Teilereignisse der Validierung für den RMSE (links) und den CSI (rechts).

Die Ergebnisse aller Teilereignisse der Validierung zeigen, dass die KI-Anwendung insgesamt für die Prognose der Überflutungsgefährdung gut geeignet ist. Der mittlere Root Mean Square Error (RMSE) beträgt 0,14, während der Median bei 0,06 liegt. Der Critical Index of Success (CSI) liegt bei 0,72, während der Median bei 1 liegt (Abbildung 5). Diese Ergebnisse zeigen, dass die KI-Anwendung eine hohe Genauigkeit bei der Prognose der Überflutungsgefährdung erreicht.

Die Mittelwerte der Fehlerkriterien sind über die verschiedenen Zeitschritte (Tabelle 1) und Steuerungsszenarien (Tabelle 2) konstant, was zeigt, dass die Vorhersagegüte nicht von den Zeitschritten und Steuerungsszenarien abhängt.

Tabelle 1: Mittelwerte des RMSE und CSI für die verschiedenen Zeitschritte.

Zeitschritt	RMSE	CSI
t + 0 min	0,11	0,78
t + 5 min	0,11	0,79
t + 10 min	0,11	0,78
t + 15 min	0,12	0,77

Tabelle 2: Mittelwerte des RMSE und CSI für die verschiedenen Szenarien.

Steuerungsszenario	RMSE	CSI
IST-Zustand	0,11	0,78
Szenario 1	0,11	0,78
Szenario 2	0,13	0,75
Szenario 3	0,10	0,81

Die Konfusionsmatrix der KI-Anwendung für die Validierung (Abbildung 6) zeigt, dass die Gefahrenklasse 0 mit 99,6 % und die Gefahrenklasse 3 mit 88,8 % richtig vorhergesagt werden. Allerdings sind deutliche Abweichungen bei den Gefahrenklassen 1 und 2 zu erkennen. Dies zeigt, dass die KI-Anwendung sehr gut geeignet ist, um vorherzusagen, ob keine oder eine hohe Überflutungsgefährdung vorliegt. Die Prognose einer geringen und mittleren Überflutungsgefährdung gelingt mit der KI-Anwendung jedoch nicht.

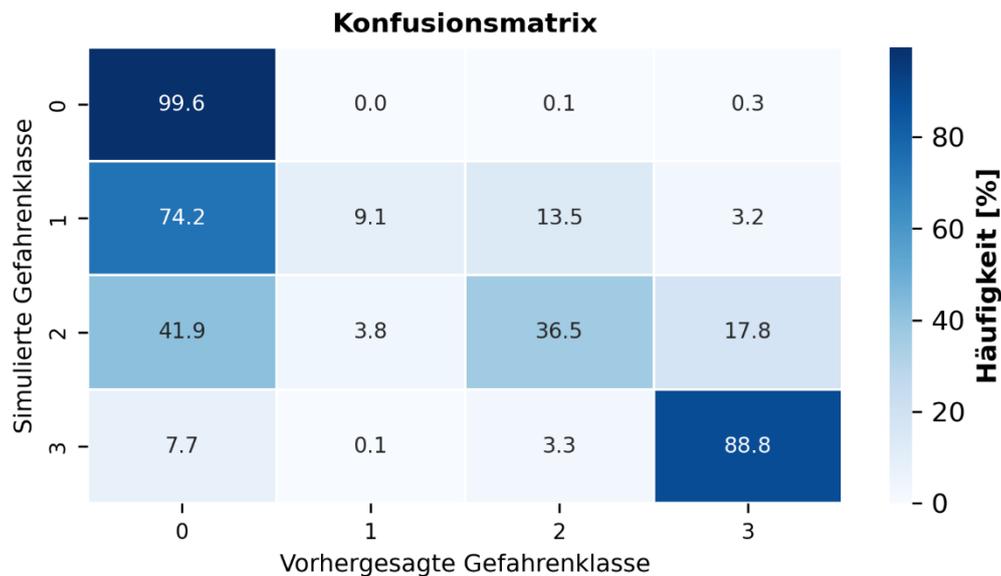


Abbildung 6: Konfusionsmatrix für die Validierung.

4 Schlussfolgerungen und Ausblick

Die vorgestellte KI-Anwendung zur Prognose der Überflutungsgefährdung zeigt sich als geeignetes Tool für die Erstellung von verlässlichen Prognosen zur Überflutungsgefährdung auf der Grundlage von Niederschlagsmessungen. Die Ergebnisse zeigen, dass die KI-Anwendung insbesondere für die Prognose von Gefahrenklasse 0 (keine Überflutungsgefährdung) und Gefahrenklasse 3 (hohe Überflutungsgefährdung) geeignet ist. Allerdings können geringe und mittlere Überflutungsgefährdungen nicht verlässlich prognostiziert werden. Insgesamt ist die KI-Anwendung vielversprechend, aber es besteht noch Verbesserungspotential. Um die KI-Anwendung für die Entscheidungsunterstützung relevanter zu gestalten, sind weitere Entwicklungen notwendig. Es ist wichtig, dass die Gefahrenklassen für die Oberfläche besser ausgewertet werden, um eine genauere Prognose zu ermöglichen, die auch das Schadenspotenzial auf der Oberfläche berücksichtigt. Die KI-Anwendung muss verbessert werden, um auch geringe und mittlere Überflutungsgefährdungen verlässlich zu prognostizieren.

5 Danksagung

Wir danken dem Bundesministerium für Forschung, Technologie und Raumfahrt für die Förderung des Projekts KI-Kanal im Rahmen der Fördermaßnahme KI4KMU sowie der SWO Netz GmbH für die gute Zusammenarbeit als assoziierte Partnerin.

6 Literatur

Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., ... & Zheng, X. (2016). Tensorflow: Large-scale machine learning on heterogeneous distributed systems. *arXiv preprint arXiv:1603.04467*.

Ahmad, A. I., Ray, B., & Chowdhury, M. (2019). Performance Evaluation of LoRaWAN for Mission-Critical IoT Networks. In *International Conference on Future Network Systems and Security*, pp. 37-51. Springer, Cham.

Chollet, F. et al. (2015). Keras. Verfügbar unter: <https://keras.io>

Korrespondenz an:

Luisa-Bianca Thiele

Ostfalia Hochschule für angewandte Wissenschaften, Center for Hydrosystems and Health, Herbert-Meyer-Straße 7, 29556 Suderburg, Deutschland

Telefon: +49 (0) 5826 988 61560

E-Mail: lu.thiele@ostfalia.de