

令和元年6月25日現在

機関番号：13101

研究種目：若手研究(B)

研究期間：2016～2018

課題番号：16K19226

研究課題名（和文）機械学習を用いた強度変調放射線治療の故障モード自動判別システムの開発

研究課題名（英文）Machine learning modeling of automatic detection of failure modes in IMRT patient-specific QA

研究代表者

宇都宮 悟 (Utsunomiya, Satoru)

新潟大学・医歯学系・助教

研究者番号：50570868

交付決定額（研究期間全体）：（直接経費） 2,800,000円

研究成果の概要（和文）：強度変調放射線治療（IMRT）はその投与線量の不確かさが比較的大きい照射法である。照射精度を担保するために実施されるのがIMRT線量検証であるが、現在最も良く用いられている「ガンマ解析」の手法では、誤差の原因（故障モード）の特定が困難である。本研究では、医用画像の特徴量抽出において広く用いられるラジオミクス手法を用いて、IMRT線量分布の特徴量を抽出しそれを学習データとする機械学習モデルを構築した。モデルは4種類のIMRT故障モードに対していずれも高い判別精度を示した。今後、実際の測定データを用いた場合でも高い判別能力を示すかどうかの検証が必要である。

研究成果の学術的意義や社会的意義

本研究は、CTやMRI等の医用画像の特徴量抽出に用いられる事の多かったラジオミクス手法を、線量分布の特徴量抽出に適用することで有用な情報を引き出そうとする点で新規性が高い。また、本研究はIMRTの患者個別の線量検証における不具合を簡便に検出できるようになることを目指しているため、IMRTの実施に先立っての安全性の担保を以前より簡易的にかつ短時間で実施できるようになることが見込まれる。従って、IMRTの更なる普及や治療可能な患者数の飛躍的な増大につながる事が期待される。

研究成果の概要（英文）：Intensity-modulated radiation therapy (IMRT) is a technique of radiation therapy with a relatively large dose uncertainty. IMRT dose verification is performed to assure that the radiation dose is accurately irradiated. The most commonly used “gamma analysis” method in IMRT dose verification has a problem that it is difficult to identify the cause of the error (failure mode). In this study, we constructed a machine learning model that uses the radiomic features, a widely used method in extracting features from medical images, as learning data set. The model showed high discrimination accuracy for all four analyzed IMRT failure modes. In the future, it may be necessary to verify the accuracy of the machine learning models with actual measured data as learning data set.

研究分野：医学物理学

キーワード：強度変調放射線治療 機械学習 ラジオミクス

様式 C - 19、F - 19 - 1、Z - 19、CK - 19 (共通)

1. 研究開始当初の背景

強度変調放射線治療 (IMRT) は投与線量の不確かさが比較的大きい手法であるので、全 IMRT 治療計画に対して線量分布検証が行われる。しかし、現在線量分布検証に良く用いられる「ガンマ解析」と呼ばれる手法では、故障モードの特定が難しいことが知られている。

2. 研究の目的

本研究は、故障モードの特定に適した新しい線量分布検証法を開発するとともに、機械学習の手法を応用して IMRT の線量分布検証結果のパターン解析から故障モードの特定を自動で行う事のできるシステムを開発する事を目的とする。


3. 研究の方法

本研究では、機械学習の手法を応用して IMRT の線量分布検証結果のパターン解析から故障モードの特定を自動で行う事のできるシステムの開発を行う。本研究は下記のような順で研究を進めていくこととした。


- (1) グラフ解析の手法を用いて故障モードの特定に適した新しい線量分布検証法の開発を行う。
- (2) IMRT の故障モードのデータベースの構築を行う。データベースに含まれる代表的な故障モードは、フィルムや多次元検出器などの設置誤差 (位置誤差)、治療計画装置のコミッションの不確かさ (コミッション誤差)、特定の MLC の位置誤差 (MLC 誤差) の3種類とする。
- (3) 任意の患者やその治療計画において最も可能性の高い故障モードを自動で判別する機械学習システムの開発を行う。

4. 研究成果

(1) 本研究では、IMRT の故障モードの特定を行う際にグラフ解析を用いた評価法を用いた。グラフの横軸は治療計画装置で計算された線量、縦軸は測定された線量の値とする。グラフ中の各点はそれぞれ線量分布上の異なる位置を表す。このグラフの対角線上の点は線量の計算値と測定値の一致を表すため、対角線からどの程度ずれるかを基に検証結果を評価することになる。このグラフを用いれば、線量誤差が大きいのは低線量域か高線量域か、などの特徴も簡便に捉える事ができる。上記のようなグラフを便宜上「線量分布検証グラフ」と呼ぶことにする。線量分布検証グラフを「位置誤差」と「MLC 誤差」に対して作成すると右図 (左: 位置誤差、右: MLC 誤差) のようになる。このグラフを見ても分かるように、故障モードの種類に応じてグラフの特徴が変化し、この特徴から故障モードの判別が行えることが示唆された。しかし、線量分布検証グラフを学習データとして機械学習モデル (k 近傍法、サポートベクトルマシン、アンサンブル法) を構築し判別性能を評価したところ、コミッション誤差の判別は不可能なことが示され、本手法の限界も明らかになった。

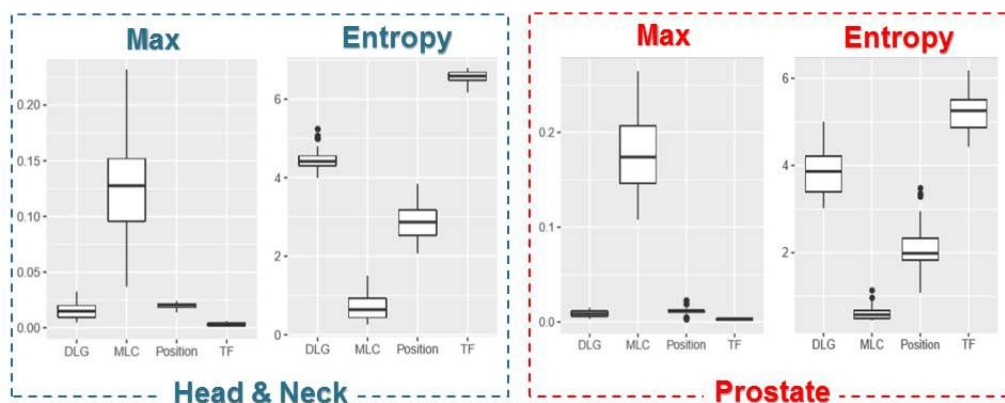


(2) (1)の結果を受けて、故障モードの特徴を抽出する方法の再検討を行った。誤差のある線量分布と誤差の無い線量分布の差分に対してヒストグラムを作成し、ラジオミクス (radiomics) 特徴量 (最大値、最小値、平均値、中央値、標準偏差、エントロピー、歪度、尖度) をそれぞれ計算しその値を学習データとして機械学習モデルを作成する手法を考案した (下図)。本手法の妥当性を検討するために、位置誤差、MLC 誤差、MLC トランスミッションファクター誤差 (コミッション誤差の一種)、MLC ギャップ幅誤差 (コミッション誤差の一種) のそれぞれについて前立腺がん患者 10 例、頭頸部がん患者 10 例の治療計画の線量分布について上記のラジオミクス特徴量を計算し、~ の間で統計検定 (ウィルコクソンの順位和検定) を行い P 値と効果量 (effect size) を求めた。結果、すべて ~ の誤差に対して、ほぼ全てのラジオミクス特徴について有意差が認められた ($P < 0.05$)。効果量は、~ については高いもので最大値 1 に近い値を示したが、~ については最大で 0.48 であった。つまり、本手法は総じて高い有効性を示したが、MLC ギャップ幅誤差の検出はやや困難であることが示唆された。



(3) (2)の結果から、ラジオミクス特徴量を基に故障モードを判別することの妥当性が検証されたので、ラジオミクス特徴量を学習データとする機械学習モデル (サポートベクトルマシン、

ロジスティック回帰)を構築し、10分割交差検定を行いそのモデルの判別精度を評価した。ラジオミクス特徴量は(2)の統計解析結果において効果量の値が大きかった上位2位までのものを用いた。判別性能はROC解析のAUC(area under the ROC)の値で評価した。AUCの値はMLCギャップ幅誤差以外の故障モードで0.99または1.00であり非常に高い判別精度を示した。MLCギャップ幅誤差では、AUCの値は0.73であり他の故障モードと比べてやや低い判別精度を示した。この結果は、(2)の統計解析の結果と一致している。本解析の結果より、前立腺がんのIMRT治療計画と頭頸部がんのIMRT治療計画では、ある特定の故障モードの判別に有効なラジオミクス特徴量は同じである傾向が見られた(下図)。つまり、本手法はIMRTの治療部位によらずに有効である可能性が示唆された。今後の課題としては、実際のIMRT線量検証で測定された線量分布を用いて故障モードが特定できるかどうかの検証を行う事が挙げられる。また、本研究の成果を61th American Association of Physicists in Medicine (AAPM) Annual Meetingで報告する予定であり、英語論文として発表する準備も進めている。



5. 主な発表論文等

〔雑誌論文〕(計0件)

〔学会発表〕(計3件)

Madoka Sakai, Haruka Koarai, Masataka Ueda, Shogo Shigeta, Hisashi Nakano, Takeshi Takizawa, Satoshi Tanabe, Ryuta Sasamoto, Hidefumi Aoyama, Satoru Utsunomiya, Machine learning with radiomic features to detect the types of errors in IMRT patient-specific QA, The 61th American Association of Physicists in Medicine (AAPM) Annual Meeting (米国・サンアントニオ)(国際学会), 2019年(予定)

坂井まどか、小荒井陽花、笹本龍太、青山英史、宇都宮悟、Feasibility of detecting the cause of errors in IMRT patient specific QA using radiomic features and machine learning, 第117回日本医学物理学会学術大会(横浜市)2019年

Utsunomiya S, Sakai M, Koarai H, Takizawa T, Kushima N, Tanabe S, Aoyama H, A Machine Learning-Based Approach to Specify the Cause of Error in IMRT Patient Specific QA, The 60th American Association of Physicists in Medicine (AAPM) Annual Meeting (米国・ナッシュビル)(国際学会), 2018年

〔図書〕(計0件)

〔産業財産権〕

出願状況(計0件)

名称:

発明者:

権利者:

種類:

番号:

出願年:

国内外の別:

取得状況(計0件)

名称:

発明者:

権利者:

種類:

番号:

取得年：
国内外の別：

〔その他〕
ホームページ等

6. 研究組織

(1) 研究分担者

研究分担者氏名：

ローマ字氏名：

所属研究機関名：

部局名：

職名：

研究者番号（8桁）：

(2) 研究協力者

研究協力者氏名：

ローマ字氏名：

科研費による研究は、研究者の自覚と責任において実施するものです。そのため、研究の実施や研究成果の公表等については、国の要請等に基づくものではなく、その研究成果に関する見解や責任は、研究者個人に帰属されます。