



## [ Jun.-Prof. Dr. Jan Stühmer // Maschinelles Lernen und Künstliche Intelligenz ]

Jan Stühmer ist seit 2022 Juniorprofessor am Institut für Anthropomatik und Robotik sowie Gruppenleiter am Heidelberger Institut für Theoretische Studien der Klaus Tschira Stiftung. Dort leitet er die Forschungsgruppe für Maschinelles Lernen und Künstliche Intelligenz. Seine Kernforschungsgebiete liegen im Bereich von dateneffizienten Lernverfahren und interpretierbaren Repräsentationen.

Er schloss 2010 sein Studium der Informatik an der TU Dresden ab und promovierte 2016 an der TU München. Während der Promotion verbrachte er einen Forschungsaufenthalt am California Institute of Technology (Caltech). Im Anschluss an die Promotion ging er als Gastwissenschaftler an das Computer Science and Artificial Intelligence Laboratory am Massachusetts Institute of Technology (MIT CSAIL) bevor er zunächst als PostDoc, dann als Researcher bei Microsoft Research Cambridge, UK und dem Microsoft MR&AI Lab in Zürich tätig wurde. Im Anschluss wechselte er 2020 zu Samsung AI in Cambridge.

120

### // Überblick und Allgemeines

**Die im Aufbau befindliche Forschungsgruppe für Maschinelles Lernen und künstliche Intelligenz beschäftigt sich mit der Entwicklung von neuartigen Algorithmen und Lernverfahren des maschinellen Lernens.** Hierbei besteht insbesondere der Fokus auf dateneffizienten Lernverfahren, sowie der Entwicklung von Algorithmen für bessere Generalisierbarkeit und interpretierbare Repräsentationen.

Methoden des maschinellen Lernens und insbesondere Verfahren des Deep

Learnings haben in den letzten Jahren große Durchbrüche in vielfältigen Anwendungsbereichen erzielt. Dabei setzt insbesondere das Deep Learning jedoch große Datenmengen für das Training der Modelle voraus. Solche großen Datenmengen sind nicht in jedem Anwendungsfall verfügbar, und das Erstellen eines Trainingsdatensatzes ist oft mit einem großen Zeit- und Kostenaufwand verbunden. Dies führt zu einer verringerten Verfügbarkeit dieser maschinellen Lernverfahren und zu einer großen Einstiegshürde für ihre Verwendung.

Die in der Forschungsgruppe entwickelten Methoden des dateneffizienten Lernens erlauben es, ein Modell welches zum Beispiel an einem großen Standarddatensatz vortrainiert wurde, an eine neuartige Anwendung anzupassen. Dabei kann der Datensatz, der für dieses sogenannte „Fine-Tuning“ verwendet wird, oftmals deutlich kleiner sein, als es ohne ein Vortrainieren des Modells möglich wäre. Ein Forschungsschwerpunkt der Arbeitsgruppe besteht insbesondere darin, Lernverfahren zu entwickeln, welche zu Modellen mit besserer Generalisierbarkeit führen. Hierdurch kann ein Modell an einem sehr kleinen Datensatz einer speziellen Domäne angepasst werden, ohne dass danach ein zu großer Fehler in der praktischen Verwendung zu erwarten ist. Dabei werden Erkenntnisse aus der Lerntheorie mit Verfahren der konvexen und nicht-konvexen Optimie-

nung kombiniert. Durch die Lerntheorie lässt sich beschreiben, welche Eigenschaften das Modell nach dem Training haben sollte. Hieraus können dann Nebenbedingungen für das Trainieren des Modells abgeleitet werden.

Ein weiterer Schwerpunkt der Arbeitsgruppe sind interpretierbare Repräsentationen. Das Ziel ist zum einen, die Modelle interpretierbar und somit besser verständlich zu machen, zum anderen können mit diesen Verfahren grundlegende Zusammenhänge in Daten veranschaulicht werden. So können mit entsprechend zugeschnittenen Lernalgorithmen die zugrunde liegenden Faktoren und teilweise sogar Modelle der kausalen Zusammenhänge von beobachteten Daten abgeleitet werden. Insbesondere in den Naturwissenschaften ergeben sich dadurch interessante Anwendungen, verständliche Modelle von Daten abzuleiten. Zum Einsatz kommen hierbei Techniken der variationellen Inferenz, statistische Verfahren um unabhängige Komponenten und Faktoren abzuleiten, sowie Graph-Neural-Networks.

### // Ausgewählte Publikationen

S.X. Hu, D. Li, J. Stühmer, M. Kim, T.M. Hospedales. Pushing the Limits of Simple Pipelines for Few-Shot Learning: External Data and Fine-Tuning Make a Difference. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022.

M.M. Negri, V. Fortuin, J. Stühmer. Meta-learning richer priors for VAEs. Fourth Symposium on Advances in Approximate Bayesian Inference, 2021.

J. Stühmer, R. Turner, S. Nowozin. Independent subspace analysis for unsupervised learning of disentangled representations. International Conference on Artificial Intelligence and Statistics (AISTATS), 2020.

N. Stöhr, E. Yilmaz, M. Brockschmidt, J. Stühmer. Disentangling Interpretable Generative Parameters of Random and Real-World Graphs. NeurIPS Workshop on Graph Representation Learning, 2019.

J. Stühmer, P. Schröder, D. Cremers. Tree Shape Priors with Connectivity Constraints using Convex Relaxation on General Graphs. IEEE International Conference on Computer Vision (ICCV), 2013.

J. Stühmer, S. Gumhold, D. Cremers. Real-time dense geometry from a handheld camera. Joint Pattern Recognition Symposium, 2010.

### // Website

[www.h-its.org/research/mli/](http://www.h-its.org/research/mli/)