



Title	散乱カーネル法と深層学習を用いた適応陽子線治療のための新しいCBCT散乱線補正法の開発〔論文内容及び審査の要旨〕
Author(s)	野村, 友祐
Description	配架番号 : 2552
Degree Grantor	北海道大学
Degree Name	博士(医学)
Dissertation Number	甲第14086号
Issue Date	2020-03-25
Doc URL	https://hdl.handle.net/2115/77941
Rights(URL)	https://creativecommons.org/licenses/by/4.0/
Type	doctoral thesis
File Information	Yusuke_Nomura_abstract.pdf, 論文内容の要旨



学位論文内容の要旨

博士の専攻分野の名称 博士（医 学） 氏 名 野村 友祐

学 位 論 文 題 名

散乱カーネル法と深層学習を用いた適応陽子線治療のための新しい CBCT 散乱線補正法の開発

(Development of novel CBCT scatter correction methods for adaptive proton therapy using scatter kernel superposition and deep learning)

【背景と目的】北海道大学病院で行われている陽子線治療は、局所集中性が高くターゲットにのみ高線量を付加できるが、患者の体内構造の変化によって大きな線量誤差が現れる可能性がある。コーンビーム CT (CBCT) は治療直前の CT 画像を取得できるため、CBCT 画像を使用すれば治療開始時点の陽子線線量分布が計算できると期待される。しかし、散乱線の影響により CBCT 画像の画質はファンビーム CT (FBCT) 画像より悪い。

CBCT 画像で陽子線線量分布を計算する方法として deformable image registration (DIR) を使用した研究が多く行われているが、DIR 法には様々な問題がある。DIR 法以外の散乱線補正法を使用した CBCT 画像が陽子線線量分布に与える影響を考察した研究はあまり無かった。

本研究は新しい CBCT 散乱線補正法を開発し、陽子線線量分布の計算精度に与える影響を検証することを目的とした。第 2 章では modified fast adaptive scatter kernel superposition (mfASKS) 法を開発し、その補正能を複数の被写体と撮像条件で評価した。さらに、mfASKS 法が陽子線線量分布計算精度に及ぼす影響を検証した。第 3 章では畳み込みニューラルネットワーク (CNN) を使用した新たな散乱線補正法を開発した。また、CNN を学習させるための最適な誤差関数について考察した。

第 2 章 新たな散乱カーネル法 (mfASKS 法) の開発

【対象と方法】散乱線を含むプロジェクション画像から散乱線のみを取り除く mfASKS 法を開発した。補正に必要な全てのパラメータは実験データから得られる。散乱カーネルは点拡がり関数 (PSF) を使用して計算され、PSF の中心信号強度、定数、強度を補正した。その他のパラメータは mfASKS 補正した再構成画像の平坦度を最適化することで校正した。mfASKS 法の補正能を検証するため、Monte Carlo (MC) シミュレーションを使用し散乱線を全て排除した CBCT 再構成画像を計算して、補正前後の再構成画像と比較した。さらに、陽子線阻止能比 (SPR) 画像の精度も評価した。mfASKS 法が陽子線線量分布の計算精度に与える影響を検証した。4 種類の異なるファントムを使用し、計画された線量分布と実際に照射される線量分布の誤差を計算した。その誤差が mfASKS 補正でどのように変化するか評価した。

【結果】mfASKS 補正を行った CBCT 画像の信号強度は真のプライマリー画像の信号強度に近くなる。さらに、被写体表面からターゲット中心までの水等価長の精度が mfASKS 補正によって改善される。mfASKS 補正を行わなかった SPR 画像で計算した陽子線線量分布は実際に照射される線量分布と大きく異なり、特に陽子線遠位端で大きな線量の過大評価がある。

一方、補正後の SPR 画像で計算された線量分布は実際の線量分布とよく一致している。MC シミュレーションと実験の両方で同様の結果が得られたため、散乱線が原因の陽子線線量分布の誤差が mfASKS 法によって改善されることが分かった。

【考察】mfASKS 法で補正した CBCT 画像は陽子線線量分布を正確に計算できることが分かった。この結果は DIR 法と同様であるが mfASKS 法は DIR を使用しないため、本手法は空間的な確かさの観点で優位な方法であると考えられる。mfASKS 法の問題点の一つに空気や骨など水等価物質以外の物質に対して補正能が高くない点がある。これは mfASKS モデルが被写体を水等価物質のみで構成されていると仮定していることが原因である。この問題を解決するために、第 3 章では自ら学習してモデルを構築する深層学習を使用した方法を開発した。

第 3 章 CNN を使用した CBCT 散乱線補正法の開発

【対象と方法】CNN を使用して散乱線を含むプロジェクション画像から散乱線のみを除去する新たな散乱線補正法を開発した。CNN を学習させるため、MC シミュレーションを使用して 5 種類のファントムのプロジェクション画像を合計 1800 枚計算した。データセットの全画像を各 100 回ずつランダムに学習させた。学習が完了した CNN モデルで補正した頭部ファントム再構成画像を補正前、mfASKS 補正後と比較した。誤差関数が CNN 補正に及ぼす影響を検証するため、二種類の異なる誤差関数で同じ CNN を学習し、補正能の違いを評価した。転移学習を使用して異なる撮像条件のプロジェクション画像のための CNN モデルに適応させた。

【結果】平均絶対誤差 (MAE) を誤差関数として学習した CNN モデルで補正した再構成画像の方が mfASKS 補正した再構成画像より散乱線を正確に補正できることが分かった。4 種類の画質指標で CNN 補正の方が mfASKS 法より優れた散乱線補正法であると示した。転移学習を用いることで異なる撮像条件のプロジェクション画像をより正確に補正できる CNN モデルを少ない学習用データで作成できた。360 枚のプロジェクション画像を補正するためにかった計算時間が約 5.5 分 (mfASKS 法) から約 4.8 秒 (CNN) まで減少した。

【考察】MAE を誤差関数とした CNN モデルの方が平均二乗誤差 (MSE) を使用した CNN モデルよりもよい補正能を示した。この要因の一つに MAE の方が真のプライマリープロジェクション画像の信号強度に依存しない関数であることが考えられる。真のプライマリープロジェクション画像の依存度を変更できる誤差関数を使用して検証した結果、この考察は有効であることが確認された。本章で使用した学習手法は先行研究よりも簡便で正確に学習が行えると考えられる。さらに、プロジェクション画像に対して行う散乱線補正は再構成画像に対して行う補正よりも、CNN の特徴を効果的に利用できるなどの利点がある。深層学習を実際に医療で使用するためには、学習したモデルを人間が解釈できない点などの課題も残されている。

【結論】本研究によって mfASKS 法が CBCT 画像を使用した陽子線線量分布の計算精度を向上させることが分かった。さらに、CNN を使った新たな散乱線補正法は mfASKS 法よりもさらに正確で高速に散乱線を補正できる。従って、CNN モデルを採用した CBCT 陽子線線量分布計算法の方がより正確で高速な方法であると期待される。これまでは CBCT 画像から陽子線線量分布を計算し評価するだけであったが、本研究によって計算時間が短くなり照射前に治療計画を再最適化できることが期待される。今後は CNN の有効性を実際の CBCT 装置を用いて評価し、陽子線治療の精度を上げるための信頼できる深層学習技術を開発することを目標とする。