

令和 3 年度 修士論文



# 4次元X線CTスキャンデータの 勾配ベクトルを用いた投影像補間と 機械学習による高解像度化

Gradient-based Projection Image Interpolation  
of Dynamically Deforming Objects and  
Super-resolution by Machine Learning for X-ray CT

東京都立大学大学院  
システムデザイン研究科  
機械システム工学域

学修番号 20862636

小宮 友希

指導教員 長井 超慧 准教授



## 概要

近年、製品製造において省エネルギー化と CO<sub>2</sub> 排出削減のため、軽量化が可能な微細構造が注目されている。微細構造とは疎で微小な類似のパターンが繰り返されている構造である。微細構造の造形には、複雑な構造も造形可能な積層造形技術が有効である。造形物に断裂・気泡等の欠陥があると強度が低下する恐れがあるため、造形物に対して欠陥を検査する必要がある。そこで、複雑な構造を非破壊で検査できる X 線 CT スキャンが有望視されている。

CT スキャンとは、X 線の減弱から計測物の 3 次元形状を計測する方法である。X 線源から照射された X 線が回転台の上にある計測物を透過し、減弱した X 線の強度を検出器で検出する。X 線の透過率に対して自然対数を取り  $-1$  を掛けた値である投影値をグレースケールで表示した画像が投影像となる。計測物を 360 度回転させて各回転角で投影像を取得する。本論文では、360 度分の投影像列をフレームと呼ぶ。1 つのフレームを CT 再構成することで 3 次元の CT 画像 (CT ボリューム) を得る。CT スキャンには視野と分解能のトレードオフの関係があり、高分解能に CT スキャンすると計測物を一部ずつ計測するため、計測物全体の CT ボリュームを得るには時間がかかる。一方、一度に計測物全体を CT スキャンすると低解像度の CT ボリュームになるため、微小な欠陥等の内部構造の観察が困難になる。

さらに、CT スキャンは物体の変形の観察用途においても需要が高い。変形する物体の CT スキャン方法として、物体の変形中に計測し、各時刻における CT ボリュームを取得する 4 次元 CT (4DCT) スキャン技術が近年注目されている。4DCT スキャンの計測方法は 2 種類あり、1 つのフレームごとに変形を止めて計測する離散的計測と変形を止めずに計測する連続的計測がある。連続的計測では計測中に変形が起こるため、投影像および再構成した CT ボリュームにブレが生じてしまう。

上記のように、低解像 CT ボリュームでは内部構造の観察が困難であるため、高解像度化する必要がある。また 4DCT スキャンの実用化のためには、任意時刻におけるブレの少ない投影像の生成が必要となる。本研究では、これらの要求に応え内部構造の高精度観察を容易にするために以下の 2 つの手法を提案する。

- 機械学習を用いた低解像 CT ボリュームに対する高解像度化
- 4DCT スキャンデータの投影像補間による、任意の時刻の投影像生成

次ページに、本論文の各章の説明をする。

第 1 章では, 背景として微細構造を有した造形物について述べ, 検査方法の CT スキャンの概要と 4DCT スキャンの特徴について述べる. また, 研究目的とアプローチについて示す.

第 2 章では, CT スキャンの関連研究を紹介する. また, 機械学習と機械学習を用いた高解像度化の原理や特徴を述べ, 4DCT スキャンで用いるフレーム補間について説明する.

第 3 章では, 機械学習による低解像 CT ボリュームの高解像度化を提案する. 低解像 CT ボリュームを入力として, 2 倍の解像度の高解像 CT ボリュームを生成する. 学習データは入力と正解データの組から成る. 入力データは低解像 CT ボリュームの形状特徴が十分にとらえられる 3 次元の小領域とする. また, 正解データは低解像 CT ボリュームの各ボクセルに対応する  $2 \times 2 \times 2$  ボクセルとする. ネットワーク構造は畳み込みニューラルネットワークを用いる.

第 4 章では, 投影像に対するフレーム補間を提案する. 生成したい任意時刻の前後のフレームを入力データとする. 前のフレームの投影値の勾配ベクトルを用いたオプティカルフローを forward flow と呼び, 次のフレームの勾配ベクトルを用いたオプティカルフローを backward flow と呼ぶ. Forward flow と backward flow の差分ベクトルのノルムが閾値以上であれば, その画素において変化が生じたとみなし, 時間をパラメタとして投影値の線形補間を行うことで, 任意時刻の投影値を計算する.

第 5 章では, 第 3 章で述べた手法についての実験, 結果および考察について述べる. 繰り返し構造や微細構造を有する造形物に対して, 高解像度化手法を適用し, 高解像 CT ボリュームを得た. 比較手法としてバイキュービック法や機械学習を用いた手法である SRCNN を用いた. PSNR と SSIM を用い, 画像のノイズと正解データとの類似度を評価し, 提案手法が従来法より高品質な CT ボリュームを生成したことを確認した.

第 6 章では, 第 4 章の手法についての実験, 結果および考察について述べる. 2 種類の 4DCT スキャン方法である離散的計測と連続的計測で得られた投影像列を実験データとした. また, 比較として, 各画素における変化を計算する手法である Lucas-Kanade 法と Horn-Shunck 法を用いた投影像補間の実験も行った. 画質は PSNR と SSIM で評価した. 画質評価の結果, 計測物の変形による影響に対し頑健な投影像を生成できた.

第 7 章では, 本研究で得られた結果を基に結論を述べ, 今後解決すべき課題及び展望を述べる. 本研究では, 低解像 CT ボリュームに対して高解像度の CT ボリュームを生成する手法と, 物体の変形に対応した中間投影像を生成し任意時刻の CT ボリュームを生成できる手法を提案し, それらの有効性を示した. 高解像度化手法では, 今回は単一素材の計測物に対してのみ実験を行った. 一般的には, 複数素材の製品が多いため, 素材の形状特徴サイズに応じて注目領域を最適化する必要がある. また, 投影像補間手法は, 変化量が大きいデータに対してはうまく補間できない. 今後は, 線形補間だけでなく, 変形量をパラメタとした機械学習などを用いることにより大変形にも対応可能な投影像補間の手法の確立が望まれる.



---

# 目次

第 1 章	序論	1
1.1	微細構造を有した造形物 .....	2
1.1.1	微細構造 .....	2
1.1.2	造形方法 .....	2
1.1.3	積層造形技術の問題 .....	3
1.2	X 線 CT スキャン .....	4
1.2.1	X 線 CT スキャンの概要 .....	4
1.2.2	CT スキャン方式 .....	5
1.2.3	CT 再構成 .....	6
1.2.4	CT スキャンの視野と分解能 .....	7
1.3	4DCT スキャン .....	8
1.3.1	4DCT スキャンの概要 .....	8
1.3.2	4DCT スキャンの流れ .....	8
1.3.3	4DCT スキャンの問題点 .....	9
1.4	研究目的 .....	11
1.4.1	欠陥を観察するための CT 画像の鮮明化 .....	11
1.4.2	投影像に対するフレーム補間 .....	11
1.5	本論文の構成 .....	12
第 2 章	関連研究	13
2.1	X 線 CT スキャンによる検査の有効性 .....	14
2.1.1	X 線 CT スキャンによる内部欠陥の評価 .....	14
2.1.2	4DCT スキャンによる内部観察 .....	15
2.2	機械学習 .....	17
2.3	画像の高解像度化に関する研究 .....	23

2.4	フレーム補間 .....	26
2.5	本研究の位置付け .....	28
2.5.1	機械学習による高解像度化 .....	28
2.5.2	投影像に対するフレーム補間 .....	28
第 3 章	高解像度化アルゴリズム .....	29
3.1	提案手法の概要 .....	30
3.2	学習データの生成 .....	31
3.3	ネットワーク構築 .....	33
3.4	画像の評価法 .....	34
第 4 章	投影像に対するフレーム補間 .....	37
4.1	提案手法の概要 .....	38
4.2	投影値の勾配を用いたオプティカルフローの算出 .....	39
4.3	投影像補間 .....	40
第 5 章	実験と考察: 高解像度化アルゴリズム .....	41
5.1	実験手順 .....	42
5.1.1	実験環境 .....	42
5.1.2	X 線 CT 装置 .....	42
5.2	実験結果 .....	43
5.2.1	X 構造モデル .....	44
5.2.2	テトラ構造モデル .....	49
5.2.3	骨構造モデル .....	53
5.3	考察 .....	57
5.3.1	切り出しサイズによる高解像度化への影響 .....	57
5.3.2	学習組数による高解像度化への影響 .....	58
5.3.3	繰り返し高解像度化の適用 .....	59
第 6 章	実験と考察: 投影像に対するフレーム補間 .....	61
6.1	離散的計測の実験 .....	62
6.1.1	計測方法 .....	62
6.1.2	離散的計測の補間結果 .....	64
6.1.3	ラティスモデルの実験評価 .....	64
6.2	連続的計測の実験 .....	66

---

6.2.1	計測方法 .....	66
6.2.2	連続的計測の補間結果 .....	67
6.2.3	ロブスターの実験評価 .....	68
6.3	考察 .....	69
6.3.1	物体の変形量による投影像補間への影響 .....	69
6.3.2	アーチファクトの発生について .....	70
6.3.3	CT ボリュームからの抽出表面の比較 .....	71
第 7 章	結論と今後の展望 .....	73
7.1	高解像度化アルゴリズム .....	74
7.1.1	まとめと結論 .....	74
7.1.2	今後の課題と展望 .....	74
7.2	投影像生成アルゴリズム .....	76
7.2.1	まとめと結論 .....	76
7.2.2	今後の課題と展望 .....	76
謝辞		79
参考文献		81





---

# 図目次

1.1	微細構造を有した造形物 .....	2
1.2	微細構造を用いて設計された部品例 [3].....	3
1.3	積層造形による欠陥の例 .....	3
1.4	CT スキャンの手順 .....	4
1.5	CT スキャン方式 .....	5
1.6	投影値の取得 .....	6
1.7	CT スキャンの視野と分解能のトレードオフの関係.....	7
1.8	耐荷重試験のための 4 次元 CT スキャンの例 [10] .....	8
1.9	4DCT の計測方法 .....	9
1.10	連続的計測の CT スキャン方法 .....	10
1.11	連続的計測による 4DCT の問題点 .....	10
1.12	画像の高解像度化の目的とアプローチ方法 .....	11
1.13	投影像のフレーム補間 .....	12
2.1	チタン製の積層造形サンプル [5] .....	14
2.2	欠陥の検査の概念図 [11] .....	15
2.3	高速回転装置 [12] .....	15
2.4	ゴムの引張試験の様子 of 4D 可視化 [13].....	16
2.5	ニューロンモデル .....	18
2.6	ニューラルネットワーク .....	18
2.7	ReLU 関数 .....	18
2.8	単回帰ニューラルネットワーク .....	20
2.9	畳み込みニューラルネットワークの一部を表す模式図 [14].....	21
2.10	LeNet-5 の CNN 構造 [20] .....	22
2.11	高解像度化法の比較 .....	24

2.12	3 層の CNN の構成 [22].....	25
3.1	提案手法の概略.....	31
3.2	学習データ生成.....	32
3.3	対応する切り出し方の例 .....	32
3.4	回帰モデル生成の流れ .....	33
3.5	CNN の構造 (切り出しサイズ $9 \times 9$ ピクセルの 3 平面の例) .....	34
4.1	提案手法の概略.....	38
4.2	Foward flow と backward flow の可視化 .....	39
5.1	METROTOM 1500.....	43
5.2	X 線 CT 装置の様子.....	43
5.3	X 構造モデルの STL データ .....	44
5.4	X 構造モデルの造形物.....	44
5.5	X 構造モデルのボリュームレンダリング .....	44
5.6	X 構造モデルの CT ボリュームの断面画像.....	44
5.7	X 構造モデルの入力データとリファレンス.....	46
5.8	X 構造モデルの高解像度化結果と拡大画像.....	47
5.9	テトラ構造モデルの STL データ .....	49
5.10	テトラ構造モデルの造形物.....	49
5.11	テトラ構造モデルのボリュームレンダリング .....	49
5.12	テトラ構造モデルの CT ボリュームの断面画像.....	49
5.13	テトラ構造モデルの入力データとリファレンス.....	51
5.14	テトラ構造モデルの高解像度化結果と拡大画像.....	51
5.15	骨モデルの写真.....	53
5.16	骨モデルのボリュームレンダリング.....	53
5.17	骨モデルの CT ボリュームの断面画像 .....	53
5.18	骨モデルの入力データとリファレンス .....	54
5.19	骨モデルの高解像度化結果と拡大画像 .....	55
5.20	X 構造モデルの入力データにおける小領域切り出しサイズ.....	57
5.21	3 種類の学習組数による高解像度化 .....	58
5.22	繰り返し高解像度化の結果.....	59
6.1	ラティスモデルの造形された実物の写真と STL データ .....	62

---

6.2	ラティスモデルの計測に用いた発泡スチロールの台と圧縮による変形 .....	63
6.3	ラティスモデルの離散的計測の様子 .....	63
6.4	ラティスモデルの投影像 .....	63
6.5	ラティスモデルの投影像のフレーム補間結果 (左から, フレーム 2, 3, 4) .....	64
6.6	ラティスモデルの補間した投影像からの CT 再構成結果の 1 断面 .....	65
6.7	水で膨らむ玩具 (左: 膨張前, 右: 膨張後) .....	66
6.8	ロブスターの実物の写真 .....	66
6.9	ロブスターの計測の様子 .....	66
6.10	ロブスターの投影像 .....	67
6.11	ロブスターの投影像のフレーム補間結果 (左から, フレーム 2, 15, 30) .....	67
6.12	ロブスターの CT 再構成結果の 1 断面 .....	68
6.13	ラティスモデルの変形量 .....	69
6.14	ロブスターの変形量 .....	69
6.15	各手法によるオプティカルフロー .....	70
6.16	ロブスターの表面メッシュの計測データ (Frame 1) からの偏差 .....	71
7.1	各種 CT ボリュームの断面画像 .....	75
7.2	投影像補間の二重表示 .....	77
7.3	投影像補間と高解像度化の組み合わせ結果 .....	78
7.4	3つのパラメータを用いた投影像補間 .....	78



---

# 表目次

5.1	計算機環境.....	42
5.2	X 線 CT 装置の仕様.....	43
5.3	X 構造モデルの計測パラメータ.....	44
5.4	X 構造モデルの学習データの種類.....	45
5.5	X 構造モデルの画質評価.....	48
5.6	テトラ構造モデルの計測パラメータ.....	49
5.7	テトラ構造モデルの学習データの種類.....	50
5.8	テトラ構造モデルの画質評価.....	52
5.9	骨モデルの計測パラメータ.....	53
5.10	骨モデルの学習データの種類.....	54
5.11	骨モデルの画質評価.....	56
6.1	ラティスモデルの計測パラメータ.....	63
6.2	ラティスモデルの CT 画像の画質評価.....	65
6.3	ロブスターの計測パラメータ.....	66
6.4	ロブスターの CT 画像の画質評価.....	68

---


# 第 1 章 序論

本章では研究の背景と目的について述べる. 第 1.1 節では本研究で対象とする微細構造の造形物について述べ, 第 1.2 節では X 線 CT スキャンについて述べる. 第 1.3 節では, X 線 CT スキャンの計測技術の応用である 4DCT スキャンについて述べる. 第 1.4 節で本研究の目的について述べる. 最後に, 第 1.5 節では本論文の構成を述べる.

## 1.1 微細構造を有した造形物

### 1.1.1 微細構造

微細構造とは, 類似の疎なパターンが繰り返されている構造である. 積層造形によって造形された, 微細構造を有した造形物を図 1.1 に示す. 強度は保ちつつ, 軽量化されることによって省マテリアル・省エネルギーのものづくりを可能にする素材として注目されている [1]. 微細構造を有した造形物の造形方法としては積層造形技術 (AM : Additive Manufacturing) が一般的である. 部品の軽量化が重視される航空分野などでの応用が期待されている. 図 1.2 に微細構造を用いて設計された部品の例を挙げる.



(a) 3 次元フォトニック結晶 [2]



(b) ランダムな梁構造

図 1.1 微細構造を有した造形物

### 1.1.2 造形方法

従来の製品製造方法の 1 つに, 除去製造法 (subtractive manufacturing) がある. この製造方法は, ある材料のブロックから, 設計した製品形状が残るまで不要な材料を手で削るか, コンピュータ数値制御の工作機械を用いて除去する技術である [4]. しかし, この製造方法では微細で複雑な構造を持つ製品の製造が困難である.

近年の積層造形技術の発展により, 幾何学的に複雑な製品を造形することが可能になった. 積層造形技術には, 造形物の三次元形状データを入力として用いる. その形状を水平にスラ






図 1.2 微細構造を用いて設計された部品例 [3]


イスした層ごとに造形することにより、製品を造形する。

### 1.1.3 積層造形技術の問題

積層造形技術は、層ごとに積み上げて造形物を完成させるため、その際に積層痕、断裂や気泡などといった欠陥が発生する可能性がある (図 1.3)。このような欠陥が発生すると造形物の強度に影響を及ぼす可能性がある。そのため、造形物の内部構造に欠陥が発生しているかを検査する必要がある。そこで、非破壊検査が可能である X 線 CT スキャンが有効な一つの手段であるとされている [5]。



(a) 剥離の例 [6]



(b) 気泡の例 [7]

図 1.3 積層造形による欠陥の例

## 1.2 X線 CT スキャン

### 1.2.1 X線 CT スキャンの概要

CT とは, Computed Tomography の略で, コンピュータ断層撮影を指している [8]. X 線 CT 装置には, 医療用 X 線 CT 装置や産業用 X 線 CT 装置などがある. 産業用 X 線 CT 装置は 1990 年代から機械部品の内部欠陥の非破壊検査を目的として普及してきた [9].

CT スキャンの計測手順は下記に示す. また, 図 1.4 にその流れを示す.

手順 1 装置内の回転台に計測物を設置し, 一回転分の X 線投影像列を得る.

手順 2 投影像列を入力として CT 再構成を行い, CT ボリューム (二次元断面の画像列) を得る.

X 線は計測物に入射すると吸収されながら透過し, 減衰する. 検出器では減衰した X 線の強度を測定する. X 線の透過率の対数を取り  $-1$  を掛けた値である投影値をグレースケール表示した画像が投影像となる. また, 計測物を回転軸周りに 360 度回転させながら, 各投影方向における投影像を得る. 本論文では, 360 度分の投影像列を 1 つのフレームと呼ぶ. 1 つのフレームから CT 再構成を行うことで CT ボリュームが得られる. CT ボリューム上で, 計測物の内部構造を観察することができる. CT ボリュームを 3 次元空間で透過表示することで物体の内部を可視化する表示方法をボリュームレンダリングという.

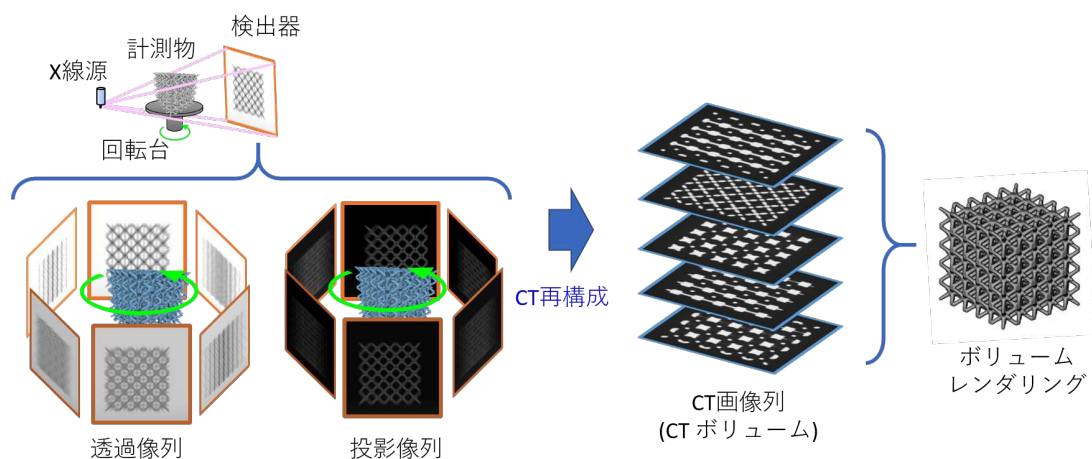


図 1.4 CT スキャンの手順

### 1.2.2 CT スキャン方式

CT スキャンの方法は開発された順に応じて第 1 世代から第 5 世代までに分けられる。本節では、初期の計測方法である第 1 世代と現在一般的に用いられている第 3 世代について原理や特徴を述べる [8]。

第 1 世代は、360 度分の投影角それぞれについて、X 線源と検出器を平行移動させながら X 線の照射と検出を行う方法である。また、Translate / Rotate (T/R) 方式とも呼ばれる (図 1.5(a))。X 線源と検出器は 1 対 1 の関係にあり、平行ビーム投影により計測する。水平方向のみの計測になるため 2 次元のデータ取得となる。この方法では計測時間が長くなってしまったため、時間の短縮のために開発されたスキャン方式が第 3 世代 (Rotate / Rotate (R/R) 方式) である。この方式は、X 線源から回転軸に対して垂直な方向に広がるファンビーム X 線を用いることで、1 投影角あたりの X 線の照射と検出を 1 度にするを可能とした (図 1.5(b))。また、3 次元の計測を行う場合には、鉛直方向の平行移動が必要になる。そこで、図 1.5(c) が示すような、三次元的な広がりを持つコーンビーム X 線と 2 次元的に配置された検出素子を持つフラットパネル検出器を用いることによって、CT スキャンによる 3 次元スキャンがより高速なものとなった。




図 1.5 CT スキャン方式

### 1.2.3 CT 再構成

CT スキャンにおける画像再構成は, 画像化したい領域について, 全方向からの線積分 (投影値列) が与えられた際, 領域内の各画素値を求めることである [8]. CT スキャンにおいて, 求める画素値は X 線の減衰係数  $\mu$  の値である. X 線に沿って減衰係数を加算したものが投影値になる (図 1.6). 図 1.6 のように投影角度  $\theta$  における, 原点からの距離  $t$  の位置の投影値  $p(t, \theta)$  は, 式 (1.1) のように定義される.

$$p(t, \theta) = \int \mu(x, y) ds \quad (1.1)$$

実際の装置の検出器では, 減衰係数の線積分値を直接測定するのではなく, 計測物を透過した線量を測定することになる. 計測物で減衰する前の線量  $I_0$  と検出器で測定する線量  $I_d$  の関係式は, 式 (1.2) となる. 投影値は, 式 (1.3) のように計測物通過前後の線量比に対して対数変換を行うことで求めることができる.

$$\begin{aligned} I_d(t, \theta) &= I_0(t, \theta) \exp \left[ - \int \mu(x, y) ds \right] \\ &= I_0(t, \theta) \exp [-p(t, \theta)] \end{aligned} \quad (1.2)$$

$$p(t, \theta) = -\ln \left[ \frac{I_d(t, \theta)}{I_0(t, \theta)} \right] \quad (1.3)$$




図 1.6 投影値の取得

### 1.2.4 CTスキャンの視野と分解能

CTスキャンでは計測物とX線源との距離によって分解能が決まってくる。CTスキャンの視野と分解能はトレードオフの関係にある(図1.7)。計測物(a)はX線源と計測物の距離が近すぎる例を示しており、計測物(b)はX線源と計測物の距離が適切な位置の例を示している。また、計測物(c)はX線源と計測物の距離が遠すぎる例を示している。計測物(a)、(b)、(c)について視野と分解能の関係について述べる。計測物(a)ではX線源と計測物が近くにあるため、分解能は高くなるが、コーンビームの範囲から計測物がはみ出している。そのため、検出器では、計測物を部分的にしかとらえることができない。計測物(b)では、コーンビームの範囲に収まっているため計測物全体を取得することができる。また、X線源に近いいため分解能も高い。計測物(c)は、コーンビームの範囲に収まっているが、X線源との距離が遠いため分解能が低くなる。このことから、造形物全体をCTスキャンした時に得られるCTボリュームは、部分ごとに分割して高精度にCTスキャンするより、低解像になることがわかる。また、分割してCTスキャンをすると、全体のCTボリュームを取得するには時間がかかってしまう。




図 1.7 CT スキャンの視野と分解能のトレードオフの関係



## 1.3 4DCT スキャン

### 1.3.1 4DCT スキャンの概要

近年では, CT スキャンは物体の変形の観察用途においても需要が高まっている. 通常の CT スキャンでは, 1 回転分のデータから 3 次元データが取得できる. 連続回転スキャンを行うことで, 3 次元データに時間軸を加えた 4 次元データが取得できる. また, 時間的な物体の変化をとらえることも可能になる. この技術を 4 次元 CT スキャン (4DCT スキャン) と呼ぶ. 図 1.8 は実際に使用されている装置の例で, 中央にある計測物を圧縮しながら X 線を照射し, 計測している様子である. 4DCT スキャンによって, 物体の変形を観察することが可能である. 4DCT スキャンの計測方法は 2 種類ある. 1 つのフレームごとに CT スキャンと変形を交互に繰り返しながら計測する離散的計測と, 変形を止めずに計測する連続的計測がある (図 1.9).




図 1.8 耐荷重試験のための 4 次元 CT スキャンの例 [10]

### 1.3.2 4DCT スキャンの流れ

4DCT スキャンの流れについて述べる. 離散的計測は, CT スキャンと変形を交互に繰り返す計測方法であるため, 1 つのフレームごとに静止した物体のデータを取得できる. 連続的計測は, 物体の変形を止めずに複数回回転させながら計測する方法である. そのため, 物体の変形を止めることなく連続したフレームが取得できる (図 1.10). 離散的計測と連続的計測のい




図 1.9 4DCT の計測方法

ずれも、360 度分の 1 つのフレームに対して CT 再構成を行うことで 3 次元の CT ボリュームを得ることができ、計測物の変形を観察することが可能である。

### 1.3.3 4DCT スキャンの問題点

通常 CT スキャンでは、計測中に物体は変形しないため、理論的には投影角が 0 度と 360 度の時で投影像が一致する。しかし、連続的計測の 4DCT スキャンは物体が変形中に計測するため、0 度と 360 度の投影像に差分が生じる (図 1.11)。1 つのフレーム内で差分が生じたまま CT 再構成を行うと CT ボリュームにブレが生じる。そのため、物体の内部構造を高精度で観察することが困難になる。




図 1.10 連続的計測の CT スキャン方法

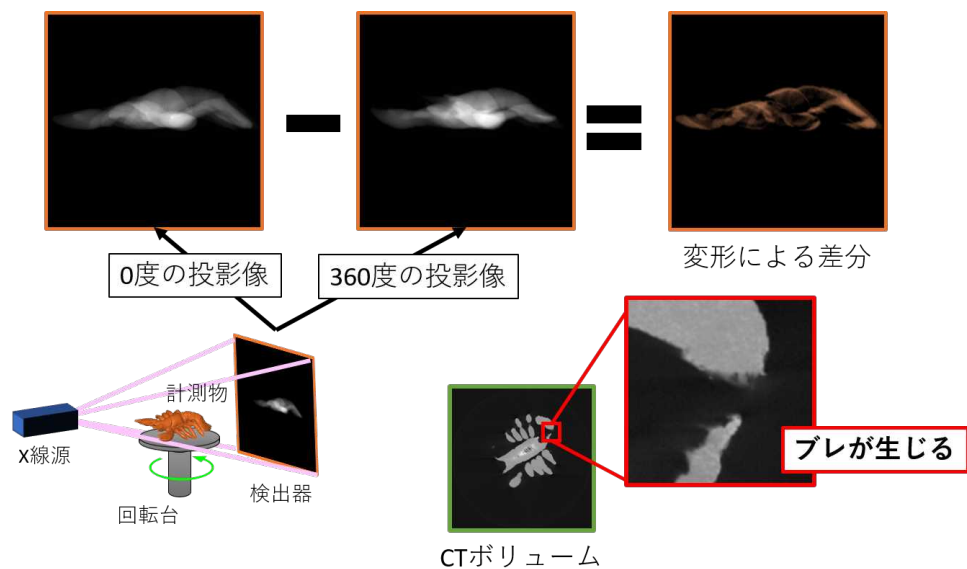


図 1.11 連続的計測による 4DCT の問題点



## 1.4 研究目的

### 1.4.1 欠陥を観察するための CT 画像の鮮明化

CT ボリュームから欠陥を検出するには、画像の鮮明化が必要である。そこで、本研究では欠陥の観察を目標とした画像の鮮明化を目指す。そのためには、低解像度の CT ボリュームでは欠陥の観察が困難であるため、CT ボリュームの高解像度化が必要であると考えられる (図 1.12)。図 1.12 に示すように、本提案では、同一構造の高解像 CT ボリュームと低解像 CT ボリュームの組を用いて、機械学習することで CT ボリュームの高解像度化を目指す。

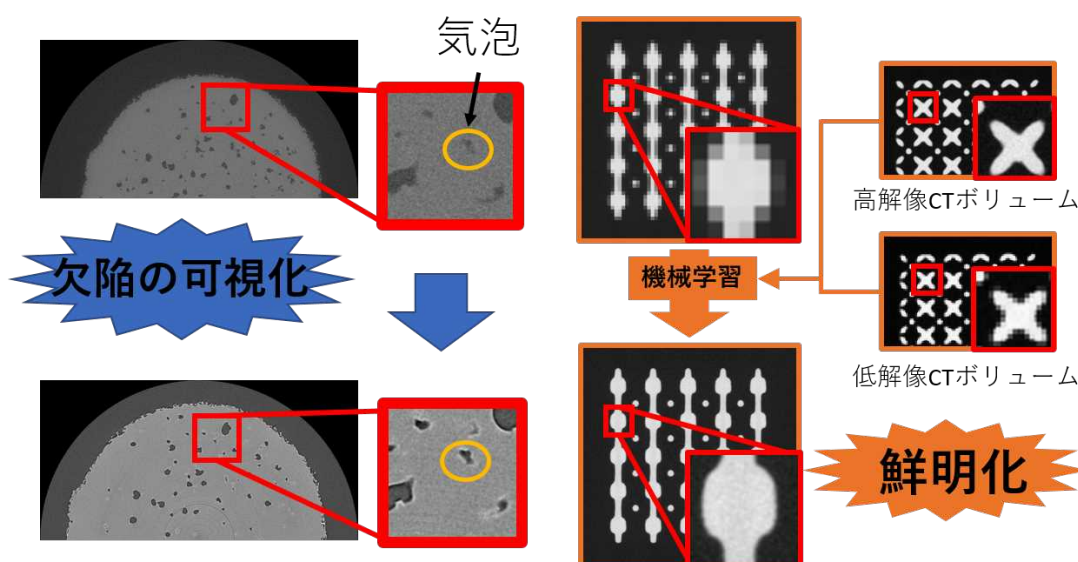


図 1.12 画像の高解像度化の目的とアプローチ方法

### 1.4.2 投影像に対するフレーム補間

4DCT スキャンの実用化のためには、任意の時刻におけるブレの少ない投影像の生成が必要である。そこで、前後の投影像から任意時刻の投影像の生成を目指す (図 1.13)。




図 1.13 投影像のフレーム補間

## 1.5 本論文の構成

本論文は, 本章を含めて全 7 章からなる. 第 1 章では, 研究背景について述べた. 第 2 章では, 第 1 章で述べた CT スキャンが検査に有効であることを示す関連研究を紹介する. また, 本研究で用いる機械学習について述べ, 機械学習を用いた高解像度化の原理や特徴, 4DCT スキャンで用いるフレーム補間についても説明する. 第 3 章では, 1 つ目の提案アルゴリズムである機械学習による低解像 CT ボリュームに対する高解像度化について述べる. 第 4 章では, 2 つ目の提案アルゴリズムである 4DCT スキャンデータの投影像補間による, 任意の時刻の投影像生成アルゴリズムについて述べる. 第 5 章では, 第 3 章で述べた高解像度化アルゴリズムについての実験, 実験結果および考察について述べる. 第 6 章では, 第 4 章で述べた投影像補間アルゴリズムについての実験, 実験結果および考察について述べる. 第 7 章では, 本研究で得られた結果を基に結論を述べ, 今後解決すべき課題及び今後の展望について述べる.

---

## 第 2 章 関連研究

本章では, 本研究と関係のある研究について述べる. 第 2.1 節では, X 線 CT スキャンによる検査の有効性について述べる. 第 2.2 節では, 機械学習について述べ, 第 2.3 節では画像の高解像度化について述べる. 第 2.4 節はフレーム補間の研究について述べる. 第 2.5 節では本研究の位置付けについて述べる.

## 2.1 X線CTスキャンによる検査の有効性

### 2.1.1 X線CTスキャンによる内部欠陥の評価

Pejryd は, 積層造形金属ネットワーク構造の欠陥を評価する際に X 線 CT スキャンが有効であると述べている [5]. 図 2.1 に示す構造は, 造形物の左から右に進むにつれて, スロット幅 (繰り返されているパターンの単位構造中の空洞の大きさ) が広くなる. このような構造の造形物は自動での欠陥評価が難しく, CT 画像をもとに視覚的評価によって欠陥を特定しているのが現状である. しかし, 複雑な内部構造を持つ造形物の場合, 欠陥評価はオペレータや解像度に依存した結果となる. このため, Pejryd は検査プロセスを自動化するため, CT 画像の検査技術の発展が必要だと述べている.




図 2.1 チタン製の積層造形サンプル [5]

金田らは, 内部格子構造を持つ部品について X 線 CT スキャンによる欠陥検出手法を提案している [11]. 具体的には CAD メッシュデータの位相的グラフ構造 (スケルトン) に基づいて, 破断, 歪み, マテリアル粉体の空隙への詰まりを検査する (図 2.2). 以下で詳細を述べる.

#### 破断

スケルトンの辺に注目する. 辺上に十分な数の点をサンプリングし, 端から順に CT ボリュームの CT 値を参照する. CT 値が閾値 (空気と物体との境界の値) を大きく下回る点が存在した場合, 断裂していると判定する (図 2.2(a)).

#### 粉詰まり

スケルトン上の 3 接点で構成される三角形構造があるとき, その三角形に対して重心を計算し, その重心における CT 値を参照する. CT 値が閾値より大きい場合, 粉詰まりと判定する (図 2.2(b)).

### 歪み

断裂と同様にスケルトンを生成する. CT ボリュームと CAD データに対して, それぞれにスケルトンを生成する. CT ボリュームのスケルトンと CAD のスケルトンの辺を比較することで歪みを判定する (図 2.2(c)).




図 2.2 欠陥の検査の概念図 [11]

### 2.1.2 4DCT スキャンによる内部観察

Mashita らは, 軸方法に制御することが可能な 2 つのモーターを用いて, 回転する試料に対して引張試験ができる高速回転装置を開発した. この装置によって, ゴムの断層画像から破断の様子を観察できることを示している [12]. 高速回転装置を図 2.3 に示し, そのゴムの CT スキャンの引張試験によって変形した様子の結果を図 2.4 に示す.

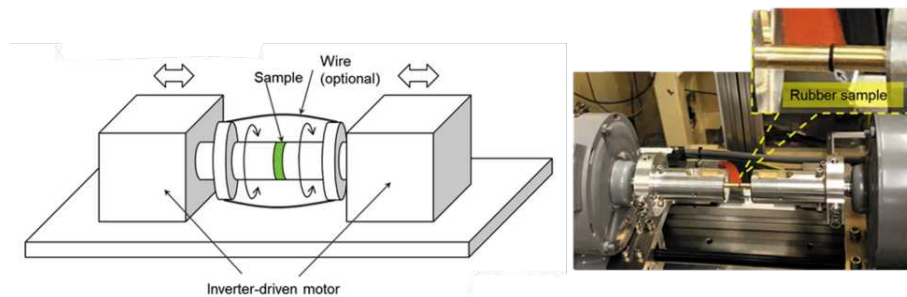


図 2.3 高速回転装置 [12]




図 2.4 ゴムの引張試験の様子の 4D 可視化 [13]

## 2.2 機械学習

本研究では, X 線 CT 画像の高解像度化に機械学習を用いる. 下記に, 機械学習の際に用いるニューラルネットワークについての関連研究を述べる.

### ニューラルネットワーク

パーセプトロンを起源としたニューラルネットワークは, 図 2.5 に示すように脳のニューロン (神経細胞) が構成するネットワークを模したニューロンモデルを用いた数学的モデルである [14]. ニューラルネットワークは, 入力層, 中間層と出力層の 3 つの層で構成される (図 2.6). 各層はニューロンの集合で表現される. 図 2.6 が示すように, 入力データ  $X$  とそれに対する正解データ  $T$  のセットから誤差逆伝播法を用いた学習を行うことによって, 出力データ  $Y$  を目標とする正解データに近づける. 実際の予測時には, 学習済みのネットワークに予測対象を入力し, 一度順方向 (左から右) にネットワークを通過させると予測結果が得られる.

ニューラルネットワークにおいて, 各ニューロンは重みが与えられる. 順方向の伝播は, 前層のニューロンから出力された値に着目しているニューロンの重みを乗算し, 後層のニューロンへと伝搬する. ニューラルネットワークの学習は, すべてのニューロンの重みを適切な値に更新することである. ニューラルネットワークのモデルを式 (2.1) に示す. ここで, 前層の入力変数を  $x$  とし入力数を  $n$  とする. また,  $w$  を重みパラメータと呼び,  $b$  をバイアスパラメータと呼ぶ. さらに,  $a$  は活性化値とする. それが微分可能な非線形活性化関数  $f(a)$  で変換され, 式 (2.2) の  $y$  が求まる. 出力データ  $y$  が次のネットワークの入力データとなり, 後層に伝搬される.

$$a = \sum_{i=1}^n w_i x_i + b \quad (2.1)$$

$$y = f(a) \quad (2.2)$$

本研究の活性化関数は, ReLU (Rectified Linear Unit) [16] を使用する. 近年のニューラルネットワークの活性化関数には ReLU が主に用いられる. ReLU は, 入力データが 0 を超えていれば, その値を出力し, 0 以下ならば 0 を出力する関数である. ReLU 関数は式 (2.3) で表される. 図 2.7 に関数のグラフを示す.

$$f(a) = \begin{cases} a & (0 < a) \\ 0 & (a \leq 0) \end{cases} \quad (2.3)$$




図 2.5 ニューロンモデル

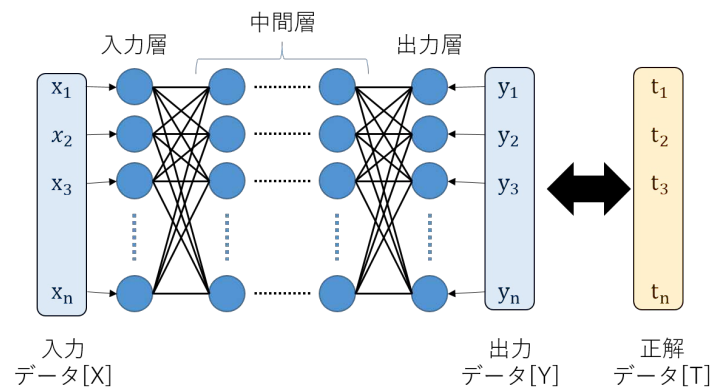


図 2.6 ニューラルネットワーク




図 2.7 ReLU 関数



### 誤差逆伝播法

誤差逆伝播法について述べる. 簡単のために, 以下のネットワークを用いて誤差逆伝播法を説明する. 例として使うネットワークは, 入力データ, 出力データ, 正解データ, 重み, バイアスがそれぞれ一つで構成されている単回帰のニューラルネットワークというものである (図 2.8). このネットワークの損失関数  $E$  を最小にする重み  $w$  とバイアス  $b$  を求める方法が誤差逆伝播法 (back-propagation) である [17]. 入力データを  $x$ , 出力データを  $y$ , 正解データを  $t$ , 損失関数 (誤差関数) を  $E$ , 重みを  $w$ , バイアスを  $b$  とすると, 出力データ  $y$  は式 (2.4) のように表せる.

$$y = wx + b \quad (2.4)$$

また, 損失関数は本例では二乗誤差 (式 (2.5)) を用いる.

$$E = (y - t)^2 \quad (2.5)$$

損失関数を最小化するには次の 2 つのステップが必要である. 1 つ目は, 損失関数の, 重みとバイアスに関する微分の計算である. 2 つ目は, ステップ 1 の微分を用いて重みの更新量を計算することである. 今回の計算では勾配降下法を用いた最適化 (オプティマイザ) を使用する. まず, 損失関数  $E$  を出力データ  $y$  で微分した式を式 (2.6) に示す.

$$\frac{\partial E}{\partial y} = 2(y - t) \quad (2.6)$$

次に, 損失関数  $E$  を, 重み  $w$  とバイアス  $b$  で微分したものを式 (2.7), (2.8) に示す.

$$\frac{\partial E}{\partial w} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial w} = \frac{\partial E}{\partial y} x \quad (2.7)$$

$$\frac{\partial E}{\partial b} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial b} = \frac{\partial E}{\partial y} \quad (2.8)$$

最後に, 重みの更新量は式 (2.9) に示すように定める.  $\eta$  は学習率と呼ばれる. 学習率は定数で, 重みの更新量の急激な変化を抑える係数である.

$$\Delta w = -\eta \frac{\partial E}{\partial w} \quad (2.9)$$




図 2.8 単回帰ニューラルネットワーク

提案手法では, 損失関数に平均二乗誤差 (MSE) を使用し, 最適化 (オプティマイザ) は RMSprop [18] を用いる. 下記に, 平均二乗誤差と RMSprop について述べる.

まず, 平均二乗誤差について述べる. 式 (2.5) で用いた損失関数は, 変数が一つのニューラルネットワークであったため単項の二乗誤差を用いている. 本研究では, 出力データ, 正解データともに変数が複数であるため平均二乗誤差を用いる. 平均二乗誤差は, 式 (2.10) で表される. また,  $k$  は変数の数である.

$$E = \frac{1}{n} \sum_k (y_k - t_k)^2 \quad (2.10)$$

次に, RMSprop について述べる. RMSprop は, 勾配降下法よりも高速なオプティマイザである. RMSprop の特徴は, 注目点の近傍の勾配のみを用いて最適化することで, 勾配降下法で起きる大域的最適解に収束しない問題を解決できることである [19]. RMSprop による重みの更新量は, 式 (2.11), 式 (2.12) で表される. ここで  $t$  は勾配の更新回数,  $v$  は更新量の勾配,  $\varepsilon$  は分母の発散防止定数である. また,  $\alpha$  は過去の勾配  $v_{t-1}$  の影響を調節する定数である.

$$v_t = \alpha v_{t-1} + (1 - \alpha) \left( \frac{\partial E}{\partial w^{(t)}} \right)^2 \quad (2.11)$$

$$\Delta w^{(t)} = -\frac{\eta}{\sqrt{v_t + \varepsilon}} \left( \frac{\partial E}{\partial w^{(t)}} \right) \quad (2.12)$$

### 畳み込みニューラルネットワーク

画像に対して機械学習を適用することを考えた時, ニューラルネットワークでは近傍の画素の情報を反映させにくいため, 近傍の画素情報を扱うことができる畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) が用いられる. 畳み込みニューラルネットワークは, 画像の小さな部分領域だけに依存する局所的な特徴を抽出し学習に利用する [20]. 畳み込みニューラルネットワーク構造の模式図を図 2.9 に示す.




図 2.9 畳み込みニューラルネットワークの一部を表す模式図 [14]

中間層の出力は, 特徴マップ (feature map) という. 一般的に畳み込み層には複数の特徴マップがあり, この数をチャンネル数と呼び, それぞれが独自の重みとバイアスのパラメータを持っている. 損失関数の勾配を評価して誤差逆伝播法を用いれば, RMSprop を用いた最適化によりネットワーク全体を最適化できる.

具体的な例として, 畳み込みニューラルネットワークの代表例である LeNet-5[20] について以下に述べる. LeNet-5 を図 2.10 に示す. この構造は全 8 層で構成されている.

LeNet-5 の構造

- 第0層 入力データサイズ:  $32 \times 32$ , チャンネル数: 1
- 第1層 カーネルサイズ:  $5 \times 5$ , チャンネル数: 6, 活性化関数: tanh
- 第2層 マックスプーリング:  $2 \times 2$ , チャンネル数: 6
- 第3層 カーネルサイズ:  $5 \times 5$ , チャンネル数: 16, 活性化関数: tanh
- 第4層 マックスプーリング:  $2 \times 2$ , チャンネル数: 16
- 第5層 全結合: 120, 活性化関数: tanh
- 第6層 全結合: 84, 活性化関数: tanh
- 第7層 出力データ: 10, 活性化関数: softmax




図 2.10 LeNet-5 の CNN 構造 [20]

## 2.3 画像の高解像度化に関する研究

本節では、機械学習を用いない高解像度化について述べてから機械学習を用いた高解像度化について述べる。各手法の高解像度化結果画像を図 2.11 に示す。図 2.11(a) は元画像であり、リファレンスと呼ぶ。リファレンスの解像度は、 $416 \times 420$  ピクセルである。図 2.11(b) はリファレンスをダウンサンプリングしたもので、これを入力データとして高解像度化する。入力データの解像度は、 $208 \times 210$  ピクセルで、高解像度化の結果  $416 \times 420$  ピクセルとなる。

### ニアレストネイバー法

ニアレストネイバー法は、画像の補間法として、最も簡単なものである [21]。拡大した画像の画素値を最近傍の元の画像の画素値とする方法である。結果画像を図 2.11(c) に示す。ニアレストネイバー法では、エッジがギザギザになりジャギーが発生しやすい。

### バイリニア補間法

バイリニア補間法は、拡大した画像の画素に最も近い  $2 \times 2$  画素 (4 画素) の画素値を使って、線形補間する方法である [21]。結果画像を図 2.11(d) に示す。バイリニア補間法では、ジャギーは目立たなくなるが、物体と空気の境目がわかりにくい。

### バイキュービック補間法

バイキュービック補間法は、 $4 \times 4$  の近傍領域 (16 画素) の画素値を用いて補間する方法である [21]。バイキュービック補間法は式 (2.13) で表される。ここで、求めたい位置  $(x, y)$  の値  $I(x, y)$  の周りの 16 点の画素値を  $f_{11}, f_{12}, \dots, f_{44}$  とする。また、関数  $h(x), h(y)$  は、sinc 関数を 3 次元多項式で近似するものである。結果画像を図 2.11(e) に示す。バイキュービック補間法では、図 2.11(d) と比較すると物体と空気の境目がはっきりしている。

$$I(x, y) = \begin{pmatrix} h(x_1) & h(x_2) & h(x_3) & h(x_4) \end{pmatrix} \begin{pmatrix} f_{11} & f_{12} & f_{13} & f_{14} \\ f_{21} & f_{22} & f_{23} & f_{24} \\ f_{31} & f_{32} & f_{33} & f_{34} \\ f_{41} & f_{42} & f_{43} & f_{44} \end{pmatrix} \begin{pmatrix} h(y_1) \\ h(y_2) \\ h(y_3) \\ h(y_4) \end{pmatrix} \quad (2.13)$$

### SRCNN

CNN を用いた高解像度化に SRCNN がある。SRCNN は 2014 年に Dong らによって発表されたディープラーニングによる超解像度化法である [22]。SRCNN は CNN を用いて低解像度の画像と高解像度の画像の関係性を学習することにより、より鮮明な画質の画像を得る

方法である [23][24]. SRCNN は以下の図 2.12 のような 3 層の CNN で構成されている. 低解像度の画像をバイキュービック補間法で拡大した画像を入力データとする. SRCNN での学習データである入力データと正解データは同じ解像度である. 入力データをこのネットワークに適用することで高画質な画像が出力される (図 2.11(f)).

ネットワークの損失関数には, 低解像度の画像を高解像度化した画像とリファレンス (正解画像) の平均二乗誤差 (MSE) が一般的に使われる. この誤差が小さくなるようにネットワークの学習を行う. SRCNN の学習結果は, バイリニア補間やバイキュービック補間に比べて品質の高い画像になる (図 2.11).




図 2.11 高解像度化法の比較




図 2.12 3層の CNN の構成 [22]

## 2.4 フレーム補間

フレーム補間とは、フレーム数の少ない動画に対して新たなフレームを挿入することで、動きを滑らかにする技術である。前後のフレームから動きなどの変化を予測して新しいフレームを生成し、見かけ上のフレームを生成する。フレーム補間は、一般的にオプティカルフローが用いられることが多い [25]。オプティカルフローとは、画像中の物体を追跡するために考えられたアイデアで、物体の移動速度をベクトルで表したものである。そこで、代表的なオプティカルフローの算出方法について説明する。

### Lucas-Kanade 法

1981 年に Lucas と Kanade によって提案された、オプティカルフローを求める手法である [26]。この手法は、注目画素に対してその周辺の画素位置でも同じように動きがあると仮定して変位量が最小になるようにオプティカルフローを算出する。時刻  $t$  で、座標  $(x, y, t)$  に映っていたものが、時刻  $t + \Delta t$  で、座標  $(x + \Delta x, y + \Delta y, t + \Delta t)$  に変位したとき、変位前の画素値  $I(x, y, t)$  は、変位後の画素値  $I(x + \Delta x, y + \Delta y, t + \Delta t)$  に一致する。

$$I(x, y, t) = I(x + \Delta x, y + \Delta y, t + \Delta t) \quad (2.14)$$

右辺をテイラー展開する。

$$I(x + \Delta x, y + \Delta y, t + \Delta t) = I(x, y, t) + \frac{\partial I}{\partial x} \Delta x + \frac{\partial I}{\partial y} \Delta y + \frac{\partial I}{\partial t} \Delta t + \dots \quad (2.15)$$

よって

$$I(x, y, t) \approx I(x, y, t) + \frac{\partial I}{\partial x} \Delta x + \frac{\partial I}{\partial y} \Delta y + \frac{\partial I}{\partial t} \Delta t \quad (2.16)$$

$$\Rightarrow \frac{\partial I}{\partial x} \Delta x + \frac{\partial I}{\partial y} \Delta y + \frac{\partial I}{\partial t} \Delta t = 0 \quad (2.17)$$

両辺を  $\Delta t$  で割ると、以下が成り立つ。

$$\frac{\partial I}{\partial x} \frac{\Delta x}{\Delta t} + \frac{\partial I}{\partial y} \frac{\Delta y}{\Delta t} + \frac{\partial I}{\partial t} = 0 \quad (2.18)$$

次に  $\frac{\partial I}{\partial x}$ ,  $\frac{\partial I}{\partial y}$ ,  $\frac{\partial I}{\partial t}$  を  $I_x$ ,  $I_y$ ,  $I_t$  と書く。オプティカルフロー (速度ベクトル)  $\mathbf{v} = (v_x, v_y)^T = \left( \frac{\Delta x}{\Delta t}, \frac{\Delta y}{\Delta t} \right)^T$  を求める。式 2.18 は以下のように置き換えられる。

$$I_x v_x + I_y v_y + I_t = 0 \quad (2.19)$$



周辺の画素  $q_i$  のオプティカルフロー  $v_x$  と  $v_y$  も同様に動くことから次が成り立つ.

$$\begin{cases} I_x(q_1)v_x + I_y(q_1)v_y = -I_t(q_1) \\ I_x(q_2)v_x + I_y(q_2)v_y = -I_t(q_2) \\ \vdots \\ I_x(q_n)v_x + I_y(q_n)v_y = -I_t(q_n) \end{cases} \quad (2.20)$$

$$A = \begin{pmatrix} I_x(q_1) & I_y(q_1) \\ I_x(q_2) & I_y(q_2) \\ \vdots & \vdots \\ I_x(q_n) & I_y(q_n) \end{pmatrix}, b = \begin{pmatrix} -I_t(q_1) \\ -I_t(q_2) \\ \vdots \\ -I_t(q_n) \end{pmatrix}$$

とにおいて上記の式をまとめると, 以下のようにかける.

$$A\mathbf{v} = b \quad (2.21)$$

最小二乗法によって  $\mathbf{v}$  が求まる.

$$A^T A \mathbf{v} = A^T b \quad (2.22)$$

$$\mathbf{v} = (A^T A)^{-1} A^T b \quad (2.23)$$

### Horn-Shunck 法

1981 年に Horn と Shunck によって提案されたオプティカルフローを求める手法である [27]. この手法は, 画像の滑らかさに制約を設けて, 移動距離が最小になるようにオプティカルフロー  $\mathbf{v}$  を求める. 移動にかかるエネルギーを  $E(\mathbf{v})$  とし, 以下のように定義する. Horn-Shunck 法では  $E(\mathbf{v})$  を最小化することでオプティカルフローを求める.

$$E(\mathbf{v}) = E_{data}(\mathbf{v}) + \alpha E_{smooth}(\mathbf{v}) \quad (2.24)$$

ここで,  $E_{data}(\mathbf{v})$  は, 画素値の輝度差を表しており, Lucas-Kanade 法同様  $I_x v_x + I_y v_y + I_t$  が 0 に近いほど, 最適な  $\mathbf{v}$  とする. 注目画素の近傍  $\Omega$  について  $(I_x v_x + I_y v_y + I_t)^2$  を足し合わせた値で,  $E_{data}(\mathbf{v})$  は以下のように定義する.

$$E_{data}(\mathbf{v}) = \int \int_{\Omega} (I_x v_x + I_y v_y + I_t)^2 dx dy \quad (2.25)$$

滑らかさの制約である  $E_{smooth}(\mathbf{v})$  は以下のように定義する.

$$E_{smooth}(\mathbf{v}) = \int \int_{\Omega} |\nabla v_x|^2 + |\nabla v_y|^2 dx dy \quad (2.26)$$

式 (2.25, 2.26) から  $\mathbf{v}$  の変化量が小さくなると  $E(\mathbf{v})$  が小さくなる. したがって, 輝度の差が少なく, 小さな変化量となる  $\mathbf{v}$  が最適になる.

## 2.5 本研究の位置付け

### 2.5.1 機械学習による高解像度化

SRCNN での学習データは, 入力画像をそのままの解像度で用いるため, 画像全体の特徴から学習といえる. そのため, 大域的手法となり, 造形物の微細な特徴がとらえにくい. 本研究では, 微細な構造の特徴を残したまま高解像度化するために, 形状特徴が 3 次元的に十分にとらえられる小領域を入力として, 高解像度化する方法を提案し, より高精度な高解像度化を目指す.

### 2.5.2 投影像に対するフレーム補間

Lucas-Kanade 法や Horn-Shunck 法では, 周辺情報の制約や滑らかさの制約があるため投影像データに対して実用的ではない. そのため, 投影像の勾配に応じて特徴を検出する必要がある. 本研究では, 生成したい任意時刻の前後のフレームを入力データとして, 入力データの勾配を求め, 勾配ベクトルを用いてオプティカルフローを算出する. オプティカルフローによって物体に変形があるかを判定して, 投影像補間をすることで求めたい時刻の投影像の画素値を計算する.

---

## 第 3 章 高解像度化アルゴリズム

本章では, 1 つ目の提案アルゴリズムである機械学習による低解像 CT ボリュームの高解像度化について述べる. 第 3.1 節では, 本論文で提案する手法の概略を述べる. 第 3.2 節では, 三次元の学習データである高解像 CT ボリュームと低解像 CT ボリュームの生成方法について述べる. 第 3.3 節では, 第 3.2 節で生成した学習データをもとにした回帰モデルの作成方法について述べる. 最後に第 3.4 節では, 画像の評価方法について述べる.

### 3.1 提案手法の概要

造形物全体の低解像 CT ボリュームを入力として, 造形物全体の高解像 CT ボリュームを生成する手法を提案する (図 3.1). 3 次元では複雑な画像になってしまうため, 2 次元での例を図 3.1 に記す. 本手法では, 繰り返しパターンからなる積層造形物を対象としている. 本手法によって高解像度化された CT ボリュームは,  $x$ ,  $y$ ,  $z$  方向にそれぞれ 2 倍の解像度になる. また, 生成された高解像 CT ボリュームを新たに入力の CT ボリュームとして使用することで, さらに高解像な CT ボリュームを得られる.

学習データとして全体の CT ボリュームを用いるのではなく, 一部の領域を用いる. 図 3.1 の訓練データから赤矢印で切り出された画像のように, 機械学習で用いる学習データを取得する. 互に対応する, 部分的な低解像 CT ボリュームと高解像 CT ボリュームを入力データと正解データに設定して機械学習を行う. 機械学習には, CNN を用いてモデルを生成する. 本論文では, 学習データに用いる部分的な低解像 CT ボリュームを「訓練用入力データ」とし, 部分的な高解像 CT ボリュームを「訓練用正解データ」とする. また, CNN により出力されたデータを「訓練用出力データ」とし, 生成したモデルを本論文では「回帰モデル」と呼ぶ.

CT ボリュームの高解像度化は図 3.1 に示すように, 全体の低解像 CT ボリュームが入力となり, 出力として全体の高解像 CT ボリュームが生成される. 回帰モデルの入力には, 全体の低解像 CT ボリュームから一部の領域を切り出した部分的な低解像 CT ボリューム (部分入力データ) を用いる. また, 回帰モデルの出力は部分的な高解像 CT ボリューム (部分出力データ) となる. 最後に, 生成された高解像度 CT ボリュームで欠陥を観察する.

高解像度化アルゴリズムは次の 4 段階からなる.

高解像度化アルゴリズム

1. 訓練データから学習データを生成
2. CNN の構築
3. 回帰モデルの作成
4. 全体の低解像 CT ボリュームから全体の高解像 CT ボリュームを生成

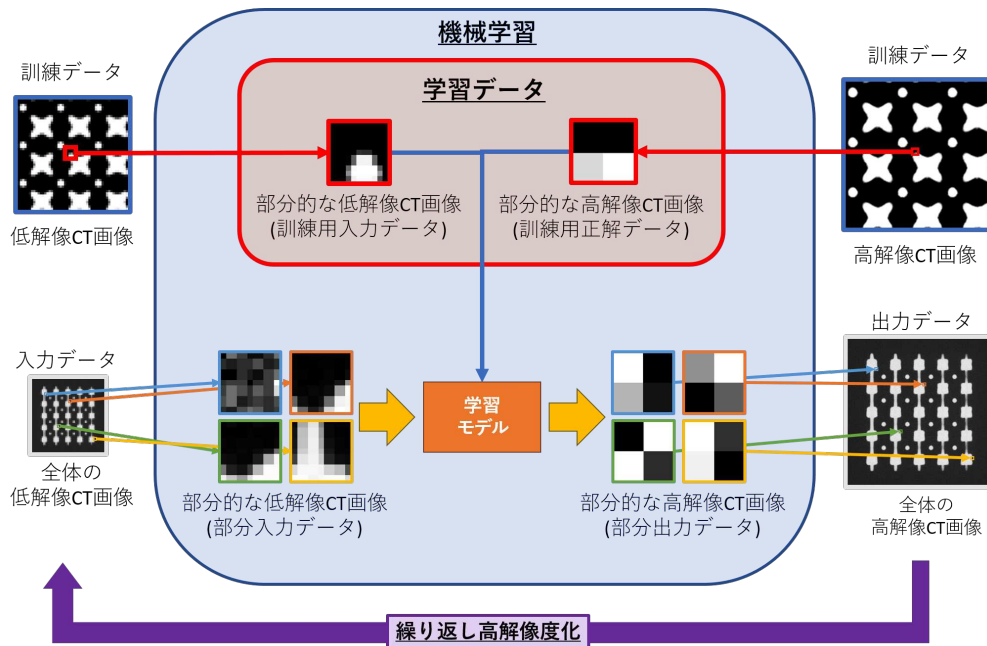


図 3.1 提案手法の概略

## 3.2 学習データの生成

本節では, CNN で学習させるための学習データの生成方法を述べる.

今回使用する訓練データは, 高解像 CT ボリュームが低解像 CT ボリュームの  $x, y, z$  方向にそれぞれ 2 倍の解像度であると仮定する. 訓練データからの部分的な CT ボリュームの切り出し方を, 図 3.2 に示す. 高解像 CT ボリュームを  $2 \times 2 \times 2$  ボクセルに切り出し訓練用正解データを生成する. また, 低解像 CT ボリュームは形状特徴を十分にとらえられる大きさで切り出し訓練用入力データを生成する. 形状特徴を 3 次元的にとらえるため, 各ボクセルを中心とした  $x-y, y-z, z-x$  の平面の小領域で切り出す.

訓練用正解データと訓練用入力データは互いに対応関係にある. その対応関係の 2 次元の例を図 3.3 に示す. この例は,  $5 \times 5$  ピクセルの画像を低解像 CT 画像とし, 高解像 CT 画像は  $10 \times 10$  ピクセルの画像である. また, 低解像 CT 画像は,  $3 \times 3$  ピクセルで切り出したものである.

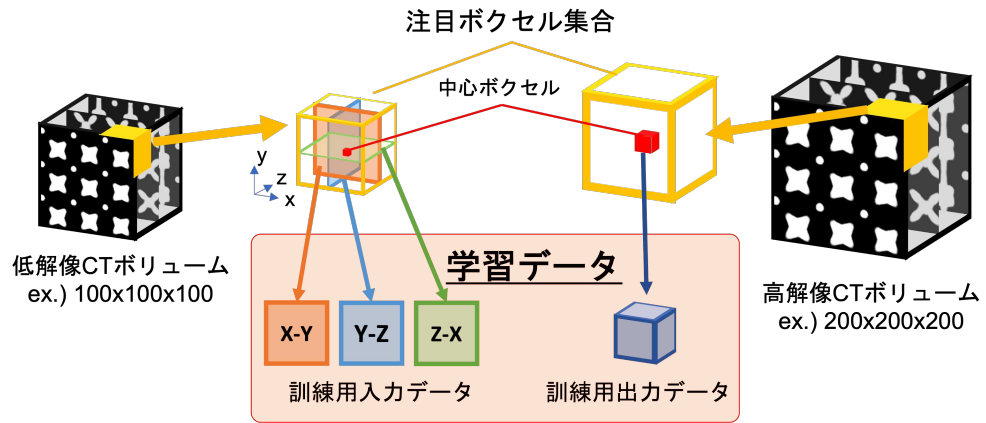


図 3.2 学習データ生成

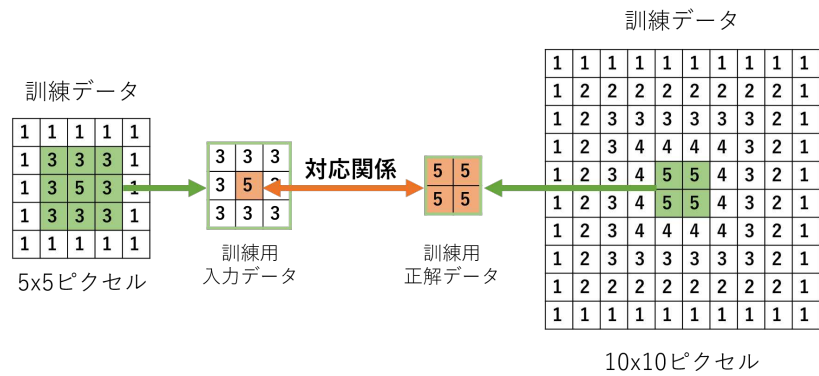


図 3.3 対応する切り出し方の例

### 3.3 ネットワーク構築

回帰モデルを生成する流れを図 3.4 に示す。

回帰モデル生成の流れ

1. 訓練用入力データから CNN により訓練用出力データを生成する
2. 訓練用出力データと訓練用正解データから損失関数によって損失値を求める
3. オプティマイザによって損失値から重みの更新量を求める
4. CNN の重みを更新する
5. 1 から 4 を繰り返して CNN の重みを損失値が収束するまで学習する

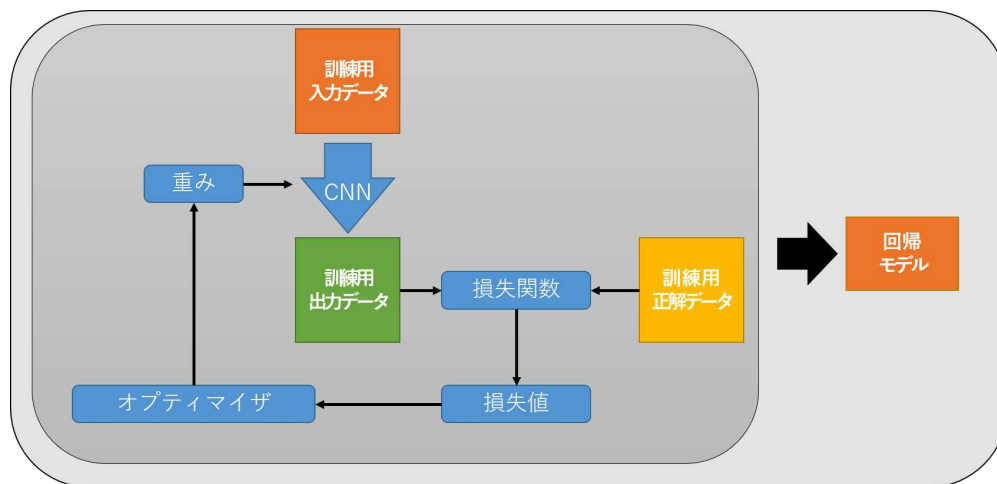


図 3.4 回帰モデル生成の流れ

CNN の構造を図 3.5 に示す。例として、切り出しサイズ  $9 \times 9$  ピクセルの 3 平面を訓練用入力データとする。CNN の構造は、以下の 5 層からなる。第 0 層が訓練用入力データで平面の数であるチャンネル数は 3 となる、第 1 層はサイズが  $3 \times 3$  ピクセルの畳み込みカーネル 16 種を用いて第 0 層の入力データを畳み込み、その結果チャンネル数は 16 となる。同様に、第 2 層はカーネルサイズが  $3 \times 3$  ピクセルでチャンネル数は 8、第 3 層はカーネルサイズが  $3 \times 3$  ピクセルでチャンネル数は 8、第 4 層は訓練用出力データで、カーネルサイズが  $2 \times 2 \times 2$  ボクセルでチャンネル数は 1 とする。なお、各層の出力データを活性化させる活性化関数は全層 ReLU (Rectified Linear Unit) [16] を用いる。

訓練用出力データと訓練用正解データから損失値を求める損失関数は、平均二乗誤差 (MSE) を使用する。また、重みの更新量を更新するオプティマイザには、RMSprop [18] を用

いる。

#### CNN の構造

- 第 0 層 入力データサイズ:  $9 \times 9$ , チャンネル数: 3
- 第 1 層 カーネルサイズ:  $3 \times 3$ , チャンネル数: 16, 活性化関数: ReLU
- 第 2 層 カーネルサイズ:  $3 \times 3$ , チャンネル数: 8, 活性化関数: ReLU
- 第 3 層 カーネルサイズ:  $3 \times 3$ , チャンネル数: 8, 活性化関数: ReLU
- 第 4 層 出力データサイズ:  $2 \times 2 \times 2$ , チャンネル数: 1, 活性化関数: ReLU




図 3.5 CNN の構造 (切り出しサイズ  $9 \times 9$  ピクセルの 3 平面の例)

## 3.4 画像の評価法

高解像度化された画像に用いる画像の評価法は PSNR (Peak Signal to Noise Ratio) [28] と SSIM (Structural Similarity) [29] を用いた. これらの方法は画像の劣化を表す代表的な指標で, それぞれ次のように定義される.

### PSNR

PSNR はリファレンス画像と評価画像の画素値の差を取り評価する手法である. この指標が高いほど品質が良い. PSNR の定義式を式 (3.1) に示す.  $\text{MAX}_I$  はリファレンス画像に含まれる画素値の最大値である. MSE (Mean Squared Error) は, 式 (3.2) で定義される.  $x^i, y^i$  はそれぞれリファレンス画像と評価画像の画素値である. また,  $n$  は対象とする画像中の画素値の数である.



$$\text{PSNR} \equiv 10 \times \log_{10} \frac{\text{MAX}_I^2}{\text{MSE}} \quad (3.1)$$

$$\text{MSE} \equiv \frac{1}{n} \sum_{i=1}^n (y^i - x^i)^2 \quad (3.2)$$

## SSIM

PSNR よりも主観評価に近いものとして開発された客観的評価指標である [29].  $x$  をリファレンス画像の注目領域の画素集合,  $y$  を評価画像の対応する領域の画素集合とする. また,  $\mu_x, \mu_y$  は注目領域の平均画素値,  $\sigma_x, \sigma_y$  は注目領域の標準偏差,  $\sigma_{xy}$  は  $x$  と  $y$  の共分散である.

SSIM は, 以下の 3 つの要素が比較画像においてリファレンス画像からどのくらい変化したかを評価している.

- 画素値の変化  $l(x, y)$
- コントラストの変化  $c(x, y)$
- 構造の変化  $s(x, y)$

これら 3 つの要素を用いて SSIM を, 式 (3.3) で定義する.

$$\begin{aligned} \text{SSIM}(x, y) &= [l(x, y)]^\alpha \cdot [c]^\beta \cdot [s(x, y)]^\gamma \\ \alpha &= \beta = \gamma = 1 \\ C_3 &= C_2/2 \end{aligned} \quad (3.3)$$

各要素は次のように定義される. 画素値の変化  $l(x, y)$  は, 式 (3.4) で定義される. 平均画素値を用いて評価する. ここで,  $C_1$  は定数で,  $C_1 = (K_1 L)^2$  である.  $K_1$  は定数で, 0.01 とすることが多い.  $L$  はリファレンス画像の画素値の最大値である.

$$l(x, y) = \frac{(2\mu_x\mu_y + C_1)}{(\mu_x^2 + \mu_y^2 + C_1)} \quad (3.4)$$

コントラストの変化  $c(x, y)$  は, 画素値の最大値と最小値がどのくらい離れているかを表す. 画素値の分布の広がり具合を表す分散と標準偏差を用いて式 (3.5) で評価する. ここで,  $C_2$  は定数で,  $C_2 = (K_2 L)^2$  である.  $K_2$  は定数で, 0.03 とすることが多い.  $L$  はリファレンス画像の画素値の最大値である.

$$c(x, y) = \frac{(2\sigma_x\sigma_y + C_2)}{(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (3.5)$$

構造の変化  $s(x, y)$  は、画像内に写っている物体の構造に依存するものなので、画素値やコントラストの変化に影響されないよう、式 (3.6) で評価する。ここで、 $C_3$  は、 $C_3 = C_2/2$  である。

$$s(x, y) = \frac{(2\sigma_{xy} + C_3)}{(\sigma_x\sigma_y + C_3)} \quad (3.6)$$

以上の要素から、SSIM は式 (3.7) で計算できる。

$$\text{SSIM}(x, y) \equiv \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (3.7)$$

---

## 第 4 章 投影像に対するフレーム補間

本章では, 2 つ目の提案アルゴリズムである投影像に対する投影像補間について述べる. 第 4.1 節では, 本論文で提案する手法の概略を述べる. 第 4.2 節では, 投影像補間に用いるオプティカルフローの算出について述べる. 第 4.3 節では, オプティカルフローを用いた投影像補間について述べる.

## 4.1 提案手法の概要

4DCT スキャンの投影像を入力として, 任意時刻の中間投影像を生成する手法を提案する (図 4.1). 4DCT スキャンは, 連続して複数回回転して CT スキャンを行うため, 1 周を 1 フレームとして複数フレームの投影像列を取得できる. 本手法では, CT スキャン時に計測物の大きな変形がない場合を対象としている. 本手法によって中間投影像を 1 フレーム分生成することで, CT 再構成により 3D データの取得が可能となる.

入力データは, 図 4.1 に示すように求めたい時刻  $t_n$  の前後のフレーム, Frame (n-1) と Frame (n+1) からなる. 青矢印のように, これらのフレームの同じ投影角  $\theta$ , 位置  $(x, y)$  の画素において投影値の勾配ベクトルを用いてオプティカルフローを計算する. オプティカルフローを基に変形の影響があるか否かを判定し, 影響があれば投影像補間を行うことで時刻  $t_n$  の中間投影像を生成する.

投影像補間アルゴリズムは以下のようになる.

投影像補間アルゴリズム

全投影角について以下を行う.

1. 前後のフレームに対して勾配ベクトルを用いてオプティカルフローを算出する.
2. オプティカルフローを用いて投影像補間を行う.

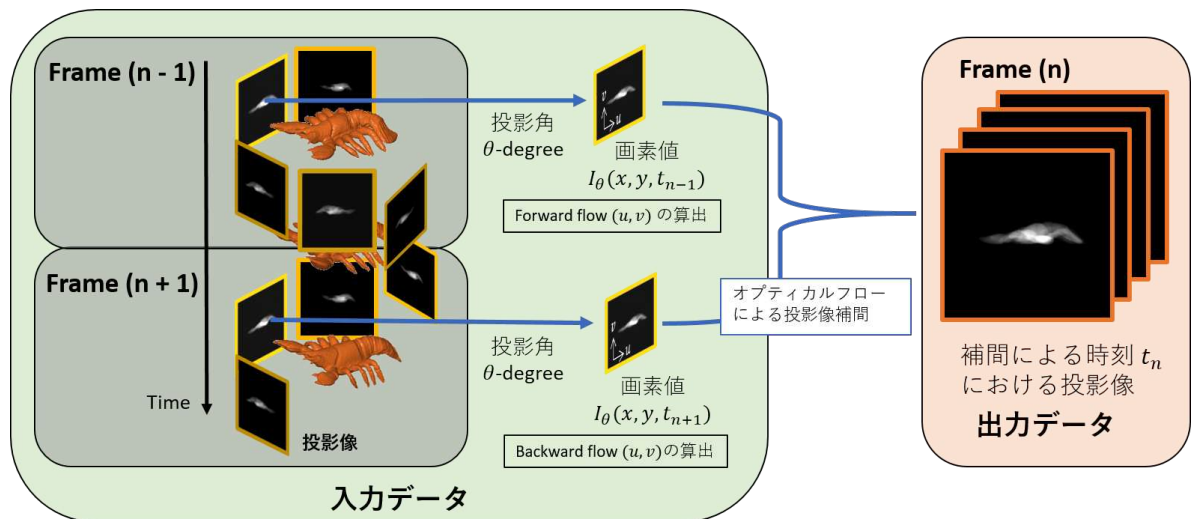


図 4.1 提案手法の概略

## 4.2 投影値の勾配を用いたオプティカルフローの算出

本節では, 前後の投影像のフレームの勾配ベクトルからオプティカルフローを取得する方法を示す. 投影像補間では, 投影像間での動きの特徴の抽出を行い, 得られた動きの特徴に基づき中間フレームにおける投影像を生成する. 画像間の動きの特徴を抽出する方法の一つとしてオプティカルフローがある. 時刻  $t_{n-1}$  の投影像中の位置  $(x, y)$  におけるオプティカルフローを, 式 (4.1) のベクトル  $(u, v)$  で定義する. ここで,  $h$  は投影像のピクセルのサイズである.

Frame (n-1) の投影角  $\theta$ ・位置  $(x, y)$  の画素値の  $x$  方向の中心差分  $dI_{n-1}/dx$  と  $y$  方向の中心差分  $dI_{n-1}/dy$  から, オプティカルフロー  $(u, v)$  は  $(dI_{n-1}/dy, -dI_{n-1}/dx)$  と定義される. 本稿では, Frame (n-1) のオプティカルフローを forward flow, Frame (n+1) のオプティカルフローを backward flow と呼ぶ (図 4.2).

$$\begin{cases} u = dI_{n-1}/dy = \frac{I(x, y+1, t_{n-1}) - I(x, y-1, t_{n-1})}{2h} \\ v = -dI_{n-1}/dx = -\frac{I(x+1, y, t_{n-1}) - I(x-1, y, t_{n-1})}{2h} \end{cases} \quad (4.1)$$




図 4.2 Forward flow と backward flow の可視化

### 4.3 投影像補間

本節では, 第4.2節で求めたオプティカルフロー  $(u, v)$  を基に物体の変形の影響があるかを判定し, 影響があれば投影像補間を行う手法を説明する. Forward flow と backward flow の差分ベクトルのノルムが閾値以上であればこの点で変化があったと考え, 画素値  $I_\theta(x, y, t_{n-1})$  と  $I_\theta(x, y, t_{n+1})$  の時刻に関する線形補間を行い, 時刻  $t_n$  における画素値  $I_\theta(x, y, t_n)$  を計算する. 差分ベクトルのノルムが閾値以下の場合には変化がない画素とし, 前の時刻の画素値  $I_\theta(x, y, t_{n-1})$  を  $I_\theta(x, y, t_n)$  とする. 補間による画素値の計算の式を式(4.2)に示す. ここで  $\Delta t$  は求めたいフレームの時刻  $t_n$  とひとつ前のフレームの時刻  $t_{n-1}$  の差分である.

$$I(x, y, t_n) = (1 - \Delta t)I_\theta(x, y, t_{n-1}) + \Delta t I_\theta(x, y, t_{n+1}) \quad (4.2)$$

---

## 第 5 章 実験と考察: 高解像度化アルゴリズム

本章では, 第 3 章で提案した高解像度化アルゴリズムを複数のデータに適用した結果について述べる. まず, 第 5.1 節では, 実験の手順や計算機環境について述べる. 第 5.2 節では, 各入力データに対する高解像度化の結果について述べる. 最後に第 5.3 節で実験結果の考察を行う.

## 5.1 実験手順

以下に実験の手順について示す.

- 1 CT ボリュームから学習データを生成する.
- 2 提案手法で示した CNN 構造で学習させ回帰モデルを生成する.
- 3 回帰モデルに対して, 低解像 CT ボリュームを入力とし高解像度化する.
- 4 ステップ 3 で高解像度化された CT ボリュームをステップ 3 の入力として繰り返し高解像度化する.

### 5.1.1 実験環境

基本的にプログラミングは Python を使用した. 機械学習のフレームワークは, Keras[30] を用いた. Keras を用いた学習には, 高速化を図るために GPU を使用した. 表 5.1 に本実験で用いた計算機環境を示す.

表 5.1 計算機環境

CPU	Intel Core i7-9700 CPU 3.60GHz
GPU	NVIDIA GeForce RTX 2070 SUPER (NVIDIA)
OS	Windows 10 Enterprise 64-bit
RAM	32.0 GB Dual-Channel
Python	v.3.7.3
Keras	v.2.3.1
Tensor Flow	v.2.0.0
CUDA	v.9.0
cuDNN	v.7.0

### 5.1.2 X 線 CT 装置

計測物を計測する X 線 CT 装置は, Carl Zeiss 社の METROTOM 1500 を使用した. 図 5.1 に X 線 CT 装置の写真を示す. X 線源と検出器の距離が 1500mm ある. そのため, 計測物に対して所望の倍率を選択でき, 分解能と測定精度を調節できる. 主な仕様を表 5.2 に示す. また, CT 装置内部の X 線源と計測時の様子を図 5.2 に示す.





図 5.1 METROTOM 1500

表 5.2 X 線 CT 装置の仕様

電圧	30 - 225 kV
電流	10 - 1000 $\mu$ A
最小焦点スポット	5 $\mu$ m
測定範囲	350 × 350 × 350 mm
分解能	2048 × 2048 ピクセル
ピクセルサイズ	200 × 200 $\mu$ m



(a) CT 装置内部の様子



(b) CT スキャン時の様子

図 5.2 X 線 CT 装置の様子

## 5.2 実験結果

本節では, 実験結果について述べる. 以下の 3 つの計測物を用いて実験を行った.

- X 構造モデル
- テトラ構造モデル
- 骨モデル

### 5.2.1 X 構造モデル

#### 学習データの準備

X 構造モデルは, 自ら設計し, 3D プリントで造形をして, X 線 CT スキャンを行った. X 構造モデルは, 単純な繰り返しパターン構造である. 設計した STL データを図 5.3 に示す. 設計には, CAD ソフト Autodesk Netfabb Premium 2020 64-Bit Edition を使用した. 繰り返しパターンの構造は, 10[mm] × 10[mm] × 10[mm] の図 5.3 の拡大図に示す構造を単位とし, 50[mm] × 50[mm] × 50[mm] の立方体モデルを設計した.

3D プリントによって造形された造形物を図 5.4 に示す. 造形に使用した 3D プリンタは, Markforged 社の Mark Two で, 素材はナイロンベースの onxy である.

X 線 CT スキャンを行ったパラメータを表 5.3 に示す. また, CT ボリュームのボリュームレンダリングと断面画像を図 5.5, 図 5.6 に示す.




図 5.3 X 構造モデルの STL データ

表 5.3 X 構造モデルの計測パラメータ

電圧	140kV
電流	950 $\mu$ A
フィルタ	銅 (0.05mm)
投影数	700 枚
CT ボリュームの解像度	437 × 482 × 438
ボクセルサイズ	138.4 $\mu$ m



図 5.4 X 構造モデルの造形物




図 5.5 X 構造モデルのボリュームレンダリング

図 5.6 X 構造モデルの CT ボリュームの断面画像

### 回帰モデルの生成

X 構造モデルの学習には, 以下の表 5.4 の組で学習を行い回帰モデルを生成した. 学習データの切り出しサイズを  $5 \times 5$  ピクセルの 3 平面,  $7 \times 7$  ピクセルの 3 平面,  $9 \times 9$  ピクセルの 3 平面,  $11 \times 11$  ピクセルの 3 平面と  $13 \times 13$  ピクセルの 3 平面の 5 パターンで切り出した. 訓練用入力データを切り出す CT ボリュームは, Z 方向に異なる解像度で 3 パターン用意した. 解像度は,  $200 \times 200 \times 50$  ボクセル,  $200 \times 200 \times 200$  ボクセルと  $200 \times 200 \times 600$  ボクセルである. 訓練用入力データを切り出すサイズと切り出す CT ボリュームの組み合わせで 15 種類の学習データができる. それぞれに対して, 回帰モデルを生成した.

表 5.4 X 構造モデルの学習データの種類

	訓練用入力データ (切り出しサイズ $\times$ 枚数)	訓練用正解データ (ボクセル数)	学習組数 (Z 方向の解像度)
(i)	$5 \times 5 \times 3$	$2 \times 2 \times 2$	663,552 (200)
(ii)	$7 \times 7 \times 3$	$2 \times 2 \times 2$	622,938 (200)
(iii)	$9 \times 9 \times 3$	$2 \times 2 \times 2$	584,016 (200)
(iv)	$11 \times 11 \times 3$	$2 \times 2 \times 2$	546,750 (200)
(v)	$13 \times 13 \times 3$	$2 \times 2 \times 2$	511,104 (200)
(vi)	$5 \times 5 \times 3$	$2 \times 2 \times 2$	2,045,952 (600)
(vii)	$7 \times 7 \times 3$	$2 \times 2 \times 2$	1,948,338 (600)
(viii)	$9 \times 9 \times 3$	$2 \times 2 \times 2$	1,853,616 (600)
(ix)	$11 \times 11 \times 3$	$2 \times 2 \times 2$	1,761,750 (600)
(x)	$13 \times 13 \times 3$	$2 \times 2 \times 2$	1,672,704 (600)
(xi)	$5 \times 5 \times 3$	$2 \times 2 \times 2$	145,152 (50)
(xii)	$7 \times 7 \times 3$	$2 \times 2 \times 2$	125,913 (50)
(xiii)	$9 \times 9 \times 3$	$2 \times 2 \times 2$	107,916 (50)
(xiv)	$11 \times 11 \times 3$	$2 \times 2 \times 2$	91,125 (50)
(xv)	$13 \times 13 \times 3$	$2 \times 2 \times 2$	75,504 (50)

### 高解像度化


入力データの CT ボリュームの 1 断面を図 5.7(a) に示す. 入力データの解像度は,  $200 \times 200 \times 200$  ボクセルである. これは全体の高解像 CT ボリュームをダウンサンプリングしたものである. ダウンサンプリング前の高解像 CT ボリュームをリファレンスとした. リファレン

スの CT ボリュームの 1 断面を図 5.7(b) に示す. リファレンスの解像度は,  $400 \times 400 \times 400$  ボクセルである.


X 構造の入力データの高解像度化の結果の 1 断面を図 5.8 に示す. 高解像度化には, 提案手法のほかにバイキュービック法 (図 5.8(a)) と SRCNN (図 5.8(b)) も行った. 各出力データの解像度は,  $400 \times 400 \times 400$  ボクセルである. なお, 次の評価では全データに対して評価をした結果を示す.




図 5.7 X 構造モデルの入力データとリファレンス




(a) バイキュービック法




(b) SRCNN




(c) (i) の学習データ




(d) (ii) の学習データ




(e) (iii) の学習データ




(f) (iv) の学習データ




(g) (v) の学習データ




(h) (vi) の学習データ




(i) (vii) の学習データ




(j) (viii) の学習データ




(k) (ix) の学習データ




(l) (x) の学習データ




(m) (xi) の学習データ




(n) (xii) の学習データ



(o) (xiii) の学習データ



(p) (x-xiv) の学習データ



(q) (xv) の学習データ

図 5.8 X 構造モデルの高解像度化結果と拡大画像

## 高解像度化結果の評価

入力データ (図 5.7(a)) と比較して, 提案手法の高解像度化による CT ボリューム (図 5.8(i)) の 1 断面は鮮明になったことがわかる. また, 切り出しサイズ  $5 \times 5$  ピクセルの 3 平面である図 5.8(c) と切り出しサイズ  $9 \times 9$  ピクセルの 3 平面である図 5.8(e) を比較すると, CT ボリュームの 1 断面の鮮明度に差異があることがわかった.

高解像 CT ボリュームの 1 断面に対して, PSNR と SSIM の画質評価を行った結果を表 5.5 に示す. PSNR の結果から学習データ (vii) の結果 (図 5.8(i)) が, ノイズがなくリファレンスに近いデータであるということがわかった. SSIM の結果から学習データ (iii) の結果 (図 5.8(e)) が, リファレンスと類似性が高いことがわかった.

表 5.5 X 構造モデルの画質評価

高解像度化手法	PSNR	SSIM
バイキュービック法 (図 5.8(a))	23.61	0.776
SRCNN (図 5.8(b))	27.49	0.888
学習データ (i) (図 5.8(c))	24.87	0.907
学習データ (ii) (図 5.8(d))	26.03	0.924
学習データ (iii) (図 5.8(e))	27.01	0.931
学習データ (iv) (図 5.8(f))	26.83	0.923
学習データ (v) (図 5.8(g))	26.57	0.912
学習データ (vi) (図 5.8(h))	23.66	0.878
学習データ (vii) (図 5.8(i))	28.14	0.920
学習データ (viii) (図 5.8(j))	25.36	0.818
学習データ (ix) (図 5.8(k))	24.40	0.789
学習データ (x) (図 5.8(l))	26.04	0.858
学習データ (xi) (図 5.8(m))	21.36	0.789
学習データ (xii) (図 5.8(n))	22.97	0.842
学習データ (xiii) (図 5.8(o))	24.93	0.914
学習データ (xiv) (図 5.8(p))	22.50	0.889
学習データ (xv) (図 5.8(q))	20.09	0.781

### 5.2.2 テトラ構造モデル

#### 学習データの準備

テトラ構造モデルも X 構造モデルと同様に, 自ら設計し 3D プリンタで造形をした. 設計した STL データを図 5.9 に示す. テトラ構造の繰り返しパターンの単位構造は,  $10[\text{mm}] \times 10[\text{mm}] \times 10[\text{mm}]$  の図 5.9 の拡大図に示す構造を単位とし,  $50[\text{mm}] \times 50[\text{mm}] \times 50[\text{mm}]$  の立方体を設計した. このテトラ構造モデルを CT スキャンを行うことでデータを取得した.

3D プリンタによって造形された造形物を図 5.10 に示す. 造形に使用した 3D プリンタは, キーエンス社の AGILISTA 3200 で, 素材は光硬化性樹脂である.

X 線 CT スキャンを行ったパラメータを表 5.6 に示す. また, CT ボリュームのボリュームレンダリングと断面画像を図 5.11 と図 5.12 に示す.




図 5.9 テトラ構造モデルの STL データ

表 5.6 テトラ構造モデルの計測パラメータ

電圧	140kV
電流	950 $\mu$ A
フィルタ	銅 (0.05mm)
投影数	650 枚
CT ボリュームの解像度	416 × 421 × 403
ボクセルサイズ	146.2 $\mu$ m




図 5.10 テトラ構造モデルの造形物




図 5.11 テトラ構造モデルのボリュームレンダリング

図 5.12 テトラ構造モデルの CT ボリュームの断面画像

### 回帰モデルの生成

テトラ構造モデルの学習には, 以下の表 5.7 の組で学習を行い回帰モデルを生成した. 学習データの切り出しサイズを  $7 \times 7$  ピクセルの 3 平面,  $9 \times 9$  ピクセルの 3 平面,  $11 \times 11$  ピクセルの 3 平面と  $13 \times 13$  ピクセルの 3 平面の 4 パターンで切り出した. 訓練用入力データを切り出す CT ボリュームは Z 方向に異なる解像度で 2 パターン用意した. 解像度は,  $200 \times 200 \times 50$  ボクセルと  $200 \times 200 \times 200$  ボクセルである. 訓練用入力データを切り出すサイズと切り出す CT ボリュームの組み合わせで 8 種類の学習データができる. それぞれに対して, 回帰モデルを生成した.

表 5.7 テトラ構造モデルの学習データの種類

	訓練用入力データ (切り出しサイズ $\times$ 枚数)	訓練用正解データ (ボクセル数)	学習組数 (Z 方向の解像度)
(i)	$7 \times 7 \times 3$	$2 \times 2 \times 2$	622,938 (200)
(ii)	$9 \times 9 \times 3$	$2 \times 2 \times 2$	584,016 (200)
(iii)	$11 \times 11 \times 3$	$2 \times 2 \times 2$	546,750 (200)
(iv)	$13 \times 13 \times 3$	$2 \times 2 \times 2$	511,104 (200)
(v)	$7 \times 7 \times 3$	$2 \times 2 \times 2$	125,913 (50)
(vi)	$9 \times 9 \times 3$	$2 \times 2 \times 2$	107,916 (50)
(vii)	$11 \times 11 \times 3$	$2 \times 2 \times 2$	91,125 (50)
(viii)	$13 \times 13 \times 3$	$2 \times 2 \times 2$	75,504 (50)

### 高解像度化

入力データの CT ボリュームの 1 断面を図 5.13(a) に示す. 入力データの解像度は,  $200 \times 200 \times 200$  ボクセルである. これは全体の高解像 CT ボリュームをダウンサンプリングしたものである. ダウンサンプリング前の高解像 CT ボリュームをリファレンスとした. リファレンスの CT ボリュームの 1 断面を図 5.13(b) に示す. リファレンスの解像度は,  $400 \times 400 \times 400$  ボクセルである.

テトラ構造の入力データの高解像度化の結果の 1 断面を図 5.14 に示す. 高解像度化には, 提案手法のほかにバイキュービック法 (図 5.14(a)) と SRCNN (図 5.14(b)) も行った. 各出力データの解像度は,  $400 \times 400 \times 400$  ボクセルである. なお, 次の評価では全データに対して評価をした結果を示す.





図 5.13 テトラ構造モデルの入力データとリファレンス




図 5.14 テトラ構造モデルの高解像度化結果と拡大画像

## 高解像度化結果の評価

入力データ (図 5.13(a)) と比較して, 提案手法の高解像度化による CT ボリューム (図 5.14(c)) の 1 断面は鮮明になったことがわかる. また, 切り出しサイズ  $7 \times 7$  ピクセルの 3 平面である図 5.14(g) と切り出しサイズ  $13 \times 13$  ピクセルの 3 平面である図 5.14(j) を比較すると, X 構造モデルと同様に CT ボリュームの 1 断面の鮮明度に差異があることがわかった.

高解像 CT ボリュームの 1 断面に対して, PSNR と SSIM の画質評価を行った結果を表 5.8 に示す. 評価には, PSNR と SSIM を使用した. PSNR の結果から学習データ (i) の結果 (図 5.14(c)) である切り出しサイズ  $7 \times 7$  ピクセルの 3 平面, Z 方向の解像度 200 としたデータが, ノイズがなくリファレンスに近いデータであるということがわかった. SSIM の結果から SRCNN の図 5.14(b) の結果がリファレンスと類似性が高いことがわかった. しかし, SRCNN の結果 (図 5.14(b)) と学習データ (i) の結果 (図 5.14(c)) を比較すると, 学習データ (i) の結果の方が物体と空気の境目がはっきりしている.

表 5.8 テトラ構造モデルの画質評価

高解像度化手法	PSNR	SSIM
バイキュービック法 (図 5.14(a))	25.02	0.897
SRCNN (図 5.14(b))	28.78	0.940
提案手法 (i) (図 5.14(c))	30.13	0.926
提案手法 (ii) (図 5.14(d))	29.36	0.916
提案手法 (iii) (図 5.14(e))	27.61	0.906
提案手法 (iv) (図 5.14(f))	23.93	0.737
提案手法 (v) (図 5.14(g))	28.262	0.918
提案手法 (vi) (図 5.14(h))	26.45	0.903
提案手法 (vii) (図 5.14(i))	27.01	0.905
提案手法 (viii) (図 5.14(j))	21.44	0.830

### 5.2.3 骨構造モデル

#### 学習データの準備

骨モデルは、動物の骨である。この骨モデルに CT スキャンを行うことでデータを取得した。骨モデルの写真を図 5.15 に示す。X 線 CT スキャンを行ったパラメータを表 5.9 に示す。また、CT ボリュームのボリュームレンダリングと断面画像を図 5.16 と図 5.17 に示す。

表 5.9 骨モデルの計測パラメータ

電圧	180kV
電流	550 $\mu$ A
フィルタ	銅 (0.5mm)
投影数	1050 枚
CT ボリュームの解像度	755 $\times$ 849 $\times$ 628
ボクセルサイズ	106.7 $\mu$ m



図 5.15 骨モデルの写真




図 5.16 骨モデルのボリュームレンダリング

図 5.17 骨モデルの CT ボリュームの断面画像

#### 回帰モデルの生成

骨モデルの学習には、以下の表 5.10 の組で学習を行い回帰モデルを生成した。学習データの切り出しサイズを 7  $\times$  7 ピクセルの 3 平面, 9  $\times$  9 ピクセルの 3 平面, 11  $\times$  11 ピクセルの 3 平面と 13  $\times$  13 ピクセルの 3 平面の 4 パターンで切り出した。訓練用入力データを切り出す CT ボリュームの解像度は、700  $\times$  700  $\times$  40 ボクセルである。訓練用入力データを切り出すサイズと切り出す CT ボリュームの組み合わせで 4 種類の学習データができる。それぞれに対して、回帰モデルを生成した。

表 5.10 骨モデルの学習データの種類

	訓練用入力データ (切り出しサイズ × 枚数)	訓練用正解データ (ボクセル数)	学習組数 (Z 方向の解像度)
(i)	$7 \times 7 \times 3$	$2 \times 2 \times 2$	1,242,528 (40)
(ii)	$9 \times 9 \times 3$	$2 \times 2 \times 2$	1,052,676 (40)
(iii)	$11 \times 11 \times 3$	$2 \times 2 \times 2$	867,000 (40)
(iv)	$13 \times 13 \times 3$	$2 \times 2 \times 2$	685,464 (40)

### 高解像度化

入力データの CT ボリュームの 1 断面を図 5.18(a) に示す。入力データの解像度は、 $350 \times 350 \times 35$  ボクセルである。これは全体の高解像 CT ボリュームをダウンサンプリングしたものである。ダウンサンプリング前の高解像 CT ボリュームをリファレンスとした。リファレンスの CT ボリュームの 1 断面を図 5.18(b) に示す。リファレンスの解像度は、 $700 \times 700 \times 70$  ボクセルである。

骨モデルの入力データの高解像度化の結果の 1 断面を図 5.19 に示す。高解像度化には、提案手法のほかにバイキュービック法 (図 5.19(a)) と SRCNN (図 5.19(b)) も行った。各出力データの解像度は、 $700 \times 700 \times 70$  ボクセルである。なお、次の評価では全データに対して評価をした結果を示す。




図 5.18 骨モデルの入力データとリファレンス




図 5.19 骨モデルの高解像度化結果と拡大画像

## 高解像度化の評価

入力データ (図 5.18(a)) と比較して, 提案手法の高解像度化による CT ボリューム (図 5.19(c)) の 1 断面は鮮明になったことがわかる. また, 高解像度化により従来法よりも骨の構造がより鮮明になっていることがわかる.

高解像 CT ボリュームの 1 断面に対して, PSNR と SSIM の画質評価を行った結果を表 5.11 に示す. 評価には, PSNR と SSIM を使用した. PSNR の結果から学習データ (iii) の結果 (図 5.19(e)) である切り出しサイズが  $11 \times 11$  ピクセルの 3 平面が一番ノイズがなくリファレンスに近いデータが生成されたことがわかった. また, SSIM の結果から学習データ (ii) の結果 (図 5.19(d)) が, リファレンスと類似性が高いことがわかった.

表 5.11 骨モデルの画質評価

高解像度化手法	PSNR	SSIM
バイキュービック法 (図 5.19(a))	20.89	0.814
SRCNN (図 5.19(b))	22.39	0.882
提案手法 (i) (図 5.19(c))	24.63	0.921
提案手法 (ii) (図 5.19(d))	24.91	0.930
提案手法 (iii) (図 5.19(e))	26.49	0.927
提案手法 (iv) (図 5.19(f))	25.78	0.923



## 5.3 考察

### 5.3.1 切り出しサイズによる高解像度化への影響

X 構造モデル, テトラ構造モデルと骨モデルの結果から, 高解像度化には注目ボクセル集合の小領域の切り出しが影響していることがわかった. X 構造モデルの入力の CT ボリュームについて考える. 入力 CT ボリュームを各切り出しサイズで切り出した場合を図 5.20 に示す. 緑色の線が,  $5 \times 5$  ピクセルで切り出した場合の小領域で, 同様に, 青色が  $7 \times 7$  ピクセル, 黄色が  $9 \times 9$  ピクセル, 橙色が  $11 \times 11$  ピクセルと紫色が  $13 \times 13$  ピクセルである. X モデルの構造のサイズが 7 から 9 ピクセルであることから, 切り出しサイズが  $5 \times 5$  ピクセルでは特徴量が足りず, 逆に  $13 \times 13$  ピクセルでは大きすぎることを考えられる. このことから, 構造の厚みに合わせた小領域で切り出すことが必要である.




図 5.20 X 構造モデルの入力データにおける小領域切り出しサイズ

## 5.3.2 学習組数による高解像度化への影響

X 構造モデルについては, 学習組数を 3 種類の学習データを使用して学習を行った.  $200 \times 200 \times 50$  ボクセル,  $200 \times 200 \times 200$  ボクセル と  $200 \times 200 \times 600$  ボクセルの 3 種類である. 学習組数の違う 3 種類の結果とリファレンスを図 5.21 に示す. 図 5.21 から学習組数が少ないと, 微細な特徴がボケてしまっていることがわかる. また, 画質評価である PSNR と SSIM の結果 (表 5.5) から, Z 方向への解像度 200 と 600 での数値の差はそこまでないが, 50 になると悪くなってしまう. このことから, 学習組数によって高解像度化に影響があることが考えられる.




図 5.21 3 種類の学習組数による高解像度化



### 5.3.3 繰り返し高解像度化の適用

繰り返し高解像度化を適用した 1 断面の結果を図 5.22 に示す. 入力データとしては,  $100 \times 100 \times 100$  ボクセルの X 構造モデルのデータを用いた. 図 5.22(b) に, x, y, z 方向に 2 倍の解像度である  $200 \times 200 \times 200$  ボクセルの結果を示す. さらに繰り返し, 図 5.22(b) を入力として高解像度化した結果を図 5.22(c) に示す. 解像度は,  $400 \times 400 \times 400$  ボクセルとなる. このことから, 入力データでは観察が困難であった空気と物体の境目が, 1, 2 回目の高解像度化によってはっきりしてきていることがわかる.




図 5.22 繰り返し高解像度化の結果



---

## 第 6 章 実験と考察: 投影像に対するフレーム補間

本章では, 第 4 章で提案した投影像に対するフレーム補間アルゴリズムを複数のデータに適用した結果について述べる. 第 6.1 節では, 離散的計測の実験について述べる. 第 6.2 節では, 連続的計測の実験について述べる. 最後に第 6.3 節で実験結果の考察を行う.

## 6.1 離散的計測の実験

本節では, 離散的計測の実験について述べる. 装置の測定中に物体を変形させることができないため, スキャンと変形を交互に繰り返すことで実験を行う.

計測で用いた実験データは, 3D プリンタ (キーエンス社 AGILISTA 3200) を用いて, 造形を行った. 造形データとして, CAD を用いて STL データを作成した. 実験では, 造形物を変形させることが必要なため, 弾性のあるシリコンを素材として造形したものをを用いた. 図 6.1 に造形した実物の写真と STL データを示す. また, 図 6.1 の造形物をラティスモデルと呼ぶ.




図 6.1 ラティスモデルの造形された実物の写真と STL データ

### 6.1.1 計測方法

離散的計測の計測方法について述べる. 離散的な計測のため, スキャンと変形を交互に繰り返すよう, 発泡スチロールで計測物を置く台を作成し (図 6.2), そこに, 計測物を置き上から圧縮することによりスキャンと変形を繰り返して計測を行った. 図 6.3 に CT スキャンの様子を示す. 1 フレームごとに 5g のおもり (粘土) を置き圧縮を行った. X 線 CT スキャンを行ったパラメータを表 6.1 に示す. また計測によって得られた投影像の一部を図 6.4 に示す. フレーム 1 からフレーム 5 に進むにつれて圧縮されている.




図 6.2 ラティスモデルの計測に用いた発泡スチロールの台と圧縮による変形




図 6.3 ラティスモデルの離散的計測の様子

表 6.1 ラティスモデルの計測パラメータ

電圧	120kV
電流	$500\mu\text{A}$
フィルタ	-
投影像の解像度	$512 \times 512$
投影数	525 枚
フレーム数	5
投影像の解像度ピッチ	0.8mm




図 6.4 ラティスモデルの投影像

### 6.1.2 離散的計測の補間結果

ラティスモデルの離散的計測の補間結果を図 6.5 に示す. フレーム 2 を生成するために, フレーム 1 とフレーム 3 を用いて中間投影像を生成した. 同様に, フレーム 3 とフレーム 4 も前後のフレームを用いて生成を行った. CT スキャン計測で得られたフレーム 2, 3, 4 のデータをリファレンスとして, 生成された中間投影像との評価に用いた. また, オプティカルフローを用いたフレーム補間の比較アルゴリズムとして, Lucas-Kanade 法と Horn-Shunck 法を用いた結果も図 6.5 に示す. Lucas-Kanade 法 (図 6.5(a)) から表面が粗くなっていることがわかる. また, Horn-Shunck 法 (図 6.5(b)), 提案手法 (図 6.5(c)) とリファレンス (図 6.5(d)) を比較すると前後のフレームが残ってしまい二重に表示されてしまっているように見える.




図 6.5 ラティスモデルの投影像のフレーム補間結果 (左から, フレーム 2, 3, 4)

### 6.1.3 ラティスモデルの実験評価

投影像補間によりラティスモデルの投影像を 360 度分生成することで, 1 フレームの投影像列を生成した. 生成した投影像列から, CT 再構成を行って CT ボリュームを生成した. 今回は, フレーム 2 の投影像列を用いた. その結果を図 6.6 に示す. 図 6.6(a), (b) の CT 再構成結果からアーチファクトが生じてしまっていることがわかる. ラティスモデルは離散的計測であり, 前後のフレームでの変形の影響を強く受けたものと考えられる. また, 画像のノイズの強さを数値化する PSNR と, リファレンスとの類似度を数値化する SSIM で評価を行った結果を表 6.2 に示す. PSNR と SSIM の数値より提案手法が従来法よりも良いことがわかる.




図 6.6 ラティスモデルの補間した投影像からの CT 再構成結果の 1 断面

表 6.2 ラティスモデルの CT 画像の画質評価

投影像補間法	PSNR	SSIM
Lucas-Kanade 法	12.69	0.362
Horn-Shunck 法	17.15	0.606
提案手法	20.42	0.878



## 6.2 連続的計測の実験

本節では, 連続的計測の実験について述べる. CT スキャン中に物体が変形する環境を再現するために, 水で膨らむ玩具を用いた連続的な計測を行った. この玩具は, 図 6.7 のように, 水を吸収して膨張する. 今回は, このうち図 6.8 のものを使用して実験を行った. また, 今回の計測物をロブスターと呼ぶ.




図 6.7 水で膨らむ玩具 (左: 膨張前, 右: 膨張後)



図 6.8 ロブスターの実物の写真

### 6.2.1 計測方法

本実験では, 膨張した状態からスタートして収縮する様子を計測した. 計測の様子を図 6.9 に示す. 計測の際は, 物体の変形を止めずに複数回回転させながら計測を行った. また, CT スキャンを行ったパラメータを表 6.3 に示す. 1 フレームでの変化が少ないため, 32 フレームを連続的に計測を行った. 計測で得られた投影像のうち, フレーム 1, フレーム 10, フレーム 20 とフレーム 30 の投影像を図 6.10 に示す.




図 6.9 ロブスターの計測の様子

表 6.3 ロブスターの計測パラメータ

投影像の解像度	512 × 512
投影数	512 枚
フレーム数	32
投影像の解像度ピッチ	0.8mm






図 6.10 ロブスターの投影像

### 6.2.2 連続的計測の補間結果

ロブスターの連続的計測の補間結果を図 6.11 に示す. 結果には, フレーム 2, フレーム 15 とフレーム 30 を投影像補間した結果を示す. フレーム 2 の投影像補間は, フレーム 1 とフレーム 3 を用いて生成した. また同様に, フレーム 15 はフレーム 14 とフレーム 16, フレーム 30 はフレーム 29 とフレーム 31 を用いて投影像補間を行った. また, オプティカルフローを用いたフレーム補間の比較アルゴリズムとして, Lucas-Kanade 法と Horn-Shunck 法を用いた結果も図 6.11 に示す. 提案手法 (図 6.11(c)), Lucas-Kanade 法 (図 6.11(a)) と Horn-Shunck 法 (図 6.11(b)) の結果である投影像を比較すると目視ではほとんど差がない. そのため, CT 再構成を行い, 次節で CT ボリュームの比較を行った.




図 6.11 ロブスターの投影像のフレーム補間結果 (左から, フレーム 2, 15, 30)

### 6.2.3 ロブスターの実験評価

360 度分の投影像列を補間により生成したフレーム 2 に対して, CT 再構成を行った結果を図 6.12 に示す. 提案手法 (図 6.12(c)) が, Lucas-Kanade 法 (図 6.12(a)) と Horn-Shunck 法 (図 6.12(b)) よりもアーチファクトが少ないことがわかる. また, 画像のノイズの強さを数値化する PSNR と, リファレンスとの類似度を数値化する SSIM で評価を行った結果を表 6.4 に示す. PSNR の値は, 提案手法の値が最も優れていることがわかる. SSIM の値は, Horn-Shunck 法が 1 に近い数値だが, 提案手法と大きな差がないことから, 提案手法で投影像を補間することにより高画質な CT ボリュームを生成できることがわかった.




図 6.12 ロブスターの CT 再構成結果の 1 断面

表 6.4 ロブスターの CT 画像の画質評価

投影像補間法	PSNR	SSIM
Lucas-Kanade 法	26.07	0.903
Horn-Shunck 法	26.29	0.936
提案手法	26.76	0.930

## 6.3 考察

### 6.3.1 物体の変形量による投影像補間への影響

提案手法のラティスモデルの投影像補間の結果 (図 6.5(c)) より, ロブスターの投影像補間の結果 (図 6.11(c)) の方が二重表示がないため, 高精度に補間できている. そこで, ラティスモデルとロブスターでフレーム間の変形量に違いがあると考えた. フレーム 1 とフレーム 3 の同一投影角の投影像の差分をとって 2 つのフレーム間の変形量を可視化した (図 6.13, 6.14). 図 6.13, 6.14 の白くなっている箇所が 2 つのフレーム間の差分である. 図 6.13, 6.14 は可視化しやすくするためにコントラストを調節している. 変形量大きい箇所に黄線を引いた. ラティスモデルは, 変形量が 15 ピクセルあり, ピッチサイズが 0.8mm のためフレーム 1 からフレーム 3 の間に 1.85mm 程変形していることがわかる (図 6.13). 一方, ロブスターは変形量が 5 ピクセルであり, ピッチサイズが 0.8mm のためフレーム 1 からフレーム 3 の間に 1.20mm 程変形していることがわかる (図 6.14). このことからフレーム間の変形量が投影像補間に影響を与えていると考えられる.




図 6.13 ラティスモデルの変形量




図 6.14 ロブスターの変形量

### 6.3.2 アーチファクトの発生について

投影像補間で生成された投影像列を CT 再構成した実験結果から, Lucas-Kanade 法と Horn-Shunck 法で CT ボリュームにアーチファクトが生じた (図 6.6(a), (b), 図 6.12(a), (b)). アーチファクトの発生原因は, オプティカルフローの取得方法が各手法によって違うため影響しているのではないかと考えた. 各手法のオプティカルフローを図 6.15 に示す. 図 6.15 の赤で描かれている線がオプティカルフローを示している. 取得したオプティカルフローから, Lucas-Kanade 法は規則性がなく散乱していることがわかる. また, Horn-Shunck 法は規則性はあるのだが, 斜め方向に対してオプティカルフローを取得できていない. 提案手法は規則性があり, 斜め方向に対してもオプティカルフローを取得できているため, アーチファクトを抑えて CT 再構成できたと考えられる.

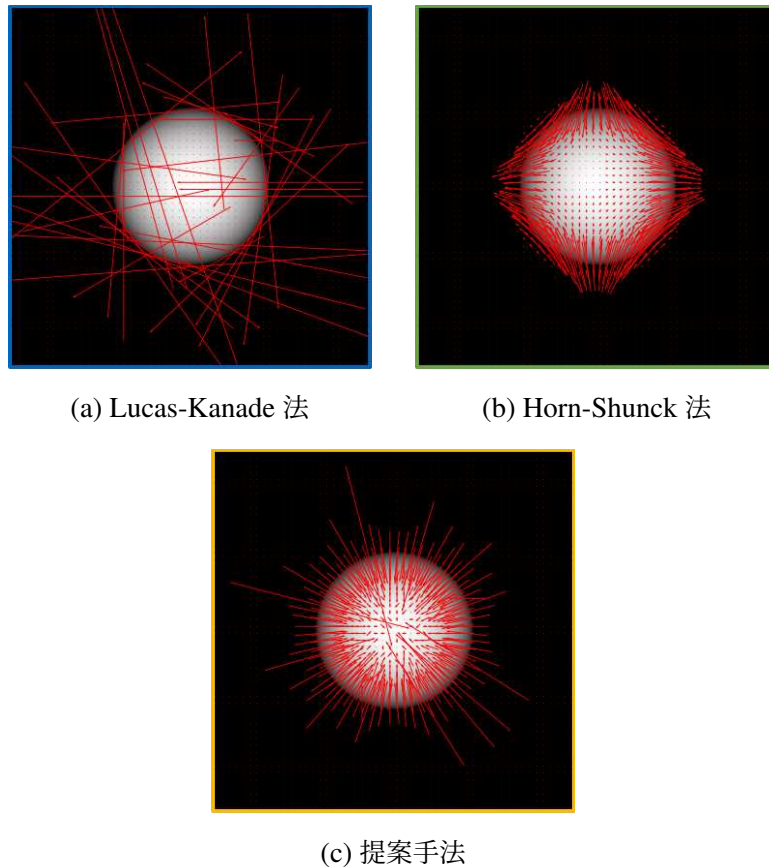


図 6.15 各手法によるオプティカルフロー

### 6.3.3 CT ボリュームからの抽出表面の比較

ロブスターの投影像補間結果を再構成した CT ボリュームから抽出した表面メッシュを図 6.16 に示す。表面メッシュ抽出には, GOM Suite 2021 [31] を用いた。投影像補間は, Frame 0 と Frame 2 に対して提案手法と Horn-Shunck 法により行った。これらと, 実際に計測したデータ (Frame 1) からの偏差を比較した。偏差を色で表示して, 偏差が正に大きい箇所は赤色になり, 負に大きい箇所は青色になる。そこで, ロブスターの足を見ると赤くなっている箇所がある。これは, 計測データ (Frame 1) からの偏差が大きい箇所である。Horn-Shunck 法の方が提案手法よりも赤い箇所が多く, 偏差が大きいことから, 提案手法の方がより精度良く投影像補間ができているとわかる。第 6.3.2 項で述べたように, Horn-Shunck 法では斜め方向に対してオプティカルフローが取得できないことから, ロブスターの足のように丸みがある個所では, このような差分が生じたと考えられる。

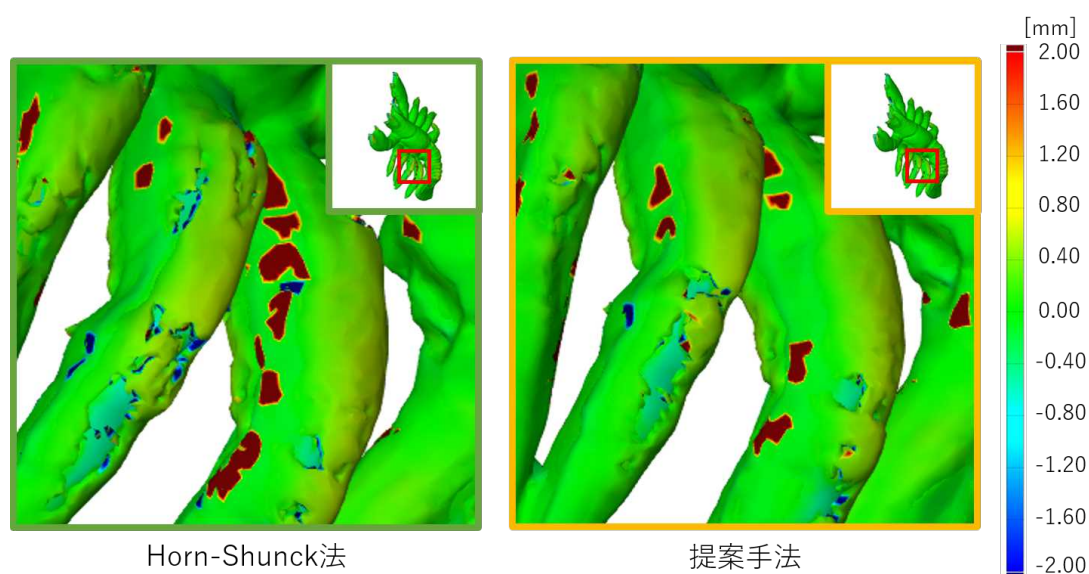


図 6.16 ロブスターの表面メッシュの計測データ (Frame 1) からの偏差



---

## 第 7 章 結論と今後の展望

本章では, 提案手法によって得られた結論を述べる. 第 7.1 節で本論文で提案した高解像度化アルゴリズムのまとめと結論, 今後の展望についてを述べる. 第 7.2 節で本論文で提案した投影像生成アルゴリズムのまとめと結論, 今後の展望についてを述べる.

## 7.1 高解像度化アルゴリズム

### 7.1.1 まとめと結論

本論文では, 内部構造の高精度観察を容易にするための一つの手段として, CT ボリュームの高解像度化の手法の提案を行った. 入力データである造形物全体の低解像 CT ボリュームを高解像度化するために, 本論文では訓練用入力データ (部分的な低解像 CT ボリューム) と訓練用正解データ (部分的な高解像 CT ボリューム) を用い, 機械学習を行うことで出力データ (全体の解像 CT ボリューム) を得る手法を提案した. 機械学習の学習データの生成では, 訓練用入力データとして低解像 CT ボリュームを特徴のわかる注目ボクセル集合の小領域で切り出したものを用い, 訓練用正解データには  $2 \times 2 \times 2$  ボクセルで高解像 CT ボリュームを切り出したものを用いた. これらを組にして学習データを生成した. ニューラルネットワーク構造は, CNN (畳み込みニューラルネットワーク) を使用した. CNN は, 低解像入力データを  $2 \times 2 \times 2$  ボクセルの出力データになるようにネットワークを構築した. 実験によって, 従来法より鮮明な高解像 CT ボリュームが得られた. 以上より, 提案手法は内部構造の高精度観察を可能にすることを示した.

### 7.1.2 今後の課題と展望

#### 今後の課題

今後の課題について述べる. 本論文では, 入力データに対して切り出しサイズを 1 つに固定して学習を行った. 課題として, 切り出しサイズが 1 つに固定されているため, 特徴量が大きい特徴と小さい特徴が混合している造形物に対しての対応が挙げられる. 本論文では, 単一材料かつ繰り返しパターンの微細構造の CT データを想定している. 一般的には, 複数材料の製品が多い. 複数材料の場合, X 線の透過率が材料によって違う. そのため, 計測された CT ボリュームの輝度にもばらつきがあり, 材料の形状特徴サイズに応じて注目ボクセル小領域を最適化する必要があると考えられる.

#### 今後の展望

一点目は, 複数材料に提案手法である高解像度化アルゴリズムを適用することである. そのためには, 切り出しサイズの最適化が必要であると考えられる. 複数材料の場合, 形状特徴が材料ごとに場合があるため, 材料ごとに切り出しサイズを用意することで最適化が可能であると考えられる.

二点目は, マイクロ CT スキャンとナノ CT スキャンへの提案手法である高解像度化アル



ゴリズムの応用である。マイクロ CT スキャンは、一般的に用いられている CT 装置になる。ナノ CT スキャンは、マイクロ CT スキャンより高精度に CT スキャンが可能である。ナノ CT スキャンは、計測物の内部構造をより高精度に観察するときなどに用いられる。マイクロ CT とナノ CT で CT スキャンされた CT 画像を図 7.1 に示す。

そこで、マイクロ CT スキャンの CT ボリューム (図 7.1(b)) を入力データとし、本提案手法である高解像度化アルゴリズムを適用し高解像度化する。マイクロ CT スキャンの CT ボリューム (図 7.1(b)) を訓練用入力データ、ナノ CT スキャンの CT ボリューム (図 7.1(a)) を訓練用正解データとして学習データを生成する。この学習データを用いて、高解像度化することで、マイクロ CT スキャンの CT ボリュームがナノ CT スキャンを用いて計測した CT ボリュームと同等の精度であると期待される。提案手法である高解像度化を適用しようとするマイクロ CT とナノ CT では解像度が異なるため、切り出し領域がずれてしまう。そのため、マイクロ CT とナノ CT のデータの位置合わせが必要である。




図 7.1 各種 CT ボリュームの断面画像

## 7.2 投影像生成アルゴリズム

### 7.2.1 まとめと結論

本論文では, 4DCT スキャンの物体の変形に対する補間の一つ的手段として, 前後の投影像から任意時刻の投影像を生成する手法の提案を行った. 任意時刻の投影像を生成するために, 本論文では, 入力データとして前後のフレームの勾配ベクトルを基にオプティカルフローを算出, それを用いた投影像補間を行うことを提案した. 前のフレームのオプティカルフローを forward flow, 後のフレームのオプティカルフローを backward flow と呼ぶ. オプティカルフローを基に物体の変形に影響があるかを判定し, 影響があれば投影像補間を行う. 実験により, 物体の変形による影響に対し, 頑健な投影像が得られた. さらに, CT 再構成を行うことで CT ボリュームを生成し, 計測物の内部構造を観察した. 画質評価の結果, PSNR と SSIM の数値が従来法よりも高いものを示した. 以上より, 提案手法は 4DCT スキャンの計測時に生じる物体の変形に対して有効であることを示した.

### 7.2.2 今後の課題と展望

#### 今後の課題

今後の課題について 2 点述べる. まず投影像補間についての課題を述べる. 本論文では, 物体の変形量が小さいデータを対象として投影像補間を行った. 課題として, 物体の変形量が大きいデータに対して補間できない点が挙げられる. 図 7.2 に補間できていない例を示す. 図 7.2 の赤丸で囲まれた箇所は, 前後のフレームの特徴に影響されて本来 1 本であるべきところが二重に表示されている.




図 7.2 投影像補間の二重表示

次に投影像補間と高解像度化を組み合わせた実験の課題について述べる. 投影像補間に用いたラティスモデルと高解像度化に用いた X 構造モデルは, 同じパターン構造であるため, この 2 つのデータを用いて実験を行った. ラティスモデルの投影像補間結果を CT 再構成したものを今回の高解像度化の入力データとした. 入力データの 1 断面を図 7.3(a) に示す. 入力データの解像度は,  $150 \times 150 \times 115$  ボクセルである. 高解像度化で用いた回帰モデルには, 第 5 章で用いた, 静止状態の X 構造モデルに対する回帰モデルを使用した. 回帰モデルの訓練用入力データは  $9 \times 9$  ピクセルの 3 平面で切り出した.

入力データ (図 7.3(a)) に対して高解像度化した結果の 1 断面を図 7.3(b) に示す. 解像度は,  $300 \times 300 \times 230$  ボクセルである. 図 7.3(b) の赤枠内の様子から, 高解像度化すると, 物体の構造が荒くなってしまっている課題があることが分かる. これは, 4DCT データに対する学習が適切でなかったことが原因であると考えられる. 今回用いた回帰モデルは静止している物体の CT ボリュームを用いて学習したものである. このことから, 4DCT データに対応した学習を行った回帰モデルの作成が必要であると考えられる.

### 今後の展望

本論文では, 線形補間を用いて投影像補間を行っているが, 今後は機械学習を用いることなどにより大変形にも対応可能な投影像補間の手法の確立が望まれる. 図 7.4 に機械学習を用いたネットワークの一例を挙げる. オプティカルフロー, 変化量と深度マップの 3 つのパラメータを用いて投影像を生成するネットワークとなっている. オプティカルフローを用いた投影像補間は本論文で提案した. 今後は, 物体の変形量を用いた投影像補間や深度推定を行って投影像補間を行うことでより大きな変形を行うデータにも対応できると考える.




図 7.3 投影像補間と高解像度化の組み合わせ結果

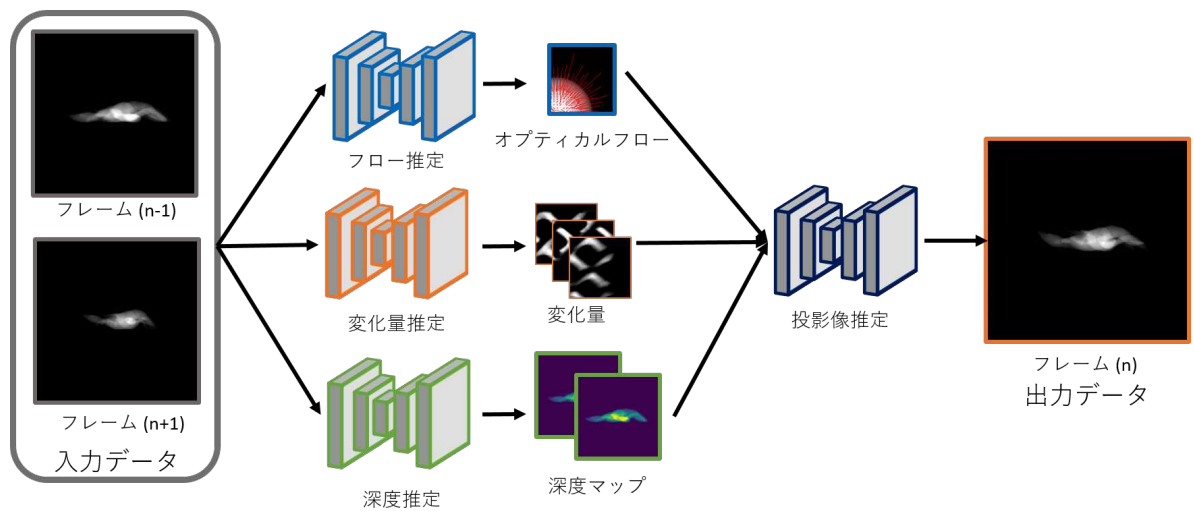


図 7.4 3つのパラメータを用いた投影像補間

---

# 謝辞

本研究を進めるに当たり、様々な方々のご支援・ご協力を頂きました。本研究は JSPS 科研費 JP19K04136, JP20H02055, 首都大学東京 傾斜的研究費（全学分）学長裁量枠 社会連携支援（都連携研究支援）と The Precise Measurement Technology Promotion Foundation の助成を受けたものです。ここに心よりの感謝を申し上げます。

東京都立大学大学院システムデザイン研究科機械システム工学域准教授、長井超慧先生には本研究の指導教員として、研究のテーマおよび方針などの根幹から、プログラミングや発表資料の作成方法や論文の執筆方法などに至るまで広くご指導を頂きました。また、研究活動のみならず、研究以外で先生とかかわる機会を設けてくださり、学部から3年間楽しく研究生活を送ることができました。長井研究室の第一期生になれたことを大変うれしく思っています。心より感謝申し上げます。

東京都立大学大学院システムデザイン研究科機械システム工学域教授、久保田直行先生、東京都立大学大学院システムデザイン研究科機械システム工学域准教授、和田一義先生には本論文の副査をお引き受けいただき、ご指導頂きました。心より感謝申し上げます。

東京大学大学院工学系研究科精密工学専攻准教授、大竹豊先生には X 線 CT 装置の使用方を基礎からご指導を頂きました。加えて、ラティス構造を有した造形物のラティスモデル、テトラ構造と格子構造を 3D プリントして頂きました。心より感謝申し上げます。

東京都立産業技術研究センター、企画部経営企画室、紋川亮様、事業化支援本部技術開発支援部実証試験技術グループ、三浦由佳様、事業化支援本部技術開発支援部計測分析技術グループ、月精智子様には研究のニーズや実用面に関して大変有益なアドバイスを頂きました。加えて、微細構造を有した造形物やの X 線 CT スキャンデータや 4DCT スキャンデータを提供して頂き、大変参考になりました。心より感謝申し上げます。

東京都立大学大学院システムデザイン研究科機械システム工学域准教授、武居直行先生にはラティス構造を有した造形物の X 構造を 3D プリントして頂きました。心より感謝申し上げます。

研究室の皆様には、研究のみならず研究生活においても大変お世話になりました。特に、同期である太田智也氏、棚谷光氏には、互いに研究について議論を交わし、研究生活を送れたこ

とで大変有意義に研究生生活を送ることができました. 心より感謝申し上げます.  
最後に, 日頃より私を支えてくれている家族, 友人に, 深く感謝の意を表します.

---

## 参考文献

- [1] Oraib Al-Ketan, Reza Rowshan, and Rashid K. Abu Al-Rub. Topology-mechanical property relationship of 3D printed strut, skeletal, and sheet based periodic metallic cellular materials. *Additive Manufacturing*, Vol. 19, pp. 167–183, 2018.
- [2] Mohammad Vaezi, Hermann Seitz, and Shoufeng Yang. A review on 3D micro-additive manufacturing technologies. *International Journal of Advanced Manufacturing Technology*, Vol. 67, No. 5-8, pp. 1721–1754, 2013.
- [3] AUTODESK. Airbus. <https://www.autodesk.co.jp/customer-stories/airbus>. Accessed: 2022-02-22.
- [4] Olaf Diegel. Additive manufacturing: An overview. In *Comprehensive Materials Processing*, pp. 3 – 18. Elsevier, Oxford, 2014.
- [5] Lars Pejryd. Evaluation of internal defects in additive manufactured metallic network structures by Computed Tomography. In *Proceedings of 8th Conference on Industrial Computed Tomography*, pp. 1–6, 2018.
- [6] Michael F. Zaeh and S. Lutzmann. Modelling and simulation of electron beam melting. *Production Engineering*, Vol. 4, No. 1, pp. 15–23, 2010.
- [7] Christian Weingarten, Damien Buchbinder, Norbert Pirch, Wilhelm Meiners, Konrad Wissenbach, and Reinhart Poprawe. Formation and reduction of hydrogen porosity during selective laser melting of AlSi10Mg. *Journal of Materials Processing Technology*, Vol. 221, pp. 112–120, 2015.
- [8] 日本医用画像工学会. 医用画像工学ハンドブック. 日本医用画像工学会, 2012.
- [9] Simone Carmignato, Wim Dewulf, and Richard Leach. *Industrial X-ray Computed Tomography*. Springer, 2018.
- [10] Deben. Insitu Micro Tensile Testing. <https://deben.co.uk/tensile-testing/muxct/ct500-500n-in-situ-tensile-stage-muxct-applications/>. Accessed: 2022-02-22.
- [11] 金田久慶, 大竹豊, 鈴木宏正. 積層造形で作成した格子構造の CT 検査に関する研究. 2019 年度精密工学会秋季大会学術講演会講演論文集, 日本, pp. 663–664, 09/2019.

- [12] Ryo Mashita, Wataru Yashiro, Daisuke Kaneko, Yasumasa Bito, and Hiroyuki Kishimoto. High-speed rotating device for X-ray tomography with 10 ms temporal resolution. *Journal of Synchrotron Radiation*, Vol. 28, No. 1, pp. 322–326, Jan 2021.
- [13] Wataru Yashiro, Wolfgang Voegeli, and Hiroyuki Kudo. Exploring frontiers of 4d x-ray tomography. *Applied Sciences*, Vol. 11, No. 19, 2021.
- [14] C. M. Bishop. パターン認識と機械学習 上. 丸善出版株式会社, 第 9 版, 2012.
- [15] Stanford University. CS231n: Convolutional neural networks for visual recognition. <http://cs231n.stanford.edu/>. Accessed: 2022-02-22.
- [16] Vinod Nair and Geoffrey E Hinton. Rectified Linear Units Improve Restricted Boltzmann Machines. In *Proceedings of the 27th International Conference on Machine Learning*, pp. 807–814, 2010.
- [17] David Rumelhart, Geoffrey Everest Hinton, and Ronald J. Williams. Learning representations by back-propagating errors. *Nature*, Vol. 323, No. 6088, pp. 533–536, 1986.
- [18] Tijmen Tieleman and Geoffrey Hinton. Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. *COURSERA: Neural Networks for Machine Learning*, pp. 26–31, 2012.
- [19] Aurélien Géron. scikit-learn と TensorFlow による実践機械学習. 株式会社オライリー・ジャパン, 初版, 2018.
- [20] Yann Lecun, Léon Bottou, Yoshua Bengio, and Patrick Haffner. Gradient-based learning applied to document recognition. Vol. 86, pp. 2278–2324, Nov 1998.
- [21] 奥富正敏. デジタル画像処理. CG-ARTS 協会, 初版, 2015.
- [22] Chao Dong, Chen Change Loy, Kaiming He, and Xiaoou Tang. Learning a Deep Convolutional Network for Image Super-Resolution. In *Proceedings of Computer Vision - ECCV 2014*, pp. 184–199, 2014.
- [23] 義博御堂, 幸治中前. 深層学習を用いた画像解析・異常検知に関する一考察. 日本信頼性学会誌, 第 40 巻, pp. 81–86, 2018.
- [24] Wenming Yang, Xuechen Zhang, Yapeng Tian, Wei Wang, Jing-Hao Xue, and Qingmin Liao. Deep Learning for Single Image Super-Resolution: A Brief Review. *IEEE Transactions on Multimedia*, Vol. 21, No. 12, pp. 3106–3121, 2019.
- [25] John Barron, David Fleet, and Steven Beauchemin. Performance of optical flow techniques. In *Proceedings of International Journal of Computer Vision*, Vol. 12, pp. 43–77, 1994.
- [26] Bruce Lucas and Takeo Kanade. An iterative image registration technique with an application to stereo vision. In *Proceedings of the 7th International Joint Conference on Artificial*



- 
- Intelligence*, Vol. 81, pp. 121–130, 04 1981.
- [27] Berthold K.P. Horn and Brian G. Schunck. Determining optical flow. *Artificial Intelligence*, Vol. 17, No. 1, pp. 185–203, 1981.
- [28] Alain Horé and Djemel Ziou. Image quality metrics: PSNR vs. SSIM. In *Proceedings of 20th International Conference on Pattern Recognition*, pp. 2366–2369, 2010.
- [29] Zhou Wang, Alan Bovik, Hamid Sheikh, and Eero Simoncelli. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*, Vol. 13, No. 4, pp. 600–612, 2004.
- [30] Francois Chollet. Python と Keras によるディープラーニング. 株式会社マイナビ出版, 第 5 版, 2018.
- [31] GOM. GOM Inspect. <https://www.gom-inspect.com/jp/index.php>. Accessed: 2022-02-22.