

## Echtzeitvorhersage von Überflutung, Schadstofftransport und Schäden für Sturzflutereignisse am Beispiel Oberricklingen in Hannover

Lothar Fuchs, Simon Berkhahn, Yu Feng, Thomas Graf, Uwe Haberlandt, Heidi Kreibich, Insa Neuweiler, Aaron Peche, Viktor Rözer, Robert Sämman Monika Sester, Bora Shehu, Julian Wahl

### Zusammenfassung

Im Rahmen des BMBF-Projekts EVUS (Echtzeitvorhersage urbaner Sturzfluten und damit verbundene Wasserkontamination) wurde ein Vorhersagemodell für urbane Sturzfluten und ihre Folgen entwickelt. Es besteht aus den Komponenten: kurzfristige Niederschlagsprognose, ein detailliertes 1D-Kanal- und 2D-Oberflächenmodell basierend auf einem digitalen Geländemodell, das mit einem Mobile Mapping Lidar verfeinert wurde; ein auf künstlichen neuronalen Netzen basierendes Überflutungsmodell zur schnellen Vorhersage von überfluteten Gebieten; ein 3D-Grundwassermodell für gesättigte und variabel gesättigte Grundwasserströmung gekoppelt mit dem 1D / 2D-Modell; ein auf Partikeln basierendes Transportmodell zur schnellen Vorhersage von Transportwegen und -zeiten von Kontaminationen auf der Oberfläche; und ein Überflutungsschadensmodell.

### 1. Einleitung

Extreme Niederschläge haben das Versagen des Entwässerungssystems zur Folge und führen zu einer Überflutung auf der Oberfläche (urbane Sturzfluten). Weitere Schadensereignisse während einer urbanen Sturzflut können durch die ungewollte Freisetzung von schädlichen Substanzen entstehen, die sowohl die Qualität von Oberflächengewässern als auch des Grundwassers beeinträchtigen können. Im Rahmen des von BMBF geförderten Projekts "Echtzeitvorhersage urbaner Sturzfluten und damit verbundene Wasserkontamination" wurde ein Vorhersagemodell für extreme Niederschläge, Abflüsse und Transport im Kanalnetz, auf der Oberfläche und im Untergrund des Stadtgebiets und eine schnelle Schadensvorhersage entwickelt.

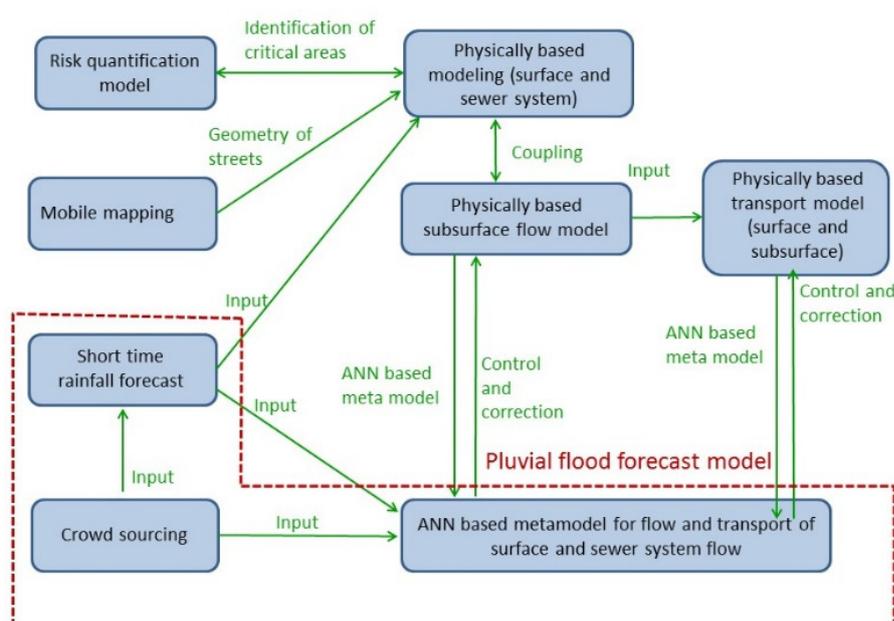


Abb. 1: Struktur des Vorhersagemodells

Zusätzliche Informationen über extreme Niederschläge und/oder Überflutungen werden mit Hilfe von Apps und durch die Auswertung von tweets gesammelt. Die Struktur des Vorhersagemodells ist aus der Abbildung 1 ersichtlich.

## **2. Erläuterung der Modellkomponenten**

### **2.1 Niederschlagsvorhersage**

Wegen ihrer hohen zeitlichen und räumlichen Auflösung, werden Radardaten als Input für Echtzeitvorhersagen verwendet (Achleitner et al. 2009, Li et al. 1995). Die räumliche Auflösung der Radardaten ermöglichen die Identifizierung von Ereignistypen, deren Verfolgung und zeitliche Extrapolation. Für konvektive, sich schnell entwickelnde Niederschlagsereignisse beträgt die Vorhersagezeit normalerweise Minuten bis maximal 2 Stunden. Im Rahmen des Projekts wurde, die Niederschlagsquantifizierung für urbane Sturzfluten verbessert, indem ein besseres Niederschlagsfeld durch die Merging verschiedener Arten von Niederschlagsquellen geschätzt wird, ein neues Niederschlagsvorhersagemodell für die Stadt Hannover mit verbesserter Vorlaufzeit entwickelt wurde und die Unsicherheit durch Erzeugung von Ensemblemitgliedern quantifiziert wurde.

Schwerpunkt war die Erzielung höherer Vorlaufzeiten für das Nowcasting von Niederschlägen durch die Verwendung von Mergingdaten als Input für den Tracking-Algorithmus. Zu diesem Zweck wurde die von Berndt et al. (2014) vorgeschlagene und später bei Fuchs et al. (2017) für die 5 min Auflösung getestete Methode verwendet. Der von Kraemer (2008) entwickelte Hyratrac-Algorithmus, der Niederschlagsereignisse identifiziert, verfolgt und linear extrapoliert, wird zur Vorhersage von Radarintensitäten bei unterschiedlichen Vorlaufzeiten von Minuten bis 2 Stunden eingesetzt. Die Ergebnisse von 86 ausgewählten Ereignissen innerhalb des Radarbereichs der Station Hannover für den Zeitraum 2006-2012 sind in Abbildung 2 dargestellt.

Die Ergebnisse zeigen, dass bei Vorlaufzeiten von weniger als 2 Stunden die Vorhersage der Mergingdaten deutlich besser ist als die von den Radarrohdaten. Allerdings ist die Vorhersage nur für maximale Vorlaufzeiten von 30 Minuten bis zu 2 Stunden besser. Bei einer Vorlaufzeit ab 2 Stunden, gibt es keinen klaren Unterschied zwischen Radar und Merging basierter Vorhersage. Dies deutet darauf hin, dass bei solch hohen Vorlaufzeiten der Vorhersagefehler unabhängig von der Eingabedatenqualität ist und stattdessen fast ausschließlich vom Extrapolationsfehler abhängt. Daher wird nunmehr eine Betrachtung von nichtlinearen Extrapolationen durchgeführt, d. h. es werden aus historischen Beobachtungen ähnliche Muster gesucht. Verwendet wird dafür ein KNN-Algorithmus, der in den Hyratrac-Algorithmus integriert und trainiert wird, um die Vorlaufzeiten zu erhöhen und Ensembleprognosen zu erstellen.

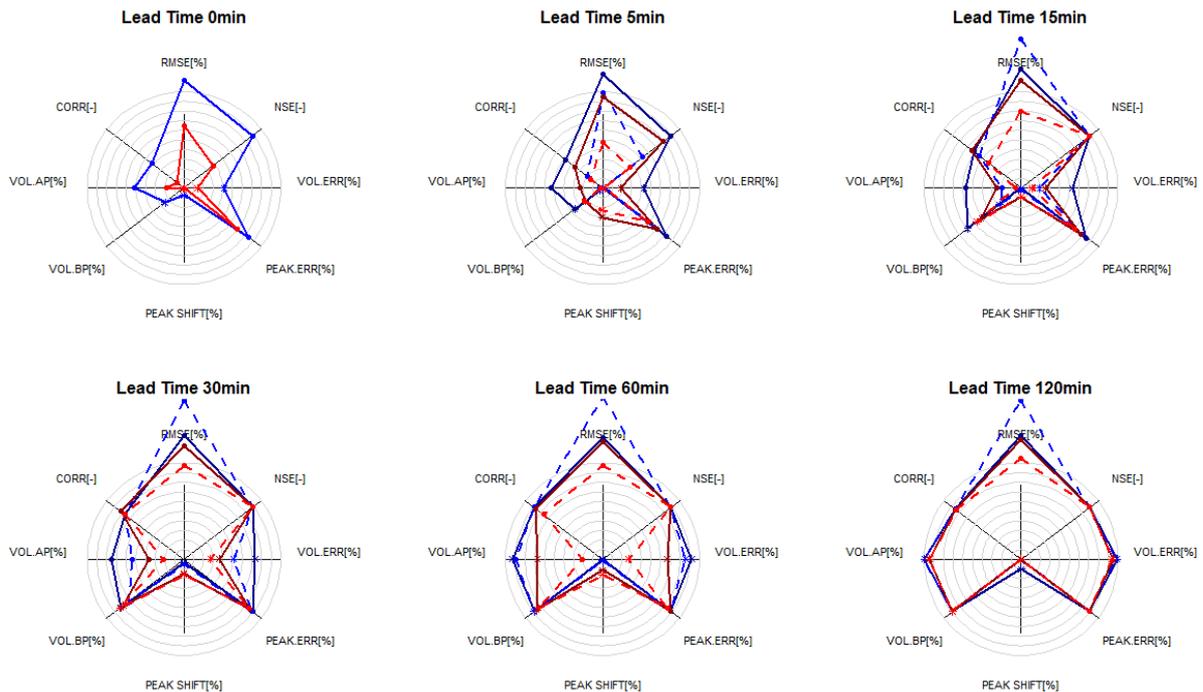


Abb. 2: Vergleich von Vorhersagegütekriterien. Radarrohdaten (blau) und Mergingdaten (rot) im Vergleich mit beobachteten Niederschlägen von Bodenstationen (dicke Linien) und mit beobachteten Radardaten (Strichlinie) gemittelt für die 86 ausgewählten Ereignisse und für verschiedene Vorlaufzeiten: 5, 15, 30, 60 und 120 min. Alle Gütewerte sind normalisiert und das Optimum (1 für Korrelation, NSE und Peak Timeshift, 100 % für alle anderen) steht im Mittelpunkt der Abbildung. Je näher am Zentrum, desto besser die Güte. Jeder graue Kreis zeigt einen Fehlerrückgang um 10 % oder 0,1 an.

## 2.2 Oberflächenabflussmodell

Ein gekoppeltes 1D/2d Kanalnetz und Oberflächenabflussmodell (HYSTEM-EXTRAN 2D, itwh 2017) wurde für die gesamte Stadt Hannover basierend auf einem 50 cm Digitalen Geländemodell (DGM) aufgestellt. Die Oberfläche wird mit einem unstrukturierten Berechnungsgittern bestehend aus Dreieckselementen diskretisiert. Für das Testgebiet in Hannover Ricklingen wurden die Straßen und angrenzende Bereiche bis zu ca. 200 m mit einem Mobile Mapping System (MMS) mit einer Auflösung von 10 cm erfasst. Das Ergebnis dieser Erfassung wurde mit Bodenfilterungsalgorithmen überarbeitet und in Abbildung 3a dargestellt. In Abbildung 3c ist der Bereich einer Straße mit einer Auflösung von 10 cm dargestellt. Dieses DGM wurde mit einem verfügbaren DGM mit 50 cm Auflösung zusammengeführt (Abbildung 3b), um die Bereiche abzudecken, die nicht vom MMS erfasst wurden. Dabei wurde eine Interpolation angewendet, um unerwartete Höhengsprünge an Verbindungsgrenzen von zwei DTMs zu glätten. Auf diese Weise wurde die Auflösung eines DGM mit 50 cm Auflösung im Straßenbereich auf 10 cm verbessert und die Vollständigkeit der Daten erreicht (Abbildung 3d).

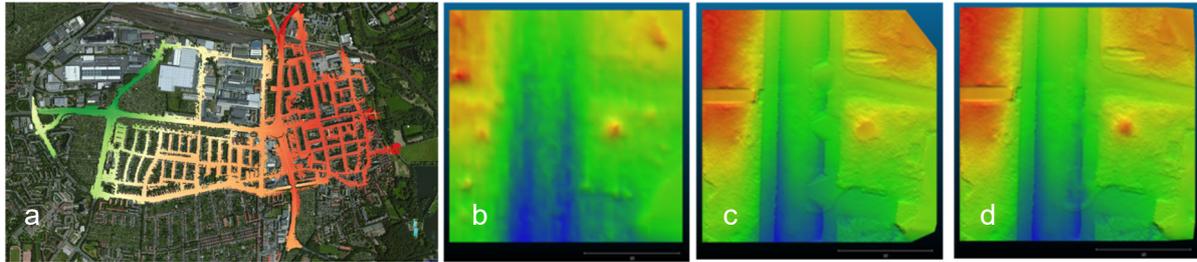


Abb. 3: Digitales Geländemodell (DGM) erzeugt aus dem Mobile Mapping System (a). verfügbares DGM mit einer Auflösung von 50 cm (b), DGM des Mobile Mapping System in 10cm Auflösung (c) und zusammengeführtes DGM (d).

Das Überflutungsmodell wird anhand von radarbasierten Niederschlagsmessungen, Feuerwehrschadensmeldungen und Informationen aus den sozialen Medien validiert. Parameterbedingte Modellunsicherheiten wurden über Sensitivitätsstudien analysiert (Tecklenburg et al. 2017)

Das beschriebene numerische Überflutungsmodell mit Kopplung an das Untergrundströmungsmodell wird verwendet um die Trainingsdaten für das künstliche neuronale Netz zur Echtzeitvorhersage von maximalen Wasserständen auf der Oberfläche zu generieren. Dafür wurden ca. 1500 Starkregenszenarien berechnet. Weiterhin bilden die im Kanalnetz und an der Oberfläche berechneten, zeitabhängigen Wasserstände und Fließgeschwindigkeiten der Szenarien die Grundlage für das Schadstofftransportmodell.

### 2.3 Wasserstandsvorhersage

Aufbauend auf der Vorhersage der Niederschläge ist eine Echtzeitvorhersage Wasserständen innerhalb von wenigen Sekunden notwendig. Detaillierte physikalisch basierte Modelle können diese Anforderung nicht erfüllen. In Henonin et al. (2013) zeigt, dass die Auswahl vorsimulierter Szenarien die einzige Möglichkeit darstellt, Echtzeitvorhersagen mit detaillierten hydrodynamischen Modellen zu realisieren. Bermúdez et al. (2018) berechnet Szenarien werden mit einem detailliertem 1D-2D hydrodynamischen Modell, jedoch ist bei der Auswahl von vorsimulierten Szenarien keine Interpolation zwischen den Szenarien möglich. Unter Berücksichtigung der Variabilität von Regenereignissen und der Unsicherheit in der Regenvorhersage, ist die Möglichkeit der Interpolation bei der Umsetzung von Echtzeitvorhersagen unabdingbar. Das hier entwickelte Modell zur Vorhersage von maximalen Wasserständen besitzt die Fähigkeit der Interpolation. Mit Hilfe von vorsimulierten Szenarien (siehe 2.2) werden künstliche neuronale Netze trainiert. Die Eingabe in das Netz umfasst dabei die Regenvorhersage in fünf Minuten Zeitschritten und die Ausgabe der maximalen Wasserstände mit einer zweidimensionalen räumlichen Verteilung. Durch die Verwendung eines Ensembles von neuronalen Netzen wird die Interpolationsfähigkeit des Modells deutlich verbessert. Der konzeptionelle Aufbau des Modells ist in Abbildung 4 dargestellt.

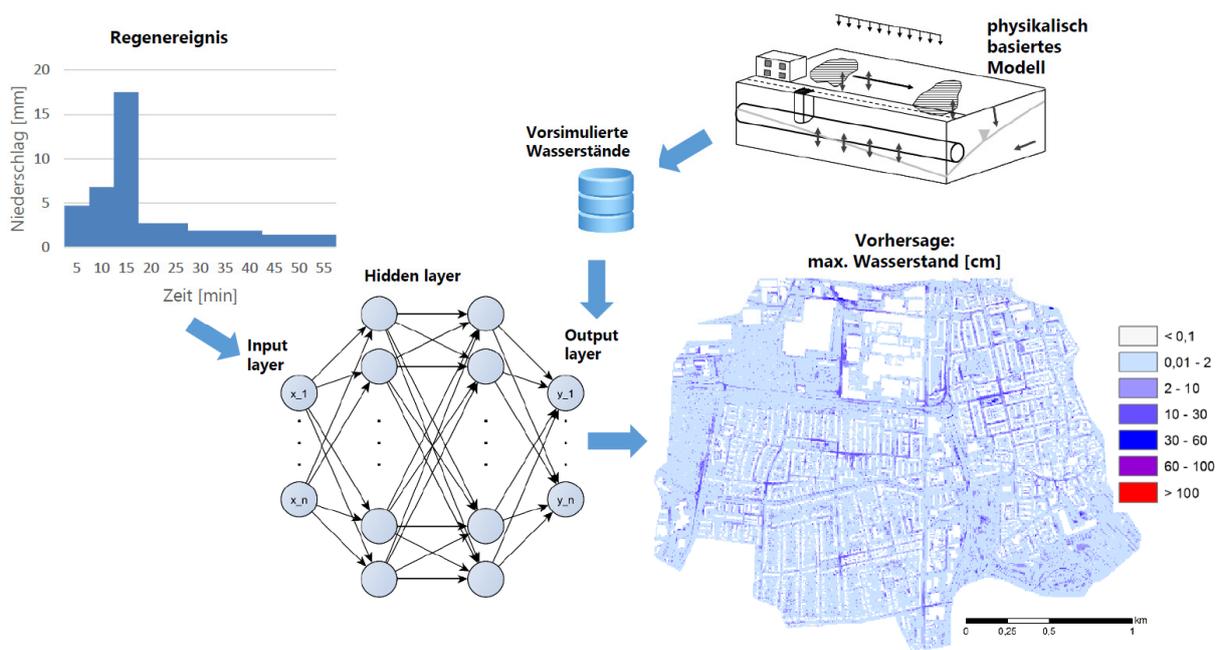


Abb. 4: Konzeptionelles Modell zur Vorhersage urbaner Sturzfluten

Das Vorhersagemodell ist ausführlich in Berkahn et al. (2018) erläutert. Die Rechenzeit des Modells liegt bei 2-3 Sekunden pro Regenereignis. Mit einem durchschnittlichen RMSE für ausgewählte Testereignisse von weniger als einem Zentimeter kann das Modell die Ergebnisse HE 2D sehr gut nachbilden.

## 2.4 Gekoppeltes Kanalnetz-Grundwassermodell

Um den Austritt von Abwasser in das Grundwasser bzw. den Eintritt von Grundwasser in das Kanalnetz abzubilden, wurde ein gekoppeltes Kanalnetz-Grundwassermodell erstellt. Dafür wurde der Grundwasserströmungssimulator OpenGeoSys [OGS] (Kolditz et al. 2012) mit dem hydrodynamischen Modell HYSTEM-EXTRAN [HE] (itwh 2014) zum Leckagemodell OGS-HE gekoppelt. Die bidirektionale, nicht-iterative Kopplung basiert auf der Aktualisierung von Quelltermen. Das Datentransfer-Schema wurde mit der, als effektiv geltenden (Laszewski & Nauduri 2011) FiFo Methode NamedPipes realisiert. Konzeptionelles Modell und Datentransfer sind schematisch in Abbildung 5 gegeben.

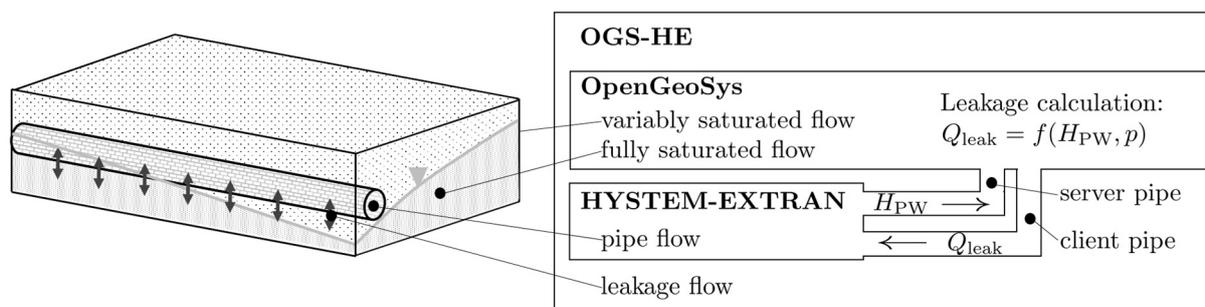


Abb. 5. Konzeptionelles Modell OGS-HE (modifiziert nach Peche et al. 2017).

Das gekoppelte Modell wurde erfolgreich validiert und verifiziert. Eine detaillierte Beschreibung von OGS-HE einschließlich mathematischem Modell, Kopplung, Validierung und Verifizierung ist in Peche et al. (2017) und Peche et al. (2018) gegeben.

Im Rahmen des EVUS-Projektes wird OGS-HE als Erweiterung des hydrodynamischen Modells HE2D für die präzise Berechnung von Überflutungsszenarien genutzt. Ergebnisse des gekoppelten Modells werden für das Training des Metamodells (siehe 2.3) verwendet.

## 2.5 Schadstofftransportmodell

Unfälle mit Lagerbehältern oder Verkehrsunfälle mit austretenden Schadstoffen stellen punktuelle Schadstoffeinträge dar. Eine schnelle Erfassung und Vorhersage der betroffenen Gebiete ermöglicht eine Eindämmung und Schutz vor weitreichender Kontamination. Dazu wurde Transportmodell für Schadstoffe entwickelt, welches schnell genug ist, um für eine Echtzeitvorhersage eingesetzt zu werden.

Das Transportmodell für Schadstoffeinträge aus lokal begrenzten Quellen wird über einen Partikelansatz umgesetzt. In dieser Lagrange'schen Betrachtungsweise wird der Schadstoff über viele Massepunkte dargestellt, die sich mit dem Strömungsfeld des Regenwassers bewegen und sich zusätzlich durchmischen. Als Grundlage für das Strömungsfeld werden Ergebnisse aus der hydrodynamischen Simulation genutzt, welche in einer Datenbank abgelegt sind.

Die Durchmischung der Partikel wird über die Random-Walk Methode umgesetzt (Kinzelbach 1988). Dabei erfährt jedes Partikel zusätzlich zu seiner advektiven Bewegung im dynamischen Strömungsfeld eine zufällige Bewegung quer und längs der Strömung.

Durch die Partikel-Betrachtungsweise wird der Schadstoff eindeutig verfolgt. Anders als bei gitterbasierten Methoden treten keine numerischen Effekte auf, welche zu einer Verschmierung der Konzentrationsfronten und zu einer Unterschätzung von Konzentrationsspitzen führen (Pathirana et al. 2011).

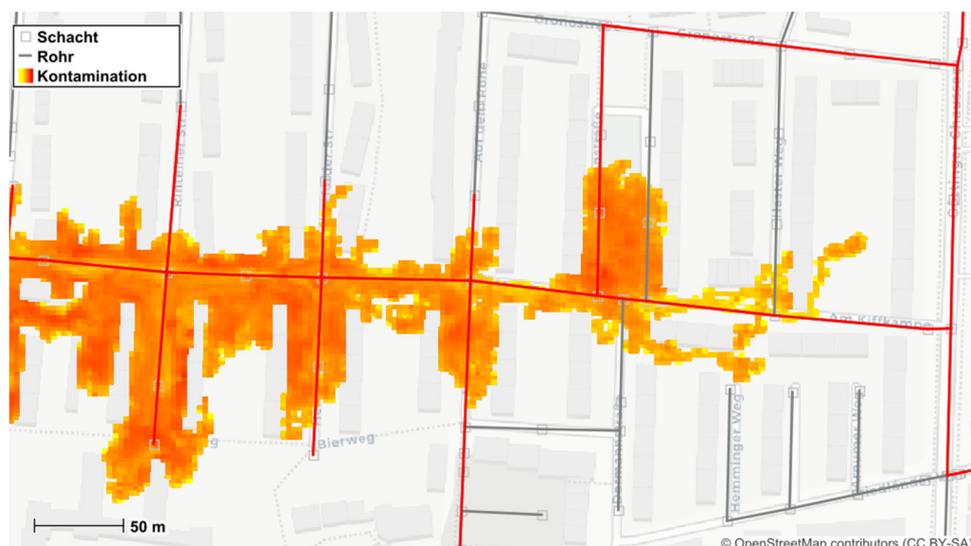


Abb. 6: Ausbreitungsgebiet eines Schadstoffeintrags. Kontamination der Kanalrohre durch Rotfärbung gekennzeichnet. Gradient der Oberflächenfärbung von gelb (schwach) bis rot (stark kontaminiert)

Für eine Auswertung des Verschmutzungspotentials werden alle Partikel auf ein Raster projiziert und die gebildete Massensumme mit dem Wasserstand verrechnet.

Die Simulation für ein Unfallereignis mit 20.000 Partikeln benötigt ca. 90 Sekunden. Da die Ausbreitung über zwei Stunden stattfindet, ist die Vorhersage ausreichend schnell genug, um eine Echtzeitvorhersage mit ausreichender Vorwarnzeit zu erstellen. Abbildung 6 zeigt eine beispielhafte Ausbreitungskarte.

## **2.6 Risikoquantifizierung**

Zur Quantifizierung des Starkregenrisikos werden das Überflutungs- und Schadstofftransportmodell mit einem Schadensmodell gekoppelt. Ziel ist es auf Basis der Gefährdungsabschätzungen (Überflutungsflächen, Wassertiefen) eine probabilistische Abschätzung der zu erwartenden Schäden an Gebäuden zu geben. Dazu wurde auf der Basis empirischer Schadensdaten aus vergangenen Starkregenereignissen in Deutschland, ein probabilistisches multivariates Schadensmodell entwickelt. Mit Hilfe von maschinellen Lernen wurden zunächst die wichtigsten schadensbeeinflussenden Prädiktoren aus einem Set von 57 Eingangsvariablen bestimmt. Hierbei wurden zum einen Variablenkombinationen zur Erklärung der Schadenshöhe, sowie zum anderen der Schadenseintrittswahrscheinlichkeit identifiziert. Dabei konnte gezeigt werden, dass die Schadenshöhe vor allem durch Gefährdungsvariablen wie Wasserstand oder Überflutungsdauer gesteuert wird; die Schadenseintrittswahrscheinlichkeit jedoch neben dem Wasserstand vor allem von Widerstandsparametern wie der Art des Gebäudes oder dem Wissen der Bewohner über das Starkregenrisiko beeinflusst wird.

In einem zweiten Schritt wurde auf Basis der als wichtig identifizierten Prädiktoren ein probabilistisches multivariates Schadensmodell auf Basis einer Bayesschen Beta-Regression entwickelt. Dabei wird der Schaden pro Gebäude in Relation zum Gebäudewert als Wahrscheinlichkeitsverteilung für das Intervall (0 = kein Schaden; 1 = Totalschaden) geschätzt. Die Wahrscheinlichkeitsverteilung wird dabei als Kombination der zu erwartenden Schadenshöhe als auch der Schadenseintrittswahrscheinlichkeit bestimmt. Die probabilistische Schadensverteilung für jedes Gebäude wird individuell auf der Basis von Markov-Chain-Monte-Carlo (MCMC) Stichproben angenähert. Dadurch kann im Vergleich zu deterministischen Verfahren die Zuverlässigkeit der Schadensschätzung deutlich verbessert werden. Dies erlaubt eine Echtzeitvorhersage der zu erwartenden Schäden während eines Starkregenereignisses bei der die Unsicherheiten der Schätzung kommuniziert, sowie schrittweise reduziert werden können, sobald detaillierte Eingangsdaten vorliegen. Die Verwendung Bayesscher Verfahren erlaubt zudem die Integration von Expertenwissen in Form von a-priori Verteilungen zur Kalibrierung des Modells bei räumlichen und zeitlichen Transfers.

## **2.7 Crowdsourcing**

Der Begriff Crowdsourcing bezeichnet eine aktuelle Methode zur Datenerfassung, die sich in den vergangenen Jahren schnell entwickelt hat und sich insbesondere darauf bezieht, Daten aus Sozialen Medien zu nutzen. Die über Crowdsourcing erhobenen Daten werden gemeinhin als Volunteered Geographic Information (VGI) bezeichnet. Das Ziel ist es, nützliche Informationen mit Ortsinformationen von freiwilligen Nutzern zu sammeln. Für das Projekt EVUS wurde eine Dateninfrastruktur entwickelt, die das Erfassen von Crowdsourcing-Informationen, den

Austausch notwendiger Informationen zwischen den Teilprojekten sowie die Visualisierung der Vorhersageergebnisse ermöglicht (Abbildung 7).

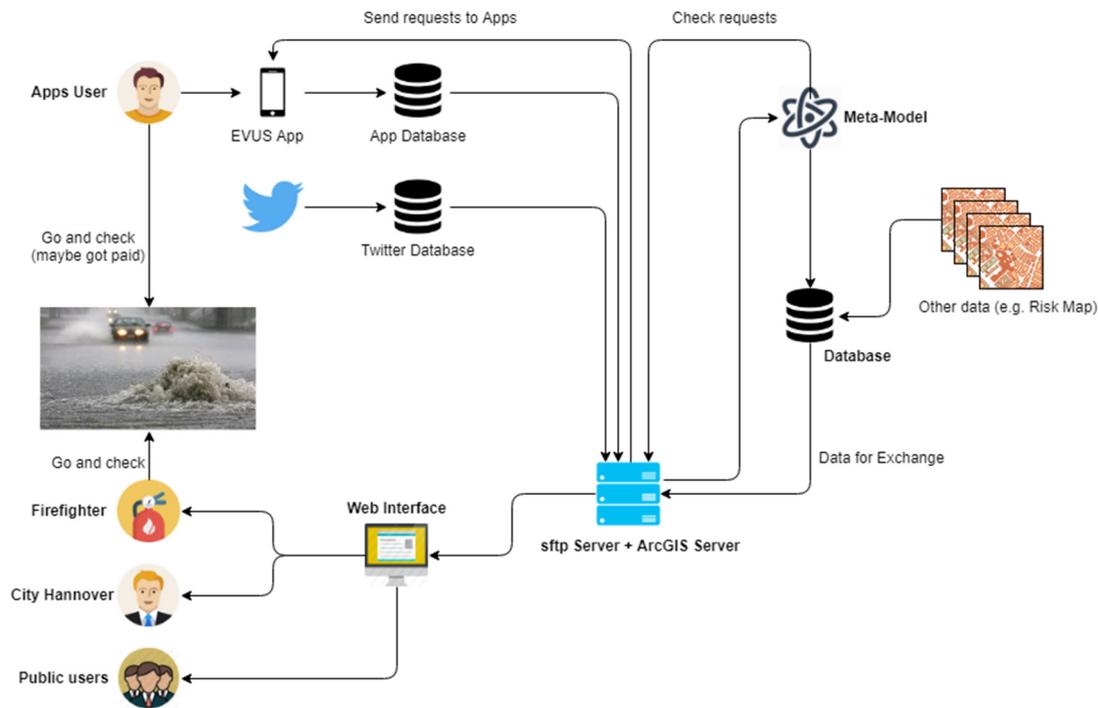


Abb. 7: Dateninfrastruktur für das Projekt EVUS.

Crowdsourcing-Methoden können grob in zwei Kategorien eingeteilt werden: partizipativ und opportunistisch. Beide Kategorien werden im Projekt genutzt. Partizipative Methoden erfordern die bewusste und aktive Teilnahme der Nutzer. Zu diesem Zweck wurde eine Handy-App entwickelt, um Sturzflut-relevante Informationen von freiwilligen Nutzern zu sammeln. Es enthält den Standort des Benutzers und auch gewünschte Informationen wie Regenintensität, Überschwemmungsbereich und das Auftreten von Kontaminationen (s. Abbildung 8, links). Im Gegensatz dazu erfordern opportunistische Methoden keine aktive Beteiligung des Nutzers am Messvorgang. In diesem Zusammenhang wurde ein Ansatz zur Identifizierung und Lokalisierung von Niederschlags- und Hochwasserereignissen aus sozialen Medien durch die Analyse der benutzergenerierten Texte und Fotos entwickelt (Feng & Sester 2017, Feng & Sester 2018). Deep-Learning-Modelle werden trainiert, um relevante Beiträge von Nutzern in sozialen Medien zu identifizieren. Die einzelnen Beiträge werden durch ein raumzeitliches Clustering aggregiert, um regen- oder flutrelevante Ereignisse zu extrahieren (Abbildung 8, rechts). Die Crowdsourcing-Information dient als notwendiger Input für die Schadstoffbewegungsanalyse.

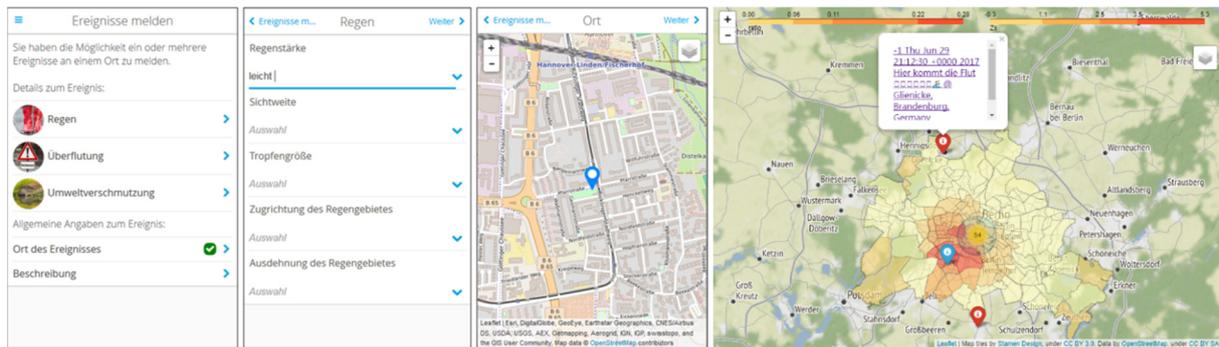


Abb. 8. Screenshots der Handy-App zur Datenerfassung (links). Extrahierte, raumzeitliche Cluster in Berlin am 29. Juni 2016 (rechts).

### 3. Zusammenfassung

Die Modellumgebung wurde für ein Teileinzugsgebiet entwickelt und getestet. Die einzelnen Modelle werden weiterentwickelt und weiter getestet, erweitert und validiert. Erste Experimente mit der Verarbeitung von Crowdsourcing von Niederschlagsereignisdaten wurden durchgeführt. Bilder von Social-Media-Plattformen werden mit Deep-Learning-Ansätzen analysiert, um ihr Potenzial für die Erkennung von Niederschlagsereignissen zu untersuchen. Ob das Modellierungssystem für die gesamte Stadt Hannover umgesetzt wird, ist derzeit noch offen.

### Danksagung

Das Projekt wird im Rahmen des BMBF-geförderten Forschungsprojekts "EVUS - Echtzeit-Vorhersage urbaner Sturzfluten und damit verbundene Schadstoffkontaminationen" (BMBF, 03G0846B) gefördert. Radar- und Niederschlagsdaten wurden vom Deutschen Wetterdienstes (DWD), Luftbilder und Katasterkarten vom Amt für Geoinformation der Stadt Hannover zur Verfügung gestellt.

### Literatur

- Achleitner, S., Fach, S., Einfalt, T., Rauch, W., 2009. Nowcasting of rainfall and of combined sewage flow in urban drainage systems. *Water Science and Technology*, 59: 1145-51.
- Ahlstrom, S., Foote, H., Arnett, R., Cole, C., Serne, R., 1977. Multicomponent mass transport model: theory and numerical implementation (discrete-parcel-random-walk version). Tech. rep., Battelle Pacific Northwest Labs., Richland, Wash. (USA).
- Berkhahn, S., Fuchs, L., Neuweiler, I. An ensemble neural network model for real-time prediction of urban floods. Manuscript in preparation.
- Bermúdez, M., Ntegeka, V., Wolfs, V., Willems, P., 2018. *Water Resour Manage* 32, 2801-2815. <https://doi.org/10.1007/s11269-018-1959-8>
- Berndt, C., Rabiei, E., Haberlandt, U., 2014. Geostatistical merging of rain gauge and radar data for high temporal resolutions and various station density scenarios. *Journal of Hydrology* 508, 88-101.
- Feng, Y., Sester, M., 2017. Social media as a rainfall indicator. In: Bregt, A., Sarjakoski, T., Lammersen, R. van, Rip, F. (Eds.). *Societal Geo-Innovation: short papers, posters and*

- poster abstracts of the 20th AGILE Conference on Geo-graphic Information Science, Wageningen, the Netherlands.
- Feng, Y., Sester, M., 2018. Extraction of Pluvial Flood Relevant Volunteered Geographic Information (VGI) by Deep Learning from User Generated Texts and Photos. *ISPRS International Journal of Geo-Information*, 7(2), 39.
- Fuchs, L., Graf, F., Haberlandt, U., Kreibich, H., Neuweiler, I., Sester, M., Berkhan, S., Feng, Y., Peche, A., Rözer, V., Sämann, R., Shehu, B., Wahl, J., 2017. Real time prediction of pluvial floods and induced water contamination in urban areas. *Proceedings of International Conference of urban drainage*, 2017 Prague.
- Henonin, J., Russo, B., Mark, O., Gourbesville, P., 2013. Real-time urban flood forecasting and modelling - a state of the art. *Journal of Hydroinformatics* 15(3),717-736.
- itwh, 2014. Kanalnetzberechnung - Hydrodynamische Abfluss-Transport- und Schmutzfrachtberechnung. HYSTEM-EXTRAN 7 Modellbeschreibung, Institut für technisch-wissenschaftliche Hydrologie GmbH Hannover.
- itwh, 2017. HE2D – Urbane Sturzfluten, Modellbeschreibung, Institut für technisch-wissenschaftliche Hydrologie GmbH Hannover.
- Kinzelbach, W., 1988. The random walk method in pollutant transport simulation. In: *Groundwater flow and quality modelling*. Springer, pp. 227-245.
- Kolditz, O., Bauer, S., Bilke, L., Böttcher, N., Delfs, J. O., Fischer, T., Park, C. H., 2012. OpenGeoSys: an open-source initiative for numerical simulation of thermo-hydro-mechanical/chemical (THM/C) processes in porous media. *Environmental Earth Sciences* 67(2), 589-599.
- Kraemer, S., 2008. Quantitative Radardatenaufbereitung für die Niederschlagsvorhersage und die Siedlungsentwässerung. *Mitteilungen Institut für Wasserwirtschaft, Hydrologie und landwirtschaftlichen Wasserbau, Gottfried Wilhelm Leibniz Universität Hannover, Heft 92, ISSN 0343-8090, Hannover, Germany.*
- Li, L., Schmid, W., Joss, J., 1995. Nowcasting of motion and growth of precipitation with radar over a complex orography. *J Appl Meteorol* 34, 1286-300.
- Pathirana, A., Maheng Dikman, M., Brdjanovic, D., 2011. A Twodimensional pollutant transport model for sewer overflow impact simulation. In: *Proceedings: 12th International Conference on Urban Drainage, Porto Alegre/Brazil*. pp. 10-15.
- Peche, A., Graf, T., Fuchs, L., Neuweiler, I., 2017. A coupled approach for the three-dimensional simulation of pipe leakage in variably saturated soil. *Journal of Hydrology* 555, 569-585.
- Peche A., Graf, T., Fuchs, L., Neuweiler, I., Maßmann, J., Huber, M., Vassolo, S., Stoeckl, L., Lindenmaier, F., Neukum, C., Jing, M., Attinger, S., 2018. HH Processes. In: Kolditz O., Nagel T., Shao H., Wang W., Bauer S. (Eds) *Thermo-Hydro-Mechanical-Chemical Processes in Fractured Porous Media: Modelling and Benchmarking. Terrestrial Environmental Sciences*. Springer, Cham.
- Tecklenburg, J., Wachenhausen, J., Neuweiler, I., Fuchs, L., 2017. Framework for an automated sensitivity analysis for modelling urban flooding; *Proc. 17th ICUD, Prague, 2017.*