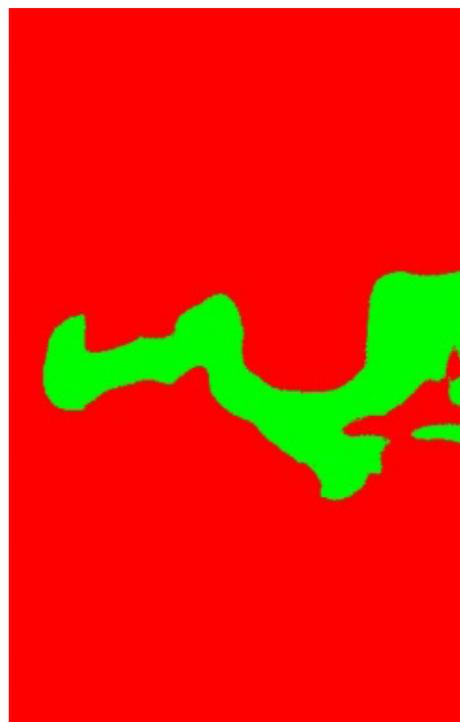
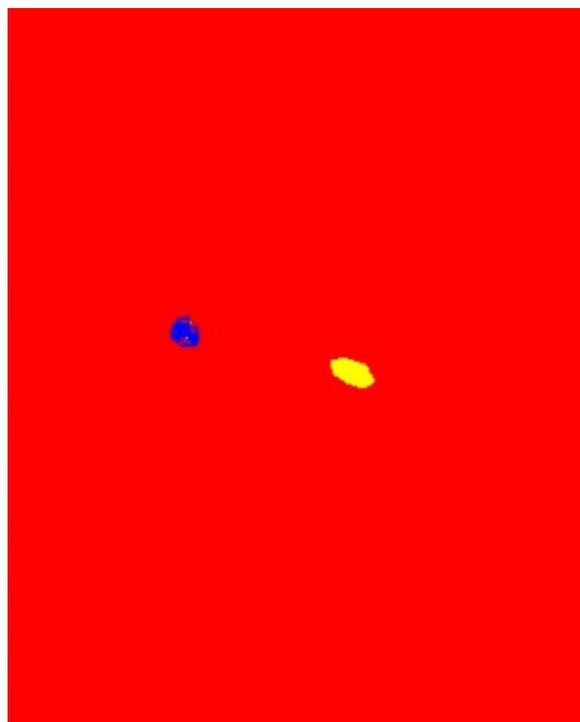
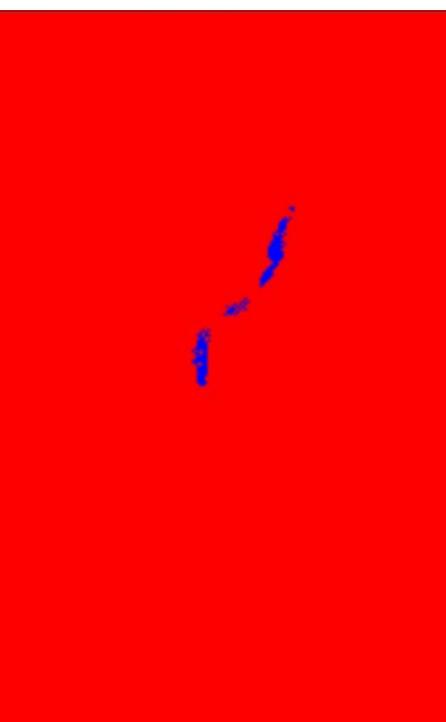


## 積層造形製合金の金属介在物のソフトウェアを使ったセグメンテーション - 微細構造と材料特性の関連性



本書では、人工知能（AI）に基づく高度な画像解析技術が、金属合金中の介在物のセグメンテーションにどのように使われているかを紹介します。プリントされた軽量の高温アルミニウム合金の微細構造（特にその介在物）を、光学顕微鏡と電子顕微鏡で得られた観察結果を結び付けるマルチモーダルな手法で特性評価します。この実験では、画像処理ソフトウェアとして ZEISS ZEN Intellesis (ZEN core の AI ツールキットのモジュール) と ZEISS arivis Cloud を使用しました。

## はじめに

材料の特性とその微細構造、さらにはナノ構造の関連性を深く理解することは、新しい材料を開発する上で不可欠です。そのため、微細構造解析の分野では、画像のセグメンテーションと解析に機械学習（ML）を導入することが非常に有効です。本研究では、堅牢で安定した ML システムが、積層造形で生成された高耐熱性アルミニウム合金の介在物の特性評価にどのように使用されているかを紹介します。光学・電子相関顕微鏡では ML のセグメンテーショントレーニングに欠かせない有意義なデータが得られ、その結果、積層造形工程で生成された介在物を定量的に同定することができます。

## アルミニウム合金

アルミニウム（Al）合金は、軽量で高強度という特性から、自動車および航空宇宙産業で広く使われています。航空機の構造重量の 70% はアルミニウム合金が占め、主に主翼や胴体などに使用されています。しかし、この分野では 200℃、あるいは 300℃ 以上の高温に耐えられる材料が求められます。従来のアルミニウム合金は、一般に 200℃ を超えると強度が著しく低下します。これまで、300℃ にまで及ぶ耐熱性は、Al-Si-(Mg) などの従来の高耐熱性合金でしか達成されていません。そのため、この特性をアルミニウム合金にも拡張することに大きな関心が寄せられています。



図 1: 高耐熱性アルミニウム合金を使用した主翼と胴体

## アルミニウム合金の積層造形

レーザーを用いたアルミニウム合金の積層造形は、短期で少量部品や試作品の製造が求められる自動車産業や航空宇宙産業の研究開発に最適な技術です。さらに、この技術により複雑な部品の設計（格子生成やトポグラフィ最適化など）が可能のため、他の手法では達成できないさらなる軽量化を実現することができます。とりわけ、粉末を用いた積層造形はアルミニウム合金に多く用いられています。最近では、欠陥のない部品を造形できるようになり、AM 分野における大きな進歩が期待されています。また、アルミニウム合金の造形性を考慮すると、従来の Al-Si-(Mg) 合金に比べてさらに高温耐性に優れた他の合金でも造形が可能だと考えられています。また AM に適した、軽量かつ高温（300℃ 以上）に耐え得る機械的安全性を備えた前駆体の新システムを導入することを目的とした研究が進められています [1]。

## 微細構造と機械的特性の関連性

微細構造設計を使用して、機械的特性に影響を与えることができます。その好例が、熱的に安定した強化相（HTPSA）を有する析出強化型合金です。ナノメートルサイズの強化相を持つ HTPSA は、鋳造の分野ではよく知られています。なお、この強化相は最高 400℃ の耐粗化性があり、合金元素の付加により顕著な強度と耐クリープ性を発揮します。ただ、AM 工程自体や一般的な粒成長関連工程によって形成される、他の微細構造を見つけなければなりません。しかし、この材料の機械的特性や性能には、そのどちらもが関係しています。Michi et al. (2021) は、AM アルミニウム合金の高温での疲労亀裂のきっかけに関連する様々な微細構造の特徴（表面付近の多孔率、融合欠陥の欠如、介在物と硬質粒子、表面粗さ、持続性滑り帯、および溶融プール境界）を概説しています [2]。また、本研究では多孔と介在物に焦点を当てています。



図 2: 積層造形製高温 Al 合金断面の SEM 像。微細構造が確認できる

## セグメンテーション

微細構造の定量的解析において最も重要なステップの1つは、顕微鏡画像のセグメンテーションですが、依然としてあまり着目されていません。セグメンテーションには、古典的でよく知られた単純なヒストグラム閾値処理から、ディープラーニングによって強化された従来の機械学習を利用した手法まで、様々なものがあります。近年、ディープラーニングは、特に煩雑な背景画像に対して、物体のセグメンテーションを非常に効率的に行えることが実証されています。機械学習を活用したこれらの大きな進歩は、とりわけ金属の研究や、産業界で普及している古典的な閾値セグメンテーションと比較すると、データ品質を大幅に改善できる可能性を秘めています [3]。具体的なアプローチはアプリケーションの複雑さによって異なるため、本研究では、AM アルミニウム合金の金属介在物に適用されるセグメンテーションワークフローを紹介します。

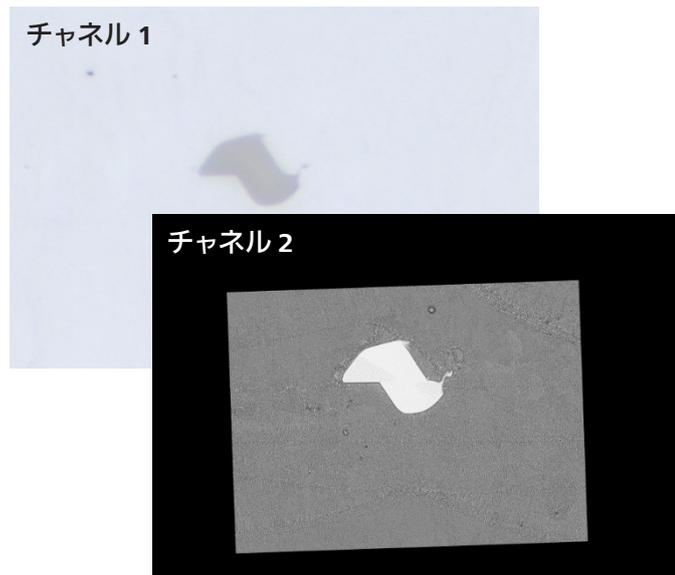
## 機械学習とは

機械学習とは、コンピュータに特定のタスク（この場合は画像セグメンテーション）を明示的にプログラムすることなく、コンピュータが自ら学習してそのタスクを達成する能力のことです。ディープラーニングは機械学習の一種です。ディープラーニングの強みは、トレーニングした人工のニューラルネットワークを通してデータ表現を特定することにあります。タスクの複雑さによって、それを解決するのに必要なトレーニングレベルと人工知能の程度が決まります。



図 3: ディープラーニングは一般的な機械学習の特殊なサブセットであり、人工知能のサブセットでもある

**材料科学における機械学習に基づくセグメンテーション**  
 セグメンテーションは、その後すべての定量的画像解析の基礎となるため、画像解析ワークフローの中で最も重要な要素です。まず、ソフトウェアベースの機械学習により、アルミニウム合金中の介在物のセグメンテーションモデルをトレーニングさせます。この目的は、顕微鏡画像上の様々な物体（この場合は、気孔、Zr-In 包有物、酸化物包有物、試料調製時の汚れ）を同定することです。ここで使用したソフトウェアソリューションは、画像処理ソフトウェア ZEISS ZEN core のモジュールである ZEISS ZEN Intellesis Segmentation です。



ZEN Intellesis Segmentation は、両チャンネルを考慮したセグメンテーションモデルのトレーニングに使用されます。セグメンテーションの結果は、個々の二値画像マスクに分割することができます。

#### チャンネル

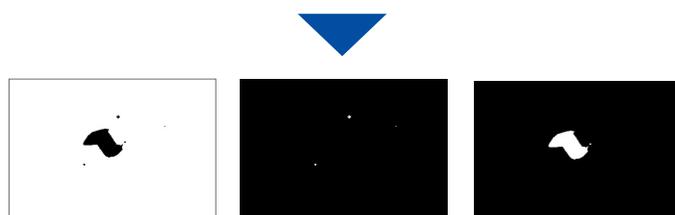
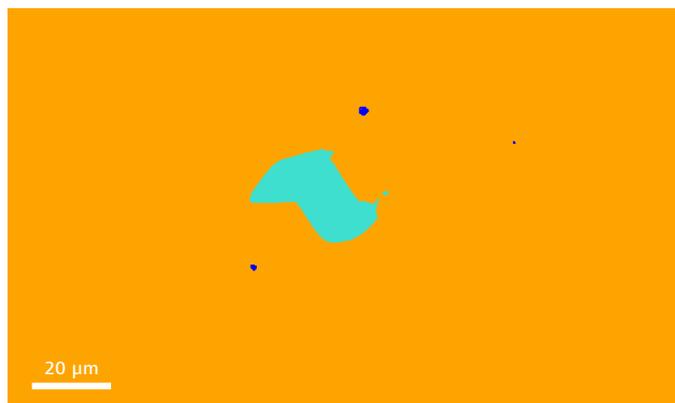


図 4: 2 つの顕微鏡モダリティ（「チャンネル」）の情報を利用したセグメンテーション: 光学顕微鏡 (LM) 画像と走査電子顕微鏡 (SEM) で取得した EDS マップ

この手法の強みは、一枚の画像に対してセグメンテーションモデルをトレーニングさせるだけで、同様の実験条件で撮影した他の画像のピクセルラベルを予測できる点です (図 4)。その後、セグメンテーションの結果を専門家が判断する必要があります。機械学習モデルは、経験豊富な顕微鏡技師が選んだ画像内のピクセルに対してトレーニングします。まず、ユーザーがマウスを数回クリックして、画像内の様々な（異なるクラスに関連付けられている）ピクセルをラベル付けします。これにより、ラベリング工程におけるユーザーの体験が活用され、正解データに到達できます [5]。今回の実験では、走査型電子顕微鏡で取得した光学顕微鏡画像と EDS マップをモデルのトレーニングベースとしました。また、両方のチャンネルの情報を活用することで補完情報にアクセスでき、セグメンテーションの精度が向上します。さらに、単一チャンネルのデータと比べて、結果として得られるセグメンテーションをトレーニングする必要があまりないことも利点の 1 つです。

EDS および SEM データに基づく知識は、ワークフローが完成した後、最初に取得した LM 画像のインスタンスをセグメンテーションするのに使用されます。ワークフローは次の 3 つのステップで構成されています。

- 1) SEM および LM 画像に基づく ML セグメンテーションにより、二値の画像マスクが生成される
- 2) スマートラベリングが、インスタンスのセグメンテーションのためにトレーニングしたディープラーニング用の画像マスクを使用する
- 3) トレーニングしたモデルを使用して、LM 画像上の異なるインスタンスを同定する

## 合金中の介在物を同定するためのワークフロー

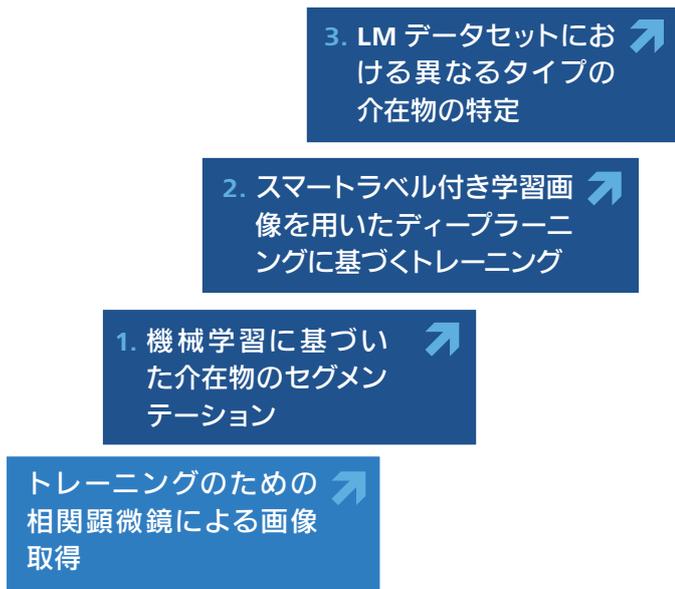


図 5: 合金中の介在物を同定するためのワークフロー。LM データセットを取得し、一連の機械学習とディープラーニングを経た後に、介在物が自動的に同定可能になります。

まず、インスタンスを気孔や Zr-In 介在物などの様々なオブジェクトとしてラベル付けします。画像解析では、これらのオブジェクトは 1 つのカテゴリのインスタンスとして扱われます。2 つ目のステップでは、様々な種類の介在物を認識するために、これらのオブジェクトをセグメンテーションします。機械学習だけではこの作業を行うのに不十分なため、ディープラーニングに基づくセグメンテーションを追加する必要があります。最終的な結果は、LM 画像の異なる介在物を同定するのに使用されます。

### ディープラーニングに基づく画像セグメンテーション - 様々なオブジェクトのセグメンテーション

ディープラーニングに基づく手法は、微細構造の分類に適用され、画像分類問題の解決において優れたパフォーマンスを発揮します。これらの手法は、有意義な結果を得るために、通常、事前に手動でラベル付けされたいくつかのデータセットを必要とします。ここでは、機械学習を用いてピクセル単位の画像セグメンテーションを行うことで、正確でスマートなセグメンテーションラベルを使用できるという利点があるだけでなく、複数の画像でモデルをトレーニングする必要性も省かれています。

## 説明

トレーニングを行ったモデルが LM 画像に使用されます。事前に定義されたクラスに基づいて、LM データセット内の様々な材料介在物や気孔率を同定することができます。

スマートラベル付きのデータを使用することで、わずかに数枚の画像でディープラーニングが可能になります。追加の EDS 情報は、異なる材料の介在物または、気孔率をオブジェクトとして分類するのに使用されます。

LM 画像に対して機械学習を行い、介在物の正確なセグメンテーションのためのモデルをトレーニングします。追加の SEM 画像は、トレーニング結果とプロセスの最適化に役立ちます。

複数の介在物が存在する広い領域を特定し、LM でイメージングします。相関顕微鏡により、SEM でその介在物を再配置することができます。

一連の機械学習とディープラーニングを経た後に、介在物が自動的に同定可能に

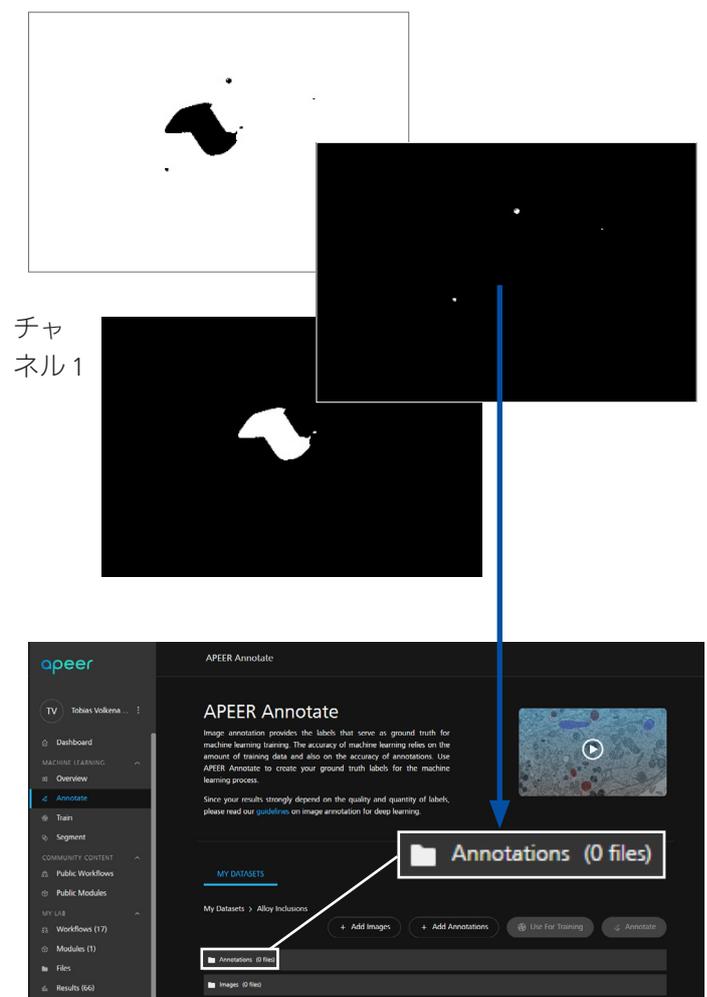


図 6: スマートラベリング - Intellesis でセグメンテーションされたラベルを使用して、arivis Cloud でディープラーニングモデルをトレーニング

特殊なケースとして、特定のディープラーニングアルゴリズムでは複雑すぎて対応できない画像があります。このような場合、クラウドベースの画像解析プラットフォームである arivis Cloud を利用してそのギャップを埋める事ができます [6]。その際、セグメンテーションの必要性に応じて、カスタマイズされたディープラーニングアルゴリズムが使用されます。その後、ZEN Intellesis は、arivis Cloud によって作成された高度なディープラーニングモデルを扱えるようになります。介在物がセグメンテーションされると、結び付けられたピクセルが領域としてまとめられます。これらの領域は、様々な特性（直径、配向、輝度、丸みなど）に関して解析、測定されます。これらの情報はすべて、オブジェクト分類モデルをトレーニングするためのインプットとなります。1つ目のステップで得られたセグメンテーションの結果に基づいて、画像は、個々の二値画像マスクに分割されます。これらは、モデルをトレーニングするためのラベルとして使用されます。介在物のタイプは、前述のラベリング処理と同様に、マウスをクリックするだけでいくつかの粒子に手動で割り当てられます。EDS と SEM 画像からの追加情報は、介在物クラスのラベル付けに使用されます。



図 7: 様々なオブジェクトのセグメンテーション - 青: Zr-In 介在物、黄: 気孔、緑: 酸化物

ZEN Intellesis Segmentation は、arivis Cloud などの他のソリューションでトレーニングされた機械学習モデルの実行に使用できます。arivis Cloud で作成された Python パッケージは、ディープラーニングによるセグメンテーションモデルのトレーニングに使用されます。これには、すでに ZEN Intellesis Segmentation 内で行われたセグメンテーションの結果の画像 (LM 画像のみ) が使われます。すると、このモデルは、LM 画像のみに基づいて介在物のセグメンテーションができるようになります。微細構造の自動解析により、様々なタイプの介在物の認定が可能になり、気孔や介在物を正しく認識できます。これらの結果は、AM 材料の機械的挙動に関連付け可能です。また、結果を ZEN core で可視化してさらなる解析を行うことで、より広いコンテキストで見ることができます。

### まとめ

機械学習に基づく分類により、1つのデータセットでトレーニングし、複数の試料に適用することで、主観を排除した反復的な結果を得ることができます。局所的なグレースケール値だけではない特徴に基づく分類、特にテクスチャ情報に基づく分類は、材料研究において、画像からさらに多くの情報を取得できる可能性を秘めています。

### 参考文献

- [1] Plotkowski, A., Siscob, K., Bahl, S., Shyama, A., Yang, Y., Allard, L., Nandwana, P., Marquez Rosy, A., Dehoffa, R.R. (2020). Microstructure and properties of a high temperature Al–Ce–Mn alloy produced by additive manufacturing. *Acta Materialia* 196, 595-608. <https://doi.org/10.1016/j.actamat.2020.07>
- [2] Michi, R. A., Plotkowski, A., Shyam, A., Dehoff, R. R., Sudarsanam, S. B. (2022). Towards high-temperature applications of aluminium alloys enabled by additive manufacturing. *International Materials Reviews* 67: 3, 298-345. <https://doi.org/10.1080/09506608.2021.1951580>
- [3] Müller, M., Britz, D., Mücklich, F. (2020). Application of Trainable Segmentation to Microstructural Images Using Low-alloy Steels as an Example. *Practical Metallography* 57: 5, 337-358. <https://doi.org/10.3139/147.110640>
- [4] Kumar Choudhary, A., Jansche, A., Bernthaler, T., Schneider, G. (2020). Machine Learning for Microstructure Quantification of Different Material Classes. *Practical Metallography* 57:7, 475-501. <https://doi.org/10.3139/147.110632>
- [5] Varambhia, A., Goode, A. E., Sato, R., Tran, T., Stratulat, A., Boese, M., Hatton, G., Ozkaya, D. (2022). *Johnson Matthey Technology Review* 66: 3. <https://doi.org/10.1595/205651322X16508983994949>
- [6] [www.arivis.com](http://www.arivis.com)

**Carl Zeiss Microscopy GmbH**  
07745 Jena, Germany  
microscopy@zeiss.com  
www.zeiss.com/microscopy

**Carl Zeiss Co., Ltd.**  
2-10-9 Kojimachi, Chiyoda-ku  
Tokyo, 102-0083, Japan  
Phone: + 81-570-02-1310

2 ページの画像 : AdobeStock; Dushlik

医療措置または診断用ではありません。一部の製品は入手できない国があります。詳細は ZEISS ジャパンにお問い合わせください。

JP\_42\_013\_358 | CZ 06-2023 | 設計、お届けする製品の内容、技術的な内容は予告なく変更される場合があります。 | © Carl Zeiss Microscopy GmbH