

状態空間時系列モデルに基づく肺腫瘍位置の呼吸性移動時系列予測

Prediction of respiration-induced lung tumor motion by using state-space representation of time series component models

○佐藤 雄介*, 市地 慶*, 本間 経康*

○Yusuke Sato*, Kei Ichiji*, Noriyasu Homma*

*東北大学

*Tohoku University

キーワード：状態空間時系列モデル (State-space representation of time series component models), 放射線治療 (Radiation therapy), 自己回帰モデル (Autoregressive model), トレンド成分モデル (Trend component model), カルマンフィルタ (Kalman filter)

連絡先：〒980-8575 仙台市青葉区星陵 2-1 東北大学大学院医学系研究科医用画像工学分野

佐藤 雄介, Tel.: (022)717-7914, E-mail: y_sato@rii.med.tohoku.ac.jp

1. はじめに

現代のがん治療では、がんに対するさまざまな治療法が提案・確立されている一方で、がん患者の数は依然として増えており、がん治療の重要性は年々増している¹⁾。がんの主な治療方法には外科的療法、化学療法、放射線治療の主に3つがあり、このうち放射線治療は低侵襲性・副作用の局所性という点で他の治療法に比べて大きな利点を持つことからその利用拡大が進められている。

放射線治療では治療効果を最大限に高めるために、十分な線量を患部に照射しながらも正常組織への放射線被ばく障害を可能な限り低減することが求められる。しかし肺腫瘍のような呼吸性移動を伴う腫瘍の場合は、照射中に腫瘍が移動してし

まうため、腫瘍のみに集中した放射線照射を実現するためには、腫瘍位置変動のリアルタイムな計測と位置変動に応じた照射の制御といった呼吸性移動対策が必要となる²⁾。

有力な呼吸性移動対策の1つとして、呼吸に合わせて照射範囲を動かす動体追尾照射が挙げられる²⁾。Fig. 1に示すような臨床で広く利用されている放射線治療装置(リニアック)により動体追尾照射を行う場合、Fig. 2に示す Multi-leaf Collimator (MLC) と呼ばれる放射線遮蔽装置を腫瘍の移動に合わせて動かして照射範囲を調整する方式が想定されている²⁾。しかし、体内腫瘍位置の計測と照射制御にかかる時間により数百ミリ秒の時間遅れが発生することが報告されている³⁾。



Fig. 1 放射線治療装置（リニアック）



・放射線遮蔽用の鉛板
赤枠内で動作させ照射範囲を制御する

Fig. 2 Multi-Leaf Collimator (MLC)

動体追尾照射システムに内在する時間遅れを補償し、正確な照射を実現するためには数百ミリ秒先の腫瘍位置の予測が必要である。このため、これまでに腫瘍位置の時系列予測手法として、線形・非線形の回帰手法をはじめとしてさまざまな手法が提案されている⁴⁾。動体追尾照射の正確性は腫瘍位置の呼吸性移動の予測の正確性に依存するため、予測性能の追求は現在も課題のひとつとなっている。

肺腫瘍位置の呼吸性移動時系列の例を Fig. 3 に示す。この例に見られるように、肺腫瘍の移動には、呼息と吸息の繰り返しによる周期的・振動的な成分が観察される。くわえて、ほかの体内臓器からの圧迫などにより、振動的振る舞いの中心軸であるベースラインの移動も見て取ることができる。このように肺腫瘍の呼吸性移動時系列は、異なる性質をもつ複数の時系列成分から構成され⁵⁾、




Fig. 3 肺腫瘍の呼吸性移動時系列とその成分

全体として複雑な振る舞いを見せる。

呼吸性移動時系列のより正確な予測の達成には、異なる複数の時系列成分をそれぞれ正確に予測することが重要と考えられる。そこで本研究では、呼吸性移動時系列に含まれる主要な成分であるベースライン成分と振動的成分をそれぞれトレンド成分モデル (Trend component model) と自己回帰 (Autoregressive model, AR) 成分モデルによりそれぞれモデリングし、また観測された呼吸性移動時系列よりこれらの 2 成分を分離し予測する手法について検討する。2 つの時系列成分モデルの分離・予測と統合の実現にあたり、本稿では時系列成分モデルの状態空間表現 (State-space representation of time series component models) を導入する^{6,7)}。複数の時系列成分モデルをひとつの状態空間モデルへと統合して表現することで、呼吸性移動時系列からの各時系列成分の分離・予測は、観測値から状態の推定・予測の問題として扱うことでカルマンフィルタなどにより効率的に予測計算を可能とする。本稿では、呼吸性移動時系列の実データを用いた予測実験により、AR+トレンド成分モデル、AR モデル単独、そしてトレンド成分モデル単独の予測性能を比較し、複数成分を想定した状態空間時系列モデルの有効性を検証する。

2. 状態空間時系列モデルを用いた呼吸性移動の予測

本研究では呼吸性移動時系列をベースライン成




Fig. 4 提案モデルによる予測のイメージ

分とベースライン周りの振動成分の 2 つの時系列に分離して考え、各成分の時系列モデルの状態空間表現を単一の状態空間時系列モデルに統合する。各成分の分離と予測にはカルマンフィルタ (Kalman filter) を用いて状態の推定を行う。Fig. 4 に提案モデルによる予測のイメージを示す。

2.1. 時系列モデルの状態空間表現

状態空間時系列モデル、または時系列成分モデルの状態空間表現 (State-space representation of time series component models) を用いることで、観測時系列に含まれる各時系列成分の分離と予測は状態推定の問題として定式化することが可能である。本稿では、1 次元の観測時系列 $\{y_n\}$, $n = 1, 2, \dots$ に関する次式の線形・ガウス型状態空間時系列モデルを検討する：

$$\mathbf{x}_n = \mathbf{F}\mathbf{x}_{n-1} + \mathbf{G}\mathbf{v}_n \quad (1)$$

$$y_n = \mathbf{H}\mathbf{x}_n + w_n \quad (2)$$

ここで、 \mathbf{x}_n は直接に観測できない l 次元の状態ベクトルであり、観測時系列に含まれる時系列成分により構成される。 \mathbf{v}_n はシステム雑音と呼ばれ、平均 0、分散共分散行列 \mathbf{Q} の q 次元正規分布に従う雑音である。一方、 w_n は平均 0、分散共分散行列 R の 1 次元正規分布に従う雑音である。 $\mathbf{F}, \mathbf{G}, \mathbf{H}$

は状態遷移のダイナミクス、システム雑音の状態への付加、観測雑音の観測時系列への付加を規定するそれぞれ $l \times l$, $l \times q$, $l \times 1$ の行列である。

(2) 式の状態空間時系列モデルは、時系列解析で用いられる線形・ガウス型時系列モデルの多くを表現でき、統一的に取り扱うことを可能とする⁶⁾。

2.2. 呼吸性移動時系列の状態空間モデリング

2.2.1. トレンド成分モデル

Fig. 3 に示したように呼吸性移動時系列には振動的成分の中心軸のゆっくりとした時間変化であるベースライン成分が含まれる。このベースライン成分を表すモデルとして本研究ではトレンド成分モデルを用いる⁷⁾。トレンド成分モデルは長期間にわたって増加や減少が続くような振る舞いの表現に有用なモデルの 1 つであり、時系列のおおよその傾向を表すことが可能である。

トレンド成分の表現にあたり、トレンド成分の時系列 T_n の k 階差分を考える。

$$\Delta^k T_n = v_n \quad (3)$$

ここで、 $\Delta^k T_n$ は時系列 T_n の k 階差分、 v_n は平均 0、分散 τ^2 の 1 次元正規分布に従うシステム雑音であり、トレンド成分に生じる微小変化を表す。

呼吸性移動時系列に含まれるベースライン成分

の表現にあたっては、式 (3) で $k = 2$ とした次の 2 階差分トレンドを用いる：

$$T_n = 2T_{n-1} - T_{n-2} + v_n \quad (4)$$

上式は、局所的には一定の速度がシステム雑音により時間変化することに対応する。すなわち、

$$T_n - T_{n-1} = T_{n-1} - T_{n-2} + v_n. \quad (5)$$

トレンド成分モデル単独に従う時系列 y_n は、(5) 式のトレンド成分 T_n に観測雑音 w_n を用いて次の式で表される。

$$y_n = T_n + w_n \quad (6)$$

ただし観測雑音 w_n は平均 0、分散 σ^2 で表される 1 次元正規分布に従う雑音である。

(4) 式と (6) 式のトレンド成分モデルを状態空間時系列モデルで表現する。式 (5) より 2 次の状態ベクトルを下記のように定義する。

$$\mathbf{x}_n = (T_n, T_{n-1})^T \quad (7)$$

このとき、 2×2 行列 \mathbf{F} および 2×1 行列 \mathbf{G} 、 1×2 行列 \mathbf{H} を

$$\mathbf{F} = \begin{bmatrix} 2 & -1 \\ 1 & 0 \end{bmatrix}, \mathbf{G} = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, \quad (8)$$

$$\mathbf{H} = [1 \quad 0]$$

と定義すれば、次のようなトレンド成分モデルの状態空間時系列モデルが得られる。

$$\begin{bmatrix} T_n \\ T_{n-1} \end{bmatrix} = \begin{bmatrix} 2 & -1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} T_{n-1} \\ T_{n-2} \end{bmatrix} + \begin{bmatrix} 1 \\ 0 \end{bmatrix} v_n \quad (9)$$

$$y_n = [1 \quad 0] \begin{bmatrix} T_n \\ T_{n-1} \end{bmatrix} + w_n \quad (10)$$

2.2.2. 自己回帰 (AR) モデル

ベースライン周りの振動成分の表すモデルとして自己回帰 (autoregressive, AR) モデルを用いる。AR モデルは過去の自分の値を回帰的に利用するモデルで、 p_n を定常時系列成分としたとき、

$$p_n = \sum_{i=1}^m a_i p_{n-i} + v_n \quad (11)$$

と表現される。ただし m は自己回帰の次数、 a_i は自己回帰係数である。 v_n は平均 0、分散 η^2 として

表される正規分布に従うシステム雑音である。

AR モデル単独に従う時系列 y_n は式 (11) より、

$$y_n = p_n + w_n \quad (12)$$

で表される。ただし w_n は平均 0、分散 σ^2 で表される 1 次元正規分布に従う観測雑音である。

AR 成分モデルの状態空間表現にあたっては、式 (10) より以下の m 次の状態ベクトルを定義する。

$$\mathbf{x}_n = (p_n, \dots, p_{n-m+1})^T \quad (13)$$

このとき $m \times m$ 行列 \mathbf{F} および $m \times 1$ 行列 \mathbf{G} 、 $1 \times m$ 行列 \mathbf{H} を

$$\mathbf{F} = \begin{bmatrix} a_1 & a_2 & \dots & a_m \\ 1 & 0 & \dots & 0 \\ \vdots & \ddots & & \vdots \\ 0 & 0 & 1 & 0 \end{bmatrix}, \mathbf{G} = \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \quad (14)$$

$$\mathbf{H} = [1 \quad 0 \quad \dots \quad 0]$$

と定義すると、次のような AR モデルの状態空間時系列モデルが得られる。

$$\begin{bmatrix} p_n \\ p_{n-1} \\ \vdots \\ p_{n-m+1} \end{bmatrix} = \begin{bmatrix} a_1 & a_2 & \dots & a_m \\ 1 & 0 & \dots & 0 \\ \vdots & \ddots & & \vdots \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} p_{n-1} \\ p_{n-2} \\ \vdots \\ p_{n-m} \end{bmatrix} + \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix} v_n \quad (15)$$

$$y_n = [1 \quad 0 \quad \dots \quad 0] \begin{bmatrix} p_n \\ p_{n-1} \\ \vdots \\ p_{n-m+1} \end{bmatrix} + w_n \quad (16)$$

2.2.3. AR+トレンド成分モデル

2.2.1 と 2.2.2 節で導入したトレンド成分モデルと AR モデルを組み合わせた次のようなモデル (以下、AR+トレンド成分モデル) を考える。

$$y_n = p_n + T_n + w_n \quad (17)$$

ただし w_n は平均 0、分散 σ^2 で表される正規分布に従う雑音である。AR+トレンド成分モデルは、ベースライン成分とベースライン周りの振動成分を組み合わせることで呼吸性移動時系列を表現するモデルである。

AR+トレンド成分モデルの状態空間時系列モデ

ルを考える．はじめにトレンド成分モデルと AR モデルの状態ベクトルを連結することで，次のような $l = (k + m)$ 次元状態ベクトルを定義する：

$$\mathbf{x}_n = (T_n, \dots, T_{n-k+1}, p_n, \dots, p_{n-m+1})^T \quad (18)$$

トレンド成分 T_n と AR 成分 p_n はそれぞれ独立に式 (9), (14) に従うと考えれば， $(2 + m) \times (2 + m)$ 行列 \mathbf{F} および $2 \times (2 + m)$ 行列 \mathbf{G} ， $1 \times (2 + m)$ 行列 \mathbf{H} を以下のように定義できる．

$$\mathbf{F} = \begin{bmatrix} 2 & -1 & 0 & \cdots & \cdots & 0 \\ 0 & 1 & 0 & \cdots & \cdots & 0 \\ 0 & 0 & a_1 & a_2 & \cdots & a_m \\ \vdots & \vdots & 1 & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & & \vdots \\ 0 & 0 & 0 & & 1 & 0 \end{bmatrix}, \mathbf{G} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 0 & 0 \\ \vdots & \vdots \\ 0 & 0 \end{bmatrix}, \quad (19)$$

$$\mathbf{H} = [1 \ 0 \ 1 \ 0 \ \cdots \ 0]$$

以上をまとめると，次のように AR モデルとトレンド成分モデルを統合したひとつの状態空間時系列モデルが得られる．

$$\begin{bmatrix} T_n \\ T_{n-1} \\ p_n \\ p_{n-1} \\ \vdots \\ p_{n-m+1} \end{bmatrix} = \begin{bmatrix} 2 & -1 & 0 & \cdots & \cdots & 0 \\ 0 & 1 & 0 & \cdots & \cdots & 0 \\ 0 & 0 & a_1 & a_2 & \cdots & a_m \\ \vdots & \vdots & 1 & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & & \vdots \\ 0 & 0 & 0 & & 1 & 0 \end{bmatrix} \begin{bmatrix} T_{n-1} \\ T_{n-2} \\ p_{n-1} \\ p_{n-2} \\ \vdots \\ p_{n-m} \end{bmatrix} + \begin{bmatrix} 1 & 0 \\ 0 & 0 \\ 0 & 1 \\ 0 & 0 \\ \vdots & \vdots \\ 0 & 0 \end{bmatrix} \mathbf{v}_n \quad (20)$$

$$y_n = [1 \ 0 \ 1 \ 0 \ \cdots \ 0] \begin{bmatrix} T_n \\ T_{n-1} \\ p_n \\ p_{n-1} \\ \vdots \\ p_{n-m+1} \end{bmatrix} + w_n \quad (21)$$

ただし， \mathbf{v}_n は 2 次元正規分布に従うシステム雑音であり，その平均 $\boldsymbol{\mu}$ と分散共分散行列 \mathbf{Q} は，トレンド成分モデルと AR モデルのシステム雑音の分散 τ^2 と η^2 より，以下のように与えられる：

$$\boldsymbol{\mu} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, \mathbf{Q} = \begin{bmatrix} \tau^2 & 0 \\ 0 & \eta^2 \end{bmatrix} \quad (22)$$

2.3. カルマンフィルタによる時系列予測

状態空間時系列モデルを利用して，観測値 y_n の

予測を行うには，2.2 節で導入した各時系列成分から構成される状態 \mathbf{x}_n を推定・予測する必要がある．今回，トレンド成分モデル，AR モデル，AR+トレンドモデルはすべて線形・ガウス型の状態空間モデルである．そこで，本研究では Fig. 5 に示すようにカルマンフィルタ (Kalman filter) により状態の推定・予測を行う．以下では，カルマンフィルタによる状態の推定・予測と観測値の予測について文献⁷⁸⁾に基づき説明する．

2.3.1. カルマンフィルタによる状態推定と予測

カルマンフィルタは時刻 $n-1$ における状態 \mathbf{x}_{n-1} の推定値の平均 $\mathbf{x}_{n-1|n-1}$ と分散共分散行列 $\mathbf{V}_{n-1|n-1}$ から，時刻 n の状態 \mathbf{x}_n の予測値の平均 $\mathbf{x}_{n|n-1}$ と分散共分散行列 $\mathbf{V}_{n|n-1}$ を得る“1 期先予測”と，観測値 y_n を含む時刻 n までに得られた情報により状態予測値 $\mathbf{x}_{n|n-1}$ ， $\mathbf{V}_{n|n-1}$ を $\mathbf{x}_{n|n}$ ， $\mathbf{V}_{n|n}$ へと修正する“フィルタリング”と呼ばれる 2 つの処理を交互に実施することで，観測値から状態を逐次推定するアルゴリズムである．具体的に 1 期先予測とフィルタリングは以下のように計算される．

(1) 1 期先予測：

$$\mathbf{x}_{n|n-1} = \mathbf{F}\mathbf{x}_{n-1|n-1} \quad (23)$$

$$\mathbf{V}_{n|n-1} = \mathbf{F}\mathbf{V}_{n-1|n-1}\mathbf{F}^T + \mathbf{G}\mathbf{Q}\mathbf{G}^T \quad (24)$$

(2) フィルタリング：

$$\mathbf{K}_n = \mathbf{V}_{n|n-1}\mathbf{H}^T(\mathbf{H}\mathbf{V}_{n|n-1}\mathbf{H}^T + \mathbf{R})^{-1} \quad (25)$$

$$\mathbf{x}_{n|n} = \mathbf{x}_{n|n-1} + \mathbf{K}_n(y_n - \mathbf{H}\mathbf{x}_{n|n-1}) \quad (26)$$

$$\mathbf{V}_{n|n} = (\mathbf{I} - \mathbf{K}_n\mathbf{H})\mathbf{V}_{n|n-1} \quad (27)$$

式 (23) にあるように，1 期先予測のアルゴリズムにおいて \mathbf{x}_n の予測値 $\mathbf{x}_{n|n-1}$ は， \mathbf{x}_{n-1} のフィルタ値 $\mathbf{x}_{n-1|n-1}$ に遷移行列 \mathbf{F} をかけることで表される．また，その分散共分散行列 $\mathbf{V}_{n|n-1}$ の時間遷移は式 (24) で表されており， $\mathbf{F}\mathbf{V}_{n-1|n-1}\mathbf{F}^T$ は \mathbf{F} による変換の影響， $\mathbf{G}\mathbf{Q}\mathbf{G}^T$ はシステム雑音 \mathbf{v}_n の影響を表す．

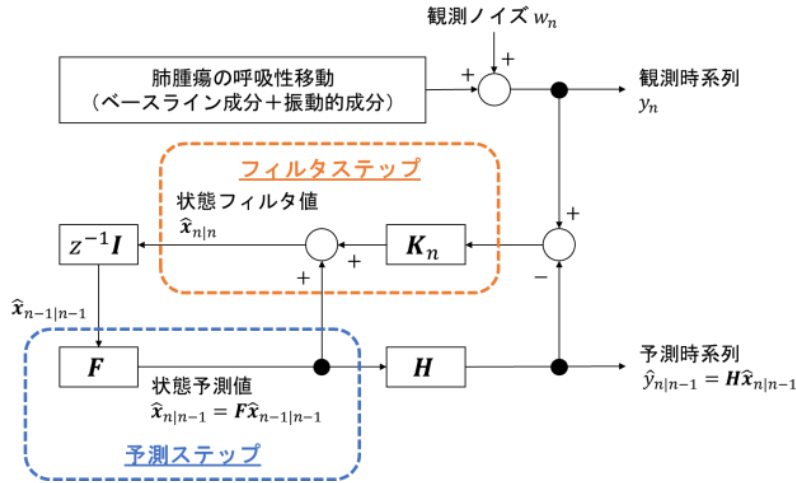


Fig. 5 カルマンフィルタによる呼吸性移動時系列からの状態推定と予測

フィルタリングのアルゴリズムでは、まず式 (25) により、カルマンゲインと呼ばれる K_n が求められる。ついで、式 (26) により、状態 x_n のフィルタ値 $x_{n|n}$ は、予測値 $x_{n|n-1}$ と観測値の 1 期先予測誤差 $y_n - Hx_{n|n-1}$ にカルマンゲインかけたものにより更新される。同様に、分散共分散行列予測値 $V_{n|n-1}$ もカルマンゲインを用いてフィルタ値 $V_{n|n}$ へと更新される。

カルマンフィルタでは、式 (23) より状態の推定とともに 1 期先予測値を得る。この 1 期先予測処理を繰り返す事で数期先の状態の予測も可能である。いま、時刻 n までの観測時系列 $\{y_1, \dots, y_n\}$ に基づいて j 期先の状態 x_{n+j} ($j > 1$) を推定する場合を考える。このとき、カルマンフィルタにより x_{n+1} の 1 期先予測の平均 $x_{n+1|n}$ および分散共分散行列 $V_{n+1|n}$ が求められる。ここで観測値 y_{n+1} は未知であるため、フィルタ処理は実行不可能である。そこでこれを省略し、予測値 $x_{n+1|n}$ および $V_{n+1|n}$ を、時刻 $n+1$ のフィルタ値 $x_{n+1|n+1}$ および $V_{n+1|n+1}$ とみなせば、次の 2 期先予測に関する式が得られる。

(3) 2 期先予測：

$$x_{n+2|n} = Fx_{n+1|n} \quad (28)$$

$$V_{n+2|n} = FV_{n+1|n}F + GQG^T \quad (29)$$

2 期先予測と同様の手順を繰り返すことで、 $i = 1, \dots, j$ 期先予測に関する式が次のように得られる。

(4) 多段階予測：

$$x_{n+i|n} = Fx_{n+i-1|n} \quad (30)$$

$$V_{n+i|n} = FV_{n+i-1|n}F + GQG^T \quad (31)$$

2.3.2. 観測値の多段予測

時系列成分(状態)の多段予測値 $x_{n+i|n}$ が式 (30) により求まると、観測値 y_{n+i} の多段予測値 $y_{n+i|n}$ は式 (2) の観測方程式に基づき、次式により求められる：

$$y_{n+i|n} = Hx_{n+i|n} \quad (32)$$

3. 予測性能の評価実験

提案する AR+トレンド成分モデルによる呼吸性移動時系列の予測性能を評価するため、実データを用いた予測実験を行った。

3.1. 予測対象データ

<http://signals.rob.uni-luebeck.de> においてオンライン公開されている腫瘍の呼吸性移動時系列データベースのうちの 1 つを用いて予測性能の評価を行った⁹⁾。Fig. 6 に本研究で用いた呼吸性移動時系列 ('p10_f33_m1_proc2_pca') を示す。

なお、本データベースは米国 Georgetown

University Hospital において CyberKnife Synchrony システムにより計測された治療中の肺がんの呼吸性移動時系列(肺癌患者 31 名 304 例分)から構成されている。詳細な解析については文献⁵⁾を参照されたい。

3.2. 比較予測モデルとパラメータ設定

実験に用いた予測手法とそのパラメータ設定を下記に示す。パラメータ推定には予測性能評価区間の直前 60 s 分 (60 s × 26 Hz = 1560 サンプル) の観測値を用いた。

(1) トレンド成分モデル単独

システム雑音の分散共分散行列 \mathbf{Q} と観測雑音の分散共分散行列 \mathbf{R} には, Neldar-Mead 法 (滑降シンプレックス法) を用いた数値最適化により, 以下の最尤推定値を設定した。

$$\mathbf{Q} = 1.515 \times 10^{-9}, \mathbf{R} = 1.159 \times 10^{-4}$$

(2) AR モデル単独

AR モデルの次数は赤池情報量規準により $m = 61$ とし, Burg 法による最小二乗推定値を使用して AR 係数 a_1, \dots, a_m を求めた。また, システム雑音と観測雑音の分散共分散行列 \mathbf{Q} と \mathbf{R} はトレンド成分モデル単独と同様に Neldar-Mead 法による以下の最尤推定値を用いた。

$$\mathbf{Q} = 1.578 \times 10^{-3}, \mathbf{R} = 3.501 \times 10^{-4}$$

(3) AR+トレンドモデル (提案法)

AR モデル単独と同様に, AR モデル次数 $m = 61$ とし, AR 係数 a_1, \dots, a_m は Burg 法による最小二乗推定値を使用した⁷⁾。システム雑音と観測雑音の分散共分散行列 \mathbf{Q} と \mathbf{R} はトレンド成分モデル単独・AR モデル単独と同様に Neldar-Mead 法による最尤推定値を用いた。

$$\mathbf{Q} = \begin{bmatrix} 2.881 \times 10^{-9} & 0 \\ 0 & 1.550 \times 10^{-3} \end{bmatrix},$$

$$\mathbf{R} = 1.071 \times 10^{-6}$$

3.3. 性能評価指標

性能評価指標には予測された観測値の Root

Mean Square 誤差 (RMSE) を用いた。RMSE は次式で表される。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (33)$$

ただし, y_i は観測値, \hat{y}_i はその予測値, N は予測性能評価区間に含まれる観測データ数である。

3.4. 実験結果

各モデルによる 192 ms 先 ($j = 5$ 期先) 予測を 120 秒間 (120 s × 26 Hz = 3120 サンプル) にわたって実施した。

はじめに提案法である AR+トレンド成分モデルにより抽出されたトレンド成分 $T_{n|n}$ と AR 成分 $p_{n|n}$ の時系列を Fig. 7 と Fig. 8 にそれぞれ示す。Fig. 7 に示すように, トレンド成分では全時間においてゆっくりとした変動が -330 mm から -325 mm の範囲に確認された。これは Fig. 6 の観測時系列の中央付近の値によく対応している。このことから, 抽出されたトレンド成分がベースラインを表現できていることがわかる。また, Fig. 8 からは Fig. 6 の観測時系列によく似ているが, 0 mm を中心軸とした振動成分が得られている。このように AR モデルにより抽出された時系列成分は, ベースライン周りの振動成分によく対応していることがわかる。以上のように, AR+トレンド成分モデルは呼吸性移動に含まれる時系列成分をうまく分離できることが確認された。

次にそれぞれの予測モデルについての結果を示す。Fig. 9 から 11 に示す予測結果は 120 秒間の各予測モデルの予測結果のうち 50 秒から 80 秒の 30 秒間を示している。はじめにトレンド成分モデル単独による 192 ms 先 (5 期先) 予測結果を Fig. 9 に示す。Fig. 7 の AR+トレンド成分モデルにより分離されたベースライン成分と異なり, トレンド成分モデル単独の予測値 (赤色実線) は振動的な振る舞いも表現できており, 観測時系列とよく一




Fig. 6 予測対象の肺腫瘍位置の呼吸性移動時系列（観測時系列）




Fig. 7 AR+トレンドモデルにより抽出されたベースライン成分




Fig. 8 AR+トレンドモデルにより抽出された振動的成分

致した変動を示した。一方、振動的な振る舞いの頂点付近では予測値が実測値と大きく乖離する現象が確認され、その周辺で予測誤差が生じていることが確認できた。これはトレンド成分モデルが式(4)で表されるように局所的な速度を一定とみなしたモデルであることから頂点付近での速度変化に対応しきれていないことが原因と考えられる。トレンド成分モデル単独予測誤差は $RMSE = 0.272 \text{ mm}$ となった。

次にARモデル単独による予測結果を Fig. 10 に示す。ARモデル単独の予測値（緑色実線）につい

ても観測時系列とよく一致した変動を示した。一方、トレンド成分モデルでも見られた振動的な振る舞いの頂点付近で予測値が実測値と乖離する現象がわずかに確認され、その周辺で予測誤差が生じていることが確認できた。これはベースライン成分を表現できていないことが原因と考えられる。ARモデル単独の予測誤差は $RMSE=0.219 \text{ mm}$ であった。

最後に、提案法であるAR+トレンド成分モデルによる予測結果を Fig. 11 に示す。図から見て取れるように、AR+トレンド成分モデルによる予測値




Fig. 9 トレンド成分モデル単独による予測結果




Fig. 10 ARモデル単独による予測結果




Fig. 11 AR+トレンド成分モデルによる予測結果

(赤色実線)は、AR単独モデルとよく似た変動を示し、観測値ともよく一致した変動を示した。また、Fig. 10のARモデル単独の予測値に見られたような振幅の頂点付近での誤差が減少していることが確認できた。ARモデルとトレンド成分モデルの併用により、ARモデル単独では表現しきれなかったベースライン成分の変動が表現され、誤差減少の効果があったと考えられる。AR+トレンド成分モデルの予測誤差はRMSE=0.216 mmと今回評価したモデルの中で最小であった。以上のように、状態空間時系列モデルによりトレンド成分と

AR成分を分離・予測することで時系列モデル単独を用いる場合よりも予測性能が向上することが確認された。

3.5. 考察

本研究で提案した提案法のAR+トレンド成分モデルはARモデル単独、トレンドモデル単独よりも優れた予測性能を示した。動体追尾照射において呼吸性移動の予測性能は、放射線照射の正確度・精度に直結するため、今後も高い予測性能が求められると考えられる。提案法のように呼吸性移動時系列を主要な時系列成分に分離して予測す

るアプローチは、今後の更なる予測性能追求に有効であると考えられる。

本研究では、呼吸性移動時系列をガウス分布に従う線形・時不変の状態空間モデルで表現し、カルマンフィルタによる推定・予測を行った。一方、実際の肺腫瘍の呼吸性移動のダイナミクスには非線形性・時変性が含まれ、またその分布はガウス型とは限らないと考えられる。したがって、非線形・時変・非ガウス型のモデルにより時系列成分を表現し、これを拡張カルマンフィルタや粒子フィルタといった手法により推定・予測することで更なる予測性能向上が期待される。

4. おわりに

本研究では、放射線治療の肺腫瘍の動体追尾照射において必須技術である呼吸性移動の時系列予測の性能向上のために、状態空間時系列モデルを用いて呼吸性移動時系列に含まれる異なる性質の複数の時系列成分への分離・予測を試みた。単独成分モデルとの予測性能比較実験の結果より、AR+トレンド成分モデルの誤差が一番小さく、単独成分モデルによる予測と比べて予測性能が向上したことが確認された。このことは、状態空間時系列モデルにより、呼吸性移動時系列を複数の異なる性質を持つ時系列成分への分離・予測する手法の有効性を示唆する。

公開データベースの全データを用いて予測を行い、本手法の信頼性を確認すること、ならびに同一データベースによる検証を行っている先行研究の予測手法との性能比較が今後の課題である。

参考文献

- 1) 国立がん研究センターがん情報サービス：がん登録・統計、年次推移、
http://ganjoho.jp/reg_stat/statistics/stat/annual.html
- 2) P. J. Keall et al: The management of respiratory motion in radiation oncology report of AAPM Task Group 76, Med. Phys., 33-10, pp. 3874-900 (2006)
- 3) P. R. Poulsen et al.: Detailed analysis of latencies in image-based dynamic MLC tracking, Med. Phys., 37-9, pp. 4998-5005 (2010)
- 4) P. S. Verma et al: Survey: Real-Time Tumor Motion Prediction for Image-Guided Radiation Treatment, Comput. Sci. Eng., 13-5, pp.24-35 (2011)
- 5) Y. Suh et al: An analysis of thoracic and abdominal tumour motion for stereotactic body radiotherapy patients, Phys. Med. Biol., 53-13, pp. 3623-40 (2008)
- 6) 北川源四郎, 佐藤整尚：一般状態空間モデルによる分散変動時系列の解析, IMES Discussion Paper Series, Discussion Paper No. 98-J-22 (1998)
- 7) 北川源四郎：時系列解析入門, 岩波書店 (2005)
- 8) 足立修一, 丸田一郎：カルマンフィルタの基礎, 東京電機大学出版局 (2012)
- 9) F. Ernst: Compensating for Quasi-periodic Motion in Robotic Radiosurgery, Springer-Verlag New York (2012)