

KI-basierte Simulation des Einflusses von Flächennutzungsänderungen auf die städtische Luftqualität

Herold, Hendrik; Meiers, Thomas; Reuschenberg, David; Petry, Lisanne

Veröffentlichungsversion / Published Version

Sammelwerksbeitrag / collection article

Empfohlene Zitierung / Suggested Citation:

Herold, H., Meiers, T., Reuschenberg, D., & Petry, L. (2022). KI-basierte Simulation des Einflusses von Flächennutzungsänderungen auf die städtische Luftqualität. In *Flächennutzungsmonitoring XIV: Beiträge zu Flächenmanagement, Daten, Methoden und Analysen* (S. 277-284). Berlin: Rhombos-Verlag. <https://doi.org/10.26084/14dfns-p028>

Nutzungsbedingungen:

Dieser Text wird unter einer CC BY Lizenz (Namensnennung) zur Verfügung gestellt. Nähere Auskünfte zu den CC-Lizenzen finden Sie hier:
<https://creativecommons.org/licenses/by/4.0/deed.de>

Terms of use:

This document is made available under a CC BY Licence (Attribution). For more information see:
<https://creativecommons.org/licenses/by/4.0>



Flächennutzungsmonitoring XIV

Beiträge zu Flächenmanagement,
Daten, Methoden und Analysen

IÖR Schriften Band 80 · 2022

ISBN: 978-3-944101-80-4

KI-basierte Simulation des Einflusses von Flächennutzungsänderungen auf die städtische Luftqualität

*Hendrik Herold, Thomas Meiers, David Reuschenberg,
Lisanne Petry*

Herold, H.; Meiers, T.; Reuschenberg, D.; Petry, L. (2022):
KI-basierte Simulation des Einflusses von Flächennutzungs-
änderungen auf die städtische Luftqualität. In: Meinel, G.;
Krüger, T.; Behnisch, M.; Ehrhardt, D. (Hrsg.): Flächennut-
zungsmonitoring XIV. Beiträge zu Flächenmanagement,
Daten, Methoden und Analysen. Berlin: Rhombos, IÖR
Schriften 80, S. 277-284.

DOI: <https://doi.org/10.26084/14dfns-p028>

KI-basierte Simulation des Einflusses von Flächennutzungsänderungen auf die städtische Luftqualität

Hendrik Herold, Thomas Meiers, David Reuschenberg, Lisanne Petry

Zusammenfassung

Die Luftqualität hat sich in vielen europäischen Städten in den letzten Jahrzehnten verbessert. Doch auch wenn die derzeit noch gültigen gesetzlichen Grenzwerte zunehmend eingehalten werden, stellen die 2021 aktualisierten, deutlich strengeren Leitlinien der WHO zur Luftreinhaltung neue Herausforderungen dar. Neue Daten des Copernicus-Programms sowie innovative Modellierungsansätze ermöglichen hochaufgelöste Analysen der raumzeitlichen Verteilung von Luftschadstoffen. Mit Hilfe von Methoden der Künstlichen Intelligenz (KI) können die amtlichen, jedoch nur punktuell gemessenen Luftschadstoffdaten mit aktuellen Satelliten-, Verkehrs-, Wetter- und Flächennutzungsdaten so kombiniert und analysiert werden, dass flächenhafte Prognosen der städtischen Luftqualität für die nächsten Tage möglich werden. Diese flächigen Vorhersagen können Kommunen u. a. bei der Planung von kurzfristigen Gegenmaßnahmen wie der temporären Verkehrsbeeinflussung unterstützen. Des Weiteren kann ein auf Basis von aktuellen Daten trainiertes KI-Modell auf eine durch Planungsvarianten veränderte Flächennutzung angewendet werden. Damit lassen sich – ceteris paribus – vorab die Auswirkungen verschiedener Planungsvarianten auf die lokale Luftqualität simulieren. In diesem Beitrag werden die Möglichkeiten und Ergebnisse derartiger KI-basierter Simulationen anhand realer Planungsbeispiele aufgezeigt.

Schlagwörter: Simulation, Luftqualität, Flächennutzung, Künstliche Intelligenz, Sentinel 5p

1 Einführung

Luftverschmutzung stellt nach wie vor eines der bedeutendsten Umweltprobleme weltweit in Städten dar. Sie beeinträchtigt nicht nur die menschliche Gesundheit, sondern auch die biologische Vielfalt sowie funktionierende terrestrische und aquatische Ökosysteme sind durch Luftschadstoffe gefährdet. Zu den Hauptverursachern der anthropogenen Luftverschmutzung zählen Verkehr, Industrie, Landwirtschaft und Verbrennungsprozesse (Petry et al. 2020). In den europäischen Städten hat sich die Luftqualität in den letzten Jahren kontinuierlich verbessert (EEA 2020). Auch wenn die bisherigen gesetzlichen Grenzwerte zunehmend eingehalten werden, stellen die 2021 veröffentlichten, sehr viel strengeren Luftqualitätsrichtlinien (Air Quality Guidelines) der Weltgesundheitsorganisation (WHO) viele Städte vor neue Herausforderungen (WHO 2021).

Um Kommunen und Behörden bei der Bewältigung dieser Herausforderungen zu unterstützen und bessere Entscheidungsgrundlagen zur Verfügung zu stellen, wurden im Rahmen des vom Bund geförderten Projektes „Satellitenbasiertes System zur Anzeige, Prognose und Simulation von Luftschadstoffen für eine nachhaltige Stadt- und Regionalentwicklung“ (SAUBER)¹ die Potenziale von neuen Daten des Copernicus-Programms (insbesondere des Satelliten Sentinel 5p) sowie innovativer KI-basierter Modellierungsansätze (Deep Learning) untersucht. Darauf aufbauend wurde gemeinsam mit Praxispartnern ein Verfahren entwickelt, das automatisiert hochaufgelöste Vorhersagen der flächenhaften Verteilung von Luftschadstoffen ermöglicht und so Kommunen bei der Planung von kurzfristigen Gegenmaßnahmen wie der temporären Verkehrsbeeinflussung unterstützt (Petry et al. 2021). In einer zweiten Verfahrenskomponente wurde der Zusammenhang zwischen der aktuellen Flächennutzung und der langfristigen Luftqualität modelliert. Mit diesem Modell lassen sich die Auswirkungen verschiedener Planungsvarianten auf die lokale Luftqualität vorab simulieren. Dies wurde von den assoziierten Partnern Landesamt für Natur, Umwelt und Verbraucherschutz (LANUV) Nordrhein-Westfalen und Landeshauptstadt Stuttgart als besonders relevant für die Planungspraxis angesehen. Im Folgenden werden die Methodik, Möglichkeiten und Grenzen derartiger KI-basierter Simulationen anhand realer Planungsbeispiele aufgezeigt.

2 Methodik und verwendete Daten

Der kombinierte Einsatz von Wettermodellen, chemischen Transport- oder Partikel-dispersionsmodellen ermöglicht die raumzeitlich konsistente Simulation und Vorhersage von Luftschadstoffkonzentrationen von der globalen bis zur lokalen Ebene (Petry et al. 2021). Zum Beispiel liefert auf europäischer Ebene der Copernicus Atmosphere Monitoring Service (CAMS) tägliche Luftqualitäts-Vorhersagen mit einer räumlichen Auflösung von $0,1^\circ$. Das entspricht rund 10 km Rasterauflösung (Copernicus 2022). Für die Vorhersage der Luftqualität in höherer räumlicher Auflösung liefert das Luftqualitätsmodellierungssystem Polyphemus/DLR operationell Vorhersagen von bis zu 72 Stunden bei räumlichen Auflösungen von 2 km bis hinunter zu 500 m (Khorsandi et al. 2018; Mallet et al. 2007). Weitere in Deutschland eingesetzte Luftqualitätsmodellierungssysteme sind EURAD-IM (Elbern et al. 2007) und REMCAL-GRID (Stern 2003). Ein großer Teil der Variabilität der Luftverschmutzung findet jedoch auf sehr kleinen Skalen statt (Lefebvre et al. 2013). Chemische und physikalische Modelle erfordern laut Petry et al. (2021: 90) daher: (1) eine genaue und hochaufgelöste Initialisierung statischer (Topographie) und dynamischer (Meteorologie, Emissionen, Landnutzung) Felder, (2) eine gute Darstellung und Parametrisierung von Prozessen, (3) einen numerisch stabilen Löser (Solver) und (4) nicht zuletzt massive Rechenkapazitäten, um die lokalen Effekte in komplexem Gelände oder städtischen Umgebungen aufzulösen.

¹ Gefördert durch das Bundesministerium für Digitalisierung und Verkehr (BMDV) im Rahmen des Modernitätsfonds (mFund), FKZ: 19F2064F.

In dem hier vorgestellten Forschungsprojekt sollte eine weitere Methode mit einer vorwiegend implizierten Modellierung der physikalisch-chemischen Prozesse untersucht und getestet werden: die Vorhersage und Simulation von Luftschadstoffen mittels Machine Learning. Weit verbreitete Modelle in diesem Feld sind Deep Neural Networks (DNN). Hier wurde ein Fully Connected Neural Network (FCNN) mit 3 Hidden Layers und Rectified Linear Unit (ReLU) Aktivierungsfunktion verwendet. Ziel der Simulation war die Modellierung der Schadstoffbelastung an einem Ort in Abhängigkeit der räumlichen Beschaffenheit der Umgebung. Um diese Abhängigkeit zu lernen, wurde das neuronale Netz darauf trainiert, die durchschnittliche Schadstoffbelastung an den Messstationen auf Grundlage der Landnutzungsklassifikation des umliegenden Gebiets vorherzusagen. Als Input hat das Netz ein distanzgewichtetes Histogramm der Häufigkeiten einzelner Landschaftsklassen in 300 m Radius um den Messstationenpunkt erhalten, das für jeden Punkt im Preprocessing berechnet wurde. Die durchschnittliche Schadstoffbelastung an den Messstationen über mehrere Jahre wurde für die jeweiligen Schadstoffarten berechnet und als Target im Training benutzt. Die Implementierung erfolgte in PyTorch 1.4.

Für die Vorhersagequalität aller KI-basierten Modelle ist die Qualität der Eingabedaten (der sogenannten Trainingsdaten) entscheidend. Daher wurden hier ausschließlich Luftschadstoffdaten der offiziellen amtlichen Messstationen berücksichtigt. Ein Überblick aller amtlichen deutschen Messstationen ist auf der Stationsübersicht des Umweltbundesamtes (UBA 2022) zu finden. Für das Training des KI-Modells wurden neben den Stationsmesswerten auch Verkehrs-, Wetter-, Satelliten- und Flächennutzungsdaten verwendet. Die Satellitendaten umfassten u. a. die seit 2017 zur Verfügung stehenden Atmosphärendaten des TROPOMI-Instruments an Bord von Sentinel-5 Precursor (Sentinel-5P). Dieser Sensor aus dem Copernicus-Programm misst – in der troposphärischen Säule und bei täglich globaler Abdeckung – Luftschadstoffe und Treibhausgase wie Stickstoffdioxid (NO₂), Schwefeldioxid (SO₂), Formaldehyd (HCHO), Kohlenstoffmonoxid (CO) und Methan (CH₄) mit einer räumlichen Auflösung von 3,5 × 5,5 km (Taubenböck et al. 2020). Diese Daten dienen im Modell der flächenhaften Modellierung der punktuell gemessenen in-situ Luftschadstoffwerte. Im Folgenden werden die Ergebnisse der Anwendung des Modells vorgestellt.

3 Simulationen der Luftqualität

Das im vorangegangenen Abschnitt beschriebene FCNN-Modell wurde auf Basis der Daten der kleinräumigen aktuellen Flächennutzung des Monitors der Siedlungs- und Freiraumentwicklung (Meinel et al. 2022) trainiert und damit implizit der Zusammenhang zwischen der Flächennutzung und den Jahresmittelwerten diverser Luftschadstoffe modelliert. Für die Simulationen wurden gemeinsam mit den Praxispartnern unterschiedlich große Fallstudiengebiete in Nordrhein-Westfalen und Stuttgart ausgewählt, für die aktuell Bebauungsplanungen vorliegen. Die geplante Bebauung wurde anschlie-

ßend in die Flächennutzungsdaten übertragen. Zusätzlich wurde ein weiterer, simulierter Datensatz (Kontrolldatensatz) erstellt, in dem der beplante Bereich virtuell in eine Grünfläche umgewidmet wurde (Abb. 1, obere Reihe). Die simulierten Datensätze wurden als Eingabelayer für das zuvor trainierte FCNN-Modell verwendet und auf diese Weise im Ergebnis die jeweilige Luftschadstoffbelastung flächenhaft simuliert (Abb. 1, untere Reihe, hier am Beispiel von Stickstoffdioxid, NO₂). Abbildung 2 zeigt die Simulationsexperimente für den Vergleich der Jahresmittelwerte der Luftschadstoffe Feinstaub (PM₁₀), Stickstoffdioxid (NO₂) und Ozon (O₃) in der aktuellen Flächennutzung, der geplanten Flächennutzung und bei Umwidmung als Grünfläche bzw. Siedlungsfreifläche.

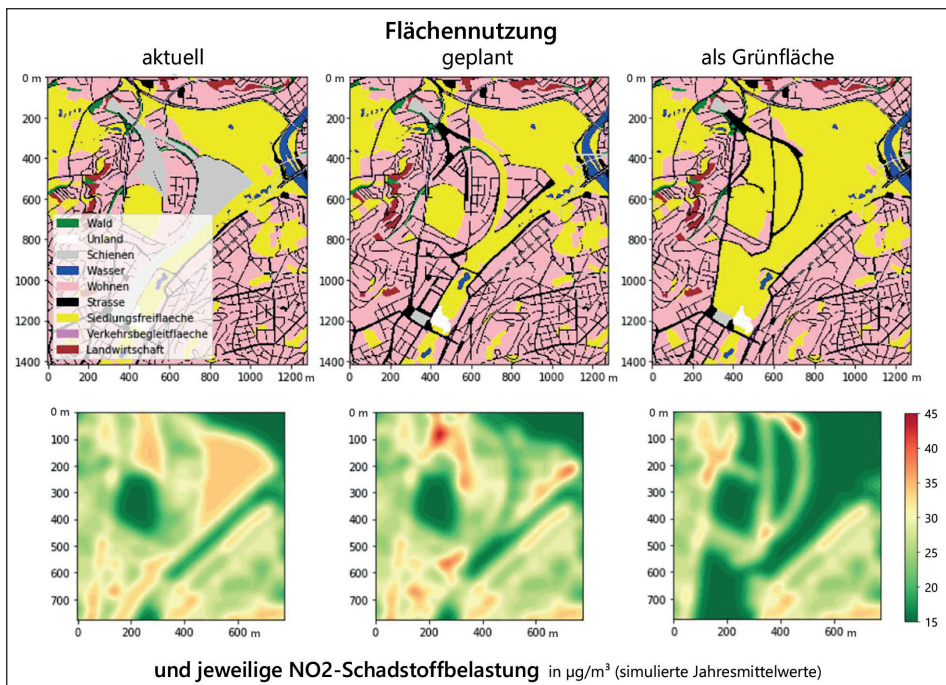


Abb. 1: Vergleich der aktuellen NO₂-Jahresmittelwerte (links unten) für die aktuelle Flächennutzung (oben links), der simulierten Jahresmittelwerte (unten Mitte) entsprechend der geplanten Flächennutzung (oben Mitte) und der simulierten Jahresmittelwerte (links unten) entsprechend der Planungen als Siedlungsfreifläche bzw. Grünfläche (rechts oben). (Quelle: eigene Darstellung, HHI)




Abb. 2: Vergleich Jahresmittelwerte für PM10 (oben), NO2 (Mitte) und O3 (unten) für die aktuelle Flächennutzung (links), für entsprechend der Planungen simulierten Flächennutzung (Mitte) und der Planung als Siedlungsfreifläche bzw. Grünfläche (rechts). (Quelle: eigene Darstellung, HHI)

4 Fazit und Forschungsbedarf

Im Zuge der neuen und im Vergleich zu aktuellen Grenzwerten wesentlich strengeren Luftqualitätsrichtlinien der Weltgesundheitsorganisation sind Anstrengungen seitens der Politik und zuständigen Verwaltungen notwendig. Um die lokale Ebene bei der Planung und Entscheidungsfindung zu unterstützen, wurde ein Verfahren vorgestellt, das die kleinräumige Simulation der räumlichen Verteilung von Luftschadstoffen auf Basis verschiedener Planungsvarianten ermöglicht. Im Gegensatz zu den verbreiteten physikalisch-chemischen Modellen, modelliert das hier vorgestellte Verfahren die Zusammenhänge der abhängigen Parameter implizit durch Training eines FCNN und ist damit zumindest hinsichtlich der Eingangsdaten und Parametrisierung weniger voraussetzungsvoll. Ein besonderer Gewinn stellen hierfür die neuen Copernicus-Daten des Sentinel-5P/TROPOMI-Instruments dar. Es wurde gezeigt, dass die Simulationen für ausreichend große Planungsgebiete plausible Jahresmittelwertverteilungen liefern. Für kleinere Gebiete unter einem Hektar sollte das Verfahren weiterentwickelt werden bzw. mit höheren Auflösungen simuliert werden. Dies wäre durch die hohe Auflösung des Flächennutzungslayers möglich, erforderte jedoch deutlich mehr Rechenleistung, insbesondere beim Training des KI-Modells. Ausstehend ist derzeit noch eine Validierung der Simulationsergebnisse anhand realer Messwerte nach Realisierung der geplanten Situation. Generell wird die Validierung aller Simulationsverfahren zur Luftqualität jedoch dadurch erschwert, dass in den neu bebauten Gebieten typischerweise keine neue amtliche Messstation eingerichtet wird, die eine lokale Validierung erlauben würde. Für eine praxisnahe Anwendung des Simulationsverfahrens wäre zudem ein Tool zur vereinfachten bzw. automatisierten Übertragung der Planungen in den Modellinput bzw. sogar eine direkte Eingabe der Bebauungspläne bzw. Planungsvarianten wünschenswert.

5 Literatur

- Copernicus (2022): Copernicus Atmosphere Monitoring Service. European air quality. <http://www.regional.atmosphere.copernicus.eu> (Zugriff: 16.09.2022).
- EEA – European Environment Agency (2020): Air quality in Europe – 2020 report. European Environment Agency, Copenhagen: 164 S.
- Elbern, H.; Strunk, A.; Schmidt, H.; Talagrand, O. (2007): Emission rate and chemical state estimation by 4-dimensional variational inversion, *Atmospheric Chemistry and Physics*, 7: 3749-3769.
- Khorsandi, E.; Baier, F.; Erbertseder, T.; Bittner, M. (2018): Air quality monitoring and simulation on urban scale over Munich, SPIE Remote Sensing, 2018, Berlin, Germany, Proceedings Volume 10793, Remote Sensing Technologies and Applications in Urban Environments III; 1079303.
- Lefebvre, W.; van Poppel, M.; Maiheu, B.; Janssen, S.; Dons, E. (2013): Evaluation of the RIO-IFDM-street canyon model chain, *Atmospheric Environment*, 77: 325-337.

- Mallet, V.; Quelo, D.; Sportisse, B.; Ahmed de Biasi, M.; Debry, E.; Korsakissok, I.; Wu, L.; Roustan, Y.; Sartelet, K.; Tombette, M.; Foudhil, H. (2007): Technical Note: The air quality modeling system Polyphemus, *Atmospheric Chemistry and Physics*, 7: 5479-5487.
- Meinel, G.; Sikder, S.; Krueger, T. (2022): „IOER Monitor: A Spatio-Temporal Research Data Infrastructure on Settlement and Open Space Development in Germany“. *Jahrbücher für Nationalökonomie und Statistik*, vol. 242, no. 1, 2022: 159-170. <https://doi.org/10.1515/jbnst-2021-0009>
- Petry, L.; Herold, H.; Meinel, G.; Meiers, T.; Müller, I.; Kalusche, E.; Erbertseder, T.; Taubenböck, H.; Zaunseder, E.; Srinivasan, V.; Osman, A.; Weber, B.; Jäger, S.; Mayer, C.; Gengenbach, C. (2020): Air quality monitoring and data management in Germany – Status quo and suggestions for improvement. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLIV-4/ (2020): 37-43*. <https://doi.org/10.5194/isprs-archives-XLIV-4-W2-2020-37-2020>
- Petry, L.; Meiers, T.; Reuschenberg, D.; Mirzavand Borujeni, S.; Arndt, J.; Odenthal, L.; Erbertseder, T.; Taubenböck, H.; Müller, I.; Kalusche, E.; Weber, B.; Käflein, J.; Mayer, C.; Meinel, G.; Gengenbach, C.; Herold, H. (2021): Design and results of an AI-based forecasting of air pollutants for smart cities. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences (2021) VIII-4/W1-20: 89-96*. <https://doi.org/10.5194/isprs-annals-VIII-4-W1-2021-89-2021>
- Stern, R. (2003): Entwicklung und Anwendung des chemischen Transportmodells REM/CALGRID. Abschlussbericht zum Forschungs- und Entwicklungsvorhaben 298 41 252 des Umweltbundesamts „Modellierung und Prüfung von Strategien zur Verminderung der Belastung durch Ozon“: 180 S.
- Taubenböck, H.; Schmich, P.; Erbertseder, T. et al. (2020): Satellitendaten zur Erfassung gesundheitsrelevanter Umweltbedingungen: Beispiele und interdisziplinäre Potenziale. *Bundesgesundheitsblatt* 63: 936-944. <https://doi.org/10.1007/s00103-020-03177-w>
- Tang, Y.; Xu, J.; Matsumoto, K.; Ono, C. (2016): Sequence-to-Sequence Model with Attention for Time Series Classification. <https://doi.org/10.1109/ICDMW.2016.0078>
- UBA – Umweltbundesamt (2022): Umweltbundesamt – Überblick und Werte aller Messstationen. <https://www.umweltbundesamt.de/daten/luft/luftdaten> (Zugriff: 16.09.22).
- WHO – World Health Organization (2021): WHO global air quality guidelines. Particulate matter (PM_{2.5} and PM₁₀), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide. Geneva: World Health Organization: 300 S.