

半導体製造工程のモデリングにおける最小二乗最小ノルム解の前処理による解の制約

木村 泰己^{1,a)} 松縄 哲明^{1,b)} 三本木 省次^{1,c)}

概要: 半導体製造では、微細な回路パターンを半導体基板上に転写するリソグラフィー工程を高速かつ高精度にシミュレーションする必要がある。従来、このモデルはいくつかのガウス関数の線形和で定式化され、観測結果と一致するように複数のモデルパラメータを組み合わせ最適化で求めていた。近年、微細化が進み精度不足が問題となっている。本論文では、高精度化の為に、線形方程式で定式化される新しいシミュレーションモデルを開発した。この問題は、観測できる条件が限られているため不良設定となり、係数行列は悪条件になる。本論文では、最小二乗法において新たに解の概形を先験情報であるガウス関数に制約する手法を開発した。この手法は、特異値分解による打ち切り最小二乗最小ノルム解において、前処理を用いて最大特異値のみで打ち切った解を先験情報に制約するものである。つまり少ない特異値で打ち切っても解は十分意味があり、ガウス関数に近い高精度な解になる。加えて、少ない特異値で打ち切れる為、Randomized SVDにより高速に解が得られる。

キーワード: 半導体リソグラフィー, 特異値分解, 前処理

1. はじめに

半導体製造では、リソグラフィー工程によって所望の回路パターンが半導体基板上に転写される。具体的には、図 1 に示す通り、光源 (Illumination)、マスク (Mask) と呼ばれる回路パターンに対応する遮光板、投影レンズ系 (Lens) で構成される露光装置を用いて、マスクの回折光を投影レンズ系で集光し、半導体基板上 (Wafer) に塗布されたフォトリソトと呼ばれる光に反応する化学材料を感光させる事により回路パターンが半導体基板上に転写される。パターンの微細化に従って、マスク上に形成したパターンを半導体基板上に忠実に転写することが原理的に難しくなり [1], [2], 場合によっては転写不良となる。半導体基板上に設計通りの回路パターンを形成するためには、マスク形状を最適化しなければならない。その為には、半導体基板上に形成されるパターンを正確に予測する技術が必要となる。

半導体チップ全体の回路パターンの転写不良を事前に予測し修正する為には、高速かつ高精度なシミュレーションモデルが必要である。これは、主に光学モデル (Optical

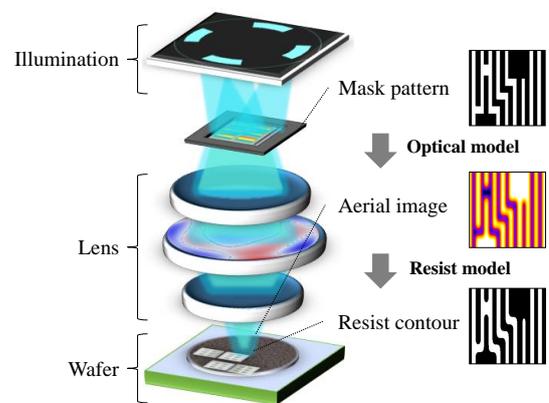


図 1 リソグラフィーシミュレーションの概要
Fig. 1 Outline of lithography simulation

model) とレジストモデル (Resist model) の 2 つのモデルで構成される。光学モデルは、光源から発せられた光が、マスク、投影レンズ系を経て、フォトリソトに照射され、光の強度分布 (Aerial image) を形成する過程を計算するモデルであり、高速かつ高精度な計算手法が確立されている [3]。レジストモデルは、最終段階の感光、現像を経て、半導体基板上に回路パターン (Resist contour) が形成されるまでのレジストプロセスと呼ばれる工程をシミュレーションするモデルであるが、これを高速かつ高精度に求める手法は確立されておらず、研究の対象となってい

¹ 東芝メモリ株式会社
Toshiba Memory Corporation
a) taiki2.kimura@toshiba.co.jp
b) tetsuaki.matsunawa@toshiba.co.jp
c) shoji.mimotogi@toshiba.co.jp

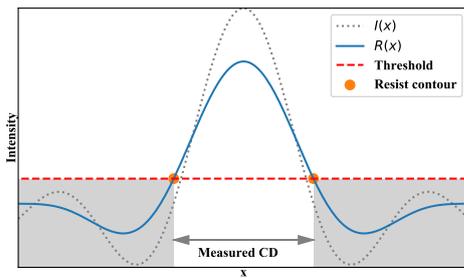


図 2 レジストモデル
Fig. 2 Resist model

る [4], [5], [6], [7].

以下, 2 章では従来のレジストモデルの概要と提案する新規モデルの定式化について, 3 章では最小二乗法における一般的な制約と, 提案する解の制約について述べる. 4 章で検証実験について述べ, 5 章でまとめと今後の課題を議論する.

2. レジストモデル

レジストモデルは, 図 2 に示した, 一定の閾値 (現像閾値) において, 実験と一致する輪郭 (等高線) が得られるレジスト像分布 $R(x, y)$ を求める形に一般化される. ここで, x - y 平面は半導体基板平面に一致しているものとし, 半導体基板に垂直な方向を z 軸とするが, 微細パターン形成においては, 感光性樹脂であるレジストが薄膜であることから無視できる. レジストモデルには, レジスト材料の化学反応式で定義された厳密モデルと, これを近似した簡易モデルがある. 本章ではこの簡易モデルの概要とその問題点, 及び今回提案する新規モデルについて述べる.

2.1 従来モデル

厳密モデルを近似した簡易モデルは, レジスト像分布 $R(x, y)$ を複数の物理モデルの線形和で表現した式 (1) となる.

$$R(x, y) = \sum_i \alpha_i I(x, y) \otimes N(0, \sigma_i^2) \quad (1)$$

ただし, α は係数, $I(x, y)$ は光学像強度分布, $N(0, \sigma_i^2)$ は分散 σ_i^2 のガウス関数である. 各項が, それぞれレジスト材料中の酸の拡散や中和反応, 酸の不純物への捕獲などの物理現象を表現している [8], [9], [10]. モデルパラメータは, 式 (1) における係数 α やガウス関数の分散 σ_i^2 になり, 実験結果と一致するモデルパラメータを組み合わせ最適化の手法を用いることで求めている. この方式は, モデルパラメータと物理現象の対応がとれるため制御しやすく, かつ原理的には線形和の項数 i を増やすことでモデル精度を向上させることができるという利点がある. しかしながら, 組み合わせ最適化を用いることから, パラメータの探索に時間がかかる点や, 局所解に陥ると所望の精度が得られないなどの課題がある.

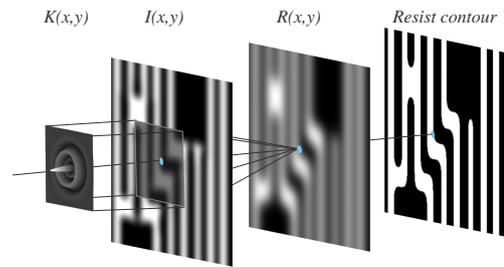


図 3 畳み込み積分モデル
Fig. 3 Convolution model

2.2 新しい簡易モデルの定式化

従来モデルで精度不足となる主な原因は, 式 (1) の項がガウス関数に制限されている点と, モデルパラメータを最適化手法によって求めている点にある. 本論文では, レジストモデルの高速化および高精度化のために, レジスト像分布 $R(x, y)$ を光学像強度分布 $I(x, y)$ と任意の積分核 $K(x, y)$ との畳み込みで表現する新しい簡易モデルを提案する. これは次式で表現できる.

$$R(x, y) = I(x, y) \otimes K(x, y) \quad (2)$$

積分核 $K(x, y)$ は, 観測で得られる $R(x, y)$ を表現するように, 実験結果と $I(x, y)$ から推定する. 以下, 定式化の基本的な考え方について述べる.

畳み込み積分は, 連立一次方程式の形式で表現できる. 従って式 (2) を離散化し行列表示で書くと,

$$A\mathbf{x} = \mathbf{b} \quad (3)$$

となる. ここで, $A \in \mathbf{R}^{M \times N}$, $\mathbf{x} = (x_1, x_2, \dots, x_N)^T$ は積分核, 行列 A の各行ベクトル $\mathbf{a}_i = (a_{i1}, a_{i2}, \dots, a_{iN})$ はある点を中心に切り出した光学像強度分布, $\mathbf{b} = (b_1, b_2, \dots, b_M)^T$ の成分 b_i はその点に対応するレジスト像分布の値である. 畳み込み積分なので, ベクトル \mathbf{a}_i と \mathbf{x}^T の内積の値が, その点のレジスト像分布の値 b_i に対応する形になっている. 図 3 は, 左から順に, 積分核 $K(x, y)$, 光学像強度分布 $I(x, y)$, レジスト像分布 $R(x, y)$, レジスト輪郭 (Resist contour) を表している.

実験で観測できるのは, 半導体基板上に転写された回路パターン, つまりレジスト像分布を一定の現像閾値で二値化したレジスト輪郭である. 実験結果とシミュレーション結果が一致するという事は, レジスト輪郭上の点で計算したレジスト像分布の値が現像閾値と一致している事を意味する. 従って, 列ベクトル \mathbf{b} の成分は現像閾値のみで構成される連立一次方程式が出来上がる. 言い換えると, この方程式には, レジスト像分布全体の中で, 現像閾値と一致する箇所の情報しか含まれていない. 輪郭上の観測点を増やせば, 見かけ上の式の数も増えるが, 先述したように現像閾値と一致しない箇所のレジスト像情報は含まれていないため, 本質的に式 (3) は不良設定問題となり, 解は不定

である。従って、適切な解を得る為には、合理的な制約を用いた解法が必要である。従来モデルで述べたように、レジスト材料の物理現象はガウス関数で近似できることが知られている。そこで、本論文では、ガウス関数を先験情報として考慮した前処理行列を導入することで、合理的な解を得る方法を提案する。

3. 制約付き最小二乗法

最小二乗法に制約を加える事で適切な解を得る方法がいくつか提案されている。本章では、はじめに一般的なL2ノルム最小化について述べ、次に新しい右前処理による制約方法について述べる。

3.1 L2 ノルム最小化

L2 ノルムを正則化項に用いた Tikhonov の正則化は

$$\mathbf{x} = \underset{\mathbf{x}}{\operatorname{argmin}} [\lambda \|\mathbf{C}\mathbf{x}\|^2 + \|\mathbf{A}\mathbf{x} - \mathbf{b}\|^2] \quad (4)$$

である。ここで λ は正則化パラメータである。この解は

$$\mathbf{x} = (\lambda \mathbf{C}^T \mathbf{C} + \mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b} \quad (5)$$

となる。ここで、 $\mathbf{C} = \mathbf{I}$ の場合は一般的な最小ノルム解である。 \mathbf{C} にラプラシアンなどの微分演算子を用いれば滑らかな解が得られる事が知られている。ここで先験情報としての解の概形がベクトル \mathbf{k} だとすると、もし $\mathbf{x} = \mathbf{k}$ の時、 $\|\mathbf{C}\mathbf{x}\|^2$ が最小となる様な行列 \mathbf{C} を構成できれば解を \mathbf{k} に制約する事が出来る。次に、式 (5) を \mathbf{AC} の特異値分解

$$\mathbf{AC} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T = \sum_{i=1}^N \sigma_i \mathbf{u}_i \mathbf{v}_i^T \quad (6)$$

を用いて書き直すと

$$\mathbf{x} = \sum_{i=1}^N w_i(\alpha) \frac{(\mathbf{u}_i^T \mathbf{b})}{\sigma_i} \mathbf{C}^{-1} \mathbf{v}_i \quad (7)$$

が得られる。ただし、

$$w_i(\alpha) = \frac{1}{1 + \frac{\alpha}{\sigma_i^2}} \quad (8)$$

である。ここで $i = t \leq N$ で特異値が急激に小さくなると仮定すると、式 (8) は

$$w_i(\alpha) = \begin{cases} 1: & i \leq t \\ 0: & t < i \leq N \end{cases} \quad (9)$$

と見なせる。よって、式 (7) は

$$\mathbf{x} = \sum_{i=1}^t \frac{(\mathbf{u}_i^T \mathbf{b})}{\sigma_i} \mathbf{C}^{-1} \mathbf{v}_i \quad (10)$$

となり、 $\mathbf{C} = \mathbf{C}^{-1} = \mathbf{I}$ とすると、式 (10) は

$$\mathbf{x} = \sum_{i=1}^t \frac{(\mathbf{u}_i^T \mathbf{b})}{\sigma_i} \mathbf{v}_i \quad (11)$$

となる。式 (11) は特異値分解による打ち切り最小二乗最小ノルム解である。この事は、後述する提案手法において使用する前処理行列 \mathbf{P} と式 (4) の Tikhonov の正則化における \mathbf{C} との関係を考える上で重要である。

3.2 新しい右前処理による制約

式 (4) において、 $\mathbf{C} = \mathbf{I}$ の時は一般的な最小ノルム解となることは既に述べたが、その他、解が滑らか等、一部の先験情報に関しては具体的な \mathbf{C} が提案されている。また、解がほぼ正確に分かっている場合、正則化項を参照ベクトルからの距離に拡張する手法 [11] などもある。しかし、先験情報として解の概形が分かっている場合の具体的な解法は提案されていない。

本論文では、前処理行列を導入することで、解を任意の概形に制約する方法を提案する。一般的に、前処理という行列の条件数を緩和する目的で使用されるが、本論文で扱う前処理を用いると条件数は悪化する。条件数は悪化するが、この前処理により解を所望の概形に誘導することができる。

提案手法の基本的な概念は、先験情報である解の概形の型を押し込む事により、解を変形させる事である。型を押し込む時、押し込まれる方が平坦 (均質) な方がより型に忠実に変形させる事が出来る。そこで、本提案における前処理は、型に押し込む前の平坦化処理と、型に押し込む処理の2つの工程から構成される。行列で表すと、平坦化とは行列の成分の均質化であり、型に押し込むとは、スケーリングに相当する。行列の成分が均質化すれば、当然、条件数は悪化する。この結果、特異値分解による打ち切り最小二乗最小ノルム解を考えると、最大特異値のみで構成した解が、型の形に変形する事になる。よって、少ない特異対で解を構成すれば、無数にある最小二乗解の中から先験情報に近い欲している解を選択する事が出来る。加えて、有効な特異対の数が少ない為、Randomized SVD [12] で高速に計算することが出来る。

3.2.1 スケーリングと畳み込み前処理

誘導したい解がベクトル $\mathbf{k} = (k_1, k_2, \dots, k_N)^T$ とすると、 \mathbf{k} を成分とするスケーリング行列 (対角行列) \mathbf{S} を

$$\mathbf{S} = \operatorname{diag}(k_1, k_2, \dots, k_N) \quad (12)$$

と定義する。また、 $\mathbf{g} = (g_1, g_2, \dots, g_N)^T$ を成分とする畳み込み行列 (Toeplitz 行列) \mathbf{T} を

$$T = \begin{pmatrix} g_1 & g_n & \cdots & g_3 & g_2 \\ g_2 & g_1 & \cdots & g_4 & g_3 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ g_{n-1} & g_{n-2} & \cdots & g_1 & g_n \\ g_n & g_{n-1} & \cdots & g_2 & g_1 \end{pmatrix} \quad (13)$$

と定義する. 行列 A に対して T を作用させると, A の全ての行成分は g で畳みこまれる. g が畳み込み演算において平滑化作用のある関数とすると, A の成分は均質化され条件数は悪化する. 本論文では以下, g は式 (14) で示すガウス関数とする.

$$g(x) = \frac{1}{\sqrt{2\pi}s^2} \exp\left(-\frac{x^2}{2s^2}\right) \quad (14)$$

ここで, s^2 は分散である. 右前処理行列 P を, S と T を用いて

$$P = ST \quad (15)$$

と定義する. この行列 P を用いて, 式 (3) の係数行列 A に右前処理を加えると

$$APP^{-1}\mathbf{x} = \mathbf{b} \quad (16)$$

となる. ここで $A' = AP$, $\mathbf{x}' = P^{-1}\mathbf{x}$ とおくと

$$A'\mathbf{x}' = \mathbf{b} \quad (17)$$

となる. \mathbf{x}' について特異値分解による打ち切り最小二乗最小ノルム解を求める. A' の特異値分解は

$$A' = AP = U\Sigma V^T = \sum_{i=1}^N \sigma_i \mathbf{u}_i \mathbf{v}_i^T \quad (18)$$

となり, \mathbf{x}' は

$$\mathbf{x}' = \sum_{i=1}^t \frac{(\mathbf{u}_i^T \mathbf{b})}{\sigma_i} \mathbf{v}_i \quad (19)$$

となり, 従って最終的に得たい解は

$$\mathbf{x} = P\mathbf{x}' = \sum_{i=1}^t \frac{(\mathbf{u}_i^T \mathbf{b})}{\sigma_i} P\mathbf{v}_i \quad (20)$$

と書ける. t は打ち切り数である. ここで, 式 (18) の $A' = AP = (AS)T$ の特異値分解を考える. ガウス関数の分散が $s^2 \rightarrow \infty$ の時, A' の成分は T によって行成分ごとに完全に均質化され一定の値になるとみなすと

$$A'_{s^2 \rightarrow \infty} = \begin{pmatrix} c_1 & c_1 & \cdots & c_1 \\ c_2 & c_2 & \cdots & c_2 \\ \vdots & \vdots & \ddots & \vdots \\ c_M & c_M & \cdots & c_M \end{pmatrix} \quad (21)$$

$$= (c_1, c_2, \dots, c_M)^T (1, 1, \dots, 1)$$

と書ける, この行列を特異値分解すれば, 当然, 右特異ベ

クトル \mathbf{v}_1 は

$$\mathbf{v}_1 = \frac{1}{\sqrt{N}} (1, 1, \dots, 1)^T \quad (22)$$

となる. 以上より, 分散 s^2 が大きいほど \mathbf{v}_1 の成分は均質化し, $s^2 \rightarrow \infty$ で完全に定数になる. 最大特異値で打ち切った解 $\mathbf{x}_{t=1}$ は式 (20) より

$$\mathbf{x}_{t=1} = \frac{(\mathbf{u}_1^T \mathbf{b})}{\sigma_1} P\mathbf{v}_1 = \frac{(\mathbf{u}_1^T \mathbf{b})}{\sigma_1} ST\mathbf{v}_1 \quad (23)$$

となる. ここで $ST\mathbf{v}_1$ に注目すると, 先に述べた通り \mathbf{v}_1 の成分は一定値に近いものに均質化されているが, ここで再度 T により均質化されるため, $T\mathbf{v}_1$ はさらに一定値に近づく. また, $(\mathbf{u}_1^T \mathbf{b})/\sigma_1$ も定数項になる. S は対角成分が k の対角行列なので, 結局, 式 (23) は

$$\mathbf{x}_{t=1} \approx \alpha \mathbf{k} \quad (24)$$

となる. ここで, α は定数である. 以上より, 右前処理行列 P の作用により, 最大特異値で打ち切った解は \mathbf{k} に制約されている. ガウス関数の分散 s^2 が大きいほど, 制約は強く, また条件数は悪化する. 当然, $t \ll N$ と打ち切りが十分早いとき

$$\mathbf{x} = P\mathbf{x}' = \sum_{i=1}^{t \ll N} \frac{(\mathbf{u}_i^T \mathbf{b})}{\sigma_i} P\mathbf{v}_i \approx \alpha \mathbf{k} \quad (25)$$

と見なせる. 以上より, \mathbf{k} が真の解の概形に近いものであれば, 少ない特異値で打ち切っても解は十分意味があり, 当然, 解は概形ベクトルに近いものになっている. また, 少ない特異値で打ち切れるので, Randomized SVD との親和性が良い.

3.2.2 ノルム最小化と右前処理行列の関係

式 (10) において $C = P^{-1}$ とすると,

$$\mathbf{x} = \sum_{i=1}^t \frac{(\mathbf{u}_i^T \mathbf{b})}{\sigma_i} P\mathbf{v}_i \quad (26)$$

となる. これは式 (20) と同じである. つまり, 行列 P で右前処理を施す事と, Tikhonov の正則化において, $C = P^{-1}$ として制約を加える事は本質的に同じである. よって, Tikhonov の正則化において, $\mathbf{x} = \mathbf{k}$ の時, 正則化項 $\|C\mathbf{x}\|^2$ が最小となる様な行列 C は P^{-1} である.

4. 実験結果

レジストモデルでは, 行列 A の各行の成分 a_{ij} は規格化された光学像強度分布なので, A は $a_{ij} \in [0.0, 1.0]$ で構成される密行列である. 積分核 K の大きさは $2.6 \times 2.6 [\mu\text{m}]$ で次元は $64 \times 64 = 4096$ とした. 照明形状の対称性から, 物理的に解は x 軸および y 軸に対して反転対称である事が要請される. よって K は 4 分の 1 だけ計算して後で展開すればよい. 従って, 計算する次元は 64×64 から $(32+1) \times (32+1) = 33 \times 33 = 1089$ になる. なおここで

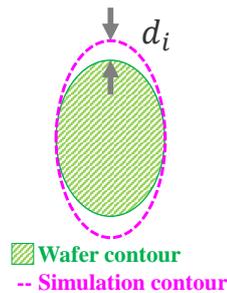


図 4 実験とシミュレーションの差分

Fig. 4 Residual between simulation and experiment

表 1 評価結果

Table 1 Evaluation results

Model	RMS [nm]	Relative Residual	Truncate Number
Conv.	10.045	N/A	N/A
Ours w/o P	2.960	0.02858	293
Ours w/ P	1.977	0.02833	16

32 + 1 と 1 を足したのは離散化したときの軸に対しての対称性を考慮して次元を奇数にする為である。本実験では、輪郭上から計 38379 点の観測点を抽出したため、用いた行列 A の規模は $M \times N = 38379 \times 1089$ である。

4.1 評価手法

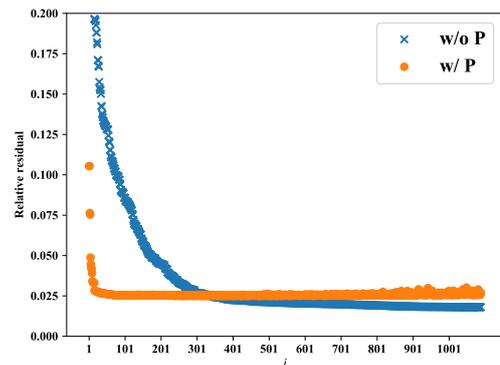
作成したモデルは、実験結果とシミュレーション結果の差分の二乗平方根 RMS(Root Mean Square) によって評価した。これは、半導体リソグラフィーの分野においてレジストモデルの精度評価に用いられる一般的な指標であり、次式で定義される。

$$\text{RMS} = \sqrt{\frac{1}{N_{mp}} \sum_{i=1}^{N_{mp}} d_i^2} \quad (27)$$

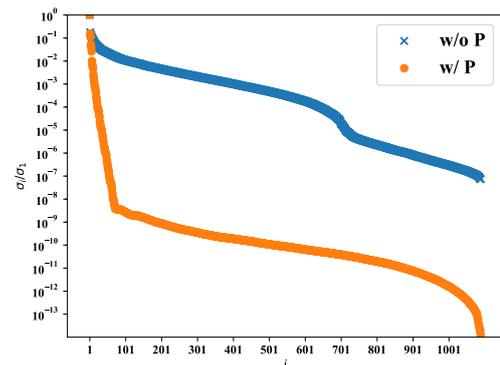
ここで N_{mp} は計測点の数、 d_i は図 4 に示す実験とシミュレーション結果の差分で、単位は nm である。この値が小さいほど、実験とシミュレーションの差が少なく精度が良い事を意味する。今回の実験では、 $N_{mp} = 11367$ である。先述した $M = 38379$ と N_{mp} が異なるが、これはモデル作成に使っていない観測点でモデル精度の評価を行ったためである。また、参考として、相対残差 $\|Ax - b\|^2 / \|b\|^2$ も評価した。

4.2 結果と考察

評価結果を表 1 に示す。RMS を見ると、提案手法は前処理有り (w/ P)、無し (w/o P) に関わらず、従来手法より良い結果である。これは、レジストモデルを畳み込み積分の形で定式化し、その積分核を推定する提案手法の有効性を示すものである。また、表 1 からは、提案手法間で、相対残差が 0.029 を下回る値に到達するのに使用した特異対



(a) Relative residual



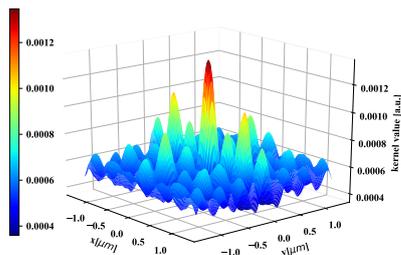
(b) Singular value

図 5 相対残差と特異値

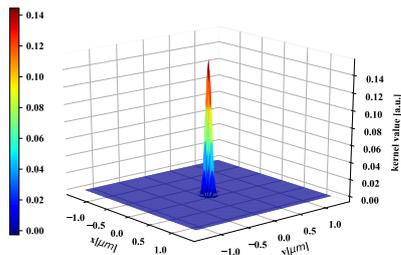
Fig. 5 Relative residual and singular value

の数は、前処理を加える事により 293 から 16 と約 12 分の 1 になっていることがわかる。この時、RMS は 2.960[nm] から 1.977[nm] に改善している。これは、右前処理を用いて解をガウス関数に制約した事の有効性を示すものである。残差が同程度であるが RMS が良いという事は、より良い解を選択できていると考えられる。

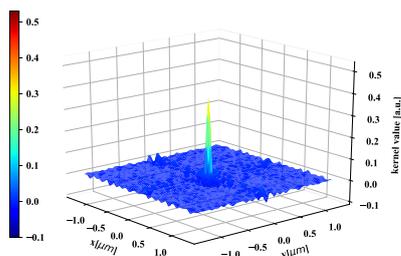
図 5 に相対残差と特異値、図 6 に解である積分核を示す。 $t = 1$ の時、前処理無しの (a) と前処理有りの (b) を比較すると、前処理有りの (b) がガウス関数に制約されている事が見て取れる。前処理の有無で残差が同じになる $t = 293$ と $t = 16$ で比較すると、前処理有りの方が周辺の値が抑えられており、よりガウス関数に近いものになっている。また、図 5(b) に示す特異値のグラフを見ると、前処理有りが無しと比較し、急に特異値が小さくなっている事が分かる。図 5(a) の残差のグラフを見ると、前処理有りが無しと比較して、急に相対残差が減少している。なお、前処理無しは $i = 342$ で前処理有りと交差し、 $i = 1089$ まで減少を続け、残差は 0.0180 まで低下している。しかしこの時の解は図 6(c) になり、過剰適合により全く先験情報からはかけ離れた意味のないものになっている。以上より、半導体リソグラフィーにおいては、提案手法は期待通りの結果を示しており、有効であることがわかる。



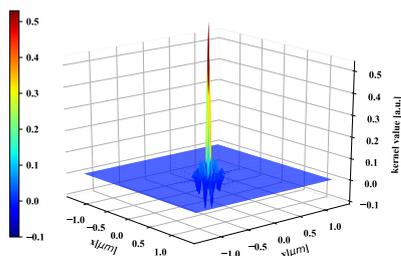
(a) w/o $P(t = 1)$



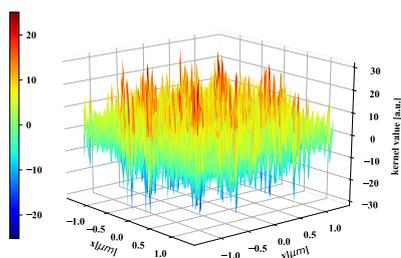
(b) w/ $P(t = 1)$



(c) w/o $P(t = 293)$



(d) w/ $P(t = 16)$



(e) w/o $P(t = 1089)$

図 6 レジストモデルの積分核

Fig. 6 Convolution Kernel for Resist Model

5. おわりに

本論文では、半導体製造工程のモデリングに不可欠なレジストモデルを、光学像強度分布と任意の積分核との畳み込み積分で定式化し、その積分核を実験結果から推定する手法を開発した。実験結果から、レジストモデルの解を先験情報であるガウス関数に制約することで高精度化を実現できる事を示した。

提案した右前処理により解を制約する手法は、その定義から、本論文で用いたように解をガウス関数に制約するだけでなく、任意の線形方程式において解を任意の関数に制約する事が可能と考えられる。従って、これを数理的に証明するのが今後の課題である。

参考文献

- [1] Hopkins, H. H.: The concept of partial coherence in optics, *Proceedings of the Royal Society of London, Series A*, Vol. 208, No. 1093, pp. 263–277 (1951).
- [2] Hopkins, H. H.: On the diffraction theory of optical images, *Proceedings of the Royal Society of London, Series A*, Vol. 217, No. 1130, pp. 408–432 (1953).
- [3] 渋谷真人, 大木裕史: 回折と結像の光学, 朝倉書店 (2005).
- [4] Matiut, D., Erdmann, A., Tollkuehn, B. and Semmler, A.: New models for the simulation of post-exposure bake of chemically amplified resists, *Proc. of SPIE*, Vol. 5039, pp. 1132–1143 (2003).
- [5] Nagahara, S., Yuan, L., Poppe, W. J., Neureuther, A., Kono, Y., Sekiguchi, A., Fujiwara, K., Watanabe, T. G., Taira, K., Kusumoto, S. et al.: Understanding quencher mechanisms by considering photoacid-dissociation equilibrium in chemically amplified resists, *Proc. of SPIE*, Vol. 5753, pp. 338–350 (2005).
- [6] Chen, A., Foong, Y. M., Zhang, D. Q., Zhang, H., Chung, A., Fryer, D., Deng, Y., Medvedev, D. and Granik, Y.: Evaluation of compact models for negative-tone development layers at 20/14nm nodes, *Proc. of SPIE*, Vol. 9426, p. 94261P (2015).
- [7] Kim, S.-M., Lim, C.-M., Jung, M.-R., Kim, Y.-S., Kwon, W.-T., Ahn, C.-N., Sun, K.-T., Fumar-Pici, A. and Chen, A. C.: Understanding of stochastic noise, *Proc. of SPIE*, Vol. 9422, p. 94220M (2015).
- [8] Garofalo, J. G., DeMarco, J., Bailey, J., Xiao, J. and Vaidya, S.: Reduction of ASIC gate-level line-end shortening by mask compensation, *Proc. of SPIE*, Vol. 2440, pp. 171–184 (1995).
- [9] Tsudaka, K., Tomita, M., Sugawara, M., Kawahira, H. and Nozawa, S.: A fast image estimation methodology using light intensity distribution, *Proc. of SPIE*, Vol. 2512, pp. 384–395 (1995).
- [10] Granik, Y., Cobb, N. and Medvedev, D.: Application of CM0 resist model to OPC and verification, *Proc. of SPIE*, Vol. 6154, p. 61543E (2006).
- [11] 岩間尚文, 大館暁: 画像再構成の数理的基礎 (画像再構成とパターン認識の数理), プラズマ・核融合学会誌, Vol. 92, No. 10, pp. 743–762 (2016).
- [12] Halko, N., Martinsson, P.-G. and Tropp, J. A.: Finding structure with randomness: Probabilistic algorithms for constructing approximate matrix decompositions, *SIAM review*, Vol. 53, No. 2, pp. 217–288 (2011).