

Adaptives luftqualitätsgewichtetes Fahrradrouting mittels Land-use Regression auf Basis offener Daten

Julian Janßen,¹ Paul Tremper,¹ Till Riedel¹

Abstract: Luftschadstoffen ausgesetzt zu sein hat langfristige negative gesundheitliche Folgen, denen besonders Fahrradfahrer im urbanen Raum ausgesetzt sind. Dabei gibt es wahrscheinlich keine unschädliche Dosis: weniger ist immer besser. Diese Arbeit zeigt, dass luftqualitätsgewichtete Fahrradrouten die persönliche Exposition gemäß dem Regressionsmodell deutlich reduzieren können, wobei die errechneten Umwege zumeist nur minimal sind. Auf Basis offener Daten wird ein neuronales Netzwerk zur Schätzung der Luftqualität trainiert. Dabei werden PM_{10} -Daten aus mobilen Messungen als Indikator der Luftqualität verwendet. Das entstehende Land-Use-Regression-Modell bezieht dabei sowohl zeitliche als auch räumliche Features mit ein. Anschließend wird dieses Modell verwendet, um luftqualitätsgewichtete Routen zu berechnen. Dabei wird gezeigt, wie ein solches feingranulare Modell im Routing verwendet werden kann. Anhand von zufällig gewählten Start/Ziel Paaren werden die luftqualitätsgewichteten Routen mit der jeweils kürzesten Strecke verglichen.

Keywords: Neuronales Netzwerk; Land Use Regression; Luftqualität; Routing

1 Warum brauchen Radfahrer künstliche Intelligenz

Luftqualität im städtischen Raum ist ein aktuelles und komplexes Thema. Dauerhafte, erhöhte Exposition an Luftschadstoffen kann zu gesundheitlichen Folgen führen, weswegen in Deutschland die innerstädtische Luftqualität staatlich überwacht wird und bei Grenzwertüberschreitungen Fahrverbote oder andere Maßnahmen verhängt werden können.

Die Schadstoffbelastung in der Stadt variiert aufgrund der Volatilität der Schadstoffe stark. In einer belgischen Studie [Pe13] wurde gezeigt, dass die PM_{10} (Feinstaub kleiner gleich 10 Mikrometer Durchmesser) Konzentration auf der Straße stark von der Verkehrsdichte abhängt. Dies führt zu der Frage, ob man durch die Wahl der Route eine deutliche Reduktion der Schadstoffexposition erreichen kann ohne dabei unzumutbare Umwege in Kauf nehmen zu müssen. Wir fokussieren uns in unserer Arbeit auf eine Routinganwendung für Radfahrer, da diese sowohl der Schadstoffexposition des Verkehrs direkt ausgesetzt sind, als auch sehr flexibel in der Wahl ihrer Route sind. Wir untersuchen dabei, ob durch die eine KI-gestützte Auswahl der Route die individuelle Schadstoffbelastung effektiv reduziert werden kann.

¹ Karlsruhe Institute of Technology (KIT), TECO, Vincenz-Prießnitz-Str. 1, 76131 Karlsruhe lastname@teco.edu

2 Hintergrund und Verwandte Arbeiten

2.1 Datensatz

Im Projekt *SmartAQnet* [Sm21] wurden über einen Zeitraum von drei Jahren Luftqualitätsdaten durch ein heterogenes Sensornetzwerk erhoben². Das Ziel war es, durch die Heterogenität des Netzwerks sowohl eine zeitlich wie räumlich hohe Auflösung zu erreichen, als auch durch qualitativ hochwertige Sensoren die Messungen der in der Breite ausgebrachten Low Cost Sensoren zu kalibrieren und zu validieren. Insgesamt enthält der Datensatz über 250 Millionen Datenpunkte. Der von uns für das maschinelle Lernen verwendete Teildatensatz enthält 16377 PM_{10} -Messwerte mit den dazugehörigen GPS-Positionen. Für kartographische Daten nutzen wir Daten des OpenStreetMap (OSM) Projekts.

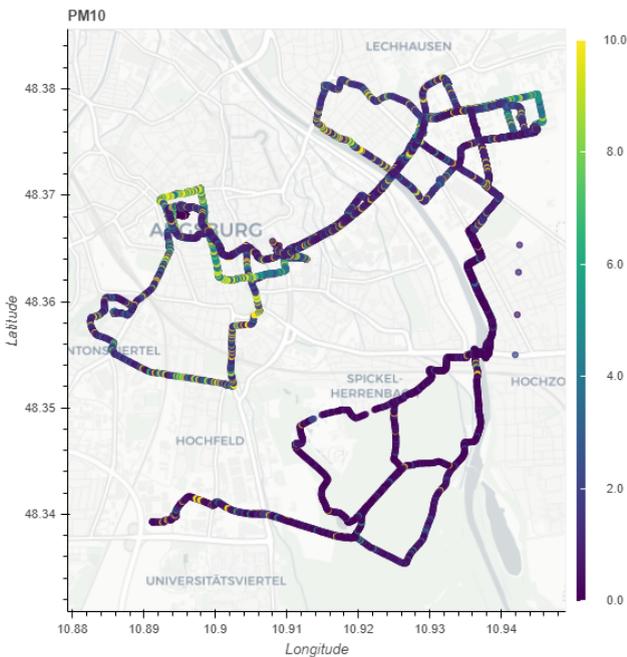


Abb. 1: Beispielhafte auf Fahrrädern gemessene PM_{10} -Belastungen in Augsburg

2.2 Land-Use-Regression

Das Land-Use-Regression-Modell (kurz LUR-Modell) ist eine häufig verwendete Methode, basierend auf maschinellem Lernen, um z.B. Luftqualitätsvorhersagen zu generieren.

² Alle Daten sind offen mittels einer OGC SensorThings-konformen API unter <https://api.smartaq.net/v1.0> abrufbar.

Innerhalb eines Regressionsmodells wird anhand von korrelierten Prädikatoren die räumliche Schadstoffverteilung auf Basis begrenzter Messkampagnen statisch hergeleitet.[Ho14]

Das LUR-Modell basiert auf zwei grundlegenden Annahmen:

1. Es genügt bereits eine kleine Anzahl an gemessenen Prädiktorvariablen, um die für die Zielgröße relevanten Umweltbedingungen abzuleiten.
2. Innerhalb eines begrenzten Trainingsgebiets kann auf zuverlässiger Weise die Beziehung zwischen der Zielgröße und den Prädikatoren ermittelt werden.[Br00]

Eine Studie in Auckland zeigt die Anwendbarkeit von LUR-Modellen im Mikromaßstab um Stickstoffdioxide vorherzusagen. Hierzu wurden für den ländlichen Raum die Kriterien Straßenbreite, Entfernung zur Hauptstraße, das Vorhandensein einer Markise und die Anzahl der Bushaltestellen (in der besagten Region ist der Einfluss der Dieselemission im Busverkehr nicht zu unterschätzen) definiert. Die Studie zeigt jedoch auch, dass die Parameter sich nicht auf den städtischen Raum übertragen lassen.[We18]

2.3 Exposition und Routing von Radfahrern

Luo et. al [LBB20] beschreiben eine neue Methode, die verkehrsbedingte Luftverschmutzung in die Routenplanung für Fahrradfahrer miteinbezieht. Die Studie evaluiert Fahrradrouten durch die Stadt Riverside, Kalifornien, anhand von Luftqualitätsdaten, welche mit einem Emissionsmodell auf geschätzter Verkehrsdichte simuliert wurde. Die Studie kommt zu dem Ergebnis, dass die Einbeziehung der Luftqualitätsdaten zu anderen Fahrradrouten führt.

Die Studie betrachtet nur von Autos befahrbare Straßen. In dieser Arbeit betrachten wir jedoch auch mögliche Routen durch Parks etc., was flächendeckende Luftqualitätsdaten notwendig macht.

Auch an anderer Stelle wird thematisiert, dass die Luftqualität zu wenig bei der Streckenwahl der Fahrradstraßen berücksichtigt wird [Tr20]. Bei der Planung der Radwege wird der negative Einfluss der Luftverschmutzung auf die Fahrradfahrer oft außer Acht gelassen. Luftqualität wird dabei mithilfe von Open-Source-Daten, Land-Use-Regression, einem Neuronalem Netz und einer räumlichen Analyse geschätzt. Eine Studie [LBB18] zeigt, dass die Luftverschmutzung bei der längeren Route um 44 - 48 % kleiner ist, abhängig von der Tageszeit. Dadurch zeigt sich, dass durch die Wahl der Route die Konzentration der Luftverschmutzung der man ausgesetzt wird, verringert werden kann. Die Studie weist noch darauf hin, dass durch die Integration weiterer Faktoren wie beispielsweise die Verkehrs-, Wetter- und bessere Luftqualitätsdaten in Echtzeit, die Wahl der Route noch verbesserte werden könnte. [Ma19] behandelt ebenfalls die Möglichkeit durch ein optimiertes Routing, die Exposition der Luftschadstoffe zu verringern. Die Studie entwickelte den so genannten CAR-Algorithmus (Clean Air Routing), der dafür verwendet wird, ein

gesundheitsoptimierendes Routing-Empfehlung zu ermitteln. Dafür werden Open-Source-Daten des Feinstaubes $PM_{2,5}$ herangezogen. Mithilfe des Straßennetzdiagramms von Taiwan und den gemessenen Feinstaubdaten wird nun eine räumlich-zeitliche Interpolation gemacht, um die $PM_{2,5}$ -Werte an den Straßennetzkreuzungen zu ermitteln.

3 Routing mittels Neuronalem Netzwerk als Land-Use-Regressor zur Streckengewichtung

Das Vorgehen bei der Erstellung des Systems ist schematisch in Abbildung 2 dargestellt. Beginnend auf der linken Seite werden die Messdaten als Basis für das Modell der Luftqualität verwendet. Zusammen bilden diese beiden Komponenten die Thematik der Land-Use-Regression ab. Das erstellte Vorhersagemodell wird anschließend im Routing verwendet um die eine luftqualitätsgewichtete Route zu bestimmen.



Abb. 2: Schematischer Systemaufbau

Um das Fahrradrouting mit Luftqualitätsdaten gewichten zu können, benötigen wir eine flächige Regression. Diese erhalten wir durch eine Land Use Regression mithilfe eines neuronalen Netzes.

Die geographische Umgebung stellt dabei eine Repräsentation der örtlichen Gegebenheiten an einem Punkt da. Dabei werden die geographischen Gegebenheiten in Kategorien eingeteilt. Für jeden Punkt und jede Kategorie wird anschließend ein numerischer Wert berechnet. Abhängig von den vorliegenden Daten zu einer Kategorie, handelt es sich hierbei entweder um die Summe der Längen bzw. der Flächen innerhalb der zu bestimmenden Umgebung.

Wir beschreiben die geographische Umgebung durch einen Kreis mit Radius r um den Messpunkt. Da im Vorhinein unklar ist welcher Umgebungsradius r für die Modellierung am geeignetes ist, wird dieser explorativ bestimmt. Dies erfolgt in Abschnitt 3. So wird die geographische Umgebung für alle Messpunkte mit verschiedenen Radien berechnet.

Die Oberkategorien „Land Use“ und „Water“, des OSM-Datensatzes, enthalten die tatsächliche geographische Ausprägung in Form von Polygonen. Die Summe der im Umgebungskreis enthaltenen Flächen für eine bestimmte Kategorie bildet hier den Wert der jeweiligen Kategorie. Elemente der Oberkategorien „Railways“ und „Road“ werden als Linien modelliert.

Hier wird die Summe der im Umgebungskreis enthaltenen Entfernungen als Wert der Kategorie verwendet.

Die Daten werden 80/20 in Trainings- und Validierungsset aufgeteilt. Hierbei werden die Trainingsdaten für die Optimierung der Modelle verwendet und zu diesem Zweck noch einmal in Trainings- und Testset aufgeteilt. Die Zuordnung zu dem jeweiligen Set, wird dabei randomisiert. Die Daten aus dem Validierungsset werden zum Schluss für die Bewertung des Modells verwendet.

Als Features für das Neuronale Netz werden die kategorisierten Anteile der geographischen Umgebung, um einen Messpunkt gewählt. Diese werden linear unter Verwendung des Minimums sowie des Maximums in den Bereich $[0,1]$ skaliert. Zusätzlich wird Wochentag und Stunde des Tages als Feature hinzugefügt. Diese wird dabei mit dem One-Hot Verfahren encodiert. Die PM_{10} Messungen werden dabei als Ausgangsgröße für das Lernen verwendet und ebenfalls Minimum/Maximum skaliert.

Auf dieser Grundlage werden verschiedene Modellierungsparameter variiert. Eines der untersuchten Parameter ist der Abstand, welcher für die Umgebungsbeschreibung verwendet wird. So werden verschiedene Radien des Umgebungskreises untersucht. Ebenso werden zwei Loss-Funktionen betrachtet. Als Aktivierungsfunktionen werden ReLU, Sigmoid sowie Tanh verwendet. Auch verschiedene Netzstrukturen werden untersucht. So wird auch eine eher Breite (Anzahl Neuronen), sowie eine etwas tiefere Struktur (Anzahl Schichten) erstellt. So werden insgesamt 90 verschiedene Modelle trainiert. Tabelle 1 gibt einen Überblick über die untersuchten Parameter.

Tab. 1: Variierte Hyperparameter

Radius der Umgebung	3, 5, 10, 15, 20
Loss-Funktion	Mittlerer absoluter Fehler (MAE), Mittlere quadratische Abweichung (MSE)
Aktivierungsfunktion	ReLU, Sigmoid, Tanh
Struktur	[128, 64, 32, 1] [128, 64, 1] [64, 32, 16, 8, 1]

Anschließend werden die trainierten Modelle miteinander verglichen. Den geringsten MAE weist das Neuronale Netz mit einer vollverbundenen Struktur von [128, 64, 1] auf. Als Loss-Funktion wird der MAE, als Aktivierungsfunktion wird Sigmoid verwendet. Dabei wird ein Umgebungsradius von 15 Metern verwendet (MAE: 0.04241, MSE: 0.01259). Die als Baseline dienenden Modelle weisen dabei einen schlechteren MAE auf. Der Random Forest weist einen MAE von 0.05863, die SVM sogar einen von 0.09297 auf.

3.1 Routing

Als Grundlage für den Routing-Algorithmus berechnen wir aus den vorliegenden Basisdaten einen gerichteten und gewichteten Graphen der Strecken. Alle für die Routing-Entscheidung nicht benötigten Details werden dabei verworfen. Die Schritte zur Bestimmung einer Route sind schematisch in Abbildung 3 dargestellt. Die Luftqualitätsdaten aus der Land Use Regression fließen dabei wie dargestellt in die Bestimmung der Gewichte ein.

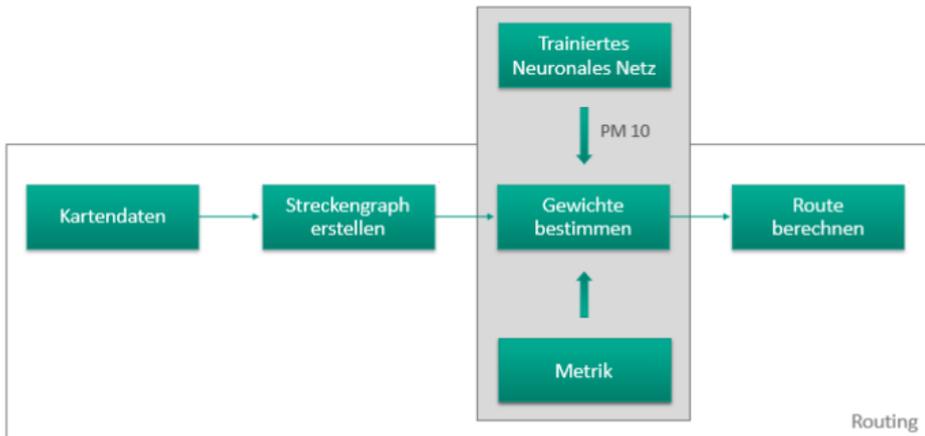


Abb. 3: Routingpipeline

Wir laden alle mit dem Fahrrad befahrbare Strecken aus dem OSM-Datensatz herunter und erstellen daraus den gerichteten Streckengraphen, bestehend aus Knoten und Kanten. Anschließend werden die Kanten mit Luftqualitätsdaten wie folgt gewichtet:

Im ersten Schritt wird ein Streckenabschnitt in vorhersagbare Punkte aufgeteilt. Hierbei wird zunächst die Anzahl der Punkte bestimmt, die auf dem Abschnitt liegen können ohne dass der Umgebungskreis sich überschneidet. Dazu wird die Länge des Abschnitts durch den Durchmesser des Umgebungskreises geteilt. Der Radius des Umgebungskreises entspricht dabei dem des Radius der für das Training des Modells verwendet wurde. In diesem Fall entspricht der Radius 15m. Anschließend werden die Lage der Punkte auf dem Teilstück so bestimmt dass diese den gleichen Abstand zueinander haben. Für jede Lokation wird nun die geographische Umgebung berechnet. Im zweiten Schritt wird diese verwendet um die Luftqualität vorherzusagen. Der Durchschnitt der Vorhersagen ergibt nun den PM_{10} Wert einer Kante.

Aufgrund der Performance werden zuerst alle vorhersagbare Punkte bestimmt. Anschließend werden die dazugehörigen geographischen Umgebungen berechnet. Nun werden für alle Umgebungen die Vorhersagen für die Luftqualität gemacht, die dann in das Kantengewicht einfließen. Die in dieser Arbeit verwendete Gewichtungsfunktion soll den Trade-Off

zwischen der Fahrzeit auf der einen, sowie der Exposition von Luftschadstoffen auf der anderen Seite abbilden. Dabei wurde folgende Formel für die Implementierung verwendet:

$$\text{Gewicht} = \text{Dauer Exposition} \times (1 + (\text{Präferenzfaktor} \times \text{Prädiktion})) \quad (1)$$

Wir vereinfachen die Formel durch die Annahme, dass der Fahrradfahrer mit konstanter Geschwindigkeit fährt und erhalten:

$$\text{Gewicht} = \text{Länge Streckenabschnitt} \times (1 + (\text{Präferenzfaktor} \times \text{Prädiktion})) \quad (2)$$

Wobei Prädiktion der entsprechende berechnete Luftqualitätswert für den Streckenabschnitt ist. Der eingebaute Präferenzfaktor ermöglicht hierbei eine individualisierung des Trade-Offs.

Für die Implementierung des Routing Abschnitts wurde ebenfalls die Programmiersprache Python verwendet. Das Paket OSMnx wurde für die Berechnung der Routen verwendet. Dieses basiert auf dem Paket NetworkX welches die Modellierung von Netzwerken in Form von Graphen ermöglicht. Als Algorithmus für die Bestimmung der optimalen Route wird der Dijkstra-Algorithmus verwendet.

4 Evaluierung

In dieser Arbeit untersuchen wir die Frage, ob ein luftqualitätsgewichtetes Fahrradrouting für gegebene Start- und Zielpunkte Routen mit deutlich reduzierter Exposition bei geringer zusätzlicher Weglänge produzieren kann. Die vagen Bezeichnungen "reduzierte Exposition" und "geringe zusätzliche Weglänge" beziehen sich dabei auf einen subjektiven Trade-Off, der durch den Präferenzfaktor frei wählbar ist.

Zur Überprüfung dieser Hypothese werden 100 verschiedene Routen berechnet. Dabei wird sowohl der Start- als auch der Zielknoten zufällig ausgewählt. Für jedes dieser Paare wird sowohl die kürzeste Strecke als Baseline sowie die luftqualitätsgewichtete Strecke bei fixem Trade-Off Faktor berechnet. Anschließend wird für beide Routen jeweils sowohl die Länge als auch die PM_{10} -Exposition berechnet. Es wird die Prozentuale Veränderung der Exposition wie auch die Prozentuale Veränderung der Länge berechnet.

In Abbildung 4 ist ein Beispiel einer Route in blau zu sehen, die nach der Länge der Strecke optimiert ist.

Die blaue (grüne) Strecke in Abbildung 4 ist die kürzeste (luftqualitätsgewichtete) Strecke für ein beispielhafte Wahl der Start- und Zielpunkte. Im Fall der luftqualitätsgewichteten Strecke macht die Routenführung nun einen Bogen um die Innenstadt. Im vorliegenden Fall weist die kürzeste Route eine um 27.8 % höhere Exposition auf als die luftqualitätsgewichtete Route. Die kürzeste Strecke von 5.096 km wird dabei lediglich um 1.1 % verlängert. Der Präferenzfaktor wurde auf 0.8 festgesetzt.

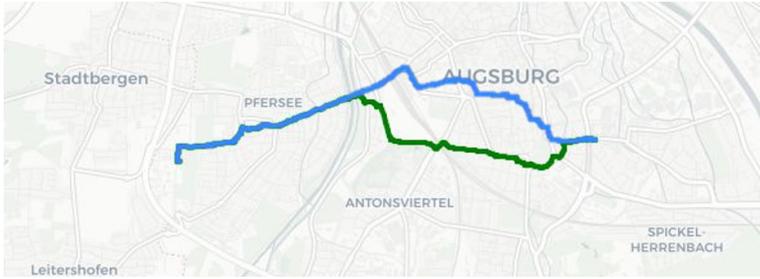


Abb. 4: Für ein Beispiel von Start- und Zielpunkten: Kürzeste Route in blau, luftqualitätsgewichteten Route in grün.

Abbildung 5 zeigt 100 zufällig gewählte Start- und Zielpaare. Die blauen Punkte repräsentieren dabei ein Start- und Zielpaar, für das die kürzeste sowie die luftqualitätsgewichtete Route bestimmt wurde. Die rote Gerade ist eine Gerade mit einer Steigung von 1. Sie lässt die unabhängige Skalierung der Achsen erkennen. Die grüne Gerade stellt eine einfache lineare Regression dar.

Dabei ist eine Häufung der Ergebnisse im Bereich nahe $[0, 0]$ zu erkennen. Dies bedeutet das viele der Luftqualitätsgewichteten Routen entweder genau der kürzesten Route entsprechen oder nur eine minimale Verbesserung erzielt werden konnten. Zum einen hängt dies natürlich mit kurzen Routen zusammen, für die wenn überhaupt eine Verbesserung nur durch große Umwege erreicht werden könnte (weil z.B. Start oder Ziel die Hauptursache für eine Exposition sind). Auch ist eine große Streuung der Ergebnisse zu beobachten, die natürlich erscheint aufgrund der nichtlinearen Zusammenhänge auf Basis der Randbedingungen in einem Straßennetz. Dennoch werden vorwiegend Routen gefunden die die Exposition deutlich reduzieren, dafür aber nur einige wenige Prozentpunkte längerer Umweg in Kauf genommen werden muss. Wichtig dabei ist zu verstehen, dass jede zusätzliche Exposition mit Feinstaub sich potentiell negativ auf die Gesundheit des Fahrradfahrers auswirken kann, da es keine unschädliche Dosis gibt ("wahrscheinlich" lineare Dosis-Wirkung-Beziehung, no adverse effect level [Or13]). Daher ist jede Einsparung ein wichtiger Beitrag zur Gesundheit (umgekehrt macht es keinen Sinn auf die Person bezogen lediglich einen Grenzwert zu unterschreiten).

Die kürzesten Strecken haben eine durchschnittliche Streckenlänge von 6.25 km, wobei die zugehörigen luftqualitätsgewichteten Strecken durchschnittlich nur um 0.028 km (0.44 %) länger sind. Von den betrachteten Start- Zielpunktpaaren waren die luftqualitätsgewichteten Strecken nie mehr als 3 % länger als die jeweilige kürzeste Strecke. Gleichzeitig weisen die kürzesten Strecken eine im Durchschnitt um 36,24 % höhere Exposition auf.

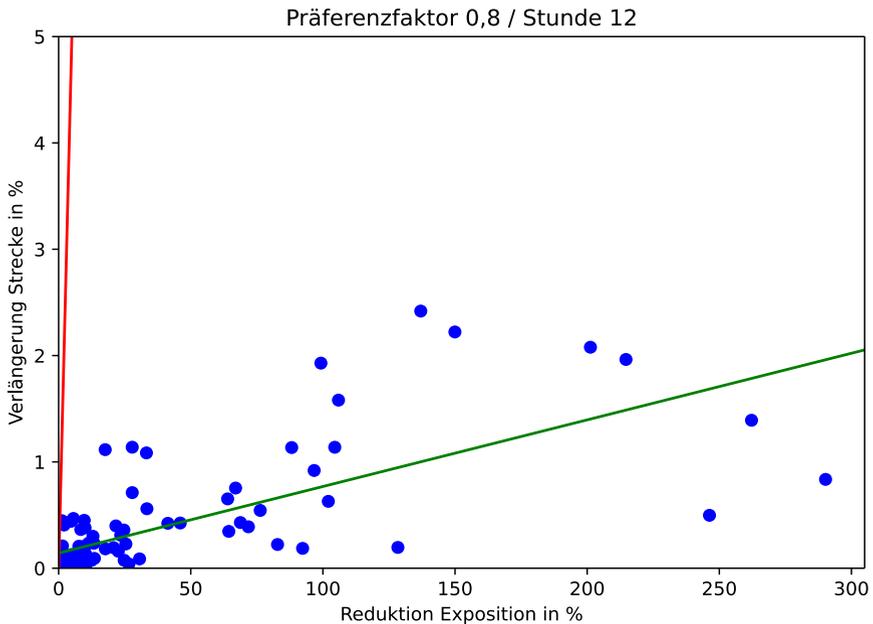


Abb. 5: Ergebnis Plot zufälliger Routen. Die Reduktion in % bezieht sich auf die erhöhte Exposition auf der kürzesten Route relativ zur luftqualitätsgewichteten Route.

5 Diskussion und Ausblick

Im Rahmen dieser Arbeit haben wir auf Basis eines Luftqualitätsdatensatzes für die Stadt Augsburg untersucht, ob durch die intelligente Auswahl einer Fahrradrouten die persönliche Feinstaubexposition deutlich reduziert werden kann ohne unpraktikable Umwege in Kauf nehmen zu müssen. Wir finden, dass hierbei zumeist zwar nur eine kleine Reduktion der Exposition erreicht werden kann, teilweise jedoch bis zu 75%, wobei die in Kauf zu nehmenden Umwege nie mehr als +3% der kürzesten Strecke betragen.

Bei der Bewertung der Ergebnisse ist zu beachten, dass diese stark von den vorhandenen Luftqualitätsdaten abhängig sind. Zudem wurde der Modellfehler des grundlegenden Neuronalen Netzes in der Arbeit nur anhand von mobilen Messungen bewertet. Um das luftqualitätsgewichtete Verkehrsrouting weiter zu entwickeln sind weitere Untersuchungen notwendig. Wird der Fehler besser bewertbar, macht es auch Sinn andere Netzarchitekturen als Regressoren zu testen. So enthält der Datensatz bereits ganze Fahrradrouten, die zur Evaluation herangezogen werden können. Hier ist jedoch noch eine Kalibrierung notwendig, da nur die fixen Sensoren im Datensatz bis jetzt kalibriert wurden. Eine weitere Frage ist, inwieweit ein Vorhersagehorizont (Now-Casting) zusätzlich zur Land-use Regression die gewählte Route verbessert, da diese gerade zu Hochverkehrszeiten stark

schwanken kann. Eine Alternative, die wir momentan betrachten, ist die Nutzung von auf Simulationen gelernten Now-Casting-Modelle als schnell ausführbare Surrogate für die Expositionsrechnung. Grundlage ist jedoch, dass die Emission wirklich vorhersagbar ist, was beispielsweise bei starken Belastungen wie Baustellenaktivitäten oft nur mit einem geringen Horizont der Fall ist. Kritisch zu hinterfragen ist weiterhin, inwieweit überhaupt eine dynamische Vorhersage das Routing verändert, oder ob es nicht ausreicht ein typisches Modell für Wochentage und Uhrzeit anzunehmen. Hierzu planen wir weitere Untersuchungen. Der Vorteil von Land.Use-Regression-Modellen und anderen Lernmodellen zum Scoring von Routenteilstücken ist prinzipiell die partielle, bedarfsgerechte Auswertung innerhalb des Routingalgorithmus.

Literaturverzeichnis

- [Br00] Briggs, David J.; de Hoogh, Cornelis; Gulliver, John; Wills, John; Elliott, Paul; Kingham, Simon; Smallbone, Kirsty: A regression-based method for mapping traffic-related air pollution: application and testing in four contrasting urban environments. *Science of The Total Environment*, 253(1):151–167, Mai 2000.
- [Ho14] de Hoogh, Kees et al.: Comparing land use regression and dispersion modelling to assess residential exposure to ambient air pollution for epidemiological studies. *Environment International*, 73:382–392, Dezember 2014.
- [LBB18] Luo, Ji; Boriboonsomsin, Kanok; Barth, Matthew: Reducing pedestrians’ inhalation of traffic-related air pollution through route choices: Case study in California suburb. *Journal of Transport & Health*, 10:111–123, September 2018. WOS:000449750400013.
- [LBB20] Luo, Ji; Boriboonsomsin, Kanok; Barth, Matthew: Consideration of exposure to traffic-related air pollution in bicycle route planning. *Journal of Transport & Health*, 16:100792, März 2020. WOS:000539174500012.
- [Ma19] Mahajan, Sachit; Tang, Yu-Siou; Wu, Dong-Yi; Tsai, Tzu-Chieh; Chen, Ling-Jyh: CAR: The Clean Air Routing Algorithm for Path Navigation With Minimal PM2.5 Exposure on the Move. *IEEE Access*, 7:147373–147382, 2019.
- [Or13] Organization, World Health et al.: Health effects of particulate matter. Policy implications for countries in Eastern Europe, Caucasus and central Asia. World Health Organization Regional Office for Europe, Copenhagen, 2013.
- [Pe13] Peters, Jan; Theunis, Jan; Van Poppel, Martine; Berghmans, Patrick: Monitoring PM10 and Ultrafine Particles in Urban Environments Using Mobile Measurements. *Aerosol and Air Quality Research*, 13(2):509–522, April 2013. WOS:000315327400008.
- [Sm21] SmartAQnet: , Website SmartAQnet. <https://www.smartaq.net/de>, Februar 2021.
- [Tr20] Tran, Phuong T. M.; Zhao, Mushu; Yamamoto, Kohei; Minet, Laura; Nguyen, Teron; Balasubramanian, Rajasekhar: Cyclists’ personal exposure to traffic-related air pollution and its influence on bikeability. *Transportation Research Part D-Transport and Environment*, 88:102563, November 2020. WOS:000591708400002.

- [We18] Weissert, L. F.; Salmond, J. A.; Miskell, G.; Alavi-Shoshtari, M.; Williams, D. E.: Development of a microscale land use regression model for predicting NO₂ concentrations at a heavy trafficked suburban area in Auckland, NZ. *The Science of the Total Environment*, 619-620:112–119, April 2018.