

## Nitrat-Monitoring 4.0 – Intelligente Systeme zur nachhaltigen Reduzierung von Nitrat im Grundwasser

Tanja Liesch<sup>1</sup>, Julian Bruns<sup>2</sup>, Andreas Abecker<sup>3</sup>, Désirée Hilbring<sup>4</sup>, Divas Karimanzira<sup>5</sup>,  
Tobias Martin<sup>6</sup>, Martin Wagner<sup>7</sup>, Andreas Wunsch<sup>8</sup>, Thilo Fischer<sup>9</sup>

**Abstract:** Nitrat im Grundwasser stellt weltweit unter anderem für die Trinkwasserversorgung ein großes Problem dar. Die Verteilung von Nitrat im Grundwasser ist dabei das Ergebnis eines komplexen Zusammenspiels vieler Einflussfaktoren, welches sich mit herkömmlichen Modellen für große Gebiete aufgrund der hohen Komplexität der Domäne nur schwer modellieren lässt. KI-Anwendungen, insbesondere Neuronale Netze bzw. Deep Learning Verfahren, lassen als datenbasierte Modelle, die komplexe Zusammenhänge aus einer großen Datenmenge extrahieren und übertragen können, hier einen deutlichen Mehrwert bei der zeitlich-räumlichen Vorhersage von Nitratwerten erwarten. Im vorliegenden Projekt soll daher ein übergreifendes System entwickelt werden, welches KI Verfahren mit Methoden der Umweltinformatik und speziell der Wasserdomäne kombiniert. Hierzu kommen State-of-the-Art Machine Learning Methoden wie Convolutional Neural Networks und Long short-term Memory Netzwerke zum Einsatz, um so eine verbesserte räumliche und zeitliche Vorhersage von Nitrat im Grundwasser zu erzielen und damit zur effizienten und nachhaltigen Nitrat-Reduzierung beizutragen. Diese werden mit Methoden des Operation Research und der semantischen Datenintegration erweitert, um damit einen Endnutzer bei der Entscheidungsfindung intelligent zu unterstützen.

**Keywords:** Convolutional Neural Networks; Long-Short Term Memory Networks; Grundwasser; Nitrat

### 1 Einleitung

Grundwasser bildet weltweit die größten Süßwasservorkommen und ist in vielen Regionen die Grundlage der Trinkwasserversorgung. So wird in Deutschland etwa 70% des Trinkwasserbedarfs über Grundwasser gedeckt [Bu16]. Darüber hinaus versorgen oberflächennahe

---

<sup>1</sup> Karlsruher Institut für Technologie (KIT), Institut für Angewandte Geowissenschaften, Abteilung Hydrogeologie, Kaiserstr. 12, 76131 Karlsruhe tanja.liesch@kit.edu

<sup>2</sup> Disy Informationssysteme GmbH, Ludwig-Erhard-Allee 6, 76131 Karlsruhe julian.bruns@disy.net

<sup>3</sup> Disy Informationssysteme GmbH, Ludwig-Erhard-Allee 6, 76131 Karlsruhe andreas.abecker@disy.net

<sup>4</sup> Fraunhofer IOSB, Fraunhoferstr.1, 76131 Karlsruhe desiree.hilbring@iosb.fraunhofer.de

<sup>5</sup> Fraunhofer IOSB-AST, Am Vogelherd 90, 98693 Ilmenau divas.karimanzira@iosb-ast.fraunhofer.de

<sup>6</sup> DVGW-Technologiezentrum Wasser (TZW), Außenstelle Dresden, Wasserwerkstraße 2 tobias.martin@tzw.de

<sup>7</sup> DVGW-Technologiezentrum Wasser (TZW), Außenstelle Dresden, Wasserwerkstraße 2 martin.wagner@tzw.de

<sup>8</sup> Karlsruher Institut für Technologie (KIT), Institut für Angewandte Geowissenschaften, Abteilung Hydrogeologie, Kaiserstr. 12, 76131 Karlsruhe andreas.wunsch@kit.edu

<sup>9</sup> DVGW-Technologiezentrum Wasser (TZW), Karlsruher Straße 84, 76139 Karlsruhe Thilo.Fischer@tzw.de

Grundwasservorkommen Pflanzen mit Wasser, bilden wertvolle Feuchtbiotope und speisen über Quellen sowie Basisabfluss Bäche und Flüsse. Die Überwachung der Grundwasserbeschaffenheit im Rahmen der europäischen Wasserrahmenrichtlinie (WRRL) hat gezeigt, dass der gute Zustand des Grundwassers vielerorts gefährdet ist. Vor allem die diffusen Einträge von Stickstoff aus der Landwirtschaft stellen hierbei ein großes Problem dar. In dieser Arbeit soll eine übergreifende Vision zur Lösung der Problematik vorgestellt werden und wie dabei KI innerhalb eines Gesamtsystems einen Beitrag für diese Fragestellung liefern kann.

### Nitratkonzentrationen Monatsmittelwerte August 2019



Abb. 1: Beispiel für aktuelles Nitratmonitoring in einer der Pilotregionen. Quelle: Zweckverband Landeswasserversorgung Baden-Württemberg

Die Verteilung von Nitrat im Grundwasser ist das Ergebnis eines komplexen Zusammenspiels vieler Einflussfaktoren, darunter neben dem Eintrag, der zum Großteil von der Landnutzung bestimmt wird, meteorologische Faktoren (Niederschlag, Verdunstung), chemisch-physikalische Eigenschaften der grundwasserüberdeckenden Schichten sowie Transport- und Reaktionsprozesse im Grundwasser selbst. Die Nitrat-Verteilung im Grundwasser stellt daher ein hochkomplexes, räumlich und zeitlich stark variables Muster dar, das regional und insbesondere vertikal eine ausgeprägte hydro-geochemische Differenzierung aufweist. Abb.1 zeigt ein Beispiel für die Situation und Ergebnisvisualisierung. Obwohl Eintrag, Transport und Ausbreitung von Nitrat im Grundwasser weitgehend bekannten chemisch-physikalischen Prozessen folgen, so ist eine Modellierung mit analytischen oder numerischen Modellen im gegebenen Maßstab auf Landes- oder Bundesebene in einer sinn-

vollen räumlichen Auflösung bisher nicht möglich. Räumliche und zeitliche Beurteilungen und damit verbundene Handlungsempfehlungen oder Maßnahmen, wie beispielsweise die novellierte Düngemittelverordnung, basieren daher aktuell weitgehend auf der Regionalisierung von punktuellen Messdaten bzw. der Auswertung von zeitlichen Trends. Gerade die Regionalisierung mit herkömmlichen Interpolationsverfahren bzw. die Beurteilung des Zustandes auf Basis der Grundwasserkörper ist auf Grund der hohen räumlichen Variabilität nur bedingt geeignet. Gleichzeitig ist hier die bisherige Datengrundlage und -integration außerhalb spezieller Pilotregionen häufig dünn. KI-Anwendungen, insbesondere Künstliche Neuronale Netze bzw. Deep Learning Verfahren, wie sie in anderen Disziplinen häufig zur Mustererkennung eingesetzt werden, bieten hier einen deutlichen Mehrwert gegenüber den etablierten Verfahren. Als datenbasiertes Modell sind sie in der Lage, komplexe Zusammenhänge aus einer großen Datenmenge zu extrahieren und zu übertragen. Gleichzeitig können KI-Anwendungen auch so trainiert werden, dass sich dadurch Generalisierungen für weitere Regionen ableiten lassen, was mit bisherigen Modellen nicht möglich ist.

## 2 Vision des Gesamtsystems

Unsere Vision ist es, ein übergreifendes, räumliches Entscheidungsunterstützungssystem (SDSS) für Nitrat-Monitoring zu entwickeln. Dieses System soll dabei innovative KI-Methoden für die Datenanalyse, die Datenintegration, die Visualisierung und die übergreifende Entscheidungsunterstützung, welche über konkrete Instanzierungen umgesetzt werden, sowie begleitende Verfahren und Prozessschritte beinhalten. Dies verfolgt das übergeordnete Ziel einer verbesserten räumlichen und zeitlichen Vorhersage von Nitrat im Grundwasser und darauf aufbauende intelligente Entscheidungsunterstützungssysteme, welche zum Beispiel durch Szenarien-Rechnungen zur Optimierung von Grundwasserschutzprogrammen einen Beitrag zur effizienten und nachhaltigen Nitrat-Reduzierung leisten können. Dabei werden jedoch nicht nur die Aspekte der KI oder reinen Umweltinformatik betrachtet sondern die Definition eines SDSS aus [JFP14] zu Grunde gelegt, wonach sich dieses aus der Kombination zweier Disziplinen zusammensetzt. Dies ist zum einen das Operation Research, gekennzeichnet nach dem bekannten drei Phasen Modell nach [Si60], und zum anderen die Geoinformatik mit Schwerpunkten in der multikriteriellen Evaluierung räumlich expliziter Modelle und der räumlichen Optimierung. Wir erweitern dies in dem geplanten System um die Komponenten der intelligenten Datenintegration unterschiedlichster Formate sowie die KI-basierte Analyse innerhalb des Systems.

Im Gegensatz zu [Jo17] verfolgt unser Ansatz die Vision, dass nur das Zusammenspiel der verschiedenen Akteure und Domänen einen Mehrwert bringt. Eine alleinige Anwendung von KI ohne Domänenwissen und Diskussion mit dem Endanwender bleibt im besten Fall ungenutzt und führt im schlimmsten Fall zu falschen Handlungsempfehlungen. Nur durch die Kooperation und Interaktion von Akteuren in einem interdisziplinärem Umfeld lassen sich tragfähige Lösungen für die Praxis entwickeln.

### **3 Übersicht relevanter Entwicklungen für den Einsatz von KI in der Umweltinformatik**

Für die Einordnung der geplanten Arbeiten und Innovationen ist ein Blick jenseits des Themenfeldes Grundwassers hin zur gesamten Umweltinformatik hilfreich. Der KI-Einsatz in der Umweltinformatik in den letzten Jahren auf mehrere parallele Entwicklungen zurückführen, für welche im Folgenden ein kurzer, stichprobenartiger Überblick gegeben werden soll. Als entscheidender Einflussfaktor lässt sich dabei der zunehmende Reifegrad der KI-Forschung betrachten, der diese stärker in den gesellschaftlichen Fokus rückt. Im letzten Jahrzehnt hat sich insbesondere im Bereich der visuellen und sprachlichen Analyse eine starke Verbesserung der KI-Anwendungen ergeben, welche innovative Algorithmen und Ansätze hervorgebracht haben. Dies hat zu einem starken Interesse in Forschung, Wirtschaft und Politik geführt, diese Fortschritte in weitere Domänen und Anwendungsfälle zu überführen, welches im Bereich der Umweltwissenschaft und Umweltinformatik in Deutschland beispielsweise vom UBA über deren Forschungsstrategiebericht [Je19] oder international über Microsoft und deren Chief Environment Scientist Lucas Joppa in seinem NATURE Beitrag [Jo17] vorangetrieben wird. In [Jo17] wird das Anwendungsfeld der Umweltprobleme für die Informatik auf zwei Kernfragen fokussiert: „Wie kann KI bei der Lösung helfen?“ und „Wie kann die Anwendung von KI eingebracht werden?“.

Neben den Umweltwissenschaften und der Umweltinformatik lassen sich zusätzlich auch aktuelle Entwicklung in der angrenzenden Disziplin der Geoinformatik betrachten. Durch den gleichartigen Schwerpunkt auf Phänomenen mit einem starken geographischen Schwerpunkt lassen sich oft Entwicklungen aus dieser Disziplin auf die Umweltinformatik direkter anwenden als aus der klassischen Informatik. [Vo18] und [Br20] haben die Entwicklungen der KI-Forschung aus dieser Disziplin genauer betrachtet. [Vo18] beschreiben dabei den Einsatz von GeoAI für Umweltepidemiologie, bei der vor allem das Ziel verfolgt wird, eine Verbesserung der Modellierung und Beurteilung von Umweltprozessen durch den Einsatz von KI-Methoden zu erhalten. Dies kann z.B. die Exposition von Umweltbelastungen oder anderer Faktoren sein. Dadurch kann auch das Verständnis über die Zusammenhänge verbessert werden. Ein von der Informatik getriebenes Beispiel hierfür ist in [Bu17] zu finden, wo die Luftqualität feingranular erfasst und analysiert werden soll, um damit den lokalen Behörden einen besseren Überblick zu liefern. In [Br18] wurden KI-Methoden wie genetische Algorithmen für die Verbesserung der Datenqualität eingesetzt. In [Br20] wird vor allem auf die Bedürfnisse und Möglichkeiten, die sich durch und für Geodaten durch die neuesten Entwicklungen ergeben, wie das Internet der Dinge, linked-Data wie OpenStreetMap und neue, geo-temporale Datenmanagement Techniken, eingegangen. Daneben bietet der Workshop GeoAI der ACM SIG Spatial, z.B. [Ga20] eine weitere Übersicht über die aktuellen Entwicklungen der Geoinformatik.

Zuletzt haben sich weitere grundlegende Möglichkeiten in dem Betrieb von Komponenten und deren Einsatz in einem Gesamtsystem ergeben. Das bekannteste Stichwort hierbei ist Edge Computing, wodurch komplexe Berechnungen direkt an der Datenquelle durchgeführt

werden und dadurch dem Übertragungsnetz zugeführt werden können. Beispielfähig hierfür ist TinyML [PW19], welches die Ausführung komplexer KI-Modelle auf Arduino-basierter Hardware zulässt und dann statt der Rohdaten nur die Ergebnisse weiterleitet. Gleichzeitig erlauben Ansätze aus dem Stream Processing und dortige Architekturen wie z.B. beschrieben in [Wi16] und [Wi20], dies auch in komplexen System umzusetzen.

## 4 KI-Anwendungen im Bereich Grundwasser

KI-Anwendungen im Bereich Grundwasser sind bisher verglichen mit anderen Disziplinen eher selten und beschränken sich weitgehend auf reine Forschungsergebnisse. In den letzten Jahren werden jedoch auch hier verstärkt Methoden des Machine Learning erfolgreich eingesetzt. Der Ansatz einer räumlichen Nitratvorhersage mit Klassifikatoren aus dem Bereich des maschinellen Lernens wurde bereits mehrfach erfolgreich von verschiedenen Autoren an Testgebieten weltweit und auch in Deutschland ([Li06]; [KBB19], u.a.) angewendet. Klassifikatoren, die hierbei zum Einsatz kommen sind typischerweise Random Forests (RF) ([An12]; [KBB19]; [NFL15]; [Ra19]; [Ro14]; [Ro18]), Künstliche Neuronale Netze (i.d.R. einfache Feed Forward Netze) ([AK05]; [Ge09]; [HM14]; [Li06]; [NFL15]) und Boosted Regression Trees (BRT) ([KBB19]; [NFL15]; [Ra17]; [Sa18]), aber auch Support Vector Machines (SVM) ([Ra19]; [Sa18]) und Bayesische Netzwerke (BN) ([NFL15]). Auch in der zeitlichen Vorhersage von Grundwasserständen zeigen KI-Methoden gute Ergebnisse (z.B. [WLB18]). Einen guten Überblick von KI-Anwendungen im Grundwasserbereich geben die beiden Reviews von [MD00] und [REN19].

Besonders vielversprechend für den Ansatz einer räumlichen und zeitlichen Modellierung von Schadstoffen im Grundwasser erscheinen Convolutional Neural Networks (CNN). Sie stellen eine Sonderform von Multi-Layer-Perceptrons dar und gelten als State-of-the-Art-Methode für zahlreiche Anwendungen im Bereich der Klassifizierung. Diese Deep Learning-basierten Netze eignen sich vor allem zur Verarbeitung von Daten mit Raumbezug und werden daher äußerst erfolgreich zur Bilderkennung und -verarbeitung angewandt. CNN wurden im Umweltbereich bereits erfolgreich z.B. zur Klassifizierung von Hyperspektral-Daten in der Fernerkundung ([Ma15]; [YJX17]), zur Vorhersage von Niederschlag ([Xi15]), zur Identifikation von Quellen der Grundwasserbelastung ([Mo19]) und zur Vorhersage von Grundwasserständen ([As17]) eingesetzt.

## 5 Geplante KI-Methodik

Die räumliche Vorhersage einer Nitratbelastung mit Hilfe von Methoden des Maschinellen Lernens ist typischerweise über den Aufbau eines Klassifikators oder einer Regression möglich. Hierfür werden räumlich flächendeckende historische und aktuelle Datensätze herangezogen (z.B. CORINE-Landnutzungsdaten, Niederschlagsrasterdaten, Bodenart, Grundwasserneubildung, Flurabstand etc.), die Rückschlüsse auf die Nitratexposition und

Vulnerabilität des Untersuchungsgebietes zulassen. Anhand von punktuell verfügbaren Messwerten von Nitrat wird der Klassifikator trainiert und ist anschließend in der Lage, auch über Gebiete, für die keine punktuellen Schadstoffinformationen zur Verfügung stehen, Aussagen zu treffen. Da es sich bei Nitrat um einen äußerst redox-sensitiven Parameter handelt, welcher abhängig von den hydrochemischen Bedingungen in unterschiedlichen Spezies vorliegt (De-/Nitrifikation), werden in die Analyse entsprechende zusätzlich verfügbare Parameter wie Redox-Potential, elektrische Leitfähigkeit und pH-Wert mit einbezogen.

CNN sind State-of-the-Art Deep Learning (DL) basierte Netze zur Verarbeitung von Daten mit Raumbezug. Im Projekt werden daher 3D-CNNs für die räumliche (2D) und zeitliche (dritte Dimension) Vorhersage des Nitratgehaltes in Grundwasser eingesetzt. Üblicherweise sind DL-Ansätze besser für sehr große und möglichst vollständige Datensätze geeignet, Nitratmessung liegen jedoch vor allem im Vergleich zu Punkten ohne Nitratmesswerte verhältnismäßig spärlich vor. Hierfür gibt es neuere Ansätze wie Sparse 3D CNNs, deren Einsatz geprüft wird. Zur verbesserten Vorhersage der zeitlichen Nitratbelastung soll zudem eine Nachschaltung eines LSTM-Netzwerkes (Long-Short Term Memory) an das CNN sowie der Einsatz von Temporal Convolutional Netzwerken (TCN) getestet werden. Neben dem neuartigen CNN-basierten Ansatz wird auch der Aufbau und die Anwendung des zuvor beschriebenen, klassischerweise gewählten Ansatzes eines KI-Klassifikators umgesetzt und die Leistungsfähigkeit beider Ansätze verglichen und evaluiert, um optimale Vorhersageergebnisse zu erzielen.

## **6 Nutzung offener Standards für die Integration von Sensor- oder Messdaten**

Für die Integration von KI-Methoden in bestehende Systeme ist die Anbindung verschiedener heterogener Datenquellen essentiell. Es wird ein intelligentes Datenmanagement benötigt, welches existierende und neue Datenquellen harmonisiert und in ein übergreifendes System zur Auswertung von Daten integrieren kann. Dabei sollen offene neue Standards eingesetzt werden. Die dadurch entstehende Kombination des harmonisierten Datenzugriffs über offene Schnittstellen und die Nutzung dieser Methoden für die KI-Integration eröffnet bisher nicht realisierte Möglichkeiten der systemübergreifenden Datenauswertung. Im Bereich des Nitrat-Monitoring erfolgt eine länderübergreifende Detail-Auswertung oder Einbeziehung aller Daten z.B. von Wasserversorgern und auf Basis von offenen Standards bisher nicht.

Für die Beschreibung von Sensoren mit Raumbezug spielt das OGC als eines der wichtigsten internationalen Standardisierungsgremien eine wesentliche Rolle, deswegen werden im Projekt die offenen Standards OGC analysiert und für das intelligente Datenmanagement getestet.

Mit dem Internet of Things haben Geodienste für die Modellierung von Sensordaten an Bedeutung gewonnen. Deswegen wurde von der OGC im Gegensatz zu bisherigen Sensordaten-Standards mit der SensorThings API ein leichtgewichtiger neuer Ansatz für

die Anbindung und Datenhaltung entwickelt, der auf langjährig bewährte Konzepte mit zeit- und georeferenzierten Sensordaten zurückgreift [LHK15]. Die SensorThings API ist grundsätzlich sowohl für den direkten Zugriff auf Sensordaten als auch für die Anbindung von bestehenden Datenbanken geeignet. Die SensorThings API steht nun zusammen mit dem Feature Service (OGC API Features) im Fokus des JRC für die Eignung der Veröffentlichung von räumlichen Daten. Im Projekt wird die Einbindung von Schadstoffdaten langjährig bestehender Quellsysteme über die Open Source Implementierung FROST @getestet werden [IO].

Ein weiterer für das Projekt wichtiger Standard des OGC ist GroundWaterML, dessen Grundwassermodell für die Zusammenführung von Grundwasserdaten verschiedener Systeme Potential hat, bisher aber in Deutschland nicht verwendet wird. Im Projekt soll untersucht werden, inwieweit eine Harmonisierung des Datenmodells von Grundwasserdaten über diesen Standard möglich und sinnvoll ist.

Essentiell für das intelligente Datenmanagement ist außerdem eine geeignete Integration von KI-Modulen in das System. Hierfür sollen verschiedene Möglichkeiten analysiert und getestet werden. Beispiele hierfür sind die Erweiterung Task Core der Sensor Things API [LK17] oder der Einsatz von ML4P-Konnektoren, die im industriellen Bereich für die Einführung von KI-Methoden verwendet werden können.

## 7 Entscheidungsunterstützung

Die Optimierung von Grundwasserschutzprogrammen und der dazugehörigen Messkampagnen basiert derzeit auf geeigneten konzeptionellen und zum Teil numerischen Modellen, welche in der Lage sind, Ursache-Wirkungs-Zusammenhänge zwischen der Umsetzung konkreter Maßnahmen wie der Verringerung der Nitrat-Einträge und der Verminderung der gemessenen Nitrat-Konzentrationen im Grundwasser zu quantifizieren. Solche Modelle müssen die zu Grunde liegenden hydrogeologischen Prozesse (u.a. Stickstoffumsatz in der Bodenzone, Nitratauswaschung mit dem Sickerwasser, Stofftransport und Stoffumsatz im Grundwasserleiter) in Abhängigkeit der Komplexität der naturräumlichen Gegebenheiten abbilden [We15]. KI-basierte, datengetriebene Ansätze erscheinen hier weitaus besser geeignet, werden jedoch bisher nicht eingesetzt. Diese bieten jedoch Vorteile für die Entscheidungsunterstützung, was für die finale Nutzung und Verwertung essentiell ist.

Ergebnisse der im Projekt erarbeiteten KI-Methoden müssen von Entscheidern analysiert werden können. Aus den Ergebnissen sollen darüber hinaus geeignete Maßnahmen abgeleitet werden können. Beispiele sind Vorgaben oder Empfehlungen hinsichtlich dynamischen Düngemanagements, Schutzzonenausweisung oder Wasseraufbereitung. Konkret können Maßnahmenggebiete (z.B. besonders gefährdete Gebiete mit geringem Nitratabbauvermögen im Grundwasserleiter) ausgewiesen und priorisiert werden

Für die Erreichung dieser Ziele benötigen die Entscheider eine geeignete Entscheidungsunterstützung. Hier ist zwischen der reinen Visualisierung und der Methodik der Optimierung

zu unterscheiden. Die Visualisierung wird dabei meist über Webplattformen und Dashboards gelöst. [Su13] hat den Einsatz von Dashboards im Rahmen einer Smart City Anwendung für die Integration verschiedener Sensordaten untersucht. In der Optimierung stehen hierbei weitere Verfahren zur Verfügung, wie z.B. die Standortplanung der Messstellen oder die Wissensfusion, die aus den erzielten Erkenntnissen Handlungsempfehlungen generieren. Für die Ableitung von geeigneten Handlungsanweisungen ist sowohl die Modellierung der Situation über Ontologien hilfreich, als auch die Schaffung von Simulationsmöglichkeiten für die Analyse verschiedener Szenarien. Ein Beispiel für die Aufgabe, verschiedene Sensordatenquellen zu fusionieren und für die Entscheidungsunterstützung entsprechend zu kombinieren, wird in „The sensor decision chain in crisis management“ von Moßgraber beschrieben [Mo18]

## **8 Ausblick**

Im Rahmen des Projekts Nitrat-Monitoring 4.0 – Intelligente Systeme zur nachhaltigen Reduzierung von Nitrat im Grundwasser (NiMo 4.0) wird der Transfer von innovativen Lösungsansätzen von KI-Anwendungen im Grundwasser-Bereich von der universitären und institutionellen Forschung in die industrielle, anwendungsnahe Forschung und Praxis vorangetrieben. Übergeordnetes Ziel ist eine verbesserte räumliche und zeitliche Vorhersage von Nitrat im Grundwasser und darauf aufbauende intelligente Entscheidungsunterstützungssysteme, welche z.B. durch Szenarienrechnungen zur Optimierung von Grundwasserschutzprogrammen und damit zur effizienten und nachhaltigen Nitrat-Reduzierung beitragen. Die betrachteten Lösungsansätze und Methoden werden anhand realer Daten aus zwei wasserwirtschaftlich bedeutenden Pilotregionen entwickelt, demonstriert und validiert. Diese weisen hinlänglich große hydrogeologische Variabilität auf, um hieraus Aussagen zur Allgemeingültigkeit und Übertragbarkeit der entwickelten Lösungen treffen zu können. Um die resultierenden, wachsenden Echtzeit-Datenströme effizient überwachen zu können, werden intelligente Monitoring-Algorithmen entwickelt, die beispielsweise automatisierte Datenplausibilisierungen, Auffälligkeitserkennung oder Frühwarnmechanismen realisieren. Schließlich ermöglicht die räumliche Vorhersage in Verbindung mit modernen Methoden der Geostatistik und des Operations-Research auch Empfehlungen zur Messnetzoptimierung. Final werden dabei diese Informationen auch an den Endanwender so vermittelt, dass dieser damit agieren kann und so ein Beitrag für die Praxis geschaffen wird.

## **Acknowledgement**

Die Vision, die in diesem Paper entwickelt wurden, sollen im Projekt Nitrat-Monitoring 4.0 - Intelligente Systeme zur nachhaltigen Reduzierung von Nitrat im Grundwasser (NiMo 4.0), gefördert vom BMU unter Förderkennzeichen FKZ 67KI2048, umgesetzt werden. Informationen zum Projekt werden sich unter <https://nimo-projekt.de/> finden.



## Literaturverzeichnis

- [AK05] Almasri, Mohammad N; Kaluarachchi, Jagath J: Modular neural networks to predict the nitrate distribution in ground water using the on-ground nitrogen loading and recharge data. *Environmental Modelling & Software*, 20(7):851–871, 2005.
- [An12] Anning, David W; Paul, Angela P; McKinney, Tim S; Huntington, Jena M; Bexfield, Laura M; Thiros, Susan A: Predicted nitrate and arsenic concentrations in basin-fill aquifers of the southwestern United States. US Department of the Interior, US Geological Survey, 2012.
- [As17] Assem, Haytham; Ghariba, Salem; Makrai, Gabor; Johnston, Paul; Gill, Laurence; Pilla, Francesco: Urban water flow and water level prediction based on deep learning. In: *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*. Springer, S. 317–329, 2017.
- [Br18] Bruns, Julian; Riesterer, Johannes; Wang, Bowen; Riedel, Till; Beigl, Michael: Automated Quality Assessment of (Citizen) Weather Stations. *GI\_Forum* 2018., 6:65–81, 2018.
- [Br20] Breunig, Martin; Bradley, Patrick Erik; Jahn, Markus; Kuper, Paul; Mazroob, Nima; Rösch, Norbert; Al-Doori, Mulhim; Stefanakis, Emmanuel; Jadidi, Mojgan: Geospatial Data Management Research: Progress and Future Directions. *ISPRS International Journal of Geo-Information*, 9(2):95, 2020.
- [Bu16] Bundesamt, Statistisches: , Tabellen zu Wassergewinnung: Bundesländer, Jahre, Wasserarten. <https://www-genesis.destatis.de/genesis/online/link/tabelleErgebnis/32211-0002>, 2016. Accessed: 2020-07-13.
- [Bu17] Budde, Matthias; Riedel, Till; Beigl, Michael; Schäfer, Klaus; Emeis, Stefan; Cyrus, Josef; Schnelle-Kreis, Jürgen; Philipp, Andreas; Ziegler, Volker; Grimm, Hans et al.: SmartAQnet: remote and in-situ sensing of urban air quality. In: *Remote Sensing of Clouds and the Atmosphere XXII*. Jgg. 10424. International Society for Optics and Photonics, S. 104240C, 2017.
- [Ga20] Gao, Song; Newsam, Shawn; Zhao, Liang; Lunga, Dalton; Hu, Yingjie; Martins, Bruno; Zhou, Xun; Chen, Feng: GeoAI 2019 workshop report: The 3rd ACM SIGSPATIAL International Workshop on GeoAI: AI for Geographic Knowledge Discovery: Seattle, WA, USA-November 5, 2019. *SIGSPATIAL Special*, 11(3):23–24, 2020.
- [Ge09] Gemtzi, A; Petalas, C; Pisinaras, V; Tsihrintzis, VA: Spatial prediction of nitrate pollution in groundwaters using neural networks and GIS: An application to South Rhodope aquifer (Thrace, Greece). *Hydrological Processes: An International Journal*, 23(3):372–383, 2009.
- [HM14] Hosseini, Seiyed Mossa; Mahjouri, Najmeh: Developing a fuzzy neural network-based support vector regression (FNN-SVR) for regionalizing nitrate concentration in groundwater. *Environmental monitoring and assessment*, 186(6):3685–3699, 2014.
- [IO] IOSB, Fraunhofer: , FROST-Server: Der: Fraunhofer Open Source SensorThingsAPI Server:.. <https://www.iosb.fraunhofer.de/servlet/is/80113/>. Accessed: 2020-07-13.
- [Je19] Jetzke, Tobias; Richter, Stephan; Ferdinand, Jan-Peter; Schaat, Samer: Künstliche Intelligenz im Umweltbereich. Umweltbundesamt, 2019.
- [JFP14] Jankowski, Piotr; Fraley, Grant; Pebesma, Edzer: An exploratory approach to spatial decision support. *Computers, Environment and Urban Systems*, 45:101–113, 2014.

- [Jo17] Joppa, Lucas N.: The case for technology investments in the environment, 2017.
- [KBB19] Knoll, Lukas; Breuer, Lutz; Bach, Martin: Large scale prediction of groundwater nitrate concentrations from spatial data using machine learning. *Science of the total environment*, 668:1317–1327, 2019.
- [LHK15] Liang, S; Huang, CY; Khalafbeigi, T.: SensorThings API Part 1: Sensing, OGC Doc. No. 15-078r6, 2015.
- [Li06] Liesch, Tanja: Ermittlung der Grundwassergefährdung mit Hilfe künstlicher neuronaler Netze. Lehrstuhl für Angewandte Geologie der Univ., 2006.
- [LK17] Liang, S; Khalafbeigi, T.: SensorThings API Part 2: Tasking Core, OGC Doc. No. 17-079r1, 2017.
- [Ma15] Makantasis, Konstantinos; Karantzalos, Konstantinos; Doulamis, Anastasios; Doulamis, Nikolaos: Deep supervised learning for hyperspectral data classification through convolutional neural networks. In: 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). IEEE, S. 4959–4962, 2015.
- [MD00] Maier, Holger R; Dandy, Graeme C: Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental modelling & software*, 15(1):101–124, 2000.
- [Mo18] Moßgraber, Jürgen; Hilbring, Désirée; van der Schaaf, Hylke; Hertweck, Philipp; Kontopoulos, Efstratios; Mitzias, Panagiotis; Kompatsiaris, Ioannis; Vrochidis, Stefanos; Karakostas, Anastasios: The sensor to decision chain in crisis management. In: ISCRAM. 2018.
- [Mo19] Mo, Shaoxing; Zabarar, Nicholas; Shi, Xiaoping; Wu, Jichun: Deep autoregressive neural networks for high-dimensional inverse problems in groundwater contaminant source identification. *Water Resources Research*, 55(5):3856–3881, 2019.
- [NFL15] Nolan, Bernard T.; Fioren, Michael N.; Lorenz, David L.: A statistical learning framework for groundwater nitrate models of the Central Valley, California, USA. *Journal of Hydrology*, 531:902 – 911, 2015.
- [PW19] Pete Warden, Daniel Situnayake: TinyML. O’Reilly Media, Inc., 2019.
- [Ra17] Ransom, Katherine M.; Nolan, Bernard T.; A. Traum, Jonathan; Faunt, Claudia C.; Bell, Andrew M.; Gronberg, Jo Ann M.; Wheeler, David C.; Z. Rosecrans, Celia; Jurgens, Bryant; Schwarz, Gregory E.; Belitz, Kenneth; M. Eberts, Sandra; Kourakos, George; Harter, Thomas: A hybrid machine learning model to predict and visualize nitrate concentration throughout the Central Valley aquifer, California, USA. *Science of The Total Environment*, 601-602:1160 – 1172, 2017.
- [Ra19] Rahmati, Omid; Choubin, Bahram; Fathabadi, Abolhasan; Coulon, Frederic; Soltani, Elinaz; Shahabi, Himan; Mollaeifar, Eisa; Tiefenbacher, John; Cipullo, Sabrina; Ahmad, Baharin Bin; Tien Bui, Dieu: Predicting uncertainty of machine learning models for modelling nitrate pollution of groundwater using quantile regression and UNEEC methods. *Science of The Total Environment*, 688:855 – 866, 2019.
- [REN19] Rajaei, Taher; Ebrahimi, Hadi; Nourani, Vahid: A review of the artificial intelligence methods in groundwater level modeling. *Journal of Hydrology*, 572:336–351, Mai 2019.

- 
- [Ro14] Rodriguez-Galiano, Victor; Mendes, Maria Paula; Garcia-Soldado, Maria Jose; Chica-Olmo, Mario; Ribeiro, Luis: Predictive modeling of groundwater nitrate pollution using Random Forest and multisource variables related to intrinsic and specific vulnerability: A case study in an agricultural setting (Southern Spain). *Science of The Total Environment*, 476-477:189 – 206, 2014.
- [Ro18] Rodriguez-Galiano, V.F.; Luque-Espinar, J.A.; Chica-Olmo, M.; Mendes, M.P.: Feature selection approaches for predictive modelling of groundwater nitrate pollution: An evaluation of filters, embedded and wrapper methods. *Science of The Total Environment*, 624:661 – 672, 2018.
- [Sa18] Sajedi-Hosseini, Farzaneh; Malekian, Arash; Choubin, Bahram; Rahmati, Omid; Cipullo, Sabrina; Coulon, Frederic; Pradhan, Biswajeet: A novel machine learning-based approach for the risk assessment of nitrate groundwater contamination. *Science of The Total Environment*, 644:954 – 962, 2018.
- [Si60] Simon, Herbert A: *The new science of management decision*. 1960.
- [Su13] Suakanto, Sinung; Supangkat, Suhono H; Saragih, Roberd et al.: Smart city dashboard for integrating various data of sensor networks. In: *International Conference on ICT for Smart Society*. IEEE, S. 1–5, 2013.
- [Vo18] VoPham, Trang; Hart, Jaime E; Laden, Francine; Chiang, Yao-Yi: Emerging trends in geospatial artificial intelligence (geoAI): potential applications for environmental epidemiology. *Environmental Health*, 17(1):40, 2018.
- [We15] Weber, Frank-Andreas; Bergmann, Axel; Kämpf, Markus; Spinola, Anette; Gerdes, Heiko; Kludt, Christoph; Schüth, Christoph; Allendorf, Arnd; Mikat, Hermann; Berthold, Georg: Quantifizierung des Nitratabbauvermögens in den Grundwasserkörpern des Hessischen Rieds und Lokalisierung von Risikogebieten. 09 2015.
- [Wi16] Wiener, Patrick; Stein, Manuel; Seebacher, Daniel; Bruns, Julian; Frank, Matthias; Simko, Viliam; Zander, Stefan; Nimis, Jens: Biggis: a continuous refinement approach to master heterogeneity and uncertainty in spatio-temporal big data (vision paper). In: *Proceedings of the 24th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*. S. 1–4, 2016.
- [Wi20] Wiener, Patrick; Zehnder, Philipp; Heyden, Marco; Philipp, Patrick; Riemer, Dominik: Fogsy: Towards Holistic Industrial AI Management in Fog and Edge Environments. *KuVS-Fachgespräch Fog Computing 2020*, S. 16, 2020.
- [WLB18] Wunsch, Andreas; Liesch, Tanja; Broda, Stefan: Forecasting groundwater levels using nonlinear autoregressive networks with exogenous input (NARX). *Journal of Hydrology*, 567:743–758, 2018.
- [Xi15] Xingjian, SHI; Chen, Zhouong; Wang, Hao; Yeung, Dit-Yan; Wong, Wai-Kin; Woo, Wang-chun: Convolutional LSTM network: A machine learning approach for precipitation nowcasting. In: *Advances in neural information processing systems*. S. 802–810, 2015.
- [YJX17] Yu, Shiqi; Jia, Sen; Xu, Chunyan: Convolutional neural networks for hyperspectral image classification. *Neurocomputing*, 219:88–98, 2017.