

ファジィロジックを用いた肺エラストランスの推定と  
患者の肺特性に適した人工呼吸器の設定法に関する研究

福井工業大学 大学院

工学研究科 博士後期課程 電気工学専攻

中道 正紀

## 目次

1	序論	1
1.1	研究の背景	1
1.2	本研究の目的	1
1.3	論文の構成	2
2	呼吸システムと人工呼吸の概要	3
2.1	呼吸システムの概要	3
2.2	人工呼吸の概要	4
3	P-V 曲線	11
3.1	肺のコンプライアンス	11
3.2	静的 P-V 曲線および動的 P-V 曲線	11
4	呼吸システムの数式モデル	13
4.1	従来の呼吸システムのモデル	13
4.2	非線形性を考慮した呼吸システムのモデル	14
5	既存の肺エラスタンスの表現と問題点	15
5.1	関数近似	15
5.2	エラスタンス多項式表現型	15
5.3	エラスタンス RBF ネットワーク表現型	16
6	数値積分法によるパラメータ推定	18
6.1	数値積分法	18
6.2	連続時間システムのパラメータ推定	22
6.3	最小二乗法	26
6.4	本章のまとめ	31
7	ファジィロジック	32
7.1	ファジィロジックについて	32
7.2	ファジィ集合	33
7.3	ファジィ論理	38

7.4	ファジィ推論 . . . . .	42
8	ファジィロジックを用いた肺エラストンス推定手法	50
8.1	関数型 SIRM <sub>s</sub> ファジィ推論法アルゴリズム . . . . .	50
8.2	関数型 SIRM <sub>s</sub> ファジィ推論法アルゴリズム用いた肺エラストンス推定手法	52
8.3	実験結果及び考察 . . . . .	56
8.4	本章のまとめ . . . . .	60
9	ファジィルール後件部関数表現形式が推定精度へ与える影響について	61
9.1	実験目的とアルゴリズム . . . . .	61
9.2	実験結果及び考察 . . . . .	63
9.3	本章のまとめ . . . . .	66
10	区間データ結合を用いたファジィ推論法	67
10.1	問題点とアルゴリズム . . . . .	67
10.2	実験結果及び考察 . . . . .	72
10.3	本章のまとめ . . . . .	72
11	ファジィ変数の決定におけるアントコロニー最適化法	75
11.1	生物と群知能 - 超個体としてのアリ . . . . .	75
11.2	アリの生活サイクル . . . . .	77
11.3	アリの群行動 . . . . .	78
11.4	道しるべフェロモンに基づくアリの食料収集 . . . . .	79
11.5	アリの群知能と問題解決 . . . . .	84
11.6	組合せ最適化問題とメタヒューリスティクス解法 . . . . .	85
11.7	アントコロニー最適化法 . . . . .	87
11.8	ファジィ変数の決定におけるアントコロニー最適化法について . . . . .	91
11.9	実験結果及び考察 . . . . .	94
11.10	本章のまとめ . . . . .	95
12	非線形肺エラストンス $f_E(V)$ 係数の繰返し最適化手法について	98
12.1	問題点と肺エラストンス式 $f_E(V)$ 以外の項の係数を統一化するアルゴリズム	98
12.2	実験結果及び考察 . . . . .	100
12.3	非線形肺エラストンス $f_E(V)$ 係数の繰返し最適化手法 . . . . .	103

12.4	実験結果及び考察 . . . . .	104
12.5	本章のまとめ . . . . .	106
13	ファジィロジックによる人工呼吸の換気条件の設定	107
13.1	既存の人工呼吸の換気条件設定法 . . . . .	107
13.2	ファジィロジックによる人工呼吸の換気条件の設定 . . . . .	109
14	結論	113

## 1 序論

### 1.1 研究の背景

我々の生活において医療技術は必要不可欠なものである。医療器具の一つである人工呼吸器は、病院や緊急搬送時の救急車内などにおいて自律呼吸が出来ないまたは不完全な患者に対して使用されている [1]。人工呼吸器は、呼吸という人間の生体における重要な機能を肩代わりしている。そのため、患者の呼吸機能の代わりにならない場合には患者の生命の有無に関わってくる。よって、人工呼吸器の使用には細心の注意（空気流量・圧力の過大など）が必要であり、患者の肺特性に合わせた人工呼吸器の設定が適切であるとされている。しかしながら、現代の医療では患者の体重や身長などの外的要項から大まかに人工呼吸器の設定を行なう手法しか確立されておらず、細かな設定に関しては熟練医師の経験や勘に頼って行なわれている。大まかな設定法しかない理由としては以下の点が挙げられる。第1点に、人工呼吸器で測定出来るデータは送気管気圧や空気流量などであり、肺内圧や肺体積などの患者の肺特性に関するデータではないことである。また第2点目としては、人間の呼吸系の特性は千差万別（たとえ身長や体重などが同じ患者であっても肺特性まで同じということはない）であり、病状の進行や回復の具合等によっても特性が変化してくることである。熟練医師の経験や勘が通じる（測定データから大まかな肺特性が予想出来る）患者に関しては、上記の設定法でも問題ないであろう。しかしながら、熟練医師の経験や勘が通じない患者（例えば肺の発育度が予想不可能な未熟児など）に対して人工呼吸器をどのように設定すればよいのかという問題点がある。以上のように、医療技術が進化するなかにおいても人工呼吸器の設定に関しては古典的な手法しか存在せず、患者の肺特性に基づいた適切な設定法がないことが問題となっている。また、近年では高齢化社会と医師不足が問題となっており、今後自律呼吸が出来ない急病人が発生した場合に対処出来る医師がおらずに患者に処置を施せないというケースも起こり得ると考えられる。患者の肺特性に基づいた適切な人工呼吸器の設定はもちろんのこと、医師の負担軽減や医療事故などを引き起こさないためにも、人工呼吸器の適切な換気条件決定法の開発は必要不可欠なものとなっている。

### 1.2 本研究の目的

本研究は、患者の肺特性を表わす静的  $P$ - $V$  曲線を求め、その静的  $P$ - $V$  曲線に基づいた人工呼吸器の気圧上限値設定を行なう手法の提案を目的とする。静的  $P$ - $V$  曲線を求める

ためには肺の弾力特性を表わす肺エラストランスの推定が必要となるが、本研究では肺エラストランスをファジィロジック表現形式で推定する手法を提案している。ファジィロジックを用いた既存の推定手法においては、他の肺エラストランス表現形式（多項式・RBF）による推定と比べ静的  $P$ - $V$  曲線の推定精度が著しく劣っていた。本研究では、ファジィロジックによる推定において推定精度が著しく劣る原因を考察し、推定精度を向上させる手法を提案している。また、静的  $P$ - $V$  曲線に基づいた人工呼吸器の気圧上限値設定においてファジィロジックを用いて設定値をもとめる手法を提案することで、肺特性推定から人工呼吸器の設定までを一貫したロジックで行なうことを試みている。各提案手法において、実際の臨床データを用いて静的  $P$ - $V$  曲線を求める推定実験を行ない提案手法の有効性を検証する。

### 1.3 論文の構成

本論文の構成として、第1章では、研究の背景や研究の目的を紹介している。第2章では、呼吸システムと人工呼吸の概要について紹介する。第3章では、患者の肺特性を表わす静的  $P$ - $V$  曲線について説明する。第4章では、従来提案されてきた呼吸システムの数式モデル及び非線形性を考慮した呼吸システムの数式モデルについて説明する。第5章では、既存の肺エラストランス表現形式とその問題点を述べる。第6章では、肺エラストランス式のパラメータ推定に必要な数値積分法及び最小二乗法について説明する。第7章では、肺エラストランス推定に用いるファジィロジックについて説明する。第8章では、ファジィロジックを用いて肺エラストランスを推定し、静的  $P$ - $V$  曲線を求める既存の手法について説明する。第9章～第13章では、既存の推定手法について問題点を説明し、その問題点を解決するためのアルゴリズムを提案する。また、人工呼吸の臨床データを用いて静的  $P$ - $V$  曲線の推定実験を行ない、提案手法の有効性を検証する。最後に本研究についての結論を述べる。

## 2 呼吸システムと人工呼吸の概要

### 2.1 呼吸システムの概要

#### 2.1.1 呼吸

呼吸(respiration)は,人体各器官の細胞に代謝に必要な酸素( $O_2$ )を供給し,そこから代謝によって生じた二酸化炭素( $CO_2$ )を除去する。体外と肺胞内の空気は換気(ventilation)で交換される(図1)。肺自体には運動性はない。換気は運動神経で支配された呼吸筋の運動による。呼吸ガスは細胞膜を拡散によって容易に通過する。 $O_2$ は肺胞気から血液中に拡散し,赤血球のHbに結合し,血流で各組織に運ばれ,細胞外液中を拡散して組織の細胞に到達する。細胞で生じた $CO_2$ は血液中では主として $HCO_3^-$ として運搬され,肺で $CO_2$ に戻され呼出される。呼吸ガスのホメオスタシスは,血液の $O_2$ と $CO_2$ の分圧を化学受容器で感受し,呼吸運動を調節することにより成立する。




図1 呼吸のメカニズムの概略図.

#### 2.1.2 肺の構造

肺(lung)は,左肺と右肺に分かれる。さらに,右肺は上・中・下葉に,左肺は上・下葉に分かれる(図2)。気道(airway)は鼻,咽頭,喉頭を経て気管となり,次いで気管支と

なって、2 本以上への分岐を繰り返す。気管支、細気管支、終末細気管支、呼吸細気管支、肺胞管等全体で 23 回分岐して肺胞に達する。肺胞は終末細気管支までは全くないが、呼吸細気管支の壁にはある。1 つの終末細気管支に付属する小区画を細葉という。細葉は終末呼吸ユニットとも呼ばれ、呼吸の構造的、機能的単位である。肺には約 6 万個の細葉があり、各細葉には 250 個の肺胞管と約 5,000 個の肺胞がある。




図 2 肺の構造図.

## 2.2 人工呼吸の概要

### 2.2.1 人工呼吸器

人工呼吸器とは、呼吸の停止した患者に対して完全に換気を代行したり、また呼吸が減弱した患者に換気を補助したりするために用いられる機器の総称である [2]。肺気腫や無気肺のようにガス交換が阻害されている患者に対して、人工呼吸器はガス交換を改善する働きをすることもある。呼吸機能が著しく阻害することは死に直結することから、呼吸機能を補助する人工呼吸器は「生命維持装置」の一種に例えることも出来る。人工呼吸器には、換気を代行したり補助することが出来るように換気量、換気回数、酸素濃度、また加湿水分の量や温度などを調節する機能が備わっていなければならない。



### 2.2.2 人工呼吸器の名称

人工呼吸器は肺換気を補助するという意味で、国際規格では人工呼吸器のことを「lung ventilator」(ラング・ベンチレータ：肺換気装置)と呼んでいる。しかし、一般的には「ventilator」(ベンチレータ)または「respirator」(レスピレータ)と呼ばれている。

一般的な概念として、「ventilation」とは外部から人工的な手段でもって換気をさせることを意味し、「respiration」とは自己の呼吸筋による自然呼吸を指している。上記の意味合いから、人工呼吸器のことを「ventilator」と呼ぶほうが適切で正式だが、習慣的に「respirator」という呼び方が通用されている。

### 2.2.3 人工呼吸の方式

人工的に換気をさせる方式としては、「鉄の肺」のように外から「陰圧」をかけて「引っ張る」形で肺胸郭をひろげるものと、日常用いられている人工呼吸器のように「陽圧」をかけて肺の中へガスを「押し込む」形で換気を行なうものに大別出来る。(図3)しかしながら、前者は現在ではほとんど用いられていない。後者には、病院で設置されているような機械的に駆動する人工呼吸器のほかにも手で押して換気させるアンビュバックなども含まれる。本研究では、後者の方式におけるケースを想定して、肺エラストンスの推定や人工呼吸器の設定をおこなうものとする。




図3 人工呼吸器の2つの方式.

#### 2.2.4 人工呼吸器の用途別分類

人工呼吸器を用途別に分類すると以下のようになる。

##### 1) 一般用人工呼吸器

最もよく使用されている人工呼吸器である。体重 15kg 程度より大きい患者に対して、種々の目的の呼吸管理に用いられている。

##### 2) 小児用人工呼吸器

これは新生児から体重 20kg くらいまでの（中には成人にも使用できるものもあるが）患者の呼吸管理に用いられている人工呼吸器。

##### 3) 麻酔用人工呼吸器

麻酔機に接続して、術中の呼吸管理に用いられる人工呼吸器。一般的に非再呼吸式（大気中に吐いた呼気をもう一度吸う換気法）ではなく、ベローを備えたものがほとんどである。

##### 4) 救急用人工呼吸器

アンビュバックのような手動式のものまで含まれ、一般に調節箇所がほとんどなく、小型で可搬式で、酸素ボンベとセットになっているものが多い。

#### 2.2.5 人工呼吸器の原理

人工呼吸および人工呼吸器が満たすべき要件は、救急蘇生の時におこなわれる口移しの mouth-to-mouth 人工呼吸の要件と同じである。つまり、1) 気道の確保、2) 必要な換気量を送り込むこと、3) 必要な酸素濃度と加湿、4) 楽に呼気が吐き出せること、5) 非再呼吸式であることなどである。したがって、人工呼吸器を設計したり使用する場合には、上記の要件を満たすようにしなければならない。

人工呼吸器は図 4 に示すような原理で作動する。最初に、気道は気管内のチューブや気管切開チューブを挿管して確保する。

吸気時には、人工呼吸器よりガスが送出され、チューブを通して患者の肺に供給される。このとき患者回路（チューブで人工呼吸器と患者間を構成する回路）の出口を呼気弁によって閉じることによって患者回路からのもれが防がれて、胸の上がりなどによって必要な換気量がモニタされる。（図 4 (a) 参照）その後、酸素濃度を調節し、患者回路に加湿




図 4 人工呼吸器の原理.

器を設ける。

呼気時には、人工呼吸器からの送気をストップし、呼吸弁が開くことによって患者は大気中に呼気を出す。(図 4 (b) 参照) また、吐いた息を再び吸い込むことがないような非再呼吸式になっている。

#### 2.2.6 人工呼吸器の基本的構成

図 4 の原理をもう少し実際の人工呼吸器に近いようにして示すと、図 5 のようになる。設定された呼吸回数や送気量でガスを送り出す「送気機構」、設定した酸素濃度のガス(酸素と空気)を取り込む「ガス取入口」「送気口」,「加湿器」、通常は Y アダプタが用いられる「患者接続口」,「呼吸弁」および「呼気出口」などより構成されている。人工呼吸器には種々な機構のものが多くて複雑に見えるかもしれないが、その基本的構成はほぼ図 5 に示すようになっている。

#### 2.2.7 人工呼吸の換気様式

自発呼吸は自分の呼吸筋(助間筋と横隔膜)の働きによって「吸い込む形」で行なわれるのに対し、人工呼吸では外部より「押し込む形」にて換気が行なわれる。

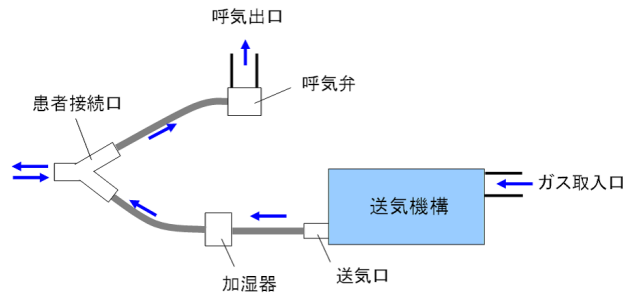


図5 人工呼吸器の基本的構成.

自発呼吸，人工呼吸を問わずに，肺内圧は吸気始めの平圧からはじまり，呼気終末には再び平圧に戻っていく。胸腔内圧（肺の外側と胸壁との間つまり助膜腔、縦隔、そして食道内などの圧）はマイナス数  $\text{cmH}_2\text{O}$  の陰圧から始まり，再びその値に戻る。そして，呼気は通常，呼吸筋が弛緩した形で，肺胸郭の弾性に押されて受動的に行なわれる。

人工呼吸では，外部より肺胸郭弾性に逆らって無理に気体を押し込むので，吸気するときには肺内は次第に陽圧が多角なり，吸気終末には  $5 \sim 15\text{cmH}_2\text{O}$  の陽圧に達する。また，胸腔内圧は陰圧が減少していく。1回の換気量が非常に大きいときには，吸気の終わりに肺内圧が  $30\text{cmH}_2\text{O}$  以上になり，胸腔内圧も+に転ずる場合がある。呼気に移ると外部からの気体の押し込みがなくなり，肺内陽圧は気体の流出とともに平圧に向かって減少していき，胸腔内圧は陰圧が大きくなって元の - 数  $\text{cmH}_2\text{O}$  の陰圧に戻っていく。(図6)




図6 人工呼吸時の肺内圧と胸腔内圧の変化例.

## 2.2.8 従来の人工呼吸器の設定法

本節では、従来の人工呼吸器の設定法とその問題点について述べる。表に示すように、換気量は小児から成人にいたるまで、1回換気量を体重 1kg あたり 10ml に設定している。換気回数は、成人では 10～15 回/分、小児で 15～20 回/分、新生児で 20～40 回/分程度に設定する。下記のような初期設定でもって人工呼吸をスタートした後、医師は患者の状態や観測データなどから経験と勘で人工呼吸器を適切な設定値に調節していく。

表 1 人工呼吸器の初期設定値

1 回換気量	換気回数
10ml /kg	成人 10～15 回/分 小児 15～20 回/分 新生児 20～40 回/分

人工呼吸中の患者は呼吸という人間にとって生きていくうえで一番重要な機能の一つを機械に頼っているのです、医療従事者は十分に注意していないと気づかぬうちに生命を脅かす事態に陥ってしまう。主な患者の観察点としては、顔色、唇の色、胸の動き、分泌物などがある。また、患者からの観測データ（血液ガス、血圧など）も注意して観察しなければならない。このように従来の人工呼吸器の設定法は、患者の体重で大まかな設定を行ない、医者経験と勘で細かい設定を行なうという手法で行なわれている。

表 2 人工呼吸器設定時に注意・観察するべき点

(1) 患者の測定値
血液ガス
血圧、気道圧力
心拍数
(2) 患者の様子
顔色、唇の色、爪の色
発汗
胸の動き
分泌物

従来手法の問題点としては、一切設定に関して肺についての情報を用いていないことである。人間の肺の特性は千差万別であり、身長・体重が同じ患者であっても肺の特性は必ずしも同じではない。経験豊富な医師であれば、過去の経験から多くの場合において人工呼吸器の適切な設定が出来るかもしれない。しかしながら、未熟児等のような医師の経験がまったく適用出来ない患者に対してはどうであろうか。おそらくは、患者の命を救うという作業を手探りで行なわなければならない状況に陥るのではないか。また、医師も人間であるため、患者に不適合な人工呼吸器の設定状況を見落としてしまうこともあるかもしれない。患者生命の安全確保と医療事故を引き起こさないためにも、患者の体重と医師の経験と勘に頼った人工呼吸器の設定手法以外の手法が求められている。

### 3 P-V 曲線

#### 3.1 肺のコンプライアンス

肺コンプライアンスとは、「肺の広がりやすさ」のことを意味している。肺が広がりやすい場合にはコンプライアンスの値は大きく、肺が広がりにくい場合にはコンプライアンスの値は小さくなる。人工呼吸を行なうときには外部より気体を送り込むが、このときに肺と胸郭の両方の弾性収縮力に打ち勝ち広げなければならない。

肺コンプライアンスは、肺の病変によっても変化する。痰がつまったり、肺泡や気管支に炎症がおこったり、肺水腫のように血中より滲出した液が肺泡や肺間質にたまったりすると低下する。また、肥満や外傷などによってもコンプライアンスは変化する。このように、コンプライアンスの低下したすなわちひろがりにくくなった肺や胸郭をひろげるには、それなりに力の強い人工呼吸器を必要とする。患者によってコンプライアンスは異なるので、患者の肺がどの程度のコンプライアンスであるのかを理解することは適切な人工呼吸器の設定に繋がることになる。




図7 肺に例えた風船とコンプライアンス.

#### 3.2 静的 P-V 曲線および動的 P-V 曲線

呼吸システムにおいて気流のない状態を静的状態といい、その状態における肺内圧力  $P_l(t)$  と肺の体積  $V(t)$  によって描かれる曲線は静的 P-V 曲線と呼ばれる。静的 P-V 曲線の  $dV/dP$  がコンプライアンスで、その逆数はエラストンスである。肺の体積  $V(t)$  における肺のエラストンスを  $V$  の非線形関数  $f_E(V, \theta)$  とすると、静的 P-V 曲線は数式

$$P_l(t) = f_E(V, \theta)V(t) \quad (1)$$

と表現できる。この静的  $P$ - $V$  曲線は人工呼吸器の設定値である気圧上限値等を決める上で重要な役割を果たしている。つまりは、患者の静的  $P$ - $V$  曲線を得ることが出来れば、肺の特性に基づいた人工呼吸器の設定が可能となるのである。図 8 に呼吸 1 周期分のデータによる動的  $P$ - $V$  曲線（実線）と静的  $P$ - $V$  曲線（点線）を示した。動的  $P$ - $V$  曲線は、患者の測定データである気管気圧データと肺内空気体積データを使い描くことが可能である。しかし、静的  $P$ - $V$  曲線については、肺内気圧を直接測定することは難しいため、システム同定の手法で推定しなければならない。




図 8 動的  $P$ - $V$  曲線 (実測:実線) と静的  $P$ - $V$  曲線 (推定:点線).



## 4 呼吸システムの数式モデル

### 4.1 従来の呼吸システムのモデル

呼吸筋の働きで圧力  $P$  が変わると、それに伴い肺の体積が変わり、肺内に空気が出入りする。この換気時に出入りする空気の体積を  $V$  で表わす。また、呼吸時には気道内で空気が移動することにより気流が生じる。この気流速度を流量  $F = dV/dt = \dot{V}$  という。以上のように、換気力学での肺、胸郭系の基本的な要素は圧力  $P$ 、空気体積  $V$ 、流量  $\dot{V}$  である [3]。

また、換気運動によって圧力  $P$ 、体積  $V$ 、流量  $\dot{V}$  に変化が生じると、それに伴い様々な抗力が生じる。弾性とは、力を加えると変形するが、除荷すれば元の寸法に戻る性質をいう。肺の弾性特性を表わしたものが前章で説明した肺エラストンス  $f_E(V)$  である。粘性とは、呼吸時に空気の流れによって気体の分子間の摩擦や気体と気道壁との摩擦が生じること、つまりは気流に対する抵抗が生ずることである。慣性とは、質量のある物体を動かす時に抵抗が生じることある。しかし、この抵抗は通常の呼吸を行なっている限りでは、他の抵抗に比べ小さい値となる。

以上の要素及び抗力を用いて呼吸システムのモデルは構成される。

1950 年代以降、呼吸の単純なモデルが Otis, Mead, Mount らによって提案されてきた。代表的な式としては、

$$P(t) + a\dot{P}(t) = bV(t) + c\dot{V}(t) + d\ddot{V}(t) \quad (2)$$

という線形モデルで一般化されている。ここで、 $V(t)$  は肺の体積、 $P(t)$  は気道気圧である。また、 $a, b, c, d$  は係数である。しかしながら、医学の研究と臨床データ等から肺のエラストンスと気管のレジスタンスに非線形性があると明らかにされており、(2) 式では非線形性を説明出来ないという問題が出てきた。

近年、肺のエラストンス（弾性特性）と圧力損失レジスタンス（粘性抵抗）の非線形性を考慮した呼吸モデルが提案されている。

$$P(t) = f_E(V)V(t) + g_R(V)\dot{V}(t) + P_{eea} \quad (3)$$

ここで、 $f_E(V)$ 、 $g_R(V)$ 、 $P_{eea}$  はそれぞれ肺のエラストンス、気道レジスタンス、肺胞の呼吸終了気圧である。このモデルの特徴としては、肺のエラストンスと気道レジスタンスが肺の体積の多項式で表現されており、それゆえこのモデルが非線形性を表現出来るということである。しかしながら、このモデルでは、(2) 式で存在した  $\dot{P}$ 、 $\ddot{V}$  の項が省略されており、呼吸のダイナミクスを説明するためには不十分である。

## 4.2 非線形性を考慮した呼吸システムのモデル

人間の肺は右肺と左肺の両側に分かれており，金江らはそれぞれを簡単な 1 次微分方程式でモデル化しても合成すると全体的には 2 次の微分方程式になると考え，呼吸システムモデルを次式で表現した [4][5]。

$$P_{ao}(t) + a_1 \dot{P}_{ao}(t) = f_E(V)V(t) + g_R(\dot{V})\dot{V}(t) + b_2 \ddot{V}(t) + P_{eea} + \epsilon(t) \quad (4)$$

ここで， $P_{ao}(t)$  は送気管の測定点での気圧， $F(t) = \dot{V}(t)$  は空気流量， $P_{eea}$  は肺胞の呼気終了気圧である。また， $g_R(\dot{V})$  は気管での圧力損失レジスタンスであり，圧力損失を  $P_r$  とすると

$$P_r(t) = g_R(F)F(t) = (r_1 + r_2|\dot{V}(t)|)\dot{V}(t) \quad (5)$$

で表現できる。 $\epsilon(t)$  は，モデル誤差と観測雑音を含む。なお，サンプリング周期で計測できる値としては圧力  $P_{ao}(t)$ ，体積  $V(t)$ ，空気流量  $F(t)$  である。このモデルは，(2) 式と同じ次数の項を含み，肺のエラスタンスと圧力損失レジスタンスが肺の体積の多項式で表現されており，呼吸の非線形ダイナミクスを説明するために十分であると考えられる。

本研究では，(4) 式の呼吸システムモデルを用いてファジィロジックにより肺エラスタンスを推定する。

## 5 既存の肺エラストランスの表現と問題点

### 5.1 関数近似

肺エラストランスは、前述のように体積の非線形関数と見なされる。よって、推定を行なう際に何らかの関数近似表現を行なわなければならない [6]。

関数近似は極めて工学的であるという特徴をもつ。すなわち、推定の結果として返される関数値が、精度が高ければ高いほど良いというわけではなく、計算量の大小、構造の複雑性等という様々な良し悪しが存在する。このようなことは、純粋な数学者にとってはとても気持ちの悪いことで、受け入れられないと思う人が多いかもしれないが、それをあえて行なうところが工学的であるという所以である。

関数近似ではアンダーフィッティングとオーバーフィッティングに注意しなければならない (図 9 参照)。アンダーフィッティングとは、真の関数 (ここでは患者の肺エラストランス) を表現する近似関数が不十分な柔軟性であることをいう。もちろん、表現力が足りないことから真の関数とは大きな誤差が生じる。一方、オーバーフィッティングとは、真の関数を表現する近似関数が柔軟過ぎて推定に使用するデータに依存しすぎることをいう。使用するデータ (患者の気管気圧や空気流量など) には当然観測雑音が含まれているため、データ内の複数の点については真値から大きく外れている事も考えられる。オーバーフィッティングである近似関数は、柔軟過ぎるゆえ、そのような点についても表現してしまい真の関数と大きな誤差を生じてしまう。アンダーフィッティングについては、柔軟性が足りない事は推定してみることで明らかになるので問題ない。一方、オーバーフィッティングについては、通常例図とは異なり真の関数が分からない事からテストデータを用いて近似関数の性能を分析しなければ発見することは難しい。このように、一概に柔軟性を高めていくことによって良い関数近似になるというわけではないことがわかる。

次節では、金江らによって提案された肺エラストランスの表現と問題点について述べる [5]。

### 5.2 エラストランス多項式表現型

肺エラストランス  $f_E(V)$  は、定数ではなく体積  $V(t)$  の非線形関数である。

肺エラストランスの多項式関数表現型は、

$$f_E(V) = k_1 + k_2 V + \cdots + k_n V^{n-1} \quad (6)$$




図9 多項式近似のアンダーフィッティングとオーバーフィッティング例.

となる。ここで、 $n$  は多項式の次数（自然数）である。

多項式表現の場合，その構造は簡単であるという利点をもつ。しかしながら，多項式の次数をむやみに高くすることは望ましくない。高次項は観測雑音の影響を受けやすく，パラメータの推定時に数値的に不安定になる可能性がある。

### 5.3 エラスタンス RBF ネットワーク表現型

ニューラルネットワークとは，ニューロン（神経細胞）とニューロン間の結合に関するシナプス部の働きをモデル化したものである [7][8]。また，RBF ネットワークとは，有限個の入出力データを補間する手法として提案された多層で構成されるニューラルネットワークである。RBF ネットワークは入力層，中間層，出力層から構成されており，中間層の各ユニットが様々な中心値と広がりをもつ RBF に相当し，出力ユニットは中間層出力の加重和を出力する。つまり，RBF ネットワークは，複数の RBF に重みを持たせて足し合わせる事により任意の関数を表現するのである。肺エラスタンスの RBF ネットワーク表現型は，

$$f_E(V) = \sum_{i=1}^{n_E} q_i \psi_i(V) \quad (7)$$

となり，ここで  $n_E$  はこの表現形式に使用された RBF ネットワークのノード数， $q_i$  は  $i$  番目の RBF ノードの重み係数である。 $\psi_i(V)$  は中心  $V_{0i}$ ，広がり  $\sigma_i$  をもつ Radial Basis Function である。

$$\psi_i(V) = \exp\left(-\frac{(V - V_{0i})^2}{2\pi\sigma_i^2}\right) \quad (8)$$

RBF ネットワークの表現において，個々のノード関数の出力は  $[0, 1]$  の範囲内にあるので，各ノード間のバランスが良く取れ，数値的安定性が期待出来る。一方，ノード数やノード関数の中心・広がりをどのように決定するのかという問題点が存在する（図 11

参照)




図 10 肺エラストンスの RBF ネットワーク表現型の構造.




図 11 RBF ネットワーク表現で設定する必要がある値.

## 6 数値積分法によるパラメータ推定

### 6.1 数値積分法

本節では，与えられた関数  $f(x)$  を  $x = a$  から  $x = b$  まで積分すること，すなわち

$$I = \int_a^b f(x) dx \quad (9)$$

を求める数値積分法について説明する [9]。ここでは，上記の式の被積分関数  $f(x)$  が，積分変数  $x$  の関数として与えられている場合を取り扱う。

上記の式において  $f(x)$  が初等関数であれば，解析的に積分できる場合もあるが，理工学分野では  $f(x)$  が初等関数で与えられない，あるいは関数形が未知のことが多い。このようなときに，必要な精度で数値的に積分することになる。関数系は必ずしも解析的に与えられているとは限らないが，ここで考えようとしているのは，等間隔である  $x$  の値に対して  $f(x)$  の値がわかっている場合と，不等間隔ではあるが数値積分法の理論が，指定する  $x$  の値に対する関数値  $f(x)$  が与えられる場合である。

数値積分とは，簡略化して説明すると， $x$  のいくつかの値  $x_i$  ( $i = 1, 2, \dots$ ) に対して  $f(x_i)$  がわかっているとき，積分値を近似的に以下の形の式で求めることである。

$$\int_a^b f(x) dx \doteq \omega_1 f(x_1) + \omega_2 f(x_2) + \omega_3 f(x_3) + \dots + \omega_N f(x_N) \quad (10)$$

ここで  $x_i$  を分点といい， $\omega_i$  を分点  $x_i$  に対応する重みという。重み  $\omega_i$  は  $x_i$  によるが， $f(x)$  にはよらない量である。 $\omega_i$  は積分値ができるだけ正確になるようにつくられる。

#### 6.1.1 数値積分法-台形公式

図 12 のように，曲線  $y = f(x)$  において， $x = a$  と  $x = b$  の間を  $N$  等分し，各分点を

$$x_i = x_0 + ih \quad (i = 0, 1, \dots, N) \quad (11)$$

とする。ここで，

$$x_0 = a$$

$$x_N = a + Nh = b$$

$$h = \frac{b-a}{N}$$

である。各分点での  $y = f(x)$  の値を

$$y_i = f(x_i) \quad (i = 0, 1, \dots, n) \quad (12)$$

とする。 $N + 1$  個の点  $(x_0, y_0), (x_1, y_1), \dots, (x_N, y_N)$  を 1 次式 (直線) で結んで,  $x$  軸と折線との間の面積  $I_1$  を (9) 式の近似値とすると,

$$I = \int_a^b f(x) dx \doteq I_1 \quad (13)$$

このとき  $I_1$  は小面積の和で計算できるので,

$$\begin{aligned} I_1 &= \frac{h}{2}(y_0 + y_1) + \frac{h}{2}(y_1 + y_2) + \dots + \frac{h}{2}(y_{N-1} + y_N) \\ &= \frac{h}{2}y_0 + h(y_1 + y_2 + \dots + y_{N-1}) + \frac{h}{2}y_N \end{aligned}$$

となる。これを書き直すと,

$$I_1 = h \left[ \frac{y_0 + y_N}{2} + \sum_{i=1}^{N-1} y_i \right] \quad (14)$$

を得る。これは, 積分値を台形面積の和で近似していることから, 台形公式と呼ばれている。

また, この場合 (10) 式の重み  $\omega$  は,

$$\begin{cases} \omega_0 = \omega_N = h/2 \\ \omega_i = h, \quad i = 1, 2, \dots, N-1 \end{cases} \quad (15)$$

となる。

台形公式を用いて積分のよりよい近似値を求めるには, 全区間  $(a, b)$  の分割数  $N$  を大きくする, すなわち小区間の幅  $h = (b - a)/N$  を小さくしてやればよい。これは, 曲線  $f(x)$  を近似する 1 次式の接線は,  $h$  が小さいほど曲線  $f(x)$  に近くなるからである。注意しなければならないこととしては,  $h$  を小さくすればするほど良い近似値が求められると考えられるが, 分点の数は 2 倍, 4 倍と多くなり, それに従って演算回数も 2 倍, 4 倍と増大するため, 丸めの誤差が大きくなる。よって, むやみに  $h$  を小さくしていても, 必ずしも良い結果が得られるとは限らない。




図 12 数値積分法-台形公式の概念図.

### 6.1.2 数値積分法-シンプソンの公式

$f(x)$  がなめらかな関数であれば, 2 次式で近似するほうが, 1 次式で近似した台形公式よりもよい精度の公式が得られる。

1 次式は 2 つの分点における  $f(x)$  の値によって決まるが, 2 次式は 3 つの分点における  $f(x)$  の値が必要である。それは, 1 つの 2 次式が 2 点を通る条件では決まらないからである。図 13 のように, 区間  $(a, b)$  を  $2N$  等分して  $h = (b - a)/2N$  とする。  $x_0 = a$ ,  $x_{2N} = b$  とし, 2 つの偶数番目の分点と 1 つの奇数番目の分点との合計 3 つの分点の小区間  $x_i \leq x \leq x_{i+2}$  ( $i$  は偶数) における  $f(x)$  を, 2 次式

$$p_2(x) = \frac{(x - x_{i+1})(x - x_{i+2})}{(x_i - x_{i+1})(x_i - x_{i+2})}y_i + \frac{(x - x_i)(x - x_{i+2})}{(x_{i+1} - x_i)(x_{i+1} - x_{i+2})}y_{i+1} + \frac{(x - x_i)(x - x_{i+1})}{(x_{i+2} - x_i)(x_{i+2} - x_{i+1})}y_{i+2} \quad (16)$$

によって近似する。  $p_2(x_i) = y_i = f(x_i)$ ,  $p_2(x_{i+1}) = y_{i+1} = f(x_{i+1})$ ,  $p_2(x_{i+2}) = y_{i+2} = f(x_{i+2})$  であるから, 各分点では  $p_2$  は  $f(x)$  に一致する。小区間  $(x_i, x_{i+2})$  での積分の近似値は,

$$\int_{x_i}^{x_{i+2}} p_2(x)dx = \int_{-h}^h p_2(x - x_{i+1})dx = \frac{h}{3}(y_i + 4y_{i+1} + y_{i+2}) \quad (17)$$



であることが2次式の積分の計算でもとめられる。したがって、

$$I = \int_a^b f(x)dx \doteq I_2 \quad (18)$$

の近似値  $I_2$  は、(16) 式を全区間加え合わせたものであり、すなわち、

$$I_2 = \frac{h}{3} \left[ y_0 + 4y_1 + y_2 + \sum_{j=1}^{N-2} (y_{2j} + 4y_{2j+1} + y_{2j+2}) + (y_{2N-2} + 4y_{2N-1} + y_{2N}) \right] \quad (19)$$

となり、次の公式となる。

$$I_2 = \frac{h}{3} \left[ y_0 + y_{2N} + 4 \sum_{j=1}^N y_{2j-1} + 2 \sum_{j=1}^{N-1} y_{2j} \right] \quad (h = \frac{b-a}{2N}) \quad (20)$$

この式では、全区間の端の値 ( $y_0$  と  $y_{2N}$ ) には重み 1、奇数番目は重み 4、偶数番目は重み 2 を掛けて加え合わせることにになっている。この積分公式をシンプソンの公式、または全体に掛かる係数からシンプソンの 1/3 公式という。

また、この場合 (10) 式の重み  $\omega$  は、

$$\begin{cases} \omega_0 = \omega_{2N} = h/3 \\ \omega_i = 4h/3, & i = 1, 3, \dots, 2N-1 \\ \omega_i = 2h/3, & i = 2, 4, \dots, 2N-2 \end{cases} \quad (21)$$

となる。




図 13 数値積分法-シンプソンの公式の概念図.

## 6.2 連続時間システムのパラメータ推定

本節では連続時間システムのパラメータ推定について説明する。今日，計算機が進歩し A/D 変換装置と組み合わせてオンラインでデータを取得して処理出来るようになった。それに伴い離散値系の同定の研究が行われてきた。しかしながら，ほとんどの物理システムは連続であり，微分方程式や状態変数表現などの連続時間系のシステム表現は，システム解析，適応制御などに用いられるので，計算機処理を前提とした連続時間系の同定手法が必要となる。離散値系の推定パラメータから変換法によって，連続時間系のパラメータを推定する方法は一意性がない。また，Walsh 関数，ブロックパルス関数，ラゲルとルシャンドルの多項式などの連続時間系のパラメータを推定する手法もあるが，これらの手法の欠点は初期値による時間の未知多項式を推定しなければならないことであり，これにより様々な問題点を生ずる。

本研究で用いた相良らによって提案された連続時間システムのパラメータ推定手法は，初期値の影響を完全に除去するような数値積分演算を用いて，システムの入出力サンプル値から連続時間系のパラメータを同定する手法である [10]。連続時間系の微分方程式は，この手法を用いることにより初期値を含まない離散値形の同定モデルに変換し，連続時間パラメータは次節で説明する最小二乗法で直接推定される。

### 6.2.1 数値積分演算

前節で説明した数値積分法より，時間区間  $[t - \ell T, t]$  における連続関数  $x(t)$  の数値積分値を近似的に計算すると，

$$\int_{t-\ell T}^t x(t) dt \doteq f_0 x(t) + f_1 x(t-T) + \cdots + f_\ell x(t-\ell T) \quad (22)$$

となる。ここで， $T$  はサンプリング周期， $\ell$  は数値積分演算のウィンドウ幅を決める正の整数である。係数  $f_i (i = 0, 1, \dots, \ell)$  は数値積分法の種類によって決まり，前節により台形公式であれば，係数  $f_i$  は，

$$\begin{cases} f_0 = f_\ell = T/2 \\ f_i = T \quad (i = 1, 2, \dots, \ell - 1) \end{cases} \quad (23)$$

となり，シンプソン公式であれば，

$$\begin{cases} f_0 = f_\ell = T/3 \\ f_i = 4T/3 \quad (i = 1, 3, \dots, \ell - 1), \\ \quad = 2T/3 \quad (i = 2, 4, \dots, \ell - 2) \end{cases} \quad (24)$$

となる。遅延オペレータ  $q^{-1}$  を用いて, (22) 式を

$$\int_{t-\ell T}^t x(t)dt \triangleq (f_0 + f_1 q^{-1} + \cdots + f_\ell q^{-\ell})x(t) \quad (25)$$

のように書き直す。ただし,  $q^{-1}x(t) = x(t - T)$  である。

時間区間  $[t - \ell T, t)$  における  $x(t)$  の  $j$  重積分を

$$I_j x(t) = \int_{t-\ell T}^t \cdots \int_{t-\ell T}^t x(t) dt^j \quad (26)$$

と定義したとき (ただし,  $I_0 x(t) = x(t)$ ), 次の定理が与えられる。

[定理 1]

$x^{(j)}(t) \triangleq d^j x(t)/dt^j$  を  $j$  回微分とする。 $x^{(j)}(t) (j = 0, 1, \dots, n)$  の (26) 式で定義した  $n$  重積分値は

$$I_n x^{(j)}(t) \triangleq \mathcal{G}_j x(t) = \sum_{i=0}^{n\ell} p_i^j q^{-i} x(t) \quad (27)$$

で近似的に計算できる。ここで,  $n$  は連続時間系の次数であり, 多項式  $\mathcal{G}_j$  は,

$$\mathcal{G}_j = (1 - q^{-\ell})^j (f_0 + f_1 q^{-1} + \cdots + f_\ell q^{-\ell})^{n-j} \quad (28)$$

で与えられる。

(定理 1 の証明)

インデックス  $j$  について数学的帰納法で次式を証明する。

$$I_j x(t) \triangleq (f_0 + f_1 q^{-1} + \cdots + f_\ell q^{-\ell})^j x(t) \quad (j = 0, 1, \dots, n) \quad (29)$$

(1)  $j$  が 0 あるいは 1 のとき定義より (29) 式が明白である。

(2)  $j = k (k > 1)$  のとき (29) 式が成立すると仮定する。すなわち,

$$I_k x(t) \triangleq (f_0 + f_1 q^{-1} + \cdots + f_\ell q^{-\ell})^k x(t) \quad (30)$$

が成り立つと仮定し,  $j = k + 1$  を示せすことが出来れば (29) 式の証明が完了する。

$$I_{k+1} x(t) \triangleq (f_0 + f_1 q^{-1} + \cdots + f_\ell q^{-\ell})^{k+1} x(t) \quad (31)$$

ここで  $(f_0 + f_1 q^{-1} + \cdots + f_\ell q^{-\ell})^k$  を簡単化し,

$$(f_0 + f_1 q^{-1} + \cdots + f_\ell q^{-\ell})^k = \sum_{i=0}^{k\ell} p_i^k q^{-i} \quad (32)$$

とおく。また，遅延オペレータと積分演算は交換可能である。整数  $i$  に対して

$$q^{-i}I_1x(t) = I_1q^{-i}x(t) \quad (33)$$

が成立する。(30)～(33) 式より

$$\begin{aligned} I_{k+1}x(t) &= I_1(I_kx(t)) \\ &\doteq I_1(f_0 + f_1q^{-1} + \cdots + f_\ell q^{-\ell})^k x(t) \\ &= I_1 \sum_{i=0}^{k\ell} p_i^k q^{-i} x(t) = \sum_{i=0}^{k\ell} p_i^k I_1 q^{-i} x(t) \\ &= \sum_{i=0}^{k\ell} p_i^k q^{-i} I_1 x(t) \\ &= (f_0 + f_1q^{-1} + \cdots + f_\ell q^{-\ell})^k I_1 x(t) \\ &\doteq (f_0 + f_1q^{-1} + \cdots + f_\ell q^{-\ell})^{k+1} x(t) \end{aligned} \quad (34)$$

となる。

同じように，数学的帰納法で次式も証明可能である。

$$I_jx^j(t) = (1 - q^{-\ell})^j x(t) \quad (35)$$

これら (29) , ( 33 ) , ( 35 ) より定理 1 を証明すると，

$$\begin{aligned} I_nx^j(t) &= I_{n-j}(I_jx^j(t)) \\ &= I_{n-j}(1 - q^{-\ell})^j x(t) \\ &= (1 - q^{-\ell})^j I_{n-j}x(t) \\ &\doteq (1 - q^{-\ell})^j (f_0 + f_1q^{-1} + \cdots + f_\ell q^{-\ell})^{n-j} x(t) \\ &\triangleq \mathcal{G}_jx(t), \quad j = 0, 1, \dots, n \end{aligned} \quad (36)$$

明らかに  $\mathcal{G}_j$  が  $q^{-1}$  に関する次数  $n\ell$  の多項式で以下のようになる。

$$\mathcal{G}_j = \sum_{i=0}^{n\ell} p_i^j q^{-i}, \quad j = 0, 1, \dots, n \quad (37)$$

(定理 1 の証明終了)

ここで，連続時間システムの入出力データはサンプリング時点  $kT(k = 0, 1, \dots)$  において測定できると仮定する。サンプル値  $x(kT)$  を  $x(k)$  で表すとするとき，(27) 式の数値積分演算は，

$$\mathcal{G}_jx(k) = \sum_{i=0}^{n\ell} p_i^j q^{-i} x(k) = \sum_{i=0}^{n\ell} p_i^j x(k-i) \quad (38)$$

という離散形で表せる。

(27), (38) 式における係数  $p_i^j$  はあらかじめ (28) 式により計算される。したがって, (38) 式の数値積分演算は係数ベクトル  $\mathbf{p}_j$  とサンプル値ベクトル  $\mathbf{x}(k)$  の内積を求めることになる。

$$\begin{cases} \mathbf{p}_i = (p_0^j, p_1^j, \dots, p_{n\ell}^j)^T \\ \mathbf{x}(k) = (x(k), x(k-1), \dots, x(k-n\ell))^T \end{cases} \quad (39)$$

(27) 式の数値積分演算では, システムの入出力測定値から微分を直接求めず, ノイズに強い積分演算を施してデータを処理する。したがって, この演算手法は測定データのある程度フィルタリングする機能をもち,  $n\ell T$  の幅のウィンドウをかけることにより, 初期値の影響を除去することが出来る。

### 6.2.2 連続時間システムのモデリング

実際のシステムはほとんど非線形であり, その特性を線形表現で把握することの出来ない場合が起こる事が, 非線形システムのモデリングの重要な課題となっている。一般的な非線形システムを記述することは困難であるが, ある種の非線形の場合には非線形微分方程式で表すことができる。

今, 次式の非線形微分方程式で表される単一入出力の非線形システムを考える。

$$\sum_{i=0}^n a_{n-i} \frac{d^i}{dt^i} \alpha_i(x, t) = \sum_{j=0}^m b_{m-j} \frac{d^j}{dt^j} \beta_j(u, t) + \sum_{h=1}^q c_h \gamma_h(x, u, t) \quad m \leq n \quad (40)$$

ここで,  $u(t)$ ,  $x(t)$  はそれぞれシステムの入出力,  $a, b, c$  は未知パラメータである。また,  $\alpha_i(x, t)$ ,  $\beta_j(u, t)$ ,  $\gamma_h(x, u, t)$  は既知関数であるとする。この (40) 式を時間区間  $[t - \ell T, t)$  にわたって  $t$  に対して  $n$  回積分して定理 1 の数値積分演算を用いると,

$$\mathcal{G}_n \alpha_n(x, k) + \sum_{i=0}^{n-1} a_{n-i} \mathcal{G}_i \alpha_i(x, k) = \sum_{j=0}^m \mathcal{G}_j \beta_j(u, k) + \sum_{h=1}^q c_h \mathcal{G}_0 \gamma_h(x, u, k) + \varepsilon(k, T) \quad (41)$$

ここで,  $\varepsilon(k, T)$  は入出力の数値積分による打切誤差を表す項である。

更に, (41) 式は

$$\mathcal{G}_n \alpha_n(x, k) = \varphi(k)^T \theta + \varepsilon(k, T) \quad (42)$$

のように同定モデルに書き直せる。ただし,

$$\begin{aligned} \varphi(k) = & (-\mathcal{G}_{n-1} \alpha_{n-1}(x, k) \cdots -\mathcal{G}_0 \alpha_0(x, k) \\ & \mathcal{G}_m \beta_m(u, k) \cdots \mathcal{G}_0 \beta_0(u, k) \\ & \mathcal{G}_0 \gamma_1(x, u, k) \cdots \mathcal{G}_0 \gamma_q(x, u, k))^T \end{aligned}$$

$$\theta = (a_1 \cdots a_n b_0 \cdots b_m c_1 \cdots c_q)^T \quad (43)$$

である。

上記の式により非線形の連続時間システムの同定モデルが数値積分演算を用いることにより導くことが出来る。これらの同定モデルは連続時間系の初期値を含んでいない。ゆえに、初期値が未知であってもシステムパラメータと一緒に推定する必要がない。この同定モデルに基づいて  $\varepsilon(k, T)$  の自乗和を最小化する最小二乗法で未知パラメータを推定する。

### 6.3 最小二乗法

本節では、未知パラメータを推定する手法である最小二乗法について説明する。

システム同定問題は、ひとたびそのモデル構造が決まれば、モデルを構成するパラメータ推定問題に帰着する [11]。そこで、パラメータ推定のための評価関数として、

$$J_N(\theta) = \frac{1}{N} \sum_{k=1}^N \ell(k, \theta, \varepsilon(k, \theta)) \quad (44)$$

を設定する。ここで、 $\ell(k, \theta, \varepsilon(k, \theta))$  は、予測誤差

$$\varepsilon(k, \theta) = y(k) - \hat{y}(k|\theta) \quad (45)$$

の大きさ（距離）を測る正のスカラー値関数である。

式 (44) 式のような評価関数を未知パラメータ  $\theta$  に関して最小化することによって、パラメータ推定値  $\hat{\theta}(N)$  は計算できる。数式では、

$$\hat{\theta}(N) = \arg \min J_N(\theta) \quad (46)$$

と表現される。ここで、評価関数の最小値がほしいわけではなく、最小値を与える  $\theta$  がほしいことに注意する。

以上のように予測誤差から構成される評価関数  $J_N(\theta)$  を最小にするように推定値を計算するパラメータ推定法を、予測誤差法と総称する。予測誤差法の立場にたつと、システム同定モデルと関数  $\ell(k, \theta, \varepsilon(k, \theta))$  をどのように選定するかによって、さまざまなパラメータ推定法を分類出来る。2 次関数

$$\ell(k, \theta, \varepsilon(k, \theta)) = \varepsilon^2(k, \theta) \quad (47)$$

を選んだ場合に最小二乗法 (least-squares method) という。

以下では，線形回帰モデルである ARX モデルおよび FIR モデルについて説明した後，最小二乗法の詳細について述べる。

### 6.3.1 ARX モデル

システムの入出力関係が差分方程式

$$y(k) + a_1 y(k-1) + \cdots + a_{n_a} y(k-n_a) = b_1 u(k-1) + \cdots + b_{n_b} u(k-n_b) + e(k) \quad (48)$$

である場合を考える。ここで， $e(k)$  は外乱項である。

このとき，パラメータベクトルを，

$$\theta = [a_1, \cdots, a_{n_a}, b_1, \cdots, b_{n_b}]^T \quad (49)$$

データベクトル（あるいは回帰ベクトル）を，

$$\varphi = [-y(k-1), \cdots, -y(k-n_a), u(k-1), \cdots, u(k-n_b)]^T \quad (50)$$

と定義すると，出力  $y(k)$  は

$$y(k) = \theta^T \varphi(k) + e(k) \quad (51)$$

と表現できる。

いま，二つの多項式

$$\begin{aligned} A(q) &= 1 + a_1 q^{-1} + \cdots + a_{n_a} q^{-n_a} \\ B(q) &= b_1 q^{-1} + \cdots + b_{n_b} q^{-n_b} \end{aligned}$$

を導入すると，(48) 式は  $A(q)y(k) = B(q)u(k) + e(k)$  と書き直すことができる。このように表現されるモデルを ARX(Auto-Regressive eXogenous) モデル，または最小二乗法に都合がよいモデルであるので最小二乗モデルという。

また，ARX モデルの 1 段先予測値は，

$$\hat{y}(k|\theta) = [1 - A(q)]y(k) + B(q)u(k) = \theta^T \varphi(k) \quad (52)$$

となる。この式から ARX モデルの 1 段先予測値が  $\theta$  に関して線形な関係式で記述でき，右辺において外乱項がないものに一致することがわかる。このため，ARX モデルは線形回帰モデルとも呼ばれる。

### 6.3.2 FIR モデル

ARX モデルにおいて,  $A(q) = 1$  とおくと,

$$\begin{aligned} y(k) &= B(q)u(k) + e(k) \\ &= b_1 u(k-1) + \cdots + b_{n_b} u(k-n_b) + e(k) \\ &= \boldsymbol{\theta}^T \boldsymbol{\varphi} + e(k) \end{aligned} \quad (53)$$

ただし,

$$\begin{aligned} \boldsymbol{\theta} &= [b_1, \dots, b_{n_b}]^T \\ \boldsymbol{\varphi} &= [u(k-1), \dots, u(k-n_b)]^T \end{aligned} \quad (54)$$

である。FIR モデルも線形回帰モデルであるので, 出力の 1 段先予測値は以下の式で与えられる。

$$\hat{y}(k|\boldsymbol{\theta}) = B(q)u(k) = \boldsymbol{\theta}^T \boldsymbol{\varphi}(k) \quad (55)$$

FIR モデルは観測雑音に対してよい性質をもつため, システム同定において頻繁に用いられる。

### 6.3.3 最小二乗法推定

ARX モデルや FIR モデルのように、出力の 1 段先予測値  $\hat{y}(k|\boldsymbol{\theta})$  が最適化されるべき未知パラメータ $\boldsymbol{\theta}$ に関して線形, すなわち,  $\hat{y}(k|\boldsymbol{\theta}) = \boldsymbol{\theta}^T \boldsymbol{\varphi}(k)$  である線形回帰モデルの場合を考える。このときの, 予測誤差は,

$$\varepsilon(k, \boldsymbol{\theta}) = y(k) - \hat{y}(k|\boldsymbol{\theta}) = y(k) - \boldsymbol{\theta}^T \boldsymbol{\varphi}(k) \quad (56)$$

で与えられる。

線形モデルに対して最小二乗法を適用する, すなわち  $\ell(k, \boldsymbol{\theta}, \varepsilon(k, \boldsymbol{\theta})) = \varepsilon^2(k, \boldsymbol{\theta})$  を選ぶと, パラメータ推定のための評価関数は,

$$J_N(\boldsymbol{\theta}) = \frac{1}{N} \sum_{k=1}^N \varepsilon^2(k, \boldsymbol{\theta}) = \frac{1}{N} \sum_{k=1}^N \{y(k) - \boldsymbol{\theta}^T \boldsymbol{\varphi}(k)\}^2 \quad (57)$$

(57) 式をさらに計算すると,

$$J_N(\boldsymbol{\theta}) = \boldsymbol{\theta}^T \mathbf{R}(N) \boldsymbol{\theta} - 2\boldsymbol{\theta}^T \mathbf{f}(N) + c(N) \quad (58)$$



が得られる。ここで  $m$  を未知パラメータの個数，すなわち  $\theta$  の次元とすると， $\mathbf{R}(N)$  (既知)， $\mathbf{f}(N)$  (既知)， $c(N)$  は，

$$\begin{aligned}\mathbf{R}(N) &= \frac{1}{N} \sum_{k=1}^N \varphi(k) \varphi^T(k) \quad (m \times m \text{ 行列}) \\ \mathbf{f}(N) &= \frac{1}{N} \sum_{k=1}^N \varphi(k) y(k) \quad (m \times 1 \text{ ベクトル}) \\ c(N) &= \frac{1}{N} \sum_{k=1}^N y^2(k) \quad (\text{スカラ})\end{aligned} \quad (59)$$

と与えられる。

式 (58) は未知パラメータベクトル  $\theta$  の 2 次形式なので， $J_N(\theta)$  を  $\theta$  に関して微分して  $\mathbf{0}$  とおくことにより， $J_N(\theta)$  を最小化する  $\theta$  を見つけることができる。

$$\nabla J_N(\theta) = 2\mathbf{R}(N)\theta(N) - 2\mathbf{f}(N) = \mathbf{0} \quad (60)$$

ここで，最小値が存在するためには  $\mathbf{R}(N)$  が正定値行列である必要がある。

(60) 式より， $N$  個の入出力データに基づく未知パラメータの最小二乗推定値  $\hat{\theta}(N)$  は，連立 1 次方程式 (正規方程式)

$$\mathbf{R}(N)\hat{\theta}(N) = \mathbf{f}(N) \quad (61)$$

を満たすことがわかる。

時刻  $k$  における ARX モデル

$$y(k) = \theta^T \varphi(k) + e(k) \quad (62)$$

を， $k = 1$  から  $N$  まで，ベクトル・行列を用いてまとめて表すと，

$$\mathbf{y}(N) = \Phi(N)\theta + \mathbf{e}(N) \quad (63)$$

が得られる。ここで， $\mathbf{y}(N)$ ， $\mathbf{e}(N)$  はそれぞれ

$$\begin{aligned}\mathbf{y}(N) &= [y(1) \ y(2) \ \cdots \ y(N)]^T \\ \mathbf{e}(N) &= [e(1) \ e(2) \ \cdots \ e(N)]^T\end{aligned} \quad (64)$$

とする。また，行列  $\Phi(N)$  (大きさ  $N \times m$ ) は，ARX モデルの場合には，

$$\Phi(N) = [-Y(N) \ U(N)]$$

$$= \begin{bmatrix} -y(0) & -y(-1) & \cdots & -y(-n+1) & u(0) & u(-1) & \cdots & u(-n+1) \\ -y(-1) & -y(0) & \cdots & -y(-n+2) & u(1) & u(0) & \cdots & u(-n+2) \\ \vdots & \vdots & & \vdots & \vdots & \vdots & & \vdots \\ -y(N-1) & -y(N-2) & \cdots & -y(N-n) & u(N-1) & u(N-2) & \cdots & u(N-n) \end{bmatrix} \quad (65)$$

FIR モデルの場合には,

$$\Phi(N) = U(N)$$

$$= \begin{bmatrix} u(0) & u(-1) & \cdots & u(-n+1) \\ u(1) & u(0) & \cdots & u(-n+2) \\ \vdots & \vdots & & \vdots \\ u(N-1) & u(N-2) & \cdots & u(N-n) \end{bmatrix} \quad (66)$$

と与えられる。上記の式は,  $R(N)$ 、 $f(N)$  の式と,

$$\begin{aligned} R(N) &= \frac{1}{N} \Phi(N)^T \Phi(N) \\ f(N) &= \frac{1}{N} \Phi(N)^T y(N) \end{aligned} \quad (67)$$

のように関係づけられる。

これらの表記を用いて, 評価関数を表現すると,

$$J_N(\theta) = \frac{1}{N} \|y(N) - \Phi \theta\|^2 \quad (68)$$

が得られる。これを  $\theta$  に関して微分して  $\mathbf{0}$  とおくと, 前述した正規方程式は

$$\left[ \frac{1}{N} \Phi(N)^T \Phi(N) \right] \hat{\theta}(N) = \frac{1}{N} \Phi(N)^T y(N) \quad (69)$$

と表現出来る。この式から明らかなように, 線形回帰モデルのパラメータを最小二乗法によって推定する問題は, 連立 1 次方程式を解く問題に帰着される。このとき、行列  $R(N)$  が正定値であるかどうか問題となり, 正定値である場合には逆行列を用いてパラメータ推定値を求めることが出来る。この同定法は最小二乗法と呼ばれ, 以下の式で計算出来る。

$$\begin{aligned} \hat{\theta}(N) &= R(N)^{-1} f(N) = \left[ \frac{1}{N} \Phi(N)^T \Phi(N) \right]^{-1} \left[ \frac{1}{N} \Phi(N)^T y(N) \right] \\ &= \left[ \Phi(N)^T \Phi(N) \right]^{-1} \Phi(N)^T y(N) \end{aligned} \quad (70)$$

## 6.4 本章のまとめ

本章では数値積分法，数値積分法を適用した連続時間システムの同定モデル導出手法，最小二乗法について説明した。

これらの手法は，後述するファジィルール後件部の関数である肺エラストンス式のパラメータを推定するために用いられる。詳述は避けるが，推定に使用される呼吸システムの数式モデルは2次の非線形微分方程式で記述された連続時間モデルであるため，連続時間システムの同定に有効とされている数値積分法を適用した本章の手法により同定モデルを導出する。また，導出された同定モデルに最小二乗法を適用することにより肺エラストンス式の未知パラメータを推定することが出来る。

## 7 ファジィロジック

### 7.1 ファジィロジックについて

現実の世界には、人間の認識や行動などに関する情報のように、あいまいさを含むものが数多く存在している。これらの解釈は、主観により異なり、一般的な基準や法則などが見つかりにくいいため、従来、計測しにくく、また、解析しにくいとされてきた。ファジィロジックとは、このあいまいな世界にメンバーシップ関数を想定し、尺度を構成することによって、人間の感情、判断、評価などに関する定性的な情報をも定量的に取り扱っている理論のことである。

ファジィロジックは、定性的な情報や事象を定量的に解析し評価する科学として、1965年にアメリカのカリフォルニア大学のザデー (L.A.Zadeh) 教授によって提唱され、今日では工学から人間科学までの広い分野に応用されている。ファジィ集合の理論は、提唱当初はあまりにも理論的すぎるという理由からそれほど注目されなかった。しかし、1970年代頃から次第に工学者の注目を集めるようになったファジィロジックは、1980年にデンマークのシュミット社の開発したセメントキルンのファジィ制御器の商用化を契機として、ファジィ制御の分野を中心として産業界での実用化が急速に開始されるようになった。また、近年では日本においても浄水場の制御・地下鉄の自動運転をはじめとするエキスパートシステムとしてのファジィ制御の実用化や、ファジィ推論チップによるファジィコンピュータにその理論が用いられている。特にファジィロジックの使い勝手のよさから、洗濯機・掃除機・エアコンなどの家電製品に多く組み込まれている [12]。

#### 7.1.1 あいまいさ

“fuzzy” という語を辞書で引いてみると、不確かさを表す形容詞として、「けばのような」「綿毛のような」「ぼやけた」という訳が出ている [13][14]。

「ファジィ」の概念が導入されたとき、日本では「あいまい (曖昧)」という語があてられた。「あいまい」というのは、「はっきりしないこと」「確かでないこと」を表す言葉である。「はっきりしている」や「確かである」であるとは、「yes、no」「1、0」「白、黒」等と答えることが出来るが、「あいまい」であるとは、「yes でも no でもない」「0.4、0.6 など」「中間」等のように、漠然とした答えということになる。

人間は日常生活の中で、「宝くじがあたるかどうか」「試験にこの問題がでるかどうか」といった「あいまいさ」に出会うことがあるが、これらは日時の経過によって結果は明確

となることであり，事象が実際に起こるか否かの確実さの度合いを扱うのは「ファジィ」ではなく確率論となる。「面白い」「楽しい」「よい」「悪い」といった，人それぞれの主観によって異なり，境界が明瞭でないことによって引き起こされる「あいまいさ」をファジィ理論では取り扱い，ファジィネス (fuzziness) という。




図 14 ファジィネスの概念図.

### 7.1.2 ファジィ理論の体系

ファジィ理論は，

1. ファジィ集合
2. ファジィ理論
3. ファジィ測度

によって組み立てられた理論体系と考えられている。

現代の数学は集合論を基礎として構成されているが，その基礎にファジィ集合を導入することによって，より広いものにすることが期待される。ファジィ理論は，「あいまいな」理論と誤解されることがあるが，実際は「あいまいさ」の存在を認めて数量化し，数学的に推論をするという理論である。

## 7.2 ファジィ集合

### 7.2.1 ファジィ集合とメンバーシップ関数

我々が日常使用する「集合」という言葉は，「いくつかのものを集めること」等のような意味をもっている。ここで「ものの集まり」を「集合」と呼ぶことに定義したとき，

1. 大学入学者の「集合」

## 2. 美しい花の「集合」

のように使用される。しかし、1 は一人一人の人が大学入学者かどうか確定出来るのに対し、2 の美しい花というのは見る人の主観によって差異がある。

通常取り扱う集合は確定された対称物の集まりであり、任意に“もの”が与えられたとき、それが集合に属するか否かを必ず判定できる。

集合を構成する個々の“もの”をその集合の要素または元という。 $x$  が集合  $A$  の要素であるとき、 $x$  は  $A$  に属するといい  $x \in A$  と書く。また、 $x$  が  $A$  の要素でないとき、 $x$  は  $A$  に属さないといい  $x \notin A$  と書く。

条件あるいは性質  $P(x)$  を満たすような  $x$  の集合を、 $\{x : P(x)\}$  で表し、全ての要素を書き出すことができる場合、 $x_1, x_2, \dots, x_n$  からなる集合を、 $\{x_1, x_2, \dots, x_n\}$  で表す。

今、「教室が暑い」という言葉を、yes か no、1 または 0 という考え方で 32 以上と約束すると、33、34 の場合は yes、30、31 の場合は no である。しかしながら、32 ならば yes、31.9 ならば no と 0.1 の差で突然入れ替わることは人間の感覚には合わない。ここで「暑い」の表現を、評価の度合いを考え、0 と 1 の間の数値を割り振ることで数量的に表現することが可能となる。

集合  $X$  の各要素に評価の度合いを割り当てる規則は次のように定義される。集合  $X$  におけるファジ集合  $A$  は、次のようなメンバーシップ関数 (membership function)  $\mu_A$  によって特徴づけられる。

$$\mu_A : X \rightarrow [0, 1]$$

$\mu_A \in [0, 1]$  を  $x \in X$  が  $A$  に属するグレードまたは度合いという。この値が 1 に近ければ  $x$  の  $A$  に属する度合いが高く、0 に近ければ  $x$  の  $A$  に属する度合いが低いことを示している。




図 15 メンバーシップ関数のグラフ.

ファジィ集合は  $X$  を横軸にとり,  $x \in X$  に対し高さが  $\mu_A(x)$  である点をとるとき ( $X$  が連続的ならば) 曲線  $\mu_A$  で表される。(図 15)

とくに,  $\mu_A(x) = 1$  または  $0$  でそれ以外の値をとらないとき,  $A$  は通常の集合である。これはファジィ集合の特別な場合でクリスプ集合 (crisp set) といわれる。




図 16 ファジィ集合の例図.

ファジィ集合の表記にあたっては, 各要素のグレードを明示することが重要であり, 次のように書く。

$$A = \{(x, \mu_A(x)) : x \in X\}$$

または,  $X$  が有限集合のときは,

$$A = \{\mu_A(x_1)/x_1, \mu_A(x_2)/x_2, \dots, \mu_A(x_n)/x_n\}$$

$X$  が連続集合のときは,

$$A = \int_X \mu_A(x)/x$$

のように表す。

ファジィ集合  $A$  のメンバーシップ関数  $\mu_A(x)$  の値が正であるような  $x \in X$  の集合, すなわち,

$$\{x \in X : \mu_A(x) > 0\}$$

を  $A$  の台 (support) または台集合という。

すべての  $x \in X$  に対して,

$$\mu_A(x) \leq u$$

となる実数  $u$  のうち最も小さい数 ( $X$  における  $\mu_A(x)$  の上限) を  $A$  の高さ (height) といい,  $\text{hgt}(A)$  と記述する。

とくに,  $hgt(A) = 1$  のとき, ファジィ集合  $A$  は正規 (normal) であるという。

以上のように, ファジィ集合は我々の身の回りにみられる ‘あいまいさ’ を数値を用いて特徴づけたもので, ‘ファジィ’ を ‘理論’ として構築する際には土台となるものである。今日の情報化社会ではいろいろな言葉をコンピュータ処理する必要性が生ずるが, そのためにはそれらの言葉の意味を定義しなければならない。この時, 判断する人間の感覚や対象の周辺環境によって微妙な違いがあり, あいまいさが生じてくる。このような場面でファジィ集合の考え方が有効となる。

最後にファジィ集合のメンバーシップ関数の決定方法であるが, メンバーシップ関数を客観的に決める方法はない。ある程度の常識の範囲内であればファジィ集合を用いる人間が好きなように自分の主観に基づいて対象に合うように決めてよい。

ファジィ理論が人間の知識や主観を取り扱うことができるのは, あいまいさの存在を許容し, あいまいさの程度を自分で好きなようにきめることができるからである。

### 7.2.2 ファジィ集合の演算

この節ではファジィ集合の演算について述べる。 $A, B$  を集合  $X$  における 2 つのファジィ集合とする。最初に, 2 つのファジィ集合の相等を定義する。すべての  $x \in X$  について,

$$\mu_A(x) = \mu_B(x) \quad (71)$$

が成り立つとき,  $A$  と  $B$  は等しく,  $A = B$  と書く。

次に, 2 つのファジィ集合の包含を定義する。すべての  $x \in X$  について,

$$\mu_A(x) \leq \mu_B(x) \quad (72)$$

が成り立つとき,  $A$  が  $B$  に含まれる, または  $A$  は  $B$  の部分集合であるといい,  $A \subseteq B$  と書く。

ファジィ集合の性質に関して以下の性質が成り立つ。

$$\begin{aligned} A &\subseteq A && \text{(反射律)} \\ A &\subseteq B, B \subseteq A \Rightarrow A = B && \text{(反対称律)} \\ A &\subseteq B, B \subseteq C \Rightarrow A \subseteq C && \text{(推移律)} \end{aligned}$$

次に, それぞれの  $x \in X$  に対して  $\mu_A(x), \mu_B(x)$  の大きい方をとるファジィ集合と小さい方をとるファジィ集合を考える。

$$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} \quad (73)$$






図 17 部分集合のグラフ.

から定まるファジィ集合を  $A$  と  $B$  の和集合あるいは結びと呼び,  $A \cup B$  と書く。

また,

$$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} \quad (74)$$

から定まるファジィ集合を  $A$  と  $B$  の共通集合あるいは交わりと呼び,  $A \cap B$  と書く。




図 18 和集合、共通集合.

和集合, 共通集合に関する性質としては次が成り立つ。

$$A \cup A = A, \quad A \cap A = A \quad (\text{べき等律})$$

$$A \cup B = B \cup A, \quad A \cap B = B \cap A \quad (\text{交換律})$$

$$(A \cup B) \cup C = A \cup (B \cup C)$$

$$(A \cap B) \cap C = A \cap (B \cap C) \quad (\text{結合律})$$

$$A \cup (A \cap B) = A, \quad A \cap (A \cup B) = A \quad (\text{吸収律})$$

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$$

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C) \quad (\text{分配律})$$

ファジィ集合  $A$  があるとき，すべての  $x \in X$  に対してメンバーシップ関数

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x)$$

で定まるファジィ集合を  $A$  の補集合と呼び， $\bar{A}$  と書く。

### 7.3 ファジィ論理

ファジィ論理とは，端的に述べると多値論理にファジィネスの概念を導入したものである。しかしながら，ファジィ理論に対する考え方にはいろいろあり，はっきりした定義はない。

ふつつ論理学とは，「太陽は恒星である」，「日本は中国の隣国である」，「2 は偶数である」のような命題の真偽を問題にするものである。論理には2 値論理に始まって，3 値論理，一般な多値論理，そしてさらに無限値論理に至るまで多くの形式があり，ひとつの論理は論理演算によって結合された命題の真理値の与え方と，推論の規則によって特徴づけられる。

真理値とは命題の真偽を数値で表したもので，2 値論理では命題の真偽は確定的に定まるものと仮定し，真を1，偽を0で表現する。3 値論理では1，0の他に真偽不明を意味する  $1/2$  という真理値を考える。無限値論理というのは，真理値として，0， $1/2$ ，1にとどまらず，真偽の程度に応じて0から1までの任意の値を考える論理である。

これらの論理においては命題の意味を改めて問題にすることはない。例を挙げると，「 $A$  はアメリカ人である」という命題を扱うときに「 $A$ 」とは誰のことであるか明確であると仮定し，また「アメリカ人」という定義も明確であると仮定する。そして，2 値論理では「 $A$ 」が「アメリカ人」であるか否かがはっきりわかるものとされる。ただし，3 値論理では「 $A$ 」のことを知らないことが「アメリカ人」か否か解らないという場合も許される。ここで，「 $A$ 」，「アメリカ人」という固有名詞は，論理においてかならず固有名詞で表現する必要はなく， $a$  や  $x$  といった記号であってもよい。固有名詞で書かれた命題は語の意味が確定しないことがほとんどであるため，通常の論理では「 $a$  は  $x$  である」という記号を用いた抽象的な命題のみを扱う。

命題を一般に  $P$ ， $Q$  などのように表わし，論理演算として， $\neg$  (否定)， $and$  (論理積)， $or$  (論理和)， $\rightarrow$  (含意またはインプリケーション)， $\leftrightarrow$  (同等)などを考える。 $\neg P$  は「 $P$  でない」， $P and Q$  は「 $P$  かつ  $Q$  である」， $P or Q$  は「 $P$  または  $Q$ 」， $P \rightarrow Q$  は「 $P$  ならば  $Q$ 」， $P \leftrightarrow Q$  は「 $P$  と  $Q$  は同じ」を意味する。命題に論理演算を論理演算をほどこしたものは論理式と呼ばれ，論理系とは論理式の真偽を個々の命題の真偽を用いて定めるも

のである。

命題  $P, Q$  の真理値を  $|P|, |Q|$  で表わすと, 2 値論理において基本的な論理式は,

$$\begin{aligned} |\neg P| &= 1 - |P| \\ |P \text{ and } Q| &= |P| \wedge |Q| \\ |P \text{ or } Q| &= |P| \vee |Q| \\ |P \rightarrow Q| &= (1 - |P|) \vee |Q| \\ |P \leftrightarrow Q| &= |P \rightarrow Q| \wedge |Q \rightarrow P| \end{aligned} \quad (75)$$

となる。2 値論理の場合には  $|P|, |Q|$  は 0 か 1 の値しかとらないので, このような関数は,

$$f : \{0, 1\} \times \{0, 1\} \rightarrow \{0, 1\} \quad (76)$$

となり, その数は有限個しかなく, 論理結合子の数も有限である。

一方で, 無限値論理では, 真理値集合は区間  $[0, 1]$  であり, 関数は,

$$f : [0, 1] \times [0, 1] \rightarrow [0, 1] \quad (77)$$

となるので, 論理結合子は無限に考えることが出来る。

ある事実をもとにして他のことを推し量る事を推論という。例として,

規則:  $x$  が市であるならば,  $x$  には市役所がある

事実: 横浜は市である

-----

結論: 横浜には市役所がある

が挙げられる。これを一般の形で書くと,

規則: A ならば, B である

事実: A である

-----

結論: B である

と書き直すことができる。例の推論式は二値論理に基づくものであり, 記号推論と呼ばれる。ここで推論にファジィの概念を取り入れると,

規則: 柿がオレンジ色に色づけば, 甘い

事実: この柿は少しオレンジ色である

-----

結論: この柿はやや甘い

のように我々の日常的な推論を下線のファジィ集合を用いて表現することができる。

推論は通常、「 $P$  ならば  $Q$ 」というインプリケーションを用いて行なわれ、modus ponens と modus tollens の 2 種類がある。

modus ponens は「 $P$  ならば  $Q$  が真」であるとき、「 $P$  が真」ならば「 $Q$  は真」であることを推論するもので、以下の式で表わされる。

$$\begin{array}{ll}
 (i) & P \\
 (ii) & P \rightarrow Q \\
 \hline
 (iii) & Q
 \end{array} \tag{78}$$

これは論理式では

$$(P \text{ and } (P \rightarrow Q)) \rightarrow Q \tag{79}$$

を意味する。(ii) のインプリケーション  $P \rightarrow Q$  の  $P$  は前件部、 $Q$  は後件部と呼ばれ、(i) の  $P$  は前提、(iii) の  $Q$  は結論と呼ばれる。このように、2 値論理の modus ponens においては、前件と前提、後件と結論がそれぞれ同じものとなる。

一方、modus tollens というのは modus ponens の対偶であり、

$$\begin{array}{ll}
 (i) & \neg Q \\
 (ii) & P \rightarrow Q \\
 \hline
 (iii) & \neg P
 \end{array} \tag{80}$$

と表せる。これは「 $P \rightarrow Q$  が真」で「 $\neg Q$  が真 ( $Q$  が偽)」のとき、「 $\neg P$  は真 ( $P$  は偽)」であることを推論するものである。

ファジィ論理では、「4 は小さい整数である」、「日本はアメリカと親しい」などのファジィ命題を扱う。命題は一般に、

$$「x \text{ は } A」$$

の形式で、 $A$  は主語  $x$  の述語と呼ばれる。ファジィ論理が他のすべての論理と異なる点は、前述したようにファジィ論理で扱われる命題の述語がファジィ集合を用いて表わされ、その意味があいまいであるということである。すなわち命題（述語）の定義が確定的ではないため、ファジィ論理では他の論理と違い命題の意味内容が重要な問題となる。

例として、次の 2 つの命題 ((a) はクリस्प命題、(b) はファジィ命題) を考える。

$$\begin{array}{ll}
 (a) & 「x \text{ は偶数である}」 \\
 (b) & 「x \text{ は小さい整数である}」
 \end{array} \tag{81}$$

非ファジィ論理については命題の意味内容は問わない、つまり、述語である「偶数」の意味は個々の人間とは無関係であり普遍的にわかっているものと仮定される。これに対して、ファジィ論理では述語の「小さい整数」の意味を問わなければならない。そして、ファジィ集合を用いて、個人の主観を定量化する。別の見方をすると、命題 (a) では、任意の数  $x$  が与えられたとき、それが偶数であるかどうか判定を行なうアルゴリズムが存在し、命題の真偽は 0 か 1 か必ず確定する。しかし、(b) では  $x$  が小さいか否かを判定するアルゴリズムは存在せず、真偽も 0 か 1 かのようにには確定しない。

このことから、ファジィ論理には他の論理と著しく異なる特徴がいくつかあり、それらの特徴は、

1. ファジィ限量子
2. 述語修飾演算子
3. ファジィ真理値
4. ファジィ推論

である。

$\rightarrow$ , *and*, *or*,  $\rightarrow$ ,  $\leftrightarrow$  などだけの論理記号を扱う命題論理に加えて、 $\forall$ ,  $\exists$  などの限量子を扱う論理は述語論理と呼ばれる。 $\forall x$  は「すべての  $x$ 」を意味し、 $\exists x$  は「ある  $x$  が存在する」を意味するが、ファジィ限量子とは「ほとんどの  $x$ 」とか「いくつかの  $x$ 」などのことである。また、ファジィ真理値とは「とても真」、「やや偽」などのようなあいまいな真理値のことで、これらは真理値集合  $[0, 1]$  のファジィ数として表わされる。ファジィ推論については次節で述べることから、ここでは述語修飾演算子について述べることにする。

述語修飾とは、「 $x$  は小さい整数である」というファジィ命題の述語を「 $x$  はとても小さい整数である」などのように修飾することである。「とても」、「やや」などの修飾語を  $m$  と表わすと、ファジィ命題「 $x$  は  $A$ 」は  $m$  によって修飾されて

$$\text{「} x \text{ は } mA \text{」}$$

となる。例として、 $m$  が「とても」、「やや」、「でない ( $\rightarrow$ )」のとき、 $mA$  はそれぞれ

$$\begin{array}{ll} \text{とても} & \cdots \cdots \cdots A = A^2 \\ \text{やや} & \cdots \cdots \cdots A = A^{1/2} \\ \rightarrow & \cdots \cdots \cdots A = 1 - A \end{array} \quad (82)$$

のように定めることが出来る。これらの式は便宜的なものであり、決め方は一通りではない。

## 7.4 ファジィ推論

ここではファジィの概念を使った推論法を説明する。まずは、ファジィルール（ファジィ規則ともいう）の構造を述べる。推論に必要な制御したいプラントの状態に関する情報を  $x_1, x_2$  , またプラントへの入力を  $y$  とすると、if（前件部）-then（後件部）型のファジィ規則は

$$\begin{aligned} & \text{if } x_1 \text{ is small and } x_2 \text{ is big then } y \text{ is medium} \\ & \text{if } x_1 \text{ is big and } x_2 \text{ is medium then } y \text{ is big} \end{aligned} \quad (83)$$

のように記述されるアルゴリズムのことで、これらはファジィ論理のインプリケーションとして表わされる。ファジィ規則は前件部と後件部に分けられるが、 $x_1, x_2, y$  などのとる値が言語ラベルの付いたファジィ集合で表わされることもあるので、言語的規則と呼ばれることもある [15]。

ファジィ規則  $R$  を一般的に表わすと

$$R^i : \text{if } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ then } y \text{ is } B_i \quad (84)$$

となる。 $i$  は規則の番号である。 $x_1, x_2$  は前件部変数、 $y$  は後件部変数と呼ばれる。 $A_i, B_i$  などはいろいろなファジィ集合で表わされるため、ファジィ変数と呼ばれることもあるが、実際には変数  $x, y$  のとるファジィ値であると考えてよい。一般的なファジィ規則を、

$$R^i : x_1 = A_{i1}, x_2 = A_{i2} \rightarrow y = B_i \quad (85)$$

のように書かれることもある。前件部では論理結合子 and が省略されている。

これまではファジィ集合  $A$  のメンバーシップ関数を  $\mu_A(x)$  などのように表わしてきたが、ファジィ集合のラベルが Medium のように長くなく、 $A$  のような短い記号である場合にはメンバーシップ関数を簡単に  $A(x)$  と表わすことにしてもよい。つまり、 $A$  はファジィ集合のラベルでもあるし、メンバーシップ関数でもある。

ファジィ推論は、複数個のファジィ規則の集合とファジィ推論部から構成される。規則の前件部変数  $x_1, x_2$  は入力、後件部変数  $y$  は出力と呼ばれる。ファジィ推論部では、実際の入力を与えられたとき、適用可能な規則を用いてファジィ推論を行なうことにより出力を計算する。ファジィ推論はファジィ論理に基づくものだが、ファジィ関係概念を用いない簡単な計算法が考案されている。これはファジィ論理における一般的ファジィ推論と異なり、実際の制御におけるファジィ推論では、推論の前提である入力値がファジィ値ではなく、ふつうの数値であることを考慮したものである。推論結果も、ファジィ値ではなく数値で与えられる。

ファジィ推論は，前件部と後件部の形式，ファジィ変数の型，推論法の3つの点から分類されるが，これらは相互に関係があり，必ずしも独立でない。

以下では基本的な2種類の推論法を説明する。

#### 推論法 1

この方法はふつうの多値論理にファジィネスを導入したファジィ論理に基づく推論法を簡単にしたものである。このファジィ論理は命題の真理値として，「かなり真」とか「やや偽」といったようなファジィ集合で表わされるあいまいな値を扱う論理である。命題はもちろんファジィである。無限値論理というのは，真理値が1、0の2値論理と異なり，区間[0,1]の任意の値を真理値として考えるもので，クリスプ集合をファジィ集合に拡張したようなものである。

このファジィ論理に基づく推論は間接法と呼ばれるが，複雑な部分は省略し，簡略化した方法だけ説明する。使われるファジィ変数は図19，図20に示すような単調型と呼ばれるものである。メンバーシップ関数は単調減少または単調増加で，図19は直線型，図20はarctan型である。

P, N はそれぞれ Positive , Negative と呼ばれるファジィ変数である。図19は

$$\begin{aligned} P(x) &= \frac{1}{2} + \frac{1}{2} \\ N(x) &= P(-x) \end{aligned} \quad (86)$$

と表現される。実際に使用するときには述語修飾演算子を用いて，とてもP，ややNなどと修飾することがある。

一方，図20のメンバーシップ関数は

$$\begin{aligned} P(x) &= \frac{1}{\pi} \tan^{-1} ax + \frac{1}{2} \\ N(x) &= P(-x) \end{aligned} \quad (87)$$

と表わされる。arctan 型の場合の台集合は規格化せず，実数の区間 $(-\infty, \infty)$ をそのまま用いる。これらの変数は1つで台集合上のすべての空間をカバーしているのが特徴的である。

例として，次の2つの規則

$$\begin{aligned} R^1 &: \text{if } x_1 \text{ is } N_{11} \text{ and } x_2 \text{ is } P_{12} \text{ then } y \text{ is } N \\ R^2 &: \text{if } x_1 \text{ is } P_{21} \text{ and } x_2 \text{ is } N_{22} \text{ then } y \text{ is } P \end{aligned} \quad (88)$$

を考えたとき，入力  $x_1 = x_1^0$  ,  $x_2 = x_2^0$  に対して，規則  $R^1$  に対するファジィ集合のグ




図 19 ファジ変数 - 単調（直線）型例図.




図 20 ファジ変数 - 単調（arctan）型例図.

レードである適合度  $\omega_1$  は,

$$\omega_1 = N_{11}(x_1^0) \wedge P_{12}(x_2^0)$$

または,

$$\omega_1 = N_{11}(x_1^0)P_{12}(x_2^0)$$

と表せる。つぎに、規則の後件部において

$$\omega_1 = N(y_1)\omega_2 = P(y_2) \quad (89)$$

となるような  $y_1$  と  $y_2$  を求める。 $N(y)$ ,  $P(y)$  は 1 対 1 の関係より,  $y_1$ ,  $y_2$  は逆関数を用いて

$$y_1 = N^{-1}(\omega_1)y_2 = P^{-1}(\omega_2) \quad (90)$$

と求められ, これらを規則  $R^1$  と  $R^2$  の推論結果とする。

全体の推論結果を  $y^0$  と定義すると,  $y^0$  は  $y_1$  と  $y_2$  の適合度  $\omega_1$ ,  $\omega_2$  による重み付き平均（合成重心法）で計算出来る。

この推論法のプロセスを図示すると図 21 のようになる。

この推論法はファジ規則の数が少なくすむ。しかし, 使われる言葉が Positive, Negative のような大ざっぱなものだけなので, オペレータの制御知識などの表現には向か



ない。ファジィ変数の数が少ないと、それだけ記述能力が劣ることになるが、これは  $P, N$  の関数を非線形にし、変化させることで補われる。つまり、この推論法はファジィ変数のメンバーシップ関数の形が推論結果に大きな影響を与えるということである。




図 21 推論法 1 のプロセス.

## 推論法 2

推論法 2 で使われる規則の前件部はファジィ命題からなり、後件部はふつうの線形式からなる。前件部で使用されるファジィ変数は図 22 に示すような台形型のメンバーシップ関数をもつものがよく使用されている。図 22 からわかるように、ファジィ変数はクリスプな領域にファジィ境界をつけたものを表わしている




図 22 ファジィ変数 - 台形型.

例として次の2つの規則を考える。

$$\begin{aligned} R^1 &: \text{if } x_1 \text{ is } A_{11} \text{ and } x_2 \text{ is } A_{12} \text{ then } y = f_1(x_1, x_2) \\ R^2 &: \text{if } x_1 \text{ is } A_{21} \text{ and } x_2 \text{ is } A_{22} \text{ then } y = f_2(x_1, x_2) \end{aligned} \quad (91)$$

ここで,  $f_1, f_2$  は,

$$y = ax_1 + bx_2 + c \quad (92)$$

のような線形式であると考え。入力  $x_1^0, x_2^0$  に対する前件部の適合度  $\omega_1, \omega_2$  は

$$\begin{aligned} \omega_1 &= A_{11}(x_1^0)A_{12}(x_2^0) \\ \omega_2 &= A_{21}(x_1^0)A_{22}(x_2^0) \end{aligned} \quad (93)$$

のように積で定義される。個々の規則による推論結果は後件部に直接  $x_1^0, x_2^0$  を代入して,

$$\begin{aligned} y_1 &= f_1(x_1^0, x_2^0) \\ y_2 &= f_2(x_1^0, x_2^0) \end{aligned} \quad (94)$$

のように求められる。全体の推論結果は推論法1と同じく、重み付き平均値（重み付き重心法）とする。すなわち、

$$y^0 = \frac{\omega_1 f_1(x_1^0, x_2^0) + \omega_2 f_2(x_1^0, x_2^0)}{\omega_1 + \omega_2} \quad (95)$$

と計算できる。

ここで規則の数が1つの場合には、上式で  $\omega_2 = 0$  と考えればよいが、すると、 $y^0 = f_1(x_1^0, x_2^0)$  となるから、PIDのような線形制御則と同じになる。

規則が複数個の場合には、入力空間をあいまいな部分空間に分割し、それぞれの部分空間で線形な入出力関係を見だし、それらの集まりによって全体の非線形な入出力関係をあらわすことになる。また、言語表現が前件部のみなので、記述能力の点でとても優れている。


以上のようにファジィを用いた推論法は様々あるが、今回の実験は非線形関数である肺のエラスタンスを推定することが目的となるため推論法2を使用することとした。

ここからはファジィモデリングと同定の問題点について説明する。

ファジィモデリングとは、式

$$\begin{aligned} R^i &: \text{if } x_1 \text{ is } A_1^i, x_2 \text{ is } A_2^i, \dots, x_m \text{ is } A_m^i \\ &\text{then } y^i = a_0^i + a_1^i x_1 + \dots + a_m^i x_m \end{aligned} \quad (96)$$

の形式で制御または推論対象を記述すること，具体的には入出力データを与えられて，上式の諸変数を同定することである。一般にシステム論において，同定は構造同定とパラメータ同定に分けられるが，ファジモデリングでは問題がかなり複雑になり，モデル同定はつぎのように分類される。



後件部の同定はふつうの線形システム同定問題と本質的に同じであり，強いて異なる点をいえば，パラメータの数が多いくらいのことである。つまり，ファジイルールの規則数個の線形モデルを同時に同定しなければならないという事である。

ファジモデルに特徴的なのは前件部の同定である。例として次のファジイルールを考える。

$$\begin{aligned}
 R^1 &: \text{if } x_1 \text{ is Small}_1 \text{ and } x_3 \text{ is Small}_2 & \text{then } y^1 &= 0.5 + 1.2x_2 - 0.6x_3 \\
 R^2 &: \text{if } x_1 \text{ is Small}_1 \text{ and } x_3 \text{ is Big}_2 & \text{then } y^2 &= 1.2 + 0.2x_1 + x_2 - 2.3x_3 \\
 R^3 &: \text{if } x_1 \text{ is Big}_1 & \text{then } y^3 &= 1.5 + 2.3x_1 - 0.9x_3
 \end{aligned} \tag{97}$$

このファジモデルにおいて入力  $x_1, x_2, x_3$  である。一般形の規則ではすべての入力の前件部と後件部に等しく表れているが，実際の制御・推定対象はそうではない。たとえば，入力  $x_2$  はどの規則の前件部変数でもない。このように同定においては，どの変数がファジイルールのどこに関係しているのか入出力データを使い発見しなければならない。前件部の構造とは，前件部変数の組と前件部変数が張る空間のファジ分割の仕方である。よって前件部の構造同定とは最適な前件部変数の組と変数空間のファジ分割を見いだすことである。ここで分割数が多いければよいということはなく，何らかの最適な分割数を見つけ出さなければならない。

前件部のパラメータ同定とはファジ分割が決定した後で，ファジ変数のパラメータを決定することである。

前述したように，後件部同定において構造とは後件部に係わる変数の組のことであり，パラメータとは線形式の係数のことである。もし，ファジイルールが1つならば，前件部の条件は何も意味をなさなくなり，後件部のみで入出力特性が記述できる。このときの

ファジモデルは線形モデルに他ならない。このことから、複数個のファジルールからなるファジモデルは非線形システムの特性を複数個の線形システムの組み合わせで近似しようとするものである。例として、次の2つのファジルールを考える。

$$\begin{aligned} R^1 &: \text{if } x \text{ is Small then } y = 0.6x + 2 \\ R^2 &: \text{if } x \text{ is Big then } y = 0.2x + 9 \end{aligned} \quad (98)$$

これは1入力1出力システムを2つのルールでモデル化したものであるが、このファジモデルの入出力特性は図23に示すようになる。 $R^1$ ,  $R^2$  と書いた直線はそれぞれ、後件部線形式のグラフである。 $x$  軸に接して、前件部のファジ分割を定める *Small*, *Big* のメンバーシップ関数を示してある。図からわかるように、このファジモデルは入力空間の“*x is Small*” と “*x is Big*” が重なる領域 ( $4 \leq x \leq 7$ ) における出力を2つの法則からファジ推論によって決めていることがわかる。




図 23 ファジモデル例.

前件部と後件部の構造とパラメータを同定するための手順のアルゴリズムを図24に示す。同定はまず、前件部に係わる諸量を仮定して、最適な後件部を発見し、つぎに前件部を修正して、というような繰り返し型のアルゴリズムである。一般に、構造同定においては有限個のデータから真の構造がわかるわけがないことから、本質的に発見的方法に頼らざる得ない性格をもっている。モデルの枠組みは仮定されるから、その枠組みの中で、可能な構造を列挙し、ある規範の下にひとつを拾いあげることができるが、全てを調べるこ

とは計算時間の点で難しいため、実際には何か探索を途中で打ち切る方策を考える必要がある。図 24 のアルゴリズムでは、後件部構造の発見と、前件部構造の発見のところで繰り返し探索が行なわれている。

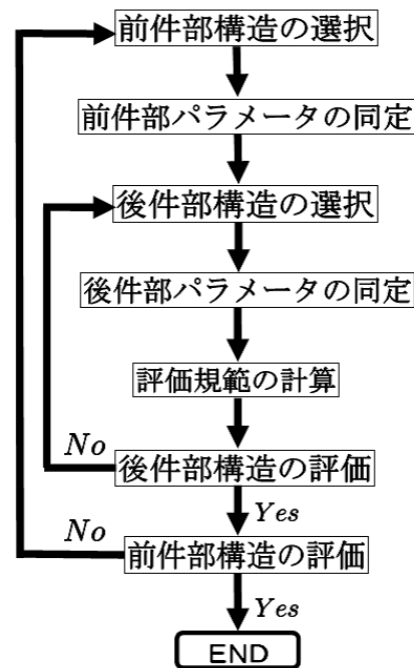


図 24 同定アルゴリズム.

## 8 ファジィロジックを用いた肺エラストランス推定手法

本章では，前研究である関数型 SIRMs ファジィ推論法を用いた肺エラストランス推定手法を説明する。

### 8.1 関数型 SIRMs ファジィ推論法アルゴリズム

Mamdani 方式の if-then 形ファジィモデルは，システムのすべての入力項目が if の前件部にセットされ，すべての出力項目が then の後件部にセットされる。入力項目数が少ない場合にはその構造が有効である。しかし，入力項目数が多く大規模化すると，各ファジィルールの設定や調整が難しくなり，またルールの数が爆発的に増加するなどの問題が生じる。

そこで，複数入力システムに対して，すべて 1 入力の if-then 形式のファジィルールから構成する「単一入力ルール群 (Single Input Rule Modules，以下 SIRMs と略す)」を適用する [16][17]。まず，各入力項目についてそれぞれ 1 つのルール群を用意して各ルール群毎に対応する入力項目のみを前件部変数とする 1 入力のファジィルールをセットする。次にシステムにおける各入力項目の重要さに注目して，それぞれの重視度（重み）を定義し，各ルール群の推論結果の重視度付き総和を最終出力とする。また，後件部が関数で構成される場合には「関数型 SIRMs 推論法」と呼ぶ。

本手法は，従来の手法とは違う非線形特性を持ち，同じ出力項目に対して同時に異なるスケーリングファクターを与えることができる。また，直接に各入力項目に独立に重視度を与え，各ルール群の合成演算結果の重視度付き総和を求めることにより，ルール数とパラメータ数を減らすばかりではなく，入力項目のシステムの出力への影響を直感通りに操作できるという利点をもつ。

SIRMs 推論法の説明を簡単にするために，以下では  $n$  入力 1 出力のシステムを例にする。

$n$  入力 1 出力のシステムに対して，入力項目数  $n$  と同じ個数の 1 入力 1 出力型のルール群から構成される SIRMs 推論法の後件部実数を関数に拡張した関数型 SIRMs 推論法の

ルール群を構成すると，

$$\begin{aligned}
 \text{Rules} - 1 : \{R_j^1 : x_1 = A_j^1 \longrightarrow y_1 = f_j^1(x_1)\}_{j=1}^{m_1} \\
 \vdots \\
 \text{Rules} - i : \{R_j^i : x_1 = A_j^i \longrightarrow y_i = f_j^i(x_i)\}_{j=1}^{m_i} \\
 \vdots \\
 \text{Rules} - n : \{R_j^n : x_n = A_j^n \longrightarrow y_n = f_j^n(x_n)\}_{j=1}^{m_n}
 \end{aligned} \tag{99}$$

となる。ここで， $R_j^i$  は  $i$  番目のルール群  $\text{Rules} - i$  の中の  $j$  番目のルールを表わす。 $x_i$  は前件部変数， $y_i$  は後件部変数である。 $A_j^i$  は前件部変数  $x_i$  のファジィ集合， $f_j^i(x_i)$  は後件部の関数出力値を意味する。なお，ルール群の番号は  $i = 1, 2, \dots, n$  を， $i$  番目のルール群  $\text{Rules} - i$  中のルール番号は  $j = 1, 2, \dots, m_i$  であり， $m_i$  はルールの個数を表わす。

以後の説明では関数型 SIRM<sub>s</sub> 推論法のファジィルールの後件部  $f_j^i(x_i)$  を

$$f_j^i(x_i) = c_j^i + d_j^i x_i \tag{100}$$

のように一次式に限った場合について説明する。

各入力  $x_i^0$  が入力されたとき，ルール群  $\text{Rules} - i$  における  $j$  番目のルールの前件部の適合度  $h_j^i$  は，

$$h_j^i = A_j^i(x_i^0) \tag{101}$$

と与えられ，そのルール群からの推論結果  $y_i^0$  は重み付き重心法により

$$y_i^0 = \frac{\sum_{j=1}^{m_i} h_j^i (c_j^i + d_j^i x_i^0)}{\sum_{j=1}^{m_i} h_j^i} \tag{102}$$

と求められる。

通常，システムに対して各入力項目の影響力あるいは貢献度は異なる。つまり，貢献度の大きい入力項目もあれば，貢献度の小さい入力項目もある。また，強調することによってシステムのパフォーマンスをより良くする項目もあれば，逆にシステムのパフォーマンスに良い効果を与えない項目もある。貢献度の大きいまたは望ましい影響をもたらす入力項目の役割を強調し，逆に貢献度の少ない入力項目の効果を抑制することは経験的手法に合致し，システムのパフォーマンス向上につながる。従来手法では，全ての入力項目が同

等に取り扱われ，たとえルールまたは後件部の実数出力値に重みを定義しても結局すべての前件部変数に同じ重みを与えることとなっていた。そこで SIRM<sub>S</sub> 推論法では，入力項目の役割の違いに着目し，各入力項目について重視度を導入している。重視度の値が大きければ対応の入力項目の役割が強調され，小さければその役割が抑制される。

各入力項目  $x_i$  ( $i = 1, 2, \dots, n$ ) の重視度を  $\omega_i$  に設定した場合，関数型 SIRM<sub>S</sub> 推論法の最終出力  $y^0$  は以下のように各ルール群からの推論結果  $y_i^0$  の重視度  $\omega_i$  付き総和として求められる。

$$y^0 = \sum_{i=1}^n \omega_i y_i^0 \quad (103)$$

これによって，重視度の大きい入力項目は最終出力に大きく貢献し，重視度の小さい出力項目は最終出力にあまり貢献しないことになる。また，重視度によって規定された入力項目間の相対関係はそのまま線形的に最終出力に写されるので，目的に合わせて重視度を操作すれば直感通りの結果を得ることが可能である。

なお，各重視度が独立に設定されているので，重視度の総和をちょうど 1 になるように規制する必要はまったくない。最終出力の式から分かるように，各重視度がすべて同じ値に設定されたならば，各単一入力ルール群の出力にすべて同じ大きさのスケールリングファクターがかかることになる。しかし，各重視度が異なる値に設定されていれば，各ルール群は同じ出力項目であるにもかかわらず，異なるスケールリングファクターが定義される。実際に重視度を決定する際には，最初に出力のスケールリングファクターを適当に設定した上で，重視度の値を試行錯誤して調整するか，学習アルゴリズム等により自動チューニングする必要がある。ここで調整を誤ると望む出力結果が得られなくなるため，どのように各重視度を決定するのかという問題が重要となってくる。

## 8.2 関数型 SIRM<sub>S</sub> ファジ推論法アルゴリズム用いた肺エラストス推定手法

### 8.2.1 ファジルールの作成

前章で説明したファジロジックにおいて著名な Mamdani 方式の if-then モデルでは，すべての入力項目がファジルールの前件部に，すべての出力項目がファジルールの後件部にセットされる。

本研究では，前件部の入力項目は体積  $V$ ，後件部の出力関数は  $f_E(V) = k_1 + k_2 V$  で表現される 1 次関数の肺エラストスであると考ええる。また，前件部のファジ分割を *small*，*medium*，*big* とする。各入力項目に対して入力項目だけを前件部変数とする 1 入力型の



if-then 形式のファジルール群を定義して，各ルール群の推論結果の重み付き総和を最終推論結論とする「関数型単一入力ルール群（Single Input Rule Modules）結合型ファジ推論法」（関数型 SIRM<sub>s</sub> 法）を適用する。前件部の入力項目  $V$  を呼気時の体積  $V_{out}$  と吸気時の体積  $V_{in}$  に区別し，ファジルールに関数型 SIRM<sub>s</sub> 推論法を導入すると，

$$\begin{aligned}
 & \text{Rule} - V_{out} \\
 & \text{if } V_{out} = \text{small}_{out} \\
 & \quad \text{then } f_{Eout}(\text{small}) = k_{1out}(\text{small}) + k_{2out}(\text{small})V \\
 & \text{if } V_{out} = \text{medium}_{out} \\
 & \quad \text{then } f_{Eout}(\text{medium}) = k_{1out}(\text{medium}) + k_{2out}(\text{medium})V \\
 & \text{if } V_{out} = \text{big}_{out} \\
 & \quad \text{then } f_{Eout}(\text{big}) = k_{1out}(\text{big}) + k_{2out}(\text{big})V
 \end{aligned} \tag{104}$$

$$\begin{aligned}
 & \text{Rule} - V_{in} \\
 & \text{if } V_{in} = \text{small}_{in} \\
 & \quad \text{then } f_{Ein}(\text{small}) = k_{1in}(\text{small}) + k_{2in}(\text{small})V \\
 & \text{if } V_{in} = \text{medium}_{in} \\
 & \quad \text{then } f_{Ein}(\text{medium}) = k_{1in}(\text{medium}) + k_{2in}(\text{medium})V \\
 & \text{if } V_{in} = \text{big}_{in} \\
 & \quad \text{then } f_{Ein}(\text{big}) = k_{1in}(\text{big}) + k_{2in}(\text{big})V
 \end{aligned}$$

と表現出来る。

### 8.2.2 後件部関数パラメータの推定

本節では呼吸システムモデルを使用し，(104) 式のファジルールの内，任意の 1 ルールについて後件部関数パラメータを推定する。(4) 式にエラストンス式  $f_E(V) = k_1 + k_2V$  を代入すると，

$$P_{ao}(t) + a_1 \dot{P}_{ao}(t) = k_1 V(t) + k_2 V^2(t) + g_R(\dot{V})\dot{V}(t) + b_2 \ddot{V}(t) + P_{eea} + \epsilon(t) \tag{105}$$

というモデル式が得られる。

ここで連続時間モデルの同定に有効である数値積分法を適用して同定モデルを導出する。モデル式 (105) を簡単な形に書き直すと

$$P_{ao}(t) = \varphi^T(t)\theta + \epsilon(t) \tag{106}$$

となる。 $\varphi(t)$ ， $\theta$  はデータベクトルと推定されるパラメータベクトルであり，それぞれ  $\varphi^T(t) = [-\dot{P}_{ao}(t), V(t), V^2(t), \dot{V}(t), |\dot{V}(t)|\dot{V}(t), \ddot{V}(t), 1.0]$ ， $\theta^T = [a_1, k_1, k_2, r_1, r_2, b_2, P_{eea}]$

である。また，体積と流量の関係式  $F(t) = \dot{V}(t)$  を用ると， $\varphi(t)$  は， $\varphi^T(t) = [-\dot{P}_{ao}(t), V(t), V^2(t), F(t), |F(t)|F(t), \dot{F}(t), 1.0]$  となる。

$k$  ( $k = 1, 2, \dots, N$ ) をサンプル時刻， $N$  をデータ長とすると，観測出来るデータは気圧・流量・体積のサンプル値データ  $P_{ao}(k)$ ， $F(k)$ ， $V(k)$  である。データ収集のサンプリング周期が  $T$  である時，ある時刻  $t = kT$  において式 (106) 式の両辺を区間  $[(k - \ell)T, kT]$  にわたり積分演算を行う。相良らが提案した数値積分法を用いると，左辺の式は，

$$y(k) = \int_{(k-\ell)T}^{kT} P_{ao}(\tau) d\tau \doteq \sum_{j=0}^{\ell} g_j P_{ao}(k - j) \quad (107)$$

となる。ここで， $\ell$  は数値積分のウィンドウ幅を決める正の整数， $g_i$  ( $i = 1, 2, \dots, \ell$ ) は数値積分則により決まる係数である。台形則の場合，係数  $g_i$  は，

$$\begin{cases} g_0 = g_\ell = T/2 \\ g_i = T, \quad i = 1, 2, \dots, \ell - 1 \end{cases} \quad (108)$$

となる。同様にデータベクトル  $\varphi(t)$  の積分は，

$$\begin{aligned} \phi(k) &= \int_{(k-\ell)T}^{kT} \varphi(\tau) d\tau \\ &= \begin{bmatrix} -P_{ao}(k) + P_{ao}(k - \ell) \\ \sum_{j=0}^{\ell} g_j V(k - j) \\ \sum_{j=0}^{\ell} g_j V^2(k - j) \\ V(k) - V(k - \ell) \\ \sum_{j=0}^{\ell} g_j |F(k - j)| F(k - j) \\ F(k) - F(k - \ell) \\ \ell T \end{bmatrix} \end{aligned} \quad (109)$$

と計算できる。また，数値積分による近似誤差  $\Delta_E$  と  $\epsilon$  の積分をまとめると，

$$e(k) = \Delta_E + \int_{(k-\ell)T}^{kT} \epsilon(\tau) d\tau \quad (110)$$

となる。こうして (107) , (109) , (110) 式から呼吸システムの離散時間形式の同定モデルが

$$y(k) = \phi^T(k) \theta + e(k) \quad (111)$$

と求めることが出来る。

測定データを用いて，各時刻  $k = \ell + 1, \dots, N$  における  $y(k)$  と  $\phi(k)$  を計算し，ベクトル方程式にまとめると，

$$\mathbf{y} = \mathbf{\Phi}\theta + \mathbf{e} \quad (112)$$

となる。ここで  $\mathbf{y} = [y(N) \cdots y(\ell+1)]^T$ 、 $\mathbf{\Phi} = [\phi(N) \cdots \phi(\ell+1)]^T$ 、 $\mathbf{e} = [e(N) \cdots e(\ell+1)]^T$  である。

最小二乗法により，評価規範  $\mathbf{J} = \|\mathbf{y} - \mathbf{\Phi}\theta\|^2$  を最小にするパラメータ推定値は

$$\hat{\theta} = (\mathbf{\Phi}^T \mathbf{\Phi})^{-1} \mathbf{\Phi}^T \mathbf{y} \quad (113)$$

と計算できる。よって，任意の 1 ルールに関する後件部関数パラメータつまり肺エラストンス式の係数は，

$$\hat{f}_E(V) = \hat{k}_1 + \hat{k}_2 V \quad (114)$$

と推定される。

以上の計算を全ルールについて行い係数をもとめることで，関数型 SIRMs 推論法ファジィルールが完成する。

### 8.2.3 肺エラストンス推定

本節では作成したファジィルールを用いて肺エラストンス式を推定する。各ルール群の推論結果は重み付き重心法 (115)，(116) 式によって求められる。

$$\begin{aligned} & \text{Rule} - V_{out} \\ & h_j^{V_{out}} = A_j^{V_{out}}(V^0) \quad (j = small, medium, big) \\ & f_{Eout}^0 = \frac{\sum_{j=small}^{big} h_j^{V_{out}} f_{Eout(j)}(V^0)}{\sum_{j=small}^{big} h_j^{V_{out}}} \end{aligned} \quad (115)$$

$$\begin{aligned} & \text{Rule} - V_{in} \\ & h_j^{V_{in}} = A_j^{V_{in}}(V^0) \quad (j = small, medium, big) \\ & f_{Ein}^0 = \frac{\sum_{j=small}^{big} h_j^{V_{in}} f_{Ein(j)}(V^0)}{\sum_{j=small}^{big} h_j^{V_{in}}} \end{aligned} \quad (116)$$

各ルール群の推論結果が求められた後，全体の推論結果  $f_E^0$  は，

$$f_E^0 = \omega_{Vout} f_{Eout}^0 + \omega_{Vin} f_{Ein}^0 \quad (117)$$

で求められる。なお， $A$  は前件部変数  $V$  のファジィ集合， $h_j$  は  $j$  のルールの前件部の適合度， $\omega_i$  ( $i = Vin, Vout$ ) は各ルール群の全体の推論結果に対する重視度である。

最後に，全体の推論結果  $f_E^0$  を用いた

$$P_\ell = f_E^0 V \quad (118)$$

の関係式によって静的  $P$ - $V$  曲線を描くことができる。

### 8.3 実験結果及び考察

本章では，患者の実データを用いて関数型 SIRM<sub>s</sub> ファジィ推論法により静的  $P$ - $V$  曲線を推定した実験結果について説明する。

本実験は，MATLAB というソフトウェアを用いて実施する。MATLAB は，MathWorks 社が開発している数値解析ソフトウェアでありその中で使うプログラミング言語の名称でもある [18][19][20]。

#### 8.3.1 実験準備 (空気流量と体積の関係式から肺の体積 $V$ を求める)

肺エラストンスの推定を行なうために，患者の実データについてデータ整理を行なう必要がある。人間の肺体積  $V$  は通常ではマイナス値をとることはないが，患者の実データ  $V$  にはマイナス値のデータが含まれる場合がある。また，吸気時にもかかわらず肺体積  $V$  値が急激に減少する部分が含まれている患者データも存在する。これらは主に観測雑音等の影響であると考えられる。そもそも測定された肺体積値  $V$  は，肺内に測定機器を入れていないため信頼出来るデータとは考えがたい。そこで空気流量と体積の関係式  $F(t) = \dot{V}(t)$  を使用し，空気流量の測定値  $F(t)$  から

$$V(t) = \int F(t)dt \quad (119)$$

により推定実験に使用する肺体積  $V(t)$  を求める。なお，計算には数値積分法の台形則を使用した。

図 25，図 26 は，ある患者データを使用して肺の体積  $V$  の観測値と関係式から求めた値を比較した図である。呼吸 1 周期分のデータにおいて，観測値が吸気開始時付近と呼気終了時付近にマイナス値をとるのに対し，計算値はマイナスの値をとることはない。また，

計算値が吸気・呼気それぞれの観測値に近い曲線を描いている。以上のように，本実験では流量と体積の関係式から肺の体積値  $V$  を算出し，静的  $P$ - $V$  曲線の推定実験に使用する。




図 25 測定値と計算値の肺体積データ（吸気）比較図.




図 26 測定値と計算値の肺体積データ（呼気）比較図.

### 8.3.2 実験準備 ( $P_{ao}(t)$ から $P_{eea}$ の値を引く)

本手法では，1周期分の呼吸データをファジルール毎に分割してパラメータ推定が行なわれている。 $P_{eea}$  は肺胞の呼気終了気圧であるが，各ファジルールのパラメータ推定の際に異なる値が推定されてしまう。よって推定実験を行なう前に，呼吸データから  $P_{eea}$  を仮定し， $P_{ao}(t) - P_{eea}$  の値を求める。実験では，求められた値を  $P_{ao}$  として使用し，呼吸システムモデルから  $P_{eea}$  の項を削除しておく。

### 8.3.3 実験結果

本節では，関数型 SIRM<sub>s</sub> ファジ推論法を用いて患者の実データから推定した静的  $P$ - $V$  曲線実験結果を例示する。なお，ファジ変数 *small*，*medium*，*big* の範囲は手動で設定した。また重視度  $\omega_i$  ( $i = V_{in}, V_{out}$ ) はそれぞれ 0.5 とした。

図 27 と図 29 は，推定実験において手動設定したファジ変数のメンバーシップ関数である。図 28 と図 30 の点線は推定された静的  $P$ - $V$  曲線であり，点 は検証用の静的  $P$ - $V$  データである。おおむね検証用データに近い値をとっているが，本結果の推定精度では研究の最終目標である人工呼吸の換気条件設定が難しい。推定精度が芳しくない原因としては，肺エラストンス式の表現力が足りていない事，ファジ変数の範囲設定や重視度値の設定が最適な値ではない事が考えられる。




図 27 推定事例 1：推定に用いたファジ変数.




図 28 推定事例 1：推定した静的  $P$ - $V$  曲線と検証データ.




図 29 推定事例 2：推定に用いたファジ変数.




図 30 推定事例 2 : 推定した静的  $P$ - $V$  曲線と検証データ.

## 8.4 本章のまとめ

本章では、関数型 SIRM<sub>s</sub> ファジィ推論法を用いて肺エラストンスを推定し、肺特性を表わす静的  $P$ - $V$  曲線を推定する手法を説明した。推定結果としては、おおむね検証  $P$ - $V$  データに近い静的  $P$ - $V$  曲線が得られたが、人工呼吸器の設定を行なうためには更に推定精度を向上させる必要がある。次章以降では、静的  $P$ - $V$  曲線の推定精度を向上させるためのアルゴリズム改善点を述べる。



## 9 ファジィルール後件部関数表現形式が推定精度へ与える影響について

### 9.1 実験目的とアルゴリズム

前章で説明した関数型 SIRMs ファジィ推論法を用いた肺エラストランス推定手法は、人工呼吸の換気条件設定を行なえる推定精度を得られなかった。推定精度が悪い原因については様々考察されるが、ここではファジィルール後件部における関数表現が肺エラストランス推定精度へ与える影響について考察した。

前述のように関数近似において真の関数（ここでは患者の肺エラストランス）を表現する近似関数が不十分な柔軟性であることをアンダーフィッティングという。アンダーフィッティングにおいては関数の表現力が足りないことから真の関数とは大きな誤差が生じる。我々は、関数型 SIRMs ファジィ推論法を用いた肺エラストランス推定精度が不十分であった原因として、ファジィルール後件部における関数表現能力が足りていなかったのではないかと推察した。そこで、ファジィルール後件部の関数表現形式を変化させて肺エラストランス推定を行ない、ファジィルール後件部における関数表現能力が十分であるか否かを実験した。

今回の実験に用いたファジィルールは式 (120) から式 (122) である。ファジィロジックにより肺エラストランス推定を行なう理由として、肺エラストランスを低次元表現で表わし観測雑音の影響を極力受けないようにするという目的がある。よって今回実験を行なった後件部関数表現は、肺エラストランス多項式表現型次数設定の目安である 3 次多項式より高い次数を取らないよう設定した。また、後件部 1 次関数・2 次関数混合表現型において *medium* 部の後件部を 1 次関数表現、*small* 部と *big* 部の後件部を 2 次関数表現とした理由については、一般的な静的  $P$ - $V$  曲線の特徴点「中間領域で線形に近く、気圧の低い領域と高い領域では平坦になる傾向がある」に基づいている。これら 3 種類のファジィルールを用いて関数型 SIRMs ファジィ推論法で肺エラストランス推定を行ない、各推定精度を比較する。

後件部 1 次関数表現型

$$\begin{aligned}
 & \text{Rule} - V_{out} \\
 & \text{if } V_{out} = \text{small}_{out} \\
 & \quad \text{then } f_{Eout}(\text{small}) = k_{1out}(\text{small}) + k_{2out}(\text{small})V \\
 & \text{if } V_{out} = \text{medium}_{out} \\
 & \quad \text{then } f_{Eout}(\text{medium}) = k_{1out}(\text{medium}) + k_{2out}(\text{medium})V \\
 & \text{if } V_{out} = \text{big}_{out} \\
 & \quad \text{then } f_{Eout}(\text{big}) = k_{1out}(\text{big}) + k_{2out}(\text{big})V
 \end{aligned} \tag{120}$$

$$\begin{aligned}
 & \text{Rule} - V_{in} \\
 & \text{if } V_{in} = \text{small}_{in} \\
 & \quad \text{then } f_{Ein}(\text{small}) = k_{1in}(\text{small}) + k_{2in}(\text{small})V \\
 & \text{if } V_{in} = \text{medium}_{in} \\
 & \quad \text{then } f_{Ein}(\text{medium}) = k_{1in}(\text{medium}) + k_{2in}(\text{medium})V \\
 & \text{if } V_{in} = \text{big}_{in} \\
 & \quad \text{then } f_{Ein}(\text{big}) = k_{1in}(\text{big}) + k_{2in}(\text{big})V
 \end{aligned}$$

後件部 2 次関数表現型

$$\begin{aligned}
 & \text{Rule} - V_{out} \\
 & \text{if } V_{out} = \text{small}_{out} \\
 & \quad \text{then } f_{Eout}(\text{small}) = k_{1out}(\text{small}) + k_{2out}(\text{small})V + k_{3out}(\text{small})V^2 \\
 & \text{if } V_{out} = \text{medium}_{out} \\
 & \quad \text{then } f_{Eout}(\text{medium}) = k_{1out}(\text{medium}) + k_{2out}(\text{medium})V + k_{3out}(\text{medium})V^2 \\
 & \text{if } V_{out} = \text{big}_{out} \\
 & \quad \text{then } f_{Eout}(\text{big}) = k_{1out}(\text{big}) + k_{2out}(\text{big})V + k_{3out}(\text{big})V^2
 \end{aligned} \tag{121}$$

$$\begin{aligned}
 & \text{Rule} - V_{in} \\
 & \text{if } V_{in} = \text{small}_{in} \\
 & \quad \text{then } f_{Ein}(\text{small}) = k_{1in}(\text{small}) + k_{2in}(\text{small})V + k_{3in}(\text{small})V^2 \\
 & \text{if } V_{in} = \text{medium}_{in} \\
 & \quad \text{then } f_{Ein}(\text{medium}) = k_{1in}(\text{medium}) + k_{2in}(\text{medium})V + k_{3in}(\text{medium})V^2 \\
 & \text{if } V_{in} = \text{big}_{in} \\
 & \quad \text{then } f_{Ein}(\text{big}) = k_{1in}(\text{big}) + k_{2in}(\text{big})V + k_{3in}(\text{big})V^2
 \end{aligned}$$

#### 後件部 1 次関数・2 次関数混合表現型

$$\begin{aligned}
 & \text{Rule} - V_{out} \\
 & \text{if } V_{out} = \text{small}_{out} \\
 & \quad \text{then } f_{Eout}(\text{small}) = k_{1out}(\text{small}) + k_{2out}(\text{small})V + k_{3out}(\text{small})V^2 \\
 & \text{if } V_{out} = \text{medium}_{out} \\
 & \quad \text{then } f_{Eout}(\text{medium}) = k_{1out}(\text{medium}) + k_{2out}(\text{medium})V \\
 & \text{if } V_{out} = \text{big}_{out} \\
 & \quad \text{then } f_{Eout}(\text{big}) = k_{1out}(\text{big}) + k_{2out}(\text{big})V + k_{3out}(\text{big})V^2
 \end{aligned} \tag{122}$$

$$\begin{aligned}
 & \text{Rule} - V_{in} \\
 & \text{if } V_{in} = \text{small}_{in} \\
 & \quad \text{then } f_{Ein}(\text{small}) = k_{1in}(\text{small}) + k_{2in}(\text{small})V + k_{3in}(\text{small})V^2 \\
 & \text{if } V_{in} = \text{medium}_{in} \\
 & \quad \text{then } f_{Ein}(\text{medium}) = k_{1in}(\text{medium}) + k_{2in}(\text{medium})V \\
 & \text{if } V_{in} = \text{big}_{in} \\
 & \quad \text{then } f_{Ein}(\text{big}) = k_{1in}(\text{big}) + k_{2in}(\text{big})V + k_{3in}(\text{big})V^2
 \end{aligned}$$

## 9.2 実験結果及び考察

実際の患者臨床データを用いて、ファジィルール後件部関数の表現型を変化させた場合における推定静的  $P$ - $V$  曲線の推定精度を比較する実験を行なった。なお、本実験ではファジィ変数  $\text{small}$ ,  $\text{medium}$ ,  $\text{big}$  の範囲は患者データ毎に手動で設定し、推定精度比較のため各表現型とも同じファジィ変数を使用した。また、呼気と吸気のルール群推論結果はどちらも同じくらい全体の肺エラストンス推定に重要であると考え、ルール群重視度  $\omega_i (i = V_{in}, V_{out})$  はそれぞれ 0.5 と設定した。推定実験は、後件部 1 次関数表現型、後件部 2 次関数表現型、後件部 1 次関数・2 次関数混合表現型について行なった。

図 31 と図 33 は、推定に使用したファジィ変数のメンバーシップ関数である。図 32 と図 34 は、後件部関数の各表現形式で推定した静的  $P$ - $V$  曲線比較図であり、と の点は検証用の静的  $P$ - $V$  データである。表 3 では、各表現形式における推定静的  $P$ - $V$  曲線と検証データの圧力誤差の二乗和平均値を表わした。数式は以下のように表わされる。

$$E = \frac{1}{N} \sum_{i=1}^N (\hat{P}_t(i) - P_{occ}(i))^2 \tag{123}$$

ここで、 $\hat{P}_\ell$  は推定した肺内圧力、 $P_{occ}$  は検証データ、 $N$  は検証データの数を表す。本研究においては、この値を推定精度として扱う。表 3 から、患者データ毎に推定精度の良い表現形式が異なることがわかる。また、後件部 2 次関数表現型による肺エラスタンス推定について、本実験データにおいては推定精度が後件部 1 次関数表現型による推定と比べ良い値を取る事はなかった。更に他データで検証を重ねる必要はあるが、本実験データに関しては後件部関数の肺エラスタンス表現能力は 1 次関数表現型でも十分であると考えられる。

表 3 各関数表現型による検証データとの圧力二乗和誤差値

	1 次関数型	2 次関数型	1 次関数・2 次関数混合型
実験事例 1	0.5658 [cmH <sub>2</sub> O]	0.9095 [cmH <sub>2</sub> O]	0.4894 [cmH <sub>2</sub> O]
実験事例 2	0.7133 [cmH <sub>2</sub> O]	5.3168 [cmH <sub>2</sub> O]	1.8456 [cmH <sub>2</sub> O]




図 31 推定事例 1：推定に用いたファジィ変数.




図 32 推定事例 1 : 各後件部表現型で推定した静的  $P$ - $V$  曲線と検証データ.




図 33 推定事例 2 : 推定に用いたファジ変数.




図 34 推定事例 2：各後件部表現型で推定した静的  $P$ - $V$  曲線と検証データ。

### 9.3 本章のまとめ

本章では，関数型 SIRM<sub>s</sub> ファジィ推論法による肺エラストンス推定においてファジィルールの後件部関数表現能力が十分であるか否かを検証した。実験の結果，今回使用した患者データに関しては後件部 1 次関数表現型でも肺エラストンス表現能力が十分である事が分かった。しかしながら，後件部関数表現の変化だけでは人工呼吸の換気条件設定に十分な推定精度を得られなかった。次章では，肺エラストンス推論法を改良し推定精度を向上させるアルゴリズムを説明する。

## 10 区間データ結合を用いたファジ推論法

### 10.1 問題点とアルゴリズム

前章まで関数型 SIRMs 推論法を用いて患者の肺エラストンスを推定してきたが、ファジルールの後件部関数表現を変化させても推定精度は劇的には改善されなかった。前手法において推定精度が悪くなった原因として考えられるのは、関数型 SIRMs 推論法アルゴリズムで用いられる重視度の存在である。関らによって開発された関数型 SIRMs 推論法は、ファジルールの入力項目が多い場合に用いられる手法とされている。本研究では、当該手法を呼気における体積  $V_{out}$  と吸気における体積  $V_{in}$  の2つの入力項目を結合するために用い、結合に用いられる各入力項目の重視度については手動で各入力項目とも0.5と定めた。これは複雑な構造である呼吸システムについて、呼気と吸気がどの程度重要であるか考察出来ないためにそれぞれ同程度重要であるとした妥協の設定である。もしかしたら、線形結合計算では結合出来ないかもしれないし、肺体積の大きさによって重視度が変化するかもしれない。我々は、患者の観測データからも予測出来ない呼気と吸気の重視度の存在が計算誤差を生みだし、推定精度が悪くなる原因に繋がっていると考察した。

本章では上記の問題点を改善すべく、区間データ結合を用いて呼気と吸気に分割されていたファジルールを一つにし、重視度計算を行わずに肺エラストンスを推定出来る手法を提案する。アルゴリズムは以下の通りである。

#### [Step1] 呼気と吸気の同定モデル結合

関数型 SIRMs 推論法による肺エラストンス推定アルゴリズムでも用いられていた連続時間モデルの同定に有効とされる数値積分法を使用し、呼気データと吸気データの同定モデルを導出する。同定モデル導出に使用される呼吸データは、ファジ変数 *small*, *medium*, *big* の設定区間に準ずる呼吸データである。ここではファジ変数 *small* についての同定モデルを例に Step1 のアルゴリズムを紹介する。まず呼気についての同定モデルは以下の通りである。

$$y_{smallout}(k) = \phi_{smallout}^T(k)\theta_{smallout} + e(k) \quad (124)$$

$$y_{smallout}(k) = \int_{(k-\ell)T}^{KT} P_{ao_{smallout}}(\tau)d\tau \doteq \sum_{j=0}^{\ell} g_j P_{ao_{smallout}}(k-j) \quad (125)$$

$$\begin{aligned} \phi_{smallout}(k) &= \int_{(k-\ell)T}^{KT} \varphi_{smallout}(\tau) d\tau \\ &= \begin{bmatrix} -P_{ao_{smallout}}(k) + P_{ao_{smallout}}(k-\ell) \\ \sum_{j=0}^{\ell} g_j V_{smallout}(k-j) \\ \sum_{j=0}^{\ell} g_j V_{smallout}^2(k-j) \\ V_{smallout}(k) - V_{smallout}(k-\ell) \\ \sum_{j=0}^{\ell} g_j |F_{smallout}(k-j)| F_{smallout}(k-j) \\ F_{smallout}(k) - F_{smallout}(k-\ell) \end{bmatrix} \end{aligned} \quad (126)$$

ここで、 $\ell$  は数値積分のウィンドウ幅を決める正の整数、 $g_i (i = 1, 2, \dots, \ell)$  は数値積分則により決まる係数である。

ファジィ変数  $small_{out}$  の設定区間に準ずる呼吸データを用いて各時刻  $k = \ell + 1, \dots, N$  における  $y_{smallout}(k)$  と  $\phi_{smallout}(k)$  を計算し、ベクトル方程式にまとめると、

$$\mathbf{y}_{smallout} = \mathbf{\Phi}_{smallout} \theta_{smallout} + \mathbf{e} \quad (127)$$

となる。ここで、 $\mathbf{y}_{smallout} = [y_{smallout}(N) \cdots y_{smallout}(\ell + 1)]^T$ 、 $\mathbf{\Phi}_{smallout} = [\phi_{smallout}(N) \cdots \phi_{smallout}(\ell + 1)]^T$  である。

同様にファジィ変数  $small_{in}$  の設定区間に準ずる呼吸データを用いて各時刻  $k = \ell + 1, \dots, N$  における  $y_{smallin}(k)$  と  $\phi_{smallin}(k)$  を計算し、ベクトル方程式にまとめると、

$$\mathbf{y}_{smallin} = \mathbf{\Phi}_{smallin} \theta_{smallin} + \mathbf{e} \quad (128)$$

となる。ここで  $\mathbf{y}_{smallin} = [y_{smallin}(N) \cdots y_{smallin}(\ell + 1)]^T$ 、 $\mathbf{\Phi}_{smallin} = [\phi_{smallin}(N) \cdots \phi_{smallin}(\ell + 1)]^T$  である。

式 (127)、(128) をそれぞれ最小二乗法を用いてパラメータ推定を行なうと、 $\theta_{smallout}$  と  $\theta_{smallin}$  が推定され、呼気と吸気ファジィルールを結合するために重視度計算を用いなければなくなる。そこで、最小二乗法を適用する前に呼気と吸気の同定モデルを一つに結合する。

$$\mathbf{y}_{small} = [\mathbf{y}_{smallin} \ \mathbf{y}_{smallout}]^T \quad (129)$$

$$\mathbf{\Phi}_{small} = [\mathbf{\Phi}_{smallin} \ \mathbf{\Phi}_{smallout}]^T \quad (130)$$



呼気と吸気の同定モデル結合について，各データに数値積分法を既に適用していることから結合後も連続時間モデルとなることが考えられる。同定モデルのベクトル方程式は，

$$\mathbf{y}_{small} = \Phi_{small}\theta_{small} + \mathbf{e} \quad (131)$$

となり，式 (131) を最小二乗法に適用することで，ファジィ変数 *small* 区間の呼気と吸気に関するパラメータ  $\theta_{small}$  が推定出来る。

上記のアルゴリズムを，ファジィ変数 *medium* と *big* に準ずる呼吸データに適用することでパラメータ  $\theta_{medium}$  と  $\theta_{big}$  が推定される。

#### [Step2] 肺エラストンス推定

各ファジィ変数 *small* , *medium* , *big* の呼気と吸気に関するパラメータ  $\theta_{small}$  ,  $\theta_{medium}$  ,  $\theta_{big}$  が推定されたことで，ファジィルールは以下のような表現となる。

$$\begin{aligned} \text{if } V = \text{small}, & \quad \text{then } f_{E(\text{small})} = k_{1(\text{small})} + k_{2(\text{small})}V \\ \text{if } V = \text{medium}, & \quad \text{then } f_{E(\text{medium})} = k_{1(\text{medium})} + k_{2(\text{medium})}V \\ \text{if } V = \text{big}, & \quad \text{then } f_{E(\text{big})} = k_{1(\text{big})} + k_{2(\text{big})}V \end{aligned} \quad (132)$$

上記式 (132) のように，吸気の方ジィルールと呼気の方ジィルールが結合されたファジィルールとなることから，肺エラストンス推定に重視度を用いる必要がなくなることがわかる。

式 (132) を用いて，重み付き重心法により肺エラストンスは，

$$\begin{aligned} h_j^V &= A_j^V(V^0), \quad (j = \text{small}, \text{medium}, \text{big}), \\ f_E^0 &= \frac{\sum_{j=\text{small}}^{\text{big}} h_j^V f_{E(j)}(V^0)}{\sum_{j=\text{small}}^{\text{big}} h_j^V}. \end{aligned} \quad (133)$$

と計算できる。なお， $A$  は前件部変数  $V$  のファジィ集合， $h_j$  は  $j$  のルールの前件部の適合度である。

図 35 と図 36 は，肺エラストンスの関数型 SIRM<sub>s</sub> 推論法と区間データ結合による推論法の手順である。図より区間データ結合による推論法は，肺エラストンス推定時の計算量が関数型 SIRM<sub>s</sub> 推論法と比べ少なくなることがわかる。

以上のように，ファジィ変数区間における数値積分法を適用した呼気と吸気のデータ結合をおこなう事で，設定が困難な重視度の問題を解決することが出来る。

## 関数型 SIRM<sub>s</sub> ファジィ推論法

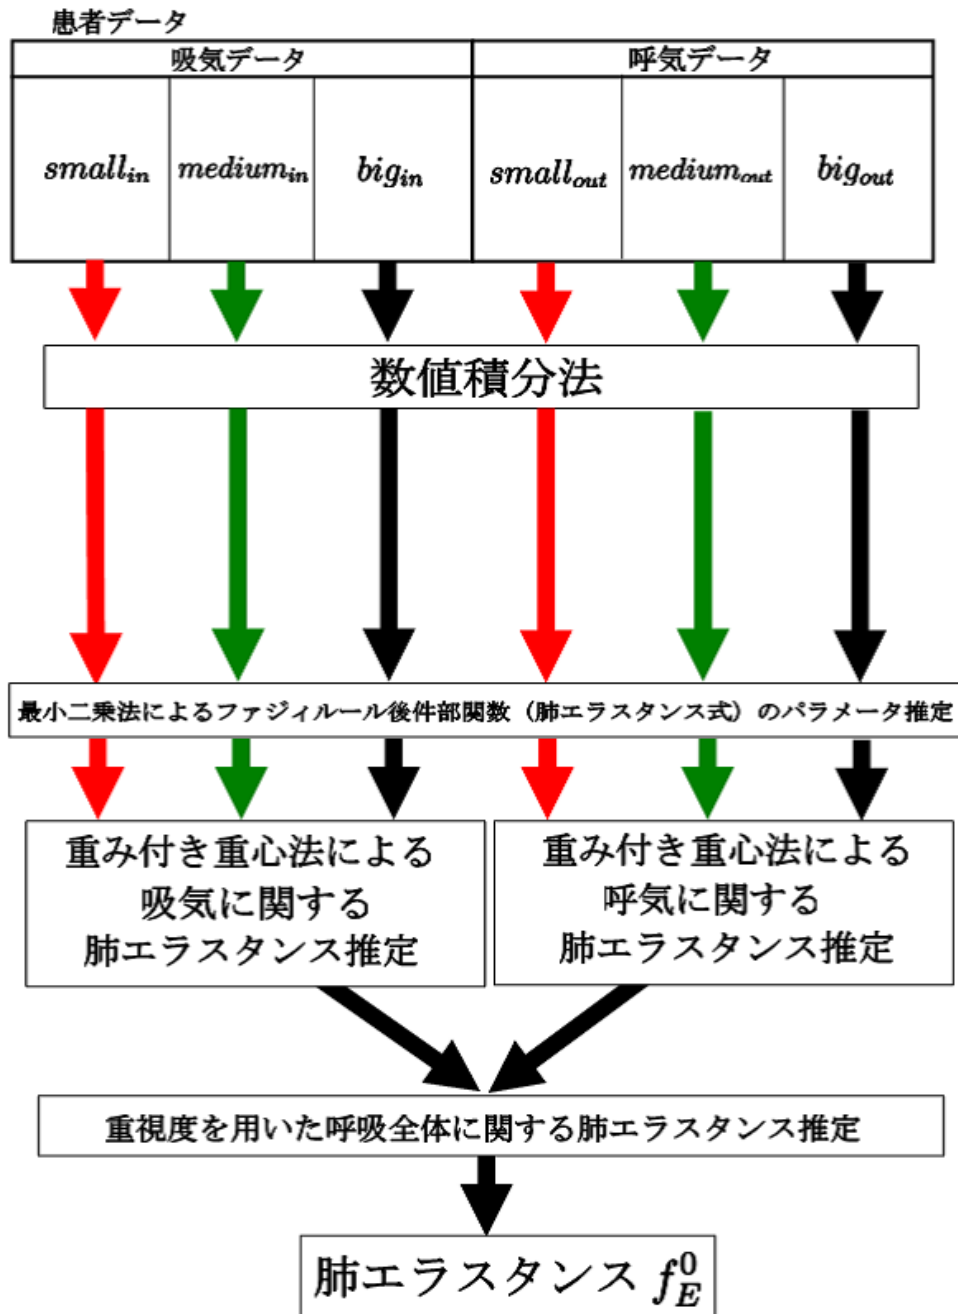


図 35 関数型 SIRM<sub>s</sub> ファジィ推論法の肺エラストランス推定手順図.

## 区間データ結合によるファジィ推論法

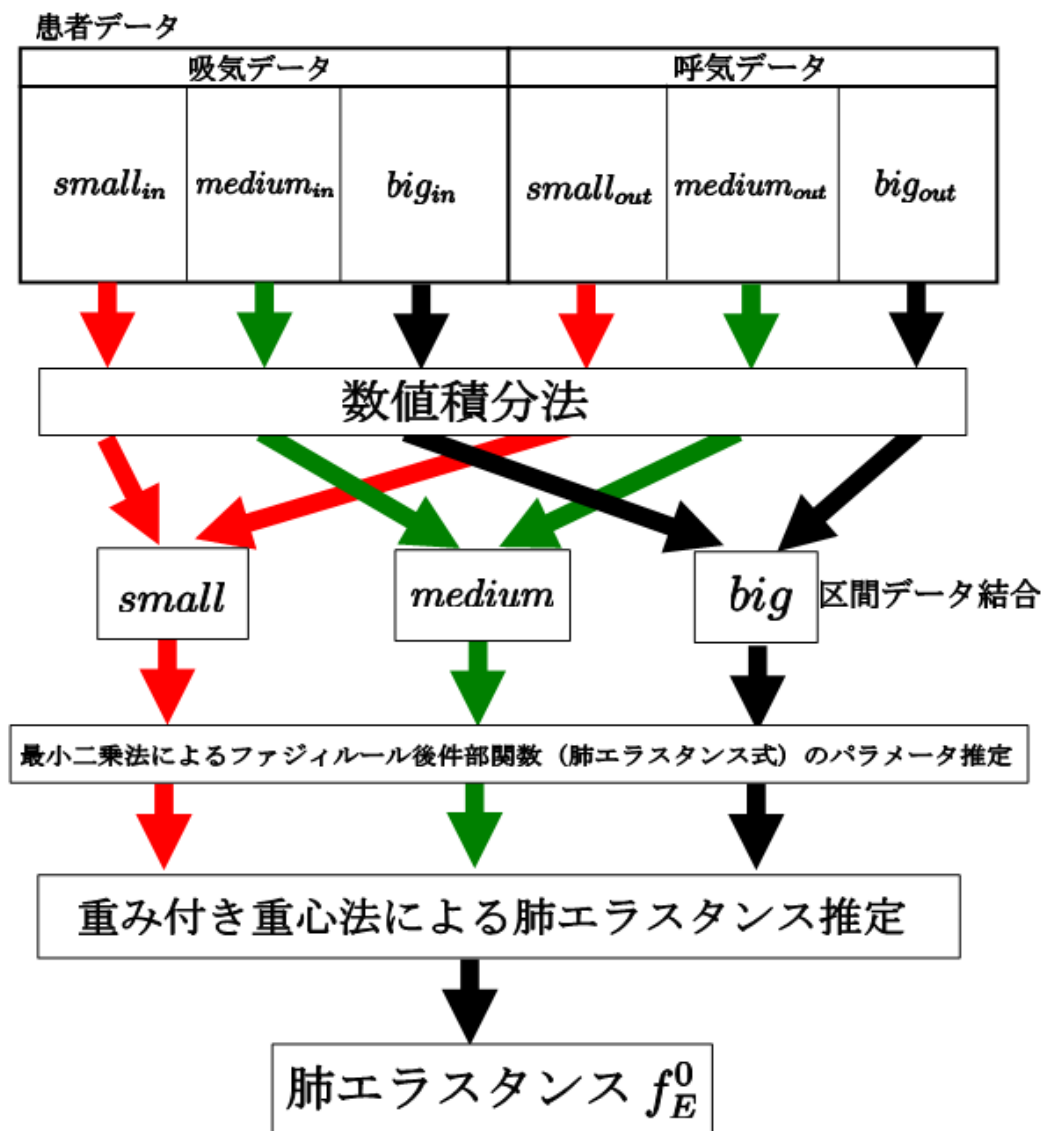


図 36 区間データ結合を用いたファジィ推論法の肺エラストンス推定手順図。

表 4 各手法による推定静的  $P$ - $V$  曲線と検証データの圧力二乗和誤差値表.

	関数型 SIRMs ファジィ推論法	区間データ結合を用いたファジィ推論法
CASE1	0.5658 [cmH <sub>2</sub> O]	0.3525 [cmH <sub>2</sub> O]
CASE2	5.4845 [cmH <sub>2</sub> O]	1.2985 [cmH <sub>2</sub> O]

## 10.2 実験結果及び考察

本節では、患者データを用いて静的  $P$ - $V$  曲線を推定し、関数型 SIRMs ファジィ推論法と区間データ結合を用いたファジィ推論法の推定精度を比較した。図 37 と図 39 は、それぞれ患者データ CASE1 と CASE2 の静的  $P$ - $V$  曲線を推定するために用いたファジィ変数である。比較のために、関数型 SIRMs ファジィ推論法と区間データ結合を用いたファジィ推論法どちらの手法にも同じファジィ変数を用いた。図 38 と図 40 は、各手法を適用し推定された静的  $P$ - $V$  曲線と検証  $P$ - $V$  データである。表 4 は、各手法の推定静的  $P$ - $V$  曲線と検証  $P$ - $V$  データの圧力二乗和誤差値表である。図や表から、区間データ結合を用いたファジィ推論法の方が推定精度が良いことがわかる。これは、重視度を用いた呼気ファジィルールと吸気ファジィルール結合による計算誤差の影響が少なくなったためであると推測される。以下の章で紹介する手法では、推定精度の良い区間データ結合を用いたファジィ推論法を用いることとする。

## 10.3 本章のまとめ

本章では、区間データ結合を用いたファジィ推論法を提案し、関数型 SIRMs ファジィ推論法内の重視度を用いた肺エラスタンス計算による計算誤差の影響を取り除いた。実験の結果、より検証  $P$ - $V$  データに近い静的  $P$ - $V$  曲線を推定することが出来、推定精度が向上した。今後の問題点としては手動で設定を行なっているファジィ変数の最適化である。次章では、アリの採餌行動特性を取り入れたアントコロニー最適化法により最適なファジィ変数を得る手法を提案する。




図 37 患者データ CASE1：推定に用いたファジィ変数のメンバーシップ関数.




図 38 患者データ CASE1：推定された静的  $P$ - $V$  曲線と検証データ ( 、 ) .




図 39 患者データ CASE2：推定に用いたファジィ変数のメンバーシップ関数.




図 40 患者データ CASE2：推定された静的  $P$ - $V$  曲線と検証データ ( 、 ) .

## 11 ファジィ変数の決定におけるアントコロニー最適化法

前章において呼気と吸気の区間データ結合によるファジィ推論法により静的  $P$ - $V$  曲線の推定精度は改善した。一方で、ファジィ推定に必要なファジィ変数の範囲設定については手動で行なっていた。しかし、一分一秒を争う医療現場においてはファジィ変数の範囲を悠長に設定している時間はない。よって、ファジィ変数の範囲を自動で最適化設定するアルゴリズムを導入しなければならない。

本研究では、多様性を維持しながら最適化を行なうアントコロニー最適化法によりファジィ変数の最適化を行なった。以下では、最初に生物の群知能やアントコロニー最適化法アルゴリズムについて述べ、本研究で行なったファジィ変数を決定するアントコロニー最適化法アルゴリズムについて説明する。

### 11.1 生物と群知能 - 超個体としてのアリ

この地球上には様々な生物が存在し、それぞれが自分のおかれる生活環境において生命を営み、子孫を残すために必死に生活をしている。そこでの生活環境はまさに生物学的複雑系とよぶもので、複雑な経路で物質やエネルギー情報等がやりとりされ、生物は互いに相互作用しあいながらそれぞれのニッチを占めている。これら自然の世界は弱肉強食であり、細胞一つからなる生物のレベルから複雑な器官をもつ多細胞生物のレベルまで、自己の生命を守るための巧妙なメカニズムに従って、細胞内の物質の流れから、器官・組織間の相互作用、そして個体レベルの行動まで制御している。

これらの生物をシステム論的にとらえるとき、その特徴は以下のように考えることが出来る。一般に生物のある組織を構成する各要素は、互いに狭い範囲で相互作用しながら活動を維持しており、その相互作用に基づいて自分自身の状態を変化させる。各要素は、自分自身が属する組織全体がどんな働きをしているのか、そしてどんな状態にあるかも認識出来るはずがないのに、各構成要素が自律的に変化した結果、組織全体にとって都合の良い行動をとっているように合目的な変化が実現されている。

言い換えると、ある生命システムを構成する各要素は局所的な相互作用のみによって得られる情報から自己の状態を変化させ、しかもそれがあたかもシステム全体として最適な状態への変化を導いているということであり、これらの性質は自律適応型のシステムと呼ぶことができる [21][22]。

このような自律適応型システムの特徴は、前もってその変化を予想することができない

ような複雑，かつ動的な環境に対する人工システムを設計するときの良い指針として，近年活発に研究されている。それらの研究の中でも，昆虫や魚類などのあまり高度なレベルの知能をもっていない個体が群をなすことにより，個々の行動パターンからは予測できない複雑な群レベルの行動をみせるという群知能 (swarm intelligence) とよばれる分野が注目されている。群知能は，典型的には社会性昆虫とよばれるアリや蜂，魚や鳥の群などに見ることが出来る。そこでは，群を構成する個々はそれほど複雑な行動はみせないが，群になることによってあたかも高度な知能をもった一つの生命体のように振舞う。そのような個体群は超個体とよばれる。中でもアリは生物学的にその生態が明らかになるにつれ，驚くべきほど巧妙な相互作用のメカニズムに基づいて，群全体の行動が維持されていることがわかってきた。その中では，女王アリや働きアリがそれぞれの役割を分担し，局所的・分散的な情報に基づいて相互作用し，自分のなすべきことを自律的に決定して行動しているにも関わらず，群全体としてはまるであたかも最適な行動がわかっているように振舞うのである。その行動調整のメカニズムは，コロニーを維持するためのさまざまな仕事に対する労働力分担に始まり，外敵の侵入や巣の崩落といった突発的な環境変化に対しても速やかに対処する。

このような超個体における群知能の特徴は，われわれがいままで得意としてきた中央集権的なシステム設計にはない柔軟性と適応性をもっている。一般に中央集権的なシステムでは，あらかじめシステムが取り扱う対象の状態変化を想定し，それに対して適切な制御出力を事前に設計しておくことにより最適な制御を行う。たとえば，電力の発電・送電システムや上下水道システム，物流などがそのようなシステムの例として挙げられる。このようなシステムは，対象の状態変化が予測の範囲内で収まるならば非常に上手くいく。しかし，そのようなシステムではひとたび予測外の事態が起こると，容易にシステム全体がダウンしてしまう。近年の人工知能やロボティクスの発達にともなって，システム設計の興味は事前にわかりきった対象だけではなく，例えば生活環境や自然環境であったり，動



図 41 生物と群知能.



的に拡大していくインターネットなどの、より未知、複雑、かつ動的な環境においていかに適切に振舞うかといったことに移ってきている。そのような環境の中で柔軟に振舞うことが出来るシステムをつくるために生物の群知能のアイデアが注目されている。

以降では、生物のアリに焦点を絞り、高度に進化したアリの生物学的なメカニズム、驚くべき群知能の一例を説明し、アリの相互作用を模倣したマルチエージェントシステムの説明を行なう。そして、アリの最適化行動を模倣した人工的な問題解決アルゴリズムであるアントコロニー最適化法 (ant colony optimization, 略して ACO) メタヒューリスティクスの概念を導入し、ACO メタヒューリスティクスの概念に基づいた組合せ最適化問題の解法について述べる。そして、肺エラストランス推定におけるファジ変数の決定について、群知能を用いることにより問題解決を図るアルゴリズムの設計について述べる。

## 11.2 アリの生活サイクル

アリのコロニーの歴史は、十分成熟したコロニーで生まれた雄のアリと、同じく別のコロニーの新生女王アリが結婚飛行に飛び立つことから始まる。結婚飛行に際し、それぞれ別のコロニーで生まれた雄が先行し、女王アリが後に続く。そして雄雌のアリ達は見晴らしの良い丘に集まり、交尾する。その後女王アリは、複数の雄との交尾によって受精のうに精子を蓄え、地上に降り立って巣作りを始める。ある程度準備が整った段階で女王アリは産卵し、女王自ら狩りに出かけて昆虫などの餌を確保したり、腹部にため込んだ脂肪などを栄養素に分解して餌にしたりしながら、最初の幼虫を育て始める。

こうして、初期の幼虫から女王自らの世話によって最初の働きアリが育つわけであるが、女王は初期の働きアリが成長するまでの投資と、コロニー立ち上げまでに必要な労力のバランスを保ちながら、巣を運営していく必要がある。初期の働きアリへの投資を出来るだけ抑え、かつより多くの働きアリを確保しようとして、女王は10個体前後の初期働きアリを育てることになる。

最初の働きアリが幼虫の世話や餌集め、巣作りをするようになると、女王はコロニーの成員を増やすために産卵に専念する。そして、コロニーが成熟してくるにつれて、コロニーの資源の一部を新たにコロニーから旅立っていく雄や新生女王アリに振り分けるようになる。やがてコロニーは円熟し、成長率も鈍くなっていく。コロニーの寿命は種によって大きく違うが、おおむね10年前後の種が多いことがわかっている。

コロニーが維持される期間、働きアリたちは生まれては死んでいき、コロニーは前にいた成員とはまったく別の成員に受け継がれながら運営されていく。コロニーが老練になっていくにつれ、コロニー全体のアリたちの行動はより慎重になっていく。そして、短いス

パンで巣を引っ越しながら、社会生活をおくっているのである。

### 11.3 アリの群行動

ここでは、アリが群の中でどのように役割分担し、群の維持のために行動するのかを説明する。アリの適応的な役割分担のメカニズムに関する研究例として、収穫アリに関する実験がある。

コロニーは共同生活体であり、コロニー全体を維持するために食料を集めて配分し、巣を拡大し、卵や幼虫、さなぎを適切に育てる必要がある。また、時には外敵や自然の脅威にさらされ、そのつどコロニー維持のために協力して対処しなければならない。もし、幸運にも大量の食料を発見した場合には、それらを集めるために大量の働きアリが必要であり、また、巣が壊れた場合には、早急に修理する必要がある。それらのことがあるときは同時に起こる可能性もあり、コロニー維持のために重要なタスクから優先的に、しかも限られた労働資源の中で柔軟に対処していく必要がある。つまり、群を維持していくためにコロニーは、時々刻々と変化する複雑で動的な環境に対処する必要がある。コロニーを効率良く運営するためには、刻々と変化しながら巣の各地で必要とされる労働力に対して、最適な資源配分を行わなければならない。しかし、各アリはたかだか自分の周囲のわずかな情報のみしか得ることが出来ず、コロニー全体がおかれる状況を適切に判断して対処することは容易ではない。どのようにしてアリのコロニーで全体の振舞いの調整が行われているのか。曲がりくねった暗い巣の中では、コロニー全体の状況を表す情報の存在や伝達は容易ではなく、それらの情報は素の内外に分散的に存在すると考える。そのような状況で、全体の情報を把握出来るような統治者が存在するとは考えにくい。つまり、各個々が自分の感知出来る分散的な情報から判断し、他個体との相互作用を通じて、いま自分が何をすべきかを判断することによって、マクロレベルでとらえたとき、あたかもコロニー全体にとって最適と思われるような行動をとっているのである。そのメカニズムの中では、女王アリでさえ、単に卵を産み、餌を与えられ、ワーカーに世話をされるだけの存在である。

ではアリたちはどのように情報を判断し、また周りのアリたちとコミュニケーションをとりながら行動を決定しているのだろう。収穫アリを含む多くの種類のアリは視力が弱く、近くのほとんどを触覚からの刺激に頼っている。したがって、仲間どうしのコミュニケーションは視覚的なものではなく、触覚から感じられる科学的な信号を用いていることが知られている。この信号は一般にフェロモン (pheromone) とよばれ、アリや蜂などの社会性昆虫はこのフェロモンと呼ばれる臭いをやりとりすることによって、言葉の代わりに

コミュニケーションをとっている。アリのコロニーにおけるフェロモンによるコミュニケーションには具体的にどのようなものがあるかというと、まず同じコロニーに属するアリたちが、自分たちが同じ家族であることを示す重要なフェロモンとして、女王フェロモンがある。このフェロモンは女王アリから発せられ、コロニーのたくさんの働きアリたちが接触することで、コロニーのアリ全体に行き渡る。また、外敵に襲われたときに周囲の仲間やコロニーの状態を警戒状態にする働きのある警戒フェロモンや、さなぎを認識するためのさなぎフェロモンなど、アリのコロニーでは数十種類のフェロモンを用いて非常に多くの成員からなる群をコントロールしている。つまり、アリのコロニーでは、各個体が自分の直面する状況に合わせて分散的にフェロモンを放出する。そして、そのフェロモンが科学的な特性やアリどうしの接触などでコロニーを取り巻く環境中に時間的・空間的に分散していき、複数の個体がだすフェロモンが相互作用することで分散的な情報が統合される。

各アリその統合情報としてのフェロモンに反応することで、各個体があたかも全体の情報を知っていて、コロニーにとって最適な行動をとっているかのようにコロニーを運営することが可能であると考えられるのである。

#### 11.4 道しるべフェロモンに基づくアリの食料収集

食料収集は、働きアリの仕事でも最も重要な仕事である。したがって、食料の探索や運搬などに必要な労働力は働きアリが携わる仕事の中で一番大きく、そのコストは少なくない。出来るだけ余分な労働力をかけずに効率良く食料を集めるということは、コロニーを維持するうえで重要なことである。アリの種類によって、食料の種類や食料収集の形態は様々であるが、一般的にアリの食料収集は、偵察アリ食料収集アリの協力によって行われる。まず、偵察アリが巣から周辺の偵察に出発する。偵察の際はジグザグに進み、巣から



図 42 アリの群行動.

扇状に探索範囲を広げていく。そして食料を発見すると、偵察アリは道しるベフェロモンとよばれるフェロモンを地面に散布することによって、帰り道にマーキングしながら巣に戻ってくる。道しるベフェロモンは揮発性であり、アリが地面にマーキングした後に徐々に蒸発していくので、道しるべの真上に高濃度のフェロモンの蒸気空間がつくられる。偵察アリが帰巣した後、食料収集アリは触覚からの感覚に頼りながら道しるベフェロモンに従って進んでいく。その様子を図 43 に示す。食料収集アリは、左の触覚に道しるベフェロモンの蒸気空間を感知したときには左に曲がり、右の触覚に感知したときには右に曲がるというように、ジグザグに道しるベフェロモンに追従していく。そして、道しるベフェロモンの蒸気空間が途絶えたところで食料収集アリの動きは緩慢になり、地面をゆっくり触覚で探るようになる。食料を発見すると採集し真っ直ぐに帰巣する。ここで重要なのは、食料収集アリも行き帰りの行進において、道しるベフェロモンによるマーキングを行うことである。働きアリによる食料収集の要点は、食料収集にでかけた働きアリたちは道しるベフェロモンに追従して食料までたどり着き、食料を発見したらそれをもって帰巣するが、その行き帰りの道筋において道しるベフェロモンによってマーキングするということである。これらの行動は一見単純であり、個々のアリが従うルールも単純であるにも関わらず、コロニーに属する複数の働きアリたちがこのルールに従うとき、まさに群知能とよぶべき振舞いをみせる。それがアリの最短経路行進である。

図 44 のように食料まで複数の経路がある場合を考えてみる。図 44 では巣から食料までの道筋に障害物があり、それによって経路が三つある。ここでのそれぞれの経路の違いは、単純に食料までの道筋の距離である。多数のアリが食料収集に従事することを考えると、いちばん長さの短い経路 2 を選択することは大幅なコスト削減になるはずであり、事実道しるベフェロモンに基づく群知能によって、アリの群は経路 2 を選択することが出来る。

ほとんど視力もなく先の経路について予測する知能をもたないアリが最短経路を見つけ




図 43 道しるベフェロモンに従うアリの振舞い.

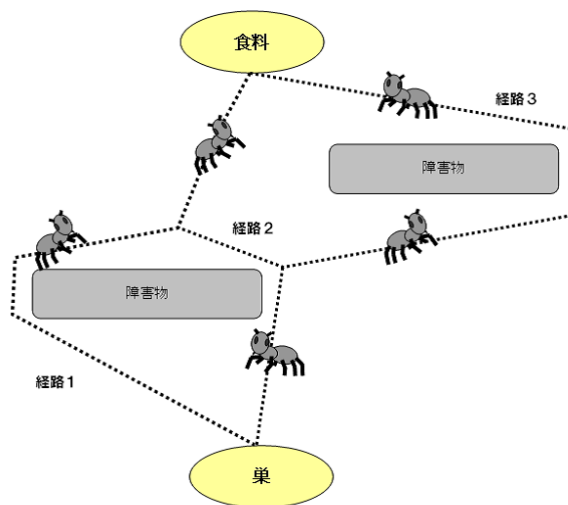


図 44 複数の経路がある場合の例.

出す仕組みについて，Deneubourg や Goss らは研究を重ねた。まずは，単純な状況について説明する。図 45 のように，巣から食料まで同じ長さの二つの経路があり，この経路を通して食料収集を行うときのアリの行動を説明する。まず，最初のアリが経路の分岐点にきたとき，そのアリは上か下のどちらかの経路を選択する。初めてきた分岐点ではランダムに経路を選択する。そのアリが食料までたどり着くと，今度は手に入れた食料を自分たちの巣まで持って帰る。帰り道には，もう一度分岐点から一つの経路を選択して巣まで帰ることになる。ここで，アリは食料収集の行進の際に道しるべフェロモンによってマーキングしていく。したがって，最初のアリが選択した道にはフェロモンによるマーキングがされていることになる。最初のアリに続き次々と後続のアリが食料収集に出かける際には，分岐点がマーキングされていることからマーキングされている経路を選択する傾向が強くなる。そして，そのアリがまた自分の選択した経路をマーキングしていき，その経路のフェロモンは強化される。一方で，選択されなかった経路は，フェロモンが空気中に蒸発していき，徐々にマーキングが薄くなっていく。

つまり，初期のわずかな偶然による傾向の違いが，後続の群行動によって徐々に強化され，わずかに多く選択されたほうは，益々選択される傾向が強くなり，少なく選択されたほうはますます選択される傾向が減少する。このように初期のわずかな差が自己触媒的なポジティブフィードバックとして強化されていき，アリたちは片方の経路集中して選択するようになる。




図 45 長さが同じ経路からなる分岐点におけるアリの振舞い.

次に経路長が異なる二つの経路を通して食料収集を行なう場合について考える。アリは、フェロモン情報のない最初は二つのうちのどちらかをランダムに選択し、後に道しるべフェロモンの情報に基づき選択する。図 46 では、分岐の両端からアリ達が出発し、反対側を目指して行進することを想定している。最初に分岐点に達したアリは、フェロモン情報がないためランダムに経路を選択するしかない。ここで、上の経路と下の経路が 2 匹のアリによって同時に選択されたと仮定する。それぞれのアリは選択した経路に従って進み、分岐点を通り過ぎる。このとき、アリの行進速度を一定と考えると、下の経路を選択したアリは上を選択したアリよりも早く分岐点を通過する。反対側の分岐点からみると、距離が短い下の経路のほうが早くフェロモンによってマーキングされることになる。よって、経路長が短い経路のフェロモンは時間とともに強化され、長い経路のフェロモンは蒸発によって素早く消滅する。アリはフェロモン量が多い経路を選択する傾向があるので、当然上下の経路を通るアリの数は図 47 のようになる。短い経路がわずかに早くマーキングされる減少と、アリの経路選択がフェロモン量の大小によって決定されるというポジティブフィードバックがアリの経路選択メカニズムの本質である。アリたちは分岐点において、どちらの経路が短いかをまったく意識することなく、単純にフェロモンの濃度が濃いほうを選択し、自分の通った経路にフェロモンをマーキングするという行動により群全体の行動最適化を行なっているのである。

次に大きな視点から群知能を捉える。アリの最短経路選択は上述の通りであるが、この行動にはアリの群知能における情報処理の本質が表れている。アリの通った道にフェロモンをマーキングすることとフェロモンの濃度が濃い道を好む行動ルールはフェロモンの濃度という局所的・分散的な情報のみに基づいており、この特性には複数の経路がある場合に最短の経路を選択するというような大域的な情報を用いる行動ルールは含まれていな




図 46 長さが異なる経路からなる分岐点におけるアリの振舞い.




図 47 分岐点におけるアリの経路選択の変化例.

い。ここで重要なのは、アリとフェロモンを取り巻く環境に、フェロモンが蒸発することとアリの歩行速度は一定であるという環境ルールが存在することである。アリのフェロモンによる相互作用、つまりコミュニケーションは単純にアリの行動ルールによって引き起こされる作用のみに基づくのではなく、環境ルールも含めた相互作用である。このようなコミュニケーションは音・言語などのシグナルそのもののみに意味のある直接的なコミュニケーションとは性質が異なり、環境の特性（ここでは環境ルール）を積極的に利用することで、分散的・局所的な情報と行動ルールに基づいて大域的な情報を統合可能としているのである。動物行動学では上記のコミュニケーション方法を stigmergy と呼んでいる。stigmergy では、自身（アリなどの生物）の知覚した局所的な情報からフェロモンを

発信して、フェロモンが特性と環境によって変化する。さらに、それを発信者であるアリが再び知覚することでアリと環境間のフィードバックが生まれ、複雑な環境への知識や情報処理能力をもたないアリがあたかも複雑な環境に柔軟に対応しているようにみえるのである。また、アリなどの生物が複数の個体によって群行動を行なう点も最短経路探索を可能としている。以上のように、群による知能が個々の行動の集合行為によって生まれるのである。アリの群知能は以下のような stigmergy に基づく創発的知能とも捉えることが出来る。

$$\text{群知能} = \text{stigmergy に基づく行動ルール} + \text{環境ルール} + \text{群の行動} \quad (134)$$

個々のアリは力も微力であり、高度な情報処理を行なっているわけでもない。しかし、多数集まることによって高度な社会を形成し、適応的な作業分担によって外的環境の変化に柔軟に対応しながら、そのコロニーを維持していく方法を進化的に獲得してきたのである。

近年の PC の計算能力の向上にともない、遺伝的アルゴリズムなどの生物進化を模倣した進化型計算を実装するシステム設計が可能となった。このような背景のもと、アリや蜂などの社会を手本にした群知能に基づくシステムも設計されるようになってきている。問題点としては、どのようにして群知能アルゴリズムを設計すればよいのかという点である。次節以降では、群知能アルゴリズムの設計手法について論じていく。

## 11.5 アリの群知能と問題解決

アリは他の生物との生存競争の中で超個体としての群行動を進化させてきた。各個体は自分の局所的な行動ルールを行っており、その行動の相互作用が stigmergy によるコミュニケーションを通して集合すつことにより、マクロレベルにおいて群知能が創発される。そして、創発されたマクロなシステムの振舞いにより、環境の変化に柔軟に適応出来るのである。アリのコロニーのような特徴と柔軟性は、人工的なシステム設計という観点からも興味深く、コンピュータ上に設計されるシステムの手本として取り上げられている。システムが直面する状況を初めから想定してそれに対する最適な出力を前もって計算しておき、システムを設計することが従来のシステム設計思想であった。しかしながら、このようなシステム設計は時々刻々と動的に変化するものに対しては不適合である、つまりシステムが動的に変化するので直面する状況が非常に多く設計出来ないまたは変化を想定出来ずに設計出来ないのである。これは、肺のエラスタンス推定におけるファジィ変数の設計にも当てはまる。アリの群のように複数の比較的単純な行動ルールに基づく要素が複数集まり柔軟なシステムを設計することはマルチエージェントシステムと呼ばれてい



る。マルチエージェントシステムは多数のエージェントと呼ばれる行動主体の集合体として定義される。そして、各エージェントが独自の判断に従って入力情報から出力としての行動を決定する。そこでは、複数のエージェントの相互作用を通して与えられたタスクを柔軟に遂行するようにエージェントの行動が設計される。アリのフェロモンに基づく相互作用を群知能の基礎とするマルチエージェントシステムは、図 48 に示すようにエージェントどうしのダイレクトコミュニケーションとフェロモンコミュニケーションの両方が実装され、エージェントがおかれる環境に基づいて設計された環境特性とフェロモンの stigmergy によって、適応的な行動を可能とする。

アントコロニー最適化法メタヒューリスティクスは、人工的なフェロモンに基づいた計算パラダイムを考えるうえで示唆に富んだ研究であり、そのメカニズムを知ることは群知能の設計論を探るうえで重要である。

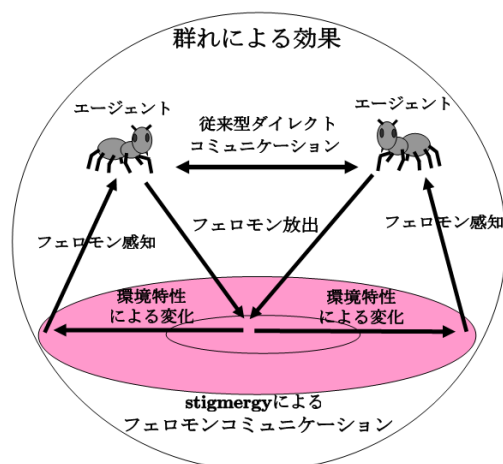


図 48 アリの群知能とフェロモンコミュニケーションに基づくマルチエージェントシステム模式図.

## 11.6 組合せ最適化問題とメタヒューリスティクス解法

具体的にアントコロニー最適化法の説明に入る前に、アントコロニー最適化法が対象とする組合せ最適化法と、それらを解くためのアルゴリズムの一種であるメタヒューリスティクス解法を簡単に説明する。組合せ最適化問題とは、ある有限個数の解集合で定義される解空間とそれぞれの解に対応する評価関数値で構成され、解空間の中で評価関数値がもっとも望ましい解を発見する問題である。解空間が有限であるので最適解が簡単

に見つかるように感じられるが、その計算量はコンピュータでも膨大なものとなる。例えば、組合せ最適解を厳密に解くためには全ての解を調べ最も評価関数値の良い解を発見すればよい（厳密解法）のだが、問題サイズが大きくなり解空間が巨大になるにつれ計算時間が膨大になり実用的な時間で問題を解くことが困難になってくる。

メタヒューリスティクス解法とは、組合せ最適化問題を解くにあたり厳密に大域的最適解を求めることを半ば諦める代わりに、問題の特徴に基づいて探索空間をコンパクトに限定しながら効率良く探索を行なうことで、実用的な時間によって素早く十分許容範囲内の解を求める手法である。メタヒューリスティクス解法のアルゴリズムは以下の通りである。

【手順 1】ランダムな初期解集団を生成

【手順 2】過去探索の情報を利用して、新たな解集団を生成

【手順 3】生成した解集団を評価し、次の探索に用いられる情報を作成

これはつまり、探索の過程において過去に探索した解からの情報、すなわち「解空間のどのあたりに良い解がありそうなのか、また悪い解がありそうなのか」という情報を抽出して、良い解がありそうな空間付近を集中的に探索することで効率よく良い解を発見しようというアルゴリズムである。探索のイメージ例図を図 49 に示す。図から分かるように、組合せ最適化問題の解空間と評価値の関係は険しい山谷のようにイメージ出来る。このとき、最も評価値が良い大域的最適解は、一番高い山の頂上に対応づけることが出来る。解




図 49 メタヒューリスティクス解法の探索イメージ例図.

空間において、メタヒューリスティクス解法はランダムな点から出発し、過去探索の情報に基づいて良い解空間のみを探索するので、まるで山を登るように解空間を探索していることになる。しかし、過去探索から得られる情報から探索空間の全てを推測することは不可能であるため、ある時には局所的最適解で収束してしまうこともある。この場合には近傍の評価関数値が低いことから、過去探索情報のみで局所的最適解から脱出することは不可能となる。以上のことから、メタヒューリスティクス解法は局所的最適解に陥らずに出来るだけ素早く良い解を発見することが望まれる。そのためには、限られた計算コストのもとで見込みのありそうな探索領域を集中的に探索しつつ、探索情報がない未知の領域についても情報を得ることをバランスよく行なうことが重要である。これらはトレードオフの関係にあり、効率良く探索を行なうためにそれぞれのどの程度行なえば良いのかという探索空間の集中化と分散化問題と呼ばれている。探索空間の集中化と分散化のバランスをとりながら、短時間で良い解を得るメタヒューリスティクス解法がいくつか提案されている。これらはいずれも生物や物理現象などの自然現象からヒントを得て集中化と分散化のバランスを実現しているという特徴がある。それは自然現象の中に最適化のメカニズムを見出すことが出来るからである。アントコロニー最適化法も、自然現象の最適化メカニズムの一つであり、またメタヒューリスティクス解法である。次節では、アントコロニー最適化法について詳細に述べる。

## 11.7 アントコロニー最適化法

アントコロニー最適化法は、アリの採餌行動における最適化行動のアナロジーを用いた最適化手法であり、主に組合せ最適化問題を対象問題として取り扱う [23][24]。概要は次の通りである。まず、ア리를模倣した複数の人工エージェントを用意する。これらのアリエージェントは、組合せ最適化問題の離散的な世界で並列的に行動するエージェントである。組合せ最適化問題において、各アリエージェントは問題構造から得られる近視眼的（局所的）な情報と、フェロモンを通して形成される複数のエージェントの群行動に基づく大域的な情報を組み合わせることによって、解を探索していく。アリエージェントが組合せ最適化問題を探索するイメージを図 50 に示す。複数のアリエージェントは開始点から出発し、各頂点を通過して終点に向かっていく。各頂点は解の要素であり、アリエージェントが5つの頂点を通り終点に到着することで5つの要素からなる最適問題の一つの解が選択される。例図では簡略化のため省いたが、まだアリエージェントに選択されていない解が複数あることに注意されたい。アリエージェントが選択した経路について、解に対する評価関数値を経路の長さにとらえることが出来る。アリエージェントの目的は短い




図 50 アントコロニー最適化法のアリエージェントによる探索イメージ例図.

経路を見つけることであるため、アリの最短経路行進のアナロジーを用いることが出来ることが直感的に理解できるであろう。ここで重要なのが、いかにしてエージェント群に相互作用しながら全体の目的に対して協調的に行動させるか、つまり人工的に stigmergy を実装するかということである。

アントコロニー最適化法では、探索の過程で得られた問題領域に対する知識（情報）を対象問題領域から事前に定義される状態空間にフェロモンを置いていくことで各エージェントに相互作用させる。これは、実際のアリが行進時にフェロモンを置いて、他の仲間に餌までの経路の情報を交換することに相当する。よって、図 50 では、それぞれの経路にフェロモンが置かれていると考えられる。そして、複数のアリエージェントによって構成されたフェロモンの場合は、複数のエージェントによる情報が集約された創発的な情報の場となる。各アリエージェントがこのフェロモンによる情報を利用することにより、実際のアリが採餌行動の際に見せる最適化行動のように、フィードバックに基づく群知能が実現できるのである。

フェロモンを媒体とした後続のエージェントとの相互作用は、現実のアリにおける経路選択時のフェロモン強化のように、基本的にポジティブフィードバックの機構である。したがって、何らかの作用によってわずかに強められた経路のフェロモンは更に強化され、逆に弱められた経路のフェロモンは更に弱くなっていく。ここで問題なのが、過去の情報に基づいた探索領域の集中化と新たな探索領域を見つける分散化のバランスングである。アントコロニー最適化法では、この問題を確率的行動選択とフェロモンの蒸発によって解決している。まず、アリエージェントの行動を確率的に決定することによって、同じ情報を共有していても各エージェントの行動選択に幅をもたせることが出来る。つまり、全

てのエージェントが「良いと思われる解」付近だけを探索するという事はない。次に、フェロモンの蒸発であるが、これは揮発性化学物質である現実のフェロモンの特徴を模倣したものである。各アリエージェントが発信するフェロモンの情報の効力を時間とともに減少させていくことで、新たに得られた情報を速やかに利用しながら一つの探索領域にスタックされるのを防止する。つまり、ある限定的な状況で探索した情報に基づくフェロモンの情報は、後に探索領域が遷移した状況では役に立たないかもしれない。そのような情報は、適切な探索に妨げになるので速やかに消去するのが望ましい。このように、アントコロニー最適化法は、確率的な行動選択と人工的フェロモンの蒸発、そして群の効果によって人工的な stigmergy を実装し、組合せ最適化問題の探索を実現しているのである。

ここからは、アントコロニー最適化法が、人工的なアリエージェントの群知能と stigmergy に基づいてどのように組合せ最適化問題を解いていくのか具体的な手順を説明する。アルゴリズムの流れは以下の通りである。

【手順 1】初期パラメータの設定

【手順 2】確率を用いた  $m$  匹のアリエージェントによる解候補群の作成（経路の生成）

【手順 3】生成された解の評価

【手順 4】解の評価値から各経路のフェロモン増加量を計算し、フェロモン増加量とフェロモン蒸発率を用いて次の繰返し回数における各経路のフェロモン量を算出

【手順 5】終了繰返し回数  $t_{max}$  に達していない場合には手順 2 に戻る

組合せ問題の要素数を  $n$ 、人工アリエージェント数を  $m$  とする。要素間の経路には人工アリエージェントによってフェロモンが置かれるものとする。ここで置かれるフェロモン量は非負の実数値で表現される。要素  $i, j$  間の経路のフェロモン量を  $\tau(i, j)$  で表わす。ここで、初期時刻における各要素のフェロモン量は  $\tau(i, j) = \tau_0$  としてある定数  $\tau_0$  で初期化しておく。つまり、初期時刻において各アリエージェントは等しい確率で各要素に向かう可能性があるということである。アルゴリズムの繰返し回数を  $t$  とするとき、アルゴリズムは各人工アリエージェントが巡回路を生成してフェロモンの量が更新されるまでを 1 ステップとして、終了ステップ  $t_{max}$  まで以下の行動が繰り返される。

まず、各人工アリエージェントは、初期点あるいは各ポイントに配置され、次の点まで「距離の近さ」と「経路に置かれているフェロモンの量」に従い確率的に次の移動先を選択しながら、各ポイントを巡回して巡回路を生成する。人工アリエージェント  $k$  がポイント  $i$  にいるものとし、 $N^k$  をエージェント  $k$  が次に選択可能なポイントの集合とする。こ

のとき,  $N^k$  の中からポイント  $j$  が次の移動先として選択される確率は,

$$p^k(i, j) = \frac{[\tau(i, j)]^\alpha [\eta(i, j)]^\beta}{\sum_{l \in N^k} [\tau(i, l)]^\alpha [\eta(i, l)]^\beta} \quad (135)$$

と与えられる。ここで,  $\eta(i, j)$  は問題領域固有の情報つまり局所的な情報を表わし, 一般的にはポイント間の距離  $d(i, j)$  の逆数として  $\eta(i, j) = 1/d(i, j)$  が採用されている。また,  $\alpha, \beta$  はそれぞれ非負の実数で、問題領域に基づく局所的な情報と, フェロモンにより段階的に形成される大域的な情報をどのくらい重要視するかのパラメータである。以上のように, 各人工アリエージェントは問題領域のポイント (解の要素) を移動し巡回路を構築していく。全てのエージェントが巡回路を生成した後, 各経路のフェロモン値  $\tau(i, j)$  は以下のルール,

$$\tau(i, j) = (1 - \rho)\tau(i, j) + \sum_{k=1}^m \Delta\tau^k(i, j) \quad (136)$$

$$\Delta\tau^k(i, j) = \begin{cases} 1/L^k, & \text{if } (i, j) \in T^k \\ 0, & \text{otherwise} \end{cases} \quad (137)$$

で更新される。ここで,  $T^k$  は人工アリエージェント  $k$  が生成した巡回路に含まれる経路集合を表わし,  $L^k$  はその巡回路の評価関数値 (例えば総距離など) を表わす。各エージェントが巡回路で用いた経路に置くフェロモンの量は, 巡回路の評価関数値の逆数によって決定されるので, 評価値が良い巡回路には大きい量のフェロモンが置かれ, 逆に評価値の悪い巡回路には少ない量のフェロモンが置かれる。それぞれの経路のフェロモン量の変化量は, 単純に各エージェントの変化量の総和で計算される。この更新式で, 個々のエージェントの探索結果に基づく情報が重なり合って, フェロモンの情報は探索領域における大域的な情報となる。また, 式 (136) における  $\rho$  はフェロモンの蒸発率を表すパラメータであり, 通常は  $0 < \rho < 1$  の間で設定される。このパラメータ  $\rho$  の影響によって, 過去のフェロモンの量は徐々に減少していき, 新しいフェロモンの情報が大きな影響をもつことになる。このようにして, それぞれの人工アリエージェントが巡回路を生成したときにフェロモンの値を更新し, さらに各エージェントはそれまでの巡回路をクリアにして, またその場所から移動を再開する。こうして, アルゴリズムの終了ステップ  $t_{max}$  がくるまで各エージェントはフェロモンによる相互作用を繰返し問題の解を探索していくのである。

以上, 基本的なアントコロニー最適化法のアルゴリズムを説明したが, 次節では本研究で提案したファジィ変数の決定におけるアントコロニー最適化法について説明する。

## 11.8 ファジ変数の決定におけるアントコロニー最適化法について

前述したように生物の自律適応型システムは，前もってその変化を予想することが出来ないような複雑，かつ動的な環境に対する人工システムを設計するときの良い指針になる。患者の肺特性も動的であり，病状の変化などで特性が刻々と変わってくる。つまり，肺エラストンス推定に用いるファジ変数の適切な自動設定が必要となる。よって本研究では，動的な環境に対して適応可能なアントコロニー最適化法を導入して自動で最適なファジ変数の範囲決定をおこなうアルゴリズムを提案する。

本研究では，ファジ変数を *small* , *medium* , *big* の3つに設定している。図 51 に，本研究で主に用いているファジ変数の例図を示した。図からファジ変数の決定ポイントとしては， *small* の右端点， *medium* の左端点， *medium* の頂点， *medium* の右端点， *big* の左端点の5点があることがわかる。




図 51 ファジ変数の決定ポイント図.

図 52 には，本研究で提案するアントコロニー最適化法のリエージェントによる最適なファジ変数探索イメージ例図を示した。各ファジ変数のポイントの解候補群（肺体積  $V = 0, \dots, N$ 、 $N$ :患者の最大肺体積値）を  $S_i (i = 1, \dots, 5)$  とする。アリを模倣した複数のエージェントは，問題領域に基づく局所的情報とフェロモンの大域的情報を用いた確率によって各群  $S_i$  の解候補を選択し巡回路（ファジ変数）を生成する。生成された巡回路は，巡回路を用いて推定した肺内圧力  $P_\ell$  と検証データの圧力の二乗和誤差により評価される。最適なファジ変数を決定するためのアルゴリズムは以下の通りである。




図 52 アントコロニー最適化法のアリエージェントによる最適なファジィ変数探索イメージ例図

**【step1】(初期化とパラメータ設定)**

- $t = 0$  繰り返し回数の初期化
- $t_{max}$  繰り返し回数の設定
- $M$  エージェント数の設定
- $\tau_0$  初期フェロモンの設定値

**【step2】(エージェントによる巡回路の生成)**

以下の確率に従いエージェントは経路を生成する。

$$p_{k_{sij}}(t) = \frac{[\tau_{sij}(t)]^\alpha [\eta_{sij}]^\beta}{\sum [\tau_{sij}(t)]^\alpha [\eta_{sij}]^\beta} \quad (138)$$

ここで、 $p_{k_{sij}}(t)$  は、繰り返し回数  $t$  回目で  $k$  番目のエージェントが群  $S_i$  の数  $i$  から次の選択群  $S_{i+1}$  の数  $j$  を選択する確率である。また、 $\tau_{sij}(t)$  は、繰り返し回数  $t$  回目に群  $S_i$  の数  $i$  から次の群  $S_{i+1}$  の数  $j$  間の経路  $(i, j)$  に置かれるフェロモン量を表わし、 $\eta_{sij}$  は、問題領域に基づく局所的情報を表わす。 $\alpha, \beta$  は、非負の実数であり、それぞれ大域的情報と局所的情報の重要度である。本研究における大域的情報量は【step3】で計算される。また、本研究で探索される問題領域はファジィ変数の設定範囲であり、作成された巡回路でファジィ変数値が与えられない肺体積領域があると肺エラストランスを推定できなくなってしまう、あるいは明らかに患者の肺エラストランスとは異なる値が推定されてしまう。よって、本研究における局所的情報量は、ファジィ変数値が与えられない肺体積領域を作らな



いように各経路に値を設定した。

【step3】(生成した巡回路の評価)

全てのエージェントが巡回路を生成した後，生成した巡回路 (ファジィ変数) を用いて肺エラストンス  $f_E$  と静的  $P$ - $V$  曲線を推定する。巡回路は，推定された肺内圧力  $P_\ell$  と検証データとの圧力の二乗和誤差  $E_k(t)$  によって評価される。このとき評価値  $E_k(t)$  が小さければ小さいほど，良い巡回路 (ファジィ変数) ということである。

【step4】(フェロモンの更新)

【step3】で求めた  $E_k(t)$  を用いてフェロモン増加量  $\Delta\tau_{k_{sij}}(t)$  を計算すると，

$$\Delta\tau_{k_{sij}}(t) = \begin{cases} \frac{1}{\omega * E_k(t)}, & \text{if } (i, j) \in T_k(t) \\ 0, & \text{otherwise} \end{cases} \quad (139)$$

となる。ここで  $T_k(t)$  は， $k$  番目のエージェントによって得られた巡回路である。 $E_k(t)$  にかかる係数  $\omega$  は，過剰にフェロモン値を増加して解の多様性を失わないようにするための係数である。

各経路のフェロモン更新は，

$$\tau_{sij}(t+1) = (1 - \rho)\tau_{sij}(t) + \sum_{k=1}^M \Delta\tau_{k_{sij}}(t) \quad (140)$$

によって行なわれる。ここで， $\rho$  はフェロモンの蒸発率である。

【step5】

$t = t + 1$  とし， $t = t_{max}$  に達していなければ【step2】に戻る。

【step6】

得られた巡回路のうち最良の巡回路を出力して終了。

次節では，本アルゴリズムを用いて実患者データの最適なファジィ変数をもとめた実験結果を示す。

表 5 本実験におけるアントコロニー最適化法の設定値.

エージェント数 $M$	1000
繰返し回数 $t_{max}$	20
大域的情報の重要度 $\alpha$	1
局所的情報の重要度 $\beta$	1
フェロモン加重防止調整値 $\omega$	200

## 11.9 実験結果及び考察

患者の実データを用いて、アントコロニー最適化法による最適なファジィ変数の決定実験を行なった。実験に際して設定したパラメータを、表 5 に示す。

図 53, 図 54, 図 55 は、蒸発率  $\rho$  を変化させた時の各繰返し回数において生成された巡回路の  $E_k(t)$  の最大値, 最小値, 平均値の推移図である。それぞれ蒸発率  $\rho$  の変化によって収束速度に変化はあるものの、集団としての多様性を保持しながら探索を行なっていることがわかる。最適化アルゴリズムが多様性を保持しているので、急に肺の特性が変化し現在最適とされていたファジィ変数が不適切になった場合にも直ぐに新たな解の探索に移行出来る。

図 56 と図 57 は、今回の実験でアントコロニー最適化法アルゴリズム (蒸発率  $\rho=0.1$ ) が終了したときに得られた最良の巡回路から生成したファジィ変数と推定された静的  $P$ - $V$  曲線である。の点は他の手法で計測した検証用の静的  $P$ - $V$  データであり、推定曲線がおおむね検証用データに近い値をとっていることがわかる。前章における同データの手動設計ファジィ変数を用いた静的  $P$ - $V$  曲線と検証用  $P$ - $V$  データの圧力誤差平均値が  $0.3525[\text{cmH}_2\text{O}]$  であったのに対し、今回のアントコロニー最適化法アルゴリズムを用いた自動設計ファジィ変数の圧力誤差平均値は  $0.2864[\text{cmH}_2\text{O}]$  と推定精度が改善された。図 53, 図 54, 図 55 の  $E_k(t)$  の最小値を見て分かるが、蒸発率を変化させても概ね静的  $P$ - $V$  曲線と検証用  $P$ - $V$  データの圧力誤差平均値が  $0.3[\text{cmH}_2\text{O}]$  を下回ることが分かる。以上のことから、アントコロニー最適化法を用いた最適なファジィ変数の決定により推定される静的  $P$ - $V$  曲線の推定精度が向上した。

今回アントコロニー最適化法を用いた最適なファジィ変数の決定に使用した患者データは、呼吸 1 回分のデータである。現在保持している患者データは、多くても呼吸 3 回分程度とデータ数が非常に少なく肺の特性が急激に変化するデータは保持していない。よっ

て、患者の肺の特性が変化したときにアントコロニー最適化法の多様性がどのような効果をもたらすのかという検証は出来なかった。

今後は、更なる設定パラメータの調整とアルゴリズムの改良を行なっていきたい。

## 11.10 本章のまとめ

本章では、患者の肺エラストンスをファジロジックにより推定する際に必要なファジ変数をアントコロニー最適化法を用いて決定する手法を提案した。患者の実データを用いたファジ変数の最適化実験では、集団としての多様性を保持しながら探索を行ない、手動設計で作成したファジ変数よりも推定精度の良いファジ変数を得ることが出来た。今後は、更なる設定パラメータの調整とアルゴリズムの改良を行ない、患者の肺の特性が急激に変化した場合に本アルゴリズムが対応出来るかなどの検証も行なっていきたい。




図 53 各繰返しにおける巡回路の評価値  $E_k$  の最大値、最小値、平均値 [ $\rho = 0.1$ ].




図 54 各繰返しにおける巡回路の評価値  $E_k$  の最大値、最小値、平均値 [ $\rho = 0.5$ ].




図 55 各繰返しにおける巡回路の評価値  $E_k$  の最大値、最小値、平均値 [ $\rho = 0.9$ ].




図 56 アントコロニー最適化法により得られたファジィ変数 [ $\rho = 0.1$ ].




図 57 アントコロニー最適化法により得られたファジィ変数を用いて推定した静的  $P$ - $V$  曲線 [ $\rho = 0.1$ ].

## 12 非線形肺エラストランス $f_E(V)$ 係数の繰返し最適化手法について

### 12.1 問題点と肺エラストランス式 $f_E(V)$ 以外の項の係数を統一化するアルゴリズム

前章まで説明した手法において, *small* 部・*medium* 部・*big* 部の3分割されたファジィルールを用いて推論により肺エラストランス値を推定していた。つまり, 各ルールの係数推定を行なう際には下記の呼吸システム式を用いていたが, 各ルール毎に  $\theta_i^T = [a_{1i}, k_{1i}, k_{2i}, r_{1i}, r_{2i}, b_{2i}]$ , ( $i = \text{small, medium, big}$ ) が推定されていた。

$$P_{ao}(t) + a_1 \dot{P}_{ao}(t) = f_E(V)V(t) + r_1 F(t) + r_2 |F(t)|F(t) + b_2 \dot{F}(t) + \epsilon(t) \quad (141)$$

推定された肺エラストランス  $f_E(V)$  のパラメータ  $\theta_f^T = [k_1, k_2]$  が, ファジィルール毎に異なるのは問題ない。ここで問題となるのが,  $\theta$  内の気道抵抗などのパラメータ  $\theta_o^T = [a_1, r_1, r_2, b_2]$  の値である。これらの値は, 医学的に短時間(一呼吸内)では変化しないと言われている。短時間では変化しないパラメータ  $\theta_o$  が各ファジィルールで異なる値をとるので, 静的  $P$ - $V$  曲線の推定精度にも影響を及ぼしていると考えられる。本章では, この推定時の問題点を解決する手法を提案した。提案手法では, 肺エラストランス以外の項の係数  $\theta_o^T = [a_1, r_1, r_2, b_2]$  を推定する手順と肺エラストランスの項の係数  $\theta_f^T = [k_1, k_2]$  を推定する手順を分けることによって, 各ファジィルールの係数推定の際に  $\theta_o^T = [a_1, r_1, r_2, b_2]$  の統一化を行なっている。提案手法のアルゴリズムは以下の通りである。

#### 【手順1】

肺エラストランスを多項式  $f_E(V) = k_1 + k_2 V + k_3 V^2 + k_4 V^3$  で近似したと仮定し, その時の肺エラストランス式以外の項の係数を推定する。

$$y(k) = \phi^T(k)\theta + e(k) \quad (142)$$

$$y(k) = \int_{(k-\ell)T}^{KT} P_{ao}(\tau) d\tau \doteq \sum_{j=0}^{\ell} g_j P_{ao}(k-j) \quad (143)$$

$$\begin{aligned} \phi(k) &= \int_{(k-\ell)T}^{KT} \varphi(\tau) d\tau \\ &= \begin{bmatrix} -P_{ao}(k) + P_{ao}(k-\ell) \\ \sum_{j=0}^{\ell} g_j V(k-j) \\ \sum_{j=0}^{\ell} g_j V^2(k-j) \\ \sum_{j=0}^{\ell} g_j V^3(k-j) \\ \sum_{j=0}^{\ell} g_j V^4(k-j) \\ V(k) - V(k-\ell) \\ \sum_{j=0}^{\ell} g_j |F(k-j)| F(k-j) \\ F(k) - F(k-\ell) \end{bmatrix} \end{aligned} \quad (144)$$

ただし  $g_j$  は数値積分法の係数  $\varphi^T(t) = [-\dot{P}_{ao}(t), V(t), V^2(t), V^3(t), V^4(t), F(t), |F(t)|F(t), \dot{F}(t)]$ ,  $\theta^T = [a_1, k_1, k_2, k_3, k_4, r_1, r_2, b_2]$  である。各時刻における (142) 式をベクトル方程式にまとめ、最小二乗法により肺エラストンス式以外の項の係数  $\theta_o^T = [a_1, r_1, r_2, b_2]$  が推定される。手順 2 ではこれら推定された係数  $\theta_o$  を用いて、肺エラストンス式の係数を推定する。

## 【手順 2】

手順 1 で求めた係数  $\theta_o^T = [a_1, r_1, r_2, b_2]$  を用いて、各ファジィ変数 small, medium, big における肺エラストンス式  $f_E(V) = k_1 + k_2 V$  の係数  $\theta_f^T = [k_1, k_2]$  を推定する。

この時の同定モデルは、

$$y(k) = \phi^T(k) \theta + e(k) \quad (145)$$

$$\begin{aligned} y(k) &= \int_{(k-\ell)T}^{KT} P_{ao}(\tau) d\tau - a_1 \int_{(k-\ell)T}^{KT} -\dot{P}_{ao}(\tau) d\tau - r_1 \int_{(k-\ell)T}^{KT} F(\tau) d\tau \\ &\quad - r_2 \int_{(k-\ell)T}^{KT} |F(\tau)| F(\tau) d\tau - b_2 \int_{(k-\ell)T}^{KT} \dot{F}(\tau) d\tau \end{aligned} \quad (146)$$

$$\begin{aligned}\phi(k) &= \int_{(k-\ell)T}^{KT} \varphi(\tau) d\tau \\ &= \begin{bmatrix} \sum_{j=0}^{\ell} g_j V(k-j) \\ \sum_{j=0}^{\ell} g_j V^2(k-j) \end{bmatrix}\end{aligned}\quad (147)$$

ただし,  $\varphi^T(t) = [V(t), V^2(t)]$ ,  $\theta_f^T = [k_1, k_2]$  である。

ここでは前述した, 数値積分法を適用した呼気と吸気データを各ファジィ変数の区間データ毎に結合させて最小二乗法により係数を推定する手法を用いた。

### 【手順 3】

手順 2 で求めた各ファジィ変数 *small*, *medium*, *big* における肺エラストンス式  $f_E(V) = k_1 + k_2 V$  の係数を用いて, ファジィ推定により肺エラストンスならびに静的  $P$ - $V$  曲線を求める。

ファジィルールを表すと,

$$\begin{aligned}& \text{if } V = \text{small} \\ & \quad \text{then } f_{E(\text{small})} = k_{1(\text{small})} + k_{2(\text{small})} V \\ & \text{if } V = \text{medium} \\ & \quad \text{then } f_{E(\text{medium})} = k_{1(\text{medium})} + k_{2(\text{medium})} V \\ & \text{if } V = \text{big} \\ & \quad \text{then } f_{E(\text{big})} = k_{1(\text{big})} + k_{2(\text{big})} V\end{aligned}\quad (148)$$

となる。

以上のように, 最初に肺エラストンス表現を多項式と仮定して, 肺エラストンス式以外の項の係数  $\theta_o^T = [a_1, r_1, r_2, b_2]$  を推定することにより統一化することが出来る。一見すると 2 度手間のように感じるかもしれないが, ファジィロジックは多項式より低次数で非線形関数 (ここでは肺エラストンス) を表現出来るので, この手法によってより推定精度の良い静的  $P$ - $V$  曲線が推定されることが期待出来る。

## 12.2 実験結果及び考察

本節では, 肺エラストンス式以外の項の係数  $\theta_o^T = [a_1, r_1, r_2, b_2]$  統一化手法の有効性を検証した。



『検証 1』

多項式  $f_E(V) = k_1 + k_2V + k_3V^2 + k_4V^3$  により推定された静的  $P$ - $V$  曲線と提案手法により推定された静的  $P$ - $V$  曲線について、検証データとの圧力二乗和誤差を求めた。提案手法における手順 1 で用いる多項式については、比較対象と同じである 3 次多項式  $f_E(V) = k_1 + k_2V + k_3V^2 + k_4V^3$  を用いた。




図 58 3 次多項式で推定した静的  $P$ - $V$  曲線と検証データ.




図 59 推定に用いたファジ変数.




図 60 本手法で推定した静的  $P$ - $V$  曲線と検証データ.

表 6 各手法による推定静的  $P$ - $V$  曲線と検証データとの圧力二乗和誤差値

	多項式による推定	提案手法による推定
圧力二乗和誤差値	0.320529 [cmH <sub>2</sub> O]	0.319004 [cmH <sub>2</sub> O]

実験結果では、本手法で推定した静的  $P$ - $V$  曲線のほうが検証データにより近い値を取り提案手法の有効性が見られた。これは、ファジィロジックが 3 次多項式より非線形関数（ここでは肺エラストンス）を表現するのに優れているからであると考えられる。

## 『検証 2』

ファジィルール毎に全ての係数を推定する手法（前章までの手法）により推定された静的  $P$ - $V$  曲線と提案手法により推定された静的  $P$ - $V$  曲線について、検証データとの圧力二乗和誤差を求めた。なお、ファジィ推定に用いたファジィ変数は、図 59 と同じである。

実験結果では、本手法で推定した静的  $P$ - $V$  曲線のほうが検証データにより近い値を取り提案手法の有効性が見られた。ここでは、肺エラストンス式以外の項の係数  $\theta_o^T = [a_1, r_1, r_2, b_2]$  を統一化し推定時の問題点を解決したことにより、より良い肺エラストンス式の係数  $\theta_f^T = [k_1, k_2]$  が推定されたことが推定精度改善の要因であると考えられる。



 図 61 従来の手法で推定した静的  $P$ - $V$  曲線と検証データ.

表 7 各手法による検証データとの圧力二乗和誤差値

	従来の手法による推定	提案手法による推定
圧力二乗和誤差値	0.352500 [cmH <sub>2</sub> O]	0.319004 [cmH <sub>2</sub> O]

### 12.3 非線形肺エラストンス $f_E(V)$ 係数の繰返し最適化手法

上記の手法は，肺エラストンス式以外の項の係数が短時間で変化するという推定時の問題点を解決するだけでなく，静的  $P$ - $V$  曲線の推定精度改善にも繋がった。また，本手法は係数  $\theta_o^T = [a_1, r_1, r_2, b_2]$  と  $\theta_f^T = [k_1, k_2]$  を別々の手順で推定していることから，手順を繰り返すことで更に静的  $P$ - $V$  曲線の推定精度を改善出来ると考えられる。前述した推定手順に以下の手順 4 を付け加える。

#### 【手順 4】

手順 3 で求めた各ファジ変数 *small*, *medium*, *big* における肺エラストンス式  $f_E(V) = k_1 + k_2V$  の係数を用いて，各  $V(t)$  における肺内圧力  $\hat{P}_\ell$  を推定する。

$$\hat{P}_\ell(t) = \hat{f}_E(V)V(t) \quad (149)$$

呼吸システム式は次式のようなモデルで表現される。

$$P_{ao}(t) + a_1 \dot{P}_{ao}(t) = f_E(V)V(t) + r_1 \dot{V}(t) + r_2 |F(t)|F(t) + b_2 \dot{F}(t) + \epsilon(t) \quad (150)$$

(150) 式に (149) 式を代入すると、

$$P_{ao}(t) + a_1 \dot{P}_{ao}(t) = \hat{P}_\ell + r_1 \dot{V}(t) + r_2 |F(t)|F(t) + b_2 \dot{F}(t) + \epsilon(t) \quad (151)$$

となる。この式を用いて数値積分を行ない同定モデルをもとめると、

$$y(k) = \phi^T(k)\theta + e(k) \quad (152)$$

$$y(k) = \sum_{j=0}^{\ell} g_j P_{ao}(k-j) - \sum_{j=0}^{\ell} g_j \hat{P}_\ell(k-j) \quad (153)$$

$$\begin{aligned} \phi(k) &= \int_{(k-\ell)T}^{KT} \varphi(\tau) d\tau \\ &= \begin{bmatrix} -P_{ao}(k) + P_{ao}(k-\ell) \\ V(k) - V(k-\ell) \\ \sum_{j=0}^{\ell} g_j |F(k-j)|F(k-j) \\ F(k) - F(k-\ell) \end{bmatrix} \end{aligned} \quad (154)$$

となる。ただし、 $g_j$  は数値積分法の係数、 $\varphi^T(t) = [-\dot{P}_{ao}(t), \dot{V}(t), |F(t)|F(t), \dot{F}(t)]$ 、 $\theta_o^T = [a_1, r_1, r_2, b_2]$  である。各時刻における (152) 式をベクトル方程式にまとめ、最小二乗法により新たな肺エラストランス式以外の項の係数  $\theta_o^T = [a_1, r_1, r_2, b_2]$  が推定される。そして、手順 2、3 に戻りファジィロジックにより静的  $P$ - $V$  曲線を推定する。

## 12.4 実験結果及び考察

肺エラストランス式以外の項の係数  $\theta_o^T = [a_1, r_1, r_2, b_2]$  の推定手順【手順 1、4】とファジィロジックにより静的  $P$ - $V$  曲線を推定する手順【手順 2、3】を 5 回繰返し、推定された静的  $P$ - $V$  曲線の推定精度つまり検証データとの圧力二乗和誤差について検証した。なお、観測雑音の影響でマイナスの値を取る  $V(t)$  については、ファジィ変数の値が存在せずファジィ推定が出来ないのでデータから除いて推定を行なった。推定に用いたファジィ変数は図 59 と同じである。図 62 は、各繰返し回数における推定静的  $P$ - $V$  曲線と検証データとの圧力二乗和誤差値推移図である。また、表 8 に各繰返し回数における推定静的  $P$ - $V$  曲線と検証データとの圧力二乗和誤差値をのせた。繰返し毎に推定静的  $P$ - $V$  曲線の推定精度が改善していくのがわかる。しかしながら、繰返し最適化を行なう毎に推定静的  $P$ - $V$  曲線の推定精度改善量が少なくなってくる。今後の課題としては、何回程度の非

線形肺エラストンス  $f_E(V)$  係数の繰返し最適化手法を行なうのが良いのか検証していく必要がある。図 63 は、提案手法を 5 回繰り返した時に推定された静的  $P$ - $V$  曲線とファジロジックを用いて推定した気道気圧上限値図である。表 9 を見ると、繰返し 1 回目と 5 回目では設定される気道気圧上限値が微妙に変化していくのが分かる。




図 62 各繰返し回数における検証データとの圧力二乗和誤差値推移図.

表 8 各繰返し回数における検証データとの圧力二乗和誤差値

	圧力二乗和誤差値
1 回目	0.319004 [cmH <sub>2</sub> O]
2 回目	0.318297 [cmH <sub>2</sub> O]
3 回目	0.317772 [cmH <sub>2</sub> O]
4 回目	0.317379 [cmH <sub>2</sub> O]
5 回目	0.317084 [cmH <sub>2</sub> O]

表 9 提案手法繰返し 1 回目と繰返し 5 回目でもとめた気道気圧上限値

	1 回目	5 回目
気圧上限値	5.9827[cmH <sub>2</sub> O]	5.9834[cmH <sub>2</sub> O]




図 63 提案手法で推定した静的  $P$ - $V$  曲線 (繰返し 5 回目) と検証データ.

## 12.5 本章のまとめ

本章では、非線形肺エラストンス  $f_E(V)$  係数の繰返し最適化手法を提案した。本手法は、肺エラストンス以外の項の係数推定手順と肺エラストンス項の係数推定手順を分離させることで、短時間では変化しない肺エラストンス以外の項の係数の統一化を図る手法である。実験では、提案手法によって静的  $P$ - $V$  曲線の精度が改善された。今後の課題としては、何回程度の非線形肺エラストンス  $f_E(V)$  係数の繰返し最適化手法を行なうのが良いのか検証していく必要がある。

## 13 ファジィロジックによる人工呼吸の換気条件の設定

### 13.1 既存の人工呼吸の換気条件設定法

本章では、ファジィロジックを用いた人工呼吸の換気条件設定について説明する。一般的に、人工呼吸の気道気圧上限値は静的  $P$ - $V$  曲線上の飽和開始点に設定するのが適切であるとされている。この飽和開始点は静的  $P$ - $V$  曲線上で曲率が一番大きい点にあたるとされる。既存の人工呼吸の換気条件設定法としては、静的  $P$ - $V$  曲線のような曲線に対して適切な回転変換を行なうことで変換後の関数を最大にする点に変換前の曲率最大点に対応することに着目し、推定で得た静的  $P$ - $V$  曲線に対して回転変換を施してから、その最大点をとるポイントを見つけるアプローチで、元の静的  $P$ - $V$  曲線上の飽和開始点を決定する手法がある。

具体的なアルゴリズムは以下の通りである。

#### Step1

推定で得られた静的  $P$ - $V$  曲線に基づき、区間  $[V_{min}, V_{max}]$  内で各  $V$  に対して  $P_\ell$  を計算し、データを次のような行列にまとめる。

$$S_o = \begin{bmatrix} P_{\ell 1} & \cdots & P_{\ell q} \\ V_1 & \cdots & V_q \end{bmatrix} \quad (155)$$

ここで、 $q$  はデータの数を表わす。

#### Step2

点  $(P_{\ell 1}, V_1)$  と点  $(P_{\ell q}, V_q)$  を結ぶ直線と横軸とでなした角度を  $\alpha$  とする。数軸を角度  $\alpha$  だけ反時計方向に回す回転角度  $T$  は次のように求まる。

$$L = ((P_{\ell q} - P_{\ell 1})^2 + (V_q - V_1)^2)^{1/2} \quad (156)$$

$$sa = -(V_q - V_1)/L \quad (157)$$

$$ca = (P_{\ell q} - P_{\ell 1})/L \quad (158)$$

$$T = \begin{bmatrix} ca & -sa \\ sa & ca \end{bmatrix} \quad (159)$$

### Step3

$S_o$  に対して回転変換を実行する。

$$S_T = TS_o = \begin{bmatrix} P_{T1} & \dots & P_{Tq} \\ V_{T1} & \dots & V_{Tq} \end{bmatrix} \quad (160)$$

### Step4

区間  $[P_{T1}, P_{Tq}]$  内で  $V_T$  が最大値をとる点  $P_{Tm} (1 < m < q)$  を探索する。

$$V_{Tm} = \max_{i=1, \dots, q} V_{Ti} \quad (161)$$

このときの添え字  $m$  は静的  $P$ - $V$  曲線上で曲率が最大になるポイントの添え字と同等であり，気道気圧上限値  $P_m$  が求まる。

以下に，参考として MATLAB プログラム例を記載する。

『% 回転変換で最大曲率を計算し，気圧上限値をもとめる手法

```
%step1
S0=[PP';V]; %PP は推定肺内圧力，V は肺体積
%step2
L=sqrt((PP(N)-PP(1))^2+(V(N)-V(1))^2); %N はデータ数
sa=-(V(N)-V(1))/L;
ca=(PP(N)-PP(1))/L;
T=[ca -sa; sa ca];
%step3
ST=T*S0;
%step4
VTm=ST(2,1:N);
[m, ind] = max(VTm(:))
Pm=PP(1,ind) % 気道気圧上限値 Pm
```

』

上記のように回転変換を用いて気道気圧上限値を求める手法が存在するが，問題点としては本手法が一般的な静的  $P$ - $V$  曲線の曲形にしか対応しない点である。静的  $P$ - $V$  曲線は人それぞれであり，必ずしも推定毎に一般的な形の静的  $P$ - $V$  曲線が推定されとは限らない。本論文で主に使用した患者データによる推定静的  $P$ - $V$  曲線は，一般的な静的  $P$ - $V$



曲線の形をしておらず (図 64), この曲線に回転変換を用いて気道気圧上限値を設定すると, 到底飽和開始点とは考えられない点に設定されてしまう。




図 64 回転変換でもとめた気圧上限値.

## 13.2 ファジロジックによる人工呼吸の換気条件の設定

本節では, 回転変換を用いた人工呼吸の気道気圧上限値設定の問題点を解消し, 静的  $P$ - $V$  曲線推定から人工呼吸の設定までを一貫したロジックで行なうための手法を述べる。

ここで重要なのは, ファジロジックの特徴点を人工呼吸設定に活かせるという点である。まずは, ファジロジックの特徴点について再度説明する。ファジ推論とは, 対象の特徴についてのおおまかな知識をもとに推論ルールを導き, ファジ推論法によってアルゴリズムを実行する。推論のために情報はいくつかの場合分けをし, if-then 型の論理的指令として表現される。対象の大まかな知識, 場合に応じた論理的指令というところに, エキスパートによる推論の特徴がみられる。ファジ推論を実際に適用するとき, 最初に問題になるのはファジ規則の設計である。従来の推論理論のように設計手法は確立されていないが, 設計の指針は整理されている。設計の考え方は, 想定される対象物の応答の色々なフェイズにおいて, どのような推論をすればよいかを記述するというものである。ファジ推論は (ファジ制御もだが), 目に見える又は分かっている状況で何をするのかというアルゴリズムから成り立っている。肺の研究では, 静的  $P$ - $V$  曲線に関して 3 つ




図 65 2 ルールによる入出力特性図.

の特徴的な傾き（呼吸開始部分，中央部分，飽和部分）をアルゴリズム（ファジィルール）に割り当てている。Mamdani のファジィ推論を設計するという事は，ファジィルールを記述することである。問題点としては，前件部と後件部の決定に分けられる。前件部については，第 1 点としてファジィ規則の前件部変数の選択が挙げられる。これは本研究では，前件部変数を肺体積  $V$  としている。第 2，3 点としては，条件の設定すなわち前件部変数空間のファジィ分割の決定とファジィ変数のパラメータの決定である。これらの問題点についてはアントコロニー最適化法で適切なファジィ変数空間の最適化おこない解消している。以上のように，多くの場合においてファジィ推論がうまくいくかどうかは，適切な情報の選択と条件付けにかかわっている。

また，複数個の法則からなるファジィモデルは対象物の非線形モデルであると推察される。ファジィモデルというのは，非線形システムの特性を複数個の線形システムの組合せで近似しようとするものである。どのような近似については，次の簡単な例でみる。

$$\begin{aligned}
 L^1 : & \text{if } x \text{ is small then } y = 0.6x + 2 \\
 L^2 : & \text{if } x \text{ is big then } y = 0.2x + 9
 \end{aligned} \tag{162}$$

これは，1 入力 1 出力システムを 2 つの規則でモデル化したものであるが，このファジィモデルの入出力特性は図 65 に示すようになる。 $L^1$ ， $L^2$  と書いた直線はそれぞれ，後件部の線形式のグラフである。図からわかるように，このファジィモデルは入力空間の "  $x$  is small " と "  $x$  is big " が重なる領域における出力を 2 つの法則からファジィ推論によって決めていることがわかる。本研究においても肺エラスタンス  $f_E(V)$  の後件部関数を一次

関数で表現していることから，最適なファジィ分割がなされていれば各後件部関数は静的  $P$ - $V$  曲線の特徴点を捉えて，分割の重なる領域で曲線（または最大曲率）が発生する事が分かる。

以上の点をふまえて，肺エラストランス推定のためのファジィルールにおいて，ファジィルールが適切に設定されている事を前提にすれば静的  $P$ - $V$  曲線中央部分表現ルール  $\text{if } V = \text{medium then } f_{E(\text{medium})} = k_{1(\text{medium})} + k_{2(\text{medium})}V$  と静的  $P$ - $V$  曲線飽和部分表現ルール  $\text{if } V = \text{big then } f_{E(\text{big})} = k_{1(\text{big})} + k_{2(\text{big})}V$  の間に飽和開始点が存在する事が容易に推察出来る。本研究では，静的  $P$ - $V$  曲線中央部分表現ルール  $f_{E(\text{medium})}$  の値と静的  $P$ - $V$  曲線飽和部分表現ルール  $f_{E(\text{big})}$  の値の大小関係が入れ替わる点を飽和開始点であると設定した。アルゴリズム及び MATLAB によるプログラム例については以下の通りである。

### Step1

ファジィ推論で得られた静的  $P$ - $V$  曲線中央部分表現ルール  $f_{E(\text{medium})}$  の値と静的  $P$ - $V$  曲線飽和部分表現ルール  $f_{E(\text{big})}$  の値に基づき，肺体積  $V(i) \{i = 1, \dots, N\}$  における両値の大小関係が逆転するデータ番号  $\text{ind}$  を探索する。

### Step2

Step1 で探索されたデータ番号  $\text{ind}$  に該当する推定肺内圧力値  $PP_{\text{fuzzy}}$  を，気道気圧上限値  $P_m$  に設定する。

$$P_m = PP_{\text{fuzzy}}(\text{ind}) \quad (163)$$

『%medium の曲線値と big の曲線値の大小関係が入れ替わるポイントの探索

```
for i=1:N
    if Medium_Value(i)<Big_Value(i)
        Pm=fuzzy_PP(i)
        break;
    end
end
```

』

ここで Medium\_Value は静的  $P$ - $V$  曲線中央部分表現ルール  $f_{E(\text{medium})}$  の値，Big\_Value は静的  $P$ - $V$  曲線飽和部分表現ルール  $f_{E(\text{big})}$  の値， $N$  はデータ数，fuzzy\_PP はファジィ推論で推定された肺内圧力である。

本手法の利点としては，回転変換による手法と比較して計算量が圧倒的に少ない点にあ

る。両手法のアルゴリズムを見比べてみれば分かると思うが、回転変換による手法は推定された肺内圧と肺体積を用いて新たな計算を行なっている。一方で、ファジロジックを用いた手法については、肺エラストランス推定におけるファジ推論値の大小関係を探索しているのみである。また、本手法は静的  $P$ - $V$  曲線の曲率に頼らない設定法であるため、回転変換手法において問題であった一般的な形をしていない静的  $P$ - $V$  曲線にも対応出来る。

図 66 は、本手法を用いて設定した人工呼吸の気道気圧上限値である。図では呼吸の飽和開始点付近に設定されているように見えるが、設定された値が適切であるか否かについては今後更なる検証が必要である。また、ファジルール及びファジ変数が適切に設計されていない場合においては本手法が使用出来ない事から、今後はアントコロニー最適化法の改良や新たな最適化法を用いて、より呼吸の特徴点を捉えられるアルゴリズムを開発していきたい。




図 66 ファジロジックでもとめた気圧上限値.

## 14 結論

本研究は、患者の肺特性に合わせた人工呼吸器設定法の開発を目的とした。これは、現在患者の体重などの外的要因と医師の経験と勘によって人工呼吸器が設定されており、明確な人工呼吸器の設定法がないためである。このような設定法では、未熟児など肺特性の推測が難しい患者に対しては設定出来ないという問題が出てくる。本研究では、患者の肺特性を表わすとされている静的  $P$ - $V$  曲線を推定し、静的  $P$ - $V$  曲線に基づいた人工呼吸器の気圧上限値設定を提案した。静的  $P$ - $V$  曲線を求めるためには肺の弾力特性を表わす肺エラストランスの推定が必要となるが、肺エラストランスをファジィロジック表現形式で推定する手法を提案した。ファジィロジックを用いた既存の推定手法においては他の肺エラストランス表現形式（多項式・RBF）による推定と比べ静的  $P$ - $V$  曲線の推定精度が著しく劣っていたが、推定精度が著しく劣る原因を考察し推定精度を向上させる手法を提案した。また、静的  $P$ - $V$  曲線に基づいた人工呼吸器の気圧上限値設定においてファジィロジックを用いて設定値をもとめる手法を提案することで、肺特性推定から人工呼吸器の設定までを一貫したロジックで行なった。各提案手法において、実際の臨床データを用いて静的  $P$ - $V$  曲線を求める推定実験を行ない提案手法が有効であることを証明した。今後の研究としては、各アルゴリズムの調整及び改良、ファジィロジックによりもとめた人工呼吸器の気圧上限値設定について臨床的な検証が必要である。

本研究で提案したファジィロジックを用いた肺エラストランスの推定と人工呼吸器の設定については、過去に同様の研究例がない新しい枠組みである。一貫したロジックで推定・設定・制御を行なうことで、「肺エラストランス推定時に設定されたファジィ変数をファジィ制御に応用する」、「ファジィ制御の結果を肺エラストランス推定に取り入れる」などの相乗効果が期待出来る。今後は人工呼吸器の制御に関しても研究を進めていき、多くの患者の生命を助けることが出来る研究に発展させていきたい。

## 参考文献

- [1] 岡本和文, ナーシングケア Q&A 人工呼吸器とケア Q& A -基本用語からトラブル対策まで-, 総合医学社 (2004)
- [2] 桜井靖久, 渡辺敏, ME 早わかり Q & A2 人工呼吸器 麻酔器 酸素療法用機器 吸入療法用機器 医療ガスの安全, 南江堂 (1987)
- [3] K. Muramatsu, K. Yukitake, M. Nakamura, I. Matsumoto, Y. Motohiro: Monitoring of Nonlinear Respiratory Elastance Using a Multiple Linear Regression Analysis, European Respiratory Journal 17, pp.1158-1166 (2001)
- [4] S. Kanae, K. Muramatsu, Z. J. Yang, K. Wada, Modeling of respiration and estimation of pulmonary elastance, 2004 ASCC, pp.648-651 (2004)
- [5] 金江春植, 呼吸システムのモデリングと人工呼吸の換気条件の設定について, 計測と制御, **Vol.49**-No.7, pp.485-488 (2010)
- [6] 浜田穂積, 近似式のプログラミング, 培風館 (1995)
- [7] J. ハーツ, A. クロー, R.G. パルマー, ニューラルコンピュータ 統計物理学からのアプローチ, 株式会社トッパン (1994)
- [8] 西川韓一, 北村新三, ニューラルネットと計測制御, 朝倉書店 (1995)
- [9] 伊理正夫, 藤野和建, 数値計算の常識, 共立出版株式会社 (1985)
- [10] 相良節夫, 趙振宇, 数値積分演算による連続系のオンライン同定, 電気学会論文誌, **Vol.108**-No.8, pp.603-610 (1988)
- [11] 足立修一, システム同定の基礎, 東京電機大学出版局 (2009)
- [12] 長町三生, ファジィ化製品開発の基礎と実際, 海文堂 (1991)
- [13] 田中英夫, 松岡浩, ファジィ数学モデル, オーム社 (1992)
- [14] 坂和正敏, ファジィ理論の基礎と応用, 森北出版株式会社 (1989)
- [15] 菅野道夫, ファジィ制御, 日刊工業新聞社 (1988)
- [16] 湯場崎直養, 易建強, 廣田薫, 複数入力ファジィ制御のための単一入力ルール群結合型ファジィ推論モデルの提案, 日本ファジィ学会誌 **Vol.9**, No.5, pp.699-709 (1997)
- [17] 関宏理, 石井博昭, 水本雅晴, 関数型 SIRMs 結合型ファジィ推論法による非線形同定に関する一考察, 数理解析研究所講究録 2006, **Vol.1526**, pp.173-180 (2006)
- [18] 小林一行, MATLAB 活用ブック, 株式会社秀和システム (2001)
- [19] 高谷邦夫, Matlab の総合応用-例題による応用-, 森北出版 (2002)
- [20] 上坂吉則, MATLAB プログラミング入門, 牧野出版 (2000)

- [21] アジス・アブラハム, クリナ・グローサン, ヴィトリーノ・ラモス, 群知能とデータマイニング, 東京電機大学出版局 (2012)
- [22] 大内東, 山本雅人, 川村秀憲, 柴肇一, 高柳俊明, 當間 愛晃, 遠藤 聡志, 生命複雑系からの計算パラダイム, 森北出版 (2003)
- [23] Blum, C., The hyper-cube framework for ant colony optimization, Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on, **Vol.34**, pp.1161-1172 (2004)
- [24] Dorigo, M., Ant colony optimization, Computational Intelligence Magazine, IEEE, **Vol.1**, pp.28-39 (2006)

## 発表論文リスト

- [1] S. Kanae, M. Nakamichi, Z.J. Yang, K. Wada: Pulmonary elastance estimation considering respiratory periodicity, Proceedings of the International Conference on Intelligent Control and Information Processing(ICICIP2010) (2010)
- [2] S. Kanae, M. Nakamichi, Z.J. Yang, K. Wada: A New Respiratory Model considering Hysteresis for Artificial Respiration, Proceedings of the IFAC International Workshop on Adaptation and Learning in Control and Signal Processing(ALCOSP2010) (2010)
- [3] 中道正紀, 金江春植: ファジィロジックによる肺エラスタンスのモデリングと推定, 第 53 回自動制御連合講演会 (2010)
- [4] 中道正紀, 金江春植: ファジィ推論法を用いた肺エラスタンスと静的 P-V 曲線の推定, 福井工業大学研究紀要 第 41 号 (2011)
- [5] M. Nakamichi, S. Kanae, Z.J. Yang, K. Wada: Estimation of pulmonary elastance by functional type SIRMs fuzzy reasoning method, The 30th CCC (2011)
- [6] 中道正紀, 金江春植: ファジィロジックを用いた肺エラスタンスの推定について-後件部関数の表現形式に関する一考察, 平成 23 年度電気関係学会北陸支部連合大会 (2011)
- [7] 中道正紀, 金江春植: 関数型 SIRMs ファジィ推論法による肺エラスタンス推定の後件部関数表現形式について, 第 54 回自動制御連合講演会 (2011)
- [8] 中道正紀, 金江春植: ファジィ推論法の後件部関数表現形式による静的 P-V 曲線推定への影響について, 福井工業大学研究紀要 第 42 号 (2012)
- [9] M. Nakamichi, S. Kanae, Z.J. Yang, K. Wada: Estimation of pulmonary elastance fuzzy model by data combination of two respiration phases, The 2012 UKACC International Conference on Control (2012)
- [10] 中道正紀, 金江春植: アントコロニー最適化手法を用いた肺エラスタンスのファジィ推定におけるファジィ変数の決定について, 第 55 回自動制御連合講演会 (2012)
- [11] 中道正紀, 金江春植: ファジィロジックを用いた人工呼吸器の設定に関する研究, 第 13 回計測自動制御学会制御部門大会 (2013)
- [12] 中道正紀, 金江春植: ファジィロジックを用いた肺エラスタンス推定におけるアントコロニー最適化法について, 福井工業大学研究紀要 第 43 号 (2013)
- [13] S. Kanae, M. Nakamichi: An ant colony optimization method for fuzzy membership functions and its application to estimate the pulmonary elastance, The 33th CCC (2013)



[14] M. Nakamichi, S. Kanae, K. Uosaki: Estimation of the pulmonary elastance and setting of the ventilation condition using fuzzy logic, The 45th ISCIE International Symposium on Stochastic Systems Theory and Its Applications (SSS2013) (2013)

## 付録 A

本論文における実験で使用した患者データ数について，データ総数と各ファジィ変数範囲のデータ数を載せる。

[ファジィロジックを用いた既存の肺エラスタンス推定手法]

表 A-1 推定事例 1 のデータ表

データ総数	<i>small</i> 範囲のデータ数	<i>medium</i> 範囲のデータ数	<i>big</i> 範囲のデータ数
吸気 121 呼気 278	吸気 32 呼気 240	吸気 121 呼気 278	吸気 95 呼気 49

表 A-2 推定事例 2 のデータ表

データ総数	<i>small</i> 範囲のデータ数	<i>medium</i> 範囲のデータ数	<i>big</i> 範囲のデータ数
吸気 111 呼気 117	吸気 22 呼気 87	吸気 111 呼気 117	吸気 89 呼気 30

[ファジィルール後件部関数表現形式が推定精度へ与える影響について]

表 A-3 推定事例 1 のデータ表

データ総数	<i>small</i> 範囲のデータ数	<i>medium</i> 範囲のデータ数	<i>big</i> 範囲のデータ数
吸気 121 呼気 278	吸気 32 呼気 240	吸気 121 呼気 278	吸気 95 呼気 49

表 A-4 推定事例 2 のデータ表

データ総数	<i>small</i> 範囲のデータ数	<i>medium</i> 範囲のデータ数	<i>big</i> 範囲のデータ数
吸気 111 呼気 117	吸気 22 呼気 87	吸気 111 呼気 117	吸気 89 呼気 30

[区間データ結合を用いたファジィ推論法]

表A-5 CASE1 のデータ表

データ総数	<i>small</i> 範囲のデータ数	<i>medium</i> 範囲のデータ数	<i>big</i> 範囲のデータ数
吸気 121 呼気 278	吸気 32 呼気 240	吸気 121 呼気 278	吸気 95 呼気 49

表A-6 CASE2 のデータ表

データ総数	<i>small</i> 範囲のデータ数	<i>medium</i> 範囲のデータ数	<i>big</i> 範囲のデータ数
吸気 121 呼気 219	吸気 61 呼気 190	吸気 121 呼気 219	吸気 87 呼気 63

[非線形肺エラスタンス  $f_E(V)$  係数の繰返し最適化手法について]

表A-7 推定実験のデータ表

データ総数	<i>small</i> 範囲のデータ数	<i>medium</i> 範囲のデータ数	<i>big</i> 範囲のデータ数
吸気 121 呼気 278	吸気 32 呼気 240	吸気 121 呼気 278	吸気 95 呼気 49

## 謝辞

本研究を行なうにあたり，研究に集中出来る環境を与えていただいた福井工業大学に深く御礼申し上げます。

また，論文作成に際し様々な御指導と御助言を頂きました金江春植教授，鹿間敏弘教授，山西輝也教授に対しましては深く感謝申し上げます。金江春植教授には，研究室に5年間在籍する中で研究に関することばかりでなく，研究者としての姿勢など様々なことを学ばせていただきました。先生から学んだ知識・経験は私にとってかけがえのない物となっています。ここに謹んで感謝の意を表わし，厚く御礼申し上げます。

加えて，5年間の研究室生活を過ごした同輩や後輩にも大変お世話になりました。私が，楽しく勉学や研究に励むことが出来たのも皆様のおかげであり深く感謝申し上げます。

最後に，本学大学院に入学し，素晴らしい先生方や同輩に出会う事が出来ました。本学大学院を紹介して頂いた父 中道義忠（元福井工業大学准教授）にも深く感謝申し上げます。