

# 深層学習を用いて自動化した 半導体製造プロセスの欠陥分類システム

Automated Defect Classification System for Semiconductor Manufacturing Processes Using Deep Learning

井本 和範 IMOTO Kazunori 中居 友弘 NAKAI Tomohiro

半導体製造プロセスでは、ウエハーの検査工程で取得した欠陥画像を分類・監視して、プロセス異常の早期検知や歩留まりの向上に役立っている。しかし、複雑な製造プロセスでは多様な欠陥が観測されるため、人手による目視確認の作業を余儀なくされるという問題があった。

東芝グループは、この問題を解決するため、深層学習を用いて欠陥画像を高精度に自動分類する欠陥分類システムを構築した。このシステムの深層学習では、教師ラベルの不足による分類性能の低下を抑えるため、弱教師学習手法と転移学習手法を開発した。半導体工場の実データを用いた実験で、開発手法は既存手法よりも高い正解率が得られること、及び教師ラベルが少ないデータに対しても高い正解率が得られることを確認した。更に、深層学習を実用化する上で課題であった学習時間についても、開発した高速化手法の有効性を実データで確認した。

In semiconductor manufacturing processes, defect classification and monitoring using scanning electron microscope (SEM) images acquired in the wafer inspection process are essential for early detection of process abnormalities and improvement of production yield. However, conventional defect classification systems depend on visual confirmation due to a lack of classification accuracy in these complex manufacturing processes.

The Toshiba Group has developed a defect classification system that can automatically classify each defect in SEM images with high classification accuracy. To reduce deterioration of classification performance when reliable labeled data are lacking, this system utilizes two types of deep learning methods: a weakly supervised learning method and a transfer learning method. We have conducted evaluation experiments using actual data at our semiconductor manufacturing factory and confirmed that these methods achieve a higher classification accuracy rate than conventional methods as well as a high classification accuracy rate even in the case of a limited number of reliable labeled data. We have also confirmed the effectiveness of our system in terms of increasing the learning speed necessary for practical application.

## 1. まえがき

近年の半導体工場では、工程ごとに膨大な情報を取得・解析して、製造プロセスの品質管理や早期の歩留まり向上に役立っている。製造プロセス管理で重要な情報源の一つとなるのが、幾つかの製造プロセスで取得可能な欠陥検査画像である。取得した画像を事前に定義した欠陥種ごとに分類し、出現頻度のトレンドを監視することで、製造プロセスの異常を早期に検知できる。

半導体製造プロセスで取得された欠陥のSEM（走査型電子顕微鏡）画像の例を図1に示す。製造プロセスが複雑化するのに伴って、見た目の異なる多様な欠陥が観測されていることが分かる。欠陥画像の分類手法は、検査画像を欠陥種ごとに自動分類する目的で開発されたが、従来の機械学習では十分な精度が得られず、プロセス管理のため、人手による目視確認作業を余儀なくされるという問題があった。

東芝グループは、この問題を解決するため、深層学習を用いて高精度に欠陥画像を自動分類する欠陥分類システム

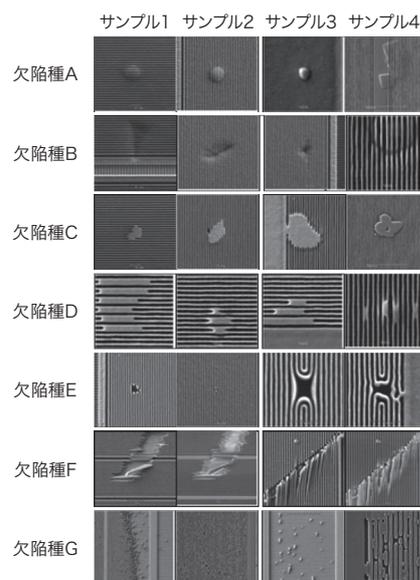


図1. 欠陥画像の代表的な分類例

製造プロセスが複雑化するのに伴って、見た目の異なる多様な欠陥が観測される。

Examples of typical classification of defects in SEM images

ムを構築した<sup>(1)</sup>。一般に、深層学習では、学習データと教師ラベルを対にして準備する必要がある。しかし、半導体製造プロセスに関する深い専門知識がなければ、教師ラベルとなる欠陥の種類に正確に分類することは難しい。更に、発生頻度が低い欠陥画像は、学習データとして大量に準備することが困難である。

ここでは、欠陥画像を自動分類するための深層学習において、教師ラベルが信頼できない場合や学習データが不足している場合でも、欠陥画像を正確に分類できる学習手法について述べる。また、深層学習を実用化する上で課題となる、学習時間の短縮化を可能にする高速化手法についても述べる。

## 2. 欠陥画像解析

欠陥画像解析作業の代表的な三つの業務フローを図2に示す。まず、製造プロセスの節目にあたる検査工程で欠陥画像を取得し、事前に定義した欠陥種ごとに分類する。次に、分類した欠陥種ごとに出現頻度をモニタリングし、トレンドに変化がないかを監視する。そして、管理値を超えるトレンドの変化が観測された場合には、対象の欠陥種だけをピックアップし、更に細かな欠陥種に細分類することで、欠陥の発生原因を調査して同定できる。特に欠陥種細分類作業は、作業そのものの発生頻度が低い中で細かな欠陥種を見分ける必要があるため、製造プロセスに対する深い専門知識が求められる、難度の高い作業である。そこで、自動的に欠陥画像を分類する技術が実現できれば、欠陥画像解析作業の高効率化と高精度化に貢献できる。

## 3. 深層学習による欠陥画像分類

### 3.1 深層学習の教師ラベル準備における課題

近年、深層学習の進展は目覚ましく、画像分類や音声認



図2. 欠陥画像解析作業の業務フロー

欠陥画像を正確に分類・監視することで、出現頻度のトレンドが変化した欠陥種を早期に検知できる。更に、その欠陥種を細分類することで、発生原因を同定できる。

Overview of defect quality control

識などのタスクでは、人間を凌駕(りょうが)する性能も達成している。画像分類の分野では、畳み込みニューラルネットワーク(CNN: Convolutional Neural Network)で高い分類精度が得られることが知られており、半導体製造分野への適用も進んでいる。しかし、深層学習を用いてより高い分類精度を実現するためには、正確な教師ラベルを付与したデータを大量に準備する必要がある。欠陥画像分類で教師ラベルを作成するには、半導体製造プロセスに関する深い専門知識が必要となるため、準備が難しいという問題がある。教師ラベルの作成の手間を削減する方法として、弱教師学習がある<sup>(2)</sup>。弱教師学習には、教師ラベルのないデータも学習に利用する半教師あり学習や、対象のタスクとは異なる分類タスクの教師ラベルや誤りを含む教師ラベルが含まれることを前提とした学習などがある。

今回は、誤りを含む教師ラベルのデータと、信頼できる教師ラベルのデータを組み合わせた弱教師学習について検討した。製造現場によっては、正確ではないが人手により作成されたデータが大量に蓄積されていることがある。そこで、このデータと、熟練者により作成された、少量の正確な教師ラベルのデータを組み合わせることで、高い分類精度を実現する学習手法を開発した。

### 3.2 誤りを含む教師ラベルを活用する弱教師学習

開発した手法の、モデル学習の概要を図3に示す。例えば、欠陥のレビューSEM画像から、教師ラベルの一部に誤りを含む大量のデータと、信頼できる教師ラベルを持つ少量のデータが得られるとき、CNNで構成される分類モデルを、それぞれのデータを用いて2段階で学習する。

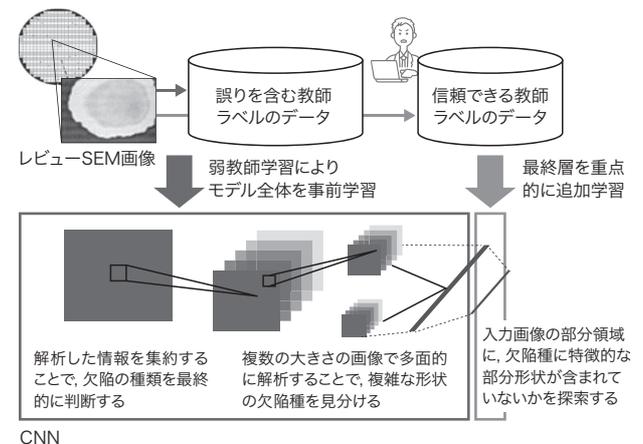


図3. 開発手法のモデル学習戦略

誤った教師ラベルを含む大量のデータで事前学習した分類モデルを初期値とし、信頼できる教師ラベルを持つ少量のデータで最終層を重点的に追加学習する。

Learning strategy of newly developed system

まず、第1段階の事前学習では、誤りを含む大量のデータを用いて分類モデルを学習する。これは、128×128ピクセルにリサイズしたSEM画像を入力し、出力結果を教師ラベルに近づけるように、誤差逆伝播(でんぱ)法を用いて分類モデルのパラメーターを更新することで行われる。この段階では、学習データに誤った教師ラベルが含まれるため、十分な分類精度を得ることは難しい。

次に、第2段階の追加学習で、信頼できる教師ラベルを持つ少量のデータを用いて、先に事前学習された分類モデルに対して更に学習する。ここでは、分類モデルの最終層だけのパラメーターを初期化し、それ以外の層は事前学習された分類モデルのパラメーターを初期値として学習を続ける。また、最終層の学習率を高く、それ以外の層の学習率を低く設定することで、最終層を重点的に学習する。これは、熟練者が付与した、信頼性の高い教師ラベルの情報を、分類への貢献度が大きな層のパラメーター更新に利用するためである。

### 3.3 弱教師学習の評価実験

開発した手法の有効性を確認するため、従来の欠陥自動分類手法(ADC: Automatic Defect Classification)<sup>(3)</sup>と分類精度を比較する実験を行った。実験には、実際の半導体工場で取得した四つのデータセットを用いた。各データセットにおける事前学習のデータ量は数万枚、追加学習のデータ量は数千枚で、欠陥種は10~20種類となっている。ここで、分類モデルのネットワーク構造として、今回の実験では33層のインセプションモデル<sup>(4)</sup>を採用した。既存手法と開発手法の正解率を図4に示す。正解率の平均値は、既存手法の77.2%に対して開発手法が87.3%と高く、全てのデータセットで開発手法の優位性を確認した。

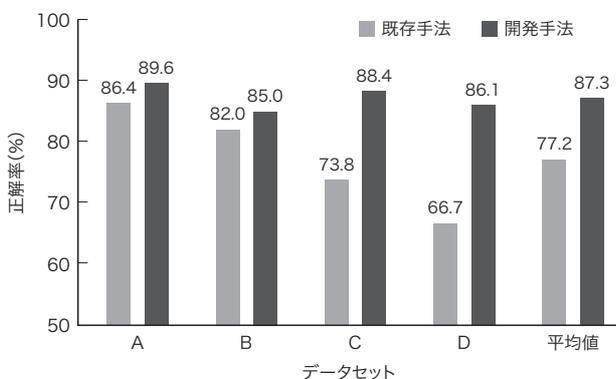


図4. 実データによる分類性能の比較

全てのデータセットにおいて、開発手法の方が既存手法よりも高い正解率が得られた。

Comparison of classification accuracy rates using actual data

## 4. 原因推定のための欠陥種細分類

### 4.1 少量データ学習のための転移学習

2章で述べたように、発生頻度が高くなった欠陥種をより細かく分類する細分類は、製造プロセスの異常原因を同定する上で重要な作業となる。しかし、作業自体の発生頻度が低い場合、細分類に必要な十分な画像を入手できない。更に、分類には、製造プロセスに対する深い専門知識が必要で、正確な教師ラベルが付与されたデータを取得できず、自動分類のためのモデルを学習することが難しいという問題があった。

学習データが十分に確保できない状況を解決する手段として、転移学習<sup>(5)</sup>が知られている。転移学習は、ドメイン間の差異に基づいて複数の手法が知られているが、今回は、特徴表現を再利用するアプローチを採用した。これは、転移元のドメインのデータで学習した分類モデルを、特徴表現を抽出する部分とクラス分類する部分に分け、特徴表現を抽出する部分だけを転移先のドメイン向けに再利用するものである。

CNNによる分類モデルのうち、最終層の手前までを特徴表現を抽出する部分、最終層だけをクラス分類する部分とした。そして、細分類前の通常分類タスクを転移元ドメイン、細分類タスクを転移先ドメインとした。したがって、転移学習の方法は、通常タスクで学習した分類モデルの最終層を除去し、細分類タスク向けの最終層を追加して細分類データで追加学習する形になる。

### 4.2 転移学習の評価実験

開発した手法の有効性を確認するため、学習済み分類モデルについて、転移学習がある場合とない場合の正解率を比較する実験を行った。実験では、追加学習に用いるデータ量を数十枚~数千枚まで調整し、追加学習のデータ数と正解率の関係性を調査した。転移学習あり/なしの場合の正解率を図5に示す。全ての学習条件で、転移学習ありの方が高い正解率が得られている。特に、追加学習データ数が数十枚と限られている条件でも、転移学習ありでは80%以上の高い正解率が得られていることを確認した。

## 5. 深層学習における高速化

深層学習による欠陥分類システムを実際に運用する場合、新製品の導入や欠陥傾向の変化などに対応するため、分類モデルの学習を頻繁に行う必要がある。したがって、学習時間をできるだけ短縮する高速化手法が求められる。

深層学習では、学習データをモデルに入力し、出力と教師ラベルとの差をロスとして計算し、ロスが小さくなるようにモデルのパラメーターを更新する。このような処理を繰り返

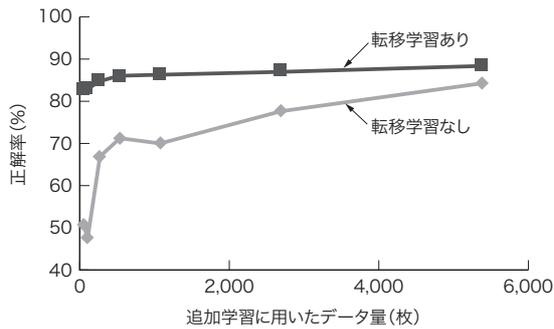


図5. 学習データ量と分類性能の関係

開発した手法(転移学習あり)では、追加学習のデータ数が少ない場合でも高い正解率が得られた。

Relationship between number of learned data and classification performance

すことで、学習データに対して正しいラベルを出力するように学習する。

ここで、学習を早期に打ち切ることで学習時間を短縮し、高速化を図る場合、打ち切るタイミングが重要である。すなわち、余り早過ぎると、学習が十分に進んでいない未学習の状態となり、分類性能が低下する。一方、余り遅過ぎると、十分に高速化できない。また、学習回数が多過ぎると、分類モデルが学習データに過剰に適合し、未知のデータの分類性能が低下する過学習が発生することがある。

そこで、学習データに加え、学習には利用しない検証データを用意し、検証データでのロスが飽和した場合に学習を打ち切る。図6に示すように、一般に学習データのロスは学習回数が増えれば多いほど減少するが、検証データのロスは、ある段階で飽和し、その後は増加に転じる。その場合は、過学習が発生していることが多いため、検証データのロスを監視し、飽和したら学習を打ち切る。

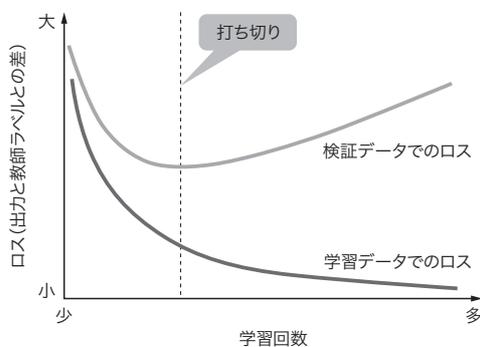


図6. 高速化のための学習の早期打ち切り

学習を高速化し過学習を回避するため、学習には利用しない検証データを用意し、検証データのロスが飽和した段階で学習を打ち切る。

Early stopping of learning to speed up learning process

学習の早期打ち切りと、複数のGPU (Graphic Processing Unit) による並列計算との組み合わせで、学習時間は40 hから4 hに短縮され、10倍の高速化が図れることを確認した。

## 6. あとがき

半導体製造プロセスの品質管理や歩留まり向上を目的とした、欠陥画像を自動分類できる深層学習手法について述べた。

今回、専門知識が必要で準備することが難しい教師ラベルのデータ数を削減するため、弱教師学習と転移学習のアプローチを検討した。蓄積されたデータに付与された教師ラベルに誤りが含まれていたり、異なる分類タスクであったりしても、少量の正確な教師ラベルを追加するだけで、高い正解率が得られることを、実際の半導体製造現場のデータで確認した。また、深層学習を実用化する上で課題であった学習時間の短縮化についても、開発した高速化手法の有効性を実データで確認した。

今後、実際の半導体製造現場への適用を進めるとともに、半導体以外の製造現場にも適用範囲を広げ、生産性の向上に役立てていく。

## 文献

- (1) Imoto, K. et al. "A CNN-based Transfer Learning Method for Defect Classification in Semiconductor Manufacturing". Proceedings of 2018 International Symposium on Semiconductor Manufacturing (ISSM 2018). Tokyo, 2018-12, IEEE. 2018, YE-O-54, p.168-170.
- (2) Zhou, Z. A brief introduction to weakly supervised learning. National Science Review. 2018, 5, 1, p.44-53.
- (3) Chou, P. B. et al. Automatic defect classification for semiconductor manufacturing. Journal of Machine Vision and Applications. 1997, 9, 4, p.201-214.
- (4) Szegedy, C. et al. "Rethinking the Inception Architecture for Computer Vision". Proceedings of 29th IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016). Las Vegas, NV, 2016-06, IEEE. 2016, p.2818-2826.
- (5) Pan, S. J.; Yang, Q. A Survey on Transfer Learning. IEEE Transactions on Knowledge and Data Engineering. 2010, 22, 10, p.1345-1359.



井本 和範 IMOTO Kazunori  
研究開発本部 研究開発センター  
アナリティクス AI ラボラトリー  
情報処理学会会員  
Analytics AI Lab.



中居 友弘 NAKAI Tomohiro, Ph.D.  
研究開発本部 研究開発センター  
アナリティクス AI ラボラトリー  
博士(工学) 電子情報通信学会会員  
Analytics AI Lab.