

Machine Learning in der Materialmikroskopie

Andreas Jansche, Olatomiwa Badmos, Amit-Kumar Choudhary, Florian Trier,
David Vogelgsang, Andreas Kopp, Timo Bernthaler, Gerhard Schneider

Institut für Materialforschung, Hochschule Aalen

<mailto:andreas.jansche@hs-aalen.de>

Der Einsatz von Machine Learning in der Materialmikroskopie – etwa zur Segmentierung von Gefügebildern, dem Detektieren von Defekten und Inhomogenitäten oder der Vorhersage von Materialeigenschaften – bietet großes Potential für Automatisierung und Reproduzierbarkeit bei der Quantitativen Gefügeanalyse.

1 Einführung

Immer höher auflösende bildgebende Verfahren, wachsende Datensätze und zunehmende Rechenleistung fordern der Quantitativen Gefügeanalyse (QGA) immer mehr ab, erlauben aber gleichzeitig eine immer effizientere Quantifizierung von Gefügen und Feingeometrien. Zur Untersuchung komplex aufgebauten oder auch inhomogener Gefüge helfen intelligente Bildverarbeitungsansätze. Die genutzten Verfahren in der klassischen QGA – meist Variationen manueller oder adaptiver Schwellwertsegmentierung – scheitern oft bei der Differenzierung optisch ähnlicher Phasen im Material. Machine Learning (ML) zur Segmentierung und Klassifikation bestimmter Gefügetypen, der Defektanalyse, sowie der Vorhersage von Materialeigenschaften aus Gefügebildern bietet hier hohes Potential. ML kann helfen Auswertungen zu automatisieren und reproduzierbar zu gestalten, die Robustheit gegen Störeinflüsse wie etwa Shading erhöhen oder Auswertungen, an denen klassische Verfahren scheitern, überhaupt erst ermöglichen.

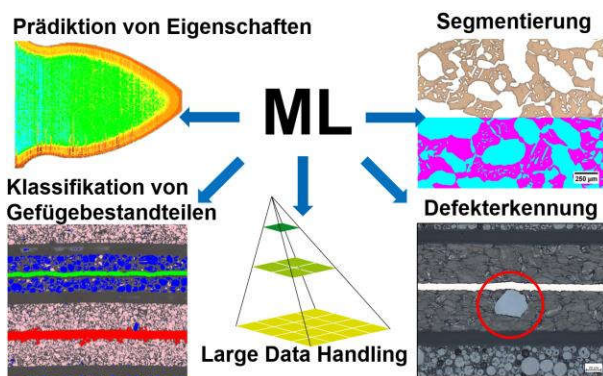


Abb. 1 Übersicht über mögliche Anwendungen von ML in der Materialmikroskopie. Die Verarbeitung großer Datenmengen ist in den meisten Fällen ein begleitendes Thema.

An den Beispielen von Stahl, Sintermaterialien, Li-Ionen-Batterien sowie Magneten wird der Einsatz von ML in diesem Beitrag dargestellt. Spezifisch zur

Ermittlung der Stahlhärte trainierte Modelle ermöglichen die Härtebestimmung aus dem Gefüge. Außerdem wird ML für die Qualitätsbewertung großformatiger prismatischer Li-Ionen Batterien angewandt. Anhand der Magnetmaterialien wird aufgezeigt wie die sog. korrelative Mikroskopie in Kombination mit Machine Learning eine zuverlässigere Segmentierung von Gefügebildern mit optisch ähnlichen Phasen ermöglicht.

2 Robuste Multiphasensegmentierung als Klassifikationsproblem

Die Segmentierung einzelner Phasen in einem Gefügebild ist ein essentieller Schritt bei der Quantitativen Gefügeanalyse und muss daher so genau und reproduzierbar wie möglich sein. Manuelle Verfahren sind hierbei sehr anfällig gegenüber Nutzereinfluss sowie für jegliche Schwankungen während der Aufnahme (wie etwa Unterschiede in Helligkeit und Kontrast). Adaptive Schwellwertverfahren sind hier deutlich robuster, liefern aber spätestens bei Shading-Effekten – also einer inhomogenen Ausleuchtung im Bild – keine korrekten Ergebnisse mehr, da sich die Grauwertintensitäten der verschiedenen Phasen im Bild über den Bildausschnitt hinweg nicht mehr korrekt differenzieren lassen. Auch Phasen, welche sich im Bild sehr ähnlich darstellen, also sehr ähnliche Grauwertverteilungen oder nur sehr geringe farbliche Unterschiede aufweisen (vgl. Abb. 2), lassen sich so kaum segmentieren. Ein Lösungsansatz, der im Hinblick auf derartige Störeinflüsse deutlicher robuster ist, ist eine ML-basierte pixelweise Klassifikation zur Segmentierung der Bilder (wie beispielsweise in [1] schon für die Anwendung Li-Ionen Zellen beschrieben). Auch für herausfordernde Gefüge reicht es hier oftmals aus lediglich die drei Farbkanäle aus RGB-Bildern als Merkmale zur Klassifikation zu verwenden. Es sind also nicht immer komplexe Modelle wie Convolutional Neural Networks nötig, obwohl auch diese sich mittlerweile mit einer moderaten Menge an Trainingsbeispielen trainieren lassen. [2]




Abb. 2 Multiphasensegmentierung an einer Magnetlegierung mittels ML. Links: Poren und Oxide lassen sich unter dem Lichtmikroskop nur schwer unterscheiden. Mitte/Rechts: Segmentierung als Klassifikationsproblem mit sieben Klassen (= Phasen) und drei Merkmalen. Korrelative Mikroskopie hilft beim Annotieren der Daten durch bessere Unterscheidung von Poren und Oxiden im Rasterelektronenmikroskop.

3 Erkennung von Defekten, Inhomogenitäten und Ungängen in Li-Ionen Batterien

Die lichtmikroskopische Untersuchung von Li-Ionen Zellen ermöglicht es verschiedene Defekte und Ungängen sichtbar zu machen und stellt so ein wichtiges Werkzeug in der Qualitätssicherung der Zellen dar. ML ermöglicht es die Suche nach solchen Auffälligkeiten in den Zellen zu automatisieren. Ein binärer Klassifikator kann hierzu beispielsweise mit Texturparametern trainiert werden, welche für jeden Bildausschnitt berechnet werden. Die Bildausschnitte selbst sind dabei mit der Information annotiert, ob sich darin ein Defekt befindet oder nicht. [1]




Abb. 3 Beispiele für detektierte Fremdeinschlüsse in Anoden einer prismatischen Li-Ionen Zelle. Rot markiert sind die Bildbereiche, die der Klassifikator auf Basis von Texturparametern als „NOK“ (= „Nicht OK“) bewertet hat. In linken Bild ist zudem eine Fehldetektion zu sehen.

4 Härtebestimmung von Stahl aus dem lichtmikroskopischen Gefügebild mittels Texturparametern und künstlichen neuronalen Netzen

Die Messung der Härte eines Materials durch Einbringung und Vermessung eines Härteeindrucks in die Probe ist zeitaufwändig und nur bedingt zerstörungsfrei. Von Fuchs et al. wurde deshalb bereits 2001 ein Ansatz zur Prädiktion der Härte auf Basis von Haralick-Parametern vorgestellt. [3][4] Hierbei wird ein künstliches neuronales Netz darauf trainiert für die Eingabe der Haralick-Parameter die Härte für den Bildbereich vorherzusagen. Als Trainingsdaten dienen Gefügebilder mit der dazu gemessenen Härte. Erweitert man die Merkmale zur Klassifikation um Morphologieparameter, lässt sich die Genauigkeit der Vorhersagen weiter steigern.

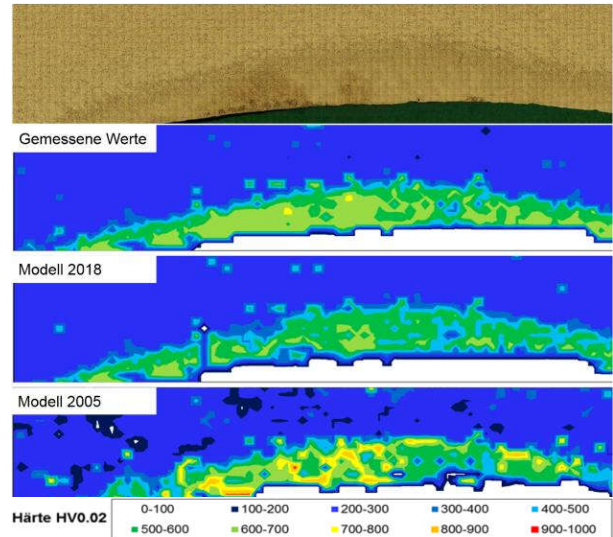


Abb. 4 Prädiktion von Stahlhärte mittels Texturparametern. Von oben nach unten: großflächiges Gefügebild; gemessene Härtewerte; Prädiktion mit Textur- und Morphologieparametern; Prädiktion mit Texturparametern.

5 Ausblick

ML kann schon jetzt einen deutlichen Mehrwert für die Quantitative Gefügeanalyse liefern. Die vorgestellten Ansätze können durch die Auswahl weiterer und/oder besserer Merkmale (z.B. Texturinformationen bei der Segmentierung) auf Genauigkeit und mittels Feature Engineering auch auf Performanz hin optimiert werden. Deep Convolutional Neural Networks versprechen gerade in der bildanalytischen Auswertung weitere Möglichkeiten zu eröffnen, da sie selbstständig lernen für die Problemstellung relevante Merkmale zu extrahieren.

Literatur

- [1] A. Jansche, F. Trier, A. Kopp, P. Schirle, T. Bernthaler, U. Klauck, G. Schneider: „Maschinelles Lernen zur Quantifizierung und Defekterkennung an lichtmikroskopischen Bildern prismatischer Li-Ionen Zellen“, Tagungsband des 22 Workshop Farbbildverarbeitung 2016 in Ilmenau, 61–74 (2016)
- [2] O. Ronneberger, P. Fischer, T. Brox: „U-Net: Convolutional Networks for Biomedical Image Segmentation“, Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, LNCS, Vol.9351: 234–241, 2015
- [3] A. Fuchs, T. Bernthaler, B. Stahl, U. Klauck, B. Reinsch, G. Schneider: „Bildanalyse komplexer Werkstoffgefüge durch Texturanalyse und Korrelation mit den Eigenschaften durch neuronale Netze“, Zeitschrift für Metallkunde, Vol. 92, 8, 979–985 (2001)
- [4] R. M. Haralick, K. Shanmugam, I. Dinstein: „Textural Features for Image Classification“, IEEE Transactions on Systems, Man, and Cybernetics, Vol. 3, 6, 610–621 (1973)