

畳み込みニューラルネットワークを応用した
三次元屈折率分布計測システムの開発

貫洞 大地

博士（工学）

北海道大学大学院工学院
量子理工学専攻

令和元年度(2019)

目次

第1章 序論	1
1.1 はじめに	1
1.2 三次元屈折率分布計測システムの原理	4
1.2.1 入射角可変マッハツェンダー干渉計による多角度からの干渉画像の撮影	4
1.2.2 干渉計測の原理	4
1.2.3 フーリエ変換法	6
1.2.4 位相アンラッピング	11
1.2.5 コンピュータトモグラフィー (CT) の原理	14
1.2.6 光位相CT	15
1.3 計測システムとその課題	15
1.4 機械学習	16
1.4.1 教師あり学習	18
1.4.2 畳み込みニューラルネットワーク	19
1.4.3 機械学習についてのまとめ	25
1.5 本研究の目的と意義	25
1.6 本論文の構成	26
第2章 畳み込みニューラルネットワークを利用した位相抽出	28

2.1	はじめに	28
2.2	ネットワーク構成	28
2.2.1	オリジナルのU-netと位相抽出ネットワークの差異	29
2.3	学習条件およびその他のハイパーパラメータ	33
2.4	シミュレーションによる学習データ生成	34
2.4.1	正解データ：位相変化像の作成	35
2.4.2	入力データ：干渉画像の作成	37
2.5	学習経過および抽出結果	40
2.5.1	ハイパーパラメータの比較	46
2.6	まとめ	48
第3章	学習データの改善によるネットワークの性能評価	49
3.1	はじめに	49
3.2	実測情報を利用した学習データによる学習	49
3.2.1	正解データ：位相変化像の作成	49
3.2.2	入力データ：干渉画像の作成	57
3.2.3	学習経過および抽出結果	61
3.3	本章のまとめ	69
第4章	三次元再構成	70
4.1	はじめに	70
4.2	投影データの準備	73
4.3	三次元再構成結果	74
4.3.1	既存の手法による再構成結果	74
4.3.2	新手法による再構成結果	80

第5章 結論	84
参考文献	86
謝辞	91

第1章 序論

1.1 はじめに

媒質中の光の速度 v は媒質の誘電率 ϵ および透磁率 μ に依存し，また波長の逆数に比例する波数 k は角周波数 ω と媒質中の光の速度 v の比として表される．

$$v = \frac{1}{\sqrt{\epsilon\mu}} \quad (1.1)$$

$$k = \frac{\omega}{v} = \omega\sqrt{\epsilon\mu}, \quad (1.2)$$

屈折率 n は波数 k と真空中の波数 k_0 の比により定義され，真空中の誘電率と透磁率を ϵ_0, μ_0 とすると

$$n = \frac{k}{k_0} = \sqrt{\frac{\epsilon\mu}{\epsilon_0\mu_0}} \quad (1.3)$$

と表され，非磁性体 ($\mu = \mu_0$) の場合は ϵ のみに依存する．

物質の誘電率 ϵ は分極のしやすさを与えており，分極は物質を構成する分子や原子を構成する電子の偏りやすさを表す．誘電率の周波数依存性を表すモデルとしては，絶縁体の場合，ローレンツモデルが知られている．このモデルは，外部からの電界を外力として復元力と抵抗を考慮したばねの振動モデルであり，

$$\epsilon(\omega) = \epsilon_0 + \sum_i \frac{Ne^2}{m_e(\omega_i - \omega^2 + j\omega\gamma_i)} f_i \quad (1.4)$$

で与えられる．ここで， i は異なる固有振動モードを表し， ω_i は固有振動角周波数， γ_i は固有振動の減衰定数， f_i は振動子強度， N は振動子の密度， m_e は電子の質量を

表す．金属の場合は復元力が働かないので $\omega_i = 0$ が加えられ，他のモードの影響が無視できるとすると

$$\epsilon(\omega) = \epsilon_0 - \frac{Ne^2}{m_e\omega(\omega^2 + j\gamma)} \quad (1.5)$$

となり，このモデルはドルーデモデルと呼ばれる．さらに，エネルギーの散逸がない，すなわち $\gamma = 0$ とすると

$$\epsilon(\omega) = \epsilon_0 \left(1 - \frac{\omega_p^2}{\omega^2}\right), \quad \omega_p^2 = \frac{Ne^2}{m_e\epsilon_0} \quad (1.6)$$

となり，これが無衝突のプラズマに相当する．

(1.4)-(1.6) 式はいずれも N に依存している． N は振動子の密度，あるいはプラズマの場合は電子の密度であり，これらは物質を構成する原子や分子の密度に依存する．したがって，電子密度あるいは原子や分子の密度が誘電率に影響を与え，(1.3) 式により屈折率もこれらの密度に依存することとなる．つまり，気体，液体，固体，さらにはプラズマも含めて，それらの物質の屈折率には原子，分子，あるいは電子の密度の情報が含まれており，これらの密度に依存する量，例えば気体の温度なども屈折率から得られる情報となる．言いかえると，屈折率から上に示したような量を間接的に求めることが可能である．例えば，火災周辺の非一様な温度分布や液体の濃度分布，あるいはプラズマの電子密度分布なども，屈折率の三次元計測を介して間接的に計測することができる．

任意の媒質の屈折率を直接計測することはできないが，屈折率の光路に沿った積分，すなわち，位相 ϕ

$$\phi(\mathbf{r}) = \int \mathbf{k}(\mathbf{r}) \cdot d\mathbf{r} = k_0 \cdot \int n(\mathbf{r}) d\mathbf{r} \quad (1.7)$$

を干渉計により計測することができる．厳密には，干渉計で計測できる積分情報は測定対象がある場合とない場合の位相の差であり，被積分関数も測定対象があ

る場合の屈折率 $n(\mathbf{r})$ とない場合の一様な屈折率 n_0 の差 $\Delta n(\mathbf{r}) = n(\mathbf{r}) - n_0$ となる。なお，単に位相差とすると二点間の位相の差と混同する可能性があるので，本論文では測定対象の有無による位相の差を位相変化と呼ぶこととする。

複数の入射方向からの光の経路に沿った積分情報が得られている場合に内部分布を求める方法は，既に医学の分野においてコンピュータトモグラフィー (CT) として応用されている。医学の分野では，減衰定数の線積分を透過光強度として観測しているが，減衰定数と透過光強度の組み合わせを屈折率と位相に置き換えれば，再構成のアルゴリズムは同じものを用いることができる。

三次元屈折率分布を計測する手法として，入射角可変のマッハツェンダー干渉計とCTを組み合わせたシステムが提案されている [1, 2, 3]。これは，測定対象を複数の方向から撮影した干渉画像から抽出されたそれぞれの位相変化量が対象の屈折率の撮影方向に関する積分量となっていることを利用し，それらを各方向からの投影画像とすることでCTの原理による対象の三次元屈折率分布の再構成を行うというものである。

しかし，このシステムにはハードウェアの制約から位相抽出処理に誤差が混入し，また，位相抽出処理のパラメータチューニングが必要なため，自動化の妨げとなっていた。本研究では，これらの問題を解決するために畳み込みニューラルネットワークを導入した。

次節以降では，まず三次元屈折率分布非破壊計測システムの原理，現在用いられている位相抽出法の原理について概説し，このシステムにおける干渉画像から位相抽出の際の課題について示す。その後，CTの概要，ならびに本研究で用いるニューラルネットワークを含めた機械学習の概要を示し，最後に本研究の目的と意義を示す。

1.2 三次元屈折率分布計測システムの原理

1.2.1 入射角可変マッハツェンダー干渉計による多角度からの干渉画像の撮影

干渉画像は，干渉計を用いることで撮影することができる．干渉計にはいくつかの種類があるが，ある時刻での測定対象の内部分布を計測するためには測定対象を動かすことなく複数方向からの情報を極力短い時間で取得する必要がある．このような撮影を実現するため，三次元屈折率分布計測システムでは光の入射方向を機械的に制御できるマッハツェンダー干渉計を用いている．図1.1に示す通り，常に干渉縞が生じる条件を満たすようにミラーの回転角とミラーが載っているステージの位置を機械的な制御により変化させ連続的に撮影を行うことで，複数方向からの干渉画像の測定を実現している．

1.2.2 干渉計測の原理

干渉計による測定は，干渉法の原理が用いられている．干渉法は，測定対象を透過した光(物体光)と透過していない光(参照光)の干渉によって得られる干渉画像を，光の強度分布として記録する方法である．本項では，計測システムで用いることを前提にマッハツェンダー干渉計を例に干渉計測の原理を説明する．

計測システムのマッハツェンダー干渉計ではまず，レーザー光を2枚の凸レンズによって拡大する．次にその光をハーフミラーによって2つに分け，一方を参照光とし，もう一方を測定対象に透過させ物体光とする．参照光，物体光の電界 $E_{\text{ref}}(r')$,

$E_{\text{obj}}(\mathbf{r}')$ はそれぞれ ,

$$\mathbf{E}_{\text{ref}}(\mathbf{r}') = |\mathbf{E}_0| e^{-j\mathbf{k}\cdot\mathbf{r}'} \quad (1.8)$$

$$\mathbf{E}_{\text{obj}}(\mathbf{r}') = |\mathbf{E}_0| e^{-j[(\mathbf{k}+\delta\mathbf{k})\cdot\mathbf{r}'+\phi(\mathbf{r}')] } \quad (1.9)$$

と表される . ここで , \mathbf{k} は参照光の波数ベクトル , j は虚数単位 , \mathbf{r}' は三次元座標

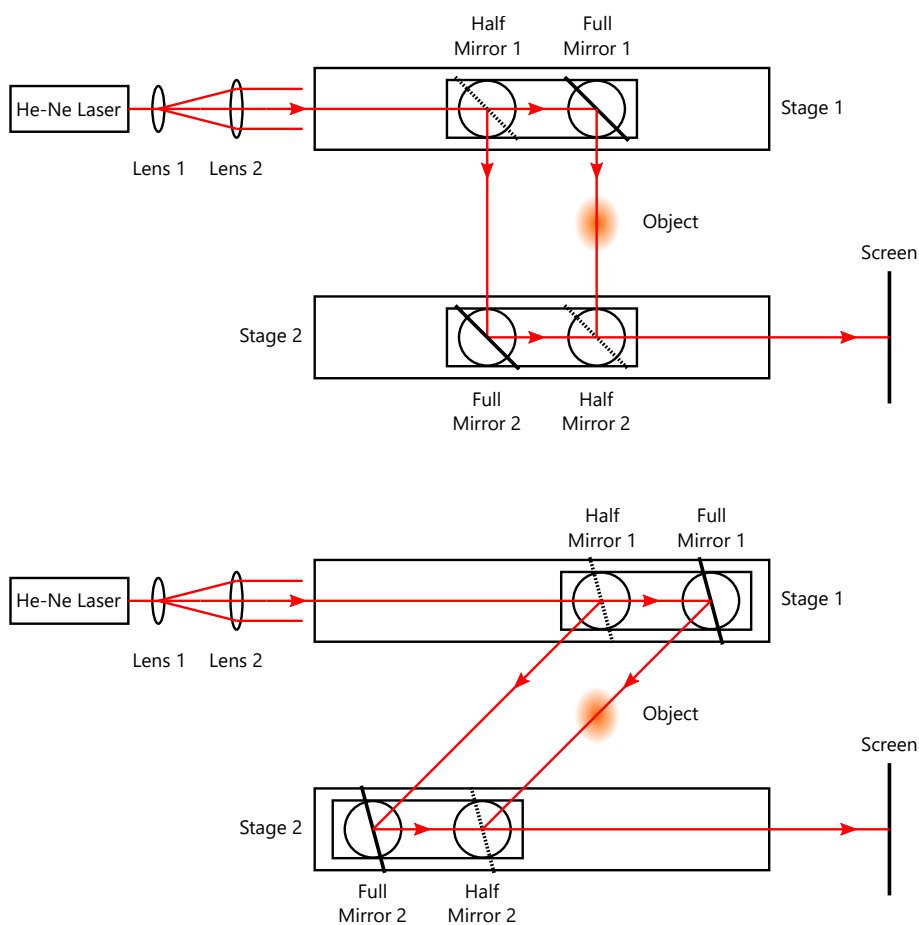


図 1.1: 入射角可変マッハツェンダー干渉計 . 4つのミラーの回転角とステージの位置を機械的に制御することにより , 複数方向からの干渉画像の連続撮影が可能 (上図と下図は異なる方向からの撮影) .

(x, y, z) , $\phi(\mathbf{r}')$ は物体光と参照光の位相差 (以降は位相変化量) を表している . このとき , 物体光の波数ベクトル $\mathbf{k} + \delta\mathbf{k}$ は参照光の波数ベクトル \mathbf{k} と大きさは等しいが方向をわずかにずらす必要がある . この2つの光を重ね合わせてスクリーンに投影し , 干渉画像を記録する . 記録される干渉画像の様子は光の強度分布 $i(\mathbf{r})$ として , 重ねられた電界の二乗で表される .

$$i(\mathbf{r}) = |\mathbf{E}_{\text{ref}}(\mathbf{r}) + \mathbf{E}_{\text{obj}}(\mathbf{r})|^2 \quad (1.10)$$

ここで , \mathbf{r} はスクリーン上の二次元座標 (x, y) である . 図1.2に示すような位相変化分布と任意の $\delta\mathbf{k}$ の値を (1.10) 式に代入して得られる干渉画像を図1.3に示す . 図1.3はシミュレーションデータなので図1.2に示す真の位相変化が分かっているが , 実際に測定する際に得られるのは干渉画像 $i(\mathbf{r})$ のみであり , 位相変化 $\phi(\mathbf{r})$ はこの $i(\mathbf{r})$ から抽出する必要がある . この図からわかるように , 干渉画像は周期的な縞模様 (背景フリンジ) が $\phi(\mathbf{r})$ により歪められた形として観測される . 1.2.3項で詳しく述べるが , 現在の位相抽出法を用いてこの $\phi(\mathbf{r})$ を求めるためには , 背景フリンジの周期を正しく検出する必要がある . 背景フリンジは $\delta\mathbf{k}$ から決まり , 以降ではこれをキャリア周波数と呼ぶ .

1.2.3 フーリエ変換法

屈折率の光路に沿った積分である位相変化を干渉画像から求めるための主な方法は , 位相シフト法 [4, 5, 6] とフーリエ変換を用いる方法 [7, 6, 8] に分類される . 位相シフト法は , 簡単な演算のみであるので広く用いられているが , 同一の測定対象に対して , 参照光に異なる 0 から 2π rad の間の既知の位相差を追加した複数 (3枚以上 , 一般には4枚) の干渉画像が必要となる . CT用にこのデータを取得するためには二つの方法が考えられる . 一つ目は , 投影方向を移動させた後に静止させ位

相差を変えながら計測し次の投影方向に移動する方法であり、他方は、ある位相差を与え投影方向を連続的に変更しながら干渉画像を計測し、その後に位相差を変更し、再び投影方向を連続的に変更しながら計測する方法である。投影方向の変更は機械的な制御により行っておりその精度は約 $10\mu\text{m}$ である一方、測定に用いるレーザー光の波長は約 $0.6\mu\text{m}$ であり、一度設定した投影方向と同じ状態を再現することは難しいため、後者の方法は不可能である。前者の方法では、位相差を変えている間は投影方向は固定されていなければならず、多くの方向からの計測が必要となるため、移動、停止の回数が増え計測時間がかなり長くなる。例えば、連続的に移動する場合は数秒から十数秒程度で済むが、一度停止させるとミラーの振動が止まるのを待つ必要があり、その都度各投影方向毎に数秒を要するため、一連の計測には数百秒を要する。したがって、CT用とした場合は位相シフト法は実現不可能である。

もう一方のフーリエ変換法は、やや処理が複雑となるが、一枚の干渉画像から位相を求めることができる。ただし、周波数空間でのフィルタリングが必要である。本節ではその原理を説明する。




図 1.2: 位相差の二次元分布 $\phi(\mathbf{r})$




図 1.3: 光の強度分布 $i(\mathbf{r})$

フーリエ変換法は，キャリアにより位相差が変調された干渉画像のフーリエ変換が，二つのキャリアと直流成分の三つのピークを構成することを利用してキャリア波を除去する方法である．フーリエ変換法の流れを以下に示す．

干渉法によって得られた光の強度分布を変形すると，以下のように表すことができる．

$$\begin{aligned}
 i(\mathbf{r}) &= |\mathbf{E}_{\text{ref}}(\mathbf{r}) + \mathbf{E}_{\text{obj}}(\mathbf{r})|^2 \\
 &= |\mathbf{E}_0|^2 + \mathbf{E}_{\text{ref}}(\mathbf{r}) \cdot \mathbf{E}_{\text{obj}}^*(\mathbf{r}) + \mathbf{E}_{\text{ref}}^*(\mathbf{r}) \cdot \mathbf{E}_{\text{obj}}(\mathbf{r}) + |\mathbf{E}_0|^2 \\
 &= 2|\mathbf{E}_0|^2 + |\mathbf{E}_0|^2 e^{+j[\delta\mathbf{k}_0 \cdot \mathbf{r} + \phi(\mathbf{r})]} + |\mathbf{E}_0|^2 e^{-j[\delta\mathbf{k}_0 \cdot \mathbf{r} + \phi(\mathbf{r})]} \\
 &= i_0(\mathbf{r}) [1 + \cos\{\phi(\mathbf{r}) + \delta\mathbf{k}_0 \cdot \mathbf{r}\}] \tag{1.11}
 \end{aligned}$$

$$= i_0(\mathbf{r}) + i_\phi(\mathbf{r}) \cdot e^{+j\delta\mathbf{k}_0 \cdot \mathbf{r}} + i_\phi^*(\mathbf{r}) \cdot e^{-j\delta\mathbf{k}_0 \cdot \mathbf{r}} \tag{1.12}$$

ここで， $|\mathbf{E}_{\text{ref}}(\mathbf{r})|^2 = |\mathbf{E}_{\text{obj}}(\mathbf{r})|^2 = |\mathbf{E}_0|^2$ ， $i_0(\mathbf{r}) = 2|\mathbf{E}_0|^2$ ， $i_\phi(\mathbf{r}) = \frac{i_0(\mathbf{r})}{2} e^{j\phi(\mathbf{r})}$ とし，記号*は複素共役を表している．

一方，位相変化 $\phi(\mathbf{r})$ は， \mathbf{r} の位置での屈折率を $n(\mathbf{r})$ ，光路 $d\xi$ 方向の単位ベクトルを \mathbf{e}_ξ とすると，

$$\phi(\mathbf{r}) = \int_{\xi} \mathbf{k}_0 \cdot \mathbf{e}_\xi n(\mathbf{r}) d\xi \tag{1.13}$$

のように得られる．

ここで，フーリエ変換を以下のように定義する．

$$F(\mathbf{k}) = \mathcal{F}[f(\mathbf{r})] = \int_{-\infty}^{\infty} f(\mathbf{r}) e^{-j\mathbf{k} \cdot \mathbf{r}} d\mathbf{r} \tag{1.14}$$

$$f(\mathbf{r}) = \mathcal{F}^{-1}[F(\mathbf{k})] = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\mathbf{k}) e^{+j\mathbf{k} \cdot \mathbf{r}} d\mathbf{k} \tag{1.15}$$

以下，周波数空間の関数は実空間での関数の文字の大文字を用いて表し， $\mathbf{k} = (k_x, k_y)$ を周波数空間座標とする．

$i(\mathbf{r})$ をフーリエ変換すると，図1.4のようなフーリエスペクトル $I(\mathbf{k})$ が得られる．これは原点について対称な分布で，

$$I(\mathbf{k}) = I_0(\mathbf{k}) + I_\phi(\mathbf{k} - \delta\mathbf{k}) + I_\phi^*(-\mathbf{k} - \delta\mathbf{k}) \quad (1.16)$$

と表される． $I_\phi(\mathbf{k} - \delta\mathbf{k})$ は $\mathcal{F}\{e^{j\phi}\}$ を周波数空間で $\delta\mathbf{k}$ だけシフトしたもので， $\mathbf{k} = \delta\mathbf{k}$ 付近にピークを持つ．また， $I_\phi(-\mathbf{k} - \delta\mathbf{k})$ も同様に $\mathbf{k} = -\delta\mathbf{k}$ 付近にピークを持つ．この $I(\mathbf{k})$ にフィルタをかけ，直流成分 $I_0(\mathbf{k})$ と，共役光成分 $I_\phi^*(-\mathbf{k} - \delta\mathbf{k})$ を除去した分布

$$I'(\mathbf{k}) = I_\phi(\mathbf{k} - \delta\mathbf{k}) \quad (1.17)$$

を得る．図1.5に $I'(\mathbf{k})$ を表した．これをフーリエ逆変換すると，

$$\begin{aligned} i'(\mathbf{r}) &= \mathcal{F}^{-1}[I'(\mathbf{k})] \\ &= \mathcal{F}^{-1}[I_\phi(\mathbf{k} - \delta\mathbf{k})] \\ &= \text{Re}[i_\phi(\mathbf{r})] + \text{Im}[i_\phi(\mathbf{r})] \end{aligned} \quad (1.18)$$

となるので，位相分布は，

$$\phi_w(\mathbf{r}) + \delta\mathbf{k} \cdot \mathbf{r} = \arctan \left(\frac{\text{Im}[i_\phi(\mathbf{r})]}{\text{Re}[i_\phi(\mathbf{r})]} \right) \quad (1.19)$$

と計算できる．両辺から $\delta\mathbf{k} \cdot \mathbf{r}$ を減ずる（キャリアシフト）ことにより，

$$\phi_w(\mathbf{r}) = \arctan \left(\frac{\text{Im}[i_\phi(\mathbf{r})]}{\text{Re}[i_\phi(\mathbf{r})]} \right) - \delta\mathbf{k} \cdot \mathbf{r} \quad (1.20)$$

と表すことができ，図1.6のように折り畳まれた位相分布 $\phi_w(\mathbf{r})$ が得られる． $I(\mathbf{k})$ から $I'(\mathbf{k})$ を求める際に用いるフィルタは複数考案されており，既存の抽出手法の例として，原点を通りキャリアピークを削らないような境界を計算によって求め，その片側にある共役光のみを取り除くハーフプレーンフィルタを採用している．




図 1.4: $i(\mathbf{r})$ のフーリエ変換 $I(\mathbf{k})$




図 1.5: $I(\mathbf{k})$ のフィルタリング後 $I'(\mathbf{k})$




図 1.6: $I'(\mathbf{k})$ のフーリエ逆変換 $\phi_w(\mathbf{r})$

1.2.4 位相アンラッピング

フーリエ変換法によって得られた位相変化 $\phi_w(\mathbf{r})$ は \arctan の値として得られるという数学的な制約から, $(-\pi, \pi]$ の範囲に折り畳まれている。しかし, 一般に位相変化の幅は 2π よりも広く, 値は連続的である。つまり, 本来連続的である位相変化が測定方法の限界によって不連続な値として測定されてしまっている。位相アンラッピング (Phase unwrapping) とは図 1.7 の 1 次元データの例に示すように, $(-\pi, \pi]$ の範囲に折り畳まれている位相変化 $\phi_w(\mathbf{r})$ を再接続し連続的な位相変化 $\phi_u(\mathbf{r})$ を得る過程のことであり, $\phi_w(\mathbf{r}), \phi_u(\mathbf{r})$ をそれぞれ Wrapped phase, Unwrapped phase という。図 1.6 の Wrapped phase を位相連結した Unwrapped phase を図 1.8 に示す。

位相変化の空間分布はスカラー関数であるので, ある点と別の点の位相差は, 二点間の任意の経路を沿った位相差を積分すれば求められる。積分の始点と終点が一致する場合はこの位相差は 0 にならなければならない。しかし, 二次元の位相アンラッピングの場合, 離散的なサンプリングであるため隣接二点間の位相差には 2π の整数倍の位相のジャンプが含まれる。この位相のジャンプが存在すると, 隣接二点間の位相差の大きさが π 以下であると仮定して始点から左, 上, 右, 下と一画素毎に移動して始点に戻って来る経路の位相差の和を求めてしまうと, 位相差の和が 0 にはならない。この 4 点の中心 (4 画素の共有点) を特異点と言う。また, 4 点の場合は特異点を含む経路の位相差は $\pm 2\pi$ となる。

この特異点の除去を目的として, さまざまな二次元位相アンラッピングアルゴリズムが提案されている。一つの方法は, path-following 法 [9, 10, 11, 12, 13, 14, 15] と称される方法で, 正負の位相差を持つ異なる特異点の間にカットと称される線を引き, そのカットを跨ぐピクセル間に 2π の位相を加える。このとき, カットをどのように入れるかがアンラッピング結果に大きな影響を与える。もう一つの方法は, 最小自乗法に基づく方法 [16, 17, 18, 19, 20, 21, 22] であり, アンラッピング結果をラップ

($\pm\pi$ の範囲になるよう 2π の整数倍を減算)し, それと元のアンラップ前の位相の残差を最小化する方法である. これらの結果は, 特異点の寄与を全画素に広げることになる.

特異点の寄与を可能なかぎり特異点近傍に閉じ込める方法として, 特異性拡散法 [23] が提案され, 類似な方法として, 特異性を全空間でポアソン方程式により解く方法 [24, 25], さらに, 特異になる空間を限定してポアソン方程式を解く方法 [26] が提案されている.

これらの方法のいくつかの性能評価の比較 [27] から, 本計測システムでは, Tomioka 等による特異性を局在化させた位相補償法 [26] を用いている.

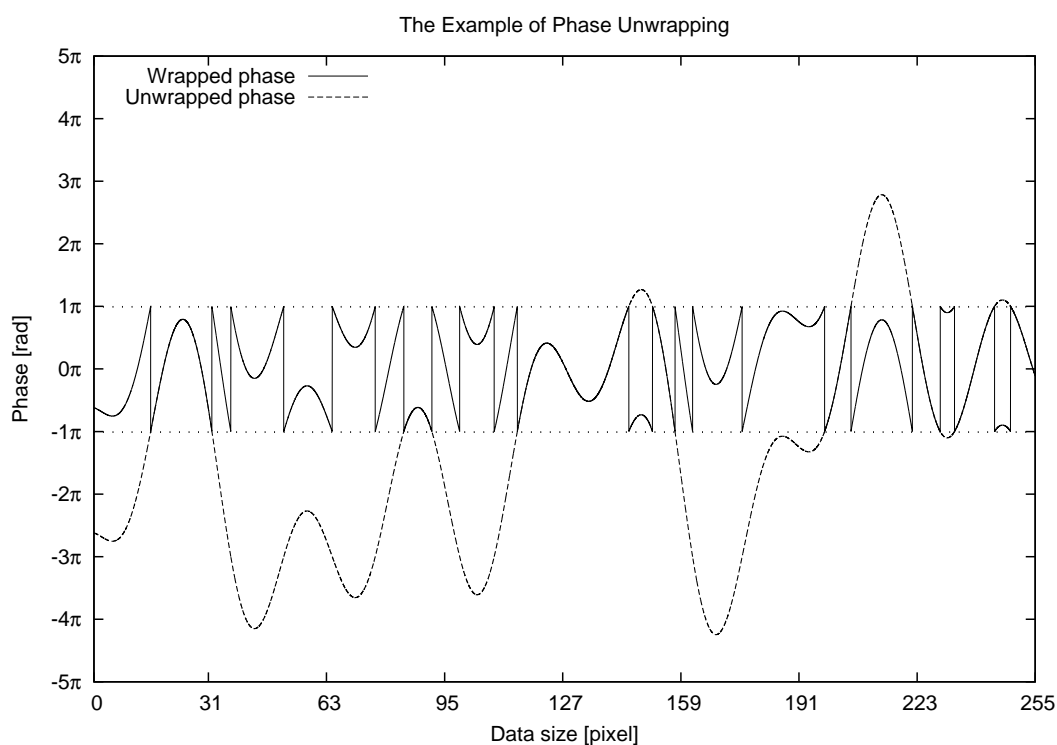


図 1.7: Wrapped phase と Unwrapped phase




図 1.8: $\phi_w(\mathbf{r})$ の位相アンラッピング後の位相 $\phi_u(\mathbf{r})$

1.2.5 コンピュータトモグラフィ (CT) の原理

計測システムでは、抽出した位相変化の二次元分布から、コンピュータトモグラフィ (CT) の原理を用いて三次元再構成する。CTは、非破壊、非接触に物体の三次元分布を計測できる技術である。物体にX線などのビームを照射すると、透過する際にビームが減衰するため、その減衰率を二次元画像として測定することができる。ビームの入射方向を変え全方向の測定データを取得し、それらの画像から三次元再構成をすることにより物体の三次元分布が得られる。

測定対象に対して固定した座標系を x - y 座標系、そこから θ だけ傾けた座標系を X - Y 座標系とする。座標 (x, y) における測定対象の吸収係数分布を $\mu(x, y)$ とし、またそれぞれの座標系の関係は

$$\begin{cases} x = X \cos \theta - Y \sin \theta \\ y = X \sin \theta + Y \cos \theta \end{cases} \quad (1.21)$$

と表すことができる。対象の物体に強度が I_0 であるビームを入射すると、出力として

$$I(X, \theta; y) = I_0 e^{-\int_{-\infty}^{\infty} \mu(x, z; y) dZ} \quad (1.22)$$

で表される強度のビームが得られる。この式の両辺を I_0 で割って自然対数をとると、

$$g(X, \theta; y) = -\ln \left\{ \frac{I(X, \theta; y)}{I_0} \right\} \quad (1.23)$$

$$= \int_{-\infty}^{\infty} \mu(x, z; y) dZ \quad (1.24)$$

と表すことができる。二次元投影分布である $g(X, \theta; y)$ を、 θ の値を変え多方向から取得することにより、物体の三次元分布を求めることができる。

1.2.6 光位相CT

プラズマや気体などの媒質はX線を透過させてもほとんど減衰しないため，上記のCTのような測定を行うことはできない．そこで，X線の代わりに波長の長い可視光を利用することで屈折率の積分量である位相変化量の二次元分布を測定し，CTと同様の原理で再構成することで物体の三次元分布の測定を行う．この手法を光位相CTと称する．

1.3 計測システムとその課題

「ディープラーニング」¹提案されている計測システムでは短時間で複数方向からの干渉画像を撮影するために干渉体系のミラーを機械制御により移動・回転させながら撮影を行うが，これにより干渉画像のキャリア（搬送波）の周波数 δk を制御することができないこと，ならびに機械の振動に起因する干渉画像のぶれを抑えるためにカメラのシャッタースピードを速くしゲインを上げることに伴い干渉画像に振幅ノイズが多く含まれること，という2つの問題点が発生する．これらの問題点により，入射角可変マッハツェンダー干渉計により撮影された干渉画像の多くは悪条件の画像となり，キャリア成分を含んだ干渉画像の位相変化量抽出に通常用いられるフーリエ変換法と位相アンラッピングの組み合わせという既存のルールベース手法では位相抽出を行うことができない場合も少なくない．シミュレーションによって生成した良条件・悪条件それぞれの干渉画像からの既存の手法による位相抽出の結果を図1.9に示す．このことは悪条件となった入射方向の屈折率の積分量情報が得られないことを意味し，三次元再構成の精度低下の原因となってしまう．計測システムでは時間変化する物体の内部分布を短時間で計測したいという要求があるため，干渉体系の改善は困難である．現在この計測システムを利用する際は，

本来自動で行われるべき位相抽出の際に用いられる様々なパラメータを手動で調整することで悪条件の干渉画像からの位相抽出の質を補い、またその結果を目視で確認し利用の可否を人間が判断することによって三次元再構成を行っているが、この作業には多大な労力を要する。したがって、この計測システムには上記の悪条件の干渉画像から位相抽出を高精度に、かつ人間の判断を介さず自動的に処理を行うことができる新たな抽出手法が求められている。

1.4 機械学習

現在、様々な分野で「人工知能」や「機械学習」、「深層学習」といった言葉が取り沙汰されている。これらの概念の関係を図1.10に示す。人工知能とは広範囲を指す言葉で、人間の知的なふるまいの一部をコンピュータソフトウェアを用いて人工的に再現したものであり、あらかじめ条件を並べておきそれに基づいて分類などの処理を行うルールベースアルゴリズムも人工知能の一種である。それに対し「機械学習」とは、「データを用いて繰り返し学習し、何らかのパターンを見つけるこ




図 1.9: フーリエ変換法による各条件の干渉画像からの抽出例。上段は良条件（抽出成功）、下段は悪条件（抽出失敗）の例を示している。

と」と言え、ルールを人間が記述するのではなくコンピュータがデータから自動的に獲得する点が特徴である。深層学習とは、主に機械学習の手法のひとつであるニューラルネットワークの層を深くしたモデルによる学習を指しており、このことにより人間の脳のような複雑な構造を模擬し、ネットワークが高い表現力を得ることが可能となる。本研究で用いる畳み込みニューラルネットワークは必然的に層の数が多くなるため、この深層学習の一種であるといえる。近年、コンピュータの性能の向上によって以前は事実上不可能であった大量のデータによる深いネットワークの学習が可能となっており、今までルールベース手法では解決できなかった問題が深層学習により解決する可能性も高まっている。

そこで本節では、畳み込みニューラルネットワークを用いた干渉画像からの位相変化量抽出を行う第2章への導入として、畳み込みニューラルネットワークの理解に必要な事柄の解説を行う。

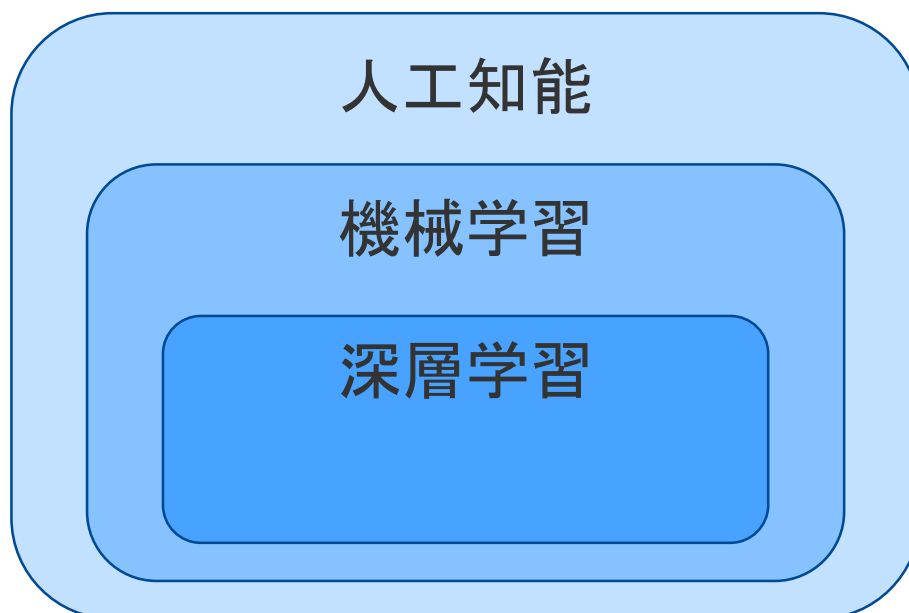


図 1.10: 人工知能，機械学習，深層学習の関係。

1.4.1 教師あり学習

教師あり学習とは，ニューラルネットワークの学習にも用いられる機械学習の代表的な学習手法のひとつである．教師あり学習では，はじめに入力データ x とそれに対応する正解データ t の組にした学習データ (x, t) を大量に用意する．次に x を機械学習モデル $f(\cdot)$ に与えて得られる出力 $y = f(x)$ と t を比較し，その誤差をもとに $f(\cdot)$ の持つパラメータを更新する．この誤差が十分小さくなるまで入出力とパラメータ更新を反復するのが教師あり学習の基本原理である．最終的に，学習を終えたモデルに学習に用いていない未知のデータを入力し適切な出力が得られているかどうかを検証する．

勾配降下法

ニューラルネットワークは，パラメータ θ により特徴づけられた損失関数 $L(\theta)$ を定義し，その値を最小にするパラメータを求める最適化を行うことにより学習を行う．この最適化には，勾配降下法を利用することが多い．勾配降下法は，現在のパラメータ $\theta^{(t)}$ における勾配 $\nu = \frac{\partial L(\theta)}{\partial \theta} \Big|_{\theta=\theta^{(t)}}$ を求め，

$$\theta^{(t+1)} \leftarrow \theta^{(t)} - \tau \nu \quad (1.25)$$

に基づいて更新を行う．ただし $\tau > 0$ は学習率である．学習率は何らかの規則により決定されるか，様々に提案されている手法に従って適応的に調整される．

誤差逆伝播法

ある入力 x に依存して y が決まり，ベクトル y に基づいて z が決まるとすると，これらの関係は

$$\mathbf{y} = g(x), z = f(\mathbf{y}) \quad (1.26)$$

と表される。この時、微分の連鎖律により $\frac{\partial z}{\partial x} = \sum_i \frac{\partial z}{\partial y_i} \frac{\partial y_i}{\partial x}$ であり、 x を小さく変化させた場合の各 y_i の変化量は $\Delta y_i = \frac{\partial y_i}{\partial x} \Delta x$ 、 z の変化量は $\sum_i \frac{\partial z}{\partial y_i} \frac{\partial y_i}{\partial x} \Delta x$ と表される。この関係を利用し、入力から各層のパラメータを用いて出力を計算した順とは逆順に、出力と正解により計算される損失関数から各パラメータの勾配を順に求めるのが誤差逆伝播法である。畳み込みニューラルネットワークを含めた深いネットワークのパラメータの誤差に対する重みをそれぞれ直接計算するのは計算量が多くなってしまいが、以上のような誤差逆伝播法を利用することで効率的に求めることができる。

1.4.2 畳み込みニューラルネットワーク

本節では、畳み込みニューラルネットワークの説明を行う。それに先立ち、はじめにニューラルネットワークの起源であり最小単位ともいえるパーセプトロン、次にニューラルネットワークについて述べ、その後畳み込みニューラルネットワークについて説明する。

パーセプトロン

パーセプトロンは、複数の信号を入力として受け取りひとつの信号を出力するモデルである。はじめに最も簡単な例として、2入力、つまり二次元データ $\mathbf{x} = (x_1, x_2)$ を0または1の2値に分類する問題を解くような、入力層と出力層のみからなるパーセプトロンを考える。

パーセプトロンの出力は1か0の2値である。 x_1, x_2 を入力信号、 w_1, w_2 を入力信号に対応する重みとすると、それらの総和がある閾値 θ を超えたときは1、そうで

ない時は0を出力するパーセプトロンは，

$$y = \begin{cases} 0, & w_1x_1 + w_2x_2 \leq \theta \\ 1, & w_1x_1 + w_2x_2 > \theta \end{cases} \quad (1.27)$$

と表すことができる．このように，パーセプトロンは各入力に対して固有の重みを持っており，その大小によって入力の重要度が決定する．図1.11に2入力のパーセプトロンの概念図を示す．ここで， $b = -\theta$ で表されるバイアス b を導入し，(1.27)式を

$$y = \begin{cases} 0, & b + w_1x_1 + w_2x_2 \leq 0 \\ 1, & b + w_1x_1 + w_2x_2 > 0 \end{cases} \quad (1.28)$$

のように変形する．(1.28)式からわかる通り，1層のパーセプトロンでは入力に対して線形な分類しかできない．

次に，新たに中間層 s を追加した，2層のパーセプトロンについて考える．図1.12に2層のパーセプトロンの例を示す．ここで，入力を第0層，中間層を第1層，出力層を第2層と呼び，要素数 J の第 i 層の j 番目の値を $s_j^{(i)}$ ， $s_j^{(i-1)}$ の $s_k^{(i)}$ に対する重みを $w_{kj}^{(i-1)}$ ，バイアスを $b^{(i-1)}$ とすると， $s_k^{(0)} = x_k$ ， $s_k^{(2)} = y_k$ で表され(ただし1出力なので




図 1.11: 2入力のパーセプトロン．

y の添え字は省略する), 中間層または出力層の値は,

$$s_k^{(i)} = \begin{cases} 0, & b^{(i-1)} + \sum_{j=1}^J w_{kj}^{(i-1)} s_j^{(i-1)} \leq 0 \\ 1, & b^{(i-1)} + \sum_{j=1}^J w_{kj}^{(i-1)} s_j^{(i-1)} > 0 \end{cases} \quad (1.29)$$

と表すことができる. 詳細な説明は省略するが, このように層を増やすことにより, 単層のパーセプトロンでは不可能であった非線形な分類が可能となる.

ニューラルネットワーク

ニューラルネットワークは, パーセプトロンと共通する点が多い. 例として, 図 1.13 のような 2 入力 2 出力, 中間層の個数が 3 個の 2 層ニューラルネットワークを考える. ニューラルネットの各要素の接続方法はパーセプトロンと同様であるが, 信号の伝達方法が異なる. パーセプトロンでは (1.29) 式のように入力に対する出力はバイアスと重みによって 0 か 1 にコントロールされる. ここで, (1.29) 式を

$$s_k^{(i)} = h \left(b^{(i-1)} + \sum_{j=1}^J w_{kj}^{(i-1)} s_j^{(i-1)} \right) \quad (1.30)$$




図 1.12: 2 入力で中間層の個数が 2 である 2 層のパーセプトロン.




図 1.13: 2入力2出力，中間層の要素数が3の2層ニューラルネットワークの例。

$$h(x) = \begin{cases} 0, & x \leq 0 \\ 1, & x > 0 \end{cases} \quad (1.31)$$

と書き換えると, $s_k^{(i)}$ は入力の総和が $h(x)$ という関数によって変換されたものに見えることができる。このような, 入力信号の和を出力信号に変換する関数を活性化関数と呼ぶ。パーセプトロンの活性化関数は (1.31) 式のようなステップ関数であったが, ニューラルネットワークではシグモイド関数

$$h(x) = \frac{1}{1 + \exp(-x)} \quad (1.32)$$

や, ReLU 関数

$$h(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (1.33)$$

のような, 入力に対して出力が連続的に変化する, つまり微分が定義できる関数を用いることで, 後述する勾配法による学習を可能としている。また, 活性化関数に非線形関数を用いることで, 層の深いネットワークはより高い表現力を得ることができる。

畳み込みニューラルネットワーク

これまでに説明したニューラルネットワークは, 隣接する層のすべてのニューロン間で結合が存在していた。これを全結合層という。それに対し, 「畳み込み層」が存在するニューラルネットワークを畳み込みニューラルネットワークと呼ぶ。いま, 入力が二次元データであるネットワークを考える。入力層が全結合層だった場合, 二次元画像の画素データを一次元に変形して入力する必要があるが, 全ての画素を同等のニューロンとして扱うため, 画素間の距離に関する情報は失われてし

まう。これに対し，畳み込み層は図 1.14 のように二次元画像の入力に対してネットワークの重みパラメータに相当する二次元のカーネルを用いて畳み込み演算を行い，二次元画像を出力する。これにより，画像中の形状に関する情報を利用することができる。畳み込み層では，入出力データを特徴マップと呼ぶ。

畳み込みニューラルネットワークでは，プーリング層と呼ばれる層がよく用いられる。プーリングとは，縦・横方向の空間を小さくする演算である。図 1.15 は Max プーリングと呼ばれ，例では 2×2 の領域の最大値を取り出すことで領域の縦・横のサイズを $1/2$ にする演算の例である。プーリング層は微小な位置変化に対してロバストであり，画像の重要な特徴を残しつつデータサイズを小さくすることで，計算量を小さくする効果がある。

畳み込みニューラルネットワークは，全結合層よりも重みの自由度が小さい畳み込み層とデータサイズを小さくするプーリング層を導入することで，データ次元数が必然的に多くなってしまいう画像処理の分野でのニューラルネットワークの学習を容易にしている。




図 1.14: 畳み込み演算の例。

1.4.3 機械学習についてのまとめ

本節では、本研究において干渉画像の位相変化量抽出に利用する畳み込みニューラルネットワークについて、学習手法とネットワークの仕組みについて説明した。

1.5 本研究の目的と意義

本研究の目的は、干渉画像の位相抽出を高精度化・かつ自動化させることによる三次元屈折率分布計測の高精度化である。この目的のため、本研究ではこれまでフーリエ変換法と位相アンラッピングの組み合わせというルールベース手法で行われていた干渉画像からの位相抽出について、機械学習モデルのひとつである畳み込みニューラルネットワークを用いる手法を提案する。1.2.2項で述べた通り、干渉計測において得られる干渉画像の光の強度分布は、参照光と物体光の位相差によって決まるキャリア周波数を持つ余弦関数としてあらわれ、測定対象による物体光の位相変化は、その余弦関数の位相変調として観測される。このように干渉現象はモデル化されているので、位相変化の分布を用意し任意のキャリア周波数を与えることでその位相変化に応じて変調した干渉画像のシミュレーションデータを生成することができる。この干渉画像と元の位相変化像の組を大量に生成し、機械学習の学習手法のひとつである「教師あり学習」により入力干渉画像、出力が位




図 1.15: プーリング演算の例。

相変化像となるような入出力関係をネットワークに学習させることで，未知の干渉画像を入力すると対応する適切な位相変化像が出力されるネットワークを生成できると考えた．

計測システムで頻繁に発生し，その入射方向からの位相変化量情報の欠損を引き起こしていた悪条件の干渉画像からの位相抽出を既存のルールベース手法よりも高精度かつパラメータ調整なしに行うことができるネットワークを生成することができれば，再構成に利用できる画像の割合が増加，つまりより多くの入射方向の情報を生じた再構成が可能となり，屈折率三次元再構成の自動化と精度の向上が期待できる．

1.6 本論文の構成

本論文は以下の5つの章で構成されている．

第1章では前節までに述べた通り，物体の三次元屈折率分布計測の概要について，提案されている計測システムの原理を，干渉画像の撮影，干渉画像の位相変化量抽出，三次元再構成の過程に分けて説明し，三次元屈折率分布の応用例について述べた．次に本システムが抱えている課題について説明し，その解決のために畳み込みニューラルネットワークの導入を提案し，本研究の目的と意義について述べた．

第2章では，畳み込みニューラルネットワークを用いた干渉画像からの位相抽出手法について具体的に述べる．ネットワーク構成，教師あり学習に用いた正解データとしての位相変化像および入力データとしての干渉画像の作成方法について述べ，それらの学習データによる学習を行ったネットワークに未知のシミュレーションデータおよび実測データを入力して得られる出力結果について，既存の位相抽出手法として用いられているフーリエ変換法と位相アンラッピングの組み合わせで

あるルールベース手法による抽出結果と比較し、その性能を評価する。また、ネットワーク構成において手動で決定されるハイパーパラメータを変化させることにより得られるネットワークの性能を評価する。

第3章では、第2章の結果を受け、学習データの改善を行う。より適切と思われる学習データの作成方法を考案し、実際にその方法で作成した学習データによって学習を行ったネットワークの性能を第2章のものと比較する。

第4章では、計測システムで用いられている、限られた範囲の角度からしか干渉画像を撮影できない際に行う重みつき屈折率三次元再構成の手法について説明し、第3章で得られた位相抽出結果に対して重みパラメータを決定する方法を提案する。最後に本研究によって得られた位相変化像と重みを用いた三次元再構成の結果を示し、既存の手法による再構成結果と比較しその精度や利便性について本研究の成果の優位性を示す。

第5章では、各章のまとめと本研究の結論について述べる。

第2章 畳み込みニューラルネットワーク を利用した位相抽出

2.1 はじめに

本章では，第1章で説明した畳み込みニューラルネットワークを利用した干渉画像の位相抽出が可能か否かを検討する．シミュレーションにより生成した位相変化像と干渉画像を用いてネットワークの学習を行い，そのネットワークによってシミュレーションと実測の干渉画像の位相抽出を行い，抽出性能を既存のルールベース手法の性能と比較し評価する．

2.2 ネットワーク構成

ネットワーク構成は，1.4.2項で説明した「畳み込みニューラルネットワーク」の一種であり，特にコンピュータビジョンの分野で良く用いられ成果を挙げている”U-net”[28]と呼ばれる構成を用いた．U-netのネットワーク構成を図2.1に示す．U-netとは，医用画像のセグメンテーション（画像中の画素ごとにクラス分類を行う問題）用に考案された，全結合層がない全層畳み込みネットワーク(FCN)の一種である．その特徴として，ネットワークの前半（低層部）では畳み込み層とプーリング層を重ねて出力特徴マップを小さくしていくことで徐々に大域的な特徴を抽出し，後半（高層部）では入力特徴マップの周囲や画素間を空白で埋めたものに対して畳み込

みを行う逆畳み込み（転置畳み込み）層によって出力特徴マップを大きくしていくことで解像度を上げていく構成になっていることと、低層部の特徴マップを対応する高層部で再利用する連結パスが存在する点が挙げられる。これらの特徴により、局所的な特徴を保持している低層の特徴マップを大域的な特徴を保持している高層の特徴マップと合わせて利用することができ、従来のFCNの欠点であるセグメンテーションの境界に粗さが生じるという問題を解決している。本研究で行う干渉画像からの位相抽出は、画素ごとの回帰問題でありセグメンテーションとは異なるが、大域的特徴量であるバックグラウンド $\delta k \cdot r$ の情報と局所的特徴量である位相変化 $\phi(r)$ の情報を正確に捉えることが必要であり、そのためにU-netのネットワーク構造は有用であると考え、また、U-netを回帰問題に利用した例[42]も存在するため、U-netのネットワーク構成を位相抽出ネットワークとして採用した。

2.2.1 オリジナルのU-netと位相抽出ネットワークの差異

本研究で用いる位相抽出ネットワークはU-netのネットワーク構成を利用しているが、原著のU-netと一部の構成やパラメータが異なっている。図2.2に、本研究で用いる位相抽出ネットワークの構成を示す。また、表2.1にU-netの原著に示されているネットワーク構成からの変更点を示す。

原著のU-netは分類問題を対象としているため出力層のチャンネル数は分類ラベル数であり、活性化関数はソフトマックス関数と呼ばれる、入力が各ラベルへ分類される確率を示す関数である。一方本研究の位相抽出ネットワークは回帰問題を対象としているため出力チャンネル数を1、活性化関数を恒等関数とし得られる出力値を $\phi_{\text{out}}(r)$ としている。

また、ハイパーパラメータと呼ばれる、学習の前に手動で決定するいくつかのパラメータについて、中間層の特徴マップのチャンネル数、畳み込み層のカーネル

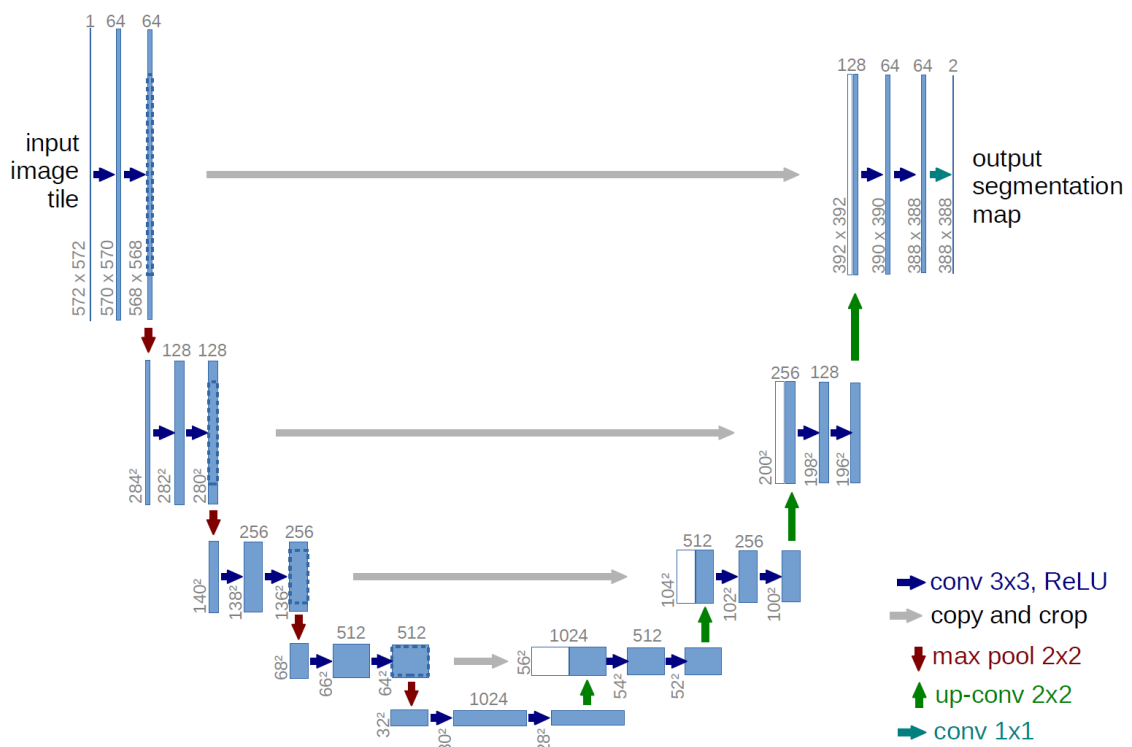


図 2.1: U-net のネットワーク構成 ([28] より引用) .

サイズの変更を行っている。チャンネル数とは、特徴マップがいくつの二次元データにより構成されているのかを表す値で、例として本研究の入力画像はグレースケール、つまり保持している情報は光の明暗のみなので、チャンネル数は1である。畳み込み層では入力に対して複数のカーネルを用意することで、異なる特徴が現れる特徴マップを獲得することができる。原著の特徴マップは入力側から順に1, 64, 64, 128, ... となっているが、本研究では計算量を抑えるため1, 32, 32, 64, ... としている。また、畳み込み層のカーネルサイズは原著では (3×3) となっているが、本研究のネットワークでは (5×5) とした。これらのハイパーパラメータの妥当性については2.5.1項で述べる。

また、原著のネットワークで行われている前半部から後半部へ受け渡される特徴マップのサイズ調整を不要とするため、本位相抽出ネットワークでは前半部の畳み込み層でパディングを行っている。パディングとは入力画像の周囲を0などの値で埋めてサイズを調整することをいい、この処理を行うことで畳み込み演算によって出力サイズが入力サイズより小さくなることを防いでいる。また過学習の防止、学習の進行速度の上昇、重みの初期値に対するロバスト性の獲得などの効果が得られるため、オリジナルでは採用されていないBatch Normalization[29]をそれぞれ各畳み込み層の後に追加した。




図 2.2: 位相抽出ネットワークの構成 .

表 2.1: 原著の U-net と本研究の位相抽出ネットワークの比較

	原著のネットワーク	本研究で用いたネットワーク
対象としている問題	分類	回帰
畳み込みカーネルサイズ k	(3×3)	(5×5)
特徴マップのチャンネル数	1, 64, 64, 128, ...	1, 32, 32, 64, ...
パディング	なし	あり
Batch Normalization の有無	なし	あり

2.3 学習条件およびその他のハイパーパラメータ

位相抽出ネットワークの学習方法として、1.4.1項で説明した「教師あり学習」を用いた。「入力データ」を干渉画像 $i(\mathbf{r})$ 、「正解データ」を位相変化像 $\phi_{\text{true}}(\mathbf{r})$ とする教師あり学習によって、ネットワークの学習を行った。 $i(\mathbf{r})$ 、 $\phi_{\text{true}}(\mathbf{r})$ は共に画像で、画素ごとに実数値を持つ。学習時の損失関数 E は、位相抽出ネットワークによって出力された位相変化像を $\phi_{\text{out}}(\mathbf{r})$ とすると、

$$E = \left\langle \sqrt{\left\langle \{\phi_{\text{out}}(\mathbf{r}) - \phi_{\text{true}}(\mathbf{r})\}^2 \right\rangle_{\text{pixel}}} \right\rangle_{\text{batch}} \quad (2.1)$$

で表される「画素ごとの平均二乗誤差平方根 (Route mean squared error; RMSE) のバッチサイズの画像ごとの平均」とした。

ネットワークの最適化手法には、多くの問題設定で最適な収束性能を達成している Adam[30] を用いた。Adam の中で設定するパラメータは全て原著の推奨値を用いた。

ニューラルネットワークは大規模な並列計算を行うため、本研究には nVIDIA 製の GPU である「NVIDIA GeForce RTX 2080 Ti」を用いた。また、学習及び推論のプログラムの作成には Python ベースのディープラーニング向けのフレームワークである「Chainer」を利用した。

その他のハイパーパラメータについて、「一度にネットワークへの入力、損失関数の計算を行うデータ数」を意味するバッチサイズを 10、「学習データセットに含まれるデータを全て 1 回ずつ学習に用いたこと」を意味するエポック数は 100、学習データセットと検証データセットに含まれる干渉画像と位相変化像からなるデータ組数はともに 10000 とした。

2.4 シミュレーションによる学習データ生成

本章では，シミュレーションにより生成した位相変化像と干渉画像を学習データとしてネットワークの学習を行う．本節では，データの作成方法およびそれらのデータを用いた学習により得られたネットワークの性能について述べる．

ニューラルネットワークの学習には一般に大量の学習データが必要である．未知の位相変化と様々なキャリア周波数を持つ干渉画像に対して高い抽出性能を持つ汎用的なモデルを獲得するためには，形状や変化量について様々なバリエーションを持つ位相変化像と，その位相変化を持ちかつ様々なキャリア周波数を持つ干渉画像の組を大量に用意する必要がある．まず干渉画像の生成について，ある正解データである位相変化像に対して，その位相変化を持ち任意のキャリア周波数を持つ干渉画像をシミュレーションにより生成することは可能である．つまり，位相変化が既知であり，かつ1.3節で示したようなルールベース手法による位相抽出が困難な悪条件の干渉画像もシミュレーションによって生成することができる．このような干渉画像を学習データに含むことで，悪条件の干渉画像からの位相抽出を可能とするネットワークの獲得を目指す．また，位相変化像の生成について，良条件の干渉計測を様々な位相変化を持つ測定対象に対して行いその抽出結果を正解データとする方法も考えられるが，十分なバリエーションの位相変化像のデータを実測によって得ることは非常に困難である．

したがって，位相変化像，干渉画像はともにコンピュータシミュレーションによって生成することを考える．本節では，シミュレーションによる位相変化像の生成方法，それを用いた干渉画像の生成方法について説明する．

2.4.1 正解データ：位相変化像の作成

干渉画像からの位相抽出という目的に沿ったシミュレーション学習データを生成するため、火炎による位相変化像の形状を確認する。図2.3にルールベース手法による位相抽出が可能である良条件の下で撮影したろうそくの火炎の干渉画像と、その画像からルールベース手法によって抽出した位相変化像を示す。図2.3を見る限り、火炎の位相変化量は中心をピークとして滑らかに小さくなっていくと考えられる。また、形状についてはほぼ軸対称であり、揺らぎにより傾く場合もある。以上の観察結果から、火炎による位相変化分布を図2.4に示すような二次元ガウス分布によって代用する。また、位相変化は屈折率の撮影方向に関する積分量である



図 2.3: 干渉画像と位相変化像の例（位相変化像の等高線は 2π [rad]ごと）。




図 2.4: 2次元ガウス分布により1つの火炎を模擬した位相変化像の例（位相変化像の等高線は 2π [rad]ごと）。

ため，撮影方向に火炎が複数並んでいる時の位相変化はそれぞれの炎による位相変化の足し合わせで表すことができる．以上の条件をまとめると，画像中の位置・幅・最大値・傾きの異なる二次元ガウス分布を複数足し合わせることで，多様な位相変化像のシミュレーションデータを生成できると考えられる．

上記の考察を踏まえ，位相変化像のシミュレーションデータ $\phi_{\text{true}}(\mathbf{r})$ を，

$$\phi_{\text{true}}(\mathbf{r}) = \sum_{m=0}^2 \phi_{m_{\text{max}}} \text{gauss}(\mathbf{r}; \mathbf{c}_m, \theta_m, a_m, b_m) \quad (2.2)$$

に従ってランダムに生成した．ここで，

$$\text{gauss}(\mathbf{r}; \mathbf{c}, \theta, a, b) = e^{-(\mathbf{r}-\mathbf{c})^T \mathbf{R}^T(\theta) \mathbf{W}^{-2}(a,b) \mathbf{R}(\theta)(\mathbf{r}-\mathbf{c})}, \quad (2.3)$$

$$\mathbf{R}(\theta) = \begin{pmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{pmatrix}, \quad \mathbf{W}^{-2}(a, b) = \begin{pmatrix} 1/a^2 & 0 \\ 0 & 1/b^2 \end{pmatrix} \quad (2.4)$$

である．表 2.2 に各パラメータの説明とそれらのパラメータが取り得るランダム値の範囲を示す．パラメータの範囲は，シミュレーションデータが実測データに近いものとなるよう経験的に決定している．また，(2.2) 式によって生成される $\phi_{\text{true}}(\mathbf{r})$ の例を図 3.9 に示す．

表 2.2: シミュレーションデータ生成に用いる二次元ガウス分布のランダムパラメータ

パラメータ		取り得る範囲
ϕ_{max}	最大値	$1.5 \cdot 2\pi \leq \phi_{\text{max}} < 3.0 \cdot 2\pi$ [rad]
\mathbf{c}	中心座標	$(\frac{1}{4}N_x, \frac{1}{2}N_y) \leq \mathbf{c} < (\frac{3}{4}N_x, N_y)$ [pixel]
θ	y 軸に対する傾き	$-15 \leq \theta < 15$ [°]
(a, b)	(x, y) 方向の幅	$(\frac{1}{16}N_x, \frac{1}{2}N_y) \leq (a, b) < (\frac{1}{4}N_x, N_y)$ [pixel]

2.4.2 入力データ：干渉画像の作成

1.3節で示した通り，位相変化像が $\phi(\mathbf{r})$ である時の干渉画像 $i(\mathbf{r})$ は

$$i(\mathbf{r}) = i_0(\mathbf{r}) [1 + \cos \{\phi(\mathbf{r}) + \delta \mathbf{k} \cdot \mathbf{r}\}] \quad (2.5)$$

とモデル化されている．ただし実際の測定では，撮影機器に由来する干渉画像の振幅ノイズ $i_{\text{noise}}(\mathbf{r})$ が生じる．これを考慮し，干渉画像 $i(\mathbf{r})$ のシミュレーションデータは

$$i(\mathbf{r}) = i_0(\mathbf{r}) [1 + \cos \{\phi(\mathbf{r}) + \delta \mathbf{k} \cdot \mathbf{r}\}] + i_{\text{noise}}(\mathbf{r}) \quad (2.6)$$

で表される式に従い生成する．ここで， $i_0(\mathbf{r})$ は(2.3)式を用いて

$$i_0(\mathbf{r}) = \text{gauss}(\mathbf{r}; \mathbf{c}_{i_0}, 0, a_{i_0}, b_{i_0}) \quad (2.7)$$

と表される分布， $i_{\text{noise}}(\mathbf{r})$ は

$$i_{\text{noise}}(\mathbf{r}) \sim N[0, \alpha^2] \quad (2.8)$$

に従う白色のガウシアンノイズとした．表2.3に各パラメータの説明と，それらのパラメータが取り得るランダム値の範囲を示す．パラメータの範囲は，シミュレ-




図 2.5: (2.2) 式により生成された位相変化像の例（等高線は 2π [rad]ごと）．

シミュレーションデータを実測データに近いものとなるよう経験的に決定している。また，図 3.9 で示した $\phi_{\text{true}}(\mathbf{r})$ を用いて (2.6) 式によって生成される $i(\mathbf{r})$ の例を図 2.6 に示す。

位相変化は干渉画像の縞の移動量によって表されるので，重要なのは1枚の画像における隣接画素間の明暗の相対的な変化量であり，干渉画像の各画素の数値自体は重要ではない。そのため，学習を効率的に行う前処理として，干渉画像 $i(\mathbf{r})$ は画像ごとに最小値が0，最大値が1となるようにスケーリングを行った。

表 2.3: シミュレーション干渉画像生成に用いるランダムパラメータ

変数		値が取り得る範囲
\mathbf{c}_{i_0}	明るさの分布の中心座標	$(\frac{1}{4}N_x, \frac{1}{4}N_y) \leq \mathbf{c} < (\frac{3}{4}N_x, \frac{3}{4}N_y)$ [pixel]
(a_{i_0}, b_{i_0})	明るさの分布の (x, y) 方向の幅	$(N_x, N_y) \leq (a_{i_0}, b_{i_0}) < (\frac{3}{2}N_x, \frac{3}{2}N_y)$ [pixel]
$\delta \mathbf{k}$	キャリア周波数	$2\pi \cdot (-\frac{3}{32}, -\frac{3}{32}) \leq \delta \mathbf{k} < 2\pi \cdot (\frac{3}{32}, \frac{3}{32})$ [rad/pixel]
α	振幅ノイズの大きさ	$0.1 \leq \alpha < 0.5$ [-]




図 2.6: (2.6) 式によって生成されるシミュレーション干渉画像 $i(\mathbf{r})$ と, 生成に用いた $\phi_{\text{true}}(\mathbf{r})$ の例 .

2.5 学習経過および抽出結果

これは学習データの質が原因であり1本節では，2.2節で示したネットワークを2.4節で示した方法により生成したデータによって学習させ，得られた学習済みネットワークに未知のシミュレーション干渉画像，実測干渉画像を入力した際に得られた出力について示す．

はじめに，図2.7に学習経過を示す．横軸をエポック数，縦軸を

$$E_r = \left\langle \sqrt{\frac{\langle \{\phi_{\text{out}}(\mathbf{r}) - \phi_{\text{true}}(\mathbf{r})\}^2 \rangle_{\text{pixel}}}{\langle \{\phi_{\text{true}}(\mathbf{r})\}^2 \rangle_{\text{pixel}}}} \right\rangle_{\text{image}} \quad (2.9)$$

で定義する位相抽出性能評価関数としており， E_r 値が小さいほど位相抽出性能が良いと判断できる．この図から，学習が進むにつれて学習データと検証データに対する評価関数 E_r の値が伴って減少しており，学習は成功しているといえる．

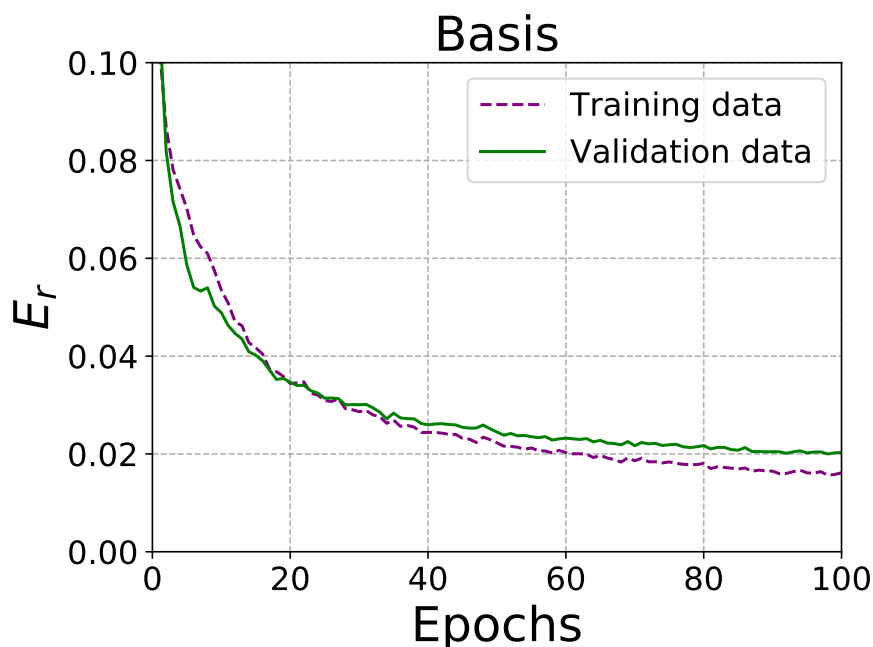


図 2.7: 学習の推移 .

次に，図 2.8 に学習済みネットワークとルールベース手法による抽出誤差のヒストグラムを示す．学習済みネットワーク，ルールベース手法により抽出された位相変化をそれぞれ $\phi_{\text{CNN}_0}(\mathbf{r})$ ， $\phi_{\text{RB}}(\mathbf{r})$ とし，横軸は $\phi_{\text{out}}(\mathbf{r}) = \phi_{\text{CNN}_0}(\mathbf{r})$ または $\phi_{\text{RB}}(\mathbf{r})$ とした時に

$$e_r = \sqrt{\langle \{\phi_{\text{out}}(\mathbf{r}) - \phi_{\text{true}}(\mathbf{r})\}^2 \rangle_{\text{pixel}} / \langle \{\phi_{\text{true}}(\mathbf{r})\}^2 \rangle_{\text{pixel}}} \quad (2.10)$$

で表される「1枚の $\phi_{\text{true}}(\mathbf{r})$ に対する $\phi_{\text{out}}(\mathbf{r})$ の相対誤差」の値であり，階級は e_r を 0.01 ごとに区切ったものとしている．縦軸は度数としている．なお， e_r が 1.0 を超えるデータは表示されていない．青色が学習済みネットワークからの出力，赤色が既存のルールベース手法による出力を表している．次に，図 2.9 に同じテストデータ $i(\mathbf{r})$ から出力された $\phi_{\text{CNN}_0}(\mathbf{r})$ と $\phi_{\text{RB}}(\mathbf{r})$ の e_r の散布図を示す．横軸が $\phi_{\text{RB}}(\mathbf{r})$ の e_r ，縦軸が $\phi_{\text{CNN}_0}(\mathbf{r})$ の e_r を表している．この図を見る限り，それぞれの e_r に相関はみられない．

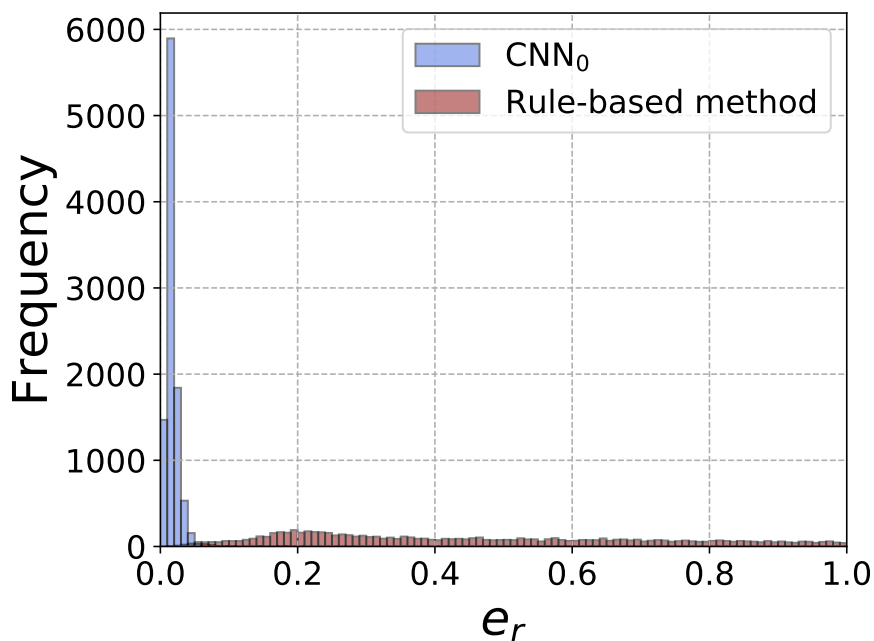


図 2.8: テストデータ 10000 枚に対する誤差のヒストグラム．

つまり、学習済みネットワークとルールベース手法は全く異なるアルゴリズムであるということがいえる。

次に、図2.10に学習データと同様、(2.2)、(2.6)式によって生成されたテストデータを学習済みのネットワークとルールベース手法に入力して得られた出力結果の例を示す。(a)-(d)はそれぞれ異なるサンプルデータを表している。 $i(\mathbf{r})$ は位相抽出法に入力される干渉画像、 $\phi_{\text{true}}(\mathbf{r})$ は $i(\mathbf{r})$ の生成に用いた真の位相変化像、 $\phi_{\text{CNN}_0}(\mathbf{r})$ 、 $\phi_{\text{RB}}(\mathbf{r})$ は $i(\mathbf{r})$ をそれぞれ学習済みネットワーク、ルールベース手法に入力して得られる出力を表しており、それぞれの画像の下に書かれている数値は(2.10)式で定義される相対誤差 e_r を表している。図2.8のヒストグラムや図2.10の出力結果を見る限り、学習済みネットワークによる出力の精度はルールベースのものを上回っている。また、1.3節で述べた通りフーリエ変換法では原理的に(c)、(d)のような縞にリングが生じている干渉画像からは位相の抽出ができないのに対し、学習済みネット

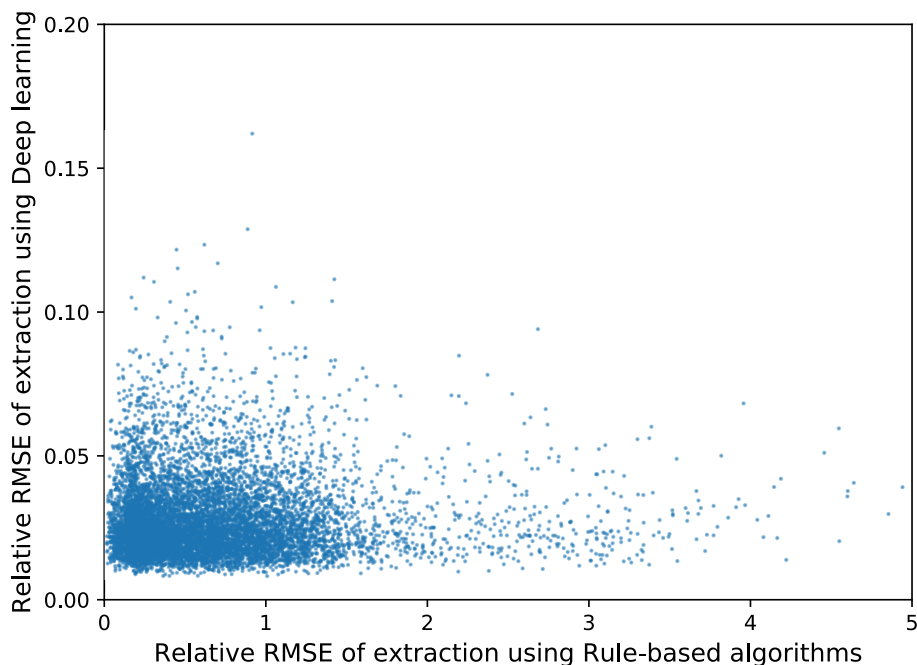


図 2.9: テストデータの $\phi_{\text{CNN}_0}(\mathbf{r})$ と $\phi_{\text{RB}}(\mathbf{r})$ に対する、 $\phi_{\text{true}}(\mathbf{r})$ との相対誤差 e_r の散布図。

ワークでは正しい位相変化像が出力されている。これは、機械学習ではこのような位相抽出問題を1対1の画像のパターン認識の問題とすることができ、リングを持つデータをあらかじめ学習データに含めることによりフーリエ変換法とは別の位相抽出アルゴリズムを得ることができることを示している。

次に、図2.11に実測の干渉画像 $i(\mathbf{r})$ を学習済みネットワークとルールベース手法に入力して得られた結果 $\phi_{\text{CNN}_0}(\mathbf{r})$, $\phi_{\text{RB}}(\mathbf{r})$ の例を示す。(a)-(f)は異なるサンプルデータを表している。 $i(\mathbf{r})$ には位相変化量に相当する縞の本数を目視で数えやすいよう

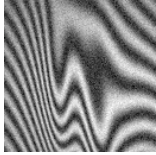
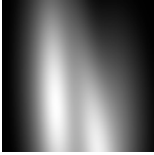
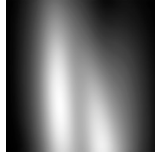
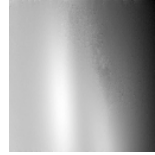
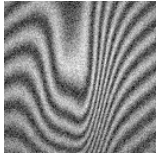
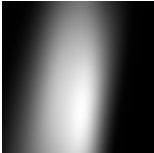
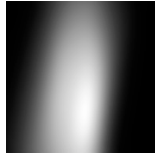
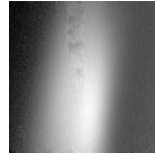
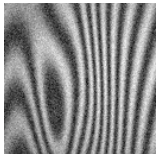
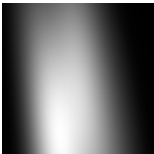
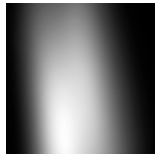

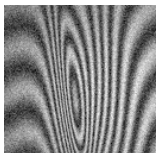
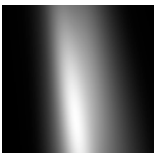
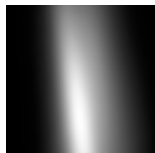
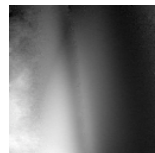
	$i(\mathbf{r})$	$\phi_{\text{true}}(\mathbf{r})$	$\phi_{\text{CNN}_0}(\mathbf{r})$	$\phi_{\text{RB}}(\mathbf{r})$
(a)				
			$e_r = 0.025$	0.907
(b)				
			$e_r = 0.024$	0.193
(c)				
			$e_r = 0.016$	0.611
(d)				
			$e_r = 0.022$	1.102

図 2.10: 抽出された位相変化像の例。

に赤い線を引いてある． N は赤い線が通る縞の本数を示している．実測の干渉画像は真の位相分布が不明であるため出力の定量的な評価はできないが，図 2.11 の画像を見る限り学習済みネットワークによる出力の精度はルールベース手法のもの

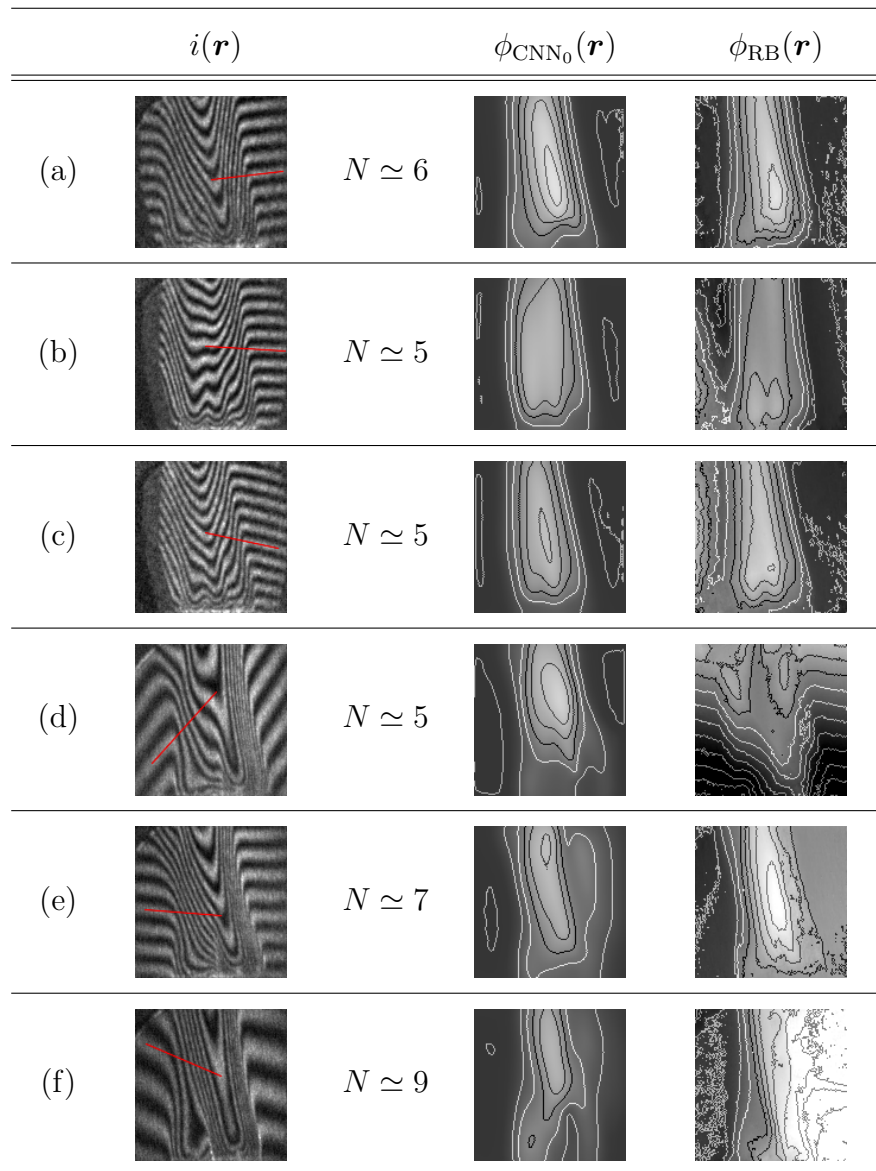


図 2.11: 実測データに対する学習済みネットワーク・ルールベース手法による出力結果の例 ($\phi_{\text{CNN}_0}(\mathbf{r})$, $\phi_{\text{RB}}(\mathbf{r})$ の等高線は $2\pi[\text{rad}]$ ごと) .


のより良い様に見える．しかし，学習済みネットワークの出力であっても (e) や (f) については明らかに測定対象の形状とは異なっており，適切な出力とは言い難い．これは，学習データと実測データに乖離がありネットワークが入出力関係の適切な学習を行えていないことを示している．

2.5.1 ハイパーパラメータの比較

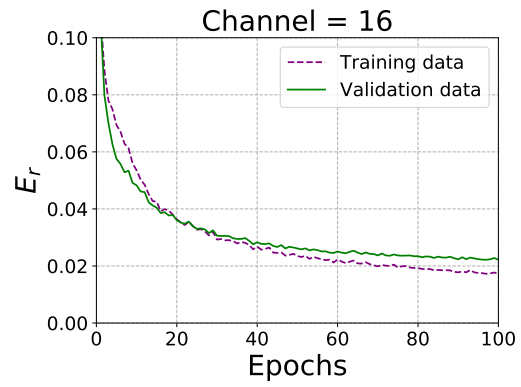
本項では、本章で用いたネットワークについてそれぞれ他のハイパーパラメータを固定し、ネットワークのチャンネル数、畳み込み層のカーネルサイズ、学習データの数を変化させて学習を行い得られた学習経過、および学習済みネットワークに実測の干渉画像を入力して得られた出力結果を示す。

はじめに、図2.12にそれぞれのネットワークの学習経過を示す。全て横軸はエポック数、縦軸は E_r である。図2.12を見る限り、カーネルサイズを 3×3 、もしくはチャンネル数を16としたネットワークよりも本章で採用したネットワーク構成の方がわずかであるが E_r が小さくなっている。一方、カーネルサイズを 7×7 、もしくはチャンネル数を64としたネットワークは本章で採用したネットワーク構成よりも E_r が小さくなっているが、その差はカーネルサイズを 3×3 、もしくはチャンネル数を16としたネットワークと本章で採用したネットワーク構成との差よりも小さくなっており、学習時間は大幅に長くなっていることがわかる。


以上の結果と学習に要する時間との兼ね合いから、次章以降も本章で採用したハイパーパラメータを用いることとする。




$E_r = 0.0221$, 学習時間 : 1 時間 14 分




$E_r = 0.0228$, 学習時間 : 1 時間 11 分



$E_r = 0.0202$, 学習時間 : 2 時間 39 分



$E_r = 0.0194$, 学習時間 : 5 時間 59 分



$E_r = 0.0198$, 学習時間 : 7 時間 47 分

図 2.12: 異なるハイパーパラメータを持つネットワークの学習推移 .

2.6 まとめ

本章ではシミュレーションにより生成した干渉画像と位相変化像を用い，入力を干渉画像，出力を位相変化像とする畳み込みニューラルネットワークの学習を行った．学習は成功し，シミュレーションにより生成した未知の干渉画像を学習済みネットワークに入力すると，ルールベース手法による出力結果よりも適切な位相変化像が出力された．学習済みネットワークは実測の干渉画像に対する位相抽出性能においても従来のルールベース手法を上回っているとみられるが，その抽出精度は良いとは言えない．これは学習データ生成の際の，ガウス分布の重ね合わせによる実測データへの近似が不十分であることが原因であり，より実測データに近い学習データによる学習を行うことで実測の干渉画像に対してもより高精度な出力を行うネットワークの獲得が可能であると考えられる．

第3章 学習データの改善によるネットワークの性能評価

3.1 はじめに

第2章で生成した位相抽出ネットワークは実測の干渉画像の入力に対する出力性能が悪いことが課題として挙げられた。そこで本章では、この課題の解決を試みる。具体的には、学習データセットの生成方法に改良を加えることによる実測の干渉画像に対する高性能なネットワークの生成を試みる。

3.2 実測情報を利用した学習データによる学習

3.2.1 正解データ：位相変化像の作成

2.5節で述べた通り、2.4節で用いた学習データは実測データの模擬という点で不十分であったと考えられる。この原因は「火災による位相変化像をガウス分布により代用したこと」にあると考えられる。実測によって学習に十分な枚数分の様々な変化量や形状を持った位相変化像のデータを得られれば良いが、それは労力の観点から現実的ではない。したがって、数枚の実測の干渉画像から抽出された位相変化像を組み合わせることによる多様な位相変化像 $\phi_{\text{true}}(r)$ のシミュレーションデータの作成を行う。

まずはじめに，図3.1に示すような通常のマッハツェンダー干渉計により図3.2に示すような火炎の干渉画像 $\phi_{\text{seed}}(\mathbf{r})$ を良条件で数パターン撮影し，ルールベース手法によって位相抽出を行った．

この撮影は1.3節で説明した計測システムでの撮影と異なり，縞の間隔を任意に調整することができ装置の移動による振動も発生しないため，明瞭な干渉画像を撮影することができ，得られた干渉画像からはルールベース手法によって十分に信頼できる精度で位相抽出を行うことができる．図3.3に，得られた $\phi_{\text{seed}}(\mathbf{r})$ の例を示す．

次に，得られた位相変化像 $\phi_{\text{seed}}(\mathbf{r})$ について，値のスケーリングや拡大縮小・移動・




図 3.1: 通常のマッハツェンダー干渉計．



図 3.2: 良条件の実測干渉画像 $i_{\text{seed}}(\mathbf{r})$ とルールベース手法による抽出位相 $\phi_{\text{seed}}(\mathbf{r})$ の例． $\phi_{\text{seed}}(\mathbf{r})$ の等高線間隔は 2π [rad] ．

せん断変形といった変形をランダムに行い,さらにそれらのうち複数を足し合わせるにより多様な位相変化像を大量に生成する.ただし, $\phi_{\text{seed}}(\mathbf{r})$ のバックグラウンド部分にはルールベース手法では考慮されていないカメラに由来するノイズが生じているため,この画像を用いて収縮やせん断を行うと図3.4の例のように位相の段差が生じた不自然なデータとなってしまう.この事象を防ぐため,2つの位相分布像生成法を検討した.




図 3.3: 良条件の干渉画像からの抽出位相 $\phi_{\text{seed}}(\mathbf{r})$ の例.等高線は $2\pi[\text{rad}]$ ごと.



図 3.4: 変形処理により不自然な位相の段差が生じた位相変化像 $i_{\text{seed}}(\mathbf{r})$ と, $i_{\text{seed}}(\mathbf{r})$ から生成された干渉画像の例.位相変化像の等高線は $2\pi[\text{rad}]$ ごと.

生成法1：位相変化像補外モデルの利用

1つ目は，一度 $\phi_{\text{seed}}(\mathbf{r})$ の周囲を補外した画像を生成し，その画像の一部を切り取って使用することで，不自然な段差を回避する方法である．補外には，畳み込みニューラルネットワークを用いた．はじめに正解データとして，2.4.1項と同様の条件で幅や最大値が様々に異なる二次元ガウス分布を複数組み合わせた位相変化像を1000枚生成する．ただし，後に一部分を切り取って使用することを可能とするため，画像サイズは位相抽出ネットワークの学習に用いるサイズ (N_x, N_y) に対して $(2N_x, 2N_y)$ とし，その画像の中心の (N_x, N_y) の範囲に $\phi_{\text{sim}}(\mathbf{r})$ が現れるような画像 $\phi_{\text{sim}+}(\mathbf{r})$ とし，入力データを $\phi_{\text{sim}}(\mathbf{r})$ とする．ただしこの時，干渉体系の媒質（空気）の不均一さに由来する位相ノイズを考慮に入れ，位相に対して

$$\phi_{\text{noise}}(\mathbf{r}) \sim \text{N}[0, \sigma_{\text{noise}}^2] \quad (3.1)$$

で表される白色ガウシアンノイズを加えた

$$\phi_{\text{sim}+}(\mathbf{r}) = \sum_{m=0}^2 \phi_m^{\text{max}} \text{gauss}(\mathbf{r}; \mathbf{c}_m, \theta_m, a_m, b_m) + \phi_{\text{noise}}(\mathbf{r}) \quad (3.2)$$

に従って $\phi_{\text{sim}+}(\mathbf{r})$ を生成した．図3.5に $\phi_{\text{sim}+}(\mathbf{r})$, $\phi_{\text{sim}}(\mathbf{r})$ の例を示す．これらのデータによって学習を行ったネットワークに $\phi_{\text{seed}}(\mathbf{r})$ を入力することで，画像サイズ $(2N_x, 2N_y)$ の $\phi_{\text{seed}+}(\mathbf{r})$ を得ることができる．図3.6に $\phi_{\text{seed}}(\mathbf{r})$, $\phi_{\text{seed}+}(\mathbf{r})$ の例を示す．この図を見る限り， $\phi_{\text{seed}+}(\mathbf{r})$ は $\phi_{\text{seed}}(\mathbf{r})$ の撮影範囲外の位相変化分布が自然に補外された画像となっているといえる．この $\phi_{\text{seed}+}(\mathbf{r})$ に対して拡大縮小・移動・せん断変形をランダムに行い $\phi_{\text{trans}+}(\mathbf{r})$ とし，中心付近の (N_x, N_y) の領域を切り取ることで前述のような位相に不自然な境界が生じる問題は解決される．切り取られた位相変化像を $\phi_{\text{trans}}(\mathbf{r})$ とし，異なる $\phi_{\text{seed}}(\mathbf{r})$ から得られた $\phi_{\text{trans}}(\mathbf{r})$ を

$$\phi_{\text{true}}(\mathbf{r}) = \sum_{m=0}^2 s_m \phi_{\text{trans}}(\mathbf{r}) \quad (3.3)$$





図 3.5: 位相分布補外ネットワーク用正解データ $\phi_{sim+}(\mathbf{r})$ と $\phi_{sim}(\mathbf{r})$ の例 . 画像サイズは $\phi_{sim+}(\mathbf{r})$ が $(2N_x, 2N_y)$, $\phi_{sim}(\mathbf{r})$ が (N_x, N_y) である . 値域は $[0, 1]$ にスケールしており , 等高線は 0.2 ごと .





図 3.6: $\phi_{seed}(\mathbf{r})$ と $\phi_{seed+}(\mathbf{r})$ の例 (いずれも $[0, 1]$ にスケール) . 等高線は 0.2 ごと .

に従ってランダムにスケールし足し合わせることで $\phi_{\text{true}}(\mathbf{r})$ のデータセットを生成した。 $\phi_{\text{seed+}}(\mathbf{r})$ から $\phi_{\text{trans+}}(\mathbf{r})$ への変形には画像のアフィン変換を用いたが、詳しいパラメータは省略する。 $\phi_{\text{trans}}(\mathbf{r})$ のスケールパラメータ s_m は、 $4\pi \leq s_m < 10\pi$ とした。図3.7に $\phi_{\text{trans}}(\mathbf{r})$, $\phi_{\text{true}}(\mathbf{r})$ の例を、図3.8に様々な $\phi_{\text{seed+}}(\mathbf{r})$ から得られた $\phi_{\text{trans}}(\mathbf{r})$ の例を示す。この図では s_m を乗じた後の値となっている。また、図3.9に生成された $\phi_{\text{true}}(\mathbf{r})$ の例を示す。

生成法2: バックグラウンド位相勾配・ノイズの事前除去

2つ目の方法は、少数の $\phi_{\text{seed}}(\mathbf{r})$ のバックグラウンドの位相勾配を手動で補正し、さらに画像全体に移動平均をかけノイズを落とし、最後にある閾値以下の画素値を0とした $\phi_{\text{seed}}^{\text{clean}}(\mathbf{r})$ を用いるという方法である。これにより得られる $\phi_{\text{seed}}^{\text{clean}}(\mathbf{r})$ は、実測の火炎による位相変化像の形状の特徴を保持しつつバックグラウンド部分が0と




図 3.7: $\phi_{\text{trans}}(\mathbf{r})$ の例 . 等高線は0.2ごと .




図 3.8: $s_m \phi_{\text{trans}}(\mathbf{r})$ の例 . 等高線は $2\pi[\text{rad}]$ ごと .

なっているので，移動やせん断といった変形を行っても位相に不自然な境界が生じない．この $\phi_{\text{seed}}^{\text{clean}}(\mathbf{r})$ を用いて，

$$\phi_{\text{true}}(\mathbf{r}) = \sum_{m=0}^2 s_m \phi_{\text{seed}}^{\text{clean}}(\mathbf{r}) \quad (3.4)$$

に従って $\phi_{\text{true}}(\mathbf{r})$ を生成する．図 3.10，図 3.11 に $\phi_{\text{seed}}^{\text{clean}}(\mathbf{r})$ ， $s_m \phi_{\text{trans}}(\mathbf{r})$ の例を示す．図 3.12 に，生成された $\phi_{\text{true}}(\mathbf{r})$ の例を示す．




図 3.9: $\phi_{\text{true}}(\mathbf{r})$ の例．等高線は $2\pi[\text{rad}]$ ごと．




図 3.10: $\phi_{\text{seed}}^{\text{clean}}(\mathbf{r})$ の例 ($[0, 1]$ にスケールング)．等高線は 0.2 ごと．




図 3.11: $s_m \phi_{\text{trans}}(\mathbf{r})$ の例 . 等高線は $2\pi[\text{rad}]$ ごと .




図 3.12: $\phi_{\text{true}}(\mathbf{r})$ の例 . 等高線は $2\pi[\text{rad}]$ ごと .

3.2.2 入力データ：干渉画像の作成

干渉画像 $i(\mathbf{r})$ の生成方法は基本的には2.4.2項で示した生成方法と同じである。ただし，撮影機器に由来する干渉縞のの振幅ノイズ $i_{\text{noise}}(\mathbf{r})$ に加え，干渉体系の媒質（空気）の不均一さに由来する位相ノイズ $\phi_{\text{noise}}(\mathbf{r})$ を考慮に入れ，干渉画像 $i(\mathbf{r})$ は

$$i(\mathbf{r}) = i_0(\mathbf{r}) [1 + \cos \{ \phi(\mathbf{r}) + \delta \mathbf{k} \cdot \mathbf{r} + \phi_{\text{noise}}(\mathbf{r}) \}] + i_{\text{noise}}(\mathbf{r}) \quad (3.5)$$

で表される式によって生成した。また，2.4.2項では明るさの分布 $i_0(\mathbf{r})$ をランダムなガウス分布としていたが，本項では生成するシミュレーション干渉画像をより実測の干渉画像に近づけるため，実測の干渉画像を二次元離散フーリエ変換し低周波成分のみをフィルタリングにより取り出して二次元離散フーリエ逆変換することによって得られる分布を用いる。図3.13に $i_0(\mathbf{r})$ の例を示す。また，ランダムに決定するキャリア周波数 $\delta \mathbf{k}$ が取り得る範囲について，より多くの範囲のキャリア周波数によるデータを模擬するため，表3.1に示す範囲とした。

以上を踏まえ，(3.5)式によって干渉画像 $i(\mathbf{r})$ を生成した。位相分布生成法1,2によって生成された位相変化像 $\phi_{\text{true}}(\mathbf{r})$ を用いて生成したものをそれぞれ図3.14，図3.15に示す。ただし，2.4.2項と同様，学習を効率的に行うための前処理として，干渉画像 $i(\mathbf{r})$ は画像ごとに最小値が0，最大値が1となるようにスケーリングした。

表 3.1: シミュレーション干渉画像生成に用いるランダムパラメータ

変数	値が取り得る範囲
$\delta \mathbf{k}$ キャリア周波数	$2\pi \cdot (-\frac{1}{8}, -\frac{1}{8}) \leq \delta \mathbf{k} < 2\pi \cdot (\frac{1}{8}, \frac{1}{8})$ [rad/pixel]




図 3.13: 実測の $i(r)$ の低周波成分を抽出した $i_0(r)$ (上段) と抽出元の $i(r)$ (下段) の例 .




図 3.14: 位相変化像生成法1によって生成された $\phi_{\text{true}}(\boldsymbol{r})$ を用いて (3.5) 式によって生成される $i(\boldsymbol{r})$ (上段) と, 生成に用いた $\phi_{\text{true}}(\boldsymbol{r})$ (下段) の例 .




図 3.15: 位相変化像生成法2によって生成された $\phi_{\text{true}}(\boldsymbol{r})$ を用いて (3.5) 式によって生成される $i(\boldsymbol{r})$ (上段) と, 生成に用いた $\phi_{\text{true}}(\boldsymbol{r})$ (下段) の例 .

3.2.3 学習経過および抽出結果

本項では、2.2節で示したネットワークを3.2.1項、3.2.2項で生成したデータによって学習させ、得られたネットワークに未知のシミュレーションデータ、実測データを入力した際に得られた出力について示す。以下、本節で示した生成法1,2によって生成した干渉画像 $i(\mathbf{r})$ と位相変化像 $\phi_{\text{true}}(\mathbf{r})$ からなるデータセットをそれぞれデータセット1、データセット2とし、2.4節で用いたデータセットをデータセット0とする。

データセット1による学習経過および抽出結果

はじめに、図3.16に学習経過を示す。2.5節と同様横軸をエポック数、縦軸を

$$E_r = \left\langle \sqrt{\frac{\langle \{\phi_{\text{out}}(\mathbf{r}) - \phi_{\text{true}}(\mathbf{r})\}^2 \rangle_{\text{pixel}}}{\langle \{\phi_{\text{true}}(\mathbf{r})\}^2 \rangle_{\text{pixel}}}} \right\rangle_{\text{image}} \quad (2.9)$$

で表される評価関数 E_r としている。この図を見る限り、図2.7と比較するとやや E_r の値が大きいものの学習データとテストデータに対する評価関数 E_r の値が伴って減少しており、データセット1を用いた学習は成功しているといえる。

次に、図3.17にデータセット1と同様の手法で生成されたテストデータをデータセット1による学習済みのネットワーク、ルールベース手法に入力して得られた出力結果の例を示す。図3.17の出力結果を見る限り、テストデータに対してはデータセット1による学習済みネットワークからの出力の方がルールベース手法による抽出より精度が良いことがわかる。

次に、図3.18に実測の干渉画像に対してデータセット1による学習済みネットワークを適用した結果の例を示す。ここで、 $i(\mathbf{r})$ は実測の干渉画像、 $\phi_{\text{CNN}_1}(\mathbf{r})$ はデータセット1による学習済みネットワークに $i(\mathbf{r})$ を入力して得られる出力結果を示している。比較のため、データセット0による学習済みネットワークからの出力結果 $\phi_{\text{CNN}_0}(\mathbf{r})$ を再掲している。実測データでは真の位相変化がわからないため定性的な




図 3.16: データセット 1 を用いた学習の推移 .

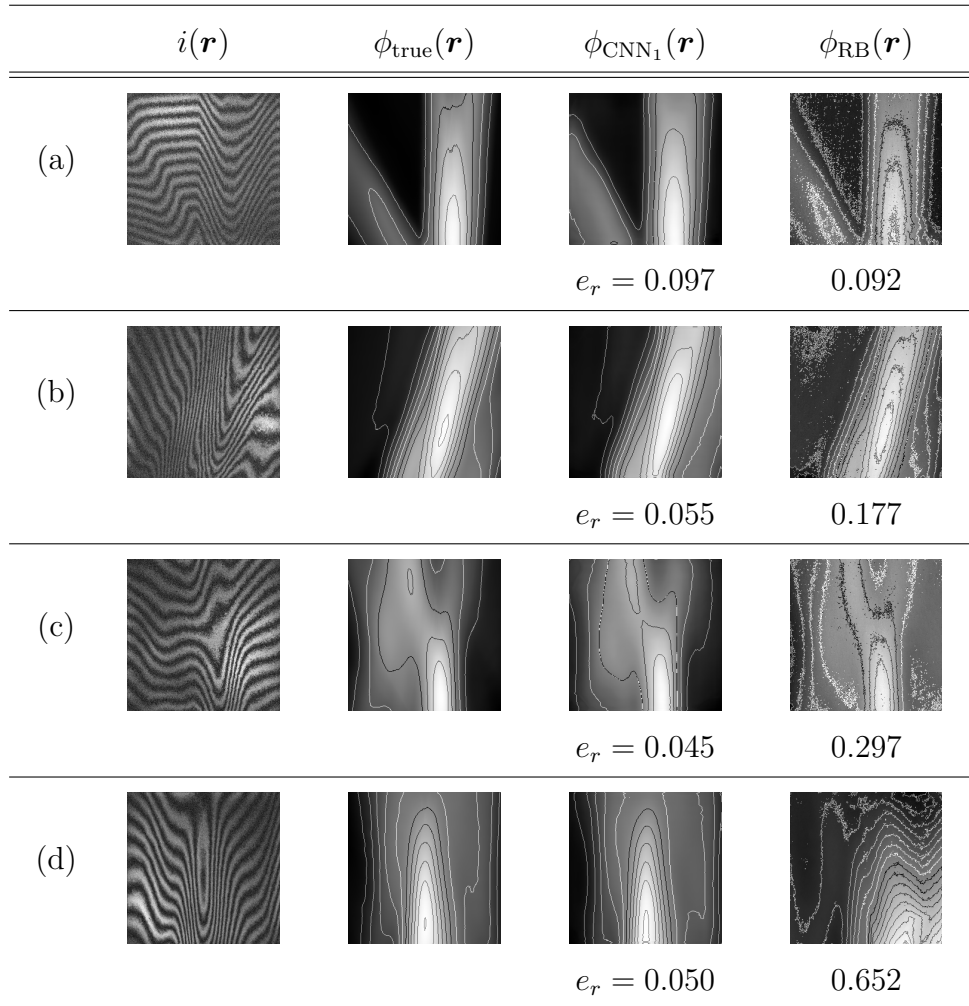


図 3.17: 抽出された位相変化像の例 . (a)-(d) はそれぞれ異なるサンプルデータに対する結果であり, $i(\mathbf{r})$ 干渉画像, $\phi_{\text{true}}(\mathbf{r})$ は $i(\mathbf{r})$ の生成に用いた真の位相変化像, $\phi_{\text{CNN}_1}(\mathbf{r})$, $\phi_{\text{RB}}(\mathbf{r})$ は $i(\mathbf{r})$ をそれぞれデータセット 1 による学習済みネットワーク, ルールベース手法に入力して得られる出力を表す . $\phi_{\text{CNN}_1}(\mathbf{r})$, $\phi_{\text{RB}}(\mathbf{r})$ の各画像の下に書かれている数値は (2.10) 式で定義される $\phi_{\text{true}}(\mathbf{r})$ との相対誤差 e_r を表す .

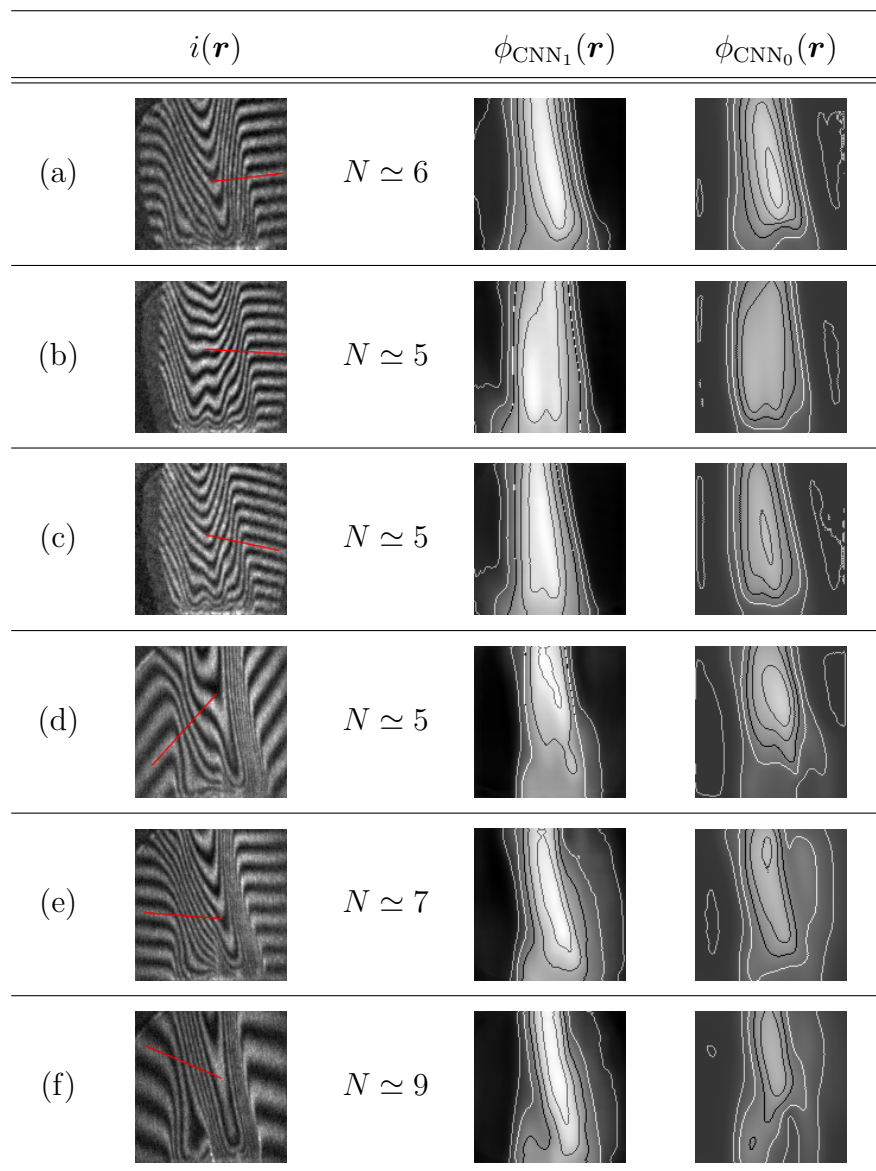


図 3.18: 実測データに対する学習済みネットワーク, ルールベース手法による出力結果の例. (a)-(f) は異なるサンプルデータ. $i(\mathbf{r})$ は位相抽出手法へ入力される実測の干渉画像. $i(\mathbf{r})$ 中の赤い線は縞の本数を数える目安. N は赤い線が通る縞の本数. $\phi_{\text{CNN}_1}(\mathbf{r})$, $\phi_{\text{CNN}_0}(\mathbf{r})$ は $i(\mathbf{r})$ をそれぞれデータセット 1, データセット 0 による学習済みネットワークに入力して得られる出力結果. 等高線は 2π ごと.

評価となってしまうが，結果を見る限り実測データに対してもデータセット1による学習済みネットワークからの出力の方がルールベース手法による抽出より精度が良いと考えられる．

データセット2による学習経過および抽出結果

データセット1による結果と同様に示す．はじめに，図3.19に学習経過を示す．この図を見る限り，図3.16同様，図2.7と比較するとやや E_r の値が大きいものの学習データとテストデータに対する評価関数 E_r の値が伴って減少，収束しており，データセット2を用いた学習は成功しているといえる．

次に，テストデータをデータセット2による学習済みのネットワーク，ルールベース手法に入力して得られた出力結果の例を図3.21に示す．図3.21の出力結果を見る限り，データセット2による学習済みネットワークからの出力の方がルールベース手法による抽出より精度が良いことがわかる．

次に，図3.21にデータセット2による学習済みネットワークに実測の干渉画像 $i(r)$ を入力して得られる出力結果 $\phi_{\text{CNN}_2}(r)$ の例を示す．比較のため，データセット1による学習済みネットワークからの出力結果 $\phi_{\text{CNN}_1}(r)$ を再掲している．定量評価はできないものの，図3.21の赤い直線を横切る縞の本数と出力結果の等高線の本数や縞の変化の形状から， $\phi_{\text{CNN}_2}(r)$ の出力精度は $\phi_{\text{CNN}_1}(r)$ のものを上回っていると予想できる．

次章では，データセット2の学習データを用いた学習により生成したネットワークを利用して，得られた位相を用いる．




図 3.19: データセット 2 を用いた学習の推移 . 横軸はエポック数 , 縦軸は評価関数 E_r .

	$i(\mathbf{r})$	$\phi_{\text{true}}(\mathbf{r})$	$\phi_{\text{CNN}_2}(\mathbf{r})$	$\phi_{\text{RB}}(\mathbf{r})$
(a)				
			$e_r = 0.017$	0.077
(b)				
			$e_r = 0.030$	0.487
(c)				
			$e_r = 0.032$	0.822
(d)				
			$e_r = 0.028$	1.390

図 3.20: 抽出された位相変化像の例 . (a)-(d) はそれぞれ異なるサンプルデータ . $i(\mathbf{r})$ 干渉画像 , $\phi_{\text{true}}(\mathbf{r})$ は $i(\mathbf{r})$ の生成に用いた真の位相変化像 , $\phi_{\text{CNN}_2}(\mathbf{r})$, $\phi_{\text{RB}}(\mathbf{r})$ は $i(\mathbf{r})$ をそれぞれデータセット 2 による学習済みネットワーク, ルールベース手法に入力して得られる出力 . , 各画像下部の数値は $\phi_{\text{true}}(\mathbf{r})$ との相対誤差 e_r .

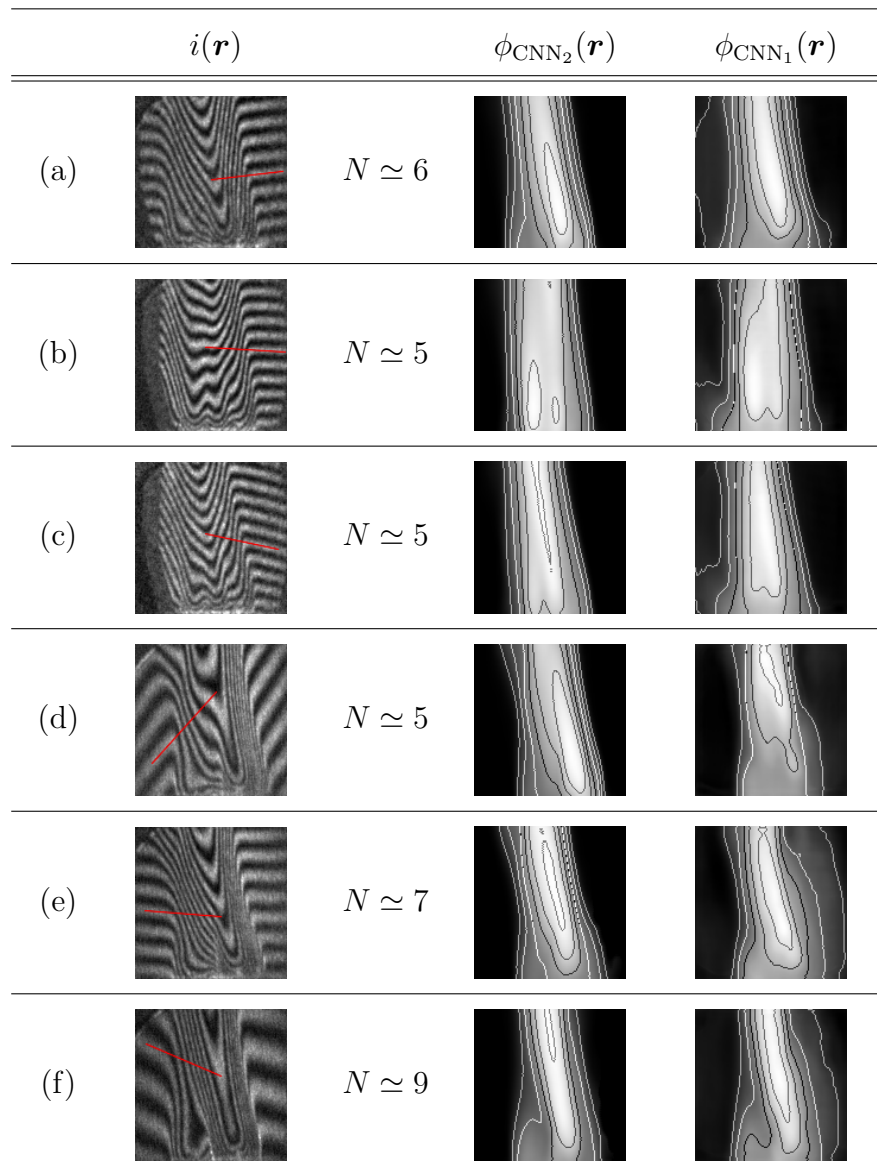


図 3.21: 実測データに対する, データセット 2 による学習済みネットワークからの出力結果の例. $i(\mathbf{r})$ は位相抽出手法へ入力される実測の干渉画像を表しており, 位相変化量に相当する縞の本数を目視で数えやすいように $i(\mathbf{r})$ の中に赤い直線を引き, N に赤い線が横切る縞の本数を示した. $\phi_{\text{CNN}_2}(\mathbf{r}), \phi_{\text{CNN}_1}(\mathbf{r})$ は $i(\mathbf{r})$ をそれぞれデータセット 2, データセット 1 (再掲) による学習済みネットワークに入力して得られた出力結果を表す. 等高線間隔は 2π .

3.3 本章のまとめ

前章では畳み込みニューラルネットワークに数学的なモデルで与えられた位相分布をもとに、計測モデルのシミュレーションにより干渉画像を生成し、これらをそれぞれ教師あり学習の出力と入力とした。しかしそれらのデータによる学習済みモデルは実測の干渉画像の入力に対する出力の精度が不十分であった。これは実測データとシミュレーションデータの乖離が原因であると考え、実測の火炎の位相変化像を用いることでより実測データに近いシミュレーションデータを生成した。新たに生成したデータセットによる学習を行ったモデルの実測データに対する出力精度が向上したことを確認し、適切なシミュレーションデータを学習データとして用意することで実測データからの位相変化像抽出に用いることができるモデルの獲得が可能であることを示した。

第4章 三次元再構成

4.1 はじめに

一般的なCTによる三次元再構成では、1.2.5項および1.2.6項で概要を説明した通り、まず測定対象をカバーできる太さに広げた平行ビームを用い、測定対象を通り抜ける際の測定対象内の再構成したい量(医療用であれば減衰率、本研究の場合は屈折率)の光路に沿った積分の二次元分布を方向を変えながら二次元の投影分布

$$p(\xi, z; \theta) = \int_{-\infty}^{\infty} f(x, y, z) d\eta \quad (4.1)$$

として測定する。ここで、 ξ, z はビーム断面座標で、 η はビームに沿う方向を示す。また、 x, y, z は θ に依存しないデカルト座標系であり、それに対して、 ξ, η は、 θ に依存する。 z については、積分に依存しないので別に考えるものとし、ある z の $f(x, y)$ の二次元の積分核の断層像(スライスと呼ぶ)を求めることを考える。 (x, y) 面内の f を $N \times N$ のグリッドで離散化すると、未知数の個数は N^2 となる。また、測定結果も ξ 軸を N_ξ 分割し、入射方向の数も N_θ とすると $N_\xi N_\theta$ 本の方程式が得られる。測定値と積分核をそれぞれ寸法 $N_\xi N_\theta$ の一次元行列 p と寸法 N^2 の一次元行列 f とし、積分を寸法が $N_\xi \theta \times N^2$ の二次元係数行列 C により表せば、これらの関係は、

$$p = Cf \quad (4.2)$$

の連立方程式で表される。仮に $N^2 = N_\xi N_\theta$ でかつこれらが互いに独立であれば、連立方程式を解くことにより $f(x, y)$ を決定できる。しかし、 $N = 500$ 程度であったと

しても， C の一次元寸法は25万となり，計算機資源の制限から容易には連立方程式を解くことはできないため，一般には連立方程式を直接解くことはせず別の方法が取られる．

もっとも単純な方法は単純逆投影と呼ばれる方法で， θ 毎に $g(\xi, \theta)$ の ξ を通る光路上のピクセルに平均値をマップし，そのマップを全ての θ について積算する．単純逆投影では， $f(x, y)$ のエッジが鈍ってしまうので，マップする前に，投影データのエッジを強調するフィルタ関数 $W(\xi' - \xi)$ を用いて

$$p'(\xi, \theta) = \int W(\xi' - \xi)p(\xi, \theta) d\xi' \quad (4.3)$$

の畳み込み積分によりエッジ強調された $p'(\xi, \theta)$ をマップする方法が，フィルタ付逆投影法 [32] として広く用いられている．

これらの逆投影法は再構成の計算コストが低いが，投影方向が全周方向(厳密には正反対からの投影は独立な方程式ではないので半周方向)からの投影データが測定される完全投影データセットの場合しか用いることができず，本研究の投影方向可変干渉計により得られる一部の投影角度からの投影データが欠落した不完全投影データセットには利用できない．

この他に，逆投影結果を基に再度数値的な投影を行い(順投影)，それと測定値の差や比を求め，それらを再度逆投影するという過程を繰り返しながら，測定投影データと数値投影データを徐々に収束させる方法 [33, 34, 35, 36, 37, 38, 39, 40, 41] が繰り返し逆投影法として知られており，特に，Shepp と Vardi が提案した方法 [35] は，最大尤度期待値最大化法 (Maximum Likelihood Expectation Maximization (ML-EM) 法) として広く用いられている．

ML-EM法による再構成法では，投影と逆投影を以下により与える．

$$p_{kl}^{(n)} = \mathcal{F}_{kl} \left\{ f_{ij}^{(n)} \right\}, \quad (4.4)$$

$$f_{ij}^{(n+1)} = \mathcal{B}_{ij} \left\{ \frac{p_{kl}^M}{p_{kl}^{(n)}} \right\} f_{ij}^{(n)}, \quad (4.5)$$

ここで (x_i, y_j) は (x, y) 座標の離散点を， (ξ_k, θ_l) は (ξ, θ) 座標での離散点を表し， $\mathcal{F}_{kl} \{ \cdot \}$ が数値的な順投影， $\mathcal{B}_{ij} \{ \cdot \}$ が逆投影演算を表し，上付き添字の (n) は繰り返し回数を，また上付き添字 M は測定データを示している．なお， p_{kl} のように ξ 軸および θ 軸に関する投影データを二次元行列として表したものはサイノグラムと呼ばれる．

本研究では，この ML-EM 法を不完全投影データセットに対しても応用できるように改良した重み付き再構成法 [3] を用いている．

重み付き再構成では，(4.5) 式の逆投影演算を

$$f_{ij}^{(n+1)} = \mathcal{M} \left\{ \mathcal{B}_{ij} \left\{ W_l \frac{p_{kl}^M}{p_{kl}^{(n)}} \right\} f_{ij}^{(n)} \right\}, \quad (4.6)$$

$$\sum_l W_l = 1 \quad (4.7)$$

のように，測定逆投影データと数値逆投影の比を求めた後に，投影角度 θ_l に応じて，重み W_l を乗じる．また， $\mathcal{M} \{ \cdot \}$ は移動平均演算子を表しており，サイノグラムに含まれるスペクルノイズや， θ_l 毎のノイズの除去に利用する．

重み付き再構成法は，図 4.1 に示すような測定体系により欠落範囲に一つでも投影データが得られれば再構成像の品位が向上することが分かっており，さらに，投影データの信頼性が異なる場合も測定データの標準偏差を考慮し得る重み付き最小自乗法と同様に信頼性に応じて重みを与えることにより，誤差の大きな投影データの寄与を低減することができることも示されている [3] ．

4.2 投影データの準備

再構成を行う前に，位相変化像の加工を行う必要がある．第2章では画像として扱いやすくするため位相変化量を正の値としていたが，空気と火炎の屈折率の関係から位相変化量は負の値となる．したがって，固定方向，可変方向ともに得られた位相変化像の値に -1 を乗じた．次に，固定方向から得られた位相変化像の中から，再構成に使用する画像の選択を行った．計測システムでは可変方向の撮影と同時に同フレーム数の固定方向の撮影を行う．求めたいのはある時刻での屈折率分布であるため撮影時間はなるべく短くし固定方向のデータは全て一致することが望ましいが，システムの制約により得られた複数データには分布の揺らぎによる




図 4.1: 入射方向可変干渉計と固定干渉計による投影データ取得体系．入射方向可変干渉計は X1, X2 の一軸ステージ上に搭載した回転ステージ上の HM1, HM2 の二つのハーフミラーと FM1, FM2 の二つのフルミラーにより構成し，固定干渉計は，HM3, HM4, FM3, FM4 により構成．可変干渉計の投影角度は $\theta = [-45^\circ, +15^\circ]$ ，固定干渉計では $\theta = 90^\circ$ ．

わずかな時間変化が生じる．したがって，固定方向のデータの平均をとり平均との残差が最も小さいフレームの画像を代表として採用した．

4.3 三次元再構成結果

本節では，測定対象を図4.2のような3本のろうそくの炎とし計測システムを用いて得られた屈折率分布三次元再構成結果について示す．図4.3，図4.4に入射方向可変干渉計から得られた，それぞれ可変方向，固定方向の干渉画像を示す．計測システムでは，可変方向は $[-45^\circ, 15^\circ]$ の方向から計154枚の干渉画像を取得しているが，ここではその例として10枚を取得した角度とともに示す．

4.3.1 既存の手法による再構成結果

図4.5，図4.6に図4.3，図4.4の干渉画像からルールベース手法によって行った位相抽出結果を示す．

次に，各位相変化像に対する信頼性に基づく重みの決定方法を示す．ルールベース手法により最終的に得られた位相変化像 ϕ^{RB} とその値を再び位相の主値に折り



図 4.2: 測定対象．

ただ値 ϕ_w^{RB} に対し,

$$\epsilon(\mathbf{r}) = \mathcal{W}\{\phi^{\text{RB}}(\mathbf{r}) - \phi_w^{\text{RB}}(\mathbf{r})\} \quad (4.8)$$

を定義する。ここで, $\mathcal{W}(\cdot)$ は位相の主値を求める演算である。 \mathbf{r} はスクリーン座標であり離散点は x_i, z_j で定義される。この中の x_i を投影方向に垂直な ξ_k に変換すると, $\epsilon(x_i, z_j)$ から $\epsilon(\xi_k, z_j) \equiv \epsilon_{kj}$ に変換できる。この値を用いて

$$W_{l(\theta \neq 90^\circ)}^\dagger = \exp\left(-\frac{\text{SD}_l[\epsilon_{kj}]^2}{\sigma_W^2}\right), \quad (4.9)$$

$$W_{l(\theta=90^\circ)}^\dagger = W_{\text{Fix}}^\dagger, \quad (4.10)$$




図 4.3: 可変方向の干渉画像の例。




図 4.4: 固定方向 ($\theta = 90^\circ$) の干渉画像の例。

$$W_l = W_l^\dagger / \sum_l W_l^\dagger \quad (4.11)$$

によって定義される W_l を各干渉画像の重みとする。ここで、SD は標準偏差を意味し、 σ_w は図 4.7 に示す誤差分布の標準偏差のヒストグラムに基づき、0.4 とした。 $\theta = 90^\circ$ については、この角度付近の投影データが少ないため $\theta = 90^\circ$ の情報量が大きいと考えられるので $W_{\text{Fix}}^\dagger = 10$ とした。

図 4.8a, 図 4.8b に $\phi^{\text{RB}}(r)$ から得られたサイノグラムと重み W_l を示す。

以上のデータを用いて得られた再構成結果について「重みあり、移動平均なし」




図 4.5: 可変方向干渉画像からのルールベース手法による位相抽出結果の例 (等高線は 2π 間隔)。




図 4.6: 固定方向 ($\theta = 90^\circ$) 干渉画像からのルールベース手法による位相抽出結果。

「重みなし，移動平均あり」「重みあり，移動平均あり」の3パターンを図4.9に示す．「重みあり(なし)」は重み付き ML-EM 法による再構成か一般の ML-EM 法による再構成か，「移動平均あり(なし)」は逆投影データに対して移動平均をかけているか否かを表す．図4.9から，重み・移動平均を用いた再構成結果がアーチファクトを軽減しつつ屈折率の平滑化を抑えているという点で最も良い結果といえる．また，再構成された屈折率を温度に換算した結果を図4.10に示す．





図 4.7: 誤差分布のヒストグラムと重み関数．



(a) サイノグラム．

(b) 重み W_l^dagger ．

図 4.8: サイノグラムと重み W_l^dagger の例 ($z = 10[\text{mm}]$)．縦軸は共通で θ , (a) の横軸は ξ , (b) の横軸が W_l^dagger ． θ は非等間隔．

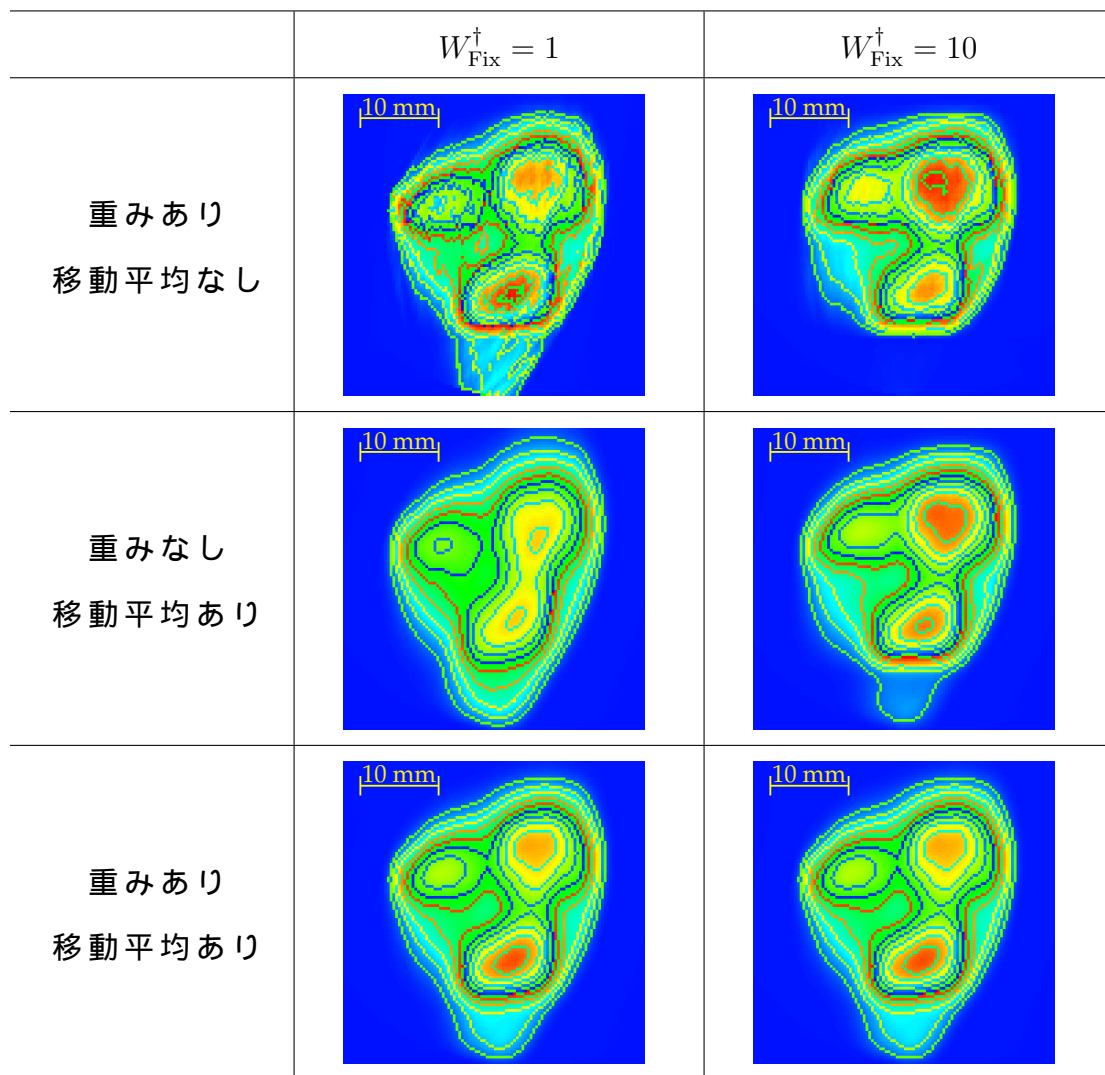


図 4.9: $z = 10$ [mm] の屈折率再構成結果 (等高線は 2×10^{-5}) ごと .




図 4.10: 温度分布の再構成結果 .

4.3.2 新手法による再構成結果

図 4.11, 図 4.12 に図 4.3, 図 4.4 の干渉画像から学習済みネットワークによって行った位相抽出結果を示す.

次に, 各位相変化像に対する信頼性に基づく重みの決定方法を示す. 学習済みネットワークによる位相抽出では干渉画像の入力に対して直接位相変化像が出力されるため, ルールベース手法のように抽出過程で得られるパラメータを用いて重




図 4.11: 可変方向干渉画像からの学習済みネットワークによる位相抽出結果の例(等高線は 2π 間隔).




図 4.12: 固定方向($\theta = 90^\circ$)干渉画像からの学習済みネットワークによる位相抽出結果.

みを計算することができない。したがって、図4.13に示すような、干渉画像を入力すると位相抽出ネットワークによる抽出の信頼性を推定する新たな畳み込みニューラルネットワークを構成し学習を行った。このネットワークの学習データは、入力データを「悪条件、良条件双方を含んだ干渉画像」、正解データを「データセット2による学習済み位相抽出ネットワークに入力データを入力して得られる出力と真の位相変化像のRMSE」とした。再構成の際は、この学習済み誤差推定ネットワークに干渉画像を入力して得られる抽出誤差推定値を $\epsilon_{\text{est},l}[\text{rad}]$ とし、 W_l^\dagger をルールベース手法の(4.9)式から

$$W_l^\dagger = \exp\left(-\frac{\epsilon_{\text{est},l}^2}{2\sigma_W^2}\right) \quad (4.12)$$




図 4.13: 位相抽出誤差推定ネットワーク。

に変更，固定方向の重みと規格化はルールベース手法と同じく (4.10), (4.11) 式を用いて W_l を求めた．ここで， σ_W は図 4.14 に示す誤差分布の標準偏差のヒストグラムに基づき， $\frac{\pi}{4}$ とした．図 4.15b に $\phi^{\text{cnn}}(r)$ から得られたサイノグラムと重み W_l を示す．

以上のデータを用いて得られた温度の再構成結果について，図 4.16 に示す．図 4.16 から，ルールベース手法の抽出結果を用いた再構成結果と比べ実際の炎に近い





図 4.14: 誤差分布のヒストグラムと重み関数．



(a) サイノグラム．

(b) 重み W_l^{\dagger} ．

図 4.15: サイノグラムと重み W_l^{\dagger} の例 ($z = 10[\text{mm}]$) ．縦軸は共通で θ , (a) の横軸は ξ , (b) の横軸が W_l^{\dagger} ． θ は非等間隔．

温度分布が再構成されていること，また，位相抽出ネットワークからの出力と誤差推定ネットワークを用いて得られた重みの組み合わせによる再構成は，移動平均をかけなくてもアーチファクトが現れない，定性的に良い結果となっていることがわかる．




図 4.16: 温度分布の再構成結果 .

第5章 結論

本研究では，物体の三次元屈折率分布の非破壊計測システムの高精度化に寄与する，既存の手法より高精度な干渉画像からの位相抽出手法の提案を行った．

三次元屈折率計測システムによる撮影において少なくない割合で発生してしまう悪条件の干渉画像からの位相抽出は既存のルールベース手法では困難であるという問題を示し，畳み込みニューラルネットワークを応用することでその問題の解決を試みた．

教師あり学習のニューラルネットワークでは，入力画像である干渉画像と正解である位相像の組を多数準備する必要があるが，干渉画像の実測データでは，バックグラウンド干渉縞の間隔が狭い場合，あるいは，それが原因で干渉縞がリング状に閉じているような場合には，ルールベース手法にとっては，悪条件となり，正しい位相像を求めることができずニューラルネットワークにおける正解を準備することができない．そこで，正解データである位相分布をガウス分布の重ね合わせにより先に作成し，それからノイズも含めた計測プロセスを模擬することにネットワークへの入力となる干渉画像を求めた．この学習データを用いて，使用する畳み込みニューラルネットワークの様々なハイパーパラメータについて検討を行い，求められる出力精度と学習時間について比較検討を行い，適切なパラメータを決定した．このネットワークにより算出される位相分布は，計測プロセスの模擬により求めた干渉画像を入力としたものに対しては期待どおりの算出されていたが，実測の干渉画像には，一部誤差を含んでいる様子がみられた．この原因は位相分布を

単純なガウス分布の重ね合わせにより生成したこと原因であり，実測データの採用が重要であることが予想された．

実測の干渉画像の場合，上述した悪条件の干渉画像に対する位相像(正解)を求めることは不可能であるが，良条件の干渉画像の場合には，既存のルールベース手法により，位相像を算出可能である．そこで，良条件で実測された干渉画像から求めた位相像を重ね合わせた後，測定過程を模擬することにより悪条件の干渉画像を作成した．この学習データ生成方法により，生成した学習済ネットワークの出力は，実測データについても大きな誤差を含まないことがわかった．

このニューラルネットワークの出力である位相像を用いて三次元再構成を行うためには，位相像に含まれる誤差あるいは位相像の確かさがが必要となる．そこで，位相像を求めるためのネットワークの他に，求めた位相像の確かさを求めるためのニューラルネットワークも構築した．

これら二つのニューラルネットワークにより求めた位相像とその確かさを重みつき再構成を行い，屈折率の三次元分布を求めたところ，従来のルールベース手法の結果を用いる場合に比べて，定性的に良好な屈折率分布が得られることを示した．

今回用いた構成の畳み込みニューラルネットワークの多くは，画像を画素ごとにカテゴリ分類するセグメンテーションに広く用いられており，本研究のように，二次元関数である画像データから逆変換による元の画像データを推定する例は多く示されていない．本研究の成功により，本研究の干渉画像から位相画像を求めるだけでなく，他分野における二次元関数の逆変換にも応用できることが予想される．

参考文献

- [1] S. Tomioka, S. Nishiyama, “Nondestructive three-dimensional measurement of gas temperature distribution by phase tomography,” Proc. SPIE **8296**, 829617 (2012).
- [2] S. Tomioka, S. Nishiyama, S. Heshmat, Y. Hashimoto, and K. Kurita, “Three-dimensional gas temperature measurements by computed tomography with incident angle variable interferometer,” Proc. SPIE **9401**, 94010J (2015).
- [3] S. Tomioka, S. Nishiyama, N. Miyamoto, D. Kando, and S. Heshmat, “Weighted reconstruction of three-dimensional refractive index in interferometric tomography,” Applied Optics **56**, 6755–6764 (2017).
- [4] J. H. Bruning, D. R. Herriott, J. E. Gallagher, D. P. Rosenfeld, A. D. White, and D. J. Brangaccio, “Digital wavefront measuring interferometer for testing optical surfaces and lenses,” Appl. Opt. **13**, 2693–2703 (1974).
- [5] B. Breuckmann and W. Thieme, “Computer-aided analysis of holographic interferograms using the phase-shift method,” Appl. Opt. **24**, 2145–2149 (1985).
- [6] K. E. Perry, Jr. and J. McKelvie, “A comparison of phase shifting and Fourier methods in the analysis of discontinuous fringe patterns,” Opt. and Lasers in Engineering **19**, 269–284 (1993).

- [7] M. Takeda, H. Ina, and S. Kobayashi, “Fourier-transform method of fringe-pattern analysis for computer-based topography and interferometry,” *J. Opt. Soc. Am.* **72**, 156–160 (1982).
- [8] E. CuChe, P. Marquet, and C. Depeursinge, “Spatial filtering for zero-order and twin-image elimination in digital off-axis holography,” *Appl. Opt.* **39**, 4070–4075 (2000).
- [9] R. M. Goldstein, H. A. Zebker, and C. L. Werner, “Satellite radar interferometry: Two-dimensional phase unwrapping,” *Radio Science* **23**, 713–720 (1988).
- [10] J. M. Huntley, “Noise-immune phase unwrapping algorithm,” *Appl. Opt.* **28**, 3268–3270 (1989).
- [11] J. R. Buckland, J. M. Huntley, and S. R. E. Turner, “Unwrapping noisy phase maps by use of a minimum-cost-matching algorithm,” *Appl. Opt.* **34**, 5100–5108 (1995).
- [12] R. Cusack, J. M. Huntley, and H. T. Goldrein, “Improved noise-immune phase-unwrapping algorithm,” *Appl. Opt.* **34**, 781–789 (1995).
- [13] M. Costantine, “A novel phase unwrapping method based on network programming,” *IEEE Trans. Geoscience and Remote Sensing* **36**, 813–821 (1998).
- [14] B. Gutmann and H. Weber, “Phase unwrapping with the branch-cut method: Clustering of discontinuity sources and reverse simulated annealing,” *Appl. Opt.* **38**, 5577–5593 (1999).
- [15] S. A. Karout, M. A. Gdeisat, D. R. Burton, and M. J. Lalor, “Two-dimensional phase unwrapping using a hybrid genetic algorithm,” *Appl. Opt.* **46**, 730–743 (2007).
- [16] D. L. Fried, “Least-square fitting a wave-front distortion estimate to an array of phase-difference measurements,” *J. Opt. Soc. Am.* **67**, 370–375 (1977).

- [17] R. H. Hudgin, “Wave-front reconstruction for compensated imaging,” *J. Opt. Soc. Am.* **67**, 375–378 (1977).
- [18] B. R. Hunt, “Matrix formulation of the reconstruction of phase values from phase differences,” *J. Opt. Soc. Am.* **69**, 393–399 (1979).
- [19] D. C. Ghiglia and L. A. Romero, “Direct phase estimation from phase differences using fast elliptic partial differential equation solvers,” *Opt. Lett.* **14**, 1107–1109 (1989).
- [20] H. Takajo and T. Takahashi, “Least-squares phase estimation from the phase difference,” *J. Opt. Soc. Am. A* **5**, 416–425 (1988).
- [21] H. Takajo and T. Takahashi, “Noniterative method for obtaining the exact solution for the normal equation in least-squares phase estimation from the phase difference,” *J. Opt. Soc. Am. A* **5**, 1818–1827 (1988).
- [22] D. C. Ghiglia and L. A. Romero, “Robust two-dimensional weighted and unweighted phase unwrapping that uses fast transforms and iterative methods,” *J. Opt. Soc. Am. A* **11**, 107–117 (1994).
- [23] R. Yamaki and A. Hirose, “Singularity-spreading phase unwrapping,” *IEEE Trans. Geoscience and Remote Sensing* **45**, 3240–3251 (2007).
- [24] S. Tomioka, S. Heshmat, N. Miyamoto, and S. Nishiyama, “Phase unwrapping for noisy phase maps using rotational compensator with virtual singular points,” *Appl. Opt.* **49**, 4735–4745 (2010).
- [25] S. Heshmat, S. Tomioka, and S. Nishiyama, “A reliable phase unwrapping algorithm based on rotational and direct compensators,” *Appl. Opt.* **50**, 6225–6233 (2011).

- [26] S. Tomioka, and S. Nishiyama, “Phase unwrapping for noisy phase map using localized compensator,” *Appl. Opt.* **51**, 4984–4994 (2012).
- [27] S. Heshmat, S. Tomioka, and S. Nishiyama, “Performance evaluation of phase unwrapping algorithms for noisy phase measurements,” *Int. J. Optomechatronics* **8**, 260–274 (2014).
- [28] Ronneberger, O.; Fischer, P.; Brox, T. “U-net: Convolutional networks for biomedical image segmentation,” In *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*, Shenzhen, China, 13–17 October 2015; Springer: Cham, Switzerland, 2015; pp. 234–241.
- [29] Ioffe, Sergey, and Christian Szegedy. “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” *arXiv preprint arXiv:1502.03167* (2015).
- [30] Kingma, Diederik P., and Jimmy Ba. “Adam: A method for stochastic optimization,” *arXiv preprint arXiv:1412.6980* (2014).
- [31] Tokui, Seiya, et al. “Chainer: a next-generation open source framework for deep learning,” *Proceedings of workshop on machine learning systems (LearningSys) in the twenty-ninth annual conference on neural information processing systems (NIPS)*. Vol. 5. 2015.
- [32] L. A. Shepp and B. F. Logan, “The fourier reconstruction of a head section,” *IEEE Transactions on Nuclear Science* **21**, 21–43 (1974).
- [33] R. Gordon, R. Bender, and G. T. Herman, “Algebraic reconstruction techniques (art) for three-dimensional electron microscopy and x-ray photography,” *Journal of theoretical Biology* **29**, 471IN1477–476IN2481 (1970).

- [34] P. Gilbert, “Iterative methods for the three-dimensional reconstruction of an object from projections,” *Journal of theoretical biology* **36**, 105–117 (1972).
- [35] L. A. Shepp and Y. Vardi, “Maximum likelihood reconstruction for emission tomography,” *IEEE transactions on medical imaging* **1**, 113–122 (1982).
- [36] K. Lange and R. Carson, “Em reconstruction algorithms for emission and transmission tomography,” *J Comput Assist Tomogr* **8**, 306–16 (1984).
- [37] A. H. Andersen and A. C. Kak, “Simultaneous algebraic reconstruction technique (sart): a superior implementation of the art algorithm,” *Ultrasonic imaging* **6**, 81–94 (1984).
- [38] H. M. Hudson and R. S. Larkin, “Accelerated image reconstruction using ordered subsets of projection data,” *IEEE transactions on medical imaging* **13**, 601–609 (1994).
- [39] J. A. Fessler, “Penalized weighted least-squares image reconstruction for positron emission tomography,” *IEEE transactions on medical imaging* **13**, 290–300 (1994).
- [40] J. M. Anderson, B. A. Mair, M. Rao, and C.-H. Wu, “Weighted least-squares reconstruction methods for positron emission tomography,” *IEEE transactions on medical imaging* **16**, 159–165 (1997).
- [41] T. Gerzen and D. Minkwitz, “Simultaneous multiplicative column normalized method (smart) for the 3d ionosphere tomography in comparison with other algebraic methods,” in “*Annales Geophysicae*,” (European Geosciences Union, 2016), 34, pp. 97–115.
- [42] Yao, Wei, et al. ”Pixel-wise regression using U-Net and its application on pansharpening.” *Neurocomputing* 312 (2018): 364-371.

謝辞

本論文の作成にあたり，多くの方々にお世話になりました．ここに感謝の意を表します．

まずはじめに，指導教員である富岡智教授にお礼を申し上げます．学部4年から博士課程3年に至る6年間，プログラミングの基礎や計算機の設定，実験装置の扱いから研究の内容に至るまで幅広いご指導を頂き，また私が研究に機械学習を導入したいと言った際には専門ではない分野にも関わらず一緒に知識を深めて頂き，研究の進捗の大きな味方となりました．特に博士課程の終盤は私の都合により朝早くから夜遅くまでお付き合いくださり，富岡先生が指導教員でなければ学位取得は不可能でした．本当にありがとうございました．

副査を担当していただいた，加美山隆教授，梅垣菊男特任教授，宮本直樹准教授には，私の至らない説明にも丁寧に耳を傾けてくださり，本論文をより良いものにするため様々なご指摘を頂きました．ありがとうございました．

プラズマ生体応用工学研究室の山内有二准教授，松本裕助教，研究室改編以前にお世話になった佐々木浩一教授，及川俊一准教授，西山修輔助教にもお礼申し上げます．研究室での経過報告の際に，私が気づかなかった視点からのご指摘を多数頂いたり，計算機や実験装置についてのアドバイスを頂きました．ありがとうございました．

研究室を卒業していった先輩方や同期，そして後輩の皆様へもお礼を申し上げます．研究の息抜きにプログラミング課題を設定してお互い解き合ったり，将棋を指

したり、ソフトボール大会に出場したことはどれも良い思い出です。ありがとうございました。

そして、長い学生生活を支えてくれた両親に深く感謝します。私が何度か挫折した際はいつも温かく見守ってくれ、お陰様で博士課程卒業という節目を迎えることができました。今まで本当にありがとうございました。

本論文の作成にあたり、他にも多くの方々にお世話になりました。改めて皆様に対しお礼を申し上げます。ありがとうございました。

令和2年2月19日

貫洞 大地