

異常肺音識別における音響モデル学習のためのデータベース拡張法の検討

代表研究者 山下 優 長崎大学 大学院総合生産科学研究科 技術専門職員

1 はじめに

呼吸器系に疾患を持つ患者の肺音には副雑音が含まれることが多く、聴診器を用いた肺音の聴診は、呼吸器系の疾患の検出に有効な手段である。肺音の聴診は古くから行われており、非侵襲的な診断方法でありながら、現代でも有効な診断方法の一つであり、広く行われている。しかし、医療に関する知識と経験が必要であり、医療従事者でなければ診断が難しく、一般の家庭で疾患の早期発見に利用することは困難である。そのため、医療機関への訪問が必須となり、医療機関が遠隔地にある場合や多忙により医療機関に行くことが難しい場合は受診する機会が制限されることになる。一方、肺音に含まれる副雑音の自動検出ができれば、血圧計のように家庭で肺音の検査が可能となり、離島や高齢化、多忙等により医療機関の受診が困難な者でも健康管理が可能となり、疾患の早期発見が期待できる。

従来は、疾患の検出を目的として、肺音に含まれる副雑音の自動検出に関する研究が行われてきた。これらの研究ではウェーブレット変換によって特定の副雑音を検出することや肺音のフレーム化処理を行い、それぞれのフレームの短時間スペクトルを求め、そのフレームが副雑音であるか副雑音ではないかを判定する手法が提案された[1-5]。しかし、肺音は呼吸に伴って変化する音であり、副雑音の生起するタイミングや長さがさまざまであるため、呼吸の全体の特徴とその時間的な変化を用いて判定する方が望ましいと考えられる。また、特定の副雑音のみを対象として検出していたが、副雑音は音響特徴が異なる複数の種類があるだけでなく、呼吸音や副雑音の特徴は同じ副雑音であっても個人差や疾患の進行度によって様々であり、統計的に扱う必要があると考えられる。

そこで、我々は隠れマルコフモデル (HMM) を用いて正常肺音と異常肺音を識別する手法を提案してきた[6]。我々が用いる HMM は時系列のモデリングが可能であり、個人差や疾患の進行度によって様々である呼吸音や副雑音の特徴を表現するのに適した手法である。我々は、先行研究においてデータベースを拡張するために複数の聴診箇所から収録したデータを用いて音響モデルを学習した。しかし、聴診箇所によって呼吸音の特徴が異なるため、一部の音響特徴が類似した呼吸音だけを選択して利用する必要があった。また、疾患者の複数の聴診箇所から呼吸音を収録しても副雑音が聴取されない聴診箇所が多く存在するため、拡張に用いることができる呼吸音が少ないという課題があった。また、ガウス混合モデル (GMM) を用いた GMM-HMM の混合数及び状態数およびディープニューラルネットワーク (DNN) を用いた DNN-HMM の層数およびユニット数、繰り返し学習回数の適切な値を検討したが、大きな値にすると過学習を起こすため、小規模な学習データではいずれも小さい値が最適となり、学習データ量が不足していることを示した[7, 8]。

また、我々が用いる DNN-HMM は一般に入力する音響特徴の次元数が大きく、大量の学習データが必要であり、小規模なデータベースを用いた学習には適していないという問題がある。一方、肺音はさまざまな音響特徴を持ち、ラベルの付与には医学的な知識と経験が必要であり、ラベルの付与作業にも多大な手間がかかることから、複数ある副雑音それぞれについて大量の学習データを用意することは困難である。そのため、限られた学習データを用いて高精度なモデルを作成し、正常肺音と異常肺音の識別精度を向上させることが課題であり、本研究は時系列のモデリングが可能な GMM-HMM および DNN-HMM を高精度に学習するために学習データを大規模に拡張する手法である。

我々は、先行研究においてデータベースを拡張するために複数の聴診箇所から収録したデータを用いて HMM を学習した[9]。しかし、聴診箇所によって呼吸音の特徴が異なるため、一部の音響特徴が類似した呼吸音だけを選択して利用する必要があった。また、疾患者の複数の聴診箇所から呼吸音を収録しても副雑音が聴取されない聴診箇所が多く存在するため、拡張に用いることができる呼吸音が少ないという課題があった。

本研究の目的は、少量の呼吸音を用いて新しい音響特徴を持つ学習データを作成し、学習に用いる肺音のデータベースの拡張を行い、高精度に異常音を検出するためのモデルを作成することである。本研究では GMM-HMM および DNN-HMM の 2 種類の音響モデルを作成する。正常肺音と異常肺音の識別精度によって

学習に用いるデータベースの拡張の効果を確認し、識別に適したデータベースの拡張方法と拡張した学習データの量と識別精度の関係を明らかにする。

さらに、健常者と肺患者の識別精度の向上を目指す。従来は呼気と吸気を区別することなく、呼気と吸気の両方を用いて、正常または異常の尤度を求め、それぞれの尤度の合計を用いて健常者であるか肺患者であるかの識別を行ってきた。本研究では、異常肺音は発生に規則性があり、呼気または吸気のどちらかでのみ発生することが多いことに着目し、正常な肺音と異常な肺音の尤度の合計を、呼気と吸気のそれぞれで別々に比較する手法を提案する。

2 異常肺音識別のアルゴリズム

2-1 概要

本研究の目的を達成するため、GMM-HMM及びDNN-HMMを用いた異常肺音及び患者の検出システムを構築している[7], [8]。異常肺音及び患者検出の流れについて説明する。音声認識では一般に音声の最小単位である音素または単語や音節の音響特徴パラメータの時系列をモデル化した音響モデルと単語の出現確率を定義した言語モデルを用いられてきた。本研究での異常肺音の検出にも音声認識のアルゴリズムを応用している。図1に異常肺音検出の流れを示す。図1に示すように、識別の過程は学習と評価に分けられる。また、図2, 図3に副雑音を含む呼吸の例を示す。図2, 図3に示すように、呼気、吸気を副雑音とそれ以外の区間に

区分し、呼気、吸気 W が N 個の区間から構成されていると仮定する。 i 番目の区間を $w_i (1 \leq i \leq N)$ とする

と $W = w_1 w_2 \cdots w_N$ と表す。学習では、各区間の音響モデルと生起確率を学習する。まず、音響モデルの学

習について述べる。呼気、吸気の区間の音響特徴パラメータ X を抽出し、HMMを用いて正常肺音と異常肺音の音響モデルを学習する。正常肺音では $N = 1$ として、正常な呼気、吸気の全体を一区間として学習する。

異常肺音では $N \geq 2$ として、副雑音が含まれる呼吸を用い、副雑音が発生している区間と発生していない区間を学習する。次に生起確率の学習について述べる。それぞれの区間の生起確率にはバイグラム確率

$P(w_i | w_{i-1})$ を用いて、各区間の生起確率を1つ前の区間からの条件付き確率とし、 W の生起確率を近似的に求める。すなわち、

$$P(W) = w_1 \times \prod_{i=2}^N P(w_i | w_{i-1})$$

となる。評価では、呼気、吸気に対して音響特徴パラメータを抽出した後、音響モデルと区間の生起確率を用いて、正常肺音としての尤度

$$L(W^{no}) = \alpha \log P(W^{no}) + \log P(X | W^{no})$$

を求める。次に、副雑音を含む異常肺音としての尤度

$$L(W^{ab}) = \alpha \log P(\hat{W}^{ab}) + \log P(X | \hat{W}^{ab})$$

を求める。

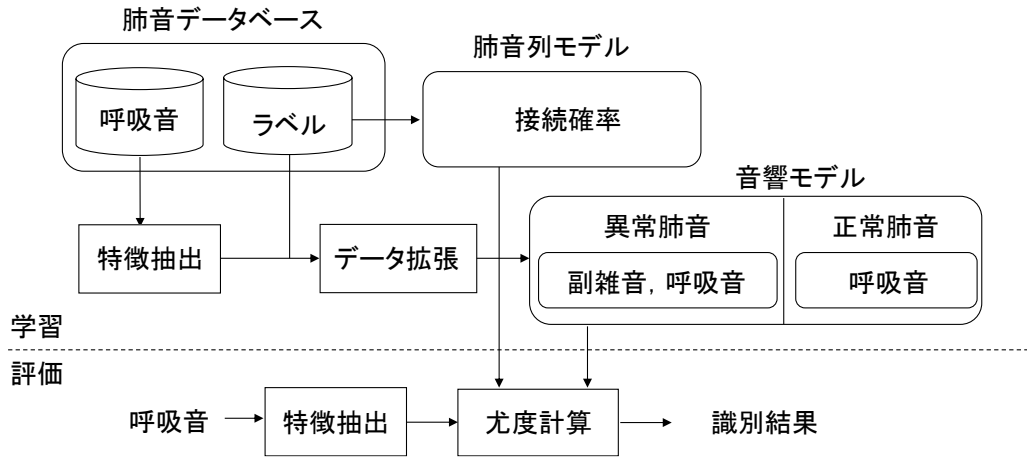


図1 異常肺音び疾患検出の流れ




図2 副雑音（笛音）を含む呼吸の例




図3 副雑音（捻髪音）を含む呼吸の例

肺疾患の検出では、被験者の一連の呼気、吸気について正常、異常としての尤度を求め、健常者であるか肺疾患者であるかの識別を行う。図2、図3に示すように、雑音が突発的に発生するのに対し、副雑音は周期的に複数の呼吸で発生している。そのため、健常者のある呼気、吸気が雑音によって異常としての尤度が高くなっても、雑音を含んでいない他の呼気、吸気は正常としての尤度が高くなると考えられる。一方、疾患者の呼吸では、複数の呼気、吸気に副雑音が含まれているため、複数の呼吸で異常としての尤度が高くなると考えられる。そこで、一連の呼気、吸気について、異常としての尤度の和と正常としての尤度の和をそれぞれ求め、異常としての尤度の和の方が大きければ肺疾患者と判定する。すなわち、一連の N 個の呼気、

吸気のうち $j(1 < j < N)$ 番目の呼気，吸気を W_j とし，異常としての尤度を $L(W_j^{ab})$ ，正常としての尤度を

$L(W_j^{no})$ とすると，

$$\sum_j L(W_j^{ab}) \geq L(W_j^{no})$$

のとき肺疾患者と判定する．

2 少量の学習データによる音響モデルの構築

2-1 概要

我々は健常者の正常な肺音と患者の異常な肺音の音響的特徴は，正常と異常の肺音を区別するために隠れマルコフモデル (HMM) を用いて表現してきた．さらに，心音を副雑音として誤検出するのを防止するため，心音モデルも構築し，心音と副雑音を区別することを試みてきたが，識別精度は高くなかった．また，呼吸音，心音，副雑音の区間の持続時間と音響特徴は異なっており，従来手法[10]では，心音と副雑音の区間のモデルに適切な HMM を構築することを目指してきた．副雑音の種類によって，音響特徴はそれぞれ異なっていたが，学習データ量が少なくそれぞれに適したモデルは構築することができなかった．本研究では，データベースを拡張することによって，それぞれの副雑音の種類およびその他の区間に適した HMM を構築した．各区間に適した HMM の状態数，混合数，繰り返し学習回数を選択することで識別精度が向上し，提案手法の有効性を示した．

この論文では，心音，2種類の副雑音，呼吸音，および正常呼吸の適切な HMM を高い精度で構築するための方法を提案する．これは，正常と異常の呼吸音を区別するために，適切な状態，混合数，繰り返し学習回数を選択することによって実装する．識別実験の結果，識別精度が向上し，提案手法の効果を確認した．

モデルの学習時の状態数，混合数，繰り返し学習回数は，音響特徴の特性と利用可能な学習データの量に応じて設定する必要があることを明らかにした．すなわち，それぞれの副雑音について学習時の適切な状態数と繰り返し学習回数が異なることを示した，

2-2 手法

聴診においては，ノイズが副雑音の高精度な検出を困難にする要因の一つである．聴診される音は，体内からのノイズや聴診器と体との擦れなどを含むことが多い．特に心臓の音は体内からの典型的なノイズである．図4は，副雑音，心音，およびその他の種類のノイズを含む呼吸音の例である．最初の音 (S1) と2番目の音 (S2) がはっきり観測できたため，S1 と S2 を心音としてラベルを付与した．心臓に近い箇所聴診される心音の発生頻度は高く，我々が使用するデータベースには多くの心音が含まれている．そのため，多くの正常な呼吸音が異常な呼吸音として識別された．副雑音と心音を区別するために，心音の音響特徴を学習した心音モデル構築した．その結果，正常な呼吸音を正しく識別することが可能となった．一方，副雑音を含む呼吸においては精度が低下し，音響モデルの構築方法に課題があった．そこで，音響モデルのトポロジーを分析した．従来の手法では，適切な状態数と混合数を選択することにより，心音と副雑音の HMM の高精度化に成功した．しかし，識別精度は不十分であった．この原因は2つ考えられた．まず，断続性副雑音と連続性副雑音の音響特徴に大きな違いがあるにもかかわらず，それらを区別せずに単一のモデルで表現してきたことである．次に，正常な呼吸のための適切な HMM の状態数，混合数，および繰り返し学習回数を設定していなかった．図2は連続性副雑音を含む呼吸であり，図3は断続性副雑音を含む呼吸である．これらの図から，断続性副雑音の音響特徴は繰り返し変化する，連続性副雑音の音響特徴は定常でほとんど変化しないことがわかる．このように副雑音の音響特徴は種類によって異なっているが，それぞれの音響特徴に適した HMM の状態数，混合数，および繰り返し学習回数は検討していなかった．さらに，健常者の正常な呼吸音についても適した HMM の状態数，混合数，および繰り返し学習回数を検討していなかった．また，比較的少量の学習データしか利用できなかったことにより，過学習する傾向があった．そこで，本研究では，連続性副雑音および断続性副雑音として大まかに分類し，それぞれの音響特徴に適した HMM の状態数，混合

数、および繰り返し学習回数を選択し、それぞれに適切な HMM を構築する方法を提案した。識別実験の結果、提案手法の有効性確認した。

従来の研究では心音区間の HMM の状態数を決定した。心音モデルの状態数、混合数、繰り返し学習回数をそれぞれ 1 から 5 と設定し、それぞれの場合の識別精度を比較した。心音区間の状態数が 2 のとき、識別精度が最も高くなった。そこで、心音区間の状態数を 2 と決定し、混合数と繰り返し学習数を順に適切な数を設定した。次に断続性副雑音、連続性副雑音のための HMM においても同様に適切な状態数、混合数、繰り返し学習回数を設定した。その結果、状態数が 3 のとき識別精度が最も高くなり、次に、混合数を 3、繰り返し学習を 3 として設定した。

また、連続する副雑音の HMM では、状態数が 1 のとき識別精度が最も高くなった。これは、連続性副雑音の音響的特徴が定常であるためと考えられる、そのため、1 つの状態で連続する副雑音区間を表現するのに十分だったと考えられる。さらに、混合物 2 と繰り返し学習回数 2 が適切な値となり、連続性副雑音の状態数は、断続性副雑音よりもちいさくなった。これは、連続する雑音の音響的特徴の変化が小さいためだと考える。このように、連続性副雑音と断続性副雑音では状態数や繰り返し学習回数を異なる値に設定して、各々の音響モデルを構築することが効果的であることを示した。

肺疾患者の呼吸音区間の HMM についても同様にまず、状態数を設定した。適切な状態数、混合物数はそれぞれ 3 であった。また、繰り返し学習回数は 4 であった。これは、呼吸音区間の学習データ量が心音や断続性副雑音の区間よりも多いためである。

健常者の正常な呼吸音区間の HMM についても同様に設定した。状態数、混合物数、繰り返し学習回数はすべて 4 とした。これは、呼吸音区間の学習データ量が心音や断続性副雑音の区間よりも多いためである。

これらの設定により識別精度が向上し、適切な状態数、混合数、繰り返し学習回数を適切に設定することが有効であることを示した。

3 データベースの拡張[11]

3-1 概要

本研究の目的は、少量の呼吸音を用いて新しい音響特徴を持つ学習データを作成し、学習に用いる肺音のデータベースの拡張を行い、高精度に異常音を検出するためのモデルを作成することである。正常肺音と異常肺音の識別精度によって学習に用いるデータベースの拡張の効果を確認し、識別に適したデータベースの拡張方法と拡張した学習データの量と識別精度の関係を明らかにする。副雑音を含む異常肺音から平均的な音響特徴を減算したものを正常肺音に加算する手法および、スパースモデリングにより副雑音の音響特徴を抽出し、正常肺音の音響特徴と副雑音の音響特徴を加算する手法を提案し、それらの精度と特徴を比較することで音響モデルの学習に有効なデータベースの拡張手法を明らかにした。

3-2 手法

本研究では少量の呼吸音を用いて新しい音響特徴を持つ学習データを作成し、データベースを拡張し高精度なモデルを学習する手法を検討する。健常者の正常肺音は疾患者の異常肺音と比較して入手しやすいことに着目し、健常者の正常肺音と少量の副雑音の音響特徴を用いて異常肺音の呼吸音データを作成する方法を検討する。本研究では、疾患者の異常肺音を健常者の正常肺音に副雑音が混入したものと考え、健常者の正常肺音に副雑音の音響特徴を加算することで異常肺音の呼吸音データを作成することを提案する。

まず、正常肺音からフレーム毎に音響特徴を抽出し、同じタイミングのフレームの音響特徴の平均を求め、正常肺音の平均的な音響特徴を求める。事前調査で明らかにした呼吸の長さの分散が小さいことを利用する。

正常肺音の総数を M 、正常肺音 r の s 番目のフレームの音響特徴を $S_{r,s}^{no}$ とすると s 番目のフレームの音響特徴

m_s は以下のようになる。

$$m_s = \frac{1}{M} \sum_{r=1}^M S_{r,s}^{no}$$

異常肺音 k の s 番目のフレームの音響特徴 $S_{k,s}^{ab}$ から m_s を減じることで副雑音のみの音響特徴 $A_{k,s}$ を得ることができると考えられる。すなわち、

$$A_{k,s} = S_{k,s}^{ab} - m_s$$

求めた副雑音の音響特徴 $A_{k,s}$ を正常肺音の音響特徴 $S_{r,s}^{no}$ に加算することで副雑音を含む異常肺音の音響特徴

$S_{r,s}^{ab}$ を新たに作成する。すなわち、

$$S_{r,s}^{ab} = S_{r,s}^{no} + A_{k,s}$$

となる。作成した異常肺音の音響特徴を学習データに用いることで学習データを拡張する。

さらに、スパースモデリングを用いた音源分離を用いることで高精度に異常肺音から副雑音の音響特徴を抽出し正常肺音に加算することで副雑音を含む異常肺音を作成する。

4 呼気と吸気を区別した肺疾患検出[12]

4-1 概要

肺音にはいくつかのノイズが含まれており、肺疾患患者の検出においては単一の異常音の検出だけで判断するとは現実的ではなく、一連の呼吸音から検出する必要がある。我々は複数の呼気および吸気の尤度を用いて患者を検出したが、分類率は低かった。異常音は呼気または吸気の一方のみに発生し、両方の尤度を用いた最尤推定では精度が低くなると考え、呼気と吸気それぞれに対して患者検出を別々に行うことで、患者を正確に検出する方法を提案した。識別実験の結果、識別精度が向上し、提案手法の有効性が示された。

4-2 手法

従来法と同様に最尤推定に基づいて最尤のセグメントの系列を求め、系列に副雑音が含まれていなければ正常な肺音として識別する。一方、副雑音のセグメントが含まれていれば異常として識別する。健康な被験者と肺疾患患者を識別するために、呼気および吸気において正常な呼吸と異常な呼吸である尤度を求める。従来の方法では、正常な呼吸と異常な呼吸の尤度の合計を比較し、異常な肺音の尤度の合計が正常な肺音の尤度よりも大きければ被験者は患者として識別した。

副雑音は呼気または吸気のいずれかに発生することが多い。そのため、本研究では正常な肺音と異常な肺音の尤度の合計を、呼気と吸気のそれぞれで別々に比較した。呼気または吸気のどちらかで異常な肺音の尤度の合計が正常な肺音の尤度の合計よりも大きければ、被験者は患者として識別した。すなわち、呼気と吸気のそれぞれで副雑音を含まないセグメントの系列と、副雑音セグメントを含む系列の最大の尤度を求め、呼気または吸気のいずれかで正常としての尤度の合計が副雑音を含む呼吸としての合計よりも大きいとき被験者は患者として識別した。

5 副雑音が発生するタイミングを考慮した異常肺音検出[13]

5-1 概要

我々の提案手法によってデータベースを拡張することで、呼気と吸気を区別してそれぞれのモデルを学習することが可能になった。一連の呼吸を呼気、吸気に分割し、複数の呼気、吸気に対して、正常肺音としての尤度と副雑音を含む異常肺音としての尤度を求めた。しかし、雑音や心音の音響特徴が副雑音と類似しており、異常肺音として誤識別される問題があった。一方、副雑音は周期的に発生することが多く、副雑音の種類によって呼気、吸気のどちらで発生するかが異なっており、さらに、呼気または吸気の中でも、どのタ

タイミングで発生しやすいかがわかっている。

そこで、正常肺音と異常肺音の識別精度向上を目的とし、副雑音の種類ごとの発生タイミングを考慮することで、雑音や心音と副雑音を区別する手法を提案した。識別実験の結果、精度が向上し、提案手法の有効性を示した。

5-2 手法

我々の従来手法では、最尤の候補を求めるビタビアルゴリズムにおいて副雑音を含むか含まないかを判定し、正常肺音であるか異常肺音であるかを識別してきた。次に、提案手法について説明する。バウムウェルチアルゴリズムにより複数の候補を求め、副雑音が発生するタイミングの条件を満たした最尤の尤度を異常肺音としての尤度として用いる。すなわち、雑音が発生するタイミングを副雑音の種類ごとに設定し、心音やその他の雑音を副雑音として誤識別するのを低減する手法である。提案手法では、副雑音の種類ごとに発生タイミングを設定するため、副雑音の種類ごとにモデルを学習する。

次に、発生タイミングの設定について述べる。発生タイミングは3つの区間で設定する。まず、呼気、吸気を、呼吸の始端、中部、終端として3区間に等分で分割する。次に、副雑音が発生する可能性がある区間を医師の助言に基づいて、3区間の中から事前に設定し、設定した区間で副雑音が発生する最尤の尤度を異常肺音の尤度とする。すなわち、設定した区間以外で副雑音が発生することがないものとする。

6 複雑なトポロジーのHMMの構築[14]

6-1 概要

これまでの研究では、限られた状態数の left-to-right の GMM-HMM を構築した。限られた状態で断続的かつ繰り返し発生する異常音を表現したため、GMM-HMM は異常音の音響特性を十分に表現できなかった。さらに、解析フレーム長と間隔が長かったため、心音などの短時間セグメントの音響特性を表現できなかった。その結果、正常な呼吸と異常な呼吸の分類率が低くなることが課題であった。

本研究では、断続的な音のための反復構造を持つエルゴード GMM-HMM の構築を提案した。さらに、音響特性を解析するための適切なフレーム長とフレーム間隔を検討した。反復的に発生する異常音や心音の音響特性を詳細に表現できるエルゴード GMM-HMM を使用することで分類率が向上し、本研究で提案した方法の有効性が確認された。

6-2 手法

副雑音は連続音と断続音の2つのクラスに分けられる。図2は連続性副雑音を含む呼吸音を示しており、図3は断続性副雑音を含む呼吸音を示している。断続性副雑音は短い音が繰り返し発生する特徴がある。副雑音の音響特性は種類によって異なるが、断続性副雑音の区間を定常状態とみなし、left-to-right の GMM-HMM を用いて表現した。そのため、正常な呼吸と異常な呼吸の識別精度が低かった。

さらに、聴診においてはノイズが高精度な副雑音の検出を妨げると考えられる。聴診音にはしばしば体からのノイズや聴診器の擦れ音が含まれており、特に、体内から発生する典型的なノイズは心音である。図4は副雑音、心音 (S1 および S2)、およびその他のノイズを含む呼吸音の例を示している。心臓付近で聴診される心音の出現頻度は高く、我々の研究で使用したデータベースにはいくつかの心音が含まれている。その結果、いくつかの正常な呼吸音が異常音として識別された。副雑音と心音を区別するために、心音を用いてモデル学習を行い、心音モデルを構築した。その結果、正常な呼吸音は正しく識別されたが、異常な呼吸音の場合には精度が低下し、これらのモデルが適していないと考えられた。

そこで、音響モデルのトポロジーと副雑音および心音のフレーム長に着目した。我々の研究では、断続性副雑音のためのエルゴード GMM-HMM を構築した。本研究では、拡張したデータベースを用いて断続性副雑音および心音を含む呼吸音に対してこの構築方法を適用し、適切な解析フレーム長と適切なフレーム間隔を設定した。さらに、それぞれの音に対するエルゴード GMM-HMM の組み合わせを検討した。その結果、短い音を含む呼吸音に対するエルゴード GMM-HMM の構築が患者の異常呼吸の検出に適していることを確認した。

7 まとめ

本研究は、肺音の聴診音を用いて、肺疾患の早期発見を目指し、正常肺音と副雑音を含む異常肺音および

健常者と肺疾患者を高精度に識別する手法を提案するものである。この実現を目指し本研究では、少量の呼吸音を用いて新しい音響特徴を持つ学習データを作成し、学習に用いる肺音のデータベースの拡張を行い、高精度に異常音を検出するための GMM-HMM および DNN-HMM を作成し、高精度な異常肺音識別を行うことを目的とした。

本研究では GMM-HMM および DNN-HMM の 2 種類の音響モデルを作成し、正常肺音と異常肺音の識別精度によって学習に用いるデータベースの拡張の効果を確認し、識別に適したデータベースの拡張方法と拡張した学習データの量と識別精度の関係を明らかにし、データの拡張によって高精度なモデルが構築できることを確認した。

また、副雑音の発生する発生タイミングを考慮し、設定した区間以外で副雑音が発生することがないものとする手法を提案した。識別実験の結果、識別精度の向上を確認し、提案手法が有効であることを示した。

また、音響モデルのトポロジーと副雑音および心音のフレーム長に着目し、断続性副雑音のためのエルゴード GMM-HMM を構築した。断続性副雑音および心音を含む呼吸音に対してこの構築方法を適用し、適切な解析フレーム長と適切なフレーム間隔を設定した。その結果、短い音を含む呼吸音に対するエルゴード GMM-HMM の構築が肺疾患者に呼吸に含まれる副雑音の検出に適していることを確認した。

さらに、副雑音は周期的に発生しており、呼気と吸気のいずれかのみで副雑音が発生することが多いことを考慮して、呼気、吸気それぞれで正常肺音としての尤度の合計と副雑音を含む異常肺音としての尤度の合計を比較し、呼気または吸気のいずれかで異常肺音としての尤度の合計が正常肺音としての尤度の合計よりも大きければ疾患者として識別する手法を提案した。その結果、健常者と肺疾患者の識別精度が向上し、呼気と吸気それぞれで健常者と疾患者を判断する手法が有効であることを示した。

以上の結果から、正常肺音と異常肺音の識別および健常者と肺疾患者の識別における GMM-HMM および DNN-HMM の学習において、学習用のデータベースの拡張を行うことは高精度なモデルの構築に有効であることを示した。

【参考文献】

- [1] Noam Gavriely: Breath Sounds Methodology, CRC Press, 1995.
- [2] M.Bahoura and X.Lu, "Separation of crackles from vesicular sounds using wavelet packet transform", proc. of IEEE ICASSP, II, pp.1076-1079, 2006.
- [3] S.A. Taplidou and L.J. Hadjileontiadis, "Wheeze detection based on time-frequency analysis of breath sounds", Computers in Biology and Medicine, Vol. 37, pp.1073-1083, 2007.
- [4] Y.P. Kahya, S. Yerer, O. Cerid, "A wavelet-based instrument for detection of crackles in pulmonary sounds", EMBC 2001 (IEEE International Conference of the IEEE Engineering in Medicine and Biology Society) (2001.2)
- [5] A. Marshall, S. Boussakta, "Signal analysis of medical acoustic sounds with applications to chest medicine", Journal of the Franklin Institute 344, pp. 230-242, 2007.
- [6] Hitoshi Yamamoto, Shoichi Matsunaga, Masaru Yamashita, Katsuya Yamauchi and Sueharu Miyahara: Classification between Normal and Abnormal Respiratory Sounds Based on Stochastic Approach. Proc. of International Congress on Acoustics 2010 (ICA), Paper No.671, 2010-8 (Sydney, Australia)
- [7] Naoki Umeno, Masaru Yamashita, Hiroyuki Takada and Shoichi Matsunaga: Training data expansion for classification between normal and abnormal lung sounds, Proc. of APSIPA 2019, pp. 935-938, 2019-11. (Lanzhou, China)

- [8] Masaru Yamashita, “Construction of effective HMMs for classification between normal and abnormal respiration,” Proc. of APSIPA 2020, pp. 914-918, 2020-12. (Auckland, New Zealand) Online
- [9] Masaru Yamashita: Construction of Suitable DNN-HMM for Classification between Normal and Abnormal Respiration, Lecture Notes in Computer Science, vol 12861. Springer, pp 609-619, 2021-8.
- [10] Masaru Yamashita: Acoustic HMMs to Detect Abnormal Respiration with Limited Training Data, IEICE Transactions on Information and Systems , Vol.E106-D,No.3,pp.374-380,Mar. 2023.
- [11] Masaru Yamashita: Examination of training data expansion for detection of abnormal respiration and patients, International Conference on Industry 4.0, Artificial Intelligence, and Communications Technology 2023 (IAICT), pp. 312-315, July, 2023. (Bali, Indonesia)
- [12] Masaru Yamashita: Patient Detection Using Inhalations or Exhalations in a Series of Respirations, 6th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI) 111-115 2023.
- [13] Masaru Yamashita: Detection of Abnormal Respirations Considering the Occurrence Timing of Adventitious Sounds, The 7th International Conference on Information and Computer Technologies (ICICT) 2024.
- [14] Masaru Yamashita: Construction of Ergodic GMM-HMMs for Classification between Healthy Individuals and Patients Suffering from Pulmonary Disease., IEICE Trans. Inf. Syst. 107(4) 544-550 2024.
- [15] Masaru Yamashita: Construction of Suitable DNN-HMM for Classification between Normal and Abnormal Respiration, Lecture Notes in Computer Science, vol 12861. Springer, pp 609-619, 2021-8.

〈 発 表 資 料 〉

題 名	掲載誌・学会名等	発表年月
Acoustic HMMs to Detect Abnormal Respiration with Limited Training Data	電子情報通信学会	2023 年 3 月
Examination of training data expansion for detection of abnormal respiration and patients	IAICT 2023	2023 年 7 月
Patient Detection Using Inhalations or Exhalations in a Series of Respirations	ISRITI 2023	2023 年 12 月
Detection of Abnormal Respirations Considering the Occurrence Timing of Adventitious Sounds	ICICT 2024	2024 年 3 月
Construction of Ergodic GMM-HMMs for Classification between Healthy Individuals and Patients Suffering from Pulmonary Disease	電子情報通信学会	2024 年 4 月