

Title	先端半導体デバイス対応欠陥レビュー走査型電子顕微鏡の画像処理技術に関する研究
Author(s)	原田, 実
Citation	大阪大学, 2019, 博士論文
Version Type	VoR
URL	https://doi.org/10.18910/72586
rights	Copyright(2018) Society of Photo-Optical Instrumentation Engineers. One print or electronic copy may be made for personal use only. Systematic reproduction and distribution, duplication of any material in this paper for a fee or for commercial purposes, or modification of the content of the paper are prohibited.
Note	

Osaka University Knowledge Archive : OUKA

<https://ir.library.osaka-u.ac.jp/>

Osaka University

先端半導体デバイス対応
欠陥レビュー走査型電子顕微鏡の
画像処理技術に関する研究

提出先 大阪大学大学院情報科学研究科
提出年月 2019年1月

原田 実

関連発表論文および資料

1. 学会誌

1. Minoru Harada, Kenji Obara, and Koji Nakamae, “A robust SEM auto-focus algorithm using multiple band-pass filters,” Measurement Science and Technology, vol. 28, pp. 015403-1-10, 2016.
2. Minoru Harada, Yohei Minekawa, Fumihiko Fukunaga, and Koji Nakamae, “In-die overlay metrology method using SEM images,” Journal of Micro / Nanolithography, MEMS, and MOEMS, Vol. 17, pp. 17-17-7, 2018
3. Minoru Harada, Yohei Minekawa, and Koji Nakamae, “Defect Detection Techniques Robust to Process Variation in Semiconductor Inspection,” Measurement Science and Technology (採択済み、掲載待ち)

2. 国際会議

1. Jaehyoung Oh, Gwangmin Kwon, Daiyoung Mun, Hyungwon Yoo, Sungsu Kim, Tae hui Kim, Minoru Harada, Yohei Minekawa, Fumihiko Fukunaga, and Mari Nozoe, “In-die overlay metrology method using defect review SEM images”, Proc.SPIE, vol. 8681, pp. 8681-8681-8, 2013

3. 国内講演

1. 原田実, 細谷直樹, 中垣亮, 平井大博, 福永文彦, 山口宏平. “走査型電子顕微鏡を用いた定点検査アプリケーションの開発,” 第30回 LSI テスティングシンポジウム, pp. 29-34, 2010.

内容梗概

本論文は筆者が(株)日立製作所 研究開発グループ 生産イノベーションセンタ及び大阪大学大学院情報科学研究科 情報システム工学専攻 博士後期課程在学中(2017年度~2018年度)に行ってきた、先端半導体デバイスの製造工程で利用される欠陥レビュー装置における画像処理技術に関する研究成果をまとめたものである。具体的には高精細画像の取得に必要なオートフォーカス処理のロバスト性向上や、画像内から欠陥部位を特定する欠陥検出処理の性能向上、半導体デバイスのできばえを定量化する機能に関するものであり、次の6章から構成されている。

第1章は序論であり、本研究の背景及び目的について述べた。具体的には本研究で扱う半導体デバイス製造におけるインラインウェハ検査システムの概要と課題について述べた。また本論文の構成を述べた。

第2章では半導体デバイスの製造工程において用いられる欠陥レビュー走査型電子顕微鏡(Scanning Electron Microscope: SEM)(以降、レビューSEMと記載)について説明した。まず、装置構成について説明し、電子光学系の概要と画像取得原理、取得される画像の性質について述べた。

第3章では電子顕微鏡を用いて高精細な画像を取得する際に必要となるオートフォーカス処理のロバスト性向上について述べた。まず、オートフォーカスの基本シーケンスについて述べた。オートフォーカスでは撮像画像から電子ビームの合焦度合いを焦点測度として定量化することが重要である。この焦点測度算出のロバスト性向上策としてマルチバンドパスフィルターを用いた手法を提案し、算出された焦点測度を統合し適切な合焦位置を算出する手法について提案した。最後に、擬似画像を用いて行った、画像の信号雑音比(Signal-to-Noise Ratio: SNR)と合焦位置算出精度に関する評価結果と、実画像を用いた合焦位置算出実験の結果について述べ、提案手法の有効性を示した。

第4章では欠陥画像の収集効率向上を目的とした欠陥再検出処理の改良について述べた。レビューSEMを用いた欠陥画像収集においては、欠陥画像収集純度と呼ぶ性能指標の向上が重要である。まず、欠陥画像収集純度を目的に開発した提案手法として2つの手法について述べた。1つ目は、製造ばらつきのランダム性に着目し、検査画像を複数枚の参照画像と比較検査することで、抽出される欠陥候補の数を抑制する手法である。2つ目は、抽出された欠陥候補それぞれについて、事前に学習した良品画像モデルを用いて、良品か欠陥かを識別する手法である。最後に、提案手法とサポートベクターマシンを用いた手法を比較した結果を述べ、提案手法の有効性を示した。

第5章では半導体デバイスのできばえ定量化を目的としたオーバーレイ計測手法について述べた。提案手法は、被計測画像と基準画像を比較することで相対的なオーバーレイを計測するものである。具体的には複数の製造工程により

形成される回路パターンの領域を撮像画像から工程別に認識し、被計測画像と基準画像間で回路パターン領域の位置ずれ量を算出することでオーバーレイを計測する。評価結果として、擬似画像を用いた精度評価を示した後、実パターン画像を用いた評価結果を示した。また、計測結果に対してモデルフィッティングを用いた解析を行った結果について述べ、提案手法の有効性を示した。

最後に、第6章で本研究の結論と今後の課題を述べた。

目次

第1章 序論	1
1.1 研究背景	1
1.1.1 半導体パターンの微細化	1
1.1.2 半導体製造プロセスにおける欠陥検査システムとレビューSEM	2
1.1.3 欠陥の観察・分析機能	4
1.1.4 できばえ定量化機能	5
1.2 研究の目的	6
1.3 論文構成	11
第2章 レビューSEM	13
2.1 まえがき	13
2.2 レビューSEMの構成と画像取得原理	13
2.2.1 全体構成	13
2.2.2 電子光学系と取得画像の性質	14
2.3 むすび	16
第3章 オートフォーカス処理のロバスト性向上技術	19
3.1 まえがき	19
3.2 レビューSEMにおけるオートフォーカスの原理	19
3.3 マルチバンドパスフィルタを用いた焦点測度算出処理	22
3.4 焦点測度分布からの合焦位置推定	24
3.5 評価実験	25
3.5.1 擬似画像を用いた合焦位置の算出精度	25
3.5.2 実SEM画像を用いた合焦位置算出の成功率	29
3.6 むすび	30
第4章 欠陥画像収集純度向上を目的とした欠陥再検出技術	33
4.1 まえがき	33
4.2 虚報識別正解率の向上策	33
4.3 欠陥再検出処理の改良	35
4.3.1 複数枚の参照画像を用いた比較検査処理	35
4.3.2 良品画像モデルを用いた識別処理	35
4.3.3 局所画像のクラスタリング処理	38
4.4 評価実験	40
4.4.1 評価方法	40
4.4.2 パッチ画像のクラスタリング結果	41

4.4.3	虚報識別率および検出成功率の評価結果	42
4.5	むすび	44
第5章	レビューSEM像を用いたオーバーレイ計測	47
5.1	まえがき	47
5.2	計測アルゴリズム	47
5.2.1	回路パターン領域認識アルゴリズム	48
5.2.2	位置ずれ量定量化アルゴリズム	50
5.3	評価実験	51
5.3.1	擬似画像を用いた感度評価	51
5.3.2	実パターン画像を用いた評価	53
5.3.3	モデルフィッティングを用いたオーバーレイ計測結果の解析	56
5.4	むすび	62
第6章	結論	63

第1章 序論

1.1 研究背景

1.1.1 半導体パターンの微細化

半導体集積回路は現代の情報社会を支える上で重要なデバイスである。デバイスの性能向上や製造コスト低減のためにトランジスタや電子回路の集積度を向上させる試みが継続的に行われている。特に「集積回路上のトランジスタ数は18か月ごとに倍になる」というムーアの法則は経験則から生まれたものであるが、性能向上の1つの目標値として広く使われている [1, 2]。図 1.1 は主要な中央処理装置 (Central Processing Unit: CPU) におけるトランジスタ数の推移を示したものである。1990年には100万トランジスタであったものが、2010年には1000倍となる10億トランジスタとなる。このまま進めば2020年には200億トランジスタを超える見通しである。




図 1.1: 主要な CPU におけるトランジスタ数の推移 [Transistor count (19 October 2018, at 09:27 (UTC)). In Wikipedia: The Free Encyclopedia. Retrieved from https://en.wikipedia.org/wiki/Transistor_count]

集積度を向上させるためにはウェハ上に形成する回路パターンのサイズを微細化する必要がある。このためにはマスク上のパターンをウェハ上に転写する露光技術が重要となる。微細なパターンを解像させるため、波長 248 nm の KrF レーザー光を用いた KrF 露光技術の後 [3, 4, 5]、波長 193 nm の ArF レーザーを用いた ArF 露光技術が開発され [6, 7]、波長が 134 nm 相当となる ArF 液浸露光

技術が開発された [8]。さらなる微細化のため、同一層の回路パターンを2回の露光に分けて行うダブルパターンニング技術 [9, 10] や、分割数を増やしたマルチパターンニング技術が用いられている。次世代の露光技術として、波長 13.5 nm の極端紫外線 (Extreme Ultra Violet: EUV) を用いた露光技術の開発が進められている [11, 12]。難易度が高いとされていた高出力光源の開発についても 2017 年には 250 W の光源が開発され [13]、量産適用に向けた評価・改良が進められている。また、従来は平面状に構成していた素子を立体的に形成する新しい構造 (FinFET など) のデバイスが開発が進められている [14]。このように半導体製造プロセスの微細化は今後も継続すると予想される。

1.1.2 半導体製造プロセスにおける欠陥検査システムとレビュー SEM

微細化および複雑化する半導体デバイスの製造において収益を得るためにはプロセス開発コストや製造コストの低減が重要である。そのため、デバイスメーカーは製造歩留りを早期に改善し、量産段階でその体制を維持することが重要課題となっている。

製造歩留りを低下させる要因として製造段階における欠陥の発生がある。半導体デバイスは多層構造をしており、シリコンウェハ上にトランジスタを形成した後、上層にトランジスタ間を結線する配線層が形成される。各層は、フォトレジストの塗布、露光、現像、エッチング、レジスト除去などの複数の工程を経て形成される。この際、各種の欠陥が生じる場合がある (図 1.2)。例えば、製造装置から発生した異物や回路パターンのショート (短絡)、エッチング不足による未開口、平坦化プロセスにより生じるスクラッチ欠陥など、ウェハ面内においてランダムに生じる欠陥がある。また、露光プロセスにおいて多層構造の回路パターンを形成する際には下層の回路パターンとの位置合わせ (オーバーレイ) が重要である。上層と下層の回路パターンの位置が合っていない場合、導通不良などデバイスの電気特性に影響が生じる場合がある。




図 1.2: 半導体デバイスの断面構造と欠陥例

製造歩留り向上のためには製造工程で生じる欠陥の発生を把握し、対策することが重要となる。半導体では、製造プロセスの微細化に伴い致命となる欠陥サイズも微小化しており、欠陥検査・観察がますます重要となっている。製造工程で生じた欠陥を把握するため、インラインウェハ検査システムが導入されている [15]。インラインウェハ検査システムはデバイスの製造工程間でウェハを検査するものであり、製造プロセスの異常を早期に検知し、その発生原因の特定するために利用される。インラインウェハ検査システムで使用される代表的な装置として、ウェハ上の欠陥を検出し位置情報を出力するウェハ検査装置、検出された位置情報をもとに欠陥の高精細画像の取得、画像分類、元素分析などを行う欠陥観察装置がある。

ウェハ検査装置としては主に光学式顕微鏡で撮像した画像を比較検査する機能を備えた装置が利用されている [16]。デバイスに致命となる欠陥のサイズはパターンサイズの約 1/2 といわれており、製造プロセスの微細化にあわせてウェハ検査装置の感度向上への取り組みも継続的に行われている。

光学式顕微鏡の分解能は数百 nm 程度であるが、欠陥が十分に解像していない状態でも検査は可能であり、光学式ウェハ検査装置は数十 nm 程度の欠陥を検出可能である。ただし、欠陥の検出は可能であっても、その外観の詳細を観察することは困難である。そのため、数 nm の分解能を有する走査型電子顕微鏡 (Scanning Electron Microscope: SEM) を備えた欠陥観察装置 (以下、レビュー SEM と記載) が利用されている [17]。図 1.3 はレビュー SEM の機能をまとめたものである。レビュー SEM の機能を大別すると、ウェハ検査装置が出力した欠陥位置情報に基づいて欠陥の観察・分析をする機能と、ユーザが指定した検査領域に対して欠陥数計測や回路パターン領域の計測を行う、できれば定量化機能からなる。なお、ここでの「できれば」とは、形成された回路パターンが設計形状に対してどの程度正確に形成できているか (もしくは設計形状からどの程度乖離しているか) を評価した値である。欠陥の観察・分析機能においては、欠陥の SEM 画像を自動収集する自動欠陥観察機能 (Automatic Defect Review: ADR) [18, 19, 20, 21]、収集した欠陥 SEM 画像を欠陥種ごとに自動分類する自動欠陥画像分類機能 [22, 23]、エネルギー分散型 X 線分析 (Energy dispersive X-ray spectrometry: EDX) を用いた組成分析機能を備えている。これにより、ユーザは欠陥種ごとの発生数の傾向を把握することが可能となり、欠陥原因となる製造装置の特定などに活用される。できれば定量化機能においては、検査位置における欠陥数の計測機能や回路パターン領域の面積や形状を定量化する機能を備えている [24]。定量化結果をウェハマップとして出力することでウェハ面内におけるできれば傾向を可視化することが可能となり、製造プロセスの調整に活用される。

前述の様に半導体製造プロセスは継続して微細化しており、それに伴って致命となる欠陥サイズも微小化している。そのため、欠陥の観察・分析機能においては、欠陥微小化への対応が継続的に必要となっている [25]。また、製造プロセス

の変動に対する許容度が小さくなっているため、回路パターンのできばえを高精度に定量化し、製造プロセスにフィードバックすることが必要となっている。

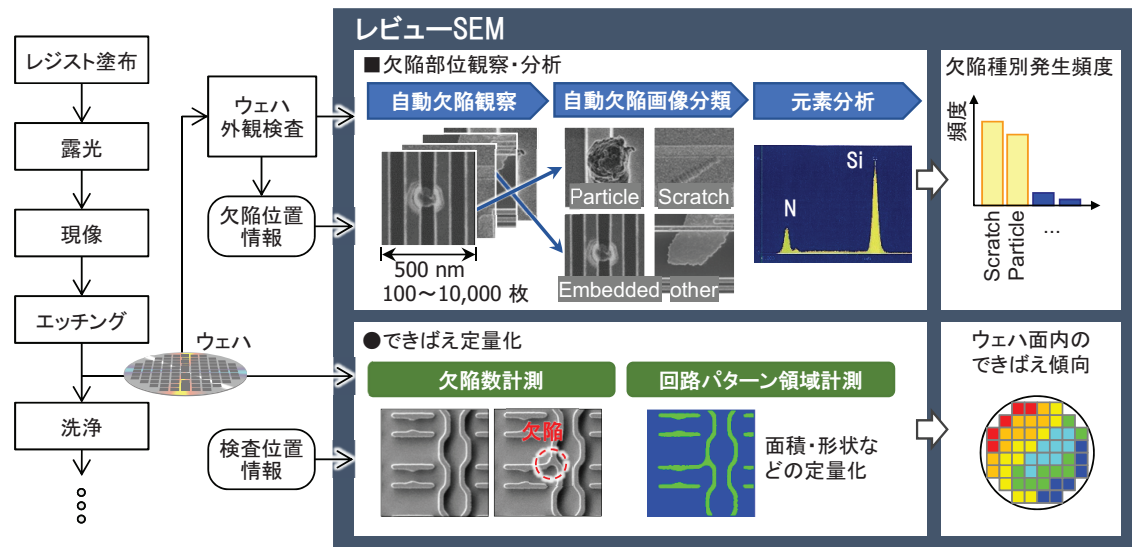


図 1.3: 半導体製造ラインにおけるレビュー SEM の役割と機能

1.1.3 欠陥の観察・分析機能

製造プロセスの開発段階においては、ウェハ上で数百から数万点の欠陥が発生することも珍しくない。欠陥の観察・分析を効率的に行うため、ADR が広く利用されている。

ADR はウェハ検査装置が出力した欠陥位置情報に基づいて画像を撮像する機能である。欠陥位置が SEM の視野に入るようにステージを制御し欠陥観察用の画像を撮像する。この際、観察すべき欠陥サイズも微小化しているため、詳細を観察するためには視野を限定して(倍率高く)観察用画像を撮像する必要がある。例えば、サイズ $0.1\ \mu\text{m}$ の欠陥を観察する際には観察用画像の視野を $0.5\ \mu\text{m}$ 四方に設定し、撮像視野内において欠陥が大きく映り、周辺の回路パターンも観察できるようにする。一方、光学式ウェハ検査装置が出力する欠陥位置情報には $\pm 1\ \mu\text{m}$ 程度の誤差が含まれる。また、レビュー SEM 自体のステージも停止誤差を持つため、欠陥位置情報に基づいて視野が $0.5\ \mu\text{m}$ 四方の観察用画像を撮像すると視野内に欠陥が含まれないケースが多発する。

上記問題を解決するため、ADR では欠陥位置情報をもとに $2\sim 3\ \mu\text{m}$ 程度の広い視野で画像を撮像し、撮像画像から欠陥位置を再検出し、欠陥位置を視野 $0.5\ \mu\text{m}$ 程度の高倍率で撮像するといった段階を踏む。

図 1.4 は具体的な処理フローを示したものである。ある欠陥の観察用画像を撮像するにあたり、まず欠陥が位置するダイに隣接するダイにおいて参照画像を低倍率(広視野)で撮像する。次に、欠陥位置において検査画像を低倍率で撮像する。参照画像と欠陥画像は同一の回路パターンが形成されるように設計され

た領域を撮像しているため、両者の画像を比較することで検査画像中の欠陥を再検出することが可能である。最後に、再検出した欠陥位置を中心に高倍率で撮像し、観察用画像を得る。この時、観察用画像において正しく欠陥を撮像できている割合を、欠陥画像収集純度と呼ぶこととする。例えば、欠陥再検出処理において欠陥以外の箇所を誤検出すると欠陥画像収集純度が低下する。

高精細な観察用画像を撮像するためには、電子ビームの焦点位置(電子ビームが集束する高さ方向の位置)を調整するオートフォーカス処理が必要となる。これは、積層した膜の応力によりウェハが反っている、塗布した膜の厚みが不均一である、などの理由により物理的な高さがウェハ面内で異なる(平坦でない)ことによる。また、仮に平坦である場合においてもウェハが帯電している場合、帯電の影響により電子ビームが意図した高さで集束しない場合もある。なお、オートフォーカス処理は100ms程度必要であるが、欠陥再検出処理と並列処理することでADRのスループットを落とさずに実行することが可能である。以上の処理を入力された欠陥位置情報について繰り返し行うことで欠陥画像の自動収集を行う。

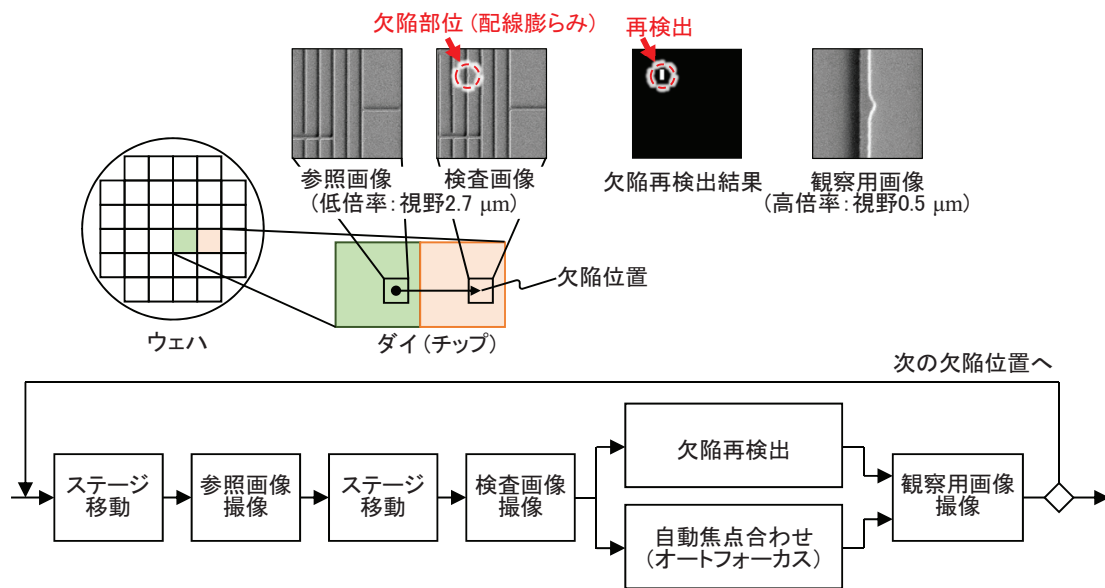


図 1.4: 自動欠陥観察機能 (ADR) の処理フロー

1.1.4 できばえ定量化機能

できばえ定量化機能は、ユーザが指定した検査座標において欠陥数の計測や、回路パターンの特徴を定量化する機能である。SEMは光学式顕微鏡に比べて画像撮像に時間を要するため、ウェハ全面を検査するには多大な時間を要する。一方、製造プロセス上、欠陥が発生しやすい領域をホットスポットとして把握可能な場合がある。例えば、回路パターンのレイアウト上、プロセス変動に対する許容度が低くショートなどの欠陥が発生しやすい箇所は、半導体デバイスの設

計情報と露光シミュレータにより抽出することが可能である。そのため、このホットスポットを重点的に検査することで製造プロセスをモニタリングすることが可能となる。

レビューSEMは指定されたホットスポットの座標情報に基づきウェハ面内の各ダイで画像を収集する。収集した画像に対して、前述の欠陥再検出処理を用いて欠陥を検出し、撮像画像内における欠陥数を計測する。また、撮像画像から回路パターンが形成されている領域を認識し、回路パターンの面積や形状を定量化することで、ウェハ面内における製造プロセス変動を可視化する。

できれば定量化の対象となる半導体製品・製造プロセスは多岐にわたり、半導体製品・製造プロセスごとに定量化が必要な項目は異なる。例えば、エッチング工程後においてはエッチング残りや回路パターンのショート・オープンなどの欠陥数を個別に定量化することが求められる。また、DRAMデバイスメーカーにおいては、キャパシタ層における孔の形状や、下層にある回路パターンとの導通を定量化することが求められる。以上の様に、定量化すべき項目は多岐にわたり、今後もデバイスの進化に合わせて変化すると考えられ、継続的な機能開発が必要とされている。

1.2 研究の目的

デバイスメーカーにおいては微細化のに向けた製造プロセスの開発、量産ラインの構築に莫大な投資が必要となっており、投資回収において、歩留りの垂直立ち上げ、および量産段階における高歩留り維持が重要課題のひとつとなっている。歩留り向上にはインラインウェハ検査システムの高度化が重要である。本研究ではインラインウェハ検査システムにおいて重要な位置を占めるレビューSEMを対象に、性能向上や機能拡充に向けた技術開発について取り組む。

具体的には、(a)オートフォーカス処理のロバスト性向上技術、(b)ADRにおける欠陥画像収集純度向上を目的とした欠陥再検出技術、(c)レビューSEM像を用いたオーバーレイ計測技術の開発に取り組む。以下、これら3つの技術について詳細を述べる。

(a) オートフォーカス処理のロバスト性向上技術

オートフォーカス処理は一次電子ビームの焦点がウェハ表面において最小となるように対物レンズの電流値などのパラメータを設定する処理であり、ADRにおいて安定して高精細の画像を撮像するための基本的かつ重要な処理である。レビューSEMはウェハ表面の高さを計測する光学式センサーを備えている。しかし、所定の高さに電子ビームが集束するように制御しても、ウェハの帯電状況などにより集束位置に誤差が生じる。そこで、オートフォーカス処理では焦点に関する制御パラメータを変えて撮像した複数枚の画像から焦点測度を算出

し、焦点測度が最大となる位置を合焦位置として、最適な制御パラメータを算出している。なお、焦点測度とは電子ビームの焦点位置とウェハ表面高さの一致度合いを画像から計測したものである。

画像を用いたオートフォーカス技術に関し、文献[26]はSEM画像を対象に焦点測度の算出方法を比較しており、フィルタの畳み込みによりエッジを抽出し、その信号強度を焦点測度とすることで合焦位置を算出可能なことを示している。レビューSEMにおいてはランダムな位置に生じた欠陥を観察するため、欠陥や周辺の回路パターンの陰影を用いて焦点測度を算出する必要がある。この際、観察位置に応じて最適なエッジ抽出フィルタの周波数特性が大きく異なるといった課題がある。図1.5は観察用画像の例として(a)回路パターン領域における欠陥の画像例と、(b)回路パターンが形成されていない領域(回路パターンなし領域)における欠陥の画像例を示している。回路パターン領域の欠陥においては集束位置の変動に応じて回路パターンが持つ高周波成分の変化が顕著となる。一方、回路パターンなし領域においては観察可能なエッジが欠陥部のみにしか存在しない。欠陥の表面がなだらかな場合には高周波成分が少なくなるため、回路パターン向けに調整したエッジ抽出フィルタでは焦点測度を正しく算出できず、オートフォーカスに失敗するケースが生じる。フィルタの最適化について、文献[27]には異なるエッジ方向に対応した複数のフィルタを併用する方法が述べられている。しかし、周波数特性が異なるフィルタを併用してひとつの焦点測度の算出した場合、焦点変化に応じた画像の周波数成分の違いに対する感度が低下し、適切な焦点測度カーブが得られない。また、合焦位置の算出精度に関して、文献[28]には焦点測度の算出誤差から合焦位置算出精度を推定する方法が述べられている。しかし、文献[28]は光学写真のようにSNRが高い画像を対象としており、SEM画像の様にSNRが低い場合における合焦位置算出精度については言及されていない。

本研究では、SNRが低いSEM画像を対象にエッジ抽出フィルタの周波数特性について設計方法を明らかにし、ロバストなオートフォーカスを可能とするエッジ抽出フィルタを開発する。また、一枚の画像から複数のエッジ抽出フィルタを用いて複数の焦点測度を算出し、最終的に得られる焦点測度分布の形から最適なエッジ抽出フィルタを選択する方法を開発する。

(b) ADRにおける欠陥画像収集純度向上を目的とした欠陥再検出技術

致命となる欠陥サイズの微小化に伴い、製造ばらつきと検出すべき欠陥の区別が困難となっている。図1.6は光学式のウェハ検査装置において虚報が発生するメカニズムの一例を示したものである。ウェハ検査装置は隣接するダイの画像を比較することで欠陥を検出する。製造ばらつきに起因してダイ間で膜厚が異なると、入射光と反射光の干渉の仕方が変わり、濃淡差を生じさせる要因と

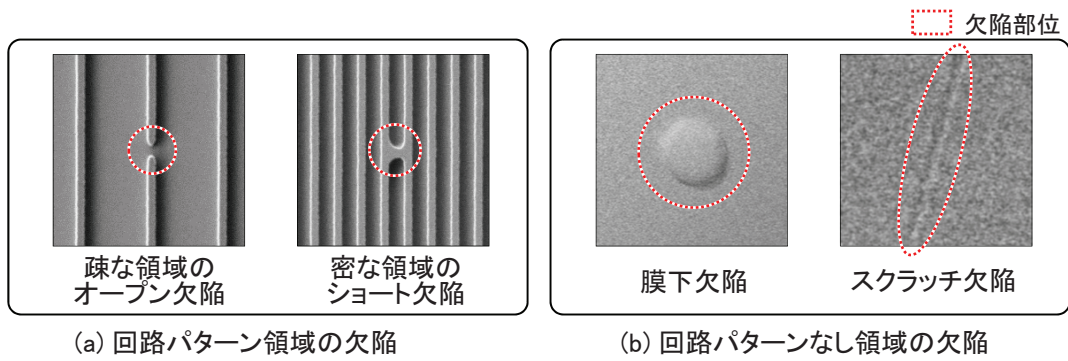


図 1.5: 回路パターン領域および回路パターンなし領域の欠陥画像例

なる。膜厚の変動がデバイスの動作に影響のない製造公差内であれば、欠陥として検出されるべきではない。しかし、欠陥サイズ微小化にともない欠陥において得られる濃淡差と、製造ばらつき起因の濃淡差の区別が困難となっている。その結果、微小欠陥を検出するために欠陥検査装置の感度を上げると、製造ばらつきを誤検出した“虚報”が大量に発生する。




図 1.6: 光学式ウェハ検査装置における虚報発生メカニズムの一例

ウェハ検査装置における欠陥検出感度向上と虚報抑制の両立は、スループットや分解能、装置コスト増大の抑制といった問題から困難となる一方である。そのため、ウェハ検査装置が出力した欠陥位置情報の中から虚報を除外し、真に欠陥である画像のみを収集することがレビューSEMのADRに求められている[29]。図1.7は欠陥位置情報に虚報が含まれる際に求められるADR動作をまとめたものである。ウェハ検査装置の出力が実報である場合(欠陥を検出した場合)、レビューSEMは検査画像から欠陥位置を正しく再検出することが望ましい動作となる(図1.7(a)検出成功)。一方、ウェハ検査装置の出力が虚報である場合は、レビューSEMで撮像した検査画像内には欠陥が含まれない。この場合、検査画像内に欠陥がないことを正しく識別し、観察用画像を取得しないことが望ましい動作となる(図1.7(c)虚報識別正解)。また、欠陥再検出において欠陥以外の位置を検出した場合は、欠陥が含まれない観察画像が収集されるため望ましくない動作となる(図1.7(b)(d)誤検出)。ウェハ検査装置の虚報率を nui_r 、ウェハ検査装置の出力が欠陥であった時の検出成功率を $tp_r(= a/(a+b))$ 、ウェハ検査装置の

出力が虚報であった時の虚報識別正解率を $tn_r (= c/(c+d))$ としたとき、欠陥画像収集純度 adr_{purity} は、式 (1.1) により求まる。




図 1.7: 欠陥位置情報に虚報が含まれる際に求められる ADR 動作

$$adr_{purity} = \frac{(1 - nui_r)tp_r}{(1 - nui_r)tp_r + nui_r(1.0 - tn_r)} \quad (1.1)$$

欠陥位置情報に含まれる虚報が少ない場合、欠陥再検出は検査画像に欠陥が含まれることを前提に再検出をすればよく、例えば参照画像と検査画像の濃淡差を算出し、最も差が大きい箇所を欠陥として出力すれば良い。しかし、欠陥位置情報に含まれる虚報が多くなるにつれ、虚報識別正解率の向上が重要となる。ウェハ検査装置と同様に、微小な欠陥とプロセスバリエーションとの識別は容易ではなく、濃淡差に対する単純なしきい値処理では識別が困難となっている。

本研究では、ADRにおける欠陥画像収集純度の向上を目的に、虚報識別正解率の向上を実現する欠陥再検出処理の改良について述べる。

(c) レビュー SEM 像を用いたオーバーレイ計測技術

前述の様に、半導体デバイスは回路パターンを積層して製造される。この際、積層する層の回路パターンの位置と、下層の回路パターンの位置が一致していない場合、導通不良などデバイスの電気特性に悪影響が生じる場合がある。この層間の位置ずれはオーバーレイと呼ばれており、製造プロセスにおける重要な管理項目のひとつとなっている。

図 1.8 に、既存のオーバーレイ計測手法および本手法の狙いを示す。従来よりオーバーレイはスクライブライン(ウェハからダイ(チップ)を切り出す際の切断

領域)に設けた計測用の専用パターンを光学式顕微鏡で撮像し、計測を行っていた [30]。この計測用パターンは n 回目の回路パターン形成工程と、 $n+1$ 回目の回路パターン形成工程で、それぞれ異なるパターンが形成されるようになっており、各パターンのずれを定量化することでオーバーレイの計測が可能である。この手法では計測用パターンのサイズを光学式顕微鏡で解像できる程度に大きくする必要があるので、デバイス回路パターンの線幅と、計測用パターンの線幅は大きく異なる。そのため、プロセスバリエーションによる影響度合いがデバイス回路パターンと計測用パターンでは異なり、計測用パターン上での計測値がデバイスのオーバーレイを正しく反映しているとは限らない。また、スクライブライン上での計測であるため、デバイス回路パターンが形成される領域における計測値を求めるには、モデルを仮定した上で補間を行うほかない。

この問題に対し、微小化した計測用パターンをSEMを用いて撮像し、計測する手法が提案されている [31, 32, 33, 34, 35]。CPUなどのロジックデバイスにおいては、回路パターンのレイアウトを工夫することで計測用パターンを配置することが可能である。一方、メモリデバイスにおいては、回路パターンが周期的かつ密にレイアウトされているため、計測用パターンを自由に配置することが困難である。

上記課題の解決には、デバイスの回路パターンを撮像した画像からオーバーレイを直接的に計測することが望ましい。図 1.8 に示したデバイスの回路パターンのレイアウトは一例であり、実際には様々な回路パターンのレイアウトに対応する必要がある。本研究では、できれば定量化機能の一機能として、オーバーレイが理想的な基準画像と被計測画像を比較することで相対的なオーバーレイを算出する技術を開発する。

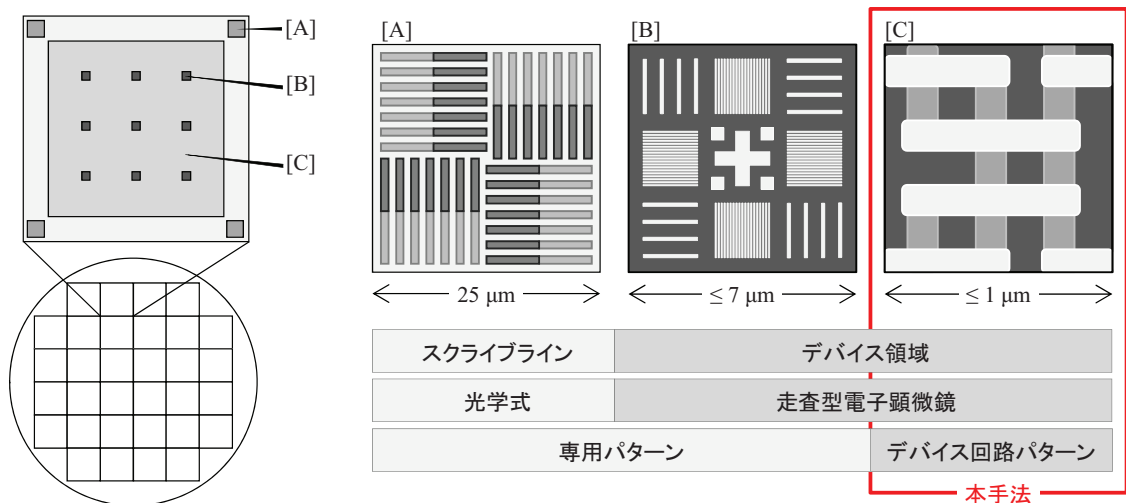


図 1.8: オーバーレイ計測手法の比較

1.3 論文構成

本論文の構成を図 1.9 に示す。まず、第 2 章において本研究の対象となるレビュー SEM の構成と特徴について説明する。次に、第 3 章において高精細な画像を安定して取得するために必要となるオートフォーカス処理のロバスト性向上技術について述べる。第 4 章では ADR における欠陥画像収集純度の向上を目的とした欠陥再検出技術について述べる。さらに、第 5 章ではできれば定量化機能の拡充を目的として開発したオーバーレイ計測技術について述べる。最後に第 6 章で本研究の結論と今後の課題を述べる。

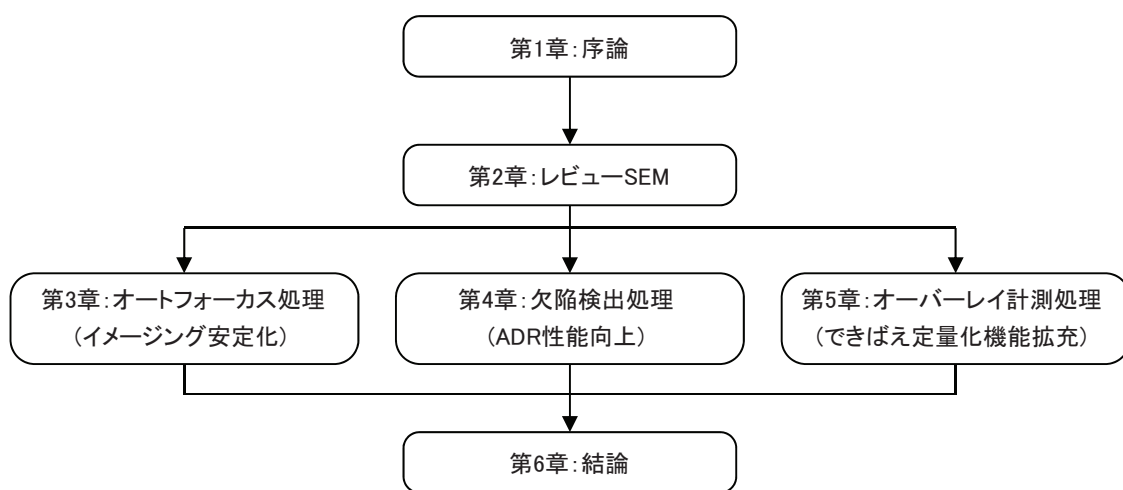


図 1.9: 論文構成

第2章 レビューSEM

2.1 まえがき

本章では、本研究で用いるレビューSEMについて、全体構成を述べた後、電子光学系の概要と画像取得原理、取得される画像の性質について述べる。

2.2 レビューSEMの構成と画像取得原理

2.2.1 全体構成

レビューSEMは半導体製造ラインにおいて発生する欠陥の観察や解析を行うための装置であり、300 mmのウェハを搭載可能なステージや、分解能がnmオーダーのSEM、撮像画像の処理機能を備えた装置である。本研究で用いるレビューSEMの構成を図2.1に示す。本装置は大別すると、(a)SEMユニットと、(b)画像処理ユニット、(c)ホストユニットからなり、各ユニットは情報の送受信が可能なネットワークを介して接続されている。

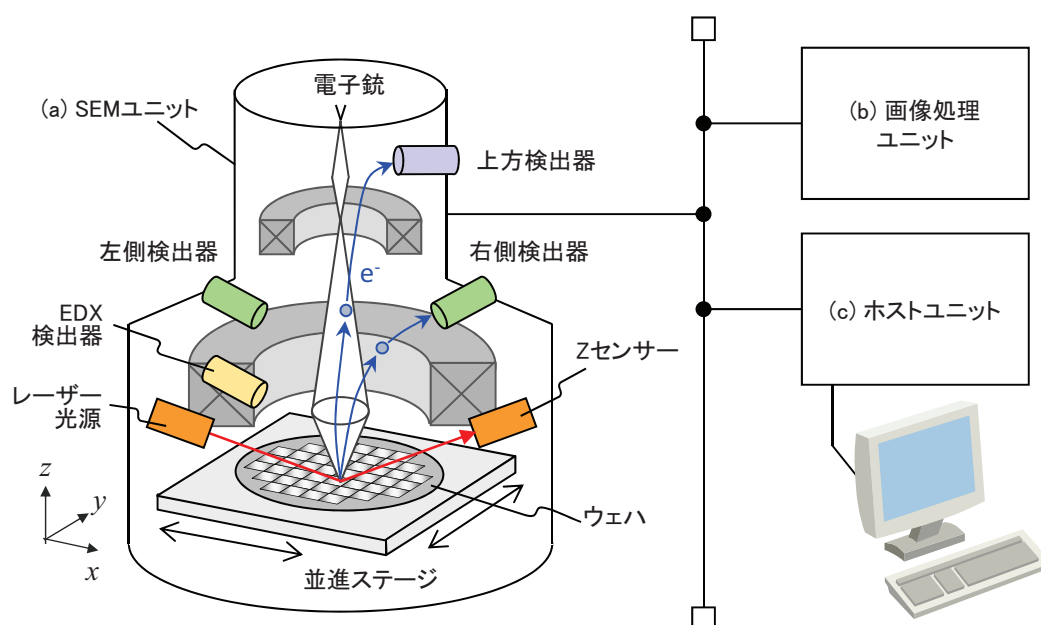


図 2.1: レビューSEMの装置構成

SEMユニットは後述する電子光学系を備えたSEMと、ウェハを搭載する並進ステージ、EDX用途の検出器、光学式Zセンサーを備える。ステージはSEMの真空チャンバー内に設けられており、ウェハ検査装置が出力した欠陥位置情報に基づいて観察を行う際、観察位置がSEMの視野に含まれるようにウェハを移動させる。EDXは欠陥に電子ビームを照射した際に発生する特性X線(蛍光X線)を検出し、エネルギー分布から欠陥を構成する元素などを解析する手法である。Zセンサーは対向して配置された光源とセンサーからなっており、一定の仰角を

もったレーザー光をウェハ表面に照射し、反射光をセンサーで検出する。試料高さが変化すると、センサー内における受光位置が変化することを利用し、ウェハ表面の高さを算出する。

画像処理ユニットは、ADR機能におけるオートフォーカス処理や欠陥再検出処理、できれば定量化機能における各種計測処理を実行するためのプロセッサを備えたユニットである。レビューSEMにおける画像処理はソフトウェアとして実装されており、画像処理ユニットでは汎用的なCPUを備えた産業用コンピュータが利用されている。

ホストユニットはSEMユニットと画像処理ユニットを制御し、「画像撮像→転送→画像処理」などの一連の動作を管理するユニットである。また、ディスプレイやキーボードなどのインターフェースを備え、ユーザからの指示受付、処理結果などの情報表示を行う。その他、画像取得条件(一次電子ビームの加速電圧や電流値など)や画像処理パラメータ、欠陥位置情報、撮像画像などを記憶する記憶領域を備えている。

次に、本研究で扱う画像の取得において特に重要となる電子光学系の概要と取得される画像の性質について述べる。

2.2.2 電子光学系と取得画像の性質

電子光学系の構成を図2.2に示す(図2.1の構成図からSEM像の形成に関係ないものは除いた)。電子ビームを発生させる電子銃、電子ビームを水平方向にスキャンするための偏向器、電子ビームを集束させるための対物レンズ、試料表面から発生した二次電子(Secondary Electron: SE)および後方散乱電子(Back-Scattered Electron: BSE)を検出する検出器を備える。検出器の構成として、本研究で用いるレビューSEMは上方検出器、左側検出器、右側検出器と呼ぶ3つの検出器を備える。このうち、左/右側検出器はそれぞれ対抗するように配置され、ウェハをステージに搭載した際、半導体ダイの配列に対して45度方向となる位置に配置されている(図2.2(b))。

画像の取得原理について説明する。電子銃から射出された一次電子ビームを対物レンズにより集束した上で、偏向器を用いて撮像したいウェハ領域内を連続的に走査し、試料から発生した二次電子や後方散乱電子を検出器により検出する。検出器からは検出した電子数に基づいたアナログ信号が出力され、これをサンプリング、量子化することにより走査領域に対応したデジタル画像を得ることができる。なお、SEMはショットノイズが大きいいため、同一箇所を一度走査するだけでは、SNRが高い画像を得ることができない場合が多い。そのため、通常は指定されたフレーム数だけ、一次電子ビームの走査およびデジタルデータの取得を行い、後にそれらの平均画像を求めることで画像データを生成する。ショットノイズはポアソン分布に従うため、平均化するフレーム数を F_{ave}




図 2.2: 電子光学系の構成

とすると、SNR は $\sqrt{F_{ave}}$ だけ向上する。

レビュー SEM の撮像画像例を図 2.3 に示す。この画像は回路パターン上の付着した球状の異物を撮像したものである (図 2.3(a))。3つの検出器を備えているため、同一の領域について3枚の画像が得られる。上方検出器は主に試料表層から発生する二次電子 (SE) を検出するように構成されている。エッジ効果によって回路パターンや欠陥など段差が生じる領域において二次電子が多く発生するため、上方検出器から得られる画像は回路パターンや欠陥の輪郭部において輝度が高くなる特徴があり、回路パターンや欠陥の形状を抽出するのに有効である。左/右側検出器は主に後方散乱電子 (BSE) を検出されるように構成されている。左/右側検出器から得られる画像からは、あたかも検出器方向から光を当てたかのような像が観察でき、対象物の凹凸情報を得ることができる。これは後方散乱電子が、その放出角度に応じて各検出器で選択的に検出されるためである。以降、上方検出から得られる画像を SE 像、左側検出器から得られる画像を Left 像、右側検出器から得られる画像を Right 像と記載する。また、Left 像と Right 像の濃淡値を足し合わせたものを BSE 像と記載する。

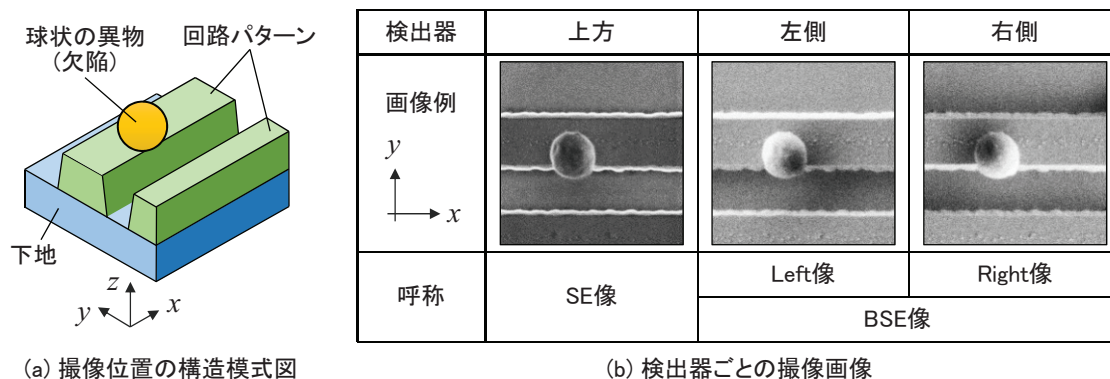


図 2.3: レビュー SEM を用いた撮像画像の例

2.3 むすび

本章では、本研究で用いるレビュー SEM の装置構成について説明し、電子光学系の概要と取得される画像の性質について述べた。

[1] 装置の基本構成

1. 装置は SEM ユニット、画像処理ユニット、ホストユニットから構成されている。
2. SEM ユニットは電子光学系と、ウェハを搭載する並進ステージ、EDX 用途の検出器、光学式 Z センサーを備える。並進ステージは観察位置が SEM の視野内に含まれるようにステージを移動する。また、光学式 Z センサーはウェハの表面高さを計測するのに利用される。
3. 画像処理ユニットは、欠陥再検出処理やできれば定量化機能における各種計測処理を実行するためのプロセッサを備えたユニットであり、産業用コンピュータにより構成されている。
4. ホストユニットは SEM ユニットと画像処理ユニットを制御し、レビュー SEM としての一連の動作を管理するユニットである。また、ディスプレイやディスプレイやキーボードなどのインターフェースを備え、ユーザからの指示受付、処理結果などの情報表示を行う。その他、画像取得条件や画像処理パラメータ、欠陥位置情報、撮像画像などを記憶する記憶領域を備えている。

[2] 電子光学系の概要と取得画像の性質

1. SEM は試料上で電子ビームを走査し、試料から発生する電子を検出することで画像を生成する。

2. 本研究で用いるレビューSEMは上方検出器、左側検出器、右側検出器と呼ぶ3つの検出器を備えている。
3. 上方検出器は主に試料表層から発生する二次電子(SE)を検出するように構成されており、得られる画像は回路パターンや欠陥の形状を抽出するのに有効である。
4. 左／右側検出器は主に後方散乱電子(BSE)を検出されるように構成されており、得られる画像からは、対象物の凹凸情報を得ることができる。
5. 上方検出から得られる画像をSE像、左側検出器から得られる画像をLeft像、右側検出器から得られる画像をRight像と記載する。また、Left像とRight像の濃淡値を足し合わせた画像をBSE像と記載する。

第3章 オートフォーカス処理のロバスト性向上技術^[36]

3.1 まえがき

本章では、電子顕微鏡を用いて高精細な画像を取得する際に必要となるオートフォーカス処理のロバスト性向上について述べる。まず、オートフォーカスの基本シーケンスと、レビューSEMにおける課題について述べる。オートフォーカスでは撮像画像から電子ビームの合焦度合いを焦点測度として定量化することが重要である。この焦点測度算出のロバスト性向上策としてマルチバンドパスフィルターを用いた手法を提案し、算出された焦点測度を統合し適切な合焦位置を算出する手法について提案する。最後に、擬似画像を用いて行った画像SNRと合焦位置算出精度に関する評価結果と、実画像を用いた合焦位置算出実験の結果について述べ、提案手法の有効性を示す。

3.2 レビューSEMにおけるオートフォーカスの原理

電子銃から照射された電子ビームは対物レンズを用いて集束され、試料に照射される。画像の分解能は電子ビームの径に依存しており、分解能の高い画像を得るためにはウェハ表面上で電子ビームが集束されるように対物レンズのパラメータを制御する必要がある。ウェハ表面で集束していない場合、試料上での電子ビーム径が大きくなり取得される画像は不鮮明なものとなる。以降、電子ビームが集束する高さを焦点位置、焦点位置とウェハ表面高さの一致度合いを画像から計測したものを焦点測度と呼ぶ。

ウェハ表面の高さは光学式のZセンサーで計測可能であり、計測結果をもとに電子ビームの焦点位置を調整することが可能である。しかし、ウェハは製造過程で帯電する場合があります、この場合は試料表面において電子ビームが減速または加速されるためZセンサーで計測した高さをもとに対物レンズを制御しても試料表面で集束しない。また、ウェハ表面が透明な材質(例えばSiO₂膜)でおおわれている場合には、光学式のZセンサーで正しい高さを計測することが困難となる。この問題を解決するため、焦点位置を振って複数の画像を撮像し、画像の鮮鋭度から合焦位置を求めるオートフォーカス処理が用いられている。

図3.1にオートフォーカス処理のフローを示す。まず光学式のZセンサーによりウェハ表面の高さを計測し、その高さが振幅の中央となるように焦点位置を一定のステップ幅で変化させながら複数枚の画像を撮像する。そして、各画像から焦点測度を算出する。図3.1では0~19の20枚の画像から焦点測度を算出した結果例を示している。次に算出した一連の焦点測度に対し、モデルフィッティングを行い、焦点測度が最大となる焦点位置を算出する。なお、焦点位置の振幅および画像の撮像間隔はオートフォーカス処理のパラメータであり、物理的な反りや帯電の度合いが大きいウェハでは振幅を大きく取る必要がある。

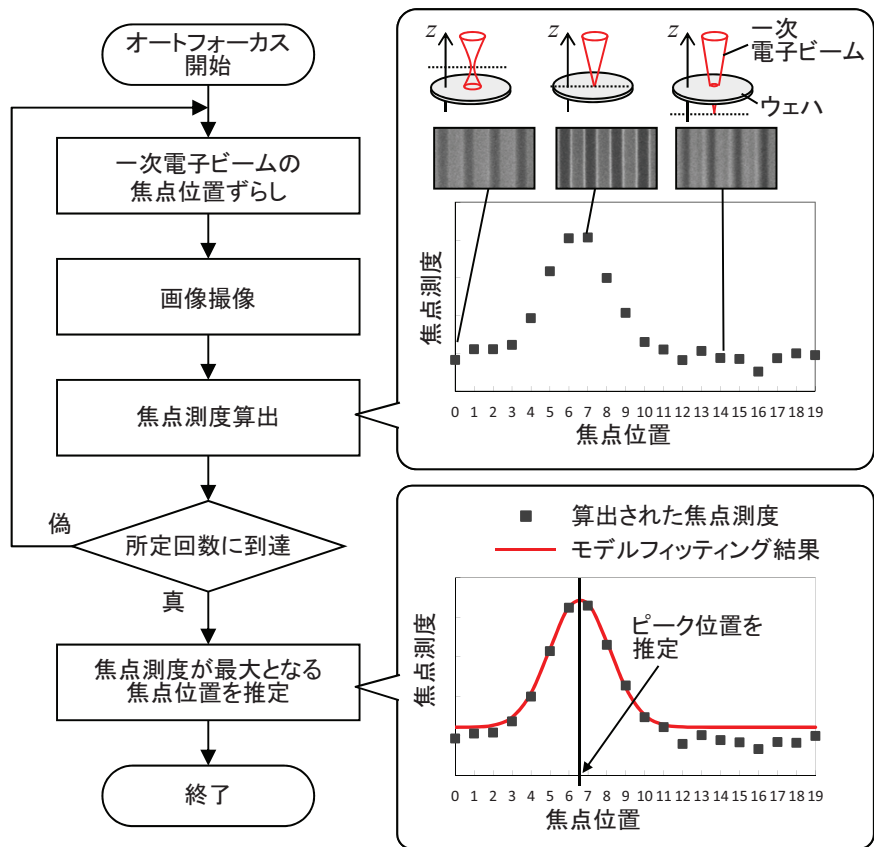


図 3.1: オートフォーカス処理のフロー

また、撮像間隔を狭く取ると安定性が向上するが、撮像に時間を要するため、ADR スループットの低下要因となる。これらのパラメータはオペレータにより事前に調整されているものとする。

焦点測度算出処理について説明する。焦点位置が適切な場合は鮮明な画像が得られ、不適切な場合は不鮮明な画像が得られることから、画像に含まれるエッジの強度を焦点測度として利用可能なことが知られている [26]。画像は1次元信号と同じく、周波数に分解して表現することが可能である。一般的に画像は様々な周波数成分を含むが、高周波成分のみを抽出すると、画像からエッジを抽出可能である。ただし、ノイズの抽出を抑制するため、一定以上の高周波成分は抽出せず、特定の周波数帯域の成分のみを抽出することが多い。図 3.2 は画像からエッジを抽出する処理を、周波数空間上の処理として表現したものである。画像を周波数空間上に変換した後、エッジ抽出フィルタを用いて特定の帯域の周波数成分のみが抽出されるように重み付けを行い、重み付けされた周波数成分を逆変換すると、画像のエッジが抽出される。

周波数空間上における重み付けは、画像に対してフィルタを畳み込む処理と等価である。高周波成分を抽出するフィルタとしてラプラシアンフィルタ、低周波成分を抽出するものとしてガウシアンフィルタがよく利用される。両者を組み合わせることにより、特定の周波数成分を抽出するバンドパスフィルタを構




図 3.2: 画像のエッジ抽出

成することができる。エッジ強度を焦点測度として使用するためには、バンドパスフィルタの周波数特性を正しく調整する必要がある。

レビューSEMのオートフォーカス処理においては、多種多様な外観を持つ画像に対応したバンドパスフィルタが必要となる。半導体チップの中には回路パターンが形成されていない領域(回路パターンなし領域)が存在し、回路パターンなし領域において生じた欠陥を観察する場合もある。図 3.3 は観察用画像の例を示したものである。回路パターンが形成されている領域においては明瞭なエッジが観察できる。一方、回路パターンなし領域においては観察可能なエッジが欠陥部のみにしか存在しない。特に、膜下欠陥などは回路パターン領域と比較してエッジ部位のコントラストが不鮮明となる。また、オートフォーカス処理にかかる時間を低減するためにはフレーム積算数 F_{ave} を低く抑えることが必要となり、焦点測度算出用の画像 SNR は観察用画像に比べて低い。そのため、ノイズ低減とエッジ抽出のバランスを取ることが重要となる。

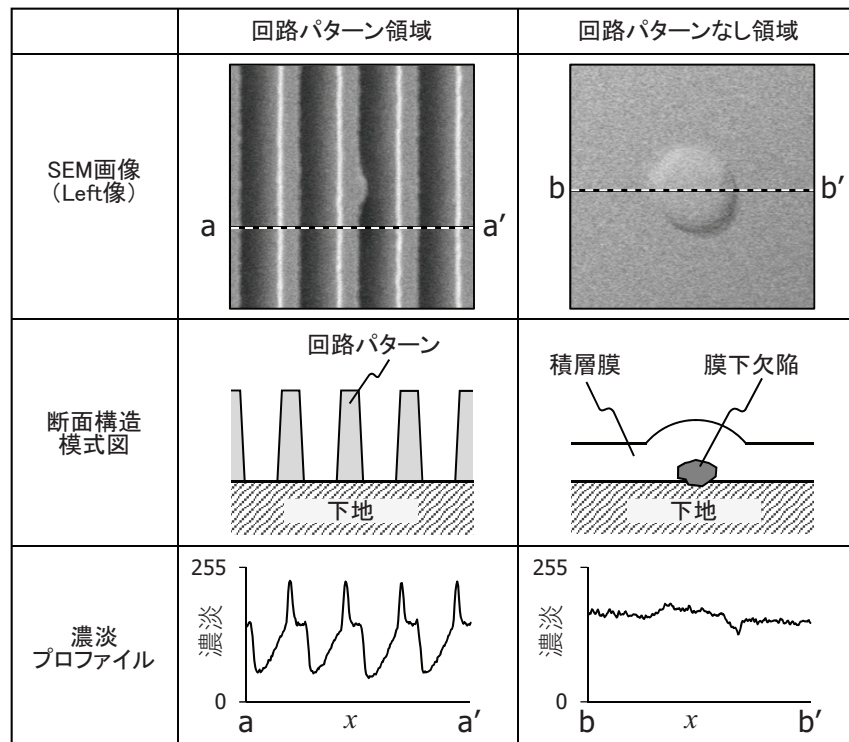


図 3.3: 回路パターン領域および回路パターンなし領域における観察画像例

3.3 マルチバンドパスフィルタを用いた焦点測度算出処理

合焦度合いの変化を焦点測度として反映する、つまり合焦位置で最大になり非合焦位置で小さくなるような焦点測度を算出するためには、合焦画像と非合焦画像の変異を定量化することが重要であり、合焦画像と非合焦画像の間で大きく変化する周波数成分をバンドパスフィルタにより抽出することが重要となる。

抽出すべき周波数成分は、焦点位置の変化に伴う点拡がり関数 (Point Spread Function: PSF) の変化と、観察対象がもつ周波数成分の相互作用により決まる。一次電子ビームの強度分布はシミュレーションなどにより求めることが可能である。ただし、SEM 画像の形成においては試料内での電子の拡散などを考慮する必要があり、画像上で観察される PSF は一次電子ビームの強度分布とは異なる。試料内での電子の拡散は、対象となるパターンの形状 (線幅やピッチ、断面形状など) や材質に依存するため、PSF を一意に算出することは現実的に困難である。

そこで、本研究では回路パターン領域と回路パターンなし領域の実画像を収集し、周波数解析を行うことで、抽出すべき周波数成分を求めることとした。回路パターンなし領域の画像としては、コントラストが低く、急峻なエッジを持たない欠陥として膜下異物、スクラッチ欠陥の画像を用いた。また、回路パターン領域の画像として、パターンピッチが 20 nm の回路パターンを視野 0.7 μm (200k 倍) で撮像した場合に相当する画像を用いた。

焦点位置の変化に感度を持つ周波数成分を抽出するため、合焦画像の周波数成分と合焦位置から 1 ステップ分焦点位置をずらした画像の周波数成分の差分を算出した。各画像から算出した差分の累積を図 3.4 の棒グラフとして示す。なお、図 3.4 では、周波数成分のうち x 方向の成分を示している。前述の通り、この周波数成分をバンドパスフィルタにより抽出することが焦点測度の算出において重要である。図 3.4 より回路パターンなし領域の低段差欠陥と、回路パターン領域の画像では異なった分布をとることがわかる。多種多様な外観を持つ画像に対して安定したオートフォーカス処理を実現するためにはこれらの分布をカバーする必要がある。ただし、焦点測度の算出に用いる画像 SNR は低いことから、幅広い帯域を抽出するフィルタを採用した場合、ノイズの影響を大きく受けると考えられる。また、画像ごとに抽出対象となる周波数成分が一部の帯域に偏っていることを考慮し、周波数特性が異なる 2 つのバンドパスフィルタを導入し、入力画像に応じてバンドパスフィルタを切り替えることとした。以降、低周波よりの周波数成分を抽出するものを低周波側フィルタ、高周波よりの周波数成分を抽出するものを高周波側フィルタと記載する。図 3.4 は開発したバンドパスフィルタの周波数特性も示しており、2 つのフィルタが回路パターン領域および回路パターンなし領域の画像の周波数成分にそれぞれ対応している。なお、後述するとおりエッジ抽出フィルタは高速化の観点から空間フィルタを適用

する形で実装している。空間フィルタとしてガウシアンフィルタやラプラシアンフィルタなどのガウシアン状の重みをもつフィルタを複数組み合わせているため、周波数空間上でもガウシアン状の周波数特性となる。




図 3.4: 周波数解析結果と開発したバンドパスフィルタの周波数特性

図 3.5 に開発した焦点測度の算出処理のフローを示す。一枚の入力画像に対して 2 つのバンドパスフィルタを独立に適用し、適用結果から 2 つの焦点測度を算出する。一般的に、画像に畳み込むフィルタのサイズを調整することで所定の周波数特性を得ることが可能である。しかし、フィルタのサイズを大きくすると処理時間の増大を引き起こす。そこで、画像をダウンサンプリングすることで所望の周波数特性を得ることとした。

入力画像 I_i ($i = 0, \dots, N-1$) (N は入力画像枚数) に対応した、焦点測度 \mathcal{F}_i^{Low} , \mathcal{F}_i^{High} は式 (3.1), (3.2) により算出する。ただし、 $Edge_i^{Low}$, $Edge_i^{High}$ はフィルタ適用後の画像を表す。以降、一連 ($i = 0, \dots, N-1$) の \mathcal{F}_i^{Low} を低周波側焦点測度分布、 \mathcal{F}_i^{High} を高周波側焦点測度分布と記載する。

$$\mathcal{F}_i^{Low} = \text{FM}(Edge_i^{Low}) = \sqrt{\frac{1}{N} \sum_{x,y} (Edge_i^{Low}(x,y) - \mu_i^{Edge_L})^2} \quad (3.1)$$

$$\mathcal{F}_i^{High} = \text{FM}(Edge_i^{High}) = \sqrt{\frac{1}{N} \sum_{x,y} (Edge_i^{High}(x,y) - \mu_i^{Edge_H})^2}$$

$$\mu_i^{Edge_L} = \frac{1}{N} \sum_{x,y} (Edge_i^{Low}(x,y)) \quad (3.2)$$

$$\mu_i^{Edge_H} = \frac{1}{N} \sum_{x,y} (Edge_i^{High}(x,y))$$

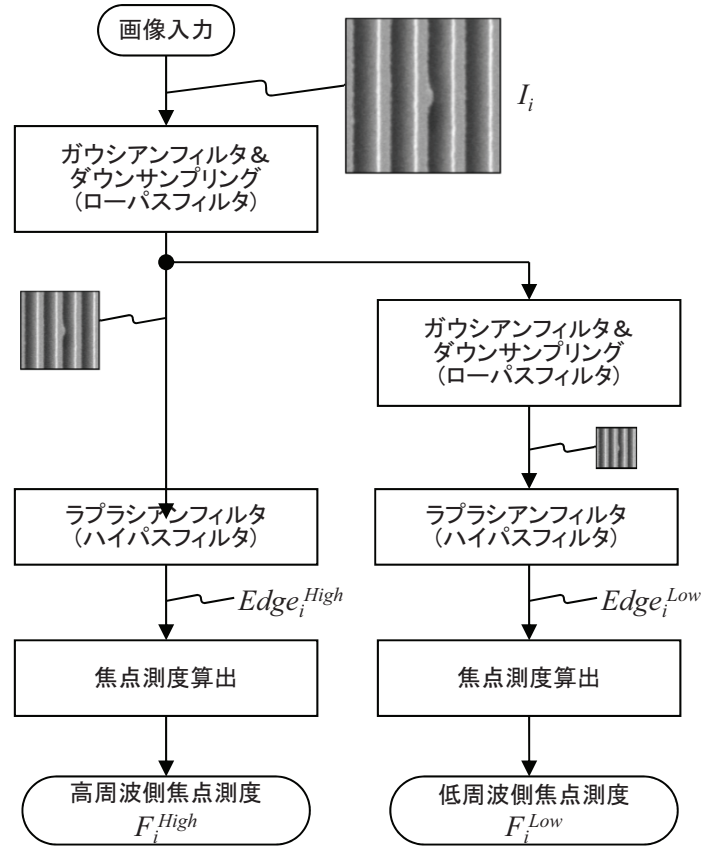


図 3.5: 2つのバンドパスフィルタを用いた焦点測定算出処理フロー

3.4 焦点測定分布からの合焦位置推定

焦点測定分布はガウス分布 (式 (3.3)) で近似できることが知られている [28]。そこで、算出された焦点測定分布に最小二乗法を用いてガウス分布を当てはめ、ピーク位置 p を合焦位置として算出する。

$$g(i) = \alpha \exp\left(-\frac{(i-p)^2}{2\sigma^2}\right) \quad (3.3)$$

前述の通り、焦点測定の算出には2つのバンドパスフィルタを用いており、結果として2つの焦点測定分布が得られる。そこで、ガウス分布を当てはめた結果をもとに信頼性判定を行い、信頼性が高い結果を用いることとした。具体的には、当てはめ誤差とガウス分布の広がり (σ) をもとに判定する。当てはめ誤差 e_{fit} は式 (3.4) に示すようにカーブ高さ α で正規化して算出する。

$$e_{fit}^{\{Low|High\}} = \frac{1}{\alpha} \sqrt{\frac{1}{N} \sum_{i=1}^N \left(g(i) - \mathcal{F}_i^{\{Low|High\}}\right)^2} \quad (3.4)$$

フィッティング時の誤差があらかじめ設定したしきい値よりも大きい場合は、ガウス分布とはみなせないため信頼性がないと判定する。また、 σ があらかじめ設定したしきい値よりも大きい場合、焦点位置の振り幅内において明瞭なピー

クが見られないため信頼性がないものと判定する。後述のシミュレーション実験より、当てはめ誤差のしきい値は高周波側フィルタから算出した焦点測度カーブに対しては0.24、低周波側フィルタから算出した焦点測度カーブに対しては0.15とした。また、 σ のしきい値は10ステップ分とした。両方の分布に信頼性が無い場合は、焦点位置の振り幅や画像の撮像視野を拡大し、画像取得の刻み幅を細かくした上でリトライ処理をする。

3.5 評価実験

3.5.1 擬似画像を用いた合焦位置の算出精度

画像SNRに対する合焦位置算出精度についてシミュレーション評価を行った。ここでは、まず焦点深度と焦点測度の関係性を評価し、次に、焦点測度の算出誤差と合焦位置の算出誤差の関係について評価し、焦点深度内の精度で合焦位置を算出するのに必要な焦点測度の算出精度を評価した。最後に画像SNRと焦点測度の算出誤差の関係について評価した。

まず、焦点深度と焦点測度の関係性を評価した。焦点深度は焦点位置の変化による画像のぼやけが目視において認識できない範囲である。本研究においては、画像ぼやけをガウシアンフィルタの重畳と仮定し、標準偏差が0.5画素のガウシアンフィルタ重畳に相当するぼやけは焦点深度以内とした。画像ぼやけに対する焦点測度の変化を定量化するため、ガウシアンフィルタを重畳した際の焦点測度の比率を数値計算により算出した。具体的にはバンドパスフィルタにガウシアンフィルタを重畳した際に透過するパワースペクトルの比率を算出しており、これは全周波数で同じ強度を持つ画像(白色雑音)における焦点測度変化率を表している。実画像においては周波数成分に偏りがあるため誤差が生じるが、多数の画像における平均的な比率として利用可能である。評価結果を図3.6に示す。




図 3.6: 画像ぼかし量に対する焦点測度分布の低下率

評価結果から、0.5画素以上のぼやけが生じるならば、開発した高周波側フィルタで算出した焦点測度は3%以上低下することがわかる。この対偶より、焦点測度の低下が3%未満ならば0.5画素未満のぼやけであり、焦点深度以内と言える。高周波側フィルタにより算出した焦点測度分布が標準偏差 σ_p^{High} のガウス分布である場合、 $\exp(-(0.247^2)/2) = 0.97$ より、 $\pm 0.247\sigma_p^{High}$ が焦点深度内となる。同様に低周波側フィルタでは焦点測度の低下が1%以内の未満であれば焦点深度内と言える。低周波側フィルタにより算出した焦点測度分布が標準偏差 σ_p^{Low} のガウス分布である場合、 $\exp(-(0.142^2)/2) = 0.99$ より、 $\pm 0.142\sigma_p^{Low}$ が焦点深度内となる。

次に、焦点測度の算出ばらつきと合焦位置の算出誤差の関係について評価した。本評価では、擬似的な焦点測度カーブ ζ_i ($i = 0, \dots, 10$)を式(3.5)に示すモデルにより作成し評価に用いた。 p は合焦位置を表すパラメータ、 ε_i^ζ は焦点測度の算出誤差を表す離散的な確率変数であり、平均 μ_ζ 、標準偏差 σ_ζ の正規分布 $\mathcal{N}(\mu_\zeta, \sigma_\zeta)$ に従うものとする。

$$\zeta^j(i) = \exp\left(-\frac{(i-p)^2}{2\sigma_p^2}\right) + \varepsilon_i^\zeta \quad (3.5)$$

$$\varepsilon_i^\zeta \sim \mathcal{N}(\mu_\zeta, \sigma_\zeta)$$

図3.7に生成した擬似的な焦点測度分布に対するモデルフィッティング結果を示す。焦点測度算出誤差の大きさ σ_ζ が小さい場合には、精度高く合焦位置を算出可能である(図3.7(a))のに対し、 σ_ζ が大きくなるとモデルフィッティングにより算出した合焦位置には誤差 p_{err} が生じる。各 σ_ζ について、10,000個の焦点測度カーブ $\zeta^j(i)$ ($j = 0, \dots, 9999$)を生成し、焦位置算出誤差 p_{err} のばらつき $\sigma_{p_{err}}$ を評価した(式(3.6))。結果を図3.8に示す。なお、3シグマ分の大きさを考慮するため、図中の横軸・縦軸の値はともに3倍している。




図 3.7: 擬似的な焦点測度分布に対するモデルフィッティング結果 ($p = 0.5, \mu_\zeta = 0.2, \sigma_p = 1.0$)

$$\sigma_{p_{err}} = \sqrt{\frac{1}{N_{\zeta}} \sum_j^{N_{\zeta}-1} \left(p_{err}^j - \frac{1}{N_{\zeta}} \sum_k p_{err}^k \right)^2}, \quad N_{\zeta} = 10000 \quad (3.6)$$




図 3.8: 焦点測度算出誤差 σ_{ζ} と合焦位置算出精度 $\sigma_{p_{err}}$ の関係

前述のとおり、高周波側フィルタ・低周波側フィルタを用いた場合の焦点深度はそれぞれ、 $\pm 0.247\sigma_p^{High}$ 、 $\pm 0.142\sigma_p^{Low}$ である。合焦位置の算出ばらつきを焦点深度 $\pm 0.247\sigma_p^{High}$ に含めるためには、高周波側フィルタを用いた際の焦点測度算出の誤差 σ_{ζ} を 0.24 以内に抑える必要があることがわかる。同様に、低周波側フィルタでは焦点測度算出の誤差 σ_{ζ} を 0.15 以内に抑える必要があることがわかる。

次に、画像 SNR と焦点測度の算出誤差 σ_{ζ} の関係について評価した。周波数およびノイズ量が既知の画像を用いるため、本評価では式 (3.7) により擬似的な画像 $I^P(x, y)$ 、 $I^B(x, y)$ を生成し、評価に用いた。 $I^P(x, y)$ は合焦画像を模擬したもの、 $I^B(x, y)$ は焦点振り幅の開始(終了)位置で撮像した非合焦画像を模擬したノイズ画像である。なお、 Q は画像幅 W を用いて正規化した周波数 ($Q = \frac{\text{周波数}}{W}$)、 ε^I はショットノイズ成分である。本来、SEM のショットノイズはポアソン分布に従うが、簡略化のため平均 0.5、標準偏差 σ_I の正規分布 $\mathcal{N}(0.5, \sigma_I)$ に従うものとした。生成した画像 $I^P(x, y)$ の例を図 3.9 に示す。

$$\begin{aligned} I^P(x, y) &= \frac{S}{2} \cos(2\pi Qx) + \varepsilon^I \\ I^B(x, y) &= \varepsilon^I \\ \varepsilon^I &\sim \mathcal{N}(0.5, \sigma_I) \end{aligned} \quad (3.7)$$




図 3.9: 評価用模擬画像の例 ($Q = 0.01, \sigma_I = 0.0$)

画像 SNR および周波数 Q が異なる擬似画像を用いて、焦点測度の算出誤差 σ_F を評価した。画像 SNR は S/σ_I とする。なお、本評価では $S = 128$ の固定とし、 σ_I を変化させることで SNR を変化させた。また、評価に用いた擬似画像の枚数 N_I は 1,000 枚とした。焦点測度の算出誤差は式 (3.8) により求める。ただし、 $\overline{\mathcal{F}^P}$ および $\overline{\mathcal{F}^B}$ は算出した焦点測度の平均値であり、式 (3.9) により算出する。このうち、 $\overline{\mathcal{F}^B}$ はノイズ画像から算出される焦点測度の平均値であり、焦点測度分布のオフセット成分 (式 (3.5) における μ_C) に対応する。焦点測度分布の高さを 1 としたときの算出誤差を求めるため、 $(\overline{\mathcal{F}^P} - \overline{\mathcal{F}^B})$ で正規化を行っている。

画像シミュレーションにより求めた焦点測度の算出誤差 σ_F と、前述の擬似的な焦点測度分布に与えた σ_C を比較することで、焦点深度以内となる画像条件を明らかにすることが可能となる。

$$\sigma_F = \frac{1}{\overline{\mathcal{F}^P} - \overline{\mathcal{F}^B}} \sqrt{\frac{1}{N_I} \sum_{k=0}^{N_I-1} (\text{FM}(I_k^P) - \overline{\mathcal{F}^P})^2} \quad (3.8)$$

$$\begin{cases} \overline{\mathcal{F}^P} = \frac{1}{N_I} \sum_{k=0}^{N_I-1} \text{FM}(I_k^P) \\ \overline{\mathcal{F}^B} = \frac{1}{N_I} \sum_{k=0}^{N_I-1} \text{FM}(I_k^B) \end{cases} \quad (3.9)$$

評価結果を表 3.1 に示す。焦点深度以内となっている条件 (0.24 および 0.15 以内) をハッチングで示している。以上示した結果より、低周波側フィルタと高周波フィルタを組み合わせることにより、画像 SNR が 1.5 以上あれば周波数 $Q = 0.01 \sim 0.08$ の範囲で焦点深度以内の合焦位置を算出可能である。対応周波数の妥当性に関して述べる。先端プロセスで製造される線幅 10nm、ピッチが 20 nm

の回路パターンを観察するためには撮像倍率として200k~500k程度が利用される。この場合、画像上のピッチは約15~38画素となり、周波数 Q は約0.07~0.03となる。よって、周波数 Q は0.01~0.08までカバーすれば先端プロセスによる微細回路パターンに対して十分に対応可能である。

表 3.1: 画像SNRおよび周波数 Q に対する焦点測度の算出誤差 σ_F の評価結果

(a) 低周波側フィルタ

		Q [cycle/pixel]									
		0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.10
SNR	0.5	0.169	0.039	0.041	0.059	0.458	1.000	1.000	1.000	1.000	1.000
	1.0	0.061	0.019	0.023	0.025	0.135	1.000	1.000	1.000	1.000	1.000
	1.5	0.038	0.013	0.015	0.016	0.075	1.000	1.000	0.693	1.000	1.000
	2.0	0.029	0.010	0.012	0.012	0.051	1.000	1.000	0.459	1.000	1.000
	2.5	0.024	0.009	0.009	0.010	0.040	1.000	0.953	0.282	0.849	1.000
	3.0	0.020	0.007	0.008	0.009	0.035	1.000	0.712	0.216	0.644	1.000
	3.5	0.016	0.006	0.007	0.008	0.031	1.000	0.530	0.172	0.486	1.000
	4.0	0.016	0.006	0.006	0.008	0.028	1.000	0.423	0.143	0.378	1.000

(b) 高周波側フィルタ

		Q [cycle/pixel]									
		0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.10
SNR	0.5	1.000	0.147	0.054	0.041	0.039	0.048	0.086	0.231	1.000	1.000
	1.0	0.318	0.046	0.021	0.016	0.016	0.020	0.033	0.073	0.333	1.000
	1.5	0.166	0.027	0.013	0.011	0.011	0.013	0.022	0.040	0.159	1.000
	2.0	0.104	0.020	0.009	0.008	0.008	0.010	0.018	0.026	0.094	1.000
	2.5	0.076	0.016	0.007	0.007	0.006	0.008	0.013	0.018	0.070	0.740
	3.0	0.055	0.013	0.006	0.005	0.005	0.007	0.011	0.015	0.054	0.522
	3.5	0.047	0.012	0.005	0.005	0.003	0.006	0.010	0.011	0.043	0.394
	4.0	0.040	0.010	0.005	0.005	0.003	0.006	0.009	0.011	0.035	0.300

3.5.2 実SEM画像を用いた合焦位置算出の成功率

焦点測度カーブの算出結果例を図3.10に示す。(a)は回路パターンの形成密度が疎な領域に対する結果であり、2つのバンドパスフィルタ両方によりピークが得られている。(b)は回路パターンの形成密度が密な領域に対する結果であり、高周波側フィルタのみにおいてピークが得られている。この画像は周波数 Q がおおよそ0.06となる画像であり、シミュレーション実験結果(表3.1)からも低周波側フィルタでは焦点測度を安定に算出できないことがわかる。(c)は低コントラスト欠陥の例として膜下欠陥を対象とした結果であり、低周波側フィルタのみにおいてピークが得られている。

ピークが得られないフィルタについては回路パターンもしくは欠陥の陰影ではなく、他のノイズ成分に反応していると言える。仮に、2つのバンドパスフィルタの周波数特性を1つのフィルタでカバーするようにした場合、回路パターンや欠陥の陰影とノイズ成分の分離性が低下する。2つのバンドパスフィルタを

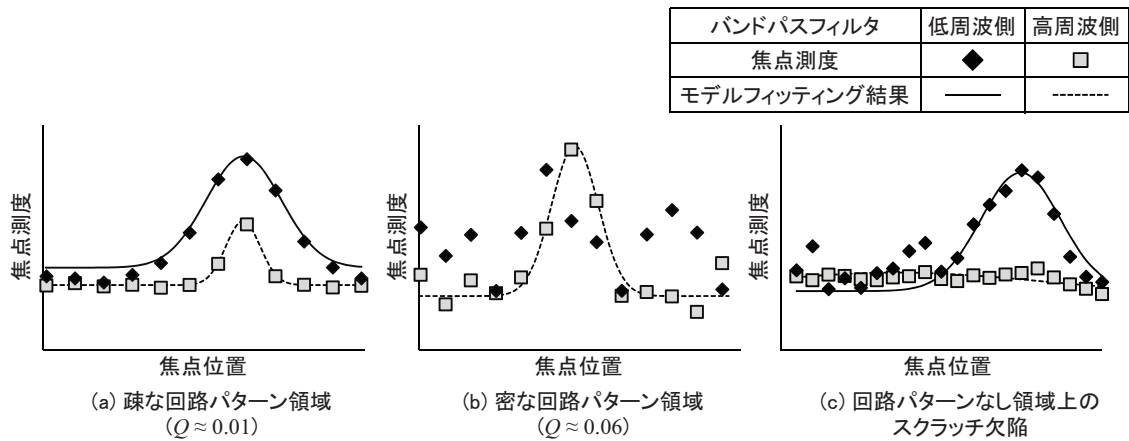


図 3.10: 実SEM画像から算出した焦点測定分布の例

用いて区分的に焦点測定を算出することにより、ノイズに対するロバスト性が向上していると考えられる。

次に、回路パターン領域の45画像、回路パターンなし領域の23画像、計68画像を用いて合焦位置算出成功率を評価した。結果を表3.2に示す。複数のバンドパスフィルタを用いることにより、高周波側フィルタのみを用いた場合と比較して成功率が60.3→95.6%に向上した。失敗した事例はいずれも画像SNRが1.5未満、周波数成分 Q は約0.01の画像であり、シミュレーション実験結果(表3.1)とも一致する。この場合、画像SNRが向上するように画像取得条件を変更(例えば加算フレーム数を高くする)してリトライする必要がある。以上、2つのバンドパスフィルタを用いることで実画像において合焦位置をロバストに算出可能となることがわかった。また、失敗事例に関してシミュレーション実験と一致していることを確認した。

表 3.2: 合焦位置算出の成功率

#	画像種類	評価数	成功率 %	
			高周波側フィルタのみ	フィルタ併用
1	回路パターン領域	45	84.4	100.0
2	回路パターンなし領域	23	13.0	87.0
Total		68	60.3	95.6

3.6 むすび

本章では、レビューSEMにおいて高精細な画像を取得する際に必要となるオートフォーカス処理のロバスト性向上について述べた。

1. オートフォーカスの基本シーケンスについて、電子ビームの焦点位置を変えながら複数枚の画像を撮像し、撮像画像から抽出したエッジの強度を焦点測定として算出し、合焦位置を求める処理について説明した。

2. 画像からエッジを抽出するためには、高周波成分を抽出するラプラシアンフィルタや、低周波成分を抽出するガウシアンフィルタなどを組み合わせてバンドパスフィルタを構成することが重要である。回路パターン領域と、回路パターンなし領域の画像について周波数解析を行い、抽出すべき周波数成分が異なることを明らかにした。
3. 周波数特性が異なる2つのバンドパスフィルタを導入し、入力画像に応じてバンドパスフィルタを切り替える手法を提案した。提案手法は、入力画像に対して2つのバンドパスフィルタを独立に適用し、得られた焦点測度分布の信頼性を評価することで、2つのフィルタを切り替える。
4. 提案手法の精度評価として擬似画像を用いた評価を行った。本評価により、先端プロセスで製造される線幅10nm、ピッチが20 nmの微細な回路パターン領域においても、画像SNRが1.5以上あれば安定してオートフォーカスを実行可能なことを明らかにした。
5. 実デバイスのSEM画像を用いた評価を行い、複数のバンドパスフィルタを用いることで、1つのバンドパスフィルタのみを用いた場合と比較して成功率が60.3 → 95.6%に向上することを確認した。

第4章 欠陥画像収集純度向上を目的とした欠陥再検出技術

4.1 まえがき

本章ではADRにおける欠陥画像収集純度の向上を目的とした、欠陥再検出処理の改良について述べる。特に虚報識別正解率の向上を目的として開発した2つの手法について述べる。1つ目は、製造ばらつきのランダム性に着目し、検査画像を複数枚の参照画像と比較検査することで、抽出される欠陥候補の数を抑制する手法である。2つ目は、抽出された欠陥候補それぞれについて、事前に学習した良品画像モデルを用いて、良品か欠陥かを識別する手法である。最後に、提案手法とサポートベクターマシンを用いた手法を比較した結果を述べ、提案手法の有効性を示す。

4.2 虚報識別正解率の向上策

欠陥再検出処理では、まず検査画像と参照画像の濃淡差を算出し、しきい値処理をすることで濃淡差が大きい領域を欠陥候補として検出する(以降、比較検査処理と記載)。次に、抽出された欠陥候補に対し、面積や濃淡差の大きさなどを算出し、最も欠陥らしい候補位置を欠陥位置として出力する。図4.1は、参照画像を用いて検査画像から欠陥候補を検出した結果の例である。検査画像の画像中央付近には回路パターンの線幅が広がった「配線太り」欠陥がある。製造ばらつきにより、回路パターンの線幅や側壁角はウェハ内で一定ではない。また、視野内に限ってもラインエッジラフネス(回路パターンのエッジが直線から凹凸にずれる現象)や表面ラフネスが生じる。微小な欠陥が検出できるように感度を高める(検出しきい値を下げる)と、製造ばらつきに起因した差異が欠陥候補として大量に検出される。図中の黄色枠は欠陥候補であり、ラインエッジラフネスが生じる回路パターンのエッジにおいて誤検出される傾向が強い。

検査画像と参照画像の画素同士の比較検査のみでは、微小欠陥の検出感度を維持しつつ誤検出を抑制することは困難である。現状、検査画像から欠陥候補がひとつでも抽出されると「欠陥あり」と判定される。そのため、検査画像が欠陥を含まない良品画像(=ウェハ検査装置の虚報)である場合においても、欠陥がないことを正しく識別できず、欠陥画像収集純度の低下要因となっている。

上記課題を解決するため、本研究では2つのアプローチを検討した。1つ目は、製造ばらつきのランダム性に着目し、検査画像を複数枚の参照画像と比較検査することで、正常部から抽出される欠陥候補の数を抑制する手法である。2つ目は、抽出された欠陥候補それぞれについて、事前に学習した良品画像モデルを用いて、各欠陥候補が良品か欠陥かを識別する手法である。




図 4.1: 比較検査において製造ばらつきに起因した誤検出 (黄枠) が大量に発生する事例

2つ目の識別処理では、欠陥候補点を中心として、 16×16 画素の局所画像を切り出し、局所画像の濃淡値を特徴量として識別器を構成した。全ての欠陥候補が良品と判定された場合、検査画像内には欠陥が含まれないと判定する。半導体デバイスの欠陥画像を、ユーザが定義した基準で自動分類する手法として、複数のものが提案されている [37, 38, 39, 40]。また、画像分類のタスクにおいては深層学習を用いることで非常に高い精度が得られることが報告されている [41, 42, 43]。これらの手法は百～数百枚程度の画像に対して、ユーザが一枚一枚カテゴリーを教示する必要がある。回路パターンの外観は製造工程ごとに様々であり発生する欠陥も多種多様であるため、各製造工程に応じた教示が必要となる。ただし、半導体デバイスの製造工程は数百工程からなるため、学習用サンプル収集および教示にかかる負荷低減が大きな課題となり現実的ではない。そこで、本研究では良品の局所画像のみを学習することで、欠陥と良品の局所画像を識別する手法について研究した。各工程のウェハがあれば良品画像を収集することは自動で行うことができ、ユーザによる教示も不要となる。このように、あるカテゴリーのサンプルのみを学習した上で、入力サンプルを学習済みカテゴリーと、未学習カテゴリーに分類する問題は1クラス分類と呼ばれる。

サポートベクターマシン (Support Vector Machine, SVM) は、分類問題に対する機械学習の手法として広く使われている手法であり [44, 45]、1クラス分類にも拡張されている [46]。1クラス分類向けのSVM(以降、OC-SVMと記載)は、全ての学習サンプルが1つのカテゴリーであるとみなし、特徴量空間において、全ての学習サンプルを包含する超平面を構築する。識別段階においては、識別対象のサンプルが超平面に包含されない場合、学習したカテゴリーとは別のカテゴリーであると識別する。OC-SVMは、1クラス識別問題の典型的な方法であるが、超平面は高次元の特徴空間において生成されるので、検証が困難である。

また、学習処理パラメータ調整が不十分である場合、過学習などを引き起こし識別性能の低下が生じる。本研究では、複数の良品局所画像から、良品の濃淡値分布を算出し、識別対象の局所画像が良品の分布に含まれるか否かを判定する処理を開発した。

4.3 欠陥再検出処理の改良

本検討では、比較検査による用いる参照画像の枚数を1枚から2枚に増やした。2枚の参照画像はそれぞれ検査画像との比較検査に用いられ、2つの比較検査結果を統合することで欠陥候補数を抑制する。さらに、2枚の参照画像同士を比較することで、製造ばらつきが生じやすく誤検出されやすい部位を欠陥候補として抽出することができる。参照画像同士の比較検査から得られる欠陥候補の局所画像は全て良品局所画像であるため、ユーザによる選別が不要で、自動的に識別器を学習することができる。

4.3.1 複数枚の参照画像を用いた比較検査処理

ラインエッジラフネスなどの製造ばらつきはランダムに生じるため、ラインエッジラフネスの凹凸の位置や大きさは撮像画像ごとに異なる。よって、撮像位置が異なる複数枚の参照画像を用いて検査画像と比較検査した場合、比較検査結果ごとに、製造ばらつきに起因して抽出される欠陥候補の位置が異なると期待できる。一方、欠陥の位置は検査画像内で変わらない。以上のことを利用し、異なる参照画像との比較結果から共通に検出された部分を欠陥候補として抽出する。処理フローを図4.2に示す。比較検査結果において、欠陥候補と抽出された領域の濃淡値は1、他は0とする。共通に検出された部分を抽出するために、複数の比較検出結果の論理積を画素ごとに適用する。

参照画像の数を3枚以上に増やし比較検査結果を統合することにより、さらに欠陥候補数を抑制できると考えられる。しかし、参照画像を撮像するための時間がかかり、ADRスループットが低下要因となる。本研究では、2枚の参照画像を用いた場合の性能評価を行った。

4.3.2 良品画像モデルを用いた識別処理

本処理は、複数枚の良品局所画像の特徴を良品画像モデルとして学習し、局所画像の特徴が良品画像モデルに当てはまらないものを欠陥として識別する。

図4.3に処理全体のフローを示す。本手法では、ADRを行う前に良品画像モデルの学習が必要である。参照画像には欠陥が含まれないため、参照画像同士を比較することにより、製造ばらつきに起因した欠陥候補のみを抽出可能である。数十セットの参照画像を用いて比較検査処理を行い、欠陥候補を中心とした局

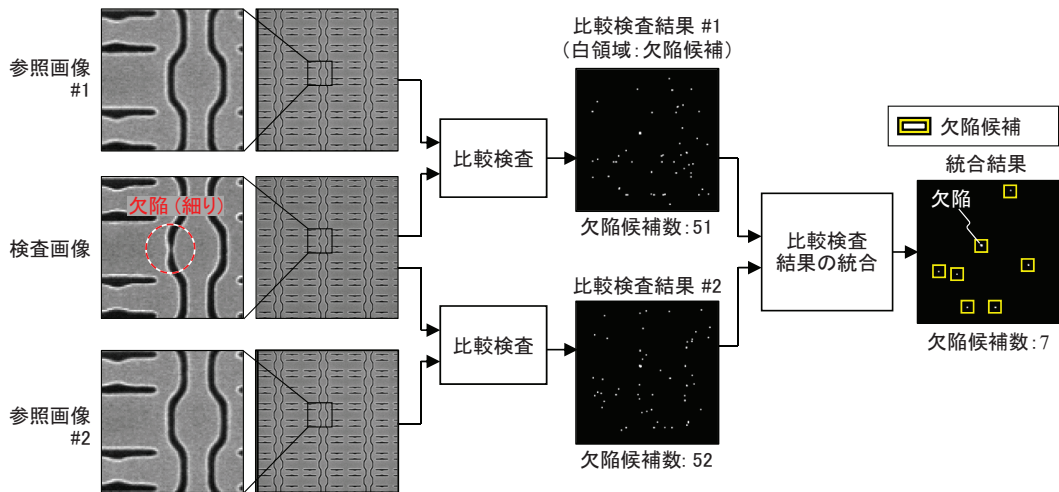


図 4.2: 複数の参照画像を用いた比較検査結果の統合

所画像を複数抽出し、良品画像モデルの学習を行う。デバイスの回路パターンレイアウトが異なっている場合においても、局所的にみると同様のパターンが観察可能なことが多い。そのため、局所画像から学習した良品画像モデルを記憶しておくことで、参照画像を撮像した領域以外の検査にも使用することができる。ADR を実行するステップでは、検査画像と参照画像を撮像し、比較検査から得られた欠陥候補に対し、良品画像モデルを用いて識別を行う。

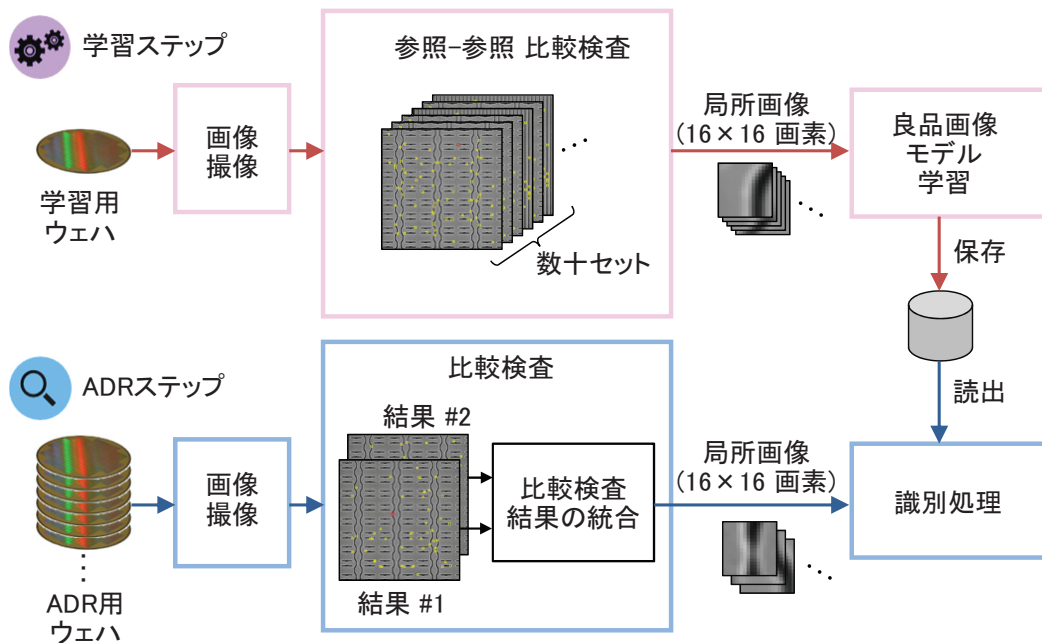


図 4.3: 学習ステップと ADR ステップの処理フロー

図 4.4 に良品画像モデルの学習処理フローおよび識別処理のフローを示す。収集された良品局所画像には、回路パターンの種類や向き、位置、線幅などが異なる様々な外観を持つものが含まれる。そのため、クラスタリングを行い、良品局所画像を類似した外観を持つもの同士のグループに分類することが重要と

なる。なお、開発したクラスタリング処理の詳細については4.3.3で述べる。

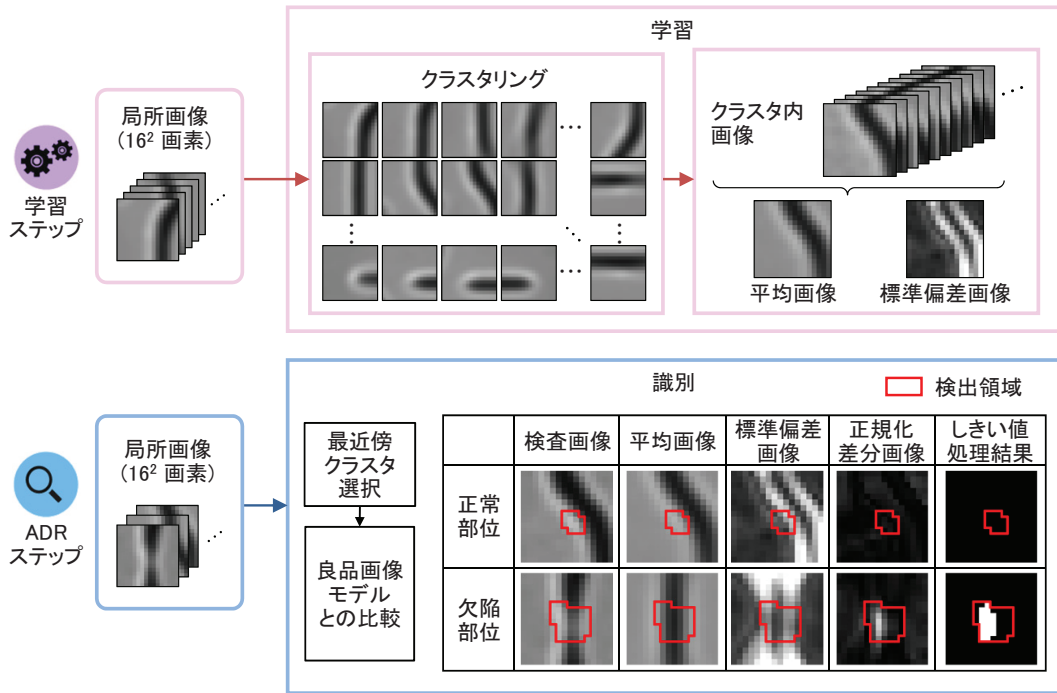


図 4.4: 学習処理と識別処理の処理フロー

クラスタリング後、各クラスタ ($c = \{1, 2, \dots, \lambda\}$) に含まれる良品局所画像について、平均画像 $\mu^c(x, y)$ と偏差画像 $\sigma^c(x, y)$ を式 (4.1) により算出する。ただし、 c_N は c 番目のクラスタに含まれる良品局所画像の枚数、 P_i^c は c 番目のクラスタにおける i 番目の画像を表す。

$$\mu^c(x, y) = \frac{1}{c_N} \sum_{i=1}^{c_N} P_i^c(x, y) \quad (4.1)$$

$$\sigma^c(x, y) = \sqrt{\frac{1}{c_N} \sum_{i=1}^{c_N} (P_i^c(x, y) - \mu^c(x, y))^2}$$

検査ステップでは検出された局所画像 ($T_i(x, y)$) に対してもっと近いクラスタ c を選択し、クラスタに対応する平均画像との差分を標準偏差で正規化した正規化差分画像 D_i を算出する (式 (4.2))。

$$D_i(x, y) = \frac{T_i(x, y) - \mu^c(x, y)}{\sigma^c(x, y)} \quad (4.2)$$

得られた正規化差分画像 D_i に対して事前に設定したしきい値 Th_D を用いてしきい値処理を行う。このしきい値 Th_D は各画素が平均値からどの程度外れている場合に異常値として判定するかを意味している。画素ごとの標準偏差 $\sigma(x, y)$ に応じて感度に変化するため、標準偏差の大きい領域の検出を抑制することが

できる。具体的には、ラインエッジラフネスの影響を大きく受けた回路パターンのエッジで誤検出を抑制することができる。

i 番目の局所画像について良品画像モデルを用いて式 (4.3) により欠陥マスク画像 $R_i(x, y)$ を再検出する。ここで、 $M_i(x, y)$ は比較検査処理により得られるマスク画像を表し、欠陥候補として検出された画素は1、それ以外は0となる画像である。そして、再検出した欠陥マスクの面積 ($\sum_{x,y}(R_i(x, y))$) が1以上の場合局所画像を欠陥と判定し、0の場合は良品と判定する。

$$R_i(x, y) = \begin{cases} 1 & D_i(x, y) \geq Th_D \wedge M_i(x, y) = 1 \\ 0 & otherwise \end{cases} \quad (4.3)$$

4.3.3 局所画像のクラスタリング処理

収集したパッチ画像は異なる外観をもつものが混在しており、良品画像モデルを作成するにあたりクラスタリングが必要となる。今回、クラスタリングの手法として自己組織化マップ (Self Organized Map: SOM)[47]を用いることとした。SOMは高次元の入力データを位相的な構造を保ちつつ低次元空間に写像することを可能とする。そして、低次元空間上に配意したノードをクラスタとみなすことでクラスタリングに活用することができる。図4.5は高次元 ((x, y, z) の3次元) データを低次元 ((u, v) の2次元) マップに写像した例を示している。低次元空間上には複数のノードが配置され、各ノードは高次元空間の一点を指し示す参照ベクトルを持つ。SOMの学習は、高次元データ空間上での入力データ同士の関係性がマップ空間上でも保たれるように参照ベクトルの更新を繰り返し行う。

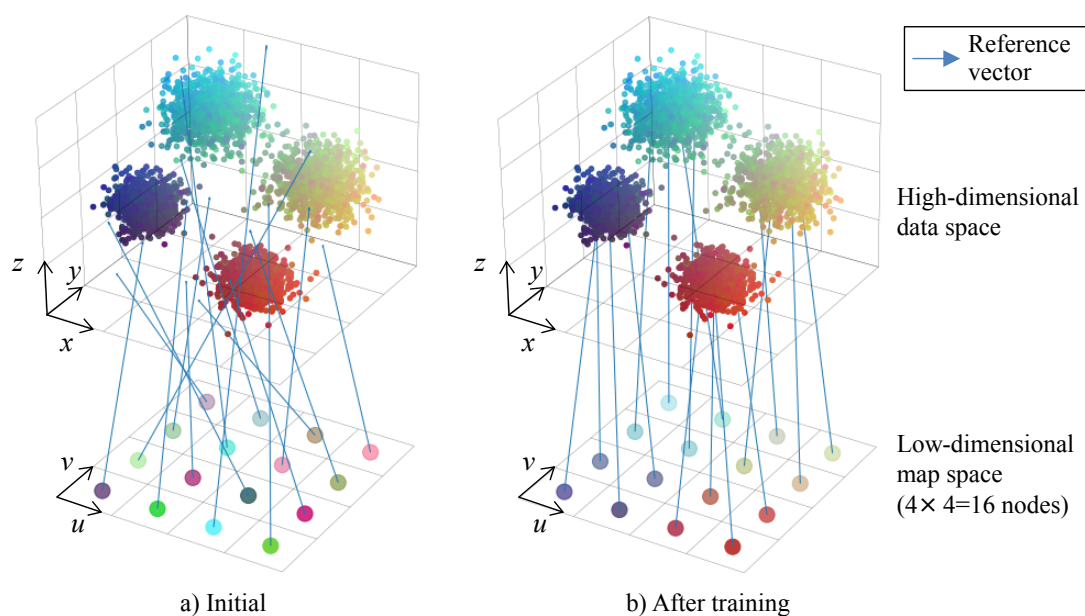


図 4.5: 自己組織化マップの概念図

識別時には識別対象の局所画像に対してもっとも近いクラスタを選択する必要がある。この時、学習時に作成したクラスタの参照ベクトルと局所画像を総当りで比較する必要がある、クラスタ数が多くなると処理時間を要する。この問題を解決するため、階層型適応的自己組織化マップ (Growing Hierarchical SOM: GHSOM)[48] を用いた。GHSOMではマップを階層化し、各マップのサイズと階層数を平均量子化誤差に応じて自動調整する。

i 番目のノードが持つ参照ベクトルを m_i とすると、 i 番目のノードに関する平均量子化誤差は式 (4.4) により求まる。ただし、 x は m_i が最近傍となる学習サンプルの集合であり、 d はその個数である。また、最上位のマップは1つのノード (m_0) のみを持つものとする。

$$mqe_i = \frac{1}{d} \sum \|x - m_i\| \quad (4.4)$$

GHSOMでは各ノードの平均量子化誤差をもとにマップの成長と階層化の判定に用いる評価値を算出する。この評価値の算出方法を式 (4.5) に、ノードと評価値の関係の例を図 4.6 に示す。

$$MQE_m = \frac{1}{n} \sum mqe_i \quad (4.5)$$




図 4.6: GHSOM における平均量子化誤差 (Mean of Quantization Error: MQE) 算出

初期のノード数は 2×2 などの少数にしておき、 $MQE_m \geq \tau_m \cdot MQE_{m-1}$ となる場合は、マップの成長 (ノード数の増加) を行う。なお、 MQE_{m-1} は親ノードの平均量子化誤差であり、 τ_m は成長を制御するパラメータである。成長処理は、まずマップの中から平均量子化誤差が最大のノード N_{max} を探索し、その近傍から平均量子化誤差が最小のノード N_{min} を探索する。そして、 N_{max} と N_{min} の間に新しいノードを挿入する。ノードが追加されることにより平均量子化誤差は低下する。以上の成長を、前述の条件が満たされなくなるまで繰り返し実行する。

また、 $mqe_i \geq \tau_u \cdot mqe_0$ であるノードについては階層化を行う。階層化は m_i が最近傍となる学習サンプルを用いて、GHSOM を再帰的に作成する。なお、 τ_u は階層化を制御するパラメータであり、事前に設定するものである。

マップ内のノード数を N 、階層数を L とすると、 N^L 個のノードが存在するが、探索は NL 回で可能である。そのため、クラスタ数を増やすにはマップ内のノード数を増やすよりも、階層数を増やした方が探索時の効率が良い。そこで、本検討では検査ステップにおけるクラスタ選択の高速化を目的にマップ内のノード数に上限を設定することとした。具体的には成長条件を満たしている場合においても繰り返し回数に上限を設けた。これにより、横方向ではなく深さ方向に細分化されると期待できる。

また、良品画像モデル(平均画像と標準偏差画像)作成時の安定化を図るため、学習サンプル数が一定数以下となるクラスタを削除し、近傍のクラスタにマージすることとした。

4.4 評価実験

4.4.1 評価方法

評価では検査画像に欠陥がある場合に欠陥部位を正しく検出する検出成功率 tp_r と、検査画像に欠陥がない場合に良品画像と判定する虚報識別正解率 tn_r を評価した。なお、検査画像からひとつも欠陥部位が検出されない場合のみ、良品画像として判定される。評価における画像の組み合わせを図4.7に示す。良品モデルの学習時は図4.7(a)に示すように良品画像同士の比較検出を行った。検出成功率の評価には検査画像として欠陥が存在する画像を設定し、参照画像として良品画像を用いた。虚報識別正解率の評価では、検査画像として欠陥を含まない良品画像を設定し、参照画像も良品画像を用いた。

評価に用いたデータセットを表4.1に示す。欠陥画像例を図4.8に示す。図では 512×512 画素の検査画像と、検査画像から欠陥部位を切り出した 85×85 画素の画像を記載している。欠陥種は配線太りと配線細りの作り込み欠陥であり、本評価では3種類の欠陥サイズを用いて評価を行った。

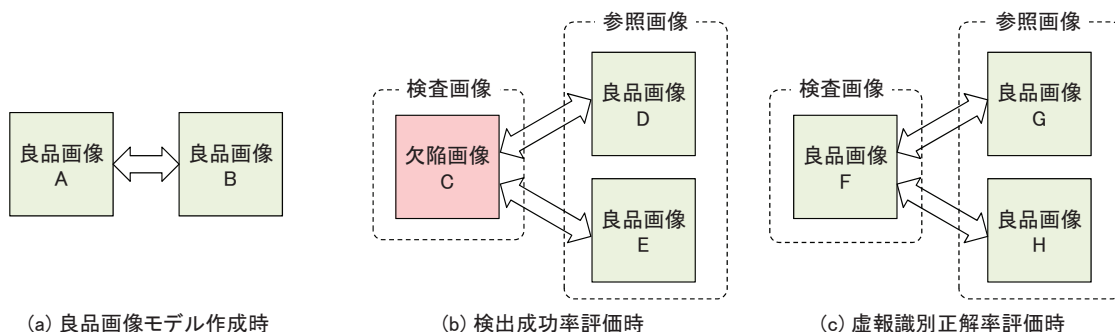


図 4.7: 評価用の画像組合せ

項目	値
欠陥画像枚数	45
良品画像枚数	45
画素サイズ	20 nm / 画素
画像サイズ	512 × 512




図 4.8: 評価用データセットにおける欠陥画像例

4.4.2 パッチ画像のクラスタリング結果

クラスタリングを行って得られた平均画像の一覧を図 4.9 に示す。GHSOM のパラメータである、 τ_m と τ_u は事前評価結果からともに 0.5 とした。各局所画像のサイズは 16 × 16 画素である。学習に用いた局所画像の数は 2908 個であり、4.3.3 節で示した手法により合計で 44 個のクラスタに分割された。画像縦方向に伸びるパターンや横方向に伸びるパターンの他、回路パターンの端部などの局所画像が見られる。




図 4.9: クラスタ結果 (平均画像の一覧)

4.4.3 虚報識別率および検出成功率の評価結果

検出成功率と虚報識別正解率について評価を行った。

OC-SVMについては、局所画像内の濃淡値を256次元(16×16)の特徴量に対して、主成分分析を適用し次元圧縮を行い、学習と識別に用いた。部分空間の次元数は、主成分分析時の累積寄与率(部分空間においてもとの特徴量をどの程度表現されているかを表す割合)が99%になるように設定した。また、OC-SVMにおいては過学習と汎化性能のトレードオフを調整するために、パラメータ ν と γ を調整する必要がある。 ν は学習サンプルに含まれる例外的なサンプルの割合を指定するパラメータ、 γ はRBFカーネルのパラメータである。本評価では、 $\nu = \{0.1, 0.2, \dots, 0.9\}$ 、 $\gamma = \{0.0078, 0.0156, 0.031, 0.063, 0.125, 0.5, 1.0, 2.0, 4.0\}$ の組合せについて評価を行った。良品画像モデル識別においては、正規化差分画像に対するしきい値 Th_D がパラメータであり、0.0~4.0の範囲で評価を行った。

良品画像モデル識別、OC-SVMそれぞれについて、1枚の参照画像を用いた場合と2枚の参照画像を用いた場合で評価した。参照画像が2枚の場合は、4.3.1節で述べた手法で比較結果を統合している。図4.10に検出成功率と虚報識別正解率の関係を示す。右上の角に近い結果ほど、検出成功率と虚報識別正解率ともに高く、性能が高いと言える。

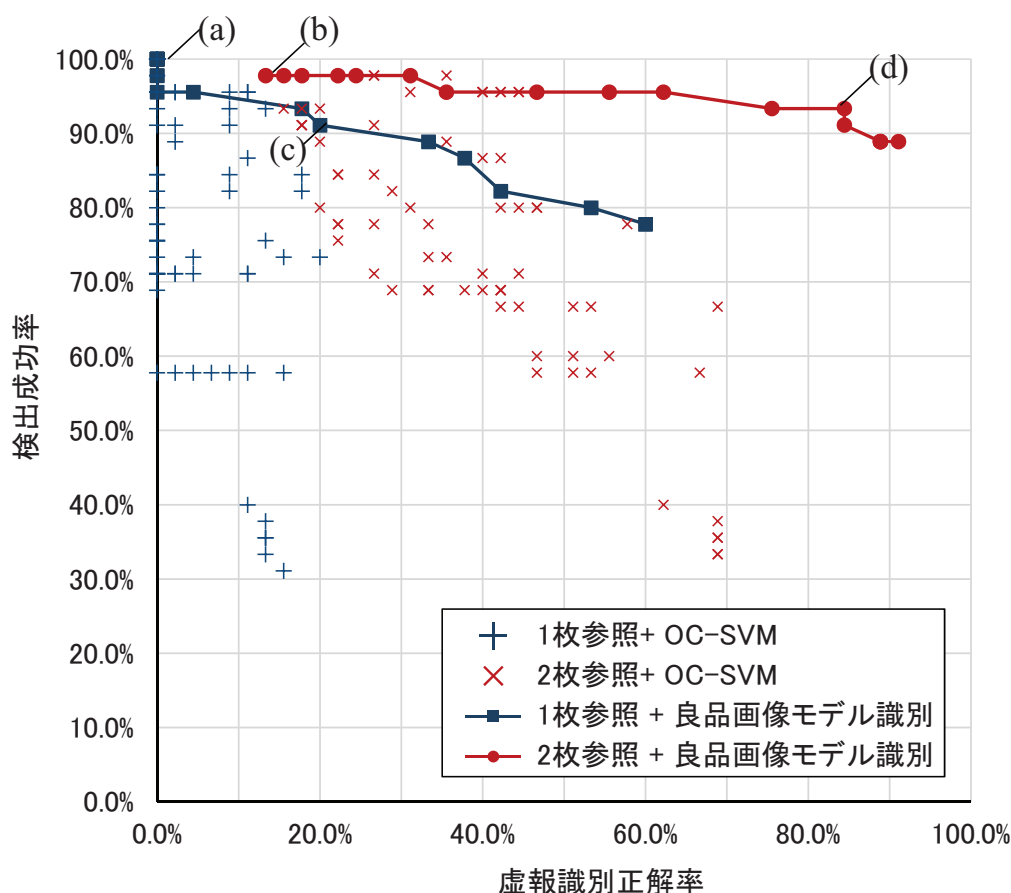


図 4.10: 虚報識別正解率と検出正効率の評価結果

開発した良品画像モデル識別はOC-SVMと比較して全体的に高い性能が得られている。OC-SVMにおいて虚報識別正解率が高い条件を選ぶと、著しく検出成功率が低下する。OC-SVMは局所画像全体の特徴を評価しているのに対し、良品画像モデル識別では比較検出によって抽出された領域 ($M_i(x, y)$) のみに着目した評価を行っている。これは各欠陥候補において個別に特徴量選択を行っているのに相当し、識別性能の向上に効果的であったと考えられる。

表 4.2 に提案手法における虚報識別正解率と検出成功率をまとめる。(a)~(d) は図 4.10 のものに対応する。なお、 $Th_D = 0$ の条件は、良品画像モデル識別を適用しない場合に相当とする。

最初に、表 4.2 と図 4.10 から画像あたりの平均誤検出数と虚報識別正解率に着目して評価結果について説明する。なお画像あたりの平均誤検出数は、抽出された欠陥候補に対して良品モデルによる識別を行い、欠陥と判定された候補数の平均値である ($Th_D = 0$ の場合は抽出された欠陥候補数の平均値)。参照画像を 1 枚から 2 枚にして比較結果を統合することにより、画像あたりの平均誤検出数が $64.6 \rightarrow 6.1$ 個に減少し、虚報識別正解率が $0.0 \rightarrow 13.3\%$ に向上した ((a) \rightarrow (b))。良品画像モデル識別を用いた場合は、画像あたりの平均誤検出数が 3.7 個となり、20.0%の虚報識別正解率を得た。そして、比較結果の統合と良品画像モデル識別を組み合わせた場合、画像あたりの平均誤検出数が 0.2 個となり、84.4%の虚報識別正解率を得られた。

次に、検出成功率の評価結果について説明する。1 枚の参照画像のみを用いた場合、検出成功率は 100.0%であったが、2 つの比較結果を統合した結果、97.8%に低下した。これは、2 つの比較欠陥を統合する際、検出された欠陥位置が完全に一致しなかったことに起因する。比較結果の統合を行わずに (参照画像 1 枚で) 良品モデルを用いた場合、検出成功率が $100.0 \rightarrow 91.1\%$ に低下した。これは識別処理により欠陥部位の局所画像が良品と識別されたことによる。そして、2 つの手法を組み合わせた場合、93.3%の検出成功率を得た。なお、比較結果の統合を行わない場合よりも検出成功率が向上している ($91.1 \rightarrow 93.3\%$) 理由は、比較結果の統合を行うことで誤検出部位が抑制されるケースがあるためであり、後段の処理で欠陥と識別された中から最も欠陥らしい部位を選択していることに起因している。なお、欠陥検出に失敗した画像は図 4.8 のうち、“サイズ小”に該当するもののみであった。

表 4.2: 虚報識別正解率と検出正効率

	Th_D	参照画像枚数	画像あたりの 平均後検出数	虚報識別 正解率 tn_r [%]	検出 成功率 tp_r [%]
(a)	0.0	1	64.6	0.0	100.0
(b)	0.0	2	6.1	13.3	97.8
(c)	3.0	1	3.7	20.0	91.1
(d)	3.0	2	0.2	84.4	93.3

欠陥画像収集純度 adr_{purity} について述べる。第1章で述べたように、ウェハ検査装置の虚報率を nui_r としたとき、欠陥画像収集純度 adr_{purity} は、以下により求まる。

$$adr_{purity} = \frac{(1 - nui_r)tp_r}{(1 - nui_r)tp_r + nui_r(1.0 - tn_r)} \quad (4.6)$$

図 4.11 は、ウェハ検査装置の虚報率 nui_r に対する欠陥画像収集純度 adr_{purity} を従来手法 ($tn_r = 0.0\%$, $tp_r = 100.0\%$) と提案手法 ($tn_r = 84.4\%$, $tp_r = 93.3\%$) について評価した結果である。従来手法はウェハ検査装置の虚報率 nui_r の増大に伴い欠陥画像収集純度 adr_{purity} が低下するのに対し、提案手法は低下度合いが緩和されていることがわかる。例えば、ウェハ検査装置の虚報率 nui_r が 50% である場合において、従来手法は欠陥画像収集純度 adr_{purity} が 50% であるのに対し、提案手法では 85.7% となる。




図 4.11: ウェハ検査装置の虚報率と欠陥画像収集純度の評価結果

4.5 むすび

本章では、レビュー SEM の ADR における欠陥画像収集純度の向上における課題について述べ、虚報識別正解率および検出成功率の向上を目的とした提案手法について述べた。

1. レビュー SEM の ADR においてはウェハ検査装置の出力から実報と虚報を識別し、真に欠陥である画像のみを収集することが求められており、欠陥再検出処理においては微小な欠陥を高感度に検出しつつ、製造ばらつきに起因した誤検出を抑制することが課題である。本研究では、(a) 複数の比較検出結果の統合手法と、(b) 良品モデルを用いた欠陥識別手法の 2 つの手法を開発した。

2. (a) 複数の比較検出結果の統合手法は、製造ばらつきに起因した誤検出はランダム性が高いことに着目し、異なる参照画像を用いた複数の比較検出結果から共通して検出される位置を欠陥として抽出する手法である。
3. (b) 良品モデルを用いた欠陥識別手法は、製造ばらつきの外観を良品モデルとして予め学習しておき、比較検査で検出された欠陥候補について欠陥か良品かを識別する手法である。
4. 実デバイスのSEM画像を用いた評価を行い、提案した欠陥識別手法は一般的な識別手法である one-class SVM よりも精度高く識別可能であった。また、提案した2つの手法を組み合わせることで虚報識別正解率が0.0%から84.4%に向上することを確認した。これにより、ウェハ検査装置に虚報率が50%である条件において欠陥画像収集純度が50.0%から85.7%に向上する。

第5章 レビューSEM像を用いたオーバーレイ計測^[49, 50]

5.1 まえがき

本章では、半導体デバイスのできばえ定量化を目的としたオーバーレイ計測手法について述べる。提案手法は、被計測画像と基準画像を比較することで相対的なオーバーレイを計測するものである。具体的には複数の製造工程により形成される回路パターン領域を撮像画像から工程別に認識し、被計測画像と基準画像間で回路パターン領域の位置ずれ量を算出することでオーバーレイを計測する。評価結果として、擬似画像を用いた精度評価を示した後、実パターン画像を用いた評価結果を示す。また、計測結果に対してモデルフィッティングを用いた解析を行った結果について述べ、提案手法の有効性を示す。

5.2 計測アルゴリズム

提案手法は下層の回路パターンに対する上層の回路パターンの位置ずれ量をオーバーレイとして計測する(以降、上層/下層の回路パターンを、単に上層/下層パターンと記載する)。ただし、上層パターンと下層パターンの正しい位置関係は計測対象のデバイスにより異なる。そのため、オペレータにより入力された基準画像における位置関係を正解として、計測に用いる。

開発したオーバーレイ計測処理のフローを図5.1に示す。まず、基準画像および被計測画像それぞれについて、回路パターンが形成されている領域を画像から認識する。この際、下層パターンと上層パターンにわけてそれぞれ認識する。次に、基準画像と被計測画像の間における下層パターンの位置ずれ量(dx_L, dy_L)と、上層パターンの位置ずれ量(dx_U, dy_U)をそれぞれ算出する。最後に、算出した位置ずれ量をもとに、式(5.1)を用いてオーバーレイを算出する。これは、基準画像と被計測画像の下層パターンの位置を合わせた上で、上層パターンの位置ずれ量を算出することを意味している。

$$\begin{cases} e_x = dx_U - dx_L \\ e_y = dy_U - dy_L \end{cases} \quad (5.1)$$

本手法以外にデバイスの回路パターン画像からオーバーレイを算出する方法として、上層パターンおよび下層パターンのエッジ位置を計測し、両者の位置関係を定量化する方法が考えられる。しかし、この方法は対象のエッジが観察できる位置を画像上で予め指定することが必要であり、条件設定に時間を要する。一方、本手法では基準画像を用意するだけで計測が可能となり条件設定が容易である。ただし、算出されるオーバーレイは基準画像に対する相対値となる。

以降、開発した処理について重要となる、回路パターン領域の認識アルゴリズム(5.2.1節)と位置ずれ量の定量化アルゴリズム(5.2.2節)について説明する。

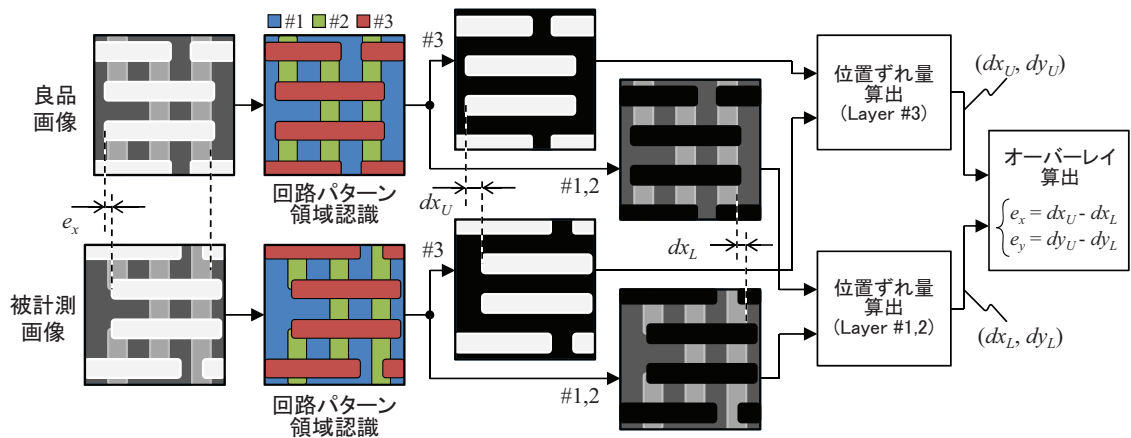


図 5.1: オーバーレイ計測処理のフロー。層#1と#2は下層パターン、層#3は上層パターンに対応する

5.2.1 回路パターン領域認識アルゴリズム

本手法では画像から各層の回路パターンの領域を認識することが重要である。これは画像の各画素がどの層(例えば、上層と下層)に属するかを分類する問題であり、画像セグメンテーションと呼ばれる。今回、各層において画像濃淡値が異なる分布を取ることに着目した手法を開発した。図 5.2 に処理のフローを示す。入力画像は、SE/Left/Right 像の 3 チャンネル画像である。まず、この 3 チャンネル画像の濃淡を混合し認識用の画像を得る。一般的に、下層パターンから射出された後方散乱電子は、上層パターンに遮蔽されて検出器まで到達しないため、Left/Right 像の濃淡を足し合わせると下層パターンが上層パターンと比較して暗い画像が得られる。次に、混合画像のヒストグラムを微分することで、ヒストグラムの谷をしきい値 th_i ($i = 1, \dots, C - 1$) として抽出する。最後に算出したしきい値をもとにセグメンテーションを行う。




図 5.2: 回路パターン領域の認識処理フロー

セグメンテーションの最も簡単な方法として、画素 X の濃淡値を X_v としたとき、 $th_i < X_v \leq th_{i+1}$ を満たす i を求める方法がある。しかし、SEM 画像の SNR は低いため、各画素において独立にしきい値を適用すると、上層パターン領域内に下層パターンと認識された領域が飛び地のように生じるなど、認識精度が低下する。このようなノイズに起因した誤抽出を抑制するには平滑化フィルタを適用するのが効果的である。ただし、微細な回路パターンに適用すると回路

パターンの陰影も平滑化され、認識精度に悪影響を及ぼすと考えられる。この問題に対しては、エッジを保存しつつ平滑化が可能な Guided Filter[51] が有効である。しかし、5.3.2節にて後述するように、本評価で用いたサンプルにおいては Guided Filter では十分な効果が確認できなかった。そこで、対象画素のみではなく隣接画素の濃淡値を考慮し、認識結果の連続性を考慮したセグメンテーションを行うことを検討した。回路パターン領域の認識問題を式(5.2)に示す目的関数を最小化する問題として捉え、最適化問題を解くことで認識を行う。

$$E(X) = \sum_{v \in V} g_v(X_v, L_v) + \sum_{(u,v) \in A} h_{uv}(L_u, L_v) \quad (5.2)$$

$$g_v(X_v, L_v) = |X_v - \bar{a}_{L_v}| \quad (5.3)$$

$$h_{uv}(L_u, L_v) = \begin{cases} 0 & L_u = L_v \\ \kappa & \text{otherwise} \end{cases} \quad (5.4)$$

ここで、 X_v は画素 v の濃淡値、 $X = \{X_v, v \in V \mid 0 \leq X_v \leq 255\}$ は M 画素からなる画像を表し、 $V = \{0, 1, \dots, M-1\}$ である。また、認識する層の数を C とし、 $L = \{L_v, v \in V \mid 1 \leq L_v \leq C\}$ は認識結果を表す。第1項 g_v はデータ項と呼び、濃淡値 X_v の画素 v を層 L_v に割り当てたときの損失を表すものであり、式(5.3)により求める。ここで、 \bar{a}_L は $\{X_v \mid th_L < X_v \leq th_{L+1}\}$ の平均値である。第2項 h_{uv} は平滑化項とよび、認識結果の連続性を評価するものであり、式(5.4)により求める。隣接画素と異なる層に認識された場合、 κ が損失として加算される。以上示した目的関数(式(5.2))はグラフカット手法[52, 53]を用いて最小化することが可能である。

図5.3は、グラフカット手法によるセグメンテーションについて $C = 3$ の場合を例に式(5.2)をグラフとして表現したものである(ただし、簡略化のため2次元画像を1次元信号として表現している)。1つの画素は縦方向に並ぶ複数のノードとして表現され、各ノードはノード間を結ぶ水平方向と縦方向のエッジを持っている。なお、ノード s, t は最上部および最下部のノードと接続された仮想的なノードである。1画素あたりの縦方向のエッジ数は層の数 C に対応しており、1ノードから伸びる水平方向の数は連続性を考慮する近傍の画素数に対応している。本検討では近傍8画素を考慮するようにした。縦方向のエッジはデータ項($g_v(X_v, L_v)$, 式(5.3))に対応する重みを持っている。例えば、濃淡値 X_v の画素 v の1番下側の縦方向エッジは、画素 v を第1層 ($L_v = 1$) に割り当てたときの損失 $g_v(X_v, 1)$ を重みとして持つ。同様に、下から2番目の縦方向エッジは重み $g_v(X_v, 2)$ 、下から3番目の縦方向エッジは重み $g_v(X_v, 3)$ を持つ。例として、各層の濃淡値の平均をそれぞれ、 $\bar{a}_1 = 80, \bar{a}_2 = 100, \bar{a}_3 = 170$ とすると、濃淡値 $X_v = 170$ の画素 $v = 0$ のエッジの重みは下側のエッジから順に 90, 70, 0 となる。水平方向のエッジは平滑化項($h_{uv}(L_u, L_v)$, 式(5.4))に対応する重み κ を持つ。

図5.3のノードを s と t をそれぞれ含む2つのグループに分割することを考

えたとき、切断されるエッジの重みの総和が式(5.2)で示した目的関数と一致する。目的関数を最小化することはグラフの最小切断を求めることと等価であり、“Min-Cut/Max-Flow”アルゴリズム[52]を用いて多項式時間で求めることができる。そして、エッジの切断位置から各画素において層の認識を行うことができる。つまり、画素 v において下から c 番目のエッジがカットされた場合、 $L_v = c$ とする。図5.3においては、最初と2番目の画素($v = 0, 1$)は下から3番目のエッジが切断されているため $L_v = 3$ となる。同様に、3~5番目の画素($v = 2, 3, 4$)は $L_v = 2$ と、6~7番目の画素($v = 5, 6$)は $L_v = 1$ と認識される。5番目の画素($v = 4$)の濃淡値 X_4 は85であり、第1層の平均値 $\bar{a}_1 = 80$ との差は5、第2層の平均値 $\bar{a}_2 = 100$ との差は15となり、データ項のみを考慮すると第1層として認識されるが、平滑化項として κ を考慮すると、第2層として認識される。このように平滑化項により、近傍画素との連続性を調整することができる。本研究においては、少数枚のSEM画像を用いた評価より、 $\kappa = 10$ とした。




図 5.3: 1次元信号におけるグラフカットの例。括弧内の数字は重みを表す($\bar{a}_1 = 80, \bar{a}_2 = 100, \bar{a}_3 = 170$.)。

5.2.2 位置ずれ量定量化アルゴリズム

本処理は、テンプレートマッチング技術により、2枚の画像間の位置ずれ量を定量化する。テンプレートマッチング技術は2枚の位置関係をずらしながら重なっている領域の類似度を算出し、類似が最大となるずらし量を位置ずれ量として算出する方法であり、類似度として正規化相互相関値がよく利用される。この手法は2枚の画像間の変形が水平方向のオフセットのみであれば精度良く位置

合わせが可能である。ただし、画像間に回転や拡大縮小などの変形が含まれている場合には、回転や拡大縮小を施した画像を用いて類似度が最大となる位置を探索する必要があり、回転角度や拡大縮小率が不明の場合には様々なパターンでの探索が必要となるため、処理時間の増大が課題となる。

半導体デバイスの回路パターンにおいては、露光工程のフォーカス位置やドーズ量、エッチング工程のエッチングレートなどの製造ばらつきに起因して、基準画像と被計測画像間で回路パターンの線幅やサイズに違いが生じる場合がある。また、回路パターンの側壁角度や、法肩の形状(トップラウンディング)の違いにより、SEM画像上での濃淡値が異なる場合もある。

上記課題を解決するため、画像濃淡値に着目したテンプレートマッチング技術に加え、回路パターンの形状変化にロバストなマッチング手法を開発した。開発手法は、回路パターンの形状変化は中心位置から等方的に生じるものと仮定し、回路パターンの重心をマッチングに用いる。具体的には、基準画像と被計測画像それぞれから回路パターンの重心位置を算出し、重心位置のずれ量を位置ずれ量として算出する。

5.3 評価実験

5.3.1 擬似画像を用いた感度評価

SEMのシミュレータとして、CASINO[54]やJMONSEL[55]などのモンテカルロシミュレーションに基づいたものが知られている。しかし、本評価ではSEM画像生成における不確定性を取り除き、理想的な感度評価を行うため、シミュレータは用いずに模擬画像を用いて評価を行った。

オーバーレイの感度評価を行うため、上層パターンが下層パターンに対してY方向に±10画素ずらした画像を生成した。また、回路パターンサイズの変動に対するロバスト性を評価するため、上層パターンのY方向のサイズが80%~120%になるように変動を加えた。

図5.4に基準画像と、模擬画像の例を示す。 (e_x, e_y) は上層パターンの位置ずれ量(画素)、サイズ変形率は上層パターンのY方向のサイズ変化率を表す。メモリデバイスを想定し、模擬画像では位置ずれ量、サイズ変形率が同一のパターンを画像視野内に4つ配置した。一般的に、パターンを多く含むほどマッチングに扱える情報が増え、計測誤差が平均化されるため、精度が向上する。ただし、多くのパターンが視野に含まれるように撮像視野を広げると、画素サイズが大きくなり、計測精度の低下要因となる。本評価では、後述の実パターン画像とあわせるために4つ配置した。なお画像の濃淡値として、下地は80、下層パターンは120、上層パターンは200とした。また、生成画像にはガウシアンフィルタ($\sigma = 1$ 画素)によるぼかしと、ガウシアンノイズ($\sigma = 10$)を重畳した。実際のSEMにおける点広がり関数(Point Spread Function : PSF)はガウシアン

フィルタよりも複雑な形状をとるが、計測は困難であるため、画像処理の評価で一般的に用いられるガウシアンフィルタとした。また、実際のSEMにおけるノイズはポアソン分布を取るが、ガウシアンノイズで十分に近似可能である。

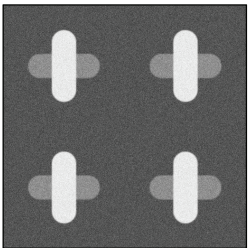
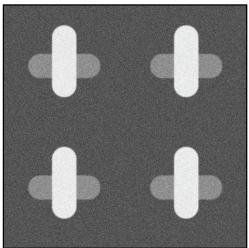
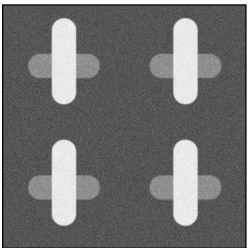
	基準画像	擬似画像例 1	擬似画像例 2
(e_x, e_y) [画素]	(0, 0)	(0, -10)	(0, -10)
サイズ 変形率 [%]	100	100	120
画像			

図 5.4: 擬似画像の例 (512 × 512 画素)

図 5.5 は、基準画像 (a) と被計測画像 (b) について上層パターンを基準に位置合わせした結果を示しており、上層パターンのエッジを重畳表示したものである。5.2.2 節で述べたとおり、上層パターンの重心位置が一致するようにマッチングされていることがわかる。




図 5.5: サイズ変化を含む画像において上層パターンを基準にマッチングした結果例

図 5.6 は計測精度の評価結果であり、ずらし量とオーバーレイの計測結果をプロットしたものである。ずらし量およびサイズ変形量の条件は表 5.1 に示すとおりである。各条件において 10 枚の画像を生成し評価に用いた。図 5.6(b) は、図 5.6(a) のうち -1.0 から 1.0 の部分を拡大表示したものである。回路パターンのサイズに変動を加えた場合においても、サブ画素の精度でずらし量に比例したオーバーレイを算出可能である。

計測結果の平均二乗誤差を評価した結果は 0.05 画素であり、擬似画像において良好な結果が得られた。例えば、画素サイズが 1 nm である場合、提案アルゴリズムの計測精度 (3σ) 0.15 nm が得られる見込みである。ただし、あくまで理想的な条件で生成した擬似画像における結果であり、実際には SEM 画像生成時の

表 5.1: ずらし量およびサイズ変形量の条件		
項目	値	組合せ数
ずらし量	$\{-10.0, -9.0, \dots, -1.0\},$	29 通り
	$\{-0.8, -0.6, \dots, 0.0, \dots, 0.8\},$	
サイズ変形量	$\{1.0, 2.0, \dots, 10.0\}$	9 通り

不確からしさを考慮する必要がある。次節以降において実パターン画像を用いた評価結果について述べる。

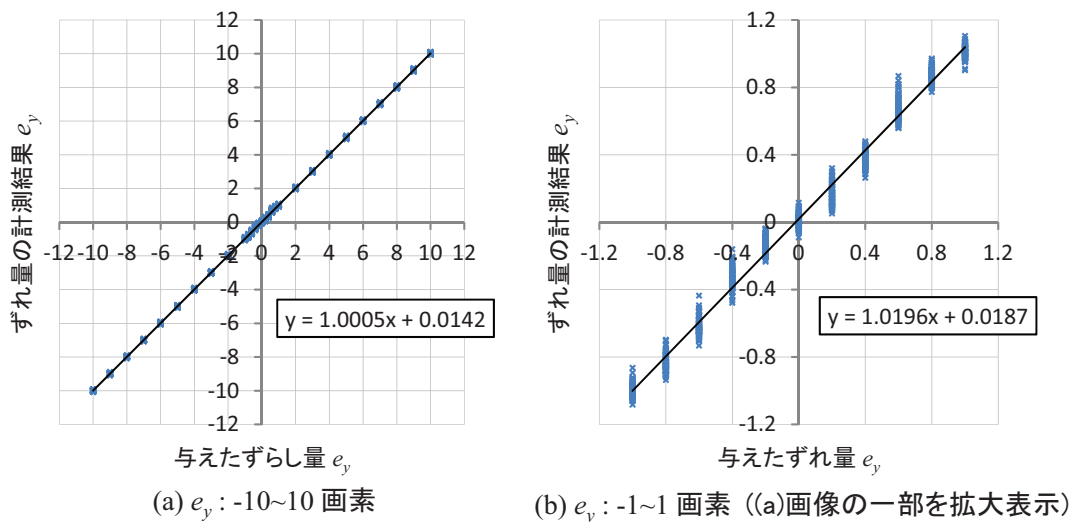


図 5.6: 擬似画像に対する計測精度

5.3.2 実パターン画像を用いた評価

図 5.7 に示す回路パターンの画像を用いて評価を行った。下層パターンは膜下に埋め込まれており、上層パターンは膜上に形成されている。本評価では、ひとつのダイの中に 12 点の計測点を設定し、ウェハの左側半分をカバーするように計 1980 枚の画像を撮像した。

画像の撮像条件を表 5.2 に示す。下層パターンを観察するためには、膜下に埋め込まれた下層パターンまで 1 次電子ビームが到達する必要がある。そのため、1 次電子ビームの加速電圧が重要となる。本研究では加速電圧として 15 keV を選択した。図 5.7 より、SE 像 ($SE(x, y)$) と、BSE 像 ($BSE(x, y)$) において明瞭に観察できていることがわかる。




図 5.7: 実パターンの評価画像例。上層パターンの幅は約 120 nm (32 画素)。

表 5.2: 画像撮像条件	
項目	設定値
加速電圧	15 keV
プローブ電流値	500 pA
加算フレーム数	16
視野	1.93 μm
撮像画像サイズ	512 \times 512 画素
画素サイズ	3.76 [nm/画素]

まず、回路パターンの認識結果について説明する。回路パターン領域の認識においては上層パターンが明るく、下層パターンが暗くなるように $(0.9\text{SE}(x, y) + 0.1(255 - \text{BSE}(x, y)))$ として画像混合した。図 5.8 は混合画像とそのヒストグラムである。 $C = 2$ として、5.2.1 節で述べたようにしきい値を算出した結果、 $Th_i = 92$ となった。

混合画像に対して単純なしきい値処理を適用した結果を図 5.9 に示す。図 5.9(a) は混合画像にしきい値を適用した結果、図 5.9(b) は混合画像に Guided Filter による平滑化を行った上でしきい値を適用した結果である。両者とも下層パターンの一部が上層パターンとして誤抽出されている。Guided Filter を用いた場合、平滑化の効果により微小な領域の抽出は抑制されているが、下層パターンの誤抽出を抑制するにはいたっていない。




図 5.8: 混合画像とヒストグラム




図 5.9: 混合画像に対するしきい値処理結果

算出したしきい値を用いてグラフカット処理により上層パターンを抽出した結果を図5.10に示す。 κ が小さい条件、つまり平滑化項が小さい場合は単純なしきい値処理を行った場合と同様に、下層パターンの一部が上層パターンとして、および上層パターンの一部が下層パターンとして誤抽出されている。 κ を大きくするにつれ、平滑化の効果が大きくなり、誤抽出される傾向は減少する。本サンプルにおいては、 $\kappa = 10 \sim 80$ において良好な結果が得られている。以降の評価においては $\kappa = 10$ とした。

上層パターンについては、抽出した領域をもとに5.2.2節で述べた重心位置による位置合わせを行う。下層パターンについては膜下に形成されており輪郭が不鮮明であるため、領域の抽出が困難である。そのため、下層パターンについては領域抽出を行わず、画像濃淡値を用いた正規化相互相関値による位置合わせを行うこととした。具体的には撮像画像から上層パターンの領域をマスクし、正規化相互相関値を算出する。

次に、繰り返し計測再現性の評価結果について説明する。まず、データの取得方法について説明する。まず、ウェハを装置のステージに搭載し、設定した1980箇所計測点において画像撮像およびオーバーレイ計測をした後、ウェハを装置から排出する。再度、同じウェハを装置に搭載し、同一の1980箇所計測点について画像撮像およびオーバーレイ計測を行い、ウェハを装置から排出する。以上を合計3回繰り返して行い、3回分のオーバーレイ計測結果を得る。

次に繰り返し計測再現性の計算方法について説明する。まず、1回目と2回目のオーバーレイ計測値を用いて、式(5.5)により計測ばらつき \mathcal{R}_1 を算出する。こ




図 5.10: 上層パターンの認識結果(青:下地+下層パターン、緑:上層パターン)。グラフカット処理により κ を導入することにより正しい形状が抽出可能となる。

ここで、 $e_{f,i}$ は f 回目の撮像における i 番目の計測点におけるオーバーレイ計測値を表す。同様に、2回目と3回目のオーバーレイ計測値から計測ばらつき \mathcal{R}_2 を、3回目と1回目のオーバーレイ計測値から計測ばらつき \mathcal{R}_3 を算出する。繰り返し計測再現性 \mathcal{R} は、得られた計測ばらつきから式 (5.6) を用いて計算した。

表 5.3 に繰り返し計測再現性の評価結果を示す。 x 方向において 0.36 画素、 y 方向について 1.17 画素の繰り返し計測再現性が得られた。表 5.2 に示した画素サイズ (3.76 [nm/画素]) をかけると、 x, y 方向でそれぞれ 1.35 nm, 6.43 nm となる。

$$\mathcal{R}_f^2 = \frac{1}{2N} \sum_{i=1}^N \left((e_{f,i} - e_{g,i}) - \frac{1}{N} \sum_{j=1}^N (e_{f,j} - e_{g,j}) \right)^2, \quad g = (f \bmod 3) + 1 \quad (5.5)$$

$$\mathcal{R} = 3\sqrt{\mathcal{R}^2} = 3\sqrt{(\mathcal{R}_1^2 + \mathcal{R}_2^2 + \mathcal{R}_3^2)/3} \quad (5.6)$$

表 5.3: 繰り返し計測再現性の評価結果 (計測点数 $N = 1980$)

方向	繰り返し計測再現性 ($3\mathcal{R}$)
x	1.35 nm (0.36 画素)
y	6.43 nm (1.71 画素)

5.3.3 モデルフィッティングを用いたオーバーレイ計測結果の解析

図 5.11 に基準画像と典型的な被計測画像における計測結果を示す。被計測画像#1においては上層パターンが下層パターンに対して右側にずれて形成されて

おり、被計測画像#2の相乗パターンは下層パターンに対して左側にずれて形成されている。回路パターンの間隔を目視で計測した結果から算出したオーバーレイ値は、それぞれ $61 - 53 = 8$ 画素と、 $46 - 53 = -7$ 画素であった。提案手法を用いたオーバーレイ計測結果 e_x はそれぞれ $+8.3$ 画素と -6.9 画素と算出されており、目視計測結果と近い値が得られている。

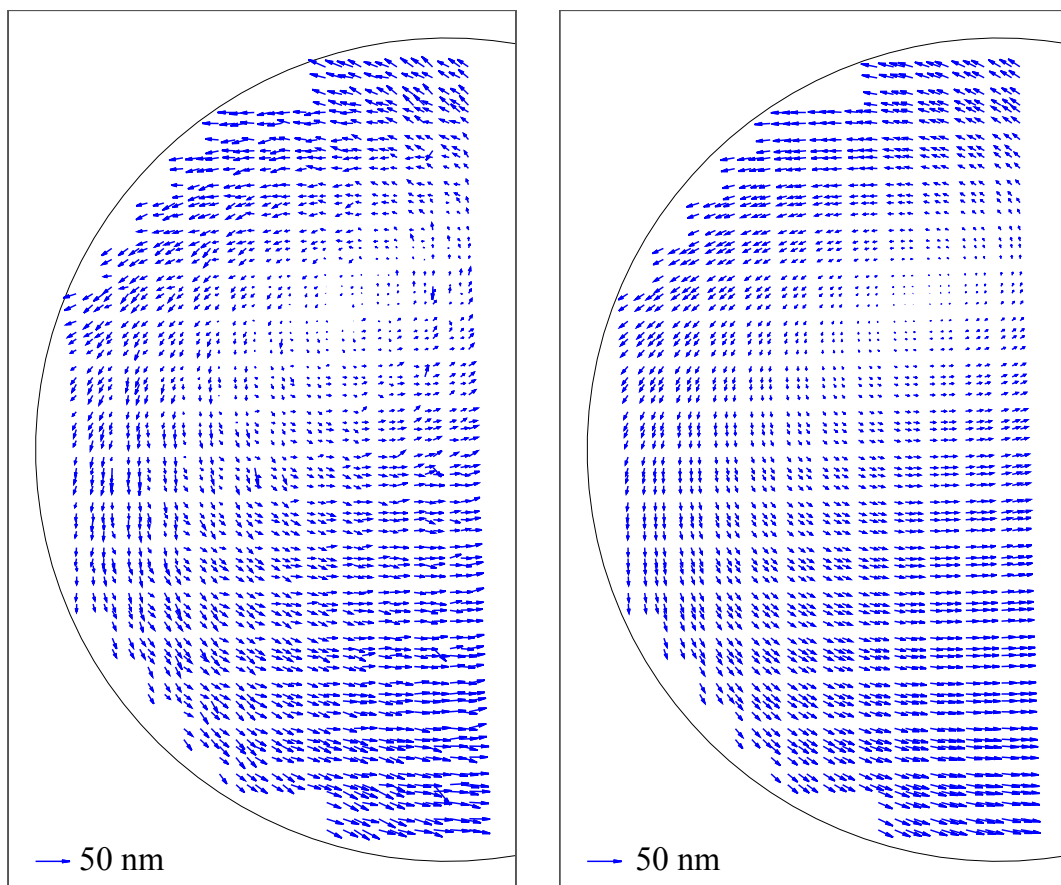
	SE画像	BSE画像	e_x
(a) 基準 画像			—
(b) 被計測 画像 #1			8.3 pixel (31.2 nm)
(c) 被計測 画像 #2			-6.9 pixel (-26.0 nm)

図 5.11: 基準画像とオーバーレイ計測結果例

図 5.12(a) は、1980 箇所におけるオーバーレイ計測結果をウェハマップとして表示したものであり、オーバーレイの向きと大きさをベクトルとして表示したものである。全体的に左巻きのシステムティックな傾向が見て取れる。図 5.12(b) はシステムティックな成分を抽出した結果であり、詳細は後述する。

オーバーレイの発生要因は露光プロセス起因やマスク起因、エッチングプロセス起因など様々な要素が考えられ、計測結果をこれらの要因に分解することは非常に困難である。しかし、最先端のデバイス製造に用いられる露光装置は、オーバーレイの計測結果をもとにした高度な補正機能を備えている。オーバーレイはシステムティックな成分と、ランダムな成分に分離することが可能であり、露光装置により高精度な補正を行うためには、ランダムな成分を含む計測結果からシステムティックな成分を抽出することが重要である。システムティックな成分は、“ウェハレベル成分”、“露光領域単位の成分”、“露光領域内の成分”に分解することができる [35]。

ウェハレベル成分は、ウェハマップに対して、多項式モデルを最小二乗法を用いて当てはめることで抽出可能である。図 5.12(b) は、オーバーレイ計測結果(図



(a) 計測結果

(b) ウェハレベル成分

図 5.12: オーバーレイ計測結果のウェハマップ表示

5.12(a)) を 3 次の多項式を用いて表現した結果である。また、図 5.13 は、当てはめるモデル次数と当てはめ誤差の関係を評価したものであり、次数を 3 以上に設定しても誤差が減少しないことから今回の計測結果においては 3 次の多項式で表現可能であると言える。




図 5.13: 当てはめたモデルの次数と当てはめ誤差

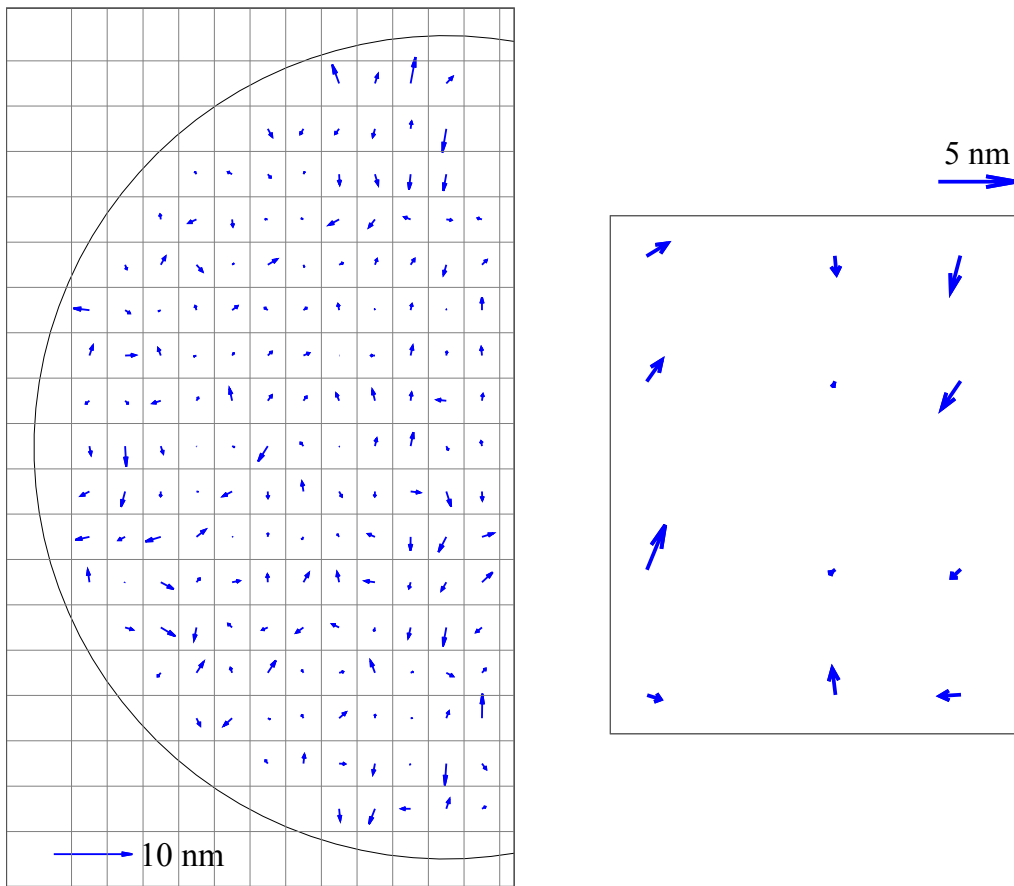
オーバーレイ計測結果 (図 5.12(a)) から、ウェハレベル成分 (図 5.12(b)) を差し引いた残差には、露光領域単位の成分と露光領域内の成分、ランダムな成分が含まれる。図 5.14(a) は、露光領域単位の成分を算出した結果である。各長方形

が露光領域を表しており、露光領域内に含まれる残差の平均を算出することで求める。図5.14(b)は露光領域内の成分を算出した結果である。オーバーレイ計測結果からウェハレベル成分、露光領域単位の成分を差し引いた上で、露光領域を基準とした座標が同一の計測点について計測結果を平均化することで求める。

図5.15は、計測結果をシステムティック成分とランダム成分に分離した結果である。システムティック成分は、前述の方法で求めた“ウェハレベル成分”と“露光領域単位の成分”，“露光領域内の成分”を足し合わせたものであり、ランダム成分は計測結果からシステムティック成分を差し引いたものである。算出したシステムティック成分においては特徴的な傾向が観察できるが、算出したランダム成分には規則的な傾向が見られない。よって、以上示した方法により計測結果からランダム成分を取り除き、システムティック成分を抽出することが可能になったと考えられる。

算出したシステムティック成分を観察すると、左回りに回転している傾向が見られる。このことは、露光時にウェハが回転ずれを含んで設置された可能性を示唆している。その他、下層パターンの上に下地の膜を塗布した後、下地膜の膨張もしくは縮退により応力が生じ、下層パターンの位置ずれが生じた可能性も考えられる。また、露光領域内の成分に着目すると、右回りに回転している傾向が見られる。これは、露光用のマスクが回転ずれを含んで設置された可能性を示唆している。


オーバーレイの発生要因を要因ごとに分解することは困難であるが、算出したシステムティック成分を露光装置にフィードバックすることで、オーバーレイを適切に管理することが可能であると期待できる。




(a) 露光領域単位の成分

(b) 露光領域内の成分

図 5.14: “露光領域単位の成分” と “露光領域内の成分” の算出結果



(a) システムティック成分



(b) ランダム成分

図 5.15: システムティック成分とランダム成分

5.4 むすび

本章では、回路パターンのできばえ定量化機能のひとつとして、オーバーレイ(層の重ねあわせずれ)計測を実現する提案手法について述べた。

1. 提案手法は、オーバーレイが良好な領域を撮像した画像を基準画像とし、被計測画像と基準画像を比較することでオーバーレイを計測する。具体的には、複数の製造工程により形成される回路パターンの領域を撮像画像から工程別に認識し、被計測画像と基準画像間で回路パターン領域の位置ずれ量を算出することでオーバーレイを計測する。
2. 画像から回路パターンの領域を認識する手法として、ヒストグラムを解析することで回路パターンの濃淡分布を推定し、グラフカットを用いてロバストにセグメンテーションを行う認識手法を提案した。
3. 擬似画像を用いた評価を行い、サブ画素精度での計測が可能であり、回路パターンのサイズ変動にもロバストに計測が可能であることを示した。
4. 実デバイスの1980箇所を3回ずつ撮像した画像を用いて評価を行い、計測再現性として1.35 nm (0.36画素)が得られた。また、計測結果が目視による計測結果と、一致していることを示した。さらに、ウェハ面内(1980箇所)の計測結果に対してモデルフィッティングを用いた解析を行い、ウェハマップ上で特徴的な傾向が観察できることを示した。

第6章 結論

先端半導体デバイスの製造工程で利用される欠陥レビューSEMを対象に、高精細画像の取得に必要なオートフォーカス処理のロバスト性向上や、画像内から欠陥部位を特定する欠陥再検出処理の性能向上、半導体デバイスのできばえを定量化する機能に関する画像処理技術について検討を行った。得られた結論を以下にまとめる。

1. 高精細な画像を取得する際に必要となるオートフォーカス処理のロバスト性向上技術について検討し、以下の結論を得た。
 - (a) オートフォーカスの基本シーケンスは、電子ビームの焦点位置を変えながら複数枚の画像を撮像し、撮像画像から抽出したエッジの強度を焦点測度として算出し、合焦位置を求める。
 - (b) 画像からエッジを抽出するためには、高周波成分を抽出するラプラシアンフィルタや、低周波成分を抽出するガウシアンフィルタなどを組み合わせてバンドパスフィルタを構成することが重要である。回路パターン領域と、回路パターンなし領域の画像について周波数解析を行い、抽出すべき周波数成分が異なることを明らかにした。
 - (c) 周波数特性が異なる2つのバンドパスフィルタを導入し、入力画像に応じてバンドパスフィルタを切り替える手法を提案した。提案手法は、入力画像に対して2つのバンドパスフィルタを独立に適用し、得られた焦点測度分布の信頼性を評価することで、2つのフィルタを切り替える。
 - (d) 提案手法の精度評価として擬似画像を用いた評価を行った。本評価により、先端プロセスで製造される線幅10nm、ピッチが20nmの微細な回路パターン領域においても、画像SNRが1.5以上あれば安定してオートフォーカスを実行可能なことを明らかにした。
 - (e) 実デバイスのSEM画像を用いた評価を行い、複数のバンドパスフィルタを用いることで、1つのバンドパスフィルタのみを用いた場合と比較して成功率が60.3→95.6%に向上することを確認した。
2. 欠陥再検出処理における虚報識別正解率および検出成功率の向上を目的とした手法について検討し、以下の結論を得た。
 - (a) レビューSEMのADRにおいてはウェハ検査装置の出力から実報と虚報を識別し、真に欠陥である画像のみを収集することが求められており、欠陥再検出処理においては微小な欠陥を高感度に検出しつつ、製造ばらつきに起因した誤検出を抑制することが課題である。本研究で

は、(a) 複数の比較検出結果の統合手法と、(b) 良品モデルを用いた欠陥識別手法の2つの手法を開発した。

- (b) (a) 複数の比較検出結果の統合手法は、製造ばらつきに起因した誤検出はランダム性が高いことに着目し、異なる参照画像を用いた複数の比較検出結果から共通して検出される位置を欠陥として抽出する手法である。
- (c) (b) 良品モデルを用いた欠陥識別手法は、製造ばらつきの外観を良品モデルとして予め学習しておき、比較検査で検出された欠陥候補について欠陥か良品かを識別する手法である。
- (d) 実デバイスのSEM画像を用いた評価を行い、提案した欠陥識別手法は一般的な識別手法である one-class SVM よりも精度高く識別可能であった。また、提案した2つの手法を組み合わせることで虚報識別正解率が0.0%から84.4%に向上することを確認した。これにより、ウェハ検査装置に虚報率が50%である条件において欠陥画像収集純度が50.0%から85.7%に向上する。

3. 回路パターンのできばえ定量化機能のひとつとして、オーバーレイの計測手法について検討し、以下の結論を得た。

- (a) オーバーレイが良好な領域を撮像した画像を基準画像とし、被計測画像と基準画像を比較することでオーバーレイを計測する手法を提案した。具体的には、複数の製造工程により形成される回路パターンの領域を撮像画像から工程別に認識し、被計測画像と基準画像間で回路パターン領域の位置ずれ量を算出することでオーバーレイを計測する。
- (b) 画像から回路パターンの領域を認識する手法として、ヒストグラムを解析することで回路パターンの濃淡分布を推定し、グラフカットを用いてロバストにセグメンテーションを行う認識手法を提案した。
- (c) 擬似画像を用いた評価を行い、サブ画素精度での計測が可能であり、回路パターンのサイズ変動にもロバストに計測が可能であることを示した。
- (d) 実デバイスの1980箇所を3回ずつ撮像した画像を用いて評価を行い、計測再現性として1.35 nm (0.36 画素) が得られた。また、計測結果が目視による計測結果と、一致していることを示した。さらに、ウェハ面内(1980箇所)の計測結果に対してモデルフィッティングを用いた解析を行い、ウェハマップ上で特徴的な傾向が観察できることを示した。

半導体製造の微細化に伴い、製造プロセスの確立が困難となっており、高い歩留りに早期に移行するためには、製造工程で生じた欠陥の検査・解析がまず

ます重要となってくる。本研究では欠陥レビューSEMのロバスト性向上や欠陥再検出性能の向上を実現し、新たな機能としてオーバーレイ計測機能を実現した。これにより、迅速な欠陥解析やできれば定量化を可能とし、製造ラインにおける歩留りの向上に寄与できるものと考ええる。

先端半導体デバイスにおいては製造プロセスの微細化が今後も継続すると予想される。致命となる欠陥サイズも微小化するため、今後も継続して欠陥検出感度の向上に取り組む必要がある。そのため、ADRにおいては本研究で取り組んだ、良品学習型の処理がより重要になってくるものと考ええる。また、できれば定量化機能においては、微細かつ複雑な回路パターン領域を認識することが重要となる。そのため、本研究で取り組んだモデルベースの認識手法に加え、今後は機械学習技術を取り入れた手法も検討していく必要があると考える。今後は、提案手法をより多くの半導体製造プロセスに適用し、その有効性を実証していくことが必要である。

謝辞

本研究を遂行するにあたり、終始懇切丁寧な御指導と御鞭撻を賜りました、大阪大学大学院情報科学研究科 情報システム工学専攻 中前幸治教授に深く感謝申し上げます。

本論分を執筆するにあたり、懇篤なる御指導を頂くとともに数々の御教示を賜りました、大阪大学工学研究科附属 オープンイノベーション教育研究センター 谷口研二特任教授、大阪大学大学院情報科学研究科 情報システム工学専攻 尾上孝雄教授、同 三浦克介准教授に心より感謝の意を表します。

本研究に関し、有意義な御指導、御教示を賜りました大阪大学大学院情報科学研究科 情報システム工学専攻 中前研究室 御堂義博助教に心より感謝の意を表します。

筆者が大阪大学大学院情報科学研究科情報システム工学専攻後期課程に在学することへの御配慮と援助を賜りました(株)日立製作所 研究開発グループ 横浜研究所 前所長 矢川雄一氏(現、中央研究所 所長)、所長 鮫嶋茂稔氏、同社 生産イノベーションセンタ 前センタ長 森正勝氏、センター長 中垣亮博士に感謝申し上げます。

上司として本研究の機会を与えて頂くとともに、研究を進めるにあたり御指導と御配慮を賜りました、(株)日立製作所 研究開発グループ 生産イノベーションセンタ 検査・計測研究部 元部長 濱村有一博士(現、産業・流通ビジネスユニット 本部長)、前部長 三輪俊晴博士(現、日立研究所 企画室室長)、部長 田中麻紀氏に心より御礼申し上げます。

第2章、第3章、第4章、第5章に関し、研究の機会を与えて頂くとともに格別なる御指導、御支援ならびに御配慮を賜りました、(株)日立ハイテクノロジー 電子線応用システム設計部 前部長 小室修氏(現、評価システム製品本部 本部長)、部長 矢野学氏、元統括主任技師 梅原諭氏(現、光学応用システム設計部 部長)、元統括主任技師 二宮拓氏(現、評価システム製品本部 本部長付)、統括主任技師 小原健二氏、主任技師 青木一雄氏、主任技師 平井大博氏、技師 嶺川陽平博士、同社 評価ソフトウェア設計部 主任技師 福永文彦氏、中山英樹氏、同社 システム設計部 主任技師 小山晋氏、技師 董双氏に深く感謝申し上げます。

研究を進めるにあたり、日々様々な御討論、御助言を頂くとともに多大なる御支援を頂きました、(株)日立製作所 研究開発グループ 生産イノベーションセンタ 検査・計測研究部 ユニットリーダー 宮本敦博士、主任研究員 高木裕治博士、近藤直明氏、伊藤晟氏に厚く御礼申し上げます。ならびに格別なる御指導と御配慮を賜りました、(株)日立製作所 研究開発グループ 生産イノベーションセンタの各位に心から御礼申し上げます。

参考文献

- [1] R. R. Schaller. Moore's law: past, present and future. *IEEE Spectrum*, Vol. 34, No. 6, pp. 52–59, June 1997.
- [2] R. Chau, S. Datta, M. Doczy, B. Doyle, B. Jin, J. Kavalieros, A. Majumdar, M. Metz, and M. Radosavljevic. Benchmarking nanotechnology for high-performance and low-power logic transistor applications. *IEEE Transactions on Nanotechnology*, Vol. 4, No. 2, pp. 153–158, March 2005.
- [3] M. Asano. Sub-100 nm lithography using krf exposure with multiple development method. In *Digest of Papers. Microprocesses and Nanotechnology '99. 1999 International Microprocesses and Nanotechnology Conference*, pp. 154–155, July 1999.
- [4] Masafumi Asano. Sub-100 nm lithography with krf exposure using multiple development method. *Japanese Journal of Applied Physics*, Vol. 38, No. 12S, p. 6999, 1999.
- [5] M. Fritze, D. Astolfi, H. Liu, C. K. Chen, V. Suntharalingam, D. Preble, and P. W. Wyatt. Sub-100 nm krf lithography for complementary metaloxidesemiconductor circuits. *Journal of Vacuum Science & Technology B: Microelectronics and Nanometer Structures Processing, Measurement, and Phenomena*, Vol. 17, No. 2, pp. 345–349, 1999.
- [6] Geert Vandenberghe, Young-Chang Kim, Christie Delvaux, Kevin D. Lucas, Sang-Jun Choi, Monique Ercken, Kurt G. Ronse, and Bert Vleeming. Arf lithography options for 100-nm technologies. In *Proc.SPIE*, Vol. 4346, pp. 4346 – 4346 – 12, 2001.
- [7] H. S. Kim, D. H. Kim, J. M. Park, Y. S. Hwang, M. Huh, H. K. Hwang, N. J. Kang, B. H. Lee, M. H. Cho, S. E. Kim, J. Y. Kim, B. J. Park, J. W. Lee, D. I. Kim, M. Y. Jeong, H. J. Kim, Y. J. Park, and Kinam Kim. An outstanding and highly manufacturable 80nm dram technology. In *IEEE International Electron Devices Meeting 2003*, pp. 17.2.1–17.2.4, Dec 2003.
- [8] Soichi Owa and Hiroyuki Nagasaka. Advantage and feasibility of immersion lithography. *Journal of Micro/Nanolithography, MEMS, and MOEMS*, Vol. 3, pp. 3 – 3 – 7, 2004.
- [9] Jo Finders, Mircea Dusa, Bert Vleeming, Henry Megens, Birgitt Hepp, Mireille Maenhoudt, Shaunee Cheng, and Tom Vandeweyer. Double patterning for

- 32nm and below: an update. In *Proc.SPIE*, Vol. 6924, pp. 6924 – 6924 – 12, 2008.
- [10] Shinji Tarutani, Hideaki Tsubaki, and Shinichi Kanna. Development of materials and processes for double patterning toward 32 nm node arf immersion lithography. *Journal of Photopolymer Science and Technology*, Vol. 21, No. 5, pp. 685–690, 2008.
- [11] K. Ronse, P. De Bisschop, G. Vandenberghe, E. Hendrickx, R. Gronheid, A. V. Pret, A. Mallik, D. Verkest, and A. Steegen. Opportunities and challenges in device scaling by the introduction of euv lithography. In *2012 International Electron Devices Meeting*, pp. 18.5.1–18.5.4, Dec 2012.
- [12] Alberto Pirati, Rudy Peeters, Daniel Smith, Sjoerd Lok, et al. Euv lithography performance for manufacturing: status and outlook. In *Proc.SPIE*, Vol. 9776, pp. 9776 – 9776 – 15, 2016.
- [13] Anthony Yen. Continued scaling in semiconductor manufacturing with euv lithography. June 2018.
- [14] L. Chang, Yang kyu Choi, D. Ha, P. Ranade, Shiyong Xiong, J. Bokor, Chenming Hu, and T. J. King. Extremely scaled silicon nano-cmos devices. *Proceedings of the IEEE*, Vol. 91, No. 11, pp. 1860–1873, Nov 2003.
- [15] R. L. Guldi. In-line defect reduction from a historical perspective and its implications for future integrated circuit manufacturing. *IEEE Transactions on Semiconductor Manufacturing*, Vol. 17, No. 4, pp. 629–640, Nov 2004.
- [16] Usami Y, Sugimoto A, Watanabe K, Isogai S, and Watanabe T. Semiconductor inspection system for yield enhancement. Vol. 48, pp. 354–360, 01 1999.
- [17] B. Hance. Multiple applications of an automatic defect review sem in semiconductor manufacturing yield enhancement. In *2000 IEEE/SEMI Advanced Semiconductor Manufacturing Conference and Workshop. ASMC 2000 (Cat. No.00CH37072)*, pp. 130–, Sept 2000.
- [18] Hideo Ohta, Sang Hyun Lee, Tetsuya Watanabe, S. K. Park, Byeong Sam Moon, Jeong Hoon An, Katsuhiko Ichinose, J. G. Park, Kwon Hong, and Kazunori Nemoto. Quantifying yield impact of polishing induced defect on the silicon surface. In *2009 IEEE/SEMI Advanced Semiconductor Manufacturing Conference*, pp. 41–45, May 2009.

- [19] A. Jain, J. G. Sheridan, F. Levitov, V. Aristov, S. Yasharzade, and H. Nguyen. Inline sem imaging of buried defects using novel electron detection system: Di: Defect inspection and reduction. In *2018 29th Annual SEMI Advanced Semiconductor Manufacturing Conference (ASMC)*, pp. 259–263, April 2018.
- [20] S. Jansen, G. Florence, A. Perry, and S. Fox. Utilizing design layout information to improve efficiency of sem defect review sampling. In *2008 IEEE/SEMI Advanced Semiconductor Manufacturing Conference*, pp. 69–71, May 2008.
- [21] M. Avinun-Kalish, O. Sagy, Seong Moon Im, ChangHwan Lee, Jaehyoung Oh, Jungyeon Lim, Chulhong Kim, and Hyungwon Yoo. Novel sem based imaging using secondary electron spectrometer for enhanced voltage contrast and bottom layer defect review. In *2009 IEEE/SEMI Advanced Semiconductor Manufacturing Conference*, pp. 223–227, May 2009.
- [22] M. A. Hunt, T. P. Karnowski, C. Kiest, and L. Villalobos. Optimizing automatic defect classification feature and classifier performance for post-fab yield analysis. In *2000 IEEE/SEMI Advanced Semiconductor Manufacturing Conference and Workshop. ASMC 2000 (Cat. No.00CH37072)*, pp. 116–123, Sept 2000.
- [23] Ryo Nakagaki, Yuji Takagi, and Koji Nakamae. Automatic recognition of circuit patterns on semiconductor wafers from multiple scanning electron microscope images. *Measurement Science and Technology*, Vol. 21, No. 8, p. 085501, 2010.
- [24] 原田実, 細谷直樹, 中垣亮, 平井大博, 福永文彦, 山口宏平. 走査型電子顕微鏡を用いた定点検査アプリケーションの開発. 第30回 LSI テスティングシンポジウム, pp. 29–34, 2010.
- [25] Ralf Buengener. Defect inspection strategies for 14 nm semiconductor technology. In *Proc.SPIE*, Vol. 8466, pp. 8466 – 8466 – 7, 2012.
- [26] W. Liu, J. Shen, and B. Tan. Autofocusing image system of cd-sem. In *2009 2nd International Congress on Image and Signal Processing*, pp. 1–3, Oct 2009.
- [27] C. Mo and B. Liu. An auto-focus algorithm based on maximum gradient and threshold. In *2012 5th International Congress on Image and Signal Processing*, pp. 1191–1194, Oct 2012.
- [28] M. Subbarao and J. . Tyan. Selecting the optimal focus measure for auto-focusing and depth-from-focus. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 20, No. 8, pp. 864–870, Aug 1998.

- [29] Remo Kirsch, Ulrich Zeiske, Saar Shabtay, Mirko Beyer, Liran Yerushalmi, and Oren Goshen. Enhanced defect of interest [doi] monitoring by utilizing sensitive inspection and adtrue sem review. In *Proc.SPIE*, Vol. 7971, pp. 7971 – 7971 – 8, 2011.
- [30] M. Adel, M. Ghinovker, B. Golovanevsky, P. Izikson, E. Kassel, D. Yaffe, A. M. Bruckstein, R. Goldenberg, Y. Rubner, and M. Rudzsky. Optimized overlay metrology marks: theory and experiment. *IEEE Transactions on Semiconductor Manufacturing*, Vol. 17, No. 2, pp. 166–179, May 2004.
- [31] B. Schulz, R. Seltmann, J. Paufler, P. Leray, A. Frommer, P. Izikson, E. Kassel, and M. Adel. In-chip overlay metrology in 90 nm production. In *ISSM 2005, IEEE International Symposium on Semiconductor Manufacturing, 2005.*, pp. 390–393, Sept 2005.
- [32] Yi Sha Ku, Chi Hong Tung, and Nigel P.Smith. In-chip overlay measurement by existing bright-field imaging optical tools. In *Metrology, Inspection, and Process Control for Microlithography XIX*, Vol. 5752, May 2005.
- [33] Y. S. Ku, C. H. Tung, Y. P. Li, H. L. Pang, N. P. Smith, L. Binns, T. Rigden, G. Reynolds, and H. Fink. In-chip overlay metrology. In *Metrology, Inspection, and Process Control for Microlithography XX*, Vol. 6152, March 2006.
- [34] Shoji Hotta. Local overlay measurement and characterization for pitch split double patterning process using cd-sem. Vol. PC-O-18, 2012.
- [35] Boo-Hyun Ham, Sangho Yun, Min-Cheol Kwak, Soon Mok Ha, Cheol-Hong Kim, and Suk-Woo Nam. New analytical algorithm for overlay accuracy. In *Metrology, Inspection, and Process Control for Microlithography XXVI*, Vol. 8324, April 2012.
- [36] Minoru Harada, Kenji Obara, and Koji Nakamae. A robust sem auto-focus algorithm using multiple band-pass filters. *Measurement Science and Technology*, Vol. 28, No. 1, p. 015403, 2017.
- [37] Marylyn Hoy Bennett, Kenneth W. Tobin, and Shaun S. Gleason. Automatic defect classification: status and industry trends. In *Proc.SPIE*, Vol. 2439, pp. 2439 – 2439 – 11, 1995.
- [38] K. Watanabe, Y. Takagi, K. Obara, H. Okuda, R. Nakagaki, and T. Kurosaki. Efficient killer-defect control using reliable high-throughput sem-adc. In *2001 IEEE/SEMI Advanced Semiconductor Manufacturing Conference (IEEE Cat. No.01CH37160)*, pp. 219–222, 2001.

- [39] S. Chen, T. Hu, G. Liu, Z. Pu, M. Li, and L. Du. Defect classification algorithm for ic photomask based on pca and svm. In *2008 Congress on Image and Signal Processing*, Vol. 1, pp. 491–496, May 2008.
- [40] Jeff W. Ritchison, Ariel Ben-Porath, and Eric Malocsay. Sem-based adc evaluation and integration in an advanced process fab. In *Proc.SPIE*, Vol. 3998, pp. 3998 – 3998 – 11, 2000.
- [41] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger, editors, *Advances in Neural Information Processing Systems 25*, pp. 1097–1105. Curran Associates, Inc., 2012.
- [42] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich. Going Deeper with Convolutions. *ArXiv e-prints*, September 2014.
- [43] K. Simonyan and A. Zisserman. Very Deep Convolutional Networks for Large-Scale Image Recognition. *ArXiv e-prints*, September 2014.
- [44] Bernhard E. Boser, Isabelle M. Guyon, and Vladimir N. Vapnik. A training algorithm for optimal margin classifiers. In *Proceedings of the Fifth Annual Workshop on Computational Learning Theory, COLT '92*, pp. 144–152, New York, NY, USA, 1992. ACM.
- [45] Corinna Cortes and Vladimir Vapnik. Support-vector networks. *Machine Learning*, Vol. 20, No. 3, pp. 273–297, Sep 1995.
- [46] Bernhard Schölkopf, Alex J. Smola, Robert C. Williamson, and Peter L. Bartlett. New support vector algorithms. *Neural Comput.*, Vol. 12, No. 5, pp. 1207–1245, May 2000.
- [47] T. Kohonen. ”self-organized formation of topologically correct feature maps”. *Biol. Cybern.*, Vol. 43, pp. 59–69, 1982.
- [48] A. Rauber, D. Merkl, and M. Dittenbach. The growing hierarchical self-organizing map: exploratory analysis of high-dimensional data. *IEEE Transactions on Neural Networks*, Vol. 13, No. 6, pp. 1331–1341, Nov 2002.
- [49] Jaehyoung Oh, Gwangmin Kwon, Daiyoung Mun, Hyungwon Yoo, Sungsu Kim, Tae hui Kim, Minoru Harada, Yohei Minekawa, Fumihiko Fukunaga, and Mari Nozoe. In-die overlay metrology method using defect review sem images. *Proc.SPIE*, Vol. 8681, pp. 8681 – 8681 – 8, 2013.

- [50] Minoru Harada, Yohei Minekawa, Fumihiko Fukunaga, and Koji Nakamae. In-die overlay metrology method using sem images. *Journal of Micro/Nanolithography, MEMS, and MOEMS*, Vol. 17, pp. 17 – 17 – 7, 2018.
- [51] K. He, J. Sun, and X. Tang. Guided image filtering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 35, No. 6, pp. 1397–1409, June 2013.
- [52] Y. Boykov and V. Kolmogorov. An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 26, No. 9, pp. 1124–1137, Sept 2004.
- [53] Y. Boykov, O. Veksler, and R. Zabih. Fast approximate energy minimization via graph cuts. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 23, No. 11, pp. 1222–1239, Nov 2001.
- [54] Dominique Drouin, Alexandre Real Couture, Dany Joly, Xavier Tastet, Vincent Aimez, and Raynald Gauvin. Casino v2.42a fast and easy-to-use modeling tool for scanning electron microscopy and microanalysis users. *Scanning*, Vol. 29, No. 3, pp. 92–101.
- [55] Nicholas W. M. Ritchie. A new monte carlo application for complex sample geometries. *Surface and Interface Analysis*, Vol. 37, No. 11, pp. 1006–1011.