

ニュートラルネットワークを用いた軟性膀胱鏡画像からの操作推定

メタデータ	言語: jpn 出版者: 公開日: 2017-10-05 キーワード (Ja): キーワード (En): 作成者: メールアドレス: 所属:
URL	http://hdl.handle.net/2297/34833

博 士 論 文

ニューラルネットワークを用いた 軟性膀胱鏡画像からの操作推定

金沢大学大学院 自然科学研究科

電子情報科学専攻

知能情報・数理 講座

学 籍 番 号 0623112110

氏 名 金谷 二郎

主任指導教官氏名 木村 春彦

目次

第 1 章	はじめに	1
1.1	研究背景	1
1.2	本論文の構成	4
第 2 章	研究の対象	6
2.1	膀胱内壁	6
2.2	軟性膀胱鏡検査	9
第 3 章	本研究の目的と意義	12
第 4 章	膀胱内壁の画像認識の困難さ	14
第 5 章	提案システム	15
5.1	オプティカルフローの抽出	15
5.2	フレームの特徴データ	15
5.3	特徴データのクリーニング	16
5.3.1	外れ値の除去	16
5.3.2	欠損値の補間	17
5.4	更なる精度向上	18
5.5	軟性膀胱鏡操作の推定	19
第 6 章	評価実験	22

6.1	実験環境	22
6.1.1	対象	22
6.1.2	使用機器	22
6.1.3	動画の前処理	23
6.1.4	オプティカルフロー推定法について	23
6.1.5	マハラノビス距離の閾値	23
6.1.6	学習の終了条件	24
6.2	比較実験	24
6.2.1	実験1 停止を考慮しない実験	26
6.2.2	実験2 停止を考慮する実験	29
第7章 考察		31
7.1	提案手法の学習モデルの検定	31
7.2	Mahalanobis Outlier Analysis の閾値	32
7.3	ニューラルネットワークの学習終了条件	32
7.4	操作の速さと移動距離	33
7.5	提案システムの有用性	34
第8章 結論		36
謝辞		37
参考文献		38
付録		39

目 次

1.1	泌尿器科疾患の年次推移	1
1.2	硬性膀胱鏡	2
1.3	軟性膀胱鏡	2
1.4	男性の尿道	3
2.1	膀胱	7
2.2	膀胱展開図	7
2.3	各部位の膀胱鏡画像	8
2.4	軟性膀胱鏡	10
2.5	軟性膀胱鏡の操作法	10
3.1	仮想膀胱	12
3.2	仮想膀胱観察部位の着色	13
5.1	オプティカルフロー	16
5.2	ブロックマッチング法	16
5.3	特徴データとしてのオプティカルフロー	17
5.4	欠損値の補間	18
5.5	操作変更時に停止を挿入する	18
5.6	単一中間層ニューラルネットワーク	20
5.7	操作推定用ニューラルネットワーク	20

表 目 次


5.1	推定される軟性膀胱鏡操作	19
6.1	各操作別のフレーム数 (比率変更なし)	25
6.2	各操作別のフレーム数 (フレーム比率 4:4:5)	25
6.3	各操作別のフレーム数 (フレーム比率 1:1:1)	26
6.4	学習データでの判別率 (停止を考慮しない、データ比率変更なし)	27
6.5	テストデータでの判別率 (停止を考慮しない、データ比率変更なし)	28
6.6	学習データでの判別率 (停止を考慮しない、データ比率 4:4:5)	28
6.7	テストデータでの判別率 (停止を考慮しない、データ比率 4:4:5)	28
6.8	学習データでの判別率 (停止を考慮しない、データ比率 1:1:1)	29
6.9	テストデータでの判別率 (停止を考慮しない、データ比率 1:1:1)	29
6.10	学習データでの判別率 (停止を考慮する、データ比率変更なし)	30
6.11	テストデータでの判別率 (停止を考慮する、データ比率変更なし)	30
7.1	実験 1 における提案手法の F1 値 (データ比率変更なし)	32
7.2	実験 1 における提案手法の F1 値 (データ比率 4:4:5)	33
7.3	実験 1 における提案手法の F1 値 (データ比率 1:1:1)	34
8.1	仮想膀胱における各部位の定義	45

第1章

はじめに

1.1 研究背景

日本社会の高齢化に伴い、泌尿器疾患による死亡者数は増加している [1]。膀胱癌の罹患患者数、膀胱癌による死亡者数も図 1.1 に示すように年々増加している。



国立がん研究センターがん対策情報センター 地域がん登録全国推計によるがん罹患データ(1975年～2005年)
人口動態統計によるがん死亡データ(1958年～2009年)

図 1.1: 泌尿器科疾患の年次推移

CT、MRI、超音波断層検査など非侵襲的な画像検査の解像度が向上したおかげで、非侵襲的な検査のみで膀胱腫瘍が指摘される症例も存在するが、小さい病変の診断は困難である。それ故、現時点では膀胱癌の診断には膀胱鏡検査が不可欠である。膀胱鏡には大きく

分けて2つの型が存在する。一つは硬性膀胱鏡（図 1.2）、もう一つは軟性膀胱鏡（図 1.3）である。硬性膀胱鏡は、1886年にドイツの Maximilian Carl-Friedrich Nitze（1848-1906）によって実用化された [2]。今日に至るまで基本的な形状は変化していない。明るくて鮮明な視野、簡単で直感的な操作性が多くの泌尿器科医に好まれ、現在でも多くの泌尿器科医が愛用している [3]。



図 1.2: 硬性膀胱鏡



図 1.3: 軟性膀胱鏡

しかし、図 1.4 に示すように、男性の尿道は生理的にはS字状に屈曲しているにもかかわらず、硬性膀胱鏡を挿入する際には、尿道を強引に直線状にするため、男性患者に与え

る苦痛はかなり強い。




図 1.4: 男性の尿道

それに対し、軟性膀胱鏡は1960年代に実用化されたが、当時の軟性膀胱鏡はひどく解像力が低かった。ファイバースコープの画像は、原理的には1画素が1本のガラスファイバーで担っている。実用的な太さに束ねることが可能なガラスファイバーの本数は限られており、解像力は自ずと限定されていた。1980年代、先端に荷電結合素子 (CCD: Charge Coupled Device) を搭載した軟性膀胱鏡が実用化された。初期の CCD の解像度は非常に低かったが、シリコンデバイスの飛躍的な進歩に伴い CCD の解像度は向上し、近年では臨床使用に問題ないレベルとなった。軟性膀胱鏡は柔軟で男性尿道の生理的屈曲に追従する

ため、患者に与える痛みが少ない。患者の生活の質 (QOL: quality of life) が強調される今日、痛みの少ない軟性膀胱鏡を導入する病院が増加している。

硬性膀胱鏡と軟性膀胱鏡には操作性に大きな違いがある。硬性膀胱鏡は「剛体」とみなすことができ、接眼レンズ側の動きが直接対物レンズ側に伝わる。したがって対物レンズが向いている方向を容易に推定でき、直感的な操作が可能である。それに対し、軟性膀胱鏡は先端の屈曲、軸方向の回転、挿入深度を調節しながら観察を行うことが必要であり、意図した部位を観察するには熟練を要する。また、ある程度、軟性膀胱鏡操作に習熟した泌尿器科医であっても膀胱内腔全体を観察できたかどうか、不安に思うこともある。この点が軟性膀胱鏡の欠点であり、最大の課題である。近年、超音波検査、CT、MRIなどの画像検査装置の臨床現場への普及が進み、高解像度の volume data の取得が容易となった。その volume data を基に3次元再構築された臓器を観察する仮想内視鏡が発表されている [4][5]。しかし、これらのシステムは事前のCT、MRIなどが必要である。また、費用が高く、長時間かかるため、仮想内視鏡の泌尿器科領域の臨床現場への導入はほとんど進んでいない。

それ故、軟性膀胱鏡検査の際の見落としを防ぐシステムの開発が急務となっている。このたび、このシステムの前段階として、軟性膀胱鏡の動画からオプティカルフローを基にニューラルネットワークを用いて軟性膀胱鏡の先端屈曲、軸方向の回転、挿入深度の操作を推定するシステムを開発したので報告する。

尚、類似研究として文献 [6] があるが、この研究では仮想気管支鏡を事前に準備し、やはり事前にCT、MRIを施行して volume data を取得し、その後3次元再構築を行なっている。事前のCT、MRIは時間的、経済的、心理的なコストが患者、医師双方にとって大きく、無視できない。また、CTの場合は患者への放射線被爆もある。本研究は『事前』と『準備』を必要とせず、軟性膀胱鏡が既に導入されている施設であれば、画像出力の段階で本システムを付加することができる。更に、膀胱内壁は特徴と言えるものが少なく、オプティカルフローを正確に求めることが困難であり、これまで膀胱内壁の自動画像認識を扱った研究はほとんど見あたらない。

1.2 本論文の構成

本論文の構成は以下の通りである。

第2章では、研究対象である膀胱と軟性膀胱鏡検査について説明する。

第3章では、本研究の目的と意義について述べる。

第4章では、本研究の対象である膀胱内壁の画像認識の困難さについて説明する。

第5章では、本研究で提案する軟性膀胱鏡検査における検査済み範囲の推定法について述べる。

第6章では、軟性膀胱鏡動作推定の評価実験と考察を行う。

第7章では、研究経過に浮上した本研究対象の問題点や、それを踏まえた今後の課題についての考察を行う。

第8章では、本論文の結論を述べ、今後の展望についてふれる。

第2章

研究の対象

本章では、研究対象である膀胱内壁と膀胱鏡検査について述べる。

2.1 膀胱内壁

膀胱 (urinary bladder) は腎臓 (kidney) から送られてくる尿を一時的に溜めておく、拳ほどの大きさの袋状の臓器である。膀胱には図2.1のように3つの開口を有しており、それぞれ右尿管口 (right ureteral orifice)、左尿管口 (left ureteral orifice)、内尿道口 (internal urethral orifice) という。三角部 (trigone) の左右に展開する尿管口は、尿管 (ureter) という管を通して左右の腎臓と繋がっており、そこから尿が送られてくる。一方、内尿道口は尿道 (urethra) に繋がっており、そこから外部に尿を排出している。

尿管口や内尿道口以外にも、膀胱内壁にはそれぞれ名前がつけられており、図2.2のように頂部 (dome)、右側壁 (right side wall)、左側壁 (left side wall)、前壁 (anterior wall)、後壁 (posterior wall)、三角部 (trigone)、頸部 (bladder neck) の7つに分割されている。

これらの部位の例として、ある患者の各部位の画像を図2.3(a) ~ (i) に示した。また、参考までに別の患者の一部の部位を図2.3(j) ~ (l) に示した。これらの部位の中で、特に特徴の強い外観をしている部位は、三角部と頸部の2つである。三角部は、頂部や後壁といった他の部位の粘膜とは発生母地が異なるために、図2.3(g)のように多少異なった外観を呈している。三角部の特徴は全体に若干隆起していること、そして粘膜下の血管が網状であることである。また、内尿道口の周辺にあたる頸部も全体に隆起しており、粘膜下の血管は周囲に比較して拡張している。図2.3(h)内に見える黒いチューブは軟性膀胱鏡自身である。これら2つの部位や、前述した尿管口や内尿道口といった比較的特徴のある部位は、

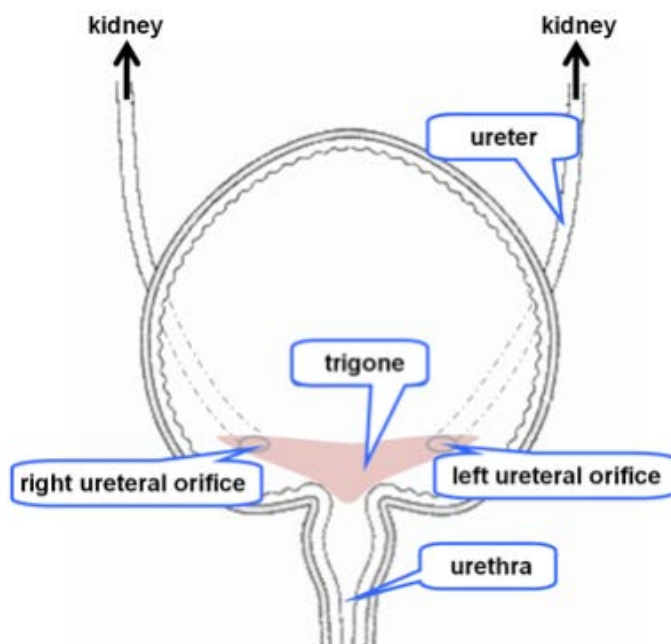


図 2.1: 膀胱




図 2.2: 膀胱展開図



図 2.3: 各部位の膀胱鏡画像

膀胱の入り口、つまり内尿道口周辺に密集している。この他の頂部、右側壁、左側壁、前壁、後壁といった部位は医学上形式的に部位分けされているだけで、同様な粘膜、同様な形状で構成されている。このため、それらの外観に大きな差はなく、区別しにくいことから、軟性膀胱鏡検査で観察部位が把握し難い要因の一つとなっている。

また、異なる人物間で同じ部位を比較した場合、形状が必ずしも同じになるとは限らない。例えば、右尿管口を見てみると、図 2.3(c) のように、穴のような形状が見て取れるものもあれば、図 2.3(1) のように尿管口が閉じられ、見た目上、穴の形状は無く、ただ凹みのようなものがあるだけのものもある。他にも、側壁、頂部などの部位に関しても、人によって膀胱内壁面に見えている血管の太さ、粘膜質の色や内壁の隆起具合といったものが異なっており、これらも画像のみによる観察位置の把握を困難にしている。

2.2 軟性膀胱鏡検査

軟性膀胱鏡検査は、柔軟性を有している管を、直接尿道から挿入して内部の状態を確認する泌尿器科の検査法の一つである。軟性膀胱鏡は、図 2.4 のようにその管の先端に CCD カメラと光源が取り付けられており、これによって尿道や膀胱内部の映像を取得し、モニターに出力することで医師は観察することができる。検査の具体的な手順は、①尿道からジェル状の麻酔薬を注入し、検査に伴う疼痛の抑制を図る。②灌流液（生理食塩水）を注入しながら軟性膀胱鏡を外尿道口から挿入し、尿道内部を観察しながら、その奥にある膀胱に至る。③膀胱内部を灌流液で満たし膨張させることで、軟性膀胱鏡先端の可動範囲を確保し、膀胱内壁を十分観察する。軟性膀胱鏡を用いて膀胱内部の検査を行う際には、次の3つの操作を複合的に用いている。

- 挿入深度の変更
- 膀胱鏡先端の屈曲
- 膀胱鏡自体の回転

1つ目の操作である「挿入深度の変更」とは、図 2.5 の (1) のように軟性膀胱鏡自体を膀胱奥へ向けて挿入したり、膀胱外へ向けて引き抜くような操作のことである。2つ目の操作である「膀胱鏡先端の屈曲」とは、図 2.5 の (2) のように先端を屈曲させる操作のことである。

ある。これは、軟性膀胱鏡の手元にあるレバーを操作することによって屈曲をさせることができ、図 2.5 の膀胱鏡先端が表記する範囲に屈曲可能である。3つ目の操作である「膀胱鏡自体の回転」とは、図 2.5 の(3)のように挿入方向を軸として、膀胱鏡自体を回転させる操作である。これらの操作を複合的に用いることで、膀胱内壁全てを網羅することができる。具体的な検査の例をあげると、検査で右尿管口を観察したい場合は、まず膀胱内に軟性膀胱鏡を挿入し、手元のレバーによって膀胱鏡の先端を屈曲させる。その後、時計回りに膀胱鏡を回転させ、その回転角度や挿入深度を調整することによって、右尿管口の周囲の観察を行うことが可能となる。このように3つの操作を複合的に用いて、挿入深度・屈曲角度・回転角度を調整していくことで、全ての部位を観察することができる。




図 2.4: 軟性膀胱鏡




図 2.5: 軟性膀胱鏡の操作法

軟性膀胱鏡検査において医師は、モニターに映し出されている観察部位の位置を、軟性膀胱鏡の挿入深度や屈曲状態等の操作状況や、その周辺におけるランドマークから推定を行っている。ここでランドマークと述べている部位には、三角部・頸部・左右尿管口・内尿

道口の4つの部位と、軟性膀胱鏡検査時の灌流液の注入によって発生する気泡である。三角部・頸部・左右尿管口・内尿道口の部位に関しては、前述したように、他の部位に比べ、色や形状に若干の特徴を有している。そのため、医師はこれらの部位を画像中に発見すると、それらを基準として、そのランドマークまでに至った経緯や、その先の進行方向の位置を推測していく。気泡に関しても同様で、空気は灌流液よりも軽いため、検査中は上方に行こうとする。検査時には患者は仰向けに寝ていることから、前壁に気泡が集まることが多い。このため、医師は気泡を見つけた場合、その画像は前壁周辺を観察していると判断することができる。しかし、気泡は検査によっては生じていない場合や、膀胱内壁の窪みに掛かり、前壁とは異なる部位に貯留することもある。常にランドマークとして用いることができる訳ではない。

第3章

本研究の目的と意義

本研究では、軟性膀胱鏡の動画から軟性膀胱鏡の操作を推定することを目的としている。このことが達成できれば、第二段階の研究として、軟性膀胱鏡の一操作の継続時間や移動距離を推定することになる。これが可能となれば、仮想膀胱（図 3.1）内での軟性膀胱鏡のカメラの先端位置と向きが推定され、仮想膀胱壁に視認される範囲を記録（色付け）することにより、図 3.2 のような視認された範囲（検査済み範囲）と見落としの範囲が推定可能となる。これにより、従来、たまたま見落としした範囲に癌化している箇所があつて、手遅れになっていたようなケースを減らすことが可能となり、泌尿器科学全体で多大な貢献ができる。

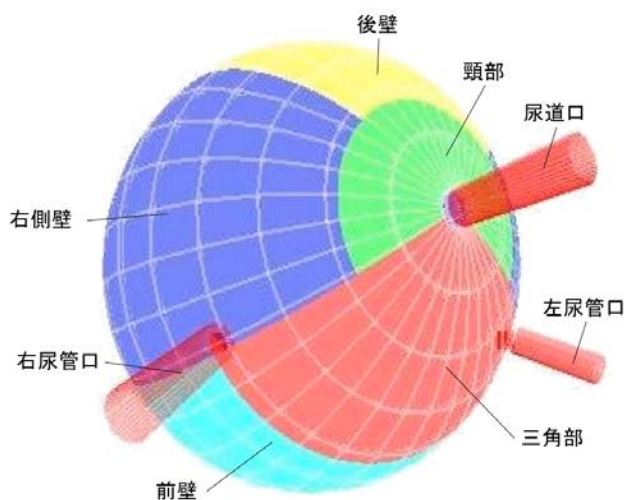


図 3.1: 仮想膀胱

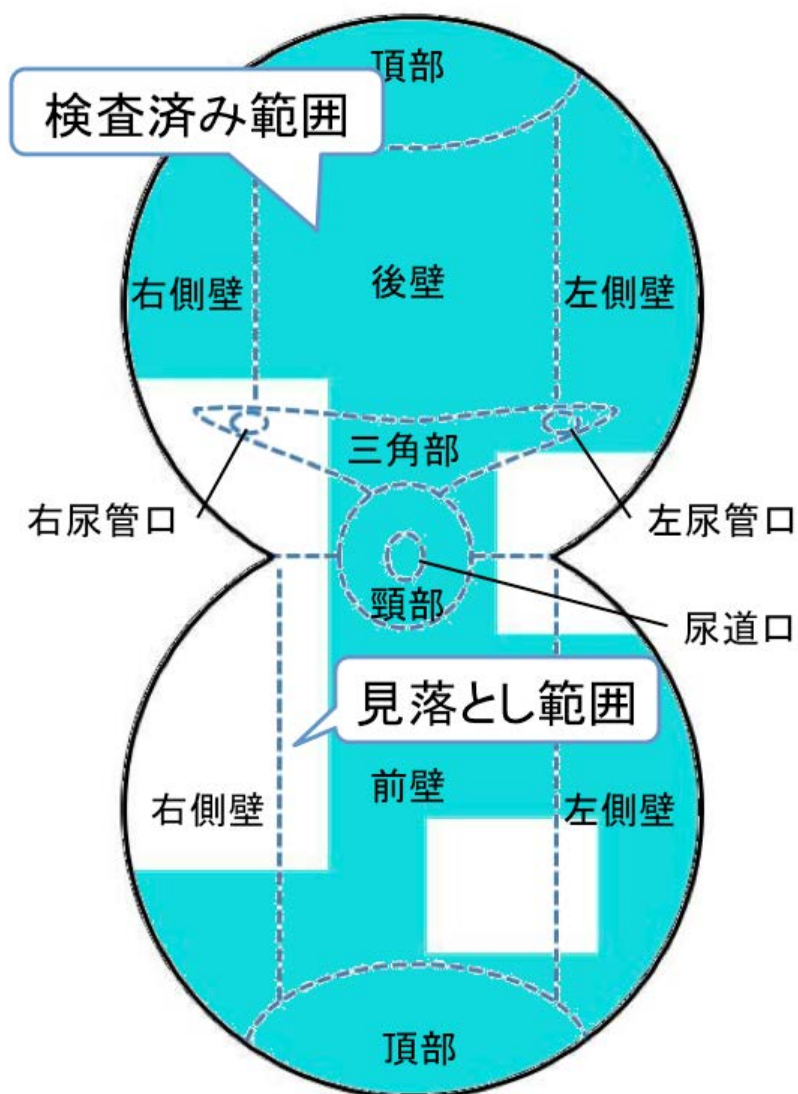


図 3.2: 仮想膀胱観察部位の着色

第4章

膀胱内壁の画像認識の困難さ

軟性膀胱鏡の動画から軟性膀胱鏡の操作を推定するためには、画面上に映っている部位が、特徴的である必要がある。第3章でも述べたが、膀胱内壁の中で比較的特徴が強い部位は三角部、頸部、左右尿管口、内尿道口の4つと数が少ない上に、これらは内尿道口の周辺に集まっている。そして、この他の部位に関しては、ほぼ同じような色や形状の粘膜で構成されており、それぞれの外観に大きな異なりがない。更に人によっても膀胱内壁の隆起具合や色が多少異なっている。つまりランドマークとなりうる特徴部位が極端に少ないという状況、またそれらが膀胱内の一部に集まっていること、そして患者が変わることで同じ部位であっても必ずしも共通する外観を得ることができないことから、特徴部位検出などの手法によって、対象フレームが膀胱内壁のどの部位にあたるかを推定することは大変困難である。また、特に次の場合が最も困難である。

- (a) 生理食塩水を注入しながら軟性膀胱鏡検査をしなければならないときがあり、このようなときは流体の渦巻きができる。
- (b) 軟性膀胱鏡の先端に付けられている光源によりハレーションが発生すると、強い光の当たった部分の周りが白くぼやける。

第5章

提案システム

本研究では、軟性膀胱鏡画像のフレーム間の変化、つまりオプティカルフロー [7] に着目し、軟性膀胱鏡の各操作のオプティカルフローをニューラルネットワークを用いて学習させることにより軟性膀胱鏡の操作を推定する。

5.1 オプティカルフローの抽出

軟性膀胱鏡から得られる動画は、1秒間当たり約30枚のフレームで実現されている。オプティカルフローとは、観測者と物体との間の相対的な運動によって生じる、画面上の見かけの速度分布を表したもので、第 n 番目のフレームと第 $n+1$ 番目のフレームを比較し、類似する箇所（ブロック）を抽出し、両者を対応付けることで推定する。オプティカルフローの推定法としては、大分して勾配法とブロックマッチング法 [8] の2種に分類することができる。勾配法は、ブロックマッチング法に比べて短時間でオプティカルフローを推定できるが、輝度値が急激に変化するところではフローの誤差が激しく、また雑音に弱いという欠点があることから、本研究ではブロックマッチング法を用いた。ブロックマッチング法とは、連続したフレーム間で類似したブロックを検索し、最も類似度の高いブロックとの差を動きベクトルとするものである。具体例を図5.2に示す。

5.2 フレームの特徴データ

フレームの特徴を表すデータを特徴データと呼ぶことにする。本システムでは、フレームを図5.3のように 10×10 のマスの分割し、各マスのオプティカルフローを1本のオ




図 5.1: オプティカルフロー




図 5.2: ブロックマッチング法

プティカルフローで代表させる。尚、オプティカルフローは原点を中心とした x 座標と y 座標のベクトル値 (dx, dy) で表すことができる。 i 行 j 列目のマスの代表オプティカルフローはマス内のオプティカルフローの x 座標のベクトル値の平均値 $dx(i, j)$ と、 y 座標のベクトル値の平均値 $dy(i, j)$ で表す。つまり、フレームの特徴データは 200 個のデータ $dx(1, 1), dy(1, 1), dx(1, 2), \dots, dy(10, 10)$ で構成される。

5.3 特徴データのクリーニング

データを以下のようにクリーニングする。

5.3.1 外れ値の除去

次に単位ベクトル化した特徴データの代表オプティカルフローに対してマハラノビス距離を求め、外れ値となるベクトルを探して除去する。用いる手法は Mahalanobis Outlier




図 5.3: 特徴データとしてのオプティカルフロー

Analysis[9][10]である。また、マハラノビス距離とは、母集団の分散に基づいて算出される距離の尺度であり、母集団の重心と標本との距離を示している。

5.3.2 欠損値の補間

外れ値の除去によって生じた単位ベクトル化された代表オプティカルフローの欠損値を次のようにして補間する。図 5.4 のように、欠損値の周辺 8 近傍に対し、1 つでも代表オプティカルフローがあれば、その平均値を欠損箇所の値として補間する。また、代表オプティカルフローが一つもない（全て欠損値）場合には、更に一回り大きな近傍領域、つまり 24 近傍領域を調べ、平均値をとり欠損値を補間する。このようにして、近傍領域の欠損状態に合わせて補間に用いる領域を変化させ、周辺近傍のオプティカルフローの傾向をとり入れた形で欠損値を補間していく。

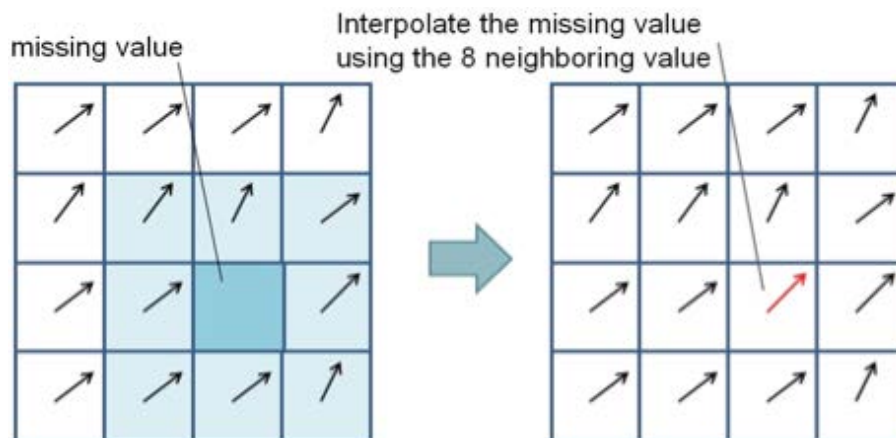


図 5.4: 欠損値の補間

5.4 更なる精度向上

膀胱鏡操作において、同一操作を連続して行い、他の操作に移る際には一旦停止させてから行うように義務づけてもらう（図 5.5）と操作判別の精度が向上する。なぜならば、停止するまでの操作は変わらないので、操作判別に多数決理論が使えるからである。一画像あたりの操作判別率が低くても、高い判別精度が期待できる。しかもこの方法は画像自体の判別手法に依存しないので、多くの操作判別の精度向上に応用可能である。

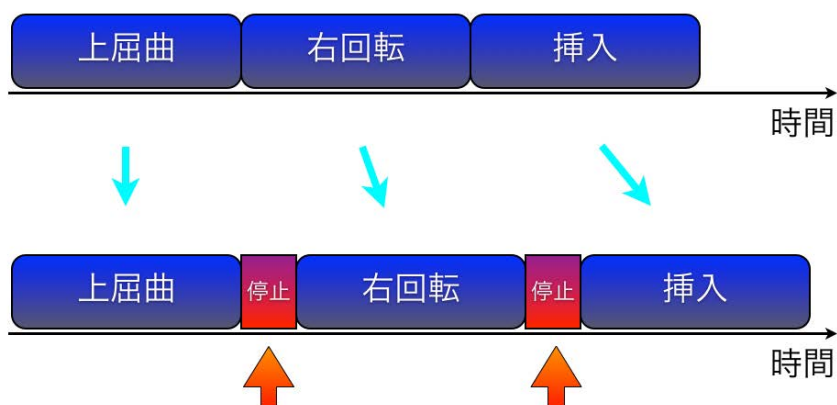


図 5.5: 操作変更時に停止を挿入する

5.5 軟性膀胱鏡操作の推定

オプティカルフローからニューラルネットワーク [11] を用いて軟性膀胱鏡の操作を推定する。本システムでは、図 5.6 のように入力層、中間層、出力層の層状に人工ニューロンを配置した、単一中間層の階層型ニューラルネットワークを用いる。また、1つの階層型ニューラルネットワークによって全ての操作を推定するのではなく、図 5.7 のように3つの階層型ニューラルネットワークの組み合わせによって操作を推定する。これは、この3つの階層型ニューラルネットワークに、それぞれ「挿入深度の変更」、「先端の屈曲操作」、「膀胱鏡の回転操作」の操作を割り当て、フレームの特徴データが入力されたときに、各操作を担当する階層型ニューラルネットワークが表 5.1 で表される操作の推定を出力する。例えば、上に屈曲する操作のフレームの特徴データが入力されると、「挿入深度の変更」は NULL（それらを伴わないその他の操作）、「先端の屈曲操作」は上屈曲、「膀胱鏡の回転操作」は NULL（それらを伴わないその他の操作）と出力する。なお、ニューラルネットワーク1個だけで軟性膀胱鏡の操作を推定することも可能である。この場合、膀胱鏡の操作は全27通りあるため、ニューラルネットワークによる判別は27通りとなる。このような多クラス分類では、比較的少数クラスの分類と比較して、計算論理が複雑で正解の候補が絞りにくく、また、あるクラスに偏って判別されるといったことが起こりやすくなる。一方、膀胱鏡の操作を各単一操作（回転操作・屈曲操作・挿入操作）に分ける場合、各単一操作に対してそれぞれ3通りの判別となるため、27通りの判別と比較して、正解データが絞り易くなる。

handles for the cystoscope	details of the estimation		
changes of insertion depth	push	pull	the other handles
bending of the tip	up	down	the other handles
rotation for cystoscope	right	left	the other handles

表 5.1: 推定される軟性膀胱鏡操作

また、各操作を担当する階層型ニューラルネットワークが操作を推定するためには、事前に学習を行っておく必要がある。本システムでは、その学習法として誤差逆伝播法 [12] を用いた。誤差逆伝播法とは、ある入力におけるニューラルネットワークの出力と、その入力の理想的な出力（教師データ）を比較し、その差をできるだけ小さくするように、ニュー




図 5.6: 単一中間層ニューラルネットワーク

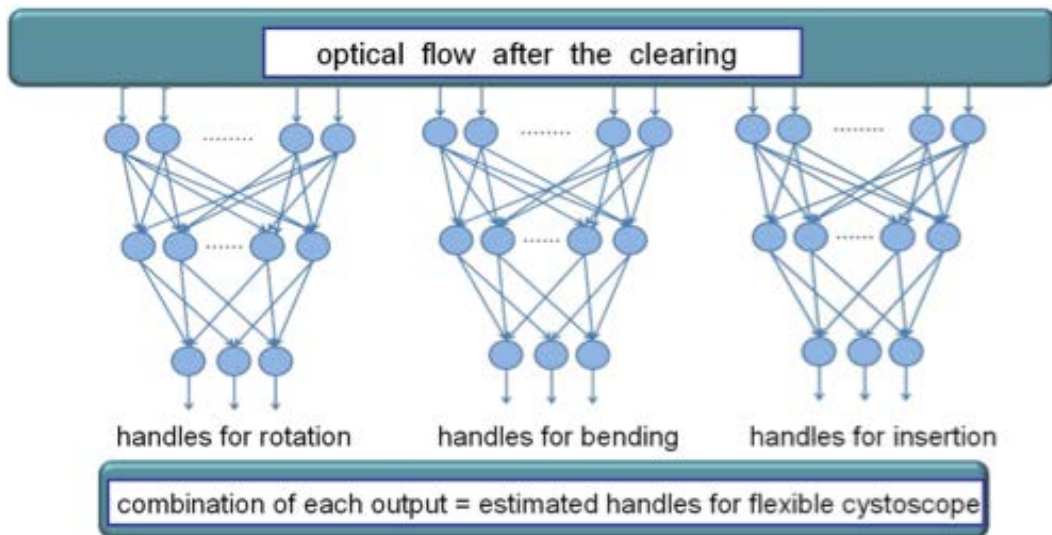


図 5.7: 操作推定用ニューラルネットワーク

ラルネットワークの結合荷重の値を変更する学習手法のことである。尚、教師データは、軟性膀胱鏡画像のフレームに対して、該当する操作を入力するものである。例えば、「上屈曲+右回転」（上に屈曲させながら同時に、右に回転させていく）の操作であれば、この操作に対応するフレームが入力されたときに、挿入操作を担当する階層型ニューラルネットワークに「挿入操作を伴わないその他の操作」が与えられ、また屈曲操作を担当する階層型ニューラルネットワークに「上屈曲」が与えられ、更に回転操作を担当する階層型ニューラルネットワークに「右回転」が与えられる。このように、それぞれのフレームに対して、教師データとして、クリーニングされたオプティカルフロー、対応する操作（理想値）を組み合わせた表 5.1 のような データを与える。そして、これらの教師データを用いた学習結果によって、フレームごとの軟性膀胱鏡の操作を推定可能としていく。

第6章

評価実験

6.1 実験環境

6.1.1 対象

対象は金沢大学附属病院泌尿器科を受診した患者の軟性膀胱鏡画像であり、8人分の動画像である。実際に用いたフレーム数は4332枚であり、不鮮明なフレームは除いた。詳細は6.1.3で述べる。また、各フレームは専門医により、予め対応する軟性膀胱鏡の操作が調べられているので、操作の推定の正解率（判別率）が計算できる。尚、患者には、研究への使用の許可を得ている。

6.1.2 使用機器

軟性膀胱鏡はオリンパス社製 CYF TYPE VA2 を使用した。視野角は 120° 、光軸と観察方向とのなす角度は 0° 、観察深度（被写界深度）は 3 - 50 mm、外径は 16.2 Fr.（直径 5.4 mm）、先端は同一平面内で円弧状に屈曲する（UP 210° / DOWN 120° ）。ビデオシステムセンター OTV-S7V から出力される IEEE1394 動画デジタル出力（DV/DVC PRO）を後の解析に備えて、いったん MiniDV テープに記録した。フレームレートは 29.97 フレーム/秒であった。MiniDV テープから画像解析用のコンピュータ（CPU: Intel Core i3 540 3.07 GHz、メモリ: 1.92 GB RAM）に動画データをコピーし、解析に用いた。軟性膀胱鏡先端が膀胱に挿入された時をスタートとし、各膀胱鏡動画約 1000 フレーム分、約 34 秒間 を用いた。

6.1.3 動画の前処理

動画には患者氏名、ID番号など解析には不要な領域が含まれており、それらを取り除いた。解析領域は 300×300 ピクセルである。尚、今回は提案手法の基本的な能力を明らかにするために、軟性膀胱鏡画像から第4章で述べた外乱が特に大きい (a) 流体の渦巻きと、(b) ハレーションのフレームを除いた。つまり、元々は患者1人あたり1000フレーム分の動画像を得ており、全体で8人分の8000フレームあったが、この中には不鮮明なフレームもあるので、その主な原因となる上記の (a)、(b) のフレームを除いた4322枚のフレームを本実験で使用した。

6.1.4 オプティカルフロー推定法について

本システムでは、比較的高精度で照明変化に頑健なブロックマッチング法を採用した。実際にはインテル社 (Santa Clara, CA, アメリカ) が開発し、有志により改良が続けられている画像解析ライブラリー OpenCV の `cvCalcOpticalFlowBM` 関数を利用した。矩形領域は 30×30 ピクセルとし、全部で 10×10 領域、計100個のオプティカルフローを推定した。

6.1.5 マハラノビス距離の閾値

マハラノビス距離の閾値 θ を0.7にした。つまり、単位ベクトル化した特徴データの代表オプティカルフローに対してマハラノビス距離を求め、0.7よりも大きければ外れ値としてそのベクトルを除去する。

$$M = \sqrt{\begin{bmatrix} x - \bar{x} & y - \bar{y} \end{bmatrix} \begin{bmatrix} S_{11} & S_{12} \\ S_{21} & S_{22} \end{bmatrix}^{-1} \begin{bmatrix} x - \bar{x} \\ y - \bar{y} \end{bmatrix}} \quad (6.1)$$

M : マハラノビス距離 \bar{x}, \bar{y} : 平均値

$\begin{bmatrix} S_{11} & S_{12} \\ S_{21} & S_{22} \end{bmatrix}$: 分散・共分散行列

6.1.6 学習の終了条件

学習の終了条件 E を 10^{-5} にした。この終了条件とは、ニューラルネットワークの出力値と教師データの自乗誤差 $E(n)$ が、

$$E(n+1) > E(n) \times (1 - e) \quad (6.2)$$

を満たすときに学習を終了させるという意味である。つまり、 e が小さくなればなるほど、細部まで教師データに合わせて学習を行うことになる。

6.2 比較実験

軟性膀胱鏡から得られた被験者 8 人分の 4322 枚のフレームに対する、軟性膀胱鏡の各操作の内訳は表 ?? のようになる。表 6.1 から各操作に対応するフレーム数に大きなばらつきがあることが判る。ニューラルネットワークのような判別学習では、多数派の判定を正確にすることが、判別誤差を小さくすることにつながるため、このようにフレーム数に偏りがある場合、小数派のフレームの判別精度が低くなり、全ての操作において、フレーム数の多い「その他（非回転、非屈曲、非挿入）」の判別精度がよくなるように学習されてしまう [13]。そこで、多数派のフレーム数を小数派に合わせてランダムに削除する（ランダムアンダーサンプリング）ことにより、判別精度の向上を図る。変更する割合としては、偏りをなくすという観点から、(1:1:1) にフレーム数の比率を変更することが妥当と考えられるが、その判別対象の性質を表すのに必要なフレームも削除される場合があるため、必ずしも (1:1:1) が最適であるとは限らない。そこで、フレーム数の比率を、偏りがあるケース（比率の変更なし）、および、最も少ないフレーム数に合わせて、(4:4:5) としたとき（表 6.2）と、(1:1:1) としたとき（表 6.3）の 3 ケースで判別精度を求める。操作推定の判別率を求める方法としては、7 名を学習データにして、残り 1 名をテストデータにして 2 つの集合に分ける方法を用いた。学習データは各操作の判別の仕方を決めるものであり、学習データによって導かれた判別方法により、学習データ、テストデータでの操作推定の判別率を求める。この操作を学習データとテストデータの組み合わせを換えて繰り返

す。8通りできるので、各学習データの判別率の平均値と、各テストデータの判別率の平均値をもってして回答とする。提案手法との比較の対象としては、次の2つの方法を選んだ。

【方法1】 各操作の基本形データ（テンプレート）との差を求め、最も小さい操作を出力する方法

【方法2】 決定木を用いて推定する方法

handles for the cystoscope	number of frames	
rotation	left	821
	right	1043
	none	2458
bending	up	849
	down	1098
	none	2375
insertion	push	813
	pull	734
	none	2775

表 6.1: 各操作別のフレーム数（比率変更なし）

handles for the cystoscope	number of frames	
rotation	left	821
	right	821
	none	1026
bending	up	849
	down	849
	none	1061
insertion	push	734
	pull	734
	none	917

表 6.2: 各操作別のフレーム数（フレーム比率 4:4:5）

handles for the cystoscope	number of frames	
rotation	left	821
	right	821
	none	821
bending	up	849
	down	849
	none	849
insertion	push	734
	pull	734
	none	734

表 6.3: 各操作別のフレーム数（フレーム比率 1:1:1）

これまで、膀胱内壁の画像判別を行った手法は提案されていないため、従来方式との比較はできない。そのため、適当な方法を考えるしかなかった。先ず方法1は、各操作に対する基本形データ（テンプレート）を用意して、入力データとのユークリッド距離（テンプレートとクリーニングされたフレームの特徴データの各対応する要素間の差の合計）を求め、最も小さかったテンプレートの操作を出力するシステムである。つまり、方法1は最小距離法である。また、テンプレートは次のようにして作成する。学習データを各操作のデータに分け、各操作のデータごとに要素ごとの平均値を計算して、それをテンプレートとする。この手法を選んだ理由は、最も基本的な手法であり、かつ原始的なものであるため、提案手法との違いが出せると考えたからである。また、方法2はデータマイニングの代表的な手法であり、決定木の学習方法には C4.5[14] を用いた。多くの判別システムで利用されているので比較の対象として妥当であると考えた。

6.2.1 実験1 停止を考慮しない実験

回転操作であれば、左回転、右回転、非回転を対象に、方法1、方法2、提案手法をそれぞれ用いて学習データに対する判別率（8回の平均値）とテストデータに対する判別率（8回の平均値）を求める。また、同様に屈曲操作と挿入操作についても学習データとテストデータに対する判別率を求める。尚、フレーム数の比率は上記の3ケースを考察する。

操作の切り替え時に意識的に停止を行うことをしないで実験を行った。

実験結果

フレーム数の比率の偏りがあるケースの各操作における学習データでの判別率を表 6.4 (各手法ごとに P_j の平均値を追加) に示す。提案手法では、全ての操作の判別率が 100% になった。このことから学習が十分なされたことが判る。それに対し、方法 2 は若干学習が不十分である。また、どの操作においても、方法 1、方法 2、提案手法の順に判別率が高くなっていく。尚、表中の P_j は正解率であり、次式 6.3 で計算できる。

$$P_j = \sum_{i=1}^3 \frac{(\text{操作 } O_{ji} \text{ のフレーム数}) \times (\text{操作 } O_{ji} \text{ の判別率})}{\text{検査対象の全体のフレーム数}} \quad (6.3)$$

因に、表 6.4 の方法 1、方法 2、提案手法のそれぞれの P_j の平均値は 75.84%、96.74%、100.00% となる。

tool	rotation				bending				insertion				average P_j
	left	right	none	P_j	up	down	none	P_j	push	pull	none	P_j	
method1	75.52%	84.24%	77.03%	78.48%	84.77%	75.37%	87.87%	84.27%	72.57%	68.97%	60.41%	64.78%	75.84%
method2	97.89%	96.48%	96.86%	96.97%	96.65%	97.18%	96.76%	96.85%	95.80%	96.82%	96.40%	96.39%	96.74%
proposal	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%

表 6.4: 学習データでの判別率 (停止を考慮しない、データ比率変更なし)

次にフレーム数の比率の偏りがあるケースの各操作におけるテストデータでの判別率を表 6.5 (各手法ごとに P_j の平均値を追加) に示す。 P_j が、方法 1、方法 2、提案手法の順に高くなっていくので、提案手法が最も判別率がよい。しかし、個別に見ると、上屈曲の判別率では 79.87%、65.12%、66.90% となり、方法 1 が最も判別率が高い。同様に、挿入の押すの操作では、68.67%、53.18%、59.47% となり、方法 1 が最も判別率が高い。また、提案手法を用いたときの「挿入の操作 (59.47%)」、「上屈曲の操作 (66.90%)」、「抜去の操作 (65.91%)」の判別率が他の操作と比べて 20% 程度低くなっている。逆に、判別率が最も高かった操作は「左回転の操作 (92.56%)」であり、回転操作の P_j も高い (85.30%)。因に、表 6.5 の方法 1、方法 2、提案手法のそれぞれの P_j の平均値は 66.34%、75.96%、81.21% となる。

フレーム数の比率を (4:4:5) にした場合の各操作における学習データでの判別率を表 6.6 (各手法ごとに P_j の平均値を追加) に示す。どの操作においても、方法 1、方法 2、提案手法

tool	rotation				bending				insertion				average Pj
	left	right	none	Pj	up	down	none	Pj	push	pull	none	Pj	
method1	76.44%	73.41%	77.97%	76.58%	79.87%	73.02%	69.94%	72.57%	68.67%	65.71%	36.87%	49.87%	66.34%
method2	70.02%	72.43%	82.17%	77.31%	65.12%	70.09%	78.64%	73.81%	53.18%	84.53%	72.75%	71.90%	75.96%
proposal	92.56%	78.74%	84.90%	85.30%	66.90%	78.64%	85.84%	81.06%	59.47%	65.91%	85.47%	77.26%	81.21%

表 6.5: テストデータでの判別率 (停止を考慮しない、データ比率変更なし)

の順に判別率が高くなってきており、それぞれの Pj の平均値は 77.29%、97.06%、100.00% となり、実験 1 よりも数値が高くなった。このことからフレーム数の比率を変えたことによる改善がなされたことが判る。

tool	rotation				bending				insertion				average Pj
	left	right	none	Pj	up	down	none	Pj	push	pull	none	Pj	
method1	76.48%	84.76%	80.28%	80.49%	85.40%	75.67%	89.32%	83.91%	72.88%	70.22%	60.93%	67.47%	77.29%
method2	96.91%	96.26%	97.48%	96.93%	98.33%	98.29%	96.34%	97.56%	97.28%	96.22%	96.61%	96.70%	97.06%
proposal	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%

表 6.6: 学習データでの判別率 (停止を考慮しない、データ比率 4:4:5)

次に、フレーム数の比率を (4:4:5) にした場合の各操作におけるテストデータでの判別率を表 6.7 (各手法ごとに Pj の平均値を追加) に示す。屈曲操作以外の操作では、方法 1、方法 2、提案手法の順に判別率が高くなっていくが、屈曲操作では、いずれも提案手法が最も判別率が低かった。それでも、方法 1、方法 2、提案手法のそれぞれの Pj の平均値は 75.20%、76.47%、81.29% となり、平均的には提案手法が最も判別率が高い。

tool	rotation				bending				insertion				average Pj
	left	right	none	Pj	up	down	none	Pj	push	pull	none	Pj	
method1	75.20%	81.96%	77.52%	78.17%	84.08%	76.46%	85.89%	82.43%	69.98%	69.27%	57.60%	65.00%	75.20%
method2	77.81%	86.85%	76.37%	80.04%	81.93%	80.78%	82.16%	81.66%	69.34%	72.47%	67.70%	69.67%	76.47%
proposal	83.79%	92.47%	83.67%	86.41%	81.07%	74.07%	81.97%	79.26%	78.64%	83.94%	78.21%	80.10%	81.29%

表 6.7: テストデータでの判別率 (停止を考慮しない、データ比率 4:4:5)

フレーム数の比率を (1:1:1) にした場合の各操作における学習データでの判別率を表 6.8 に示す。どの操作においても、方法 1、方法 2、提案手法の順に判別率が高くなってきており、それぞれの Pj の平均値は 79.24%、96.41%、100.00% となった。

次に、フレーム数の比率を (1:1:1) にした場合の各操作におけるテストデータでの判別率を表 ?? に示す。屈曲操作以外の操作では、方法 1、方法 2、提案手法の順に判別率が高

tool	rotation				bending				insertion				average Pj
	left	right	none	Pj	up	down	none	Pj	push	pull	none	Pj	
method1	77.34%	84.82%	77.65%	79.92%	90.28%	78.53%	91.12%	86.64%	72.95%	70.91%	69.66%	71.17%	79.24%
method2	95.93%	97.09%	97.50%	96.84%	97.84%	95.08%	96.97%	96.63%	96.40%	94.77%	95.07%	95.41%	96.41%
proposal	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%

表 6.8: 学習データでの判別率 (停止を考慮しない、データ比率 1:1:1)

くなっていくが、屈曲操作の Pj では、提案手法が最も判別率が低かった。それでも、方法 1、方法 2、提案手法のそれぞれの Pj の平均値は 78.25%、81.20%、81.92% となり、平均的には提案手法が最も判別率が高い。これにより、フレーム数の比率は、(偏りがあるケース)、(4:4:5)、(1:1:1) の中で、(1:1:1) が最も判別率が良いことが判った。提案手法の Pj の平均値は、表 ??、表 ??、表 ?? でそれぞれ 81.21%、81.29%、81.92% と向上し、偏りを無くすことにより、0.71% 程度の正解率向上があったことが判る。

tool	rotation				bending				insertion				average Pj
	left	right	none	Pj	up	down	none	Pj	push	pull	none	Pj	
method1	73.16%	92.95%	73.90%	80.00%	88.08%	78.50%	91.24%	85.94%	70.93%	70.46%	65.02%	68.80%	78.25%
method2	77.14%	85.14%	78.04%	80.11%	83.03%	82.64%	81.54%	82.41%	84.43%	80.79%	78.07%	81.09%	81.20%
proposal	88.14%	82.24%	82.49%	84.29%	76.36%	85.45%	76.47%	79.43%	76.12%	86.48%	83.53%	82.05%	81.92%

表 6.9: テストデータでの判別率 (停止を考慮しない、データ比率 1:1:1)

6.2.2 実験 2 停止を考慮する実験

操作の切り替え時に意識的に停止させて実験を行った。その他は実験 1 と同様の実験内容である。

実験結果

各操作における学習データでの判別率を表 6.10 に示す。停止を考慮しても、提案手法では全ての操作の判別率が 100% となった。このことから十分学習がなされたことが分かる。それに対して、方法 1、方法 2 とともに、学習が不十分であった。また、どの操作においても、方法 1、方法 2、提案手法の順に判別率が高くなっていく。フレーム数の比率については調整を行っていない (フレーム数に偏りがある)。

tool	rotation				bending				insertion				average Pj
	left	right	none	Pj	up	down	none	Pj	push	pull	none	Pj	
method1	89.39%	74.71%	80.96%	84.21%	95.94%	59.42%	74.69%	78.03%	52.02%	61.80%	61.79%	62.43%	74.80%
method2	99.20%	90.44%	92.69%	95.42%	100.0%	91.72%	89.66%	94.68%	96.08%	94.92%	91.94%	93.41%	94.50%
proposal	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%

表 6.10: 学習データでの判別率 (停止を考慮する、データ比率変更なし)

次に各操作におけるテストデータでの判別率を表 6.11 に示す。正解率 Pj は方法 1、方法 2、提案手法の順に高くなった。停止を考慮する提案手法が最も判別率が高く、停止を考慮しない提案手法よりも約 10% 向上している。

tool	rotation				bending				insertion				average Pj
	left	right	none	Pj	up	down	none	Pj	push	pull	none	Pj	
method1	90.93%	78.13%	78.52%	83.21%	88.68%	60.97%	68.46%	73.50%	64.86%	77.68%	49.53%	58.12%	71.53%
method2	89.09%	74.16%	88.23%	84.49%	96.07%	79.32%	81.94%	81.27%	71.50%	51.81%	89.99%	81.60%	82.46%
method2	89.09%	74.16%	88.23%	84.49%	96.07%	79.32%	81.94%	81.27%	71.50%	51.81%	89.99%	81.60%	82.46%

表 6.11: テストデータでの判別率 (停止を考慮する、データ比率変更なし)

第7章

考察

7.1 提案手法の学習モデルの検定

まず、提案手法の学習モデルの検定を行う。評価値としては、F1 値と操作の推定精度（判別率）の分散を用いる。F1 値は適合率 P と再現率 R の調和平均であり、7.1 式から求められる。ここで適合率とは、システムがある操作と推定したデータ集合中で、実際にその操作であったデータの割合を示す。また、再現率とは、ある操作の全てのデータのうち、システムがその操作であると推定したデータの割合を示す。再現率と適合率はトレードオフの関係にあるため、どちらか一方のみでシステムの判別精度を評価するのは難しい。

$$F1 = \frac{2}{1/R + 1/P} \quad (7.1)$$

表 6.5、表 6.7、表 6.9 の提案方法におけるテストデータでの判別率に対し、F1 と操作の判別率の分散を求めると、それぞれ表 7.1、表 7.2、表 7.3 となる。これらの結果から、フレーム数の比率が、(偏りがあるケース)、(4:4:5)、(1:1:1) となるにつれ、F1 値は 79.95%、81.31%、84.05% となり、操作精度の分散は 74.89、18.45、32.01 となるので、フレーム数の比率が (1:1:1) のときが最も性能が良くなることが判る。

handles for the cystoscope		F1 value	deviation of F1 values for each handle
rotation	left	85.51%	7.57
	right	80.84%	
	none	85.45%	
bending	up	65.60%	107.63
	down	85.10%	
	none	81.47%	
insertion	push	69.48%	108.21
	pull	62.36%	
	none	82.89%	
average		79.95%	74.89

表 7.1: 実験1における提案手法のF1値（データ比率変更なし）

7.2 Mahalanobis Outlier Analysisの閾値

Mahalanobis Outlier Analysis は標本のマハラノビス距離に対して閾値を設定し、それ以上重心からのマハラノビス距離が大きいものを外れ値として除去する方法である。次の実験では、閾値を変更して学習を行わせることにより、適切な閾値を決定する。フレーム数の比率を (1:1:1) にし、学習終了条件 E を 10^{-5} にして、マハラノビス距離の閾値 θ を 0.6、0.7、0.8 にしたときの各操作の F1 値と分散を求めた結果、F1 値の平均はそれぞれ 82.41%、84.05%、83.88% であり、ほとんど差はない。また、各操作の分散の平均値ではそれぞれ 31.59、31.64、121.70 となり、 $\theta = 0.8$ のときの分散が大きい。結局のところ、 $\theta = 0.6$ の場合と $\theta = 0.7$ の場合では殆ど同じであるが、若干、 $\theta = 0.7$ の方が F1 値の平均が大きく、各操作の分散に有意差が無いいため、 $\theta = 0.7$ の方が適切と言える。

7.3 ニューラルネットワークの学習終了条件

ニューラルネットワークの学習を行うにあたって、どれだけ出力値を教師データの理想的な出力に近づけるかを、予め設定しなければならない。出力値を教師データの理想的な出力に過剰に近づけるように学習させてしまうと、その教師データに特化した学習、つま

handles for the cystoscope		F1 value	deviation of F1 values for each handle
rotation	left	87.65%	4.12
	right	88.12%	
	none	84.33%	
bending	up	86.91%	44.49
	down	74.70%	
	none	76.28%	
insertion	push	80.41%	5.83
	pull	81.15%	
	none	76.61%	
average		81.31%	18.45

表 7.2: 実験 1 における提案手法の F1 値 (データ比率 4:4:5)

り過学習を引き起こしてしまい、汎化性能が低下してしまう。そこでニューラルネットワークの学習終了条件を変更して実験することにより、本システムの適切な終了条件を求める。フレーム数の比率を (1:1:1) にし、マハラノビス距離の閾値 θ を 0.7 にして、学習終了条件 E を 10^{-4} 、 10^{-5} 、 10^{-6} にしたときの各操作の F1 値と分散を求めた結果、F1 値の平均はそれぞれ 82.11%、84.05%、83.99% であり、 $E = 10^{-5}$ のときが最も大きい。また、各操作の分散の平均値ではそれぞれ 38.10、31.64、42.61 となり、 $E = 10^{-4}$ と $E = 10^{-5}$ ときが最も小さい。これらのことから、 $E = 10^{-5}$ のときが適切と言える。

7.4 操作の速さと移動距離

各操作 (動作) の速さはオプティカルフローのベクトルの長さに比例している。また、各操作の移動距離、またはフレーム画像の移動距離は、後日、第二段階の研究として、軟性膀胱鏡の検査済みの範囲や見落としの範囲を推定する際に必要となるが、軟性膀胱鏡の操作を推定するには不要である。この理由は、移動距離は被験者の膀胱内の状況に依存するものであり、移動距離によって操作が特定できないからである。

handles for the cystoscope		F1 value	deviation of F1 values for each handle
rotation	left	90.06%	5.16
	right	89.35%	
	none	85.53%	
bending	up	74.65%	85.08
	down	91.17%	
	none	75.61%	
insertion	push	83.90%	108.21
	pull	84.71%	
	none	81.18%	
average		84.05%	32.01

表 7.3: 実験 1 における提案手法の F1 値 (データ比率 1:1:1)

7.5 提案システムの有用性

これまで膀胱内壁を対象とした画像認識手法の研究論文はほとんど見当たらない。その理由については第 4 章でも述べたが、膀胱内壁の画像は特徴部位が少なく、また、流体の渦巻きやハレーションといった外乱のため画像認識が困難になっているためである。そこで本論文では、まず手始めに、流体の渦巻きやハレーションのない、特徴部位の少ない膀胱内壁の動画の認識をターゲットにした。先行研究がないため、比較の対象として最小距離法の方法 1 と、決定木を用いた方法 2 を選び、軟性膀胱鏡の操作を判別する精度を比較した。その結果、提案手法では学習データ (表 6.4、表 6.6、表 6.8) で常に 100% の精度を出したが、方法 1、方法 2 では、いずれの学習データにおいても 100% の精度を出すことができなかった。また、テストデータ (表 6.5、表 6.7、表 6.9) においては常に提案手法が勝っており、これらのことから膀胱内壁の画像認識にはニューラルネットワークによる判別が方法 1 や方法 2 よりも適していることが判った。しかしながら、最終的な精度が 84.05% が十分高いかと言えば、軟性膀胱鏡検査の見落としを防ぐためには、まだ不十分である。限りなく 100% に近づける努力が必要となるが、基本形としてはニューラルネットワークが特徴部位の少ない膀胱内壁の画像認識に有用であると言えよう。今後はデータクリーニングや提案手法と独立して利用できる情報を活用することにより、更なる精度の向

上が期待できる。

第8章

結論

本論文では、軟性膀胱鏡の動画像からニューラルネットワークを用いて軟性膀胱鏡の先端屈曲、軸方向の回転、挿入深度の操作を推定する手法を提案した。第一ステップということもあり、『流体の渦巻き』や『ハレーション』といった外乱が含まれる画像を抜いて実験を行った。その結果、テストデータでの判別正解率が84.05%になった。また、フレーム数の適切な比率が(1:1:1)で、Mahalanobis Outlier Analysisの適切な閾値が0.7で、適切な学習終了条件が 10^{-5} となることを実証した。

更なる正解率の向上を目指して、操作切り替え時に停止を行うことにより、テストデータでの判別率が92.08%になった。今後は、『流体の渦巻き』や『ハレーション』を含む画像を対象に、更に精度の高い手法の開発研究を行いたい。

謝辞

この研究の計画、遂行には、実に多くの方々の御指導、御助言、御協力を賜りました。特に主任指導教官である木村春彦教授には、構想段階から懇切丁寧な御指導をいただきました。博士後期課程入学時に私が抱いていた、実現が非常に困難な研究構想を軌道修正して、より実りの多い研究への方針をお示しいただきました。社会人で仕事が多忙であることを言い訳に、実験、論文執筆が大幅に遅れましたが、忍耐強く見守り、お導きいただいたことを心より感謝しております。

副査の村本健一郎教授、山本茂教授、今村幸祐准教授、南保英孝講師からも数々の御指導、御助言をいただきました。心から感謝いたします。南保英孝講師には、インドネシアのバリ島で開催された国際学会の準備段階から、実際の旅程においても大変にお世話になりました。国際学会への参加経験の少ない私には大変心強い存在でした。

博士前期課程を修了し、現在 NTT ドコモに勤務する余川洋史さんには本研究立ち上げ時より協力していただきました。余川さんの頑張りのおかげで、本研究を軌道に乗せることができました。同じく博士前期課程を修了し、今春就職された荒木将弘さんにも多大なるご協力をいただきました。

現在博士後期課程の中村宗広さんにも絶大なるご協力をいただきました。中村さんの超人的な問題解決能力のおかげで、本研究はこのような形でまとめることができました。私と同じ軟性膀胱鏡画像解析チームで研究を行っている背 溪介さんにも様々な御示唆をいただきました。本誌の印刷も背さんにしていただきました。

私が進路に迷いを感じているときに決定的な示唆を与えてくださった田中宗紀さん、博士後期課程への進学を勧めてくださった高 栄哲准教授、基礎的な研究に取り組むことを許してくださった並木幹夫教授に大変感謝しております。

最後になりましたが、社会人でありながら博士後期課程に進学するという、いわば「変わり者」の私に献身的に協力してくれた妻と、いつも笑顔で楽しい話題を提供してくれる二人の子供たちに感謝します。

参考文献

- [1] Tomohiro Matsuda, Tomomi Marugame, Ken-Ichi Kamo, Kota Katanoda, Wakiko Ajiki, and Tomotaka Sobue. Cancer incidence and incidence rates in Japan in 2003: based on data from 13 population-based cancer registries in the Monitoring of Cancer Incidence in Japan (MCIJ) Project. *Japanese Journal of Clinical Oncology*, Vol. 39, No. 12, pp. 850–858, 2009.
- [2] Harry W Herr. Max Nitze, the cystoscope and urology. *The Journal of Urology*, Vol. 176, No. 4 Pt 1, pp. 1313–1316, 2006.
- [3] R Yoshimura, S Wada, and T Kishimoto. Why the flexible cystoscope has not yet been widely introduced?: A questionnaire to Japanese urologists. *International journal of urology official journal of the Japanese Urological Association*, Vol. 6, No. 11, pp. 549–559; discussion 560–561, 1999.
- [4] J H Song, I R Francis, J F Platt, R H Cohan, J Mohsin, S J Kielb, M Korobkin, and J E Montie. Bladder tumor detection at virtual cystoscopy., 2001.
- [5] Fumihiro Asano, Yoshihiko Matsuno, Naofumi Shinagawa, Koichi Yamazaki, Toshitaka Suzuki, Takashi Ishida, and Hiroshi Moriya. A virtual bronchoscopic navigation system for pulmonary peripheral lesions. *Chest*, Vol. 130, No. 2, pp. 559–566, 2006.
- [6] Daisuke Deguchi, Kensaku Mori, Marco Feuerstein, Takayuki Kitasaka, Calvin R Maurer, Yasuhito Suenaga, Hirotsugu Takabatake, Masaki Mori, and Hiroshi Natori. Selective image similarity measure for bronchoscope tracking based on image registration. *Medical Image Analysis*, Vol. 13, No. 4, pp. 621–633, 2009.
- [7] Berthold K P Horn and Brian G Schunck. Determining optical flow. *Artificial Intelligence*, Vol. 17, No. 1-3, pp. 185–203, 1981.
- [8] S S Beauchemin and J L Barron. The computation of optical flow. *ACM Computing Surveys*, Vol. 27, No. 3, pp. 433–466, 1995.

- [9] S A Jimenez-Marquez, C Lacroix, and J Thibault. Statistical data validation methods for large cheese plant database. *Journal of Dairy Science*, Vol. 85, No. 9, pp. 2081–2097, 2002.
- [10] J Gibbon. Comparison of Outlier Detection Methods in Fault-proneness Models. In *Empirical Software Engineering and Measurement 2007 ESEM 2007 First International Symposium on*, pp. 461–463, 2007.
- [11] J J Hopfield and D W Tank. "Neural" computation of decisions in optimization problems. *Biological Cybernetics*, Vol. 52, No. 3, pp. 141–152, 1985.
- [12] D E Rumelhart, G E Hinton, and R J Williams. Learning representations by back propagating errors. *Nature*, Vol. 323, pp. 533–536, 1986.
- [13] Yasutaka Kamei, Akito Monden, Shinsuke Matsumoto, Takeshi Kakimoto, and Ken-ichi Matsumoto. The Effects of Over and Under Sampling on Fault-prone Module Detection. *Empirical Software Engineering and Measurement 2007 ESEM 2007 First International Symposium on*, pp. 196–204, 2007.
- [14] J R Quinlan. *C4.5: Programs for Machine Learning*. Morgan Kaufmann, 1993.

付録

軟性膀胱鏡基本操作

- 軟性膀胱鏡を奥に入れる (挿入)
- 軟性膀胱鏡を外に出す (抜去)
- 手元のレバーによって膀胱鏡先端を上屈させる
- 手元のレバーによって膀胱鏡先端を下屈させる
- 軟性膀胱鏡を右に回転させる
- 静止させる

軟性膀胱鏡複合操作

- 挿入 + 上屈曲 + 右回転
- 挿入 + 上屈曲 + 左回転
- 挿入 + 上屈曲
- 挿入 + 下屈曲 + 右回転
- 挿入 + 下屈曲 + 左回転
- 挿入 + 下屈曲
- 挿入 + 右回転
- 挿入 + 左回転

- 挿入
- 抜去 + 上屈曲 + 右回転
- 抜去 + 上屈曲 + 左回転
- 抜去 + 上屈曲
- 抜去 + 下屈曲 + 右回転
- 抜去 + 下屈曲 + 左回転
- 抜去 + 下屈曲
- 抜去 + 右回転
- 抜去 + 左回転
- 抜去
- 上屈曲 + 右回転
- 上屈曲 + 左回転
- 上屈曲
- 下屈曲 + 右回転
- 下屈曲 + 左回転
- 下屈曲
- 右回転
- 左回転
- 静止

軟性膀胱鏡操作と画面の動きの部分例

以下は、軟性膀胱鏡の状態と操作、そして画像の動作の関係の一部を例として示している。また、この例での操作は複合的な操作ではなく、単一の操作を示している。このため複合操作や細かい状態の変化も含めると、この他にも多数のパターンが存在する。

1. 軟性膀胱鏡を挿入

	操作時の軟性膀胱鏡状態	画像上の動作
(a)	屈曲なしの状態	奥に進む
(b)	上に屈曲した状態	画面が上方にスライド
(c)	下に屈曲した状態	画面が下方にスライド

2. 軟性膀胱鏡を抜去

	操作時の軟性膀胱鏡状態	画像上の動作
(a)	屈曲なしの状態	手前に進む
(b)	上に屈曲した状態	画面が下方にスライド
(c)	下に屈曲した状態	画面が上方にスライド

3. 膀胱鏡先端を上屈曲

	操作時の軟性膀胱鏡状態	画像上の動作
(a)	回転なしの状態	画面が下方にスライド
(b)	右に回転した状態	画面が下方にスライド
(c)	左に回転した状態	画面が下方にスライド

4. 膀胱鏡先端を下に屈曲

	操作時の軟性膀胱鏡状態	画像上の動作
(a)	回転なしの状態	画面が上方にスライド
(b)	右に回転した状態	画面が上方にスライド
(c)	左に回転した状態	画面が上方にスライド

5. 膀胱鏡を右に回転

	操作時の軟性膀胱鏡状態	画像上の動作
(a)	屈曲なしの状態	画面の中央を中心に右回転
(b)	上に90度屈曲した状態	画面が左方にスライド
(c)	下に90度屈曲した状態	画面が右方にスライド

6. 膀胱鏡を左に回転

	操作時の軟性膀胱鏡状態	画像上の動作
(a)	屈曲なしの状態	画面の中央を中心に左回転
(b)	上に90度屈曲した状態	画面が右方にスライド
(c)	下に90度屈曲した状態	画面が左方にスライド

7. 静止

	操作時の軟性膀胱鏡状態	画像上の動作
(a)	全ての状態	動作なし

異なる操作にも関わらず、画面上では
動作が類似する操作の例

画面上の動作が類似する操作の例

画面上の動作	上記の軟性膀胱鏡操作番号
画面が上方にスライドする	1.(b)、2.(c)、4.(a)、4.(b)、4.(c)
画面が下方にスライドする	1.(c)、2.(b)、3.(a)、3.(b)、3.(c)
画面が右方にスライドする	5.(c)、6.(b)
画面が左方にスライドする	5.(b)、6.(c)

軟性膀胱鏡検査再現時に用いる 仮想膀胱の定義

仮想的な膀胱モデルを作成する場合，地球儀のような形状の球形を基本として考える．ここで，北極点にあたる部位を頂部，南極点にあたる部位を内尿道口，緯度0度が後壁の中央，緯度180度が前壁の中央となるように定義する．以下はそれらを基準に膀胱内の各部位の定義を示す．

表 8.1: 仮想膀胱における各部位の定義

部位名	定 義
右尿管口	南緯 45 度，東経 60 度の部位を右尿管口と定める
左尿管口	南緯 45 度，西経 60 度の部位を左尿管口と定める
頸部	三角部の領域を除く，南緯 70 度から 90 度までの領域を頸部と定める
頂部	北緯 60 度以上の領域を頂部を定める．
三角部	南緯 45 度から南緯 90 度の間であり，かつ東経 60 度から西経 60 度に含まれる領域を三角部と定める．
後壁	北緯 60 度から南緯 45 度の間であり，かつ東経 60 度から西経 60 度に含まれる領域を後壁と定める．
前壁	北緯 60 度から南緯 70 度の間であり，かつ東経 120 度から西経 120 度に含まれる領域を前壁と定める．
右側壁	北緯 60 度から南緯 70 度の間であり，かつ東経 60 度から東経 120 度に含まれる領域を右側壁と定める．
左側壁	北緯 60 度から南緯 70 度の間であり，かつ西経 60 度から西経 120 度に含まれる領域を左側壁と定める．