

# ニューラルネットワークを用いた 電子線描画のドーズ量決定手法

## *Estimation of Dose Distribution on Electron Beam Lithography System Using Neural Networks*

森脇 耕介\*    佐藤 和郎\*    福田 宏輝\*  
*Kousuke Moriwaki   Kazuo Satoh   Hiroki Fukuda*  
 四谷 任\*\*  
*Tsutom Yotsuya*

(2008年6月20日 受理)

キーワード：電子線リソグラフィ，ドーズ，ニューラル・ネットワーク，アナログレジスト，ホログラム

### 1. はじめに

超微細加工手段の一つである電子線リソグラフィによって、微細構造物を作製する場合の、工程簡略化のための一技法を提案する。加工対象は、フレネルレンズや位相型ホログラムなどで、微小光学素子の基本的構造であるマルチレベル構造である。

マルチレベル構造は、ある平板状の基板表面に、厚み方向に勾配あるいはその近似として階段状の、段差(厚み、深さ)が形成されている状態を指す。

段差あるいは厚みにより、光波が反射・透過した際に生じる位相差の分布を、レンズやホログラムなど、波面や強度分布の変換作用をもつ光学素子として利用する。

このマルチレベル構造の作製方法の一つが、電子線リソグラフィである。図1に示すように、電子線レジストを基板材上に平坦に塗布し、電子線照射量を変調しながら照射(以下、電子線描画)することにより部分的に残存、あるいは除去の程度を変え、所望の形状を成形する。その後、必要に応じて、シリコンや石英などの基板材にドライエッチングなどの装置を使用し

て形状を転写する。

電子線レジストは、電子線の照射量(ドーズ量)に対する残膜量の特性的違いで、大別してバイナリ型とアナログ型、またそれぞれにポジ型、ネガ型が存在する。それぞれの特性や用途を論じることは主眼ではないので省略する。本報告では、電子線のドーズ量に

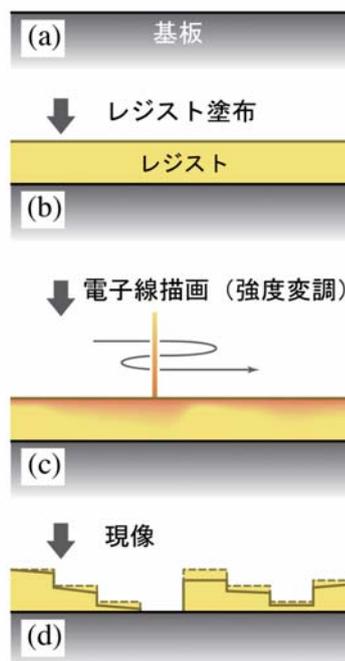


図1 レジスト成形工程

\* 情報電子部 電子・光材料系  
 \*\* 情報電子部(現 大阪府立大学 21世紀科学研究機構 ナノ科学・材料研究センター)

じて厚さ方向に滅失する，ポジ型アナログ型レジストを用いた光学素子作製の改良技法を報告する．以下，ポジ型アナログ型レジストを単にレジストと呼ぶ．

電子線描画によるレジスト成形工程の流れを図1に示す．同図中(d)の破線が目的のレジスト形状であるとする．レジストには，商品ごとに図2のような感度特性があり，これより基板上の位置によって残留させたいレジスト厚に対するドーズ量を決定し，描画を行う．現像後，所望のレジストの深さ分布が得られる．

このような単純な作業を行うと，2章に述べる近接効果と呼ばれる電子線の散乱のために，各位置ともドーズ量が過剰で，図1(d)での点線ではなく，実線のような傾向が現れる．

したがって，目的通りのレジスト深さ分布を得るには，あらかじめ近接効果を考慮して，照射するドーズ量の分布を決定すればよい．しかし，電子の散乱状況は，後述のように影響する要因が一定でないため，予測は難しい．

そこで実際の加工における手順は，大きく次の二通り考えられる．

- [1] 電子線散乱をあらかじめ計算機シミュレーションし，既知の基板材，レジスト材の物性値を使い，最適なドーズ量分布を予想し，実際の加工を実施する．
- [2] 予備的な描画を行い，目的の形状に近づくようドーズ量を適量変更し，また描画する．これを目的形状が得られるまで試行錯誤的に反復する．

上の[1]の手順は，設計品を量産する場合には適切な方法といえる．電子の散乱シミュレーションは，ハードウェアやソフトウェアともに，ある程度のコンピューティング環境を整える必要があるため，コストとの兼ね合いとなる．

しかし，ある機能形状を研究開発する段階では，さ

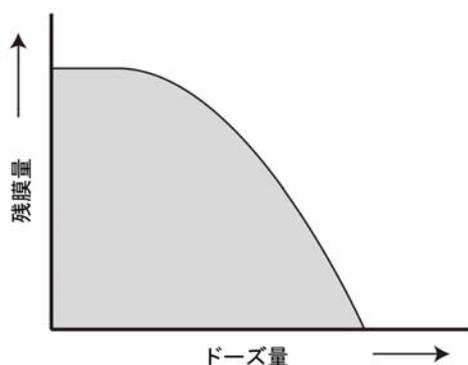


図2 レジスト感度特性

まざまな形状の短時間での少量試作が求められ，またそれはおおむね高価な設備の投入以前の段階であるため，実際には，ほとんど上記[2]の手順にならざるを得ない．

[2]のような工程で，加工手順を単純化し，研究開発のスループットを向上させるには，「試行錯誤」的作業の低減がポイントである．すなわち，少ない予備実験で最適なドーズ量を決定でき，目的形状を得ることである．また，作業者のスキルに依存しない客観性も必要である．

この課題に対して，ニューラルネットワーク(以下，NNと略記する)による学習・想起の機能を利用したドーズ量の推定法を試みた．最初にあるドーズ量を設定して予備描画を行う．誤差の大きなレジスト成形結果を用いて，ある点に関して，ドーズ量と，結果であるその近傍を含むレジストの深さ分布の対応関係を，レジスト上全点について求め，NNに学習させた．詳細は後述するが，学習済みのNNに，ある着目点とその近傍の設計形状を入力したときに，NNにはその着目点に対する補正されたドーズ量が想起されることを期待した．

実際に加工実験を実施したところ，良好な補正ドーズ量が得られた．電子線描画に関して，最適ドーズ量の導出にNNを利用した例は他に見当たらない．

一度の予備描画で本描画のためのドーズ量の最適分布が得られ，工程の短縮につながる．機械的に測定と学習を実施するのみであるため，試行錯誤的作業が低減できる．客観的で熟練も必要なく，人的・物的コストの削減につながる簡便手法を提案している．

## 2. 電子線の近接効果

電子線描画時に基板面へ照射される電子は，図3のようにレジスト内で散乱(前方散乱)し，また基板か

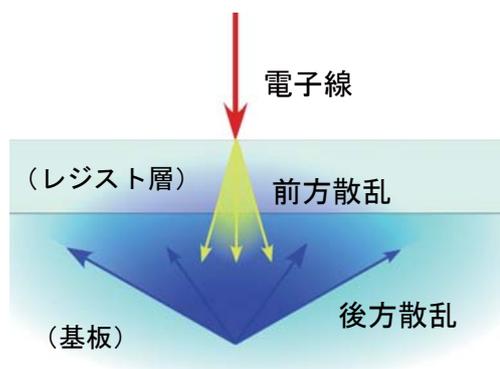


図3 近接効果

ら反射(後方散乱)する。それぞれの密度は、面方向に対し、照射点を中心とした分散の異なる正規分布で、ある着目点から距離  $r$  離れた位置の深さ  $z_0$  のレジスト中での総エネルギー密度  $E(J/m^3)$  は近似的に次式で表される<sup>1)</sup>。

$$E(r, z_0) = K \left[ \exp \left\{ -\left( r/\sigma_f \right)^2 \right\} + \eta \sigma_b^2 / \sigma_f^2 \exp \left\{ -\left( r/\sigma_b \right)^2 \right\} \right]$$

右辺第一項が照射方向へのレジスト中での前方散乱、第二項が基板からの反射による後方散乱を表す。 $\eta$  は両者の比率、 $\sigma_f$ 、 $\sigma_b$  はそれぞれ前方散乱、後方散乱のエネルギー密度がピーク値の  $e^{-1}$  になる距離、 $K$  は定数である。いずれも電子線の加速電圧、レジスト層の材料や厚み、基板材質に依存し、それにより近似精度も変わる。したがって加工の都度、実験で決定する必要がある。またレジストの電子線強度対深さ特性が線形ではない。そのため、前述のように、最適な電子線ドーズ量分布を予測して、一度の試作で意図した形状を得ることが難しい。

なお、近接効果は、半導体製造プロセスにおけるバイナリ型レジストを使用した場合の平面パターン線幅の補正対象としてよく知られる。ここでは触れないが、その補正方法は、既に数多くの手法が提案され実用化もされている。

しかし、半導体製造に比べれば需要が少ないこともあるため、アナログ型のレジストの厚みや深さの分布構造を加工する場合については、効果的な補正手法はほとんど見当たらない。電子散乱のシミュレーションによる方法も物性値や感度特性等が既知であることが前提である<sup>2)</sup>。

### 3. ニューラルネットワーク (NN)

本報告で使用した NN は、階層型である。ニューロ・ユニットの入出力 ( $s_{in} - s_{out}$ ) 特性は次式のシグモイド関数状(図4)である。

$$s_{out} = 1 / \left[ 1 + \exp \left\{ (-s_{in} + \theta) / T \right\} \right]$$

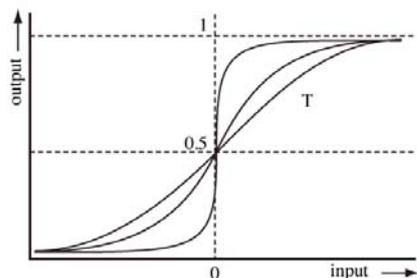


図4 シグモイド関数

ここで  $\theta$  はしきい値、 $T$  は温度と呼ばれ、シグモイド関数の応答を決めるパラメータで、ネットワークの学習時の収束性に影響する。

入力層のユニット数は、後述の学習時に用いるデータ数と同じである。入力層・中間層間、および中間層・出力層間では、ユニットはウェイトを介してすべて相互に結合させた。

レジストの深さ分布の入力層への入力値は、図1(a)のレジスト表面を基準に、予備描画結果で越えない最大深さで  $[0, 1]$  に正規化した値を用いた。同様に出力側へは最大ドーズ量を設定し  $[0, 1]$  に正規化した値を用いた。

#### (1) 学習

学習に用いる情報を図5に示す。同図のような深さの分布が設計値、あるいは描画後の形状として与えられたものとする。レジスト面上の位置は等間隔に定められた点、例えば図5で示すように、正方配置で定義され、点数が  $X \times Y$  とする。

ある着目点について、ドーズ量はその点に対する値を1点用いる。深さ分布については、同着目点を中心とするある幅  $w$  を持った近傍領域内の深さ分布  $w \times w$  点をすべて対応させる。この対応を1組の学習データとする。さらに着目点を変え、レジスト面上のすべての位置に関する同様の対応関係  $X \times Y$  組を作り、学習データセットとする。

NNの入力層ユニット数を  $w \times w$  個とし、上記のレジスト深さを対応させる。出力層ユニット数は1個であり、上記のドーズ量を対応させる。学習データセット全組を、さらに反復してNNに学習させる。

周辺の着目点で、近傍領域が描画領域を外れる場合も、電子線未照射の位置のレジスト深さをそのまま用いた。

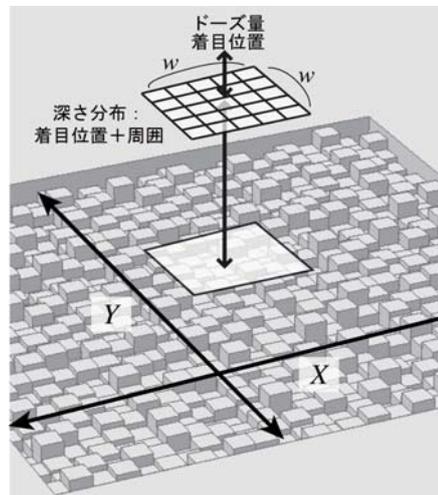


図5 ニューラルネットワーク使用する情報

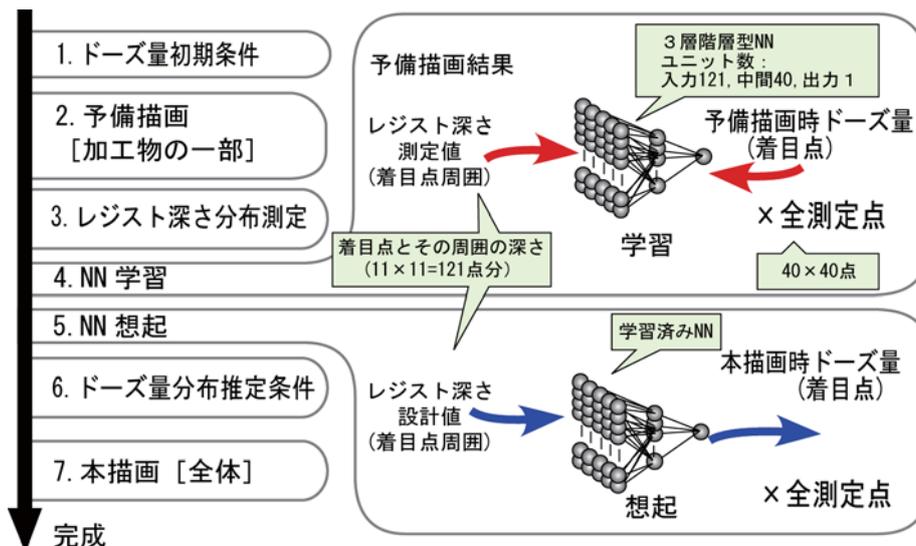


図6 提案手法のフロー

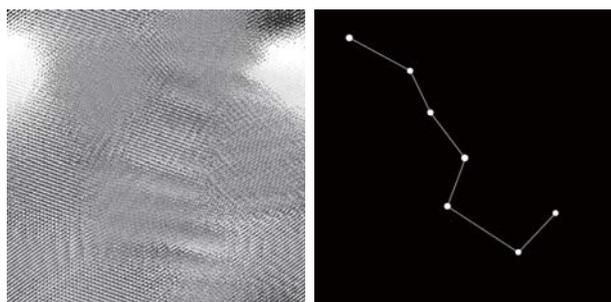
学習アルゴリズムには誤差逆伝搬法を用いた。ニューロユニットのしきい値 $\theta$ と、温度 $T$ は、すべてのユニットに一律の値を設定した。これらの調整や収束状況に関する詳細はここでは省略する。

(2) NNの想起

ニューラルネットワークでは、多変量測定値の補間値の推定に用いられることがある。学習させていない入力に対しても、学習に用いた値を補間した出力を得られる。本報告ではこの能力を利用する。

3(1)節の学習が終了したNNに、ある着目位置の学習時の深さ分布形状をそのまま入力層に入力すると、出力側には何らかの学習時のドーズ量に近い値が出力される。

学習時の深さ分布は、近接効果の誤差を含んだ予備実験によるものであるが、本当に必要な深さ分布をNNに入力するならば、出力に表れるのが、その形状に最適なドーズ量であるかもしれない。散乱電子の着目点周囲への影響が、ユニット間結合のウェイトの大きさとして学習され、想起結果を用いて描画すれば、良好な描画結果が得られることを期待する。



(a) 位相分布 (b) (a)による回折像

図7 CGHパターン

NNを取り入れる利点は、形状→ドーズ量の対応関係のブラックボックスが、機械的作業で自動的に構築できるかもしれないことである。試行錯誤を繰り返しての最適ドーズ量への調整が、経験と勘を要する作業であることを考えれば、工程全体の大幅な時間短縮につながる。

4. 試作実験

図6に、作業フローを示す。階層型NNは中間層1層を有する3層型とし、各層のニューロ・ユニット数は、入力層121( $w=11$ )、中間層4、出力層1とした。

試作対象は、計算機ホログラム (Computer Generated Hologram: 以下CGH) である。面上に位相遅れ分布を作製し、回折によって光強度分布の像を生じさせる光学素子である。特に、位相遅れ分布のみのCGHは、

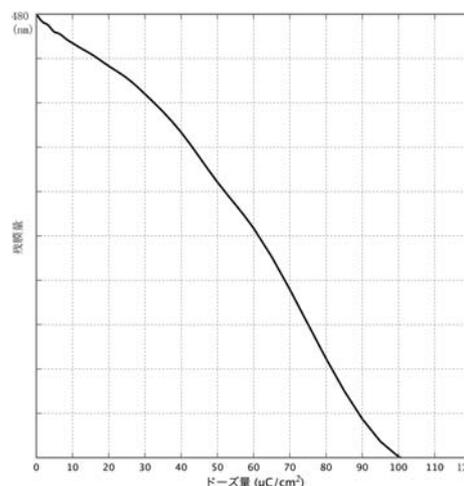


図8 OE BR1000 ドーズ量対残膜量

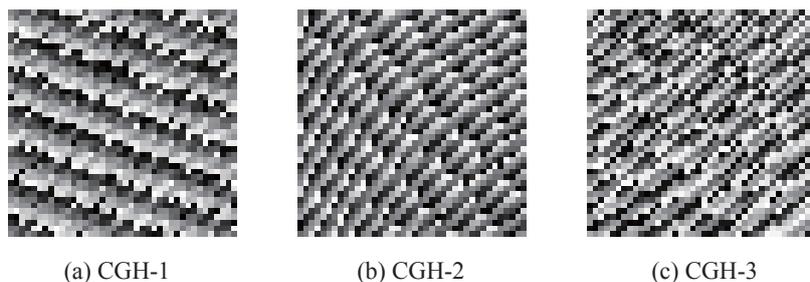


図9 試作 CGH パターン

空気中と屈折率が異なる透明媒質 —ここではレジストや基板材に相当する— に厚み分布を形成することによって実現できる。キノフォームとも呼ばれる。設計には、よく知られている反復フーリエ変換法<sup>3)</sup>を用いた。

得られた位相分布の例を図7 (a) に示す。明暗は位相遅れの大きさで、 $512 \times 512$  点の正方配置で与えられている。各点の設計位相値  $\phi(i, j)$  は  $[0, 2\pi)$  の連続値であり、多くのレベルを含むため、提案手法の目的に最も合致する対象である。参考のため同図 (b) に回折像を示す。

使用したアナログ型レジストは比較的低感度な、OEBR1000-100(東京応化工業社製)である。図8にドーズ量対残膜量の一特性を示す。CGH 各点の設計位相値に対して、OEBR1000-100 の硬化後の屈折率は約 1.5 である。再生に使用するレーザー光の波長(約 633 nm)からレジストの深さの範囲が決まる。

提案手法の評価に実際に加工したのは、図7 (a) の3カ所から切り出した  $40 \times 40$  点の3パターンである。図9 (a) ~ (c) にそれらを示す。いずれもブレード(鋸歯)状の凹凸が基調であるが、周期や方向などの特徴が異なる部分を用いた。

設計時の位相遅れは連続値であり、図10の破線に示すような滑らかな勾配を含むが、通常、同図中実線のように数レベルの階調に近似する。ここでは回折効率に大きな劣化を生じない程度とされる8レベルに近似した<sup>4)</sup>。以下図6のフローに従って実験を行った。

【予備描画と深さ測定】CGH-1 ~ CGH-3 を、8レベルのドーズ量を用いて予備試作した。各点の大きさは  $4 \mu\text{m}$  角とした。合成石英基板 (25 mm 角、厚さ 1 mm) 上に、レジスト OEBR1000-100 を  $1.9 \sim 2.0 \mu\text{m}$  厚でスピコートした。8レベルそれぞれに対する初期のドーズ量は、図8の特性に、上記レジスト厚の倍率を掛けた概略値を使用した。NNの学習によって、最適なドーズ値に修正されるかの検証が本報告の主旨なので、予備描画時のドーズ量は特に厳密な値である必要はない

電子線描画装置は、当所内フォトニクス研究開発支援センター設置の日本電子社製 JBX-5000SI を、電子線加速電圧 50 kV で使用した。

描画、現像後、CGH-1 ~ CGH-3 各試料に対し、試料上すべての着目点と、さらに外側の位置も含めて、 $55 \times 55 =$  点の深さを計測した。測定には Zygo 社製白色光干渉式顕微鏡、New-View 5020 を使用した。

【学習】3(1) 節で述べた要領で、CGH-1 に関する学習データセットを作成し、NN に学習させた。

学習は約 5000 回反復した。今回は学習停止条件は特に設定せず、学習誤差が十分低下し収束したと思われる時点で学習を停止した。

【想起】3(2) 節に述べた要領で、CGH-1 に関して学習済みの NN を用いて、CGH-1 自身の設計形状に対する出力値を、想起ドーズ量とした。

学習した内容は、CGH-1 の形状とドーズ量の関係のみである。NN が、特定の形状分布について、未学

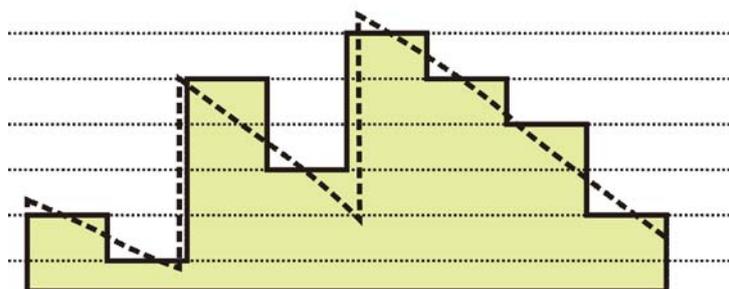


図10 レベル近似

習の深さ分布にもドーズ量を想起する汎化能力のみでなく、異なる深さ分布形状に関してもドーズ量の想起を良好に行うことを期待した。そのために、学習にも全く用いていない CGH-2, CGH-3 についても、同じ学習済み NN を用いてそれぞれドーズ量の想起を行った。

【本描画】想起させたドーズ量で、予備描画と同じ基板、レジスト厚で、CGH-1～CGH-3 の描画と現像を実施した。

## 5. 結果と考察

図 11 に実験結果をまとめる。CGH-1～CGH-3 それぞれについて、予備描画および本描画時、それぞれにおける設計形状、描画時のドーズ量頻度等を示している。

4 章【想起】で述べたように、学習と想起にあたっては、2つのケースがある。予備描画と本描画で、用いる形状が同一か異なるかである。以下に場合を分けて考察する。

### (1) 学習／想起に同一の形状を用いた場合

予備描画、本描画ともに CGH-1 の形状を使用した場合である。図 11 中、CGH-1 の列に結果を示す。

(a) は CGH-1 の設計形状で、図中、高さが深さに相当している。(b) は 8 レベルに対応する予備描画のドーズ量の頻度で、8 段階が明確に使用され、それぞれほぼ均等に混在していることがわかる。

(d) は、(b) のドーズ量で予備描画した深さ分布の、(a) の設計形状の深さ分布に対する比である。設計形状に対する均一さの目安となるが、周辺部より、中心部になるほど過剰の程度が大きくなっていることがわかる。(f) は (d) の比の値を頻度分布で示したものである。比であるから、設計形状に近いほど値 1 に集中するはずである。しかし 1.5 を中心に広く分布している。

これらからは、予備描画の結果が、全体に深さが過剰で、かつ設計形状との誤差にムラがあることを示している。これは近接効果の影響と考えられる。

この予備描画の結果である深さ分布とドーズ量分布の関係を NN に学習させ、設計形状に対して想起させたドーズ量の頻度分布が (c) である。予備描画のときの頻度分布 (b) に対して幅が生じ、多様なドーズ量が使用されている。CGH パターン上の位置との対応はここに示していないが、中心部に比べて周辺部に対するドーズ量が、やや強くなる傾向があった。

この想起されたドーズ量を用いて本描画を行った。(e)、(g) がそれぞれ本描画後の形状比分布と形状比頻

度分布である。(e) はほとんどフラットとなっており、(g) では、比の値が 1 に集中していることが明らかである。(e)、(g) から、想起されたドーズ量によって設計形状に近い描画結果が得られたことがわかる。

着目すべき点は、ドーズ量について (b)→(c) の変更が NN によって自動的に提案され、それにより (d)→(e)、および (f)→(g) のように、加工結果に明らかな改善が認められたことである。そして、そのドーズ量修正の過程が、データ分析によらず、NN での学習と想起という、計測値の単純な機械的処理によって行われたということである。

従来、経験に依存する試行錯誤的な反復作業であったマルチレベル加工が、予備描画と本描画という、2回の描画で良好な結果に達し得たことが、本報告における重要な知見である。

### (2) 学習／想起に異なる形状を用いた場合

5(1) 節では、ドーズ量と描画結果の対応関係は、学習と想起で同じ設計形状を使用し形成されたものであった。しかし、もしある形状をもとに学習を終えた NN が、異なる形状の最適ドーズ量も想起できるならば、例えば図 7 (a) のような点数の大きな設計形状であっても、予備描画にはパターン全体は必要はなく、一部領域のみで済むため、学習も短縮化でき、作業全体の効率が向上する。そこで、CGH-1 の予備描画結果を学習した NN を、CGH-2、および CGH-3 の本描画に適用しても良好な結果が得られるかの検証を行った。

図 11 中、CGH-2、および CGH-3 の列に結果を示す。(a')～(g') および (a'')～(g'') は、それぞれ (a)～(g) に対応しているが、異なるのは、CGH-2、CGH-3 の本描画用のドーズ量分布 (c')、(c'') を想起するとき、CGH-1 の予備描画結果だけを学習させた NN を用いている点である。

(d')→(e')、(d'')→(e'')、また (f')→(g')、(f'')→(g'') と、いずれも 5.1 と同様の考察ができる。すなわち、NN が想起したドーズ量によって、本描画の加工結果に顕著な改善が見られた。

5(1) 節と 5(2) 節を総括する。まず予備描画では、近接効果の散乱の影響と考えられる大きな誤差が全体にみられ、特に周辺部に比べ中央部でより大きな誤差があった。しかし、続く本描画では、誤差が設計形状全面で減少し、設計形状に大きく近づいた加工結果が得られた。

単純な予備実験と学習の手続きのみで、設計形状を入力すれば理想に近いドーズ量を出力する「ブラックボックス」が、NN に構成されたと考えられる。

本報告では詳細な解析は行っていないが、NNが学習した内容は、ある位置への電子線照射について、その周辺のドーズ量分布とそこからの散乱の影響、またドーズ量対厚みの非線形特性、さらにレジストや基板

材質など、もし個別に考慮するならば非常に複雑になるはずの要因を、全て包括して学習したものと考えられる。

さらに重要な知見は、学習済み NN が、学習に用い

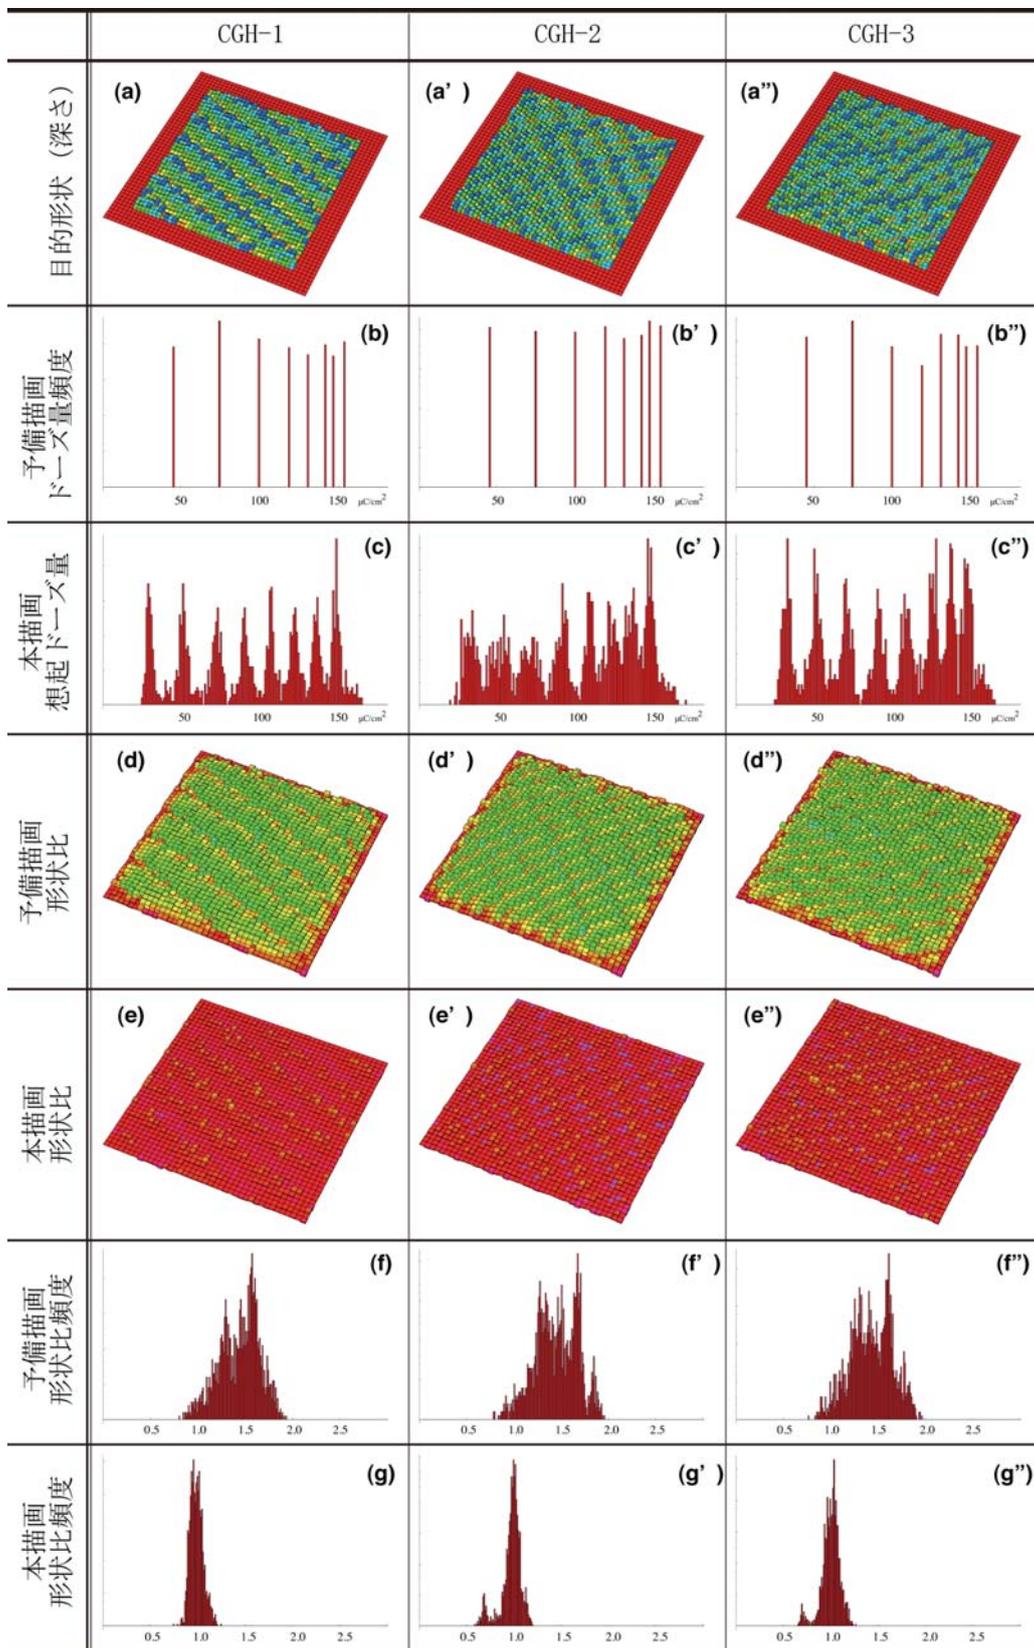


図 11 加工結果一覧

た設計形状だけでなく、学習していない設計形状に対しても有効なドーズ量を想起したことである。このことから、ある設計形状があって、その一部分を切り出して予備描画と学習を行った NN に、設計形状全体に対して最適ドーズ量を想起させ本描画するという、加工手順の効率化も可能であることがわかった。

## 6. まとめ

本報告では CGH の試作実験を取り上げ、NN の機能を利用して工程が簡便化できることを示した、初めての試みである<sup>5)</sup>。本手法の適用の範囲を、さらに拡大し検証することは興味深い課題である。

例えば、予備描画に用いる設計形状の一部分として、どのような部位のどの範囲を選択するかは結果に影響がないとは言えない。ニューラルネットワークの学習について、本報告の範囲では、学習誤差が良好に収束したが、ニューロ・ユニットの入出力特性やパラメー

タ、また階層数やユニット数などについて、最適な条件を導出したわけではない。

予備描画後に、試料のレジスト深さ分布を計測する手段が必要であることは、作業上の重要な問題点として挙げておかなければならない。

提案手法には、さらに改善する余地が多く残るが、将来実用される場合に想定される形態は、電子線描画装置に、レジスト深さ分布の測定装置とニューラルネットワークのソフトウェアを組み込んだシステムであろう。

## 参考文献

- 1) 徳山 巍編：超微細加工技術，応用物理学会 (1997) p.121.
- 2) 岡野正登：大阪府立大学学位論文 (2007) p.35.
- 3) Victor Soifer, Victor Kotlyar and Leonid Doskolovich: Iterative Methods for Diffractive Optical Elements Computation, Taylor & Francis (1997) p.11.
- 4) 回折光学素子入門，応用物理学会 (1997) p.119.
- 5) 大阪府：特開 2006-276116.