

Postprint

Sensorbasierte Vorhersage von Korngrößenverteilungen durch Machine Learning Modelle auf Basis von 3D- Lasertriangulationsmessungen

für den 11. DGAW-Wissenschaftskongress "Abfall- und Ressourcenwirtschaft"
am 17./18. März 2022 an der TU Dresden.

Nils Kroell, Paula Schönfelder, Xiaozheng Chen, Kay Johnen, Alexander Feil, Kathrin Greiff*

*Corresponding Author:

Nils Kroell, M. Sc.

Institut für Anthropogene Stoffkreisläufe (ANTS)

RWTH Aachen University

Wüllnerstr. 2, 52062 Aachen

Tel: +49 241 80-99343

nils.kroell@ants.rwth-aachen.de

www.ants.rwth-aachen.de

Zitieren als:

Kroell, Nils; Schönfelder, Paula; Chen, Xiaozheng; Johnen, Kay; Feil, Alexander; Greiff, Kathrin (2022): „Sensorbasierte Vorhersage von Korngrößenverteilungen durch Machine Learning Modelle auf Basis von 3D-Lasertriangulationsmessungen“. In: Bockreis, Anke; Faulstich, Martin; Flamme, Sabine; Kranert, Martin; Mocker, Mario; Nelles, Michael; Quicker, Peter; Rettenberger, Gerhard; Rotter, Vera Susanne (Hg.): *11. Wissenschaftskongress Abfall- und Ressourcenwirtschaft*. 17.03.2022 - 18.03.2022. Dresden.

Sensorbasierte Vorhersage von Korngrößenverteilungen durch Machine Learning Modelle auf Basis von 3D-Lasertriangulationsmessungen

Abstract: Ein ausschlaggebendes Qualitätskriterium für Recyclingbaustoffe ist die Korngrößenverteilung (KGV) nach DIN 66165-1, die mittels manueller Siebanalysen bestimmt wird. Siebanalysen sind zeit- und kostenaufwändig und Analyseergebnisse nur mit Zeitverzug verfügbar. Eine sensorbasierte Ermittlung von KGVs würde diese Probleme lösen und neue Anwendungen wie ein automatisiertes Qualitätsmonitoring ermöglichen. Zur Untersuchung der technischen Machbarkeit wurden 78.575 und 102.736 Partikel aus Quarzkies und RC-Material (3,15 mm - 31,5 mm) mittels 3D-Lasertriangulation vermessen, um die Korngröße mittels Machine Learning (ML) vorherzusagen. Die trainierten ML-Modelle ermöglichen eine präzise Vorhersage der Korngröße je Partikel ($R^2 > 0,95$) und die aus den Vorhersagen abgeleiteten KGVs stimmen bis auf $\pm 1,4$ Ma.-% (mittlerer Fehler) mit den wahren KGVs überein.

1 Einleitung

Bau- und Abbruchabfälle (CDW – Construction and Demolition Waste) sind mit 230,9 Mio. Mg/a (2019) der größte Abfallstrom Deutschlands (Statistisches Bundesamt, 2021). Ein Recycling von CDW zu hochwertigen Sekundärrohstoffen ermöglicht die Substitution von Primärrohstoffen und erzielt dadurch ökologische Vorteile (Simion et al., 2013; Wang et al., 2021). Trotz hoher massenmäßiger und ökologischer Relevanz weist das bisherige CDW-Recycling erhebliche Optimierungspotentiale auf: Zurückgewonnene Gesteinskörnungen werden bisher überwiegend in Anwendungen mit geringeren Qualitätsanforderungen wie dem Straßen-, Erd- und Deponiebau eingesetzt und lediglich 12,5 Ma.-% des Bedarfs an Gesteinskörnungen konnte 2018 durch Recyclingbaustoffe gedeckt werden (Kreislaufwirtschaft Bau, 2021). Um mehr Primärrohstoffe als bislang in hochwertigen Anwendungen zu substituieren, ist es notwendig, dass Recyclingbaustoffe anwendungsspezifische Anforderungen einhalten und deren Akzeptanz durch konstante Produktqualitäten gestärkt wird (Hinzmann et al., 2019). Ein ausschlaggebendes Qualitätskriterium für Recyclingbaustoffe ist dabei die Korngrößenverteilung (KGV) nach (DIN 66165-1), die im Stand der Technik durch manuelle Siebanalysen bestimmt wird.

Manuelle Siebanalysen sind zeit- und kostenaufwändig, haben eine begrenzte Aussagekraft (abhängig von der Qualität der vorgeschalteten Beprobung) und Analyseergebnisse sind nur mit Zeitverzug verfügbar. Folglich ist es nicht möglich frühzeitig auf Qualitätsveränderungen zu reagieren, noch können Aufbereitungsprozesse auf veränderte Stoffstromeigenschaften angepasst werden. Eine *sensorbasierte Inline-Erfassung* von KGVs würde diese Probleme lösen und neue Anwendungen wie ein automatisiertes Qualitätsmonitoring oder die Voraussetzungen für eine adaptive Prozesssteuerung ermöglichen.

Korngrößen nach (DIN 66165-1) sind nicht nach geometrischen Abmessungen, sondern dem Ergebnis der Prüfsiebung definiert; sie können folglich nicht direkt gemessen werden, sondern bedürfen einer *Vorhersage* basierend auf anderen Partikelmerkmalen. Die sensorbasierte Vorhersage von KGVs wurde bereits für Primärrohstoffe (Gao et al., 2012; Ge et al., 2020; Hussain et al., 2020; Kontry, 2017; Zhang & Liang, 2016), Gewerbeabfall (Kandlbauer et al., 2021) und Ersatzbrennstoffe (Dunnu et al., 2006) untersucht. Für CDW beschränken sich bisherige Studien auf die Vorhersage aus 2D-Haufwerksbildern (Di Maria et al., 2016). Dieser Beitrag untersucht die KGV-Vorhersage für CDW mittels 3D-Lasertriangulation (3DLT) und Machine Learning (ML) Algorithmen, die im Gegensatz zu herkömmlichen Algorithmen nicht explizit programmiert werden müssen, sondern Zusammenhänge aus gegebenen Trainingsdaten lernen (Marsland, 2014).

2 Material und Methode

2.1 Material und Probenvorbereitung

Um stoffstromseitige Einflüsse beurteilen zu können, wurde die Vorhersage von KGVs anhand von primärem Quarzkies ("PRIM", Abb. 1a) und RC-Material aus einer Bauschutt-Aufbereitungsanlage ("RCM", Abb. 1b) untersucht. Zur Erzeugung der Grundwahrheit (Partikelabmessungen und ihre zugehörigen Korngrößen) für Training und Evaluierung der ML-Modelle, wurden beide Proben auf einem Siebturm mit den Siebschnitten 3,15 mm; 4 mm; 5 mm; 6,3 mm; 8 mm; 10 mm; 12,5 mm; 16 mm; 22,4 mm und 31,5 mm für eine Siebdauer von 90 s nach (DIN 66165-1) klassiert. Da insbesondere die KGV des Mineralikanteils von Relevanz ist, wurden in der RCM-Probe enthaltene Fremdstoffe (Glas und Kunststoffpartikel; 0,56 Ma.-% Gesamtanteil) vor der Datenerfassung manuell aussortiert. Die nachfolgenden Untersuchungen fokussieren sich auf die neun Korngrößenklassen (KGVs) im Bereich von 3,15 mm bis 31,5 mm.

2.2 Partikelvermessung und Datensatzerstellung

Die einzelnen KGVs wurden auf einem 3DLT-Messstand mit einer Auflösung von 0,758 mm in z-Richtung und 0,331 mm in x- und y-Richtung vermessen (Abb. 1c). Für jeden Partikel wurden anschließend durch das Python-Modul *imea* (Kroell, 2021) 52 Partikelabmessungen (2D+3D) extrahiert (Abb. 1d). Die finalen Datensätze enthalten die Aufnahmen von insgesamt 78.575 (PRIM) und 102.736 Partikeln (RCM).



Abbildung 1: (a) PRIM- und (b) RCM-Material in den KGVs (i) 3,15 mm – 4 mm, (ii) 4 mm – 5 mm, (iii) 5 mm – 6,3 mm, (iv) 6,3 mm – 8 mm, (v) 8 mm – 10 mm, (vi) 10 mm - 12,5 mm, (vii) 12,5 mm – 16 mm, (viii) 16 mm - 22,4 mm und (ix) 22,4 mm - 31,5 mm; (c) 3DLT-Messstand: A. 3D-Kamera, B. Spiegelkonstruktion, C. Linienlaser, D. Förderband; (d) exemplarische Partikelabmessungen: (I) Minimum 2D-Bounding Box, (II) maximaler Inkreis, (III) Martin-Durchmesser.

2.3 Training und Evaluierung der Machine Learning Regressionsmodelle

Anschließend wurden beide Datensätze jeweils zufällig in 75 % Trainings- und 25 % Testdaten aufgeteilt. Zur Vorhersage der Korngrößen wurden ML-Modelle eingesetzt, die aus den 52 extrahierten Partikelabmessungen (= Modellinput) die sensorisch nicht-messbare Korngröße je Partikel (= Modelloutput) vorhersagen sollen. Die Korngröße je Partikel wurde dabei als der Mittelwert zwischen unterer und oberer KGV-Grenze definiert. Zur Vorhersage wurden lineare (Linear), Partial Least Square (PLS) und Random Forest (RF) Regressionsmodelle auf den Trainingsdaten trainiert. Um optimale Vorhersage-ergebnisse zu erzielen, wurde für jedes Modell eine systematische Hyperparameteroptimierung (GridSearchCV) durchgeführt. Die Modellevaluierung erfolgte auf dem Testdatensatz anhand des R^2 -Scores. Der R^2 -Score gibt an wie sehr vorhergesagte und wahre Korngröße übereinstimmen: Je näher der R^2 -Score an 1 ist, desto präziser ist die Vorhersage.

3 Ergebnisse und Diskussion

3.1 Korrelation zwischen Partikelabmessungen und Korngröße

Die 52 extrahierten Partikelabmessungen korrelieren mit Pearson-Korrelationskoeffizienten (PCC) zwischen 0,655 bis 0,947 (PRIM) und 0,454 bis 0,932 (RCM) insgesamt stark mit der Korngröße (vgl. Beispiele in Abb. 2a). Korrelationskoeffizienten des PRIM-Materials liegen im Mittelwert um 2,0 % höher als die des RCM-Materials, was sich vermutlich auf gleichmäßigere Partikelformen des Primärmaterials zurückführen lässt. Der *volumenäquivalente Durchmesser* korreliert insgesamt am stärksten mit der Korngröße ($PCC_{PRIM} = 0,973$; $PCC_{RCM} = 0,966$) und minimal höher als die am stärksten korrelierende 2D-Abmessung (*mittlerer Martin-Durchmesser*, $PCC_{PRIM} = 0,967$, $PCC_{RCM} = 0,959$). Gleichwohl zeigen sich insbesondere an den Rändern der Korngrößenklassen stärkere Überschneidungen der Partikelabmessungen (Abb. 2b).

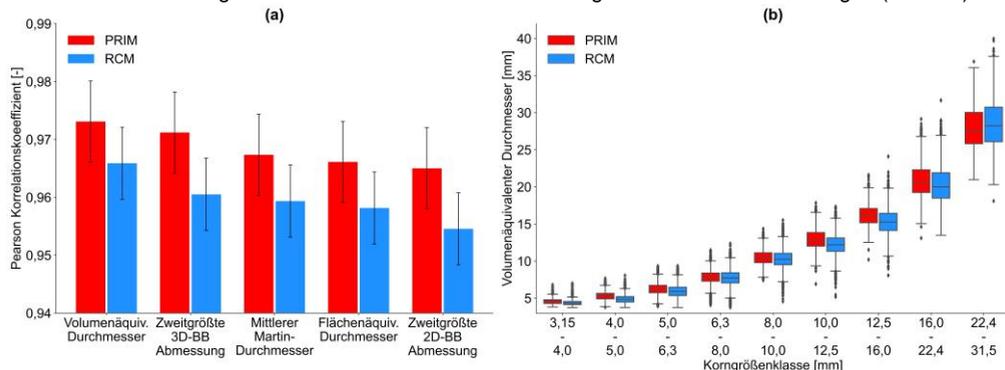


Abbildung 2: (a) Korrelation zwischen Korngröße und ausgewählten Partikelabmessungen; (b) volumenäquivalenter Durchmesser je Korngrößenklasse (Box-Whisker-Plot).

3.2 Vorhersage der Korngröße auf Partikelebene mittels Machine Learning

Die Evaluierung der ML-Modelle auf dem Testdatensatz (Abb. 3a) zeigt, dass eine präzise Vorhersage der Korngröße mit allen drei Modellen möglich ist. Kongruent zu Abschnitt 3.1 zeigt sich im Mittelwert eine etwas präzisere Vorhersage des PRIM-Materials ($R^2 = 0,962$) im Vergleich zum RCM-Material ($R^2 = 0,952$). Die präzisesten Vorhersagen werden durch das RF-Modell erzielt ($R^2_{PRIM} = 0,966$; $R^2_{RCM} = 0,959$).

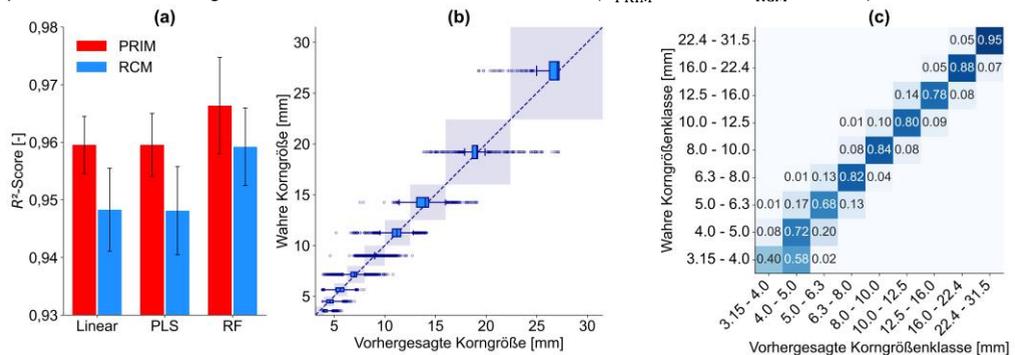


Abbildung 3: (a) Vorhersagegenauigkeit (R^2 -Score) der untersuchten ML-Modelle auf dem Testdatensatz; Vorhergesagte und wahre (b) Korngrößen und (c) Korngrößenklassen des RF-Modells auf dem RCM-Testdatensatz.

Wie in Abb. 3b am Beispiel des RCM-Materials dargestellt, streuen die Vorhersagen des besten Modells (RF) um die mittlere Korngröße je KGK. Während das RF-Modell die Korngrößen in kleinen KGKs eher überschätzt, werden die Korngrößen in größeren KGKs eher unterschätzt. Die Zuordnung der vorhergesagten Korngrößen zu KGKs (Abb. 3c) zeigt, dass die KGK in 72,1 % der Fälle korrekt vorhergesagt wird. Falsche Vorhersagen treten insbesondere zur nächstgrößeren oder nächstkleineren KGK auf, was vermutlich auf die Überlagerung an KGK-Grenzen (vgl. Abb. 2b) zurückführen ist.

3.3 Aggregation auf Stoffstromebene und Vorhersage von Korngrößenverteilungen

Mittels Approximation der Partikelmassen durch die gemessenen 3DLT-Partikelvolumina lassen sich die vorhergesagten Korngrößen in KGVs überführen, wie in Abb. 4 exemplarisch für zwei KGVs dargestellt. Ein Abgleich der wahren mit den vorhergesagten KGVs zeigt eine große Übereinstimmung für beide Stoffströme mit einer mittleren Abweichung von $\pm 1,4$ Ma.-% und einem R^2 -Wert von 0,996. Die hohe Vorhersagegenauigkeit lässt schlussfolgern, dass Abweichungen um wenige KGKs auf Partikelebene durch Zusammenfassung der Partikel zu KGKs auf Stoffstromebene ausgeglichen werden können.

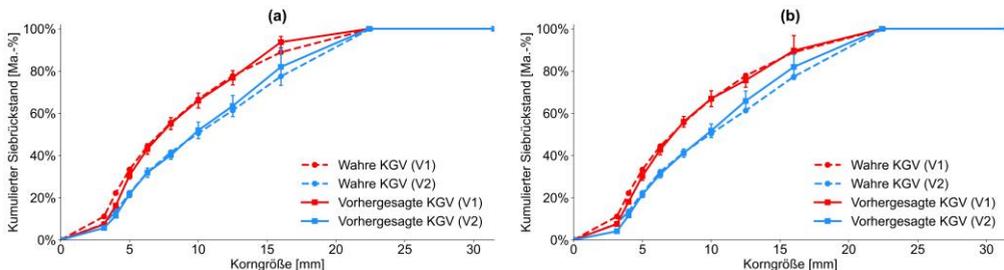


Abbildung 4: Vorhergesagte und wahre KGVs für das (a) PRIM- und (b) RCM-Material; V1: Gleichverteilte KGV (gleiche Massenanteile je Kornklasse), V2: KGV Ursprungsprobe; Fehlerbalken: 95 %-Konfidenzintervall.

4 Zusammenfassung und Ausblick

Zusammenfassend zeigt sich eine starke Korrelation zwischen extrahierten Partikelabmessungen und der Korngröße, die eine präzise Vorhersage der Korngröße auf Partikelebene ermöglicht ($R^2 > 0,95$). Durch die Kombination aus 3DLT-Sensorik und ML wird es dadurch möglich KGVs mit hoher Genauigkeit ($R^2 > 0,99$) im Labormaßstab vorherzusagen. Nichtsdestotrotz sind weitere Entwicklungsschritte notwendig, um die gezeigte technische Machbarkeit in realen Anwendungen im Anlagenmaßstab zu überführen.

In weiterer Forschung erscheint die Korngrößenvorhersage mittels Convolutional Neural Networks (CNNs) vielversprechend, da CNNs Vorhersagen anhand der ursprünglichen 3DLT-Daten statt extrahierter Partikelabmessungen ermöglichen. Ein weiteres Optimierungspotential besteht in der Umwandlung von vorhergesagten Korngrößen zu KGVs, indem Partikelmassen nicht über das Partikelvolumen approximiert, sondern mittels ML vorhergesagt werden (vgl. [Kroell et al., 2021]).

Im Anlagenmaßstab stellt sich die Herausforderung den Stoffstrom als vereinzelte Monoschicht der Sensoreinheit zu präsentieren, was in bisherigen CDW-Aufbereitungsprozessen i. d. R. nicht erforderlich bzw. üblich ist. Hier könnten angepasste Segmentierungsalgorithmen untersucht werden, die eine KGV-Vorhersage auch bei teilweiser oder fehlender Materialvereinzelung ermöglichen könnten. Gelingt die CDW-Stoffstromcharakterisierung im Anlagenmaßstab, so stellt die Nutzung der gewonnenen Stoffstromdaten zur adaptiven, d. h. an ändernde Stoffstromeigenschaften angepasste, Prozesssteuerung den nächsten Schritt dar um auch bei schwankenden Inputzusammensetzungen Recyclingbaustoffe in hoher Qualität zu gewinnen, deren Akzeptanz zu steigern und größere ökologische Vorteile zu erzielen.

Danksagung

Wir bedanken uns bei der MAV Krefeld GmbH für die Bereitstellung des RCM-Probenmaterials.

Literatur/Quellen

- Di Maria, F., Bianconi, F., Micale, C., Baglioni, S. & Marionni, M. (2016). Quality assessment for recycling aggregates from construction and demolition waste: An image-based approach for particle size estimation. *Waste management (New York, N.Y.)*, 48, 344–352. <https://doi.org/10.1016/j.wasman.2015.12.005>
- Dunnu, G., Hilber, T. & Schnell, U. (2006). Advanced Size Measurements and Aerodynamic Classification of Solid Recovered Fuel Particles. *Energy & Fuels*, 20(4), 1685–1690. <https://doi.org/10.1021/ef0600457>
- Gao, L., Yan, Y. & Lu, G. (2012). On-line measurement of particle size distribution using piezoelectric sensors. In *2012 IEEE International Instrumentation and Measurement Technology Conference Proceedings* (S. 1154–1158). IEEE. <https://doi.org/10.1109/I2MTC.2012.6229391>
- Ge, Y., Lin, Z., Tang, H., Zhong, P. & Cao, B. (2020). Measurement of Particle Size of Loose Accumulation Based on Alpha Shapes (AS) and Hill Climbing-Region Growing (HC-RG) Algorithms. *Sensors (Basel, Switzerland)*, 20(3). <https://doi.org/10.3390/s20030883>
- Hinzmann, M., Araujo Sosa, A. & Hirschnitz-Garbers, M. (2019). *Stärkung der Kreislaufführung von mineralischen Baustoffen mittels freiwilliger Selbstverpflichtung - Akteursperspektiven auf Bedarfe und Optionen: Akteursanalyse im Projekt Ressourcenpolitik 2 (PolRess 2)*. <https://www.ecologic.eu/sites/default/files/publication/2019/2583-hinzmann-araujo-hirschnitz-garbers-2019-akteursanalyse-baustoffstektor.pdf>
- Hussain, R., Alican Noyan, M., Woyessa, G., Retamal Marín, R. R., Antonio Martinez, P., Mahdi, F. M., Finazzi, V., Hazlehurst, T. A., Hunter, T. N., Coll, T., Stintz, M., Muller, F., Chalkias, G. & Pruneri, V. (2020). An ultra-compact particle size analyser using a CMOS image sensor and machine learning. *Light, science & applications*, 9, 21. <https://doi.org/10.1038/s41377-020-0255-6>
- Kandlbauer, L., Khodier, K., Ninevski, D. & Sarc, R. (2021). Sensor-based Particle Size Determination of Shredded Mixed Commercial Waste based on two-dimensional Images. *Waste management (New York, N.Y.)*, 120, 784–794. <https://doi.org/10.1016/j.wasman.2020.11.003>
- Kontny, M. (2017). Machine vision methods for estimation of size distribution of aggregate transported on conveyor belts. *Vibroengineering PROCEDIA*, 13, 296–300. <https://doi.org/10.21595/vp.2017.19151>
- Kreislaufwirtschaft Bau. (2021). *Mineralische Bauabfälle Monitoring 2018: Bericht zum Aufkommen und zum Verbleib mineralischer Bauabfälle im Jahr 2018*. Berlin. <https://kreislaufwirtschaft-bau.de/Arge/Bericht-12.pdf>
- Kroell, N. (2021). imea: A Python package for extracting 2D and 3D shape measurements from images. *Journal of Open Source Software*, 6(60), 3091. <https://doi.org/10.21105/joss.03091>
- Kroell, N., Chen, X., Maghroumi, A., Koenig, M., Feil, A. & Greiff, K. (2021). Sensor-based particle mass prediction of lightweight packaging waste using machine learning algorithms. *Waste management (New York, N.Y.)*, 136, 253–265. <https://doi.org/10.1016/j.wasman.2021.10.017>
- Marsland, S. (2014). *Machine Learning: An Algorithmic Perspective, Second Edition* (2nd ed.). CRC Press.
- DIN 66165-1 (2016). *Partikelgrößenanalyse – Siebanalyse: Teil 1: Grundlagen*. Berlin. Deutsches Institut für Normung e. V.
- Simion, I. M., Fortuna, M. E., Bonoli, A. & Gavrilesco, M. (2013). Comparing environmental impacts of natural inert and recycled construction and demolition waste processing using LCA. *Journal of Environmental Engineering and Landscape Management*, 21(4), 273–287. <https://doi.org/10.3846/16486897.2013.852558>
- Statistisches Bundesamt (Hrsg.). (2021). *Abfallbilanz 2019: (Abfallaufkommen/-verbleib, Abfallintensität, Abfallaufkommen nach Wirtschaftszweigen)*. https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Umwelt/Abfallwirtschaft/Publikationen/Downloads-Abfallwirtschaft/abfallbilanz-pdf-5321001.pdf?__blob=publicationFile

Wang, B., Yan, L., Fu, Q. & Kasal, B. (2021). A Comprehensive Review on Recycled Aggregate and Recycled Aggregate Concrete. *Resources, Conservation and Recycling*, 171, 105565. <https://doi.org/10.1016/j.resconrec.2021.105565>

Zhang, Y. & Liang, Y. (2016). Research on soft-sensor based on support vector regression for particle size of grinding and classification process. In *2016 Chinese Control and Decision Conference (CCDC)* (S. 6708–6713). IEEE. <https://doi.org/10.1109/CCDC.2016.7532204>

Kontakt

Nils Kroell, M. Sc., Wissenschaftlicher Mitarbeiter

Institut für Anthropogene Stoffkreisläufe, RWTH Aachen University

Tel.-Nr. +49 241 80-99343

E-Mail: nils.kroell@ants.rwth-aachen.de

Homepage: www.ants.rwth-aachen.de