

TR-H-028

最適化原理に基づく
運動パターンの生成と認識に関する研究

和田 安弘

1993. 9. 20

ATR 人間情報通信研究所

〒619-02 京都府相楽郡精華町光台2-2 ☎07749-5-1011

ATR Human Information Processing Research Laboratories

2-2, Hikaridai, Seika-cho, Soraku-gun, Kyoto 619-02 Japan

Telephone: +81-7749-5-1011

Facsimile: +81-7749-5-1008

最適化原理に基づく

運動パターンの生成と認識に関する研究

和田安弘

目次

1	緒言	1
1.1	研究の背景および目的	2
1.2	論文の構成	6
2	制御対象の順・逆モデルを使った腕の最適軌道生成	8
2.1	はじめに	9
2.2	最小化原理に基づいた軌道生成	10
2.2.1	躍度最小化規範に基づいた軌道生成	10
2.2.2	トルク変化最小化規範に基づいた軌道生成	11
2.3	腕の最適軌道を生成する神経回路網	17
2.3.1	順モデルと逆モデルによる 最適軌道生成神経回路網	17
2.4	数値実験	20
2.4.1	線型近似モデルによる数値実験	22
2.4.2	質点系モデルによる数値実験	25
2.5	経路点のある運動への拡張	32
2.5.1	経路点のある運動軌道の生成	32
2.5.2	数値実験	36
2.6	非線型最適化問題の解法としての理論的考察	41
2.6.1	収束解の最適性	43
2.6.2	解の収束性	46
2.7	おわりに	47

3	最適化原理に基づく書字運動モデル	51
3.1	はじめに	52
3.2	従来の書字運動のモデル	53
3.3	書字運動モデル	55
3.3.1	文字の経路点推定モデル	55
3.3.1.1	経路点抽出モジュール	55
3.3.1.2	理論的検討	59
3.3.2	経路点推定モデルに基づいた書字運動モデル	67
3.4	様々なデータに対する経路点の推定結果	69
3.4.1	経路点を与えた運動における推定	69
3.4.2	書字運動における経路点の推定	72
3.4.3	音声データによる経路点推定モデルの検証	76
3.5	文字の生成実験結果	78
3.6	書字運動モデルの考察	80
3.7	おわりに	81
4	最小化原理を応用した運動パターン認識	82
	--- 連続文字の認識と音韻時刻の推定	
4.1	はじめに	83
4.2	従来の研究	85
4.3	書字運動モデルによる連続文字の認識	86
4.3.1	文字認識における書字運動モデルの必要性	86
4.3.2	文字認識における書字運動モデルの役割	87
4.3.3	文字認識システム	88
4.3.4	文字認識結果	97

4.4	調音器官運動からの音韻推定	101
4.4.1	音韻推定モデル	101
4.4.2	音韻の推定結果	102
4.4.3	音韻推定モデルの応用	107
4.5	おわりに	109
5	新しい情報量規準とCross Validationによる汎化能力の推定	110
	---- 神経回路網モデルの実現に関する一手法	
5.1	はじめに	111
5.2	Cross Validationを使った神経回路網モデルの選択方法	112
5.2.1	汎化能力の評価	113
5.2.2	情報量規準の計算	116
5.2.3	ペナルティ項の推定	119
5.2.4	平均対数尤度の近似計算	121
5.2.5	情報量規準IC(K,N)	122
5.2.6	仮定に関する検討	123
5.3	神経回路網モデルのサイズ選択への適用結果	127
5.3.1	3層神経回路網モデルに対するIC(K,N)	127
5.3.2	適用結果	129
5.4	おわりに	132
6	結言	134
6.1	研究成果の要約	135
6.2	今後の研究課題	136
6.3	むすび	137

謝辞	139
参考文献	140
本論文に関する原著論文	147
付録1 4階微分までの連続性	150
付録2 速度の極小点だけによる軌道生成	151
付録3 閾値の違いによる推定される経由点の変化	153
付録4 調音器官の速い運動における音韻時刻の推定	154
付録5 閾値の変化による音韻時刻の推定について	155
付録6 $IC(K, N)$ とAIC との関係	157
付録7 第1の仮定について	159

第 1 章

緒 言

1.1 研究の背景および目的

脳の情報処理機構に学んだ運動制御，パターン認識，推論，行動の計画などの研究は，多くのアプローチで試みられている．ヒトの脳・神経系は百億以上のニューロンが複雑にからみあって，それらの知的情報処理を容易に実現している．神経生理学や解剖学の分野での1個のニューロンの情報処理や，脳の様々な部位の結合様式，学習や記憶の基礎過程であるシナプス可塑性についての理解の深まりとともに，計算機を用いて脳神経系の情報処理原理を探る計算論的神経科学と，その成果を工学的に応用しようとする神経回路網モデルの研究が活発に行われている．脳に学ぶ情報処理機構が，現在の情報処理で困難とされる問題に対して大きなブレークスルーを与えてくれる可能性は大きいと期待される．

我々の日常の生活における珈琲カップに手を延ばしたり，サインをしたり，障害物を飛び越えたりする動作は，自分自身の腕や指などの筋肉，足の筋肉を制御することが出来て，はじめて，その目的を達することが可能となる．また，手足ばかりでなく，会話をするときの顎，唇や舌などをうまく制御することによって意図することを話し，目的を達している．このような運動制御を実現するためには，脳は何を計算しなければならないのであろうか．この問題に対して，川人（1986）は，次の3つのレベルの計算論的問題を脳は解かなければならないことを指摘している．

（1）軌道決定：作業座標での目標軌道の決定，（2）座標変換：作業座標での目標軌道の身体座標への座標変換，（3）運動制御：身体座標での目標軌道を実現するための運動司令の計算，の3点である．（1）は，ヒトが腕を動かすときに，例えばA点からB点に動かすときに，作業座標系でA点からB点間での軌道を決定する必要があることを述べている．（2）では，作業座標系で求められた軌道を，身体座標，つまり腕の関節角座標系への座標変換の問題が指摘されている．（3）において，実際に計画された軌道を実現するために必要な運動司令（例えば各筋肉への司令）が計算されてA点からB点への腕を動かす運動が実現される．

本論文では，川人（1986）の指摘した3つの計算論的問題の中の軌道決定の問題に関して考察する．特に運動制御の課題のなかでも，人間の書字動作は比較的フィードバックの要素が少なく，かつ，種々の軌道が観測される運動の1つであること

が指摘されている (Hollerbach, 1981) . 本論文においても, 軌道決定の問題における書字動作を主たる研究対象とする. 書字運動の研究には, 少なくとも2つの意義があると考えられる. 1つは, 人間の書字運動自体の解明の問題である. 書字運動は, 我々が日常行っている運動であるが, 文字を生成する過程は複雑で, 書字運動において脳がどのような働きをしているのかは良く理解されていない. 第2に, 文字の認識と書字運動の関係である. パターン認識の問題は, 種々のアプローチから試みられて着実な成果を上げているが, 脳の認識のプロセスに生成 (書字運動) のプロセスの情報が影響を与えていると主張する研究がある (Lieberman & Mattingly, 1985; Freyd, 1983; Babcock & Freyd, 1988) . つまり, 文字生成プロセスを使った認識システムが, 脳の情報処理機構から学んだ文字認識のアプローチとして考えられる. 従って, 本論でも運動パターンの生成と認識の問題を検討課題の1つとする.

ところで, Marr (1982) は上述したような脳の情報処理機構を理解するのに3つの水準があると述べている. (1) 計算理論, (2) 表現とアルゴリズム, (3) ハードウェアの3水準である. これは抽象的なレベルで何を計算すればいいのか, という水準, そしてそれを実現するための入出力の表現とアルゴリズムの水準, 物理的な具体化の水準であり, 実際の情報処理を具現化するために必要な階層でもある. 書字運動のモデルについて, この3水準についての議論を進めたいと考えている.

人の腕の随意運動を説明するモデルとして, 最適化原理に基づいた軌道決定の規範が提案されている. 1つは, Flash & Hogan (1985) によって提案されている躍度最小化規範である. これは作業座標での各座標の躍度 (加速度の時間微分) の2乗の運動時間に渡っての積分が最小になるように運動を計画するモデルである. つまり, 加速度の変化を滑らかにするように軌道を計画するモデルである. また, Uno, Kawato & Suzuki (1989) は, 関節に発生するトルクの変化が滑らかにするように運動計画がされるとした規範を提案している. この規範は, 各関節のトルクの変化の2乗の運動時間に渡っての積分の和が最小になるように軌道を計画する規範である. この2つの規範の違いは, 第2章で詳述するがトルク変化最小規範の方が幾つかの運動において人間の運動を良く再現し, 脳の計算理論の1つとして可能性の高い規範であることが既に示唆されている. 従って, 本論文では一環してトルク変化最小規範を計算理論としたモデルについて考える.

書字運動のモデルを, 上で述べたような計算理論に従って説明したモデルとして

Edelman & Flash (1987) の書字運動モデルがある。しかしながら、このモデルは上で述べた規範（躍度最小化規範）とは異なる規範に従った、つまりスナップ（躍度の時間微分）最小化規範に従ったモデルであった。スナップ最小化規範は理論的には躍度最小化規範を包含したモデルと考えることもできるが、逆に、このことは、モデルを複雑化したとも言える。少なくとも、工学的センスからすればモデルは簡単であることが望ましい。我々は、このような観点から、上述した随意運動での運動規範と同じ規範であるトルク変化最小規範に従った書字運動のモデルを研究対象とする。

トルク変化最小規範は、人間の腕のダイナミクスに依存した規範である。腕のダイナミクスは通常非線形なダイナミクスをもっており、トルク変化最小規範を満足する軌道を見出すためには、非線形最適化問題を解かなければならない。もし人間がトルク変化最小規範に従った軌道計画を行っているとしたならば、非常に短い時間で非線形最適化問題を解いていることになる。この最適化問題を解く神経回路網も幾つか提案されている (Kawato et al., 1990b; 中村ら, 1990)。しかし、これらのモデルには、脳のモデルとして次のような批判がある。(1) 時間を空間的に表現したモデルである。(2) 解を得るために時間逆向きの計算を必要とする。(3) 最適解を得るために多くの繰り返し計算を必要とする。このような批判を解決することが、トルク変化最小規範が脳の計算理論の1つとしての妥当性を増すことになると考えられる。我々は、このような問題を解決するために順ダイナミクスモデル (Forward Dynamics Model: FDM) と逆ダイナミクスモデル (Inverse Dynamics Model: IDM) を繰り返し計算することで非線形最適化問題の近似解を得て、上の批判を解決する Forward-Inverse Relaxation Model (FIRM) を提案する。

ところで、書字運動モデルは、あるシンボルに対応した軌道を生成するモデルであり、トルク変化最小規範のような汎関数の最適化問題を考えたとき、それは、各シンボルに対応する境界条件を設定する問題を解かなければならない。この場合は軌道の境界条件であるから、それは各軌道の通過する経由点に相当すると考えるのが妥当である。問題は、文字を構成するために必要な経由点をどうやって求めるかである。これは、文字の表現に関する問題と捉えることができるが、理論的な背景に従って、文字の表現を明らかにしようとした研究はないと思われる。この困難さは、Edelman & Flash (1987) に端的に指摘されている。第1は、経由点の数の問題である。経由点の数が多ければ、文字を構成することは比較的容易になるが、表現形

式の観点から考えれば、表現は簡便であることが望ましい。第2は、経路点を選択する理論的根拠である。文字軌道が与えられたとき、その文字軌道を生成するのに使われた経路点を推定する理論的な規準が必要である。少なくとも、この2つの問題点を解決しなければ、文字の表現の問題を整理することは容易ではないと考えられる。我々は、与えられた軌道から、その軌道を実現するために必要な経路点を推定するモデルを提案する。このモデルは、上述してきた最適化規準に基づいたモデルであり、上で指摘した2つの困難を克服したモデルである。

今までに、計算理論および表現とアルゴリズムについて議論してきたが、次にハードウェアの問題について触れる。ここでは神経回路網による実現に関する点に焦点を絞った議論をする。神経回路網モデルによる実現を考えたとき、学習によりその荷重を変更して、より良いモデルを実現することを目指す。一般的には学習には限られたデータ集合だけが用いられ、学習に使われなかった未知のデータ集合に対して、良い結果を与えるモデルが汎化能力の高いモデルとして、いわゆる良いモデルとしての評価を与えられる。汎化能力の高いモデルを構成する方法としては、学習方法自体の問題、神経回路網の素子の問題や、神経回路網の構造の問題など多くのアプローチが考えられる。今、幾つかの神経回路網のモデルが与えられたときに、最も汎化能力の高いモデルを選ぶ問題を設定したとき、これはモデル選択の問題であり、統計の分野で多くの規準が提案されている (Akaike, 1974; Rissanen, 1983)。ただし、神経回路網の荷重推定は、非線形モデルのパラメータ推定の問題であり、上で示したような規準を応用するだけでは必ずしも満足したモデルを得ることは出来ない。本論では、従来提案されているモデル選択の規準が、パラメータの最尤推定量が得られていることを前提にしている点を問題と捉えて、パラメータの最尤推定量が得られていない場合のモデル選択のために、交差確認法 (以下Cross Validation) と組み合わせた情報量規準を提案する。

最後に、この論文のもう一つの課題である運動パターンの生成と認識について述べる。生成と認識に何らかの関係があるという指摘は、上で述べた心理学の研究からの指摘以外にも、Kawato (1990) やHaken et al. (1990) によって行われている。それは、生成と認識が何らかの意味で双対関係にあるという指摘であり、生成と認識も同じモデル (神経回路網モデル) によって実現できる可能性があることが述べられている。実際に、生成と認識を同じモデルの枠組みで実現する研究も幾つかある (二見, 星宮, 1990; Simard & Le Cun, 1992)。我々は、上で述べた書字運動モデ

ルを応用した認識システムによって手書きの連続文字の認識が可能であることを示す。

本研究では、ヒトの運動制御に関する計算論的アプローチの成果である運動規範に基づいた運動パターンの生成と認識に関して、その表現とアルゴリズムについての研究およびその実現手法に関する研究を行う。この研究は、脳のモデルとしては、表現とアルゴリズムの観点から1つの理論的・実験的可能性を示し、ヒトの運動制御の理解を目的としている。工学的な面からは、運動規範に基づいた表現・アルゴリズムが、現在困難とされるパターン生成・認識の問題に1つのブレイクスルーを与える可能性があることを理論と実験から示すことを目的としている。また、具体的なモデルの構成において、新しい情報量規準が有効であることを示す。

1.2 論文の構成

本論文は、緒言と結言を含めて全体を6章で構成している。第1章の序論に続いて、まず第2章でトルク変化最小規範に基づいた軌道生成モデルについて述べる。第3章で、トルク変化最小規範を計算理論とする書字運動のモデルを述べる。次に第4章において、書字運動モデルを応用した続け文字の認識モデルについて述べる。第5章では、神経回路網での実現に関して、汎化能力の高いモデルを選択する方法について述べる。

第2章では、最適化原理（トルク変化最小規範）に基づいた人の腕の随意運動を説明するモデルを述べる。人間の腕の非線形性を考慮した場合、最適軌道を決定することは、拘束条件付きの非線形最適化問題を解かなければならず、その解法は一般には非常に困難な問題である。本論文では、制御対象の順・逆ダイナミクスモデルを使った最適化手法を提案し、これによる腕の最適軌道生成モデルを示す。また、このモデルの理論的検討を行い、このモデルがある種の非線形最適化問題の一般的解法であることを述べる。

第3章では、比較的複雑な運動である書字運動について考察する。我々は文字を幾つかの経由点を通る運動によって生成された軌道と捉え、文字軌道を経由点に変換する経由点推定モデルを提案する。このモデルは、基本的に上で述べた最適化原理に立脚したモデルであり、運動の特徴量を抽出するモデルであることを理論と実験から示す。本論文で述べる書字運動モデルは、文字の内部表現としては、前述し

た経路点推定モデルによって文字と対応付けられた経路点であり、文字軌道を生成する計算理論としては、軌道生成と同様の最適化原理である。つまり、提案する書字運動モデルは、生成理論と表現の観点から言えば、最適軌道生成モデルの延長上にあるモデルであると言える。実験によって、この書字運動モデルが人間の運動を良く再現・予測することを示す。また、合わせてこの経路点推定モデルを調音器官の運動に適用した結果を示し、推定された経路点を使って運動が再構成されることを示す。

第4章では、経路点推定モデルを使った手書き連続文字の認識について考察する。経路点推定モデルによって抽出された経路点から、上で述べたように軌道生成モデルによって、与えられた元の軌道を再現することが可能であり、逆に言えば、経路点推定モデルで推定された経路点は、文字の特徴量を抽出していると考えられ、これを応用した文字認識が可能であることを示す。特に、連続文字の認識の場合、経路点推定モデルは文字と文字の区切りに経路点を推定することが可能であり、推定された経路点を文字の区切りの候補とすることで、手書き連続文字の認識が可能であることを示す。また、我々は経路点推定モデルを調音器官の運動に適用して、実験によって、調音器官の運動において推定された経路点が、音韻の時刻と良く対応していることを示し、そして、“音声知覚の運動説”に基づいて、音声認識にも文字認識と同様に軌道生成モデルを考慮した音声知覚モデルが可能であることを指摘する。

第5章では、汎化能力の高い神経回路網によって、上で述べたモデルを実現する際の方法を述べる。神経回路網の荷重推定は非線形モデルのパラメータ推定であり、最尤推定量を得ることは非常に困難な問題である。本論では、AIC (Akaike Information Criterion) を基本とした、最尤推定量を得られない場合のモデル選択のための情報量規準を提案し、数値実験によって提案した情報量規準によって汎化能力の高いモデルが選択できることを示す。

第6章では、結論として以上に関する成果のまとめを行う。

第 2 章

制御対象の順・逆モデルを使った腕の最適軌道生成

2.1 はじめに

人の随意運動を考えたとき、人間は次の3つのレベルの計算論的問題（川人, 1986）を解かなければならない。

(1) 軌道決定の問題：作業座標での目標軌道の決定,

(2) 座標変換の問題：作業座標での目標軌道の身体座標への座標変換,

(3) 運動制御の問題：身体座標での目標軌道を実現するための運動司令の計算, である。この3つの計算論的問題の中で軌道決定の問題に関して、Uno, Kawato & Suzuki (1989) は人の腕の随意運動を説明するモデルとして、トルク変化最小基準を提案している。また、この基準を実現するハードウェアモデルとして、前田ら (1989) (Kawato et al., 1990b) は腕の順ダイナミクスモデル (Forward Dynamics Model: FDM 以下順モデル) をカスケード構造に構成した神経回路網モデルを提案し、それによってトルク変化最小基準を実現する軌道生成を行っている。また、中村ら (1990) は、逆に腕の逆ダイナミクスモデル (Inverse Dynamics Model: IDM 以下逆モデル) を並列に配置した神経回路網モデルによって、トルク変化最小基準を満たす軌道生成を実現している。これらのモデルによる軌道決定問題の解法は、数学的には腕の運動の終端条件と経由点条件を境界条件とし、腕の非線形ダイナミクスを拘束条件とする最適化問題を解くことと等価であり、ペナルティー法 (嘉納, 1987) などを使って最適解を求めることに対応していた。これを脳のモデルとしてみた場合に主として、3つの批判がありうる。

(1) 時間を空間的に表現している。

(2) 繰り返し計算の中で、拘束条件を満足するために誤差逆伝播 (より一般的に言えば情報を時間の後ろ向きに伝播する解法) をする必要がある。

(3) 最適解を得るための繰り返し計算の回数が非常に多くなる。

本章で提案する腕の軌道を生成するモデルは、順モデルとその逆関数である逆モデルの両モデルを交互に繰り返し計算することで、上で述べた3つの難点を解決するものであり、後述するこのモデルの基本的な4つの構成要素は各々神経回路網で実現できるモデルである。また、この神経回路網モデルで実現される拘束条件付最

適化問題の解法は、他の問題に対しても工学的応用が可能な手法である。

まず2関節マニピュレータを使った2点間の腕の運動の軌道生成の数値実験結果を示す。次にモデルを経由点のある運動に拡張し、その数値実験の結果を示す。最後に提案したモデルが、ある種の非線型最適化問題の一般的解法であることを理論的に示す。

2.2 最小化原理に基づいた軌道生成

Abend, Bizzi & Morraso (1982) は人の水平面内における2関節運動について実験を行い、2点間の運動のとき、その軌跡は、ほぼ直線になり、速度は、ほぼベル型をしていることを報告している。人はどのようにしてこのような運動軌道を決定し、実現しているのであろうか。このような運動軌道の決定について、評価関数の最適化によって軌道計画を行っているとするモデルが提案されている。本論文で扱う運動パターンの生成と認識のモデルも、この評価関数の最適化に基づいたモデルである。本節では、人の腕の軌道計画を説明するモデルとして提案されたトルク変化最小規範と、これに近似的に等価である躍度最小規範についてまとめる。

2.2.1 躍度最小化規範に基づいた軌道生成

到達運動は手先をある対象物まで動かすような運動であるが、2点間の運動でさえも可能な軌道は、無数に存在する。つまり、軌道計画は解が一意に定まらないという意味で不良設定問題になっている。しかしながら、人間は無数の解の中からただ1つの解を選んで到達運動を達成している。つまり不良設定問題に、適当な評価関数を付加して一意な解を得ていると思われる。このような軌道計画の問題に対する評価関数として、Flash & Hogan (1985) によって提案された躍度最小規範がある。この規範は式(2.1)に示すように、手先の加速度の微分(躍度)の2乗の積分を最小にするように手先の軌道を計画する規範である。

$$C_J = \int_0^{t_f} \left\{ \left(\frac{d^3 X}{dt^3} \right)^2 + \left(\frac{d^3 Y}{dt^3} \right)^2 \right\} dt \quad (2.1)$$

ただし、(X, Y)は視覚の作業座標での手先の座標を示し、

t_f は運動時間を表す。

この規範は、軌道の計画が視覚の作業座標だけに依存して計画されることを示唆したモデルであり、実験によって、人の運動軌道とよく一致することが確かめられた。また、この躍度最小規範に基づいた軌道を生成するハードウェアモデルである神経回路網も提案されている。(Jordan, 1989; Massone & Bizzi, 1989; Hoff & Arbib, 1992)

しかしながら、躍度最小モデルは人の腕の長さ、質量、粘性抵抗などの筋骨格系のダイナミクスとは無関係に、ただ、視覚の作業座標系での幾何学的な関係(キネマティクス: Kinematics)だけで軌道計画が行われるとしたモデルである。これに対して筋骨格系のダイナミクスと深く関係した規範が提案されている。

2.2.2 トルク変化最小規範に基づいた軌道生成

Uno, Kawato & Suzuki (1989) は、滑らかなトルクによってヒト腕の運動が行われていることを示す規準を提案した。それは次式に示すトルクの変化の2乗積分を最小にする基準である。

$$C_T = \int_0^{t_f} \sum_{j=1}^M \left(\frac{d\tau^j}{dt} \right)^2 dt \quad (2.2)$$

ただし、 τ^j : 関節 j のトルク

M : 関節の数

t_f : 運動時間

このトルク変化最小規範が、実際の人間の腕の運動を良く予測・再現することが確認されている。この規範は、トルクが近似的に加速度に比例すると考えられるから、躍度最小規範と関連のある規範であることがわかる。別の言い方をすれば、躍度最小規範は、トルク変化最小規範の近似解を与えることのできるモデルであると言える。実際にトルク変化最小規範と躍度最小規範によって求められた軌道は、ほぼ同じような軌道を再現した。特に身体の正面の2点間の運動では、トルク変化最小規範によって再現される軌道は、ほぼ直線であり、躍度最小規範による軌道は完全な直線軌道である。また、速度の形状はどちらもベル型の速度を予測した。

しかしながら、以下に示すような幾つかの運動において、2つの規範の予測する軌道は異なっていた。

(1) 手を真横に伸ばした状態から身体の正面に移動させる運動：

躍度最小規範では直線となるが，トルク変化最小規範では曲線軌道となる。

(2) 垂直平面内の2関節運動：

躍度最小規範では直線となるが，トルク変化最小規範では上下の大きな運動では曲線の軌道となる。

(3) 水平面内のばねに抗して行う2関節運動：

躍度最小規範では軌道は直線で速度はベル型になるが，トルク変化最小規範では曲がった軌道で，速度には2つのピークをもつことがある。

(4) 水平面内の経路点を通る曲線運動で，線対称なもの1対：

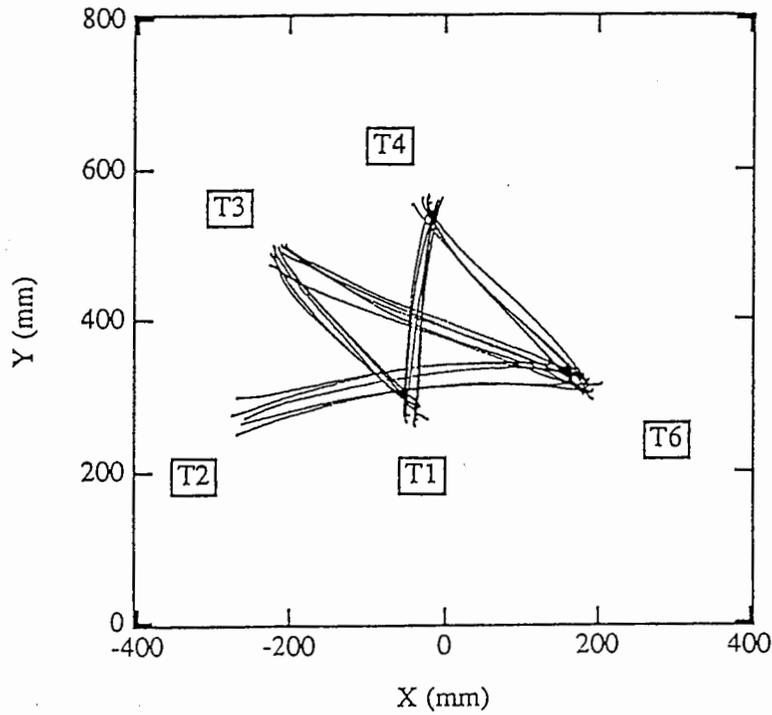
躍度最小規範は，その評価関数の並進，回転，折り返し不変により，軌道は線対称となり，速度は同一のものが予測される。しかしながら，トルク変化最小規範では体の外に凸な軌道の速度のピークは1つであるが，体の内に凸な軌道の速度プロフィールは2つのピークとなる。

上記の運動に対してUno et al. (1989) は，人を使った実験によって全てトルク変化最小規範の方が人間の運動により近いことを確かめている。

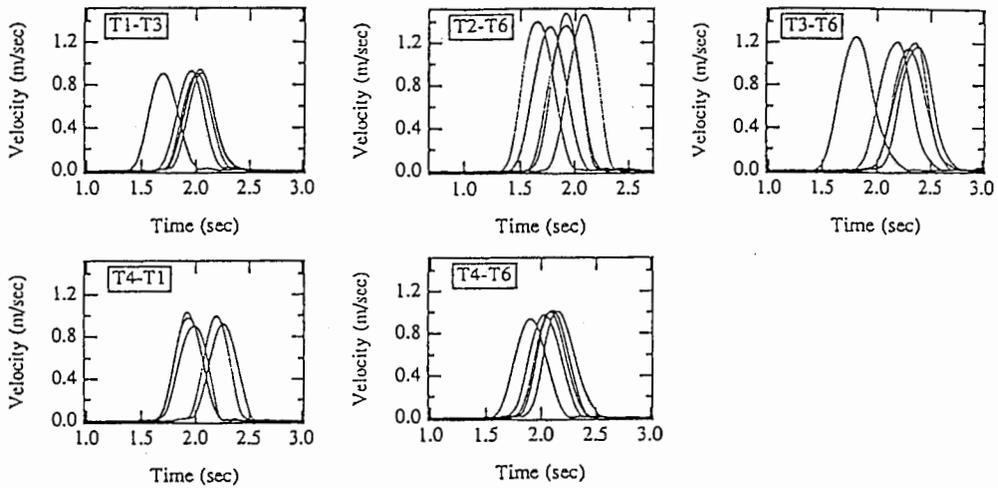
しかし，トルク変化最小規範は人の筋骨格系のダイナミクスを拘束条件とした最適化問題を解かなければならないが，人の筋骨格系のダイナミクスは非線形であるために，トルク変化最小規範を満足する軌道を得るためには，非線形最適化問題を解かなければならない。これは一般的には非常に困難な問題である。宇野，川人，鈴木 (1988) は，最適化問題におけるオイラー・ラグランジェ方程式として与えられる2点境界値問題を広義ニュートン法で求める方法 (Ojika & Kasue, 1979; 三井, 1981) を提案している。また，神経回路網を使ったモデルとしては，順ダイナミクスモデルをカスケード構造に構成したモデルが前田ら (1989) (Kawato et al., 1990b) によって提案されているし，逆に腕の逆ダイナミクスモデルを並列に配置したモデルによる神経回路網が中村ら (1990) によって提案されている。

図2.1～図2.4に(株)ATR人間情報通信研究所の小池康晴研究員らによって三次元位置計測装置OPTOTRAK(Northern Digital Inc. 製)を使って測定された人間の腕の運動軌道(小池ら, 1992; 小池 & 川人, 1993)を示す。この結果は宇野らの測定した結果と同じ傾向を示している。

また，最近トルク変化最小規範は，より生体系に沿ったモデルである筋張力変化最小規範，運動指令(変化)最小規範に展開され宇野ら(1989) (Dornay, Uno, Kawato



(a) 運動軌道



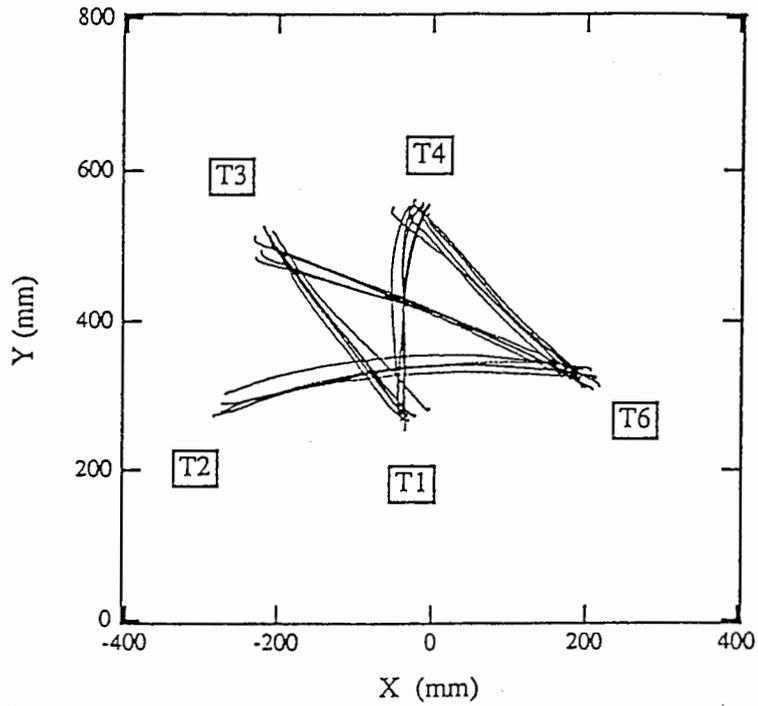
(b) 運動速度

図 2.1 2点間の運動の計測結果

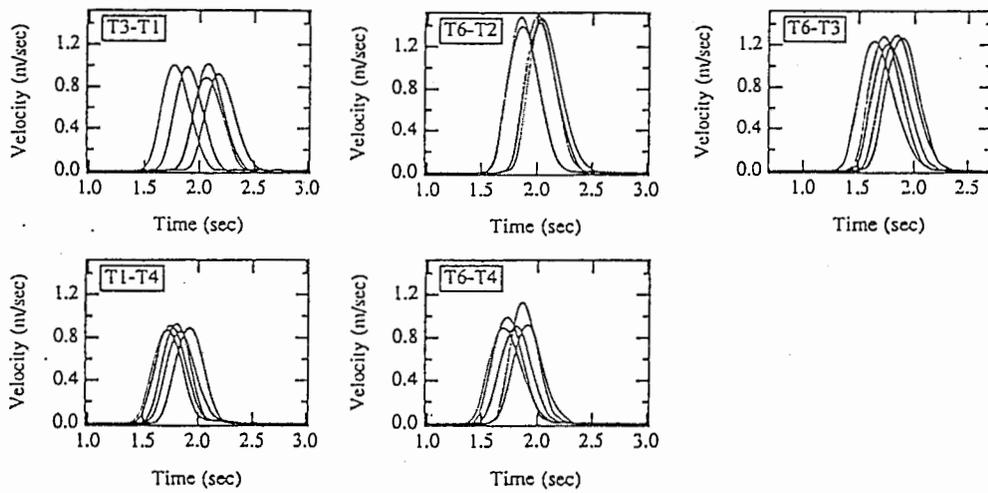
Fig 2.1 Hand trajectories observed in human arm movements.

運動軌道は、Uno et al. (1989) が計測した運動と同様の軌道である。T2->T6の運動において顕著であるように運動軌道は、少し体の外に凸型にふくらんだ運動軌道である。

なお、この計測結果は (株) ATR人間情報通信研究所小池康晴研究員がOPTOTRAKによって計測したデータである。(原点が肩の位置である。)



(a) 運動軌道



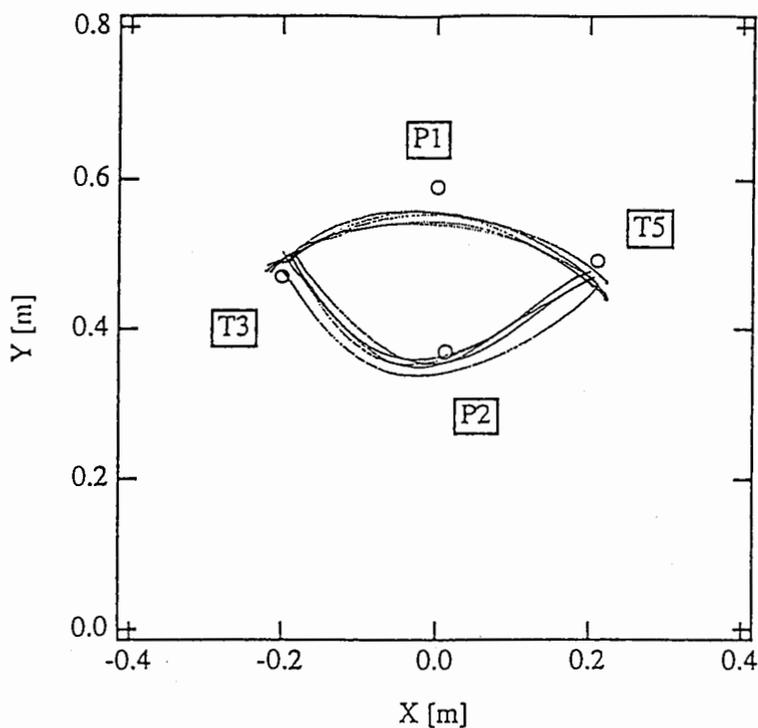
(b) 運動速度

図 2.2 2点間の運動の計測結果

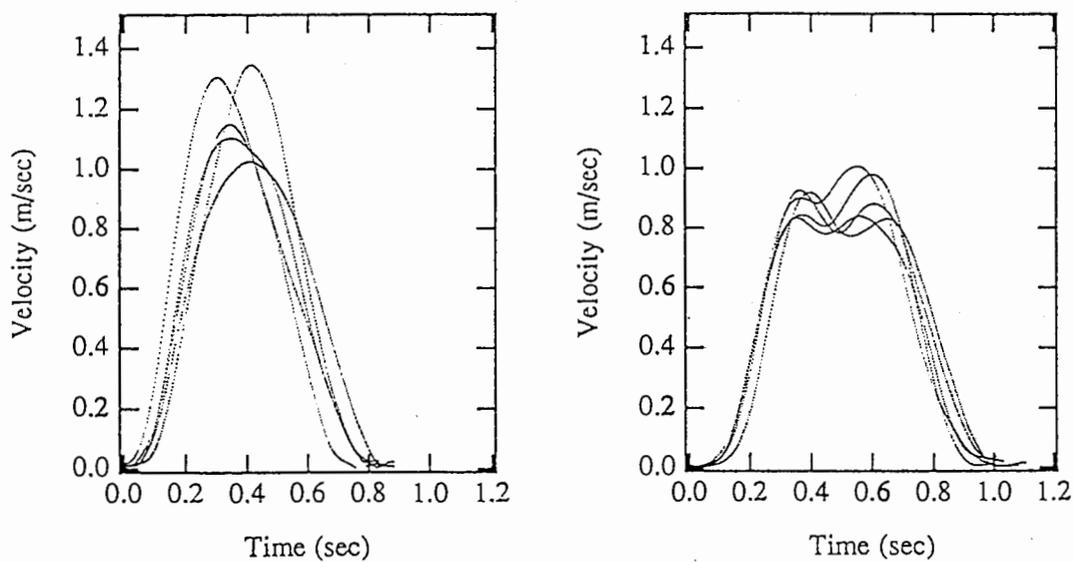
Fig 2.2 Hand trajectories observed in human arm movements.

運動軌道は、Uno et al. が計測した運動と逆の軌道である。図 2.1 と同様に少しふくらんだ運動軌道である。

((株) ATR人間情報通信研究所小池康晴研究員から提供頂いた。)



(a) 運動軌道



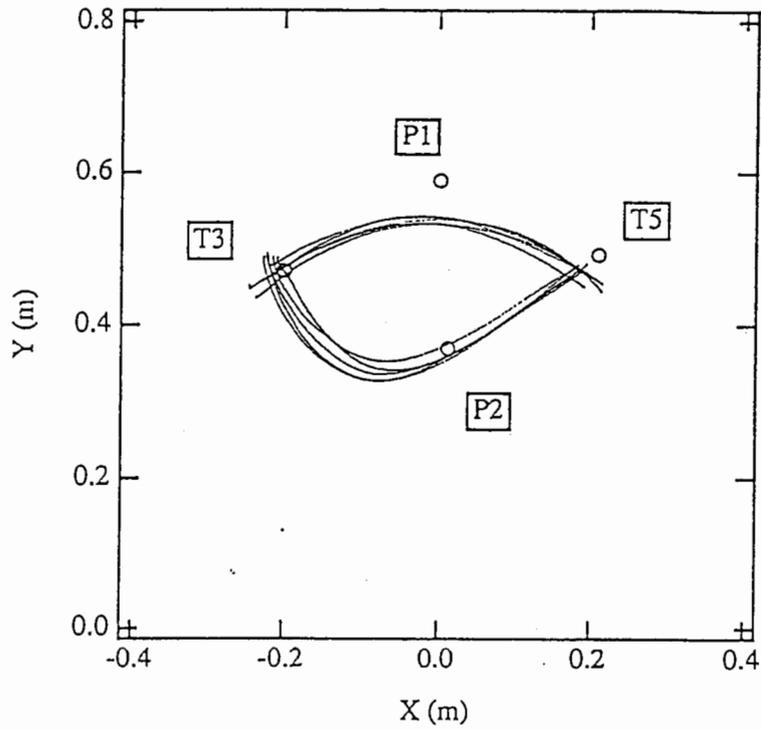
(b) 運動速度

図 2.3 経由点のある運動の計測結果

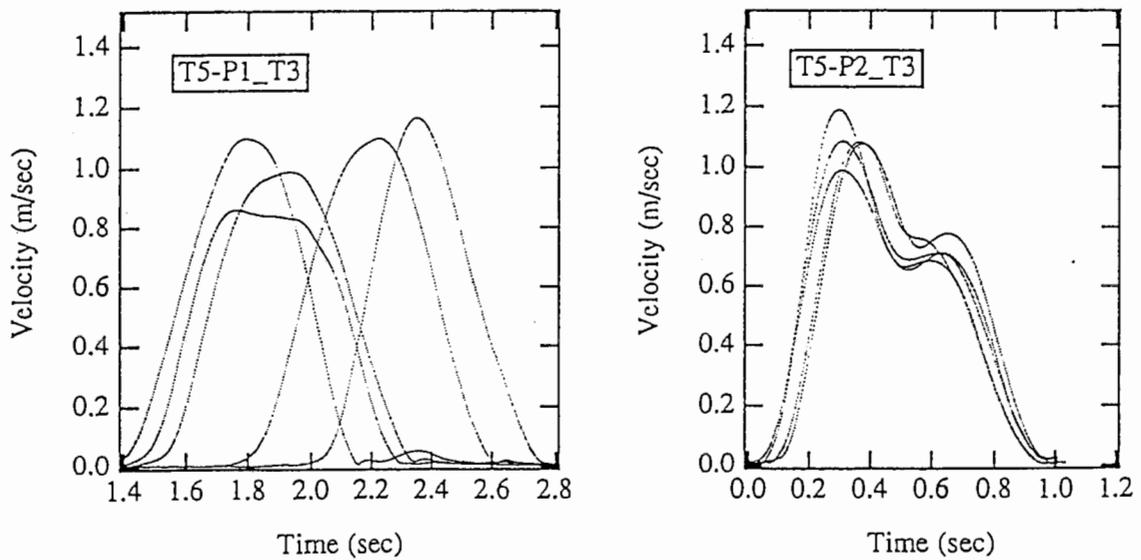
Fig 2.3 Hand trajectories observed in human arm via-point movements.

経由点が1つある場合の運動軌道。この例で顕著であるのは、T3→P2→T5の運動の速度パターンであり、ピークが2つの運動となっている点である。

((株) ATR人間情報通信研究所小池康晴研究員から提供頂いた。)



(a) 運動軌道



(b) 運動速度

図 2.4 経由点のある運動の計測結果

Fig 2.4 Hand trajectories observed in human arm via-point movements.

経由点が1つある場合の運動軌道(図2.3の逆方向の運動)。この例でも顕著であるのは、T5→P2→T3の運動の速度パターンであり、ピークが2つの運動となっている点である。(株)ATR人間情報通信研究所小池康晴研究員から提供頂いた。

& Suzuki, 1992) によって提案されている。しかしながら、これらのモデルも、非線形なダイナミクスを拘束条件とした最適化問題を解かなければならない点に関しては、トルク変化最小規範と同じであり、前述した3つの問題点を解消したモデルが必要である。

2.3 腕の最適軌道を生成する神経回路網

2.3.1 順モデルと逆モデルによる最適軌道生成神経回路網

トルク変化最小規範に従う軌道の生成を最急降下法（嘉納，1987）によって求めることを考える。この最適化問題の評価関数は次のように与えられる。式（2.3）は終端境界条件のある式（2.2）の最適化問題を、境界条件のない最適化問題のエネルギー関数に置き換えたものである。ここでは、2点間の運動について考えるものとし、離散的な時間で問題を定式化する。 i は時刻を示す添字とする。

$$\begin{aligned}
 E &= \frac{1}{2} \lambda \sum_{i=1}^N \sum_{j=1}^M (\tau_i^j - \tau_{i-1}^j)^2 + \frac{1}{2} \sum_{j=1}^M (\theta_d^j - \theta_N^j)^2 + \frac{1}{2} \sum_{j=1}^M (\dot{\theta}_d^j - \dot{\theta}_N^j)^2 \\
 &\quad + \frac{1}{2} \sum_{j=1}^M (\ddot{\theta}_d^j - \ddot{\theta}_N^j)^2 \\
 &= \lambda E_s + E_{pf} + E_{vf} + E_{af} \tag{2.3}
 \end{aligned}$$

ただし、目標位置を表す座標系から関節角度の座標系への変換によって終端での目標位置、速度および加速度が関節角座標 θ_d , $\dot{\theta}_d$, $\ddot{\theta}_d$ で与えられるとする。 θ , $\dot{\theta}$, $\ddot{\theta}$ は関節角座標での位置、速度、加速度を示す。また、添字 j は M 関節の j 番目を示し、添字 d は終端での目標を、添字 N は最終時刻での状態を示す。エネルギー E_s は、トルク変化に対応し、 E_{pf} , E_{vf} と E_{af} は各々最終時刻での位置、速度および加速度の誤差エネルギーを表す。このエネルギー関数を最急降下方向に緩和計算することを考えると、トルク τ_i^j に関する更新則は次の式で与えられる。

$$\begin{aligned}
 \frac{d\tau_i^j}{ds} &= - \frac{\partial E}{\partial \tau_i^j} \\
 &= \lambda (\tau_{i+1}^j + \tau_{i-1}^j - 2\tau_i^j)
 \end{aligned}$$

$$+ \sum_{k=1}^M (\theta_d^k - \theta_N^k) \frac{\partial \theta_N^k}{\partial \tau_i^j} + \sum_{k=1}^M (\dot{\theta}_d^k - \dot{\theta}_N^k) \frac{\partial \dot{\theta}_N^k}{\partial \tau_i^j} + \sum_{k=1}^M (\ddot{\theta}_d^k - \ddot{\theta}_N^k) \frac{\partial \ddot{\theta}_N^k}{\partial \tau_i^j} \quad (2.4)$$

ただし s は運動時間と無関係な緩和計算のための時間である。式 (2.4) 第2・第3・第4項は終端条件を満足させるために $\frac{\partial \theta_N^k}{\partial \tau_i^j}$, $\frac{\partial \dot{\theta}_N^k}{\partial \tau_i^j}$ と $\frac{\partial \ddot{\theta}_N^k}{\partial \tau_i^j}$ の計算で終端点から始点方向に時間逆方向きの計算 (誤差逆伝播) (Rumelhart, Hinton & Williams, 1986) をする必要があることを示している。通常、最適制御の諸手法ではオイラーラグランジュ方程式の随伴方程式を時間逆方向きに解くことがこれに対応する。しかしながら、終端条件を常に満足しつつ最急降下方向への繰り返し計算を行えば、式 (2.4) から考えて、誤差逆伝播の方法を用いる必要はない。つまり、誤差エネルギー E_{pf} , E_{vf} と E_{af} を常に0にできれば、更新則の誤差エネルギーに相当する項は消失し、トルクを滑らかにする操作だけで、トルク変化最小の軌道を得ることができる。

ここで、順モデルFDMは下式で表されるような時間の順方向に計算されるモデルで、現在の時刻での位置から次の時刻での位置を計算するのに使われる。また逆モデルIDMは、現在の軌道を得るのに必要なトルクを計算するのに使われるモデルであり、次のように与えておく。

$$\text{FDM: } \Theta_{i+1} = F(\Theta_i, \tau_i)$$

$$\text{IDM: } \tau_i = I(\Theta_i)$$

ただし、

$$\Theta_i = (\theta_i^1, \theta_i^2, \dots, \theta_i^M, \dot{\theta}_i^1, \dot{\theta}_i^2, \dots, \dot{\theta}_i^M, \ddot{\theta}_i^1, \ddot{\theta}_i^2, \dots, \ddot{\theta}_i^M)$$

$$\tau_i = (\tau_i^1, \tau_i^2, \dots, \tau_i^M)$$

ところで、順モデルが神経回路網モデルで実現できることはKawato et al. (1989, 1990b) やJordanのリカレントネット (Jordan & Rumelhart, 1992) で示されている。また、逆モデルが神経回路網モデルで実現できることは、Kawato et al. (1987; 1990a) によって示されている。

いま仮に終端条件を満足するようなトルクが与えられ、それを式 (2.4) のトルクの更新則に従って変化させることを考える。右辺第2項、第3項および第4項は0となり、第1項のトルクを滑らかにする更新則のみが残る。

$$\frac{d\tau_i^j}{ds} = \lambda (\tau_{i+1}^j + \tau_{i-1}^j - 2\tau_i^j) \quad (2.5)$$

式 (2.5) のトルクの更新の結果得られる軌道 Θ は通常終端条件を満足しなくなる。ここで、式 (2.4) 右辺第 2 項, 第 3 項, 第 4 項を 0 にするために、終端での誤差を補償する軌道 $\Delta\Theta$ を生成することを考える。ここでは、制御対象を簡単化 (線型化) した問題に対するトルク変化最小解 $\Delta\Theta$ を用いる。すると、 $\Theta + \Delta\Theta$ は、終端条件を満足する軌道となる。このときトルク τ と軌道 $\Theta + \Delta\Theta$ はダイナミクスを満足していない。ここで、終端条件を満足し、かつダイナミクスを満足するトルクを逆モデルを使って求める。

$$\tau_i = I(\Theta_i + \Delta\Theta_i) \quad (2.6)$$

いま得られている τ と $\Theta + \Delta\Theta$ は、終端条件とダイナミクスを満足した解であり、エネルギー関数 E の最急降下方向の計算は上で述べたようにトルクを滑らかにするだけでよい。

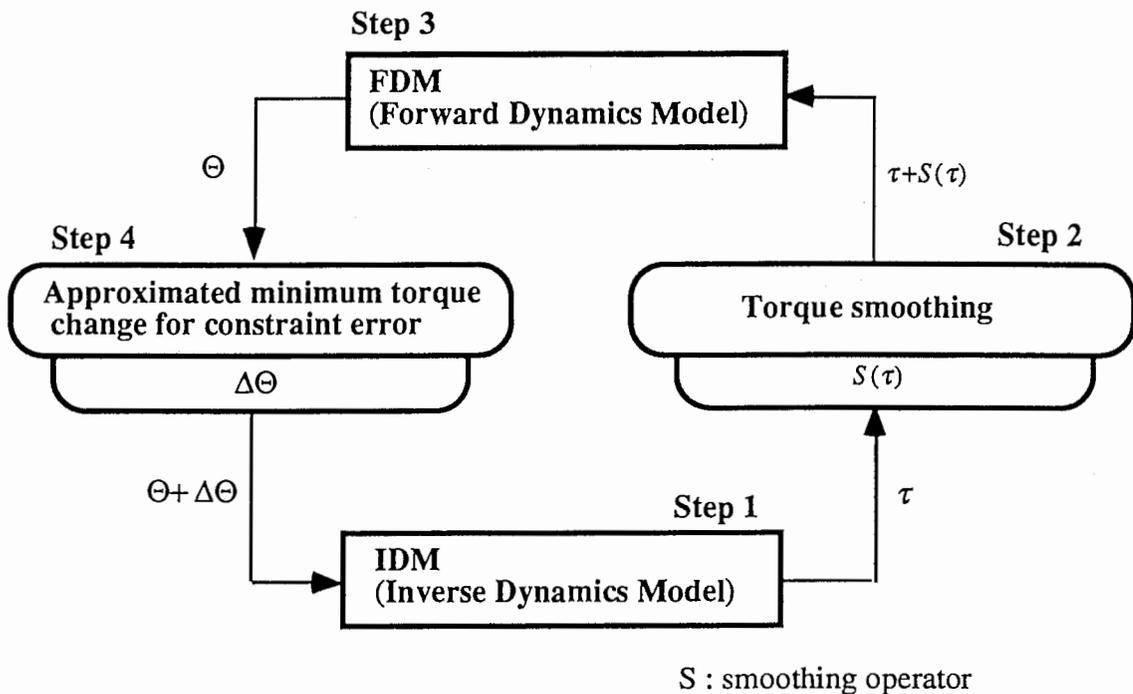


図 2.5 腕の軌道生成のための神経回路網構造

Fig.2.5 Neural network structure of trajectory formation in arm movement.

S は滑らかさのオペレーターを示している。逆モデル (IDM) の入力 $\Theta + \Delta\Theta$ と出力 τ は、運動の境界条件とダイナミクス条件を満足した解である。

ところで、ここではエネルギー関数を最急降下方向に動かすことで式(2.5)を導いた。しかし、トルクを滑らかにする操作は式(2.5)に限定する必要はなく、例えば第2.4節の数値実験で用いるフィルターなど様々な可能性がある。つまり、 S をトルクを滑らかにするオペレータとすると、式(2.5)は、一般に次のようにかける。

$$\frac{d\tau_i^j}{ds} = S(\tau_i^j)$$

エネルギー関数を最急降下方向に動かす滑らかさのオペレータ S は、式(2.5)を連続時間で表したオペレータ $\lambda \cdot d^2\tau/dt^2$ で表わされる。

いままで述べた一連のアルゴリズムを図で示すと図2.5のようになる

(Step1) 終端条件を満足する関節角軌道から、逆モデルを通して計算することでダイナミクスを満足し、かつ終端条件を満足するトルクと関節角を与える。

(Step2) トルクを滑らかにするよう更新する。

(Step3) Step2で得たトルクは、通常終端条件を満足していないので、順モデルを通して軌道を計算することで、終端条件の誤差を得る。

(Step4) 終端条件の誤差を補償する軌道を計算し、それを元の軌道と足し合わせて、終端条件を満足する軌道 $\Theta + \Delta\Theta$ を得る。

(Step1) から (Step4) を繰り返し計算することでトルク変化最小の軌道を求める。

ただし、Step1で終端条件を満足する軌道が与えられない場合(例えば、0のような始点に止まっている軌道)でも問題はなく、この場合も同様にStep3で終端を満足する軌道が生成される。

このモデルの理論的根拠は、2.6節で議論する。

2.4 数値実験

本節では、前節で提案した神経回路網モデルによる数値実験結果を示すが、今回の実験で用いた順モデルと逆モデルは数式モデルによる。実験は2点間の運動について行った。制御対象である腕のモデルとしては、以下に示す式で表せるような2関節のマニピュレータを使った。

$$\tau_1 = (I_1 + I_2 + 2M_2L_1S_2 \cos\theta_2 + M_2(L_1)^2)\ddot{\theta}_1$$

$$\begin{aligned}
 &+ (I_2 + M_2 L_1 S_2 \cos \theta_2) \ddot{\theta}_2 \\
 &- M_2 L_1 S_2 (2 \dot{\theta}_1 + \dot{\theta}_2) \dot{\theta}_2 \sin \theta_2 + b_1 \dot{\theta}_1
 \end{aligned} \tag{2.7}$$

$$\begin{aligned}
 \tau_2 = & (I_2 + M_2 L_1 S_2 \cos \theta_2) \ddot{\theta}_1 + I_2 \ddot{\theta}_2 \\
 & + M_2 L_1 S_2 (\dot{\theta}_1)^2 \sin \theta_2 + b_2 \dot{\theta}_2
 \end{aligned} \tag{2.8}$$

ただし、 τ_i , θ_i , $\dot{\theta}_i$, $\ddot{\theta}_i$ は各関節のトルク, 位置, 速度, 加速度を示し, M_i , L_i , S_i , I_i , b_i は, 各腕の重量, 長さ, 重心から関節までの長さ, 慣性および粘性係数を示す. 添え字 i は, 各関節を示し 1 が肩を, 2 が肘に対応する. 各パラメータの値は Uno et al. (1989) と同じである (表 2.1). 第 2.3 節で提案したモデルを使うためには, まず, 補償軌道 $\Delta\Theta$ を求めるモデルを決める必要がある. 本節の数値実験では, 2 種類の軌道 $\Delta\Theta$ に関して実験を行った. 最初は, 上で示した 2 関節マニピュレータの線型近似モデルを考え, そのモデルでのトルク変化最小解を補償軌道 $\Delta\Theta$ とする. 第 2 のモデルとしては, 制御対象の時間不変で関節間での相互作用のない質点系モデルを考え, このトルク変化最小解を補償軌道 $\Delta\Theta$ とする. 補償軌道は近似的な最適軌道といえるが, リカレント型神経回路モデルに近似最適軌道を学習で獲得させることが示されている (Massone & Bizzi, 1989; Jordan, 1989).

また, 本数値実験では s として $\lambda \cdot d^2/dt^2$ を適当な回数繰り返して得られる式 (2.9), 式 (2.10) で表されるオペレータを選ぶ. 式 (2.9) は, 式 (2.5) を離散時間 s で表現したものである.

表 2.1 数値実験に使った腕のパラメータの値

Table 2.1 Values of physical parameters of the two-joint manipulator.

Parameter	Link1	Link2
M_i (Kg)	0.9	1.1
L_i (m)	0.25	0.35
S_i (m)	0.11	0.15
I_i ($\text{kg} \cdot \text{m}^2$)	0.065	0.100
b_i ($\text{kg} \cdot \text{m}^2/\text{s}$)	0.07	0.07

$$\begin{aligned}\tau_i^j(s+1) &= \tau_i^j(s) + \frac{d\tau_i^j}{ds}\Delta s \\ &= \tau_i^j(s) + \lambda(\tau_{i+1}^j(s) + \tau_{i-1}^j(s) - 2\tau_i^j(s))\end{aligned}\quad (2.9)$$

ただし, $\Delta s = 1$

いま, 式 (2.9) の滑らかさの繰り返し計算の演算回数を n とすると, n を大きくすることによって, より滑らかなトルク波形を式 (2.10) によって得ることができる. n を十分大きくすると, トルクは全時間にわたって 0 に近くなる.

$$\begin{aligned}\tau_i^j(s, k+1) &= \tau_i^j(s, k) + \lambda(\tau_{i+1}^j(s, k) + \tau_{i-1}^j(s, k) - 2\tau_i^j(s, k)) \\ \tau_i^j(s+1) &= \tau_i^j(s, n+1)\end{aligned}\quad (2.10)$$

ただし, $k = 1, 2, \dots, n$

2.4.1 線型近似モデルによる数値実験

まず, 2 関節マニピュレータの線型近似モデルのトルク変化最小解の計算についてまとめる. いま式 (2.7), 式 (2.8) を一般的に,

$$\frac{d}{dt}\theta_i = f_i(\theta_1, \theta_2, \dot{\theta}_1, \dot{\theta}_2, \tau_1, \tau_2) \quad (i = 1, 2) \quad (2.11)$$

と書き直す. このとき線型化方程式は次式で与えられる.

$$\frac{d}{dt}\mathbf{X}(t) = \mathbf{A}(t)\mathbf{X}(t) + \mathbf{B}(t)\mathbf{U}(t) \quad (2.12)$$

ただし,

$$\mathbf{X}(t) = (\xi_1(t) \ \xi_2(t) \ \dot{\xi}_1(t) \ \dot{\xi}_2(t) \ \eta_1(t) \ \eta_2(t))^T$$

$$\mathbf{U}(t) = (\dot{\eta}_1(t) \ \dot{\eta}_2(t))^T$$

$$\mathbf{A}(t) = \begin{pmatrix} 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ \frac{\partial f_1(\Theta)}{\partial \theta_1} & \frac{\partial f_1(\Theta)}{\partial \theta_2} & \frac{\partial f_1(\Theta)}{\partial \dot{\theta}_1} & \frac{\partial f_1(\Theta)}{\partial \dot{\theta}_2} & \frac{\partial f_1(\Theta)}{\partial \tau_1} & \frac{\partial f_1(\Theta)}{\partial \tau_2} \\ \frac{\partial f_2(\Theta)}{\partial \theta_1} & \frac{\partial f_2(\Theta)}{\partial \theta_2} & \frac{\partial f_2(\Theta)}{\partial \dot{\theta}_1} & \frac{\partial f_2(\Theta)}{\partial \dot{\theta}_2} & \frac{\partial f_2(\Theta)}{\partial \tau_1} & \frac{\partial f_2(\Theta)}{\partial \tau_2} \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{pmatrix}$$

$$\mathbf{B}(t) = \begin{pmatrix} 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix}^T$$

ξ_1, ξ_2 は修正軌道での位置を示し, $\dot{\xi}_1, \dot{\xi}_2$ は速度を示す. また, η_1, η_2 はトルクを示す. 添字は各関節を表す.

よって, 問題は次のように定式化される.

$$J = \frac{1}{2} \int (\mathbf{U}^T \mathbf{Q} \mathbf{U}) dt \quad \rightarrow \quad \text{Min} \quad (2.13)$$

$$\text{ただし, } \mathbf{Q} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

この最適化問題の境界条件は, 平滑化操作Sによって生じる終端誤差で与えられる. $\Delta\theta_1, \Delta\theta_2$ は目標終端位置との誤差, $\Delta\dot{\theta}_1, \Delta\dot{\theta}_2$ は目標終端速度との誤差, $\Delta\tau_1, \Delta\tau_2$ は目標終端トルクとの誤差を示す.

$$\xi_1(0)=0 \quad \xi_1(t_f)=\Delta\theta_1$$

$$\dot{\xi}_1(0)=0 \quad \dot{\xi}_1(t_f)=\Delta\dot{\theta}_1$$

$$\xi_2(0)=0 \quad \xi_2(t_f)=\Delta\theta_2$$

$$\dot{\xi}_2(0)=0 \quad \dot{\xi}_2(t_f)=\Delta\dot{\theta}_2$$

$$\eta_1(0)=0 \quad \eta_1(t_f)=\Delta\tau_1$$

$$\eta_2(0)=0 \quad \eta_2(t_f)=\Delta\tau_2 \quad (2.14)$$

この問題は, リカッチ方程式で解ける (Bryson & Ho, 1975) .

本節の実験条件を以下に示す.

- (1) 運動時間: 0.75 (s)
- (2) サンプル時間: 0.01 (s)
- (3) 運動の始点T2, 終点T6 (座標は表 2.2 参照)
- (4) 平滑化操作Sの繰り返し回数 n : $n = 100$ 回

とした. 図 2.6 に繰り返し計算回数とそのときの評価関数値 (式 (2.2) に相当する値) をプロットした結果を示す. 初期値として作業座標での加速度の変化を最小

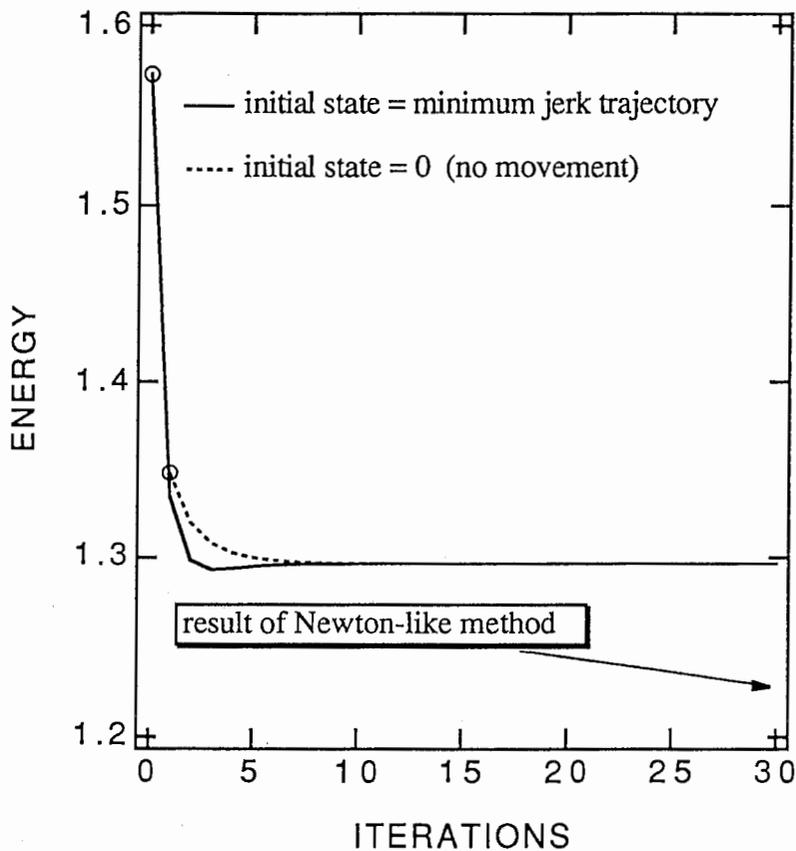


図 2.6 トルク変化最小規範の評価関数の収束性

Fig2.6 Convergence of the minimum torque-change criterion

提案したモデルによる解の収束性を, 運動軌道T2→T6によって確認した. 2つの初期値によって確認している. 1つは躍度最小軌道であり, もう1つは, 0である. この後者の場合は, 繰り返し計算の1回目の補償軌道生成において元々の境界条件を満足する軌道が, 線型近似モデルのトルク変化最小解として計算される.

表 2.2 運動の始点・終点の座標

Table 2.2 X-Y coordinates of initial target and intermediate points.

	X (cm)	Y (cm)
T1	- 0.92	30.36
T2	-24.33	30.89
T3	-19.94	47.11
T4	0.15	58.92
T5	21.09	49.33
T6	21.24	32.63
P1	0.15	58.93
P2	1.31	36.96

ただし、原点 (0, 0) の位置が肩の位置である。

にする解（躍度最小解）を与えた場合も、0を与えた場合も、オイラーラグランジェ方程式として与えられる2点境界値問題を広義ニュートン法（宇野ら，1988）で求めた最適解に近い値で収束していることがわかる。つまり，補償軌道 $\Delta\theta$ として，線型化方程式のトルク変化最小解を与えたときには，5回以内の繰り返し計算によって，ほぼ最適解と同程度の評価関数値を持つ軌道が得られることになる。

2.4.2 質点系モデルによる数値実験

本節では，前節で使った線型化方程式を簡単化した時間不変で関節間での相互作用のない次式に示すようなモデルを考える。

$$\eta_j = I^j \ddot{\xi}_j + B^j \dot{\xi}_j + K^j \xi_j \quad (2.15)$$

このトルク変化最小解は解析的に求めることができ，特に $B^j = 0$ ， $K^j = 0$ のときは，最も簡単な質点系のモデルとなり，関節角座標での躍度最小解（Flash & Hogan, 1985）と一致し，時間 t の5次多項式で与えられる。

$$\xi_j(t) = a_0 + a_1 t + a_2 t^2 + a_3 t^3 + a_4 t^4 + a_5 t^5 \quad (2.16)$$

$$a_0 = \xi_j(0)$$

$$a_1 = 0$$

$$a_2 = 0$$

$$a_3 = \left\{ 10(\xi_j(t_f) - \xi_j(0)) - 4\dot{\xi}_j(t_f) \cdot t_f + \frac{1}{2}\ddot{\xi}_j(t_f) \cdot t_f^2 \right\} / t_f^3$$

$$a_4 = \left\{ -15(\xi_j(t_f) - \xi_j(0)) + 7\dot{\xi}_j(t_f) \cdot t_f - \ddot{\xi}_j(t_f) \cdot t_f^2 \right\} / t_f^4$$

$$a_5 = \left\{ 6(\xi_j(t_f) - \xi_j(0)) - 3\dot{\xi}_j(t_f) \cdot t_f + \frac{1}{2}\ddot{\xi}_j(t_f) \cdot t_f^2 \right\} / t_f^5$$

ただし、 t_f は運動時間、 ξ_j 、 $\dot{\xi}_j$ 、 $\ddot{\xi}_j$ は各々終点の位置、速度、加速度を示す。また、このときの境界条件は、式(2.14)と同様であるが、式(2.14)では加速度の境界条件がトルクの境界条件として与えられている。

Uno et al. (1989) が測定した5種類の軌道a) T2 → T6, b) T3 → T6, c) T1 → T3, d) T4 → T1, e) T4 → T6 (座標は表2.2参照) を生成した。実験条件は、運動時間0.75 (s), サンプル時間0.01 (s) である。また、各運動で使用したパラメータと繰り返し計算の打ち切り回数を表2.3に示す。この数値実験では、初期値としては、作業座標での躍度最小解を与えた。繰り返し計算の打ち切り基準としては、評価関数値が最初に極小値をとった時点を繰り返しの打ち切りとした。表2.4に運動毎の広義ニュートン法、躍度最小解および本方法での極小評価関数値を示す。表2.3および表2.4からわかるように非常に少ない繰り返し計算によって、最適解(広義ニュートン法で求めた解)に近い評価関数値を得ていることがわかる。また、そのとき得られたX-Y軌道、速度、トルクを図2.7, 図2.8, 図2.9に示す。X-Y軌道に関しては、躍度最小解は2点間の直線軌道を与えるが、今回提案した方法では、トルク変化最小解の特徴である少し膨らんだ軌道が得られている。また、速度は、躍度最小解と同様にベル型の速度波形を出力しており、広義ニュートン法で得た解と良く一致している。トルク波形も滑らかである。つまり、質点系のような制御対象の非常に簡単なモデルを使っても、近似最適解が少ない繰り返し計算によって得られることがわかる。

また、表 2.5, 表 2.6 および図 2.10 に宇野らの測定した運動方向（以下、順方向と呼ぶ）と逆方向の運動に対して軌道生成を行った例を示す。傾向は、ほとんど順方向の運動と同じである。これは、粘性項による影響が小さいためと考えられる。

表 2.3 数値実験に使ったパラメータと繰り返し計算の回数

Table 2.3 Computer simulation parameters and number of iterations required to calculate a minimum for the objective function for each movement.

movement	λ	number of smoothing	number of iteration
T2-T6	0.3	30	5
T3-T6	0.3	60	1
T1-T3	0.3	30	2
T4-T1	0.3	30	3
T4-T6	0.3	30	1

表 2.4 各運動での評価関数の値

Table 2.4 Value of the minimum torque-change criterion.

movement	proposed method	Newton-like	minimum jerk
T2-T6	1.374	1.229	1.573
T3-T6	1.183	1.131	1.184
T1-T3	3.164×10^{-1}	3.051×10^{-1}	3.227×10^{-1}
T4-T1	1.920×10^{-1}	1.589×10^{-1}	2.968×10^{-1}
T4-T6	7.515×10^{-1}	7.156×10^{-1}	7.814×10^{-1}

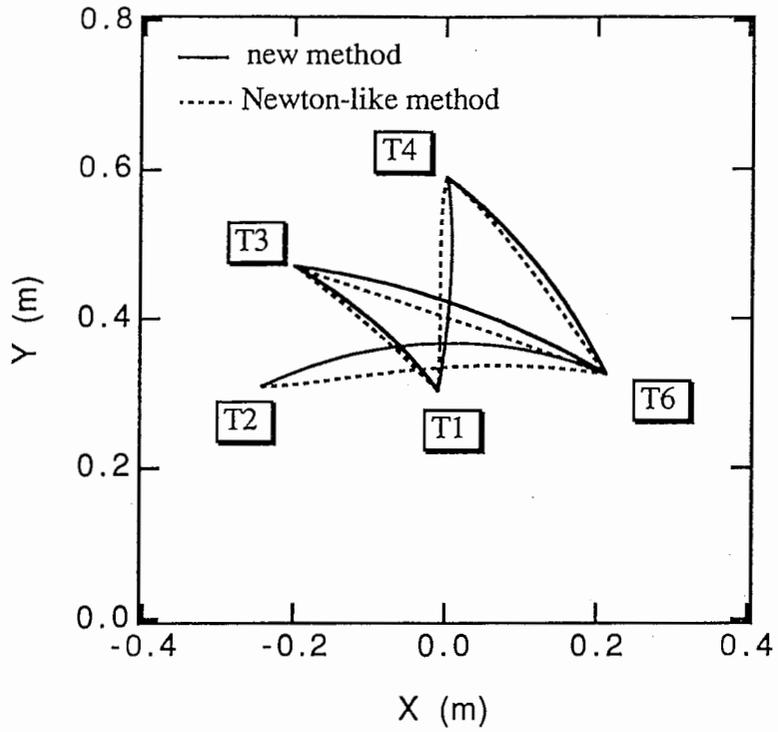


図 2.7 各運動の軌道

Fig2.7 Trajectory of each movement.

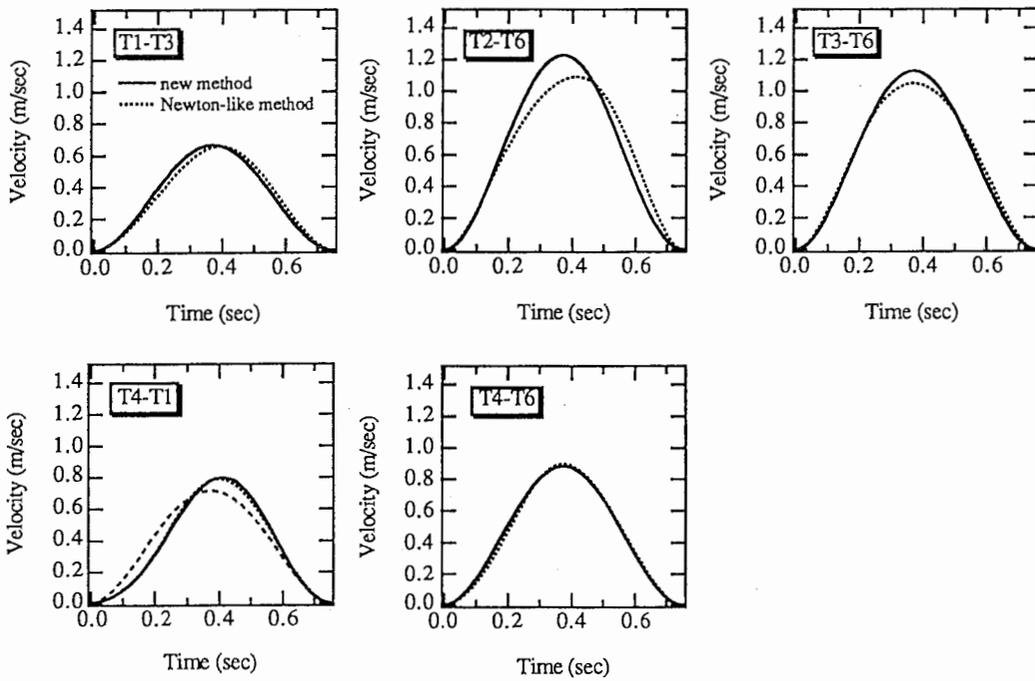


図 2.8 各運動の速度

Fig2.8 Speed profile.

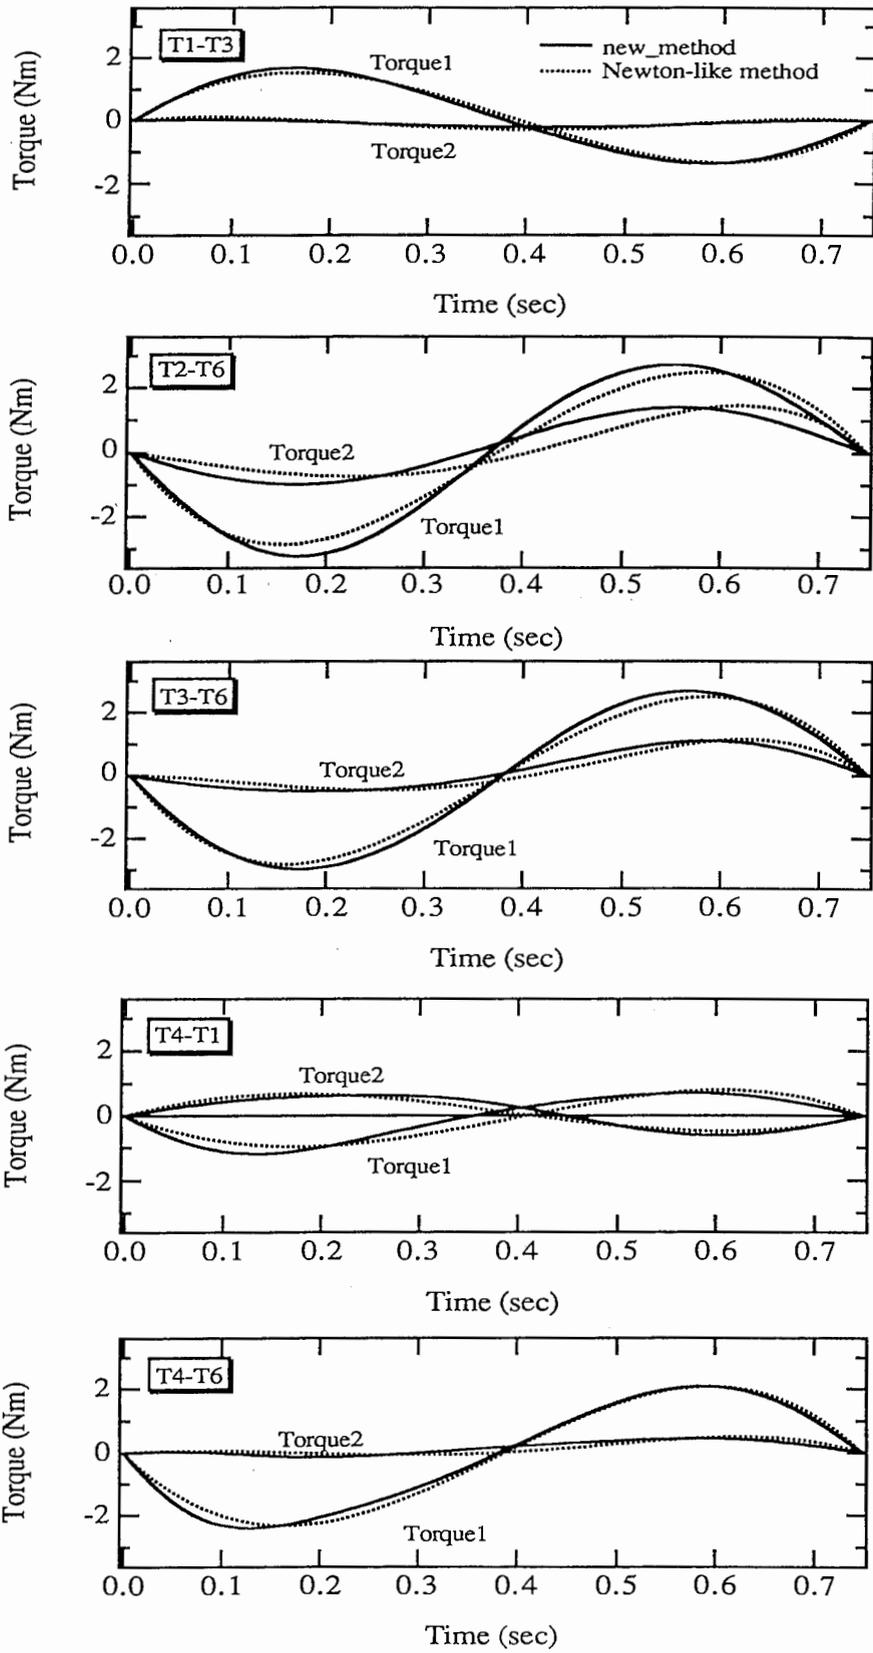


図 2.9 各運動のトルク

Fig2.9 Torque profile.

表 2.5 数値実験に使ったパラメータと繰り返し計算の回数

Table 2.5 Computer simulation parameters and number of iterations required to calculate a minimum for the objective function for each movement.

movement	λ	number of smoothing	number of iteration
T6-T2	0.3	30	4
T6-T3	0.3	60	1
T3-T1	0.3	30	2
T1-T4	0.3	30	3
T6-T4	0.3	30	1

表 2.6 各運動での評価関数の値

Table 2.6 Value of the minimum torque-change criterion.

movement	proposed method	Newton-like	minimum jerk
T6-T2	1.366	1.229	1.575
T6-T3	1.201	1.136	1.189
T3-T1	3.113×10^{-1}	3.049×10^{-1}	3.214×10^{-1}
T1-T4	1.702×10^{-1}	1.449×10^{-1}	3.023×10^{-1}
T6-T4	7.410×10^{-1}	7.156×10^{-1}	7.929×10^{-1}

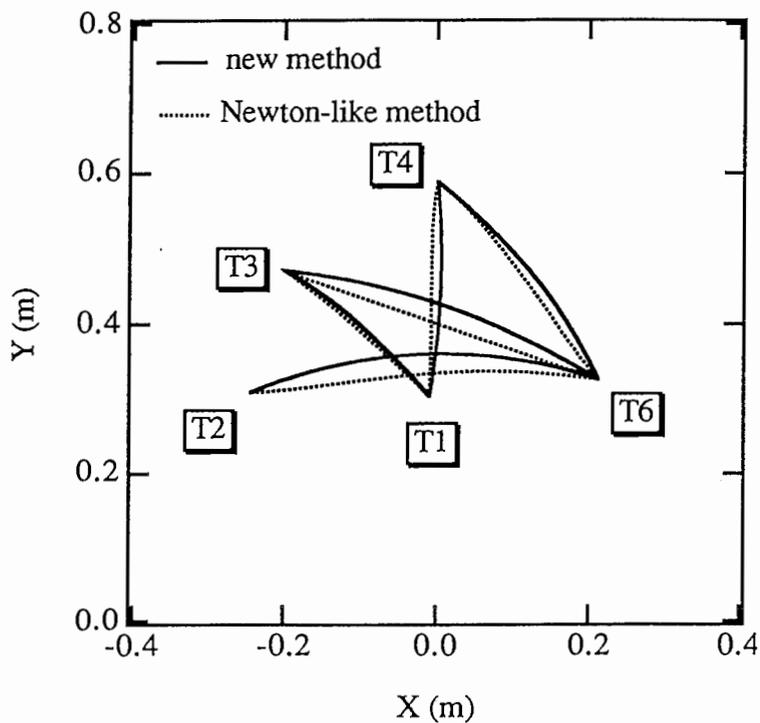


図 2.10 各運動の軌道

Fig2.10 Trajectory of each movement.

ここで示した軌道は、図 2.7 の運動と逆方向の運動軌道である。広義ニュートン法と提案した方法によって求めた軌道を示す。傾向としては、図 2.7 とほぼ同じである。2 点間の運動軌道の場合、躍度最小軌道によって計画される軌道は逆方向の運動であっても完全に直線になる。

2.5 経路点のある運動への拡張

2.5.1 経路点のある運動軌道の生成

2.3節で提案したモデルは、経路点のある運動軌道の生成に拡張することが可能である。経路点のある運動においては、経路点の位置が境界条件として、2点間の運動に追加される。従って、式(2.17)で表されるような評価関数が、式(2.3)の代わりに定式化される。

$$E = \frac{1}{2} \lambda \sum_{i=1}^N \sum_{j=1}^M (\tau_i^j - \tau_{i-1}^j)^2 + \frac{1}{2} \sum_{j=1}^M (\theta_d^j - \theta_N^j)^2 + \frac{1}{2} \sum_{j=1}^M (\dot{\theta}_d^j - \dot{\theta}_N^j)^2 + \frac{1}{2} \sum_{j=1}^M (\ddot{\theta}_d^j - \ddot{\theta}_N^j)^2 + \frac{1}{2} \sum_{j=1}^M (\theta_{via}^j - \theta_V^j)^2 \quad (2.17)$$

ただし、 θ_{via}^j は関節 j の目標経路点での位置とする。 θ_V^j は関節 j の時刻 V ($V; 1 \leq V \leq N-1$)での位置を表す。

2点間の運動と経路点のある運動には、基本的に2つの違いがある。第1は、2点間の運動においては、始点から終点間での時間が与えられていたが、経路点のある運動では、経路点を通過する時刻が与えられていない点である。第2は、経路点での速度と加速度が境界条件として与えられていない点である。この2点は、逆に言うと、経路点を通過する時刻、経路点での速度および加速度が境界条件として与えられれば2.3節で提案したモデルによって、経路点のある運動の軌道生成が可能となる。というのは、始点から経路点の軌道と、経路点から終点の軌道が2.3節のモデルで生成可能となるからである。

図2.5のStep4での補償軌道の生成における経路点での速度・加速度について考える。補償軌道を式(2.15)で表されるような質点系モデルで生成することを考えると、この補償軌道に対する始点、経路点および終点での位置・速度・加速度が境界条件として与えられると補償軌道を生成することができる。しかしながら経路点のある運動では、始点および終点での位置・速度・加速度、経路点での位置が境界条件として与えられ、補償軌道の評価関数は、式(2.18)で表されるように経路点での速度の境界条件 $\Delta \dot{\theta}_{via}$ ・加速度の境界条件 $\Delta \ddot{\theta}_{via}$ の関数として与えることができる。ただし、関節を示す添字 j は省略する。 t_{via} は経路点の時刻である。(Δは補償軌道での境界条件の意味で付加してあり、 $\Delta \dot{\theta}_{via}$ 、 $\Delta \ddot{\theta}_{via}$ は補償軌道での経路点時

刻での速度と加速度を表している。)

$$\begin{aligned}
 J(\Delta\dot{\theta}_{via}, \Delta\ddot{\theta}_{via}) &= I^2 \int_0^{t_f} \left(\frac{d\xi}{dt} \right)^2 dt \\
 &= I^2 \left\{ \int_0^{t_{via}} \left(\frac{d\xi}{dt} \right)^2 dt + \int_{t_{via}}^{t_f} \left(\frac{d\xi}{dt} \right)^2 dt \right\} \quad (2.18)
 \end{aligned}$$

このとき境界条件は次のように与えられているとする。

$$\xi(0) = \Delta\theta_0 \quad \xi(t_{via}) = \Delta\theta_{via} \quad \xi(t_f) = \Delta\theta_f$$

$$\dot{\xi}(0) = \Delta\dot{\theta}_0 \quad \dot{\xi}(t_f) = \Delta\dot{\theta}_f$$

$$\ddot{\xi}(0) = \Delta\ddot{\theta}_0 \quad \ddot{\xi}(t_f) = \Delta\ddot{\theta}_f$$

ただし、 $\Delta\theta_0$ 、 $\Delta\dot{\theta}_0$ 、 $\Delta\ddot{\theta}_0$ は各々始点での位置、速度、加速度の誤差を表し、 $\Delta\theta_f$ 、 $\Delta\dot{\theta}_f$ 、 $\Delta\ddot{\theta}_f$ は各々終点での位置、速度、加速度の誤差を示す。 $\Delta\theta_{via}$ は時刻 $t_{via}(=V)$ での経路点の位置誤差である。

ところで、式(2.18)を最小化する解は、式(2.16)と同様に5次多項式で与えられる。

$$\begin{aligned}
 \xi^1(t) &= b_0^1 + b_1^1 t + b_2^1 t^2 + b_3^1 t^3 + b_4^1 t^4 + b_5^1 t^5 \quad (0 \leq t \leq t_{via}) \\
 \xi^2(t) &= b_0^2 + b_1^2 t + b_2^2 t^2 + b_3^2 t^3 + b_4^2 t^4 + b_5^2 t^5 \quad (t_{via} \leq t \leq t_f) \quad (2.19)
 \end{aligned}$$

b_i^1 ($i=0,1,\dots,5$)は時刻 $0 \leq t \leq t_{via}$ における補償軌道の係数であり、始点と経路点での位置・速度・加速度の境界条件によって求められる。同様に時刻 $t_{via} \leq t \leq t_f$ での係数 b_i^2 は経路点と終点での位置・速度・加速度の境界条件によって求めることができる。しかしながら、経路点での速度・加速度は特定していないから、結局、式(2.18)は式(2.20)のように書くことができる。

$$\begin{aligned}
 J(\Delta\dot{\theta}_{via}, \Delta\ddot{\theta}_{via}) &= I^2 \left\{ \int_0^{t_{via}} \left(\frac{d\xi}{dt} \right)^2 dt + \int_{t_{via}}^{t_f} \left(\frac{d\xi}{dt} \right)^2 dt \right\} \\
 &= I^2 \int_0^{t_{via}} \left(6b_3^1 + 24b_4^1 t + 60b_5^1 t^2 \right)^2 dt \\
 &\quad + I^2 \int_{t_{via}}^{t_f} \left(6b_3^2 + 24b_4^2 t + 60b_5^2 t^2 \right)^2 dt \quad (2.20)
 \end{aligned}$$

経路点での速度 $\Delta\dot{\theta}_{via}$ ・ 加速度 $\Delta\ddot{\theta}_{via}$ は上の評価関数を最小化するように決定することが合理的であるから、次の2つの必要条件が要求される。

$$\begin{aligned}\frac{\partial J}{\partial \Delta\theta_{via}} &= 0 \\ \frac{\partial J}{\partial \Delta\dot{\theta}_{via}} &= 0\end{aligned}\tag{2.21}$$

故に経路点での速度・加速度が特定され、以下のように与えられる。

$$\Delta\dot{\theta}_{via} = -\frac{5}{2} \frac{t_{via} - (t_f - t_{via})}{t_{via}^i (t_f^i - t_{via}^i)} \Delta\theta_{via}\tag{2.22}$$

$$\Delta\ddot{\theta}_{via} = \frac{10 \left(t_{via}^2 - 4t_{via} (t_f - t_{via}) + (t_f - t_{via})^2 \right)}{3t_{via}^2 (t_f - t_{via})^2} \Delta\theta_{via}\tag{2.23}$$

ただし、始点での位置誤差 $\Delta\theta_0$ 、速度誤差 $\Delta\dot{\theta}_0$ と加速度誤差 $\Delta\ddot{\theta}_0$ および終点での位置誤差 $\Delta\theta_f$ 、速度誤差 $\Delta\dot{\theta}_f$ と加速度誤差 $\Delta\ddot{\theta}_f$ は0としている。以上によって、式(2.18)を最小化する経路点の速度・加速度を経路点時間 t_{via} の関数として求めることができた。

次に、逆に式(2.22)、式(2.23)の速度・加速度によって、式(2.18)の評価関数の値を計算すると、次のようになる。このとき、この評価関数は経路点の時間 t_{via} の関数となる。 $\Delta\theta_{via}$ 自体も経路点時刻 t_{via} の関数である。

$$J(t_{via}) = 20 \left\{ \Delta\theta_{via}(t_{via}) \right\}^2 \left(\frac{1}{t_{via}} + \frac{1}{t_f - t_{via}} \right)^5\tag{2.24}$$

ただし、 $\Delta\theta_{via}(t) = \theta_{via} - \gamma_1(t)$ であり、 $\gamma_1(t)$ は、始点と終点だけの境界条件を満足するように生成された補償軌道を示す。故に式(2.24)を最小とするような経路点時間 t_{via} が求める経路点の通過時間となる。

上で述べた経路点での速度・加速度および時間の決定方法を用いた経路点のある場合の補償軌道の生成アルゴリズムについてまとめる。図2.11に、このアルゴリズムを示した。

Step 1 始点・終点での位置、速度および加速度の境界条件を補償する軌道を式(2.16)に従って生成する。

Step 2 式(2.24)を最小とする経路点時間 t_{via} を求める。

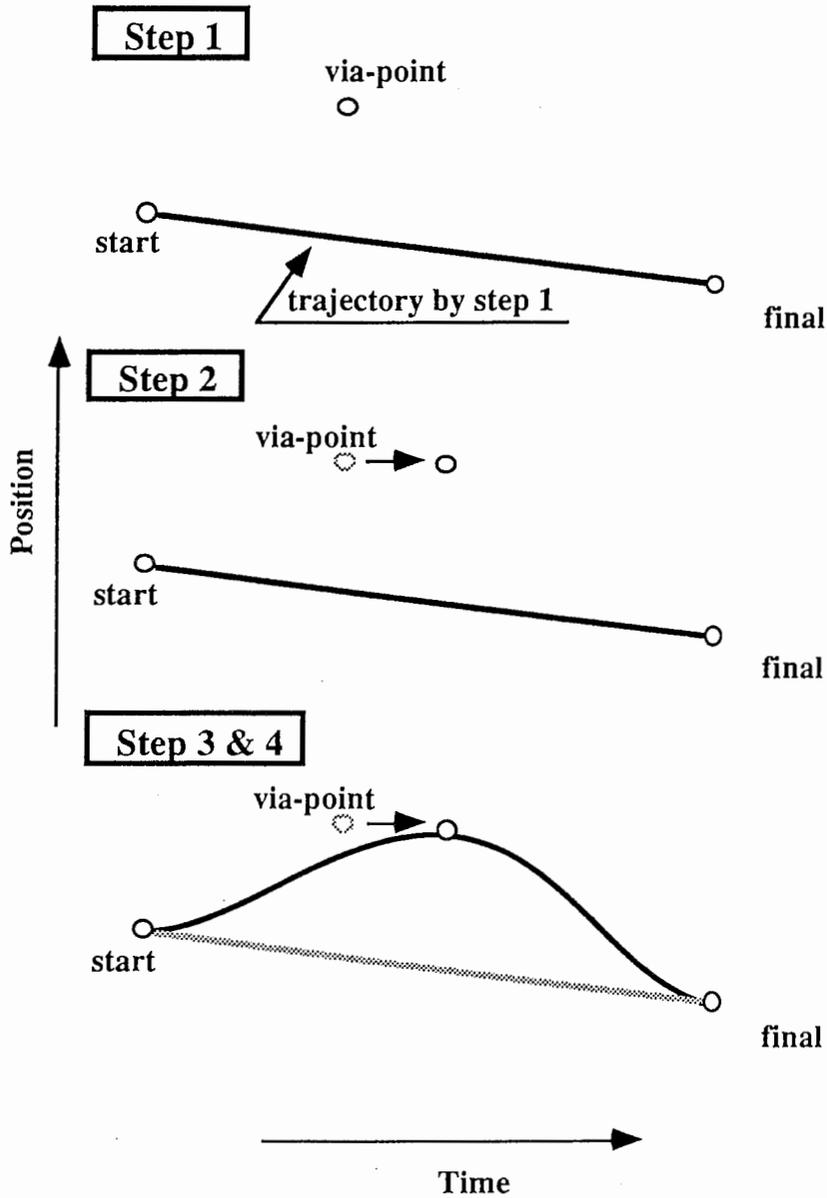


図 2.11 経由点のある場合の補償軌道の生成

Fig2.11 Compensatory trajectory formation for a via-point movement.

- Step 1 始点・終点での位置、速度および加速度の境界条件を補償する軌道を生成する。
- Step 2 経由点時間を決める。(経由点の時間を移動する。)
- Step 3 経由点での速度・加速度を計算し、始点から経由点、経由点から終点の軌道を生成する。位置・速度・加速度の境界条件は全て0である。
- Step 4 Step 1で生成した軌道にStep 3で生成した軌道を足し込むことで、始点、経由点、終点を通過する軌道を生成する。

ただし、ここでの境界条件は、図 2.5 の Step 3 の後での、元々の境界条件の誤差である。

Step 3 式 (2.22), 式 (2.23) によって経路点での速度・加速度を計算し, 式 (2.16) を使って, 始点から経路点, 経路点から終点の軌道を生成する. このとき始点・終点の元々の境界条件の誤差はStep 1 で補償されているから, 位置・速度・加速度の境界条件は全て0である.

Step 4 Step 1 で生成した軌道にStep 3 で生成した軌道を足し込む.

Step 4 で生成された軌道は, 評価関数 (2.18) を最小化する補償軌道であり, かつ, 元々の境界条件を満足する軌道である. いま, 簡単のため経路点が1つの場合について説明したが, 2個以上の場合にも同様のアルゴリズムによって軌道生成することが可能である. 具体的なアルゴリズムに関しては, 次章の”最適化原理に基づく書字運動モデル”で述べる.

しかしながら, 経路点が2個以上の場合に各経路点の時刻を最適化することは, 非常に難しい問題である. ダイナミックプログラミングなどの手法を応用して解くことが可能である.

2.5.2 数値実験

本節では, 前節で述べた経路点のある場合の軌道生成の数値実験結果を示す. 数値実験の条件は以下に示す通りである.

- (1) 運動時間: 1.00 (s)
- (2) サンプル時間: 0.01 (s)
- (3) 運動の始点T3 (T5), 終点T5 (T3), 経路点はP1あるいはP2
(座標は表 2.2 参照)

また, 滑らかさの演算の係数 λ , 滑らかさの繰り返し計算の回数 n および最適化のための繰り返し計算の回数を表 2.7 に示す. 最適化の繰り返し計算は, トルク変化最小規範の評価関数が最初に極小値をほぼとった時点で繰り返しの計算を打ち切った. ここで使った初期軌道は, 始点から経路点, 経路点から終点の間の躍度最小軌道である. 経路点での速度・加速度は0とした. T3-P1-T5とT3-P2-T5の軌道を図 2.12 に, T3-P2-T5の速度プロフィールを図 2.13 に示す. また, 表 2.6 に本方法, 広義ニュートン法および躍度最小解による評価関数値を示す. 本方法によって得られた軌道は, 10回以下の繰り返し計算によって得られており, かつ, 得られた軌道のトルク変化最小規範の評価関数の値は, 広義ニュートン法によって得られた最適値

とほぼ同じ値である。また、得られた軌道は、広義ニュートン法および躍度最小規範によって得られた軌道とほぼ同様で、人の運動軌道とも良く一致している。予測される速度プロファイルは、経由点の位置 (P1 あるいはP2) によって、ベル型 (単峰) の場合と2つのピークをもつ場合がある。この実験の場合、経由点の位置は始点と終点を結ぶ線に対して対称に置かれている。躍度最小規範によれば、予測される速度プロファイルはどちらの場合も同じであるが、トルク変化最小規範によって生成される軌道の速度プロファイルは、経由点の位置によって異なる。経由点がP1の場合はベル型となり、経由点がP2の場合は2つのピークを持つ。これは人の運動の計測結果とも一致する傾向である。(Uno et al., 1989; 小池ら, 1993) 図 2.13 に示すように、我々の提案しているモデルは、経由点がP2の場合は2つのピークを持つ軌道を生成している。従って、本モデルは数回の繰り返し計算によってトルク変化最小規範に基づいた経由点のある軌道を生成できることがわかる。また、表 2.4 と表 2.8 を比較すると、この新しいモデルは2点間の運動のような簡単な運動よりも、経由点のある運動のような複雑な運動の方が、よりトルク変化最小規範に近い軌道を生成できることがわかる。

表 2.7 数値実験に使ったパラメータと繰り返し計算の回数

Table 2.7 Computer simulation parameters and number of iterations required to calculate a minimum for the objective function for each movement.

movement	λ	number of smoothing	number of iteration
T3-P1-T5	0.3	100	4
T3-P2-T5	0.3	100	10

表 2.8 各運動での評価関数の値

Table 2.8 Value of the minimum torque-change criterion.

movement	proposed method	Newton-like	minimum jerk
T3-P1-T5	3.361×10^{-1}	3.168×10^{-1}	6.709×10^{-1}
T3-P2-T5	4.271×10^{-1}	3.322×10^{-1}	6.323×10^{-1}

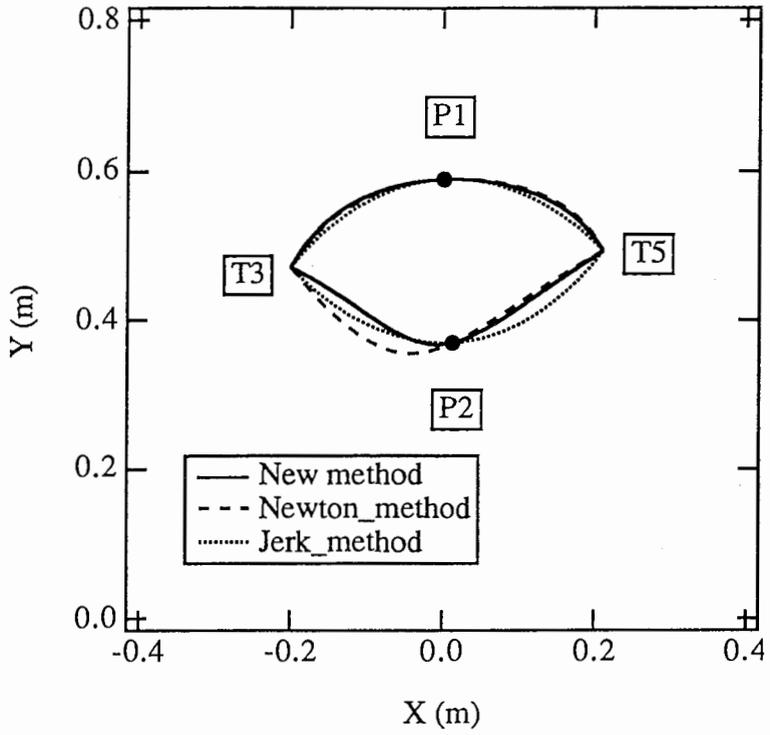


図 2.1 2 経由点のある運動の軌道

Fig 2.12 Trajectory of via-point movement in front of the body.

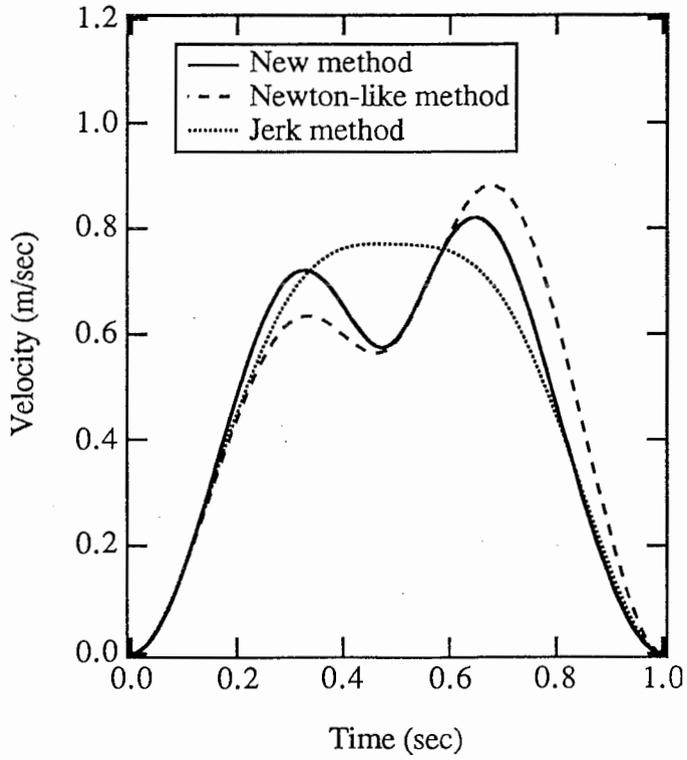


図 2.1 3 経由点のある運動 (T3-P2-T5) の速度

Fig 2.13 Speed profile of a T3-P2-T5 movement.

表 2.9, 表 2.10 および図 2.14, 図 2.15 に T5→P1→T3, T5→P2→T3 の逆方向の運動結果を示す。傾向は, 順方向の運動とほぼ同様である。

表 2.9 数値実験に使ったパラメータと繰り返し計算の回数

Table 2.9 Computer simulation parameters and number of iterations required to calculate a minimum for the objective function for each movement.

movement	λ	number of smoothing	number of iteration
T5-P1-T3	0.3	100	4
T5-P2-T3	0.3	100	10

表 2.10 各運動での評価関数の値

Table 2.10 Value of the minimum torque-change criterion.

movement	proposed method	Newton-like	minimum jerk
T5-P1-T3	3.504×10^{-1}	3.179×10^{-1}	6.709×10^{-1}
T5-P2-T3	4.218×10^{-1}	3.350×10^{-1}	6.323×10^{-1}

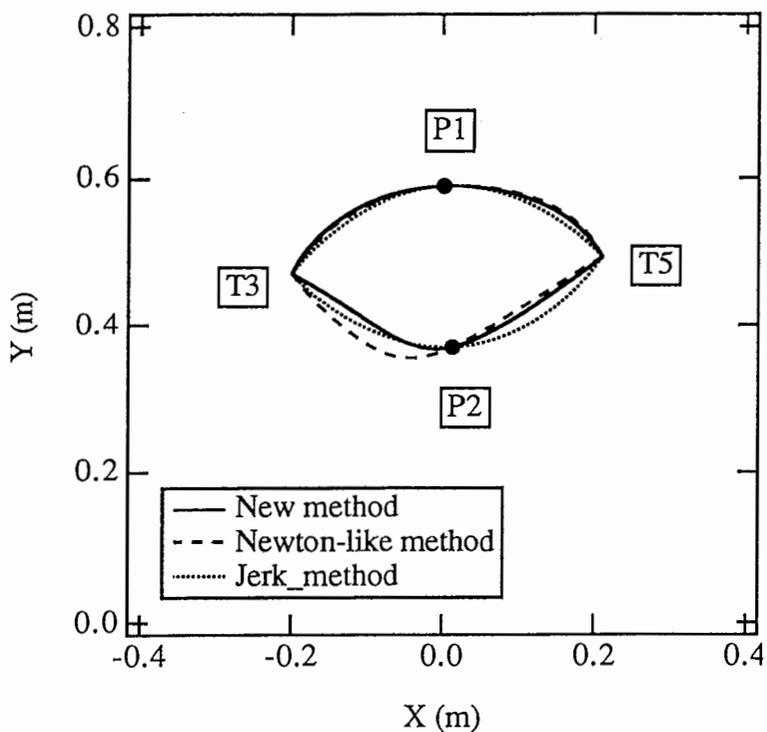


図 2.14 経由点のある運動の軌道

Fig 2.14 Trajectory of via-point movement in front of the body.

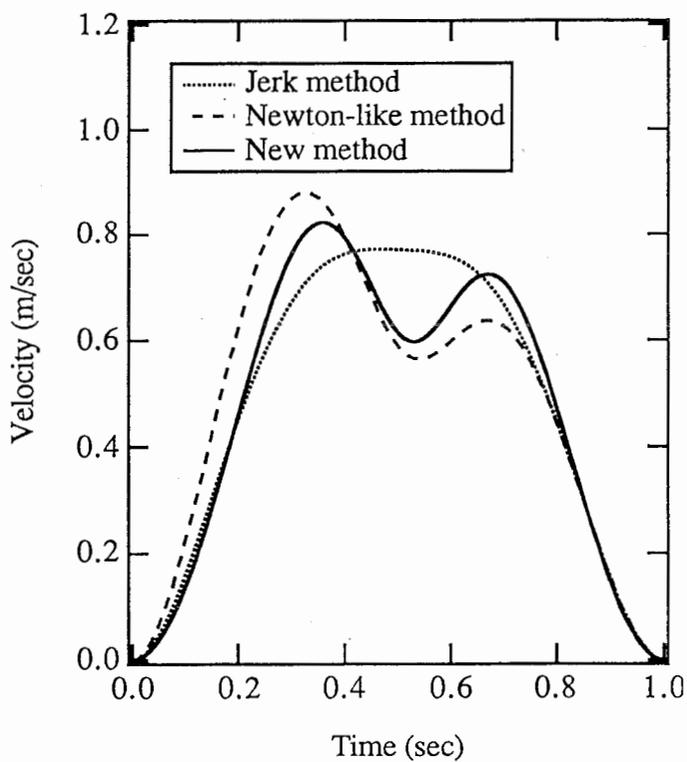


図 2.15 経由点のある運動 (T5-P2-T3) の速度

Fig 2.15 Speed profile of a T5-P2-T3 movement.

2.6 非線型最適化問題の解法としての理論的考察

第2.3節で提案した腕の最適軌道を生成する神経回路網は、ある種の拘束条件付最適化問題を解いていることになる。本節では、第2.3節で述べた神経回路網を一般的な最適化アルゴリズムとして定式化して、この解法の最適性と収束性について考察し、腕の最適軌道の生成だけでなく他の工学的問題にも応用が可能なアルゴリズムであることを示す。

最初に非線型最適化問題を以下に示すように、制約条件が与えられたときの評価関数 J を最小化する問題と考える。

[非線型最適化問題：N]

$$J = \int \left(\frac{du}{dt} \right)^2 dt \rightarrow \text{Min} \quad (2.25)$$

制約条件：

$$\frac{dx}{dt} = f(x, u), \quad (2.26)$$

$$x(0) = 0, x(t_f) = x_{df}, \quad (2.27)$$

$$u(0) = 0, u(t_f) = 0, \quad (2.28)$$

ただし、 x 、 u はそれぞれ状態変数と制御変数を表しており、 x_{df} 、 t_f は各々終端条件と、最終時刻を示す。また非線形関数 f は x 、 u に関して微分可能とする。

最初に第2.3節で提案した神経回路網モデルを以下のように一般化して、制御変数の繰り返し則を考える。まず、順モデル F の逆関数として、逆モデル G を次のように定義する。

$$G(X) = u$$

$$\text{ただし, } (x, \dot{x}) = X = F(u)$$

図2.5で考えて、 $j+1$ 回目の制御変数を Step 1 の逆モデルの出力とする。この逆モデルの入力は、 j 回目に滑らかにされたトルク（制御変数）（Step 2）によって順モデルを使って生成された軌道（Step 3）と、誤差を補償するために線形近似ダイナミクスモデルによって生成された軌道（Step 4）を足し合わせた軌道である。従って $j+1$ 回目の制御変数は次式のように与えられる。

$$u^{j+1} = G(F(u^j + S(u^j)) + \Xi) \quad (2.29)$$

ただし、 $u^j + S(u^j)$ は滑らかにされた制御変数であり、 $\Xi = (\xi, \xi)$ は、 $u^j + S(u^j)$ によって生じた終端での誤差を補償する軌道であり、かつ、下で述べるような線形最適化問題の解である。次式は式(2.29)の順モデル F を u^j でテーラー展開することによって得られる。

$$u^{j+1} = G\left(F(u^j) + \frac{\partial F(u^j)}{\partial u}S(u^j) + o(S(u^j)) + \Xi\right)$$

次に、逆モデル G を $X^j = F(u^j)$ でテーラー展開する。

$$\begin{aligned} u^{j+1} &= u^j + \frac{\partial G(X^j)}{\partial X}\left(\frac{\partial F(u^j)}{\partial u}S(u^j) + o(S(u^j))\right) + \frac{\partial G(X^j)}{\partial X}\Xi \\ &= u^j + S(u^j) + \frac{\partial G(X^j)}{\partial X}o(S(u^j)) + \frac{\partial G(X^j)}{\partial X}\Xi \end{aligned} \quad (2.30)$$

ここで、 j 回目と $j+1$ 回目の軌道の変化は通常十分小さいから、テーラー展開の2次以上の項を無視し、式(2.30)の右辺第4項を $-\eta^j$ と表記する。 η^j は下で定義する線形最適化問題の最適解である。もし、 $S(u^j)$ が十分小さければ、 $o(S(u^j))$ は無視でき次式が得られる。

$$u^{j+1} = u^j + S(u^j) - \eta^j \quad (2.31)$$

しかしながら、数値実験および以下で述べる理論的考察において、 $S(u^j)$ を十分小さいと仮定することはできない。故に、式(2.30)に従った更新則を定義する。

$$u^{j+1} = u^j + \tilde{S}(u^j) - \eta^j \quad (2.32)$$

ただし、

$$\tilde{S}(u^j) = S(u^j) + \frac{\partial G(X^j)}{\partial X}o(S(u^j))$$

ところで、次の2つの軌道は完全に同じ境界条件を満足する。

$$\frac{\partial F(u^j)}{\partial u}S(u^j) + o(S(u^j))$$

- Ξ

非線型最適化問題の繰り返しによる解法において、修正軌道を以下のような線型

最適化問題の解から決めるとする。

[線型最適化問題：L]

$$J_{\eta} = \int \left(\frac{d\eta}{dt} \right)^2 dt \rightarrow \text{Min} \quad (2.33)$$

制約条件：

$$\frac{d\xi}{dt} = \frac{\partial f(x^j, u^j)}{\partial x} \xi + \frac{\partial f(x^j, u^j)}{\partial u} \eta \quad (2.34)$$

$$\xi(0) = 0, \quad \xi(t_f) = \Delta x^j(t_f) \quad (2.35)$$

$$\eta(0) = 0, \quad \eta(t_f) = \bar{S}(u^j)(t_f) \quad (2.36)$$

ただし、 x^j, u^j はそれぞれ j 回目の軌道（状態変数）と制御変数を表しており、 $\Delta x^j(t_f)$ は非線型方程式に $u^j + S(u^j)$ を入力として与えたときの終端誤差である。

また、評価関数 J を最小にする孤立した最適解を (u^*, x^*) とする。線型最適化問題 [L] を最小とする孤立した最適解を η^{*j} 、軌道を ξ^{*j} とする。 ξ^{*j} は補償軌道である。

2.6.1 収束解の最適性

本節では提案したアルゴリズムの収束解の最適性について示す。証明することは

- (a) 必要条件： u^j が u^* に等しいとき ($u^j = u^*$)、 η^{*j} が $\bar{S}(u^j)$ と等価 ($\eta^{*j} = \bar{S}(u^j)$) となって解が収束すること、つまり、制御変数が最適解となったとき式 (2.32) の更新則が収束すること、

逆に

- (b) 十分条件： $\bar{S}(u^j)$ が η^{*j} と等しいとき ($\eta^{*j} = \bar{S}(u^j)$)、 u^j が u^* に等しくなること ($u^j = u^*$)、つまり、制御変数が収束したとき、制御変数 u^j は最適解である。

これがいれば、繰り返し則が収束することの必要十分条件が最適解が得られているということになる。

最適解の廻りでの線型化方程式は次のように与えられる。

$$\frac{d\xi}{dt} = \frac{\partial f(x^*, u^*)}{\partial x} \xi + \frac{\partial f(x^*, u^*)}{\partial u} \eta \quad (2.37)$$

ただし,

$$\xi(0) = 0, \quad \xi(t_f) = \Delta x_f^*$$

$$\eta(0) = 0, \quad \eta(t_f) = \tilde{S}(u^*)(t_f) \quad (2.38)$$

上の必要条件は次の補題と等価である.

[補題 1] 線型最適化問題 [L] の $x^j = x^*$ での最適解 η^* は $\tilde{S}(u^*)$ となる.

証明 (a) 必要条件: (背理法による)

[L] の最適解 η^* が [N] の最適解 u^* から得られる $\tilde{S}(u^*)$ と異なると仮定する ($\eta^* \neq \tilde{S}(u^*)$). このとき u^* が [N] の最適解にならないという矛盾を示す.

$$\hat{u} = u^* + \varepsilon(\tilde{S}(u^*) - \eta^*) \quad (|\varepsilon| \ll 1) \quad (2.39)$$

ε が小さければ $\hat{u} - u^*$ は線型化変分方程式 (2.37) の $\varepsilon(\tilde{S}(u^*) - \eta^*)$ を入力とする解で良く近似できる. ところで式 (2.38) から $\tilde{S}(u^*)$ と η^* の各々を制御変数とした終端境界値は一致する. したがって \hat{u} は式 (2.27), 式 (2.28) の境界条件 $x(0) = 0, x(t_f) = x_{df}, u(0) = 0, u(t_f) = 0$ を満たしている. 従って次に

$$\int \left(\frac{d\hat{u}}{dt} \right)^2 dt < \int \left(\frac{du^*}{dt} \right)^2 dt$$

を示せば, u^* が [N] の最適解であることと矛盾し, 証明が完了する. ε^2 項を無視すると次式が成り立つ.

$$\begin{aligned} \int \left(\frac{d\hat{u}}{dt} \right)^2 dt &= \int \left[\frac{d}{dt} \{ u^* + \varepsilon(\tilde{S}(u^*) - \eta^*) \} \right]^2 dt \\ &\equiv \int \left(\frac{du^*}{dt} \right)^2 dt + 2\varepsilon \int \frac{du^*}{dt} \left(\frac{d\tilde{S}(u^*)}{dt} - \frac{d\eta^*}{dt} \right) dt \end{aligned} \quad (2.40)$$

右辺第 2 項の積分を I として,

$$I > 0 \text{ ならば } \varepsilon < 0$$

$$I < 0 \text{ ならば } \varepsilon > 0$$

とおくと,

$$\int \left(\frac{d\hat{u}}{dt} \right)^2 dt < \int \left(\frac{du^*}{dt} \right)^2 dt$$

となる. また, もし $I = 0$ ならば

$$\frac{d\tilde{S}(u^*)}{dt} - \frac{d\hat{\eta}^*}{dt}$$

は恒等的には0ではないから、この方向に評価関数の微分が0となることを意味する。つまり、このとき u^* は[N]の孤立した極値にはならない。

次に十分条件であるが、それは次の補題2と等価である。

[補題 2] $\tilde{S}(u^j)$ が $\hat{\eta}^{*j}$ と等しければ ($\hat{\eta}^{*j} = \tilde{S}(u^j)$) , u^j は u^* と等しくなる ($u^j = u^*$) .

証明 (b) 十分条件: (背理法による)

評価関数の値が収束したとき制御変数 u^j が[N]の最適解となっていないとする ($u^j \neq u^*$) . まず、 $\hat{\eta}$ を次のように定義する。

$$\hat{\eta} = \tilde{S}(u^j) + \varepsilon(u^* - u^j) \quad (2.41)$$

まず、 $\hat{\eta}$ が[L]の境界条件を満足することを示す。

$$\frac{dx^*}{dt} = f(x^*, u^*) \quad (2.42)$$

を $u^* \sim u^j$ として u^j のまわりで線型近似すれば、

$$\frac{d\xi}{dt} = \frac{\partial f(x^j, u^j)}{\partial x} \xi + \frac{\partial f(x^j, u^j)}{\partial u} (u^* - u^j) \quad (2.43)$$

ところで u^* , u^j は、式(2.26)について同じ終端条件 $x(t_f) = x_{df}$ を満たすから、 u^* , u^j によって生成された軌道の差である ξ は、 $\xi(t_f) = 0$ の条件を満足する。また、 $\tilde{S}(u^j)$ が式(2.35)の境界条件を満足するので、 $\hat{\eta}$ も同様に式(2.35)の境界条件を満足する。また、 $\hat{\eta}$ は、

$$u^*(0) = u^*(t_f) = u^j(0) = u^j(t_f) = 0$$

より、式(2.36)の境界条件も満足する。

$$\frac{d\hat{\eta}}{dt} = \frac{d\tilde{S}(u^j)}{dt} + \varepsilon \left(\frac{du^*}{dt} - \frac{du^j}{dt} \right) \quad (2.44)$$

より、 ε^2 項を無視して次式を得る。

$$\int \left(\frac{d\hat{\eta}}{dt} \right)^2 dt \equiv \int \left(\frac{d\tilde{S}(u^j)}{dt} \right)^2 dt + 2\varepsilon \int \frac{d\tilde{S}(u^j)}{dt} \left(\frac{du^*}{dt} - \frac{du^j}{dt} \right) dt \quad (2.45)$$

ここで右辺第2項の積分を I として,

$$I > 0 \text{ ならば } \varepsilon < 0$$

$$I < 0 \text{ ならば } \varepsilon > 0$$

のように ε をとると,

$$\int \left(\frac{d\hat{\eta}}{dt} \right)^2 dt < \int \left(\frac{d\tilde{S}(u^j)}{dt} \right)^2 dt$$

となり, [L] の最適解が $\eta^{*j} = \tilde{S}(u^j)$ 以外に存在することになり矛盾する. また, もし $I = 0$ であるならば,

$$\frac{du^*}{dt} - \frac{du^j}{dt}$$

は, 恒等的に0でないから, η^{*j} が[L]の孤立した極値とならない. (証明終)

2.6.2 解の収束性

本節では, 評価関数 J の単調減少性, つまり, 毎回の繰り返し計算ごとに評価関数 J を減少させることができるかについて検討する.

$j + 1$ 回での評価関数 J の値は次のように与えられる.

$$J(u^{j+1}) = J(u^j + \tilde{S}(u^j) - \eta^j) \quad (2.46)$$

また, 評価関数 J は下式で与えられる2乗積分の形式である.

$$J(u^j) = \int \left(\frac{du^j}{dt} \right)^2 dt \quad (2.47)$$

故に, 式(2.46), 式(2.47)より, 評価関数 J は次のように展開・整理される.

$$\begin{aligned} J(u^{j+1}) - J(u^j) &= 2 \int \left(\frac{du^j}{dt} + \frac{d\tilde{S}(u^j)}{dt} \right) \left(\frac{d\tilde{S}(u^j)}{dt} - \frac{d\eta^j}{dt} \right) dt \\ &\quad - \int \left(\frac{d\tilde{S}(u^j)}{dt} + \frac{d\eta^j}{dt} \right) \left(\frac{d\tilde{S}(u^j)}{dt} - \frac{d\eta^j}{dt} \right) dt \end{aligned} \quad (2.48)$$

ところで、数値実験で用いた平滑化のオペレーターは、連続時間で表すと以下のようになる。

$$u_{(k+1)}^j = u_{(k)}^j + \lambda \frac{d^2 u_{(k)}^j}{dt^2} \quad (k = 1, 2, \dots, n \quad \lambda < 1)$$

ただし、 n は平滑の繰り返し回数である。 n を十分大きくすると、 $u^j + \mathcal{S}(u^j)$ は十分小さくなると考えられる。これは、解の収束のための重要な条件であるが、[N]と[L]の最適解が大きく異なっている場合には、合理的な仮定とは言えない。

式(2.32)より、 u^j が収束していないときは、次式が成り立つ。

$$\mathcal{S}(u^j) - \eta^j \neq 0 \quad (2.49)$$

さらに、 $u^j - \eta^j$ は小さな値ではないから、

$$\mathcal{S}(u^j) + \eta^j = u^j + \mathcal{S}(u^j) - (u^j - \eta^j) \quad (2.50)$$

も小さな値ではない。従って、式(2.48)の右辺の第1項は第2項に比べて十分小さくなる。よって、第1項は無視され式(2.51)が成り立つ。

$$J(u^{j+1}) - J(u^j) = \int \left(\frac{d\eta^j}{dt} \right)^2 dt - \int \left(\frac{d\mathcal{S}(u^j)}{dt} \right)^2 dt \quad (2.51)$$

η^j が[L]の最適解であることから次の不等式が成立する。

$$\int \left(\frac{d\eta^j}{dt} \right)^2 dt - \int \left(\frac{d\mathcal{S}(u^j)}{dt} \right)^2 dt \leq 0 \quad (2.52)$$

最終的に、式(2.53)に示されるような単調減少の関係が得られた。

$$J(u^{j+1}) \leq J(u^j) \quad (2.53)$$

故に、 $J(u)$ は下に有界であるから、極小値に収束する。

2.7 おわりに

第2.3節で提案した神経回路網モデルは、従来提案されている運動軌道生成のモデルである順モデルを用いたモデル(カスケード神経回路網モデル)や、逆モデルを並列に配置したモデルに対する批判、(1)時間を空間的に表現したモデル、

(2) 誤差逆伝播の必要性, (3) 繰り返し演算回数が長い, を解決するモデルである。つまり, 我々の提案したモデルでは順モデルについて時間を空間的に表現したモデルを要求する必要はなかりカレント型の神経回路網で実現することができる。また, 制御対象の線型近似モデルと順モデルの逆関数である逆モデルを使うことで, 誤差逆伝播することなく終端条件を満足する解を得ることができ, かつ, 短い時間で最適解の良い近似解を得ることができる。

数値実験および理論的考察で, 滑らかさのオペレーターとして繰り返し計算を必要とするオペレーターを適用したが, このようなオペレーターである必要はなく, 繰り返し計算を必要としないような種々のオペレーターの適用も可能である。

ところで, 結局我々の提案したモデルは図 2.16 に示すように, 基本的に5つの回路によって実現される。それは, 順モデル (Forward Dynamics Model), 逆モデル

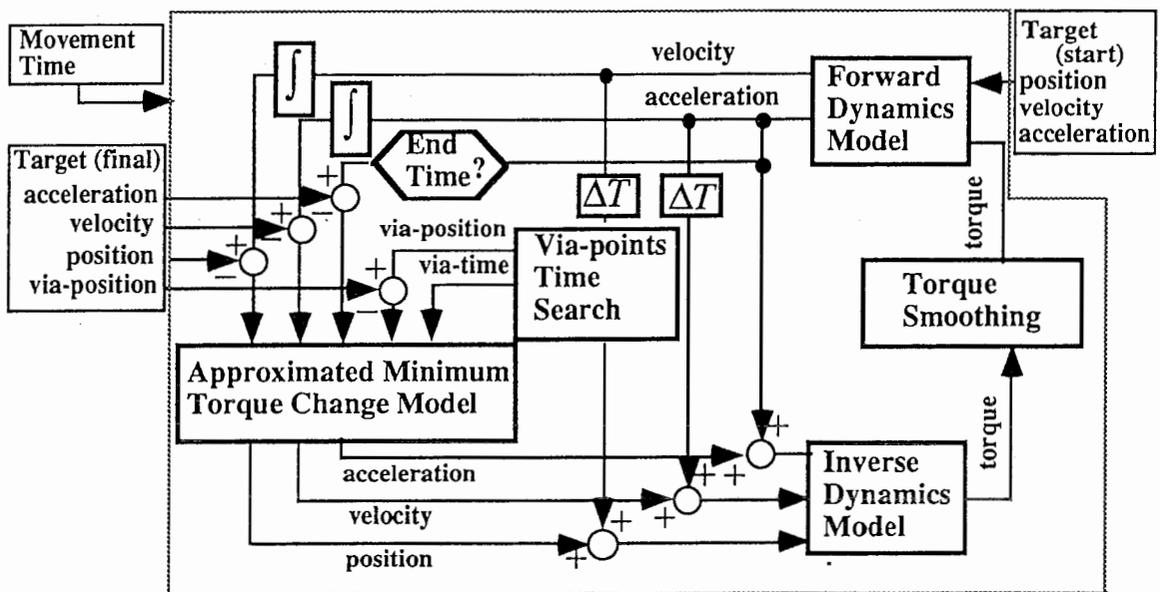


図 2.16 軌道生成のための神経回路網モデルの全体構成

Fig 2.16 Neural network structure of arm trajectory formation

(Inverse Dynamics Model) , トルクを滑らかにする回路 (Torque Smoothing) , 経路点の時間を探索する回路 (Via-points Time Search) および誤差を補償するための近似的なトルク変化最小軌道を生成するモデル (Approximated Minimum Torque Change Model) である. 順モデルは前述したようにJordanのリカレント型の神経回路網モデル (Jordan, 1992) で実現できるし, 逆モデルについてもKawato (Kawato et al., 1987; Kawato, 1990a) によって神経回路網モデルで実現できることが指摘されている. また, トルクを滑らかにする回路と経路点の時間を探索する回路は, 複雑な回路ではなく, 神経回路網モデルで実現することが可能である. また, 近似的なトルク変化最小軌道を生成するモデルは, 質点系で表されるような近似ダイナミクスモデルを考えた場合, そのトルク変化最小規範は, 関節角座標系での躍度最小規範と等価になる. Hoff & Arbib (1992) は, 終点での速度と加速度が0のときに, 躍度最小軌道がリカレント型の神経回路網モデルで実現できることを指摘している. しかも終点の速度・加速度が0でない場合にも, 彼らのモデルは簡単に拡張され, 式 (2.54) のように表される. この速度・加速度が0でない場合は, 経路点のある運動軌道の生成には重要である.

$$\frac{d}{dt}\Theta = \mathbf{A}\Theta + \mathbf{B}\Theta_v \quad (2.54)$$

$$\mathbf{A} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ -60/D^3 & -36/D^2 & -9/D \end{bmatrix}$$

$$\mathbf{B} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 60/D^3 & -24/D^2 & 3/D \end{bmatrix}$$

$$\Theta = (\theta \quad \dot{\theta} \quad \ddot{\theta})^T$$

$$\Theta_v = (\theta_v \quad \dot{\theta}_v \quad \ddot{\theta}_v)^T$$

ただし, v は終点を表す添字であり, θ_v , $\dot{\theta}_v$, $\ddot{\theta}_v$ は各々終点での位置, 速度, 加速度を示す. また, D は残り運動時間を表す. つまり時刻 $t=0$ のときは, D は始点から終点までの運動時間 t_f を示し, 時間刻み Δt 毎に時刻が経過すると, 残り運動時間もそれにともなって減少する ($D = t_f - \Delta t$). このモデルは $\dot{\theta}_v = 0$, $\ddot{\theta}_v = 0$ の

ときHoff & Arbib (1992)と同じである。故に、質点系のダイナミクスのトルク変化最小軌道はリカレント型の神経回路網モデルで構成されることがわかる。

結局、今回提案したモデルは全体を神経回路網で構成することができ、従来の神経回路網モデルの脳のモデルとしての批判を解決した、人の腕の軌道生成を実現する神経回路網モデルと言える。また、このモデルは川人、乾が提案している視覚モデル（川人、乾、1990; 早川ら、1991; 早川ら、1992）ともほとんど同じ構造をもつモデルでもある。

また、このモデルの枠組は、工学的には拘束条件付最適化問題の解法であり、順モデルとその逆関数である逆モデルが定義でき、かつ、拘束条件の誤差を補償する軌道を線型近似制御対象モデルから適切に選択することができれば、拘束条件を満足させるように変化させつつ、評価関数を最小化させることが可能なアルゴリズムである。特にこの方法は、繰り返し計算の中で逆行列などを解く必要もなく、計算時間のかからない方法であり、工学的応用範囲の広い方法である。

実際の生体系で考えた場合、トルク変化最小規範は関節でのトルクを滑らかにするように運動計画する規範である。しかしながら、生体系では関節でのトルクを発生させるためには筋の張力を計算しなければならず、筋張力変化最小規範や運動指令（運動の制御信号）変化最小規範と言ったトルク変化最小規範よりも、より生体系に即したモデルに発展してきている。このような規範に対し、提案したモデルの実現の可能性を検討し、脳のモデルとしての妥当性を研究していくことが今後の課題の1つである。特に、人の関節には多くの筋が作用しており冗長なシステムを構成している。その筋張力を決めることは不良設定の問題を解かなければならず、理論的にも重要な課題である。また、順モデルと逆モデルが完全な逆関数の関係にないときの本モデルの有効性の確認、平滑化操作のクラスの定義および一般的な評価関数に対する拡張などが今後の課題である。

第 3 章

最適化原理に基づく書字運動モデル

3.1 はじめに

書字運動は、運動制御の研究において重要な課題の1つである。手書き文字の生成はシンボルを運動指令に変換する過程を経ている。この変換過程において、脳内には文字を生成するためのどのような中間的表現が内在して、それをどのような原理によって運動計画・運動指令に変換するのだろうか。随意運動において、運動の計画が制御対象のもつダイナミクスに依存して、トルクの変化、筋張力の変化や運動指令（の変化）を最小にするように計画されるという運動の規範が提案されていること、また、ダイナミクスを考慮せず、作業座標系での加速度の変化（躍度）を最小にするという運動規範も提案されていることを第2章で述べた。我々はこれらの運動規範に立脚した書字運動モデルを考える。上で述べた運動規範は、机の上に置かれたコップをとるような運動を計画するときには、コップの位置を境界条件とした最適化問題を解くことを要求する。一方、書字運動のような複雑な運動においては、最終点だけを境界条件とした問題ではなく、幾つかの経由点を境界条件とした問題を解かなければならない。

経由点を通る最適運動によって書字運動を規定するためには、意図する文字を実現するための経由点情報を特定する必要がある。しかも、Edelman & Flash (1987) が指摘しているように、文字を実現するための経由点の数は、文字の表現の観点から考えれば最小の数であることが望ましい。また、必要となる経由点の位置を選択する適切な基準がなければならない。この2つの理論的要求の具体的な意味は、与えられた文字軌道からその軌道を再構成するために必要十分な経由点を抽出する問題を考えるとわかりやすい。非常に多くの経由点を抽出すれば、与えられた軌道を良く再現できるのは近似理論から明らかである。また、規則的なサンプリング規則に従って経由点を抽出しても、サンプリングピッチを十分小さくしなければ必要な経由点を選択できない。つまり、経由点を与えられた軌道から抽出する問題は、その数・位置の組み合わせは無数に存在し、軌道再構成モデルを特定しなければ解が一意に定まらないいわゆる不良設定問題と考えられる。

本章において我々は書字運動を多数の経由点を境界条件とする軌道生成の問題と捉えた計算論的モデルを提案する。そのために、まず文字を構成する経由点を推定

する経路点推定モデルを構築する。これは、軌道生成と経路点の抽出を交互に行い、与えられた軌道を再生する為に必要・十分な経路点を最適化規範にのっとりた軌道生成モデルに基づいて推定する。また、経路点推定モデルの理論的検討を行い、さらにこれが軌道を再構成するための経路点を推定する一般的な方法であることを音声データを使った実験で示す。次に推定された経路点を使った軌道生成で書字運動が再現できることを示す。

3.2 従来の書字運動モデル

手書き文字の認識を目的にした書字動作の解析は、1960年代、70年代から行われている。(Mermelstein & Eden, 1964; Yasuhara, 1975) 80年代になって、書字運動のモデルとして幾つかのモデルが提案されている。

Hollerbach (1981) は下式に示したような水平方向 (x) と鉛直方向 (y) に割り当てたoscillatorによって文字軌道が生成できることを示した。

$$\begin{aligned} \dot{x} &= a \sin(\omega_x(t - t_0) + \phi_x) + c \\ \dot{y} &= b \sin(\omega_y(t - t_0) + \phi_y) \end{aligned}$$

彼は、上で示したoscillatorのどのパラメータを変更することによって、人間の書く多様な文字を生成することができるかを示している。基本的に以下の3つが重要なパラメータであることを指摘している。

- (1) 文字の形を変更するのに重要なパラメータ：
鉛直方向 (y) の速度のゼロ交差点での水平方向 (x) の速度。
- (2) 文字の高さを変更するのに重要なパラメータ：
鉛直方向 (y) の速度のゼロ交差点での鉛直方向の振幅 (b) 。
- (3) 文字の傾き (slant) を変更するのに重要なパラメータ：
鉛直方向 (y) の速度のゼロ交差点での速度平面での傾き。

また、Morasso & Mussa Ivaldi (1982) は、基本ストロークの重ね合わせのメカニズムに基づく書字運動のモデルを提案している。彼らの言う基本ストロークは、実際の軌道のセグメントと考えられるストロークではなく、言わばストロークの基本構成要素であって、計測された軌道からは、このストロークを観測することはできない。この基本ストロークの重ね合わせによって全体の軌道が構成される。つまり、

各基本ストロークをスプライン関数によって構成し、その荷重付き和で文字軌道を生成する。

一方Edelman & Flash (1987) は、下式に示すようなスナップ (snap: 加速度の2階微分) 最小化基準に従った軌道生成による書字運動モデルを提案している。ただし、X, Y は視覚での作業座標での手先の位置座標である。

$$\int \left(\frac{d^4 X}{d^4 t} \right)^2 + \left(\frac{d^4 Y}{d^4 t} \right)^2 dt \rightarrow Min$$

このモデルでは、下図に示す4つの基本ストローク (hook, cup, gamma, oval) の組み合わせによって、文字が構成されるとしている。つまり、この4つのストロークを組み合わせて、結んで書くことによって文字を構成するモデルである。これらの基本ストローク自体が、上で示したスナップ最小化によって生成される。ただし、各ストロークは1つの経由点をもつ軌道である。

上で述べた3つの書字運動のモデルは、人間の文字軌道を再現することが出来た。特にEdelman & Flash (1987) の研究では、書字運動の計画原理 (計算理論) が”スナップ最小化”であり、文字の表現が”4つの基本ストローク”であることを示しており、Marr (1982) の脳の情報処理の第1水準と、第2水準に対応するモデルであると言える。しかしながら、このモデルに対する幾つかの批判が考えられる。第1に、スナップ最小化規範は、Flash & Hogan (1985) の提案した随意運動でのモデル

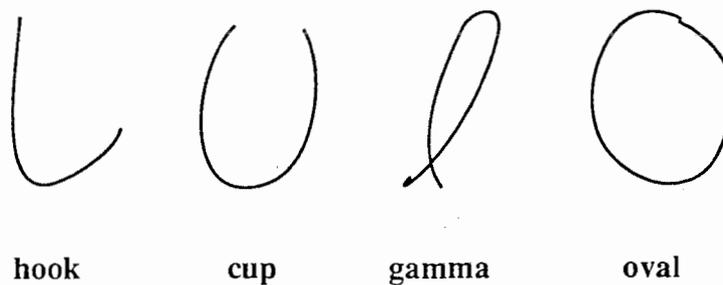


図 3.1 Edelmann & Flashの基本ストローク

Fig 3.1 Edelmann & Flash's basic strokes

躍度最小化規範を複雑にしたものであり、脳のなかにいくつもの規範が存在するのだろうか。逆に言えば、随意運動と同じ規範で書字動作を再現することは出来ないのだろうか。第2に表現の問題である。基本ストロークによる文字の表現は、言わば経験的なものであり、計算原理とは無関係な表現形式である。計算原理と密接な関係にあり、かつ理論的な背景をもつ表現形式はないのであろうか。

我々は、以上のような観点から、トルク変化最小規範を計画原理とし、この規範に基づく文字の表現形式をもつ書字運動のモデルを提案する。

3.3 書字運動モデル

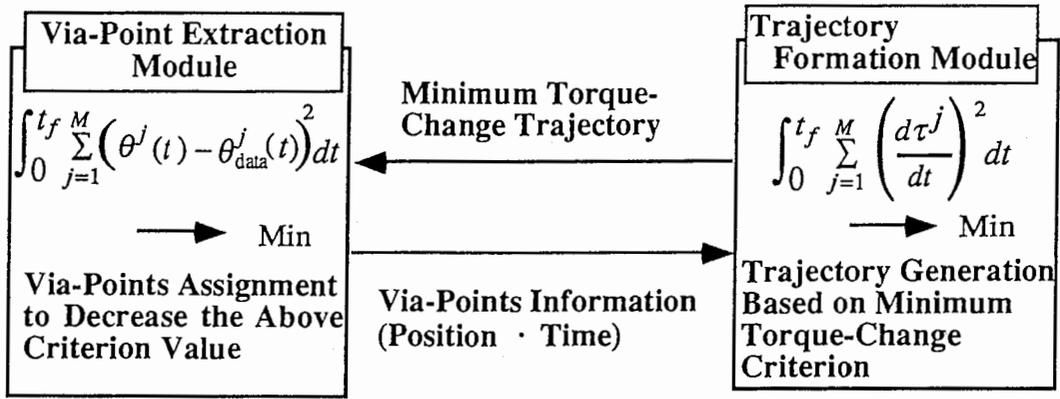
実際の文字から経路点を推定して、その経路点を境界条件とする軌道を生成することによる書字運動モデルを考える。ここで提案する書字運動モデルは、経路点推定モデルと、軌道生成モデルの2つによって構成されているものであり、基本的には2つのモデルとも最小化原理に基づいている。軌道生成モデルは、第2章で述べたトルク変化最小規範に基づいた軌道生成モデルである。このモデルは多点の経路点のある運動の軌道生成にも適用可能であり、文字軌道の適切な経路点情報（経路点位置、時間）をこのモデルに境界条件として与えれば、書字運動を再現・予測することが可能となる。

3.3.1 文字の経路点推定モデル

本節では書字運動の計測データから経路点を推定するモデルについて、アルゴリズムとその理論的根拠を述べる。基本となる考えは、経路点の推定と軌道生成を組み合わせて、与えられた軌道データを良く近似する再構成軌道を得るために最小の数の経路点を抽出することである。これは、軌道生成モデルがダイナミックな拘束条件として与えられているときに、与えられた軌道データを再構成した軌道で近似するというデータ拘束条件を最小の経路点で満たす最適化問題とみなせる。

3.3.1.1 経路点抽出モジュール

経路点推定モデルは図3.2に示すように2つのモジュールからなっている。与え

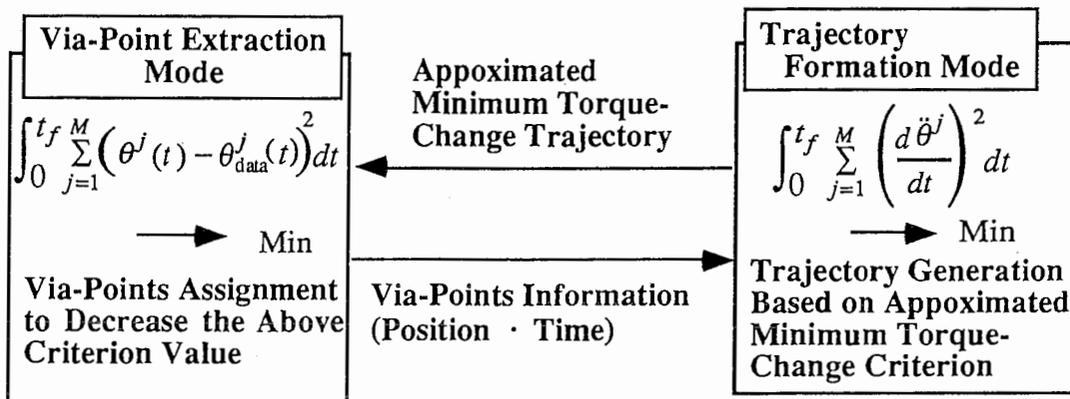


(a) 経路点推定モデル

(a) Via-point estimation model.

τ^j は関節 j によるトルクであり、 $\theta^j(t)$ 、 $\theta_{\text{data}}^j(t)$ は各々モデルによって生成された j 番目の関節角軌道と、 j 番目の関節角での与えられた軌道を示す。 t_f は運動時間を表す。

左側の経路点抽出モジュールが標準正則化理論のデータ項に相当し、右側が滑らかさの項に相当する。



(b) 経路点抽出モジュール

(b) Via-point extraction module.

経路点抽出モジュールでは与えられた軌道と生成した軌道の 2 乗誤差が最小になるように経路点を抽出する。このときモジュール内で生成される軌道は制御対象のダイナミクスを近似したトルク変化最小規範によるものであり、生成される軌道も経路点抽出毎に重ね合わせによって構成される。また、この経路点抽出モジュールにおいても、与えられた軌道と生成した軌道の 2 乗誤差がある閾値以下になるまで経路点の抽出が繰り返される。

図 3.2 経路点推定モデル

Fig 3.2 Via-point estimation model.

られた軌道から経路点を抽出するモジュールと、抽出した経路点を使って軌道を生成するモジュールである。後者は前章で説明した順・逆モデルを使った軌道生成神経回路である。

以下では経路点抽出モジュールを説明する。このモジュールの中でも経路点抽出と軌道生成は交互に繰り返される（図 3.2 (b)）が、このとき使う軌道生成原理は、元々の非線形のダイナミクスではなく、近似としての線形ダイナミクスを拘束条件としたトルク変化最小基準である。特に下式に示すような質点系のダイナミクスを近似にを使った場合にはトルク変化最小解は、関節角座標系での躍度最小モデルと等価になり、解析解が与えられる。

$$\tau^j = I^j \ddot{\theta}^j \quad (j = 1, \dots, M) \quad (3.1)$$

ただし、 $\ddot{\theta}^j$ は関節 j の角加速度を示し、 I^j は慣性モーメントを示す。

経路点の抽出は以下の手順で行われる。図 3.3 に抽出プロセスを簡単に示す。

- (Step1) 与えられた軌道の始点と終点の 2 点を通る軌道を上の近似線形原理によって生成する。（始点・終点での速度・加速度は 0 である。）
- (Step2) 与えられた軌道と生成した軌道を比較して、各関節角の両者の差の 2 乗和の最大となる点を探索して、その点を経路点の候補とする。
- (Step3) 探索した最大値がある閾値以下であれば、この点を経路点とせず経路点の抽出を終了する。もし、探索をした結果がある閾値以上であれば、この点を経路点 i として、この点を経路点とする軌道を質点系モデルによって生成し、既に生成されている軌道に足し込む。ただし、このとき生成する軌道の始点 t_0^i は抽出した経路点の時刻 t_{via}^i の直前の経路点であり、終点 t_f^i は直後の経路点である。この始点・終点の位置での誤差は 0 であるから、この軌道生成時の位置に関する境界条件は 0 となる。また、この始点・終点での軌道速度・加速度も 0 に設定する。

(Step2) , (Step3) を繰り返して経路点を抽出する。(Step2) での関節 j での経路点 i の速度 $\dot{\theta}_{via}^j$ ・ 加速度 $\ddot{\theta}_{via}^j$ は次の関節角躍度評価関数を最小にする速度・加速度によって決める。これは第 2 章で述べた経路点のある場合の軌道生成のモデルと同様である。ただし、経路点の抽出では、その経路点の時刻が抽出時点で特定される。始点 t_0^i , 終点 t_f^i での位置・速度・加速度の境界条件は 0 である。

$$J(\dot{\theta}_{via}^j, \ddot{\theta}_{via}^j) = I^2 \left\{ \int_{t_0^i}^{t_{via}^i} \left(\frac{d\dot{\theta}^j}{dt} \right)^2 dt + \int_{t_{via}^i}^{t_f^i} \left(\frac{d\dot{\theta}^j}{dt} \right)^2 dt \right\} \rightarrow Min \quad (3.2)$$

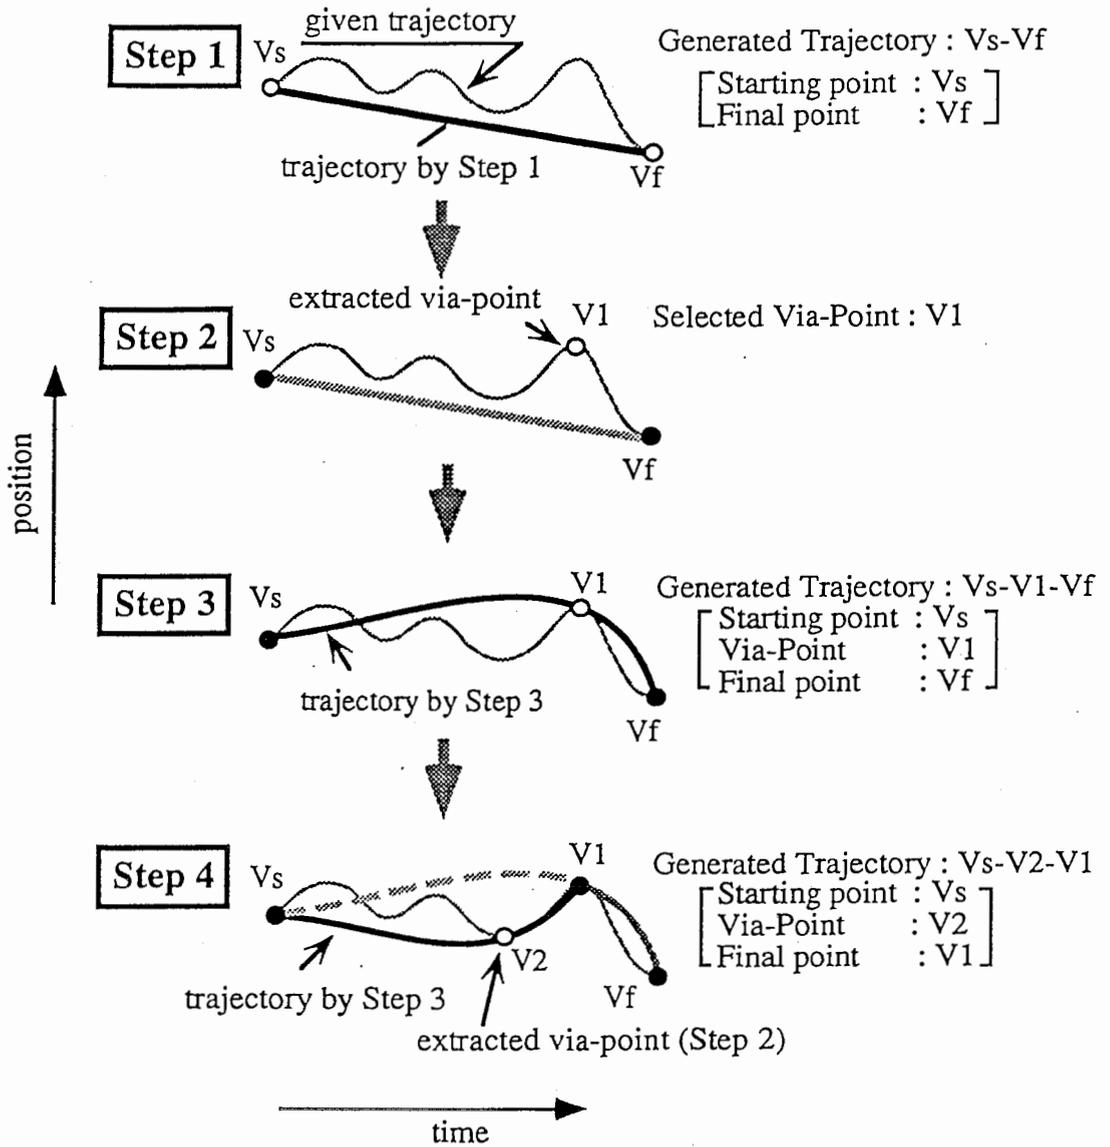


図 3.3 経路点の抽出プロセス

Fig 3.3 Extraction of via-points.

- (Step1) 与えられた軌道の始点 V_s と終点 V_f の2点を通る軌道を生成する。(始点・終点での速度・加速度は0である。)
- (Step2) 与えられた軌道と生成した軌道 V_s-V_f を比較して、各関節角の両者の差の2乗和の最大となる点 V_1 を経路点の候補とする。
- (Step3) もし、探索をした結果がある閾値以上であれば、この点を経路点 V_1 とする軌道を質点系モデルによって軌道 $V_s-V_1-V_f$ を生成する。この始点 V_s ・終点 V_f の位置での誤差は0であるから、この軌道生成時の位置に関する境界条件は0となる。また、この始点 V_s ・終点 V_f での軌道速度・加速度も0に設定する。
- (Step4) (Step2)と同様にして、各関節に対する2乗誤差の和の最大となる点 V_2 を経路点の候補とし、その値がある閾値以上であれば、軌道 $V_s-V_2-V_1$ を生成する。このときも始点 V_s ・終点 V_1 の位置での誤差は0であるから、この軌道生成時の位置に関する境界条件は0であり、この始点 V_s ・終点 V_1 での軌道速度・加速度も0に設定する。

評価関数を最小にする速度 $\dot{\theta}_{via}^j$ ・ 加速度 $\ddot{\theta}_{via}^j$ は次のようになる。

$$\dot{\theta}_{via}^j = -\frac{5}{2} \frac{t_{0,via}^i - (t_f^i - t_{via}^i)}{t_{0,via}^i (t_f^i - t_{via}^i)} \theta_{via}^j \quad (3.3)$$

$$\ddot{\theta}_{via}^j = \frac{10 \left(t_{0,via}^i{}^2 - 4t_{0,via}^i (t_f^i - t_{via}^i) + (t_f^i - t_{via}^i)^2 \right)}{3t_{0,via}^i{}^2 (t_f^i - t_{via}^i)^2} \theta_{via}^j \quad (3.4)$$

ただし $t_{0,via}^i = t_{via}^i - t_0^i$

最終的にこのモジュールが抽出した経路点は軌道生成モジュールに入力されトルク変化最小基準に基づいた軌道が作られる。そして、この軌道と与えられた軌道が十分近ければ経路点の抽出を終了し、十分でない場合は再度経路点抽出モジュールによって経路点を得て追加する。

経路点抽出モジュールは、与えられた軌道と生成した軌道の誤差の最小化を行っており、軌道生成モジュールは滑らかさの項の最小化を行っているといえる。この点において、データ項と滑らかさの項の最小化を行う標準正則化理論 (Poggio, Torre & Koch, 1985) と関連がある。ただし、我々の方法は、データ項と滑らかさの項を交互に最小化しており、標準正則化理論に相当する評価関数を最小化するという意味においては、我々の方法は大域的最適解を得る方法ではなく、近似最適解を得る方法である。

3.3.1.2 理論的検討

次に、この経路点抽出モジュールの理論的妥当性について述べる。第1に各経路点を通る軌道が互いに直交していることを示し、次にこの直交関数系による一般フーリエ級数が完備 (高木, 1983) であることを示す。最後に3.3.1.1節で提案した方法が有限個の経路点を選択する観点から最良の方法であることを述べる。

(1) 各経路点を通る軌道の直交性

ここでの直交性の議論は各関節に対して成り立つ議論であるが、関節を示す添え字は省略して記す。経路点抽出モジュールの (Step 3) で生成される軌道の関係を考える。図 3.3 の場合生成されている軌道は、Vs-Vf, Vs-V1-Vf, Vs-V2-V1 であり、この3軌道のいずれか2軌道をとっても、その始点と終点の時刻はどちらかの軌道

の始点から終点の時刻に含まれる。また、他のケースとしては、 V_s と V_2 の間に経由点 V_3 が、 V_1 と V_f の間に経由点 V_4 が推定されたとき、軌道 V_s - V_3 - V_2 と V_1 - V_4 - V_f の間には時間に関する重なりはない。かつ、経由点抽出モデルで抽出される経由点は、既に抽出された経由点と経由点の間から必ず抽出されるから、 V_3 - V_2 - V_1 、 V_2 - V_1 - V_4 となるような互いの軌道の1部分だけが重なった軌道が生成されることはない。

この考察に基づき (Step 3) で生成される軌道の躍度を $\ddot{\gamma}_1, \ddot{\gamma}_2, \ddot{\gamma}_3, \dots, \ddot{\gamma}_l$ とすると、各軌道間の直交性を検討する。いま軌道 i と j 各々の始点と終点の関係を考えると、以下のように分類される。(ただし、 $i \neq j$ とする。)

a. 軌道 i と j は時間的に重なりがない。

b. 軌道 i と j は時間的に重なりがある。

このときは、軌道 i と j の始点あるいは終点時刻が同じか、軌道 i の始点・終点の時刻が軌道 j の運動時間内に含まれる。

aの場合は明らかに、式(3.5)が成り立つ。 t_f は全体の運動時間を示す。

$$\int_0^{t_f} \left(\frac{d^3 \gamma_i}{dt^3} \right) \left(\frac{d^3 \gamma_j}{dt^3} \right) dt = 0 \quad (3.5)$$

bの場合、含まれる軌道 i の始点、終点、経由点の時刻を各々 t_0^i, t_f^i, t_{via}^i とし、 γ_i^1 を t_0^i から t_{via}^i の軌道、 γ_i^2 を t_{via}^i から t_f^i の軌道とする。

$$\begin{aligned} \int_0^{t_f} \left(\frac{d^3 \gamma_i}{dt^3} \right) \left(\frac{d^3 \gamma_j}{dt^3} \right) dt \\ = \int_{t_0^i}^{t_{via}^i} \left(\frac{d^3 \gamma_i^1}{dt^3} \right) \left(\frac{d^3 \gamma_j}{dt^3} \right) dt + \int_{t_{via}^i}^{t_f^i} \left(\frac{d^3 \gamma_i^2}{dt^3} \right) \left(\frac{d^3 \gamma_j}{dt^3} \right) dt \end{aligned} \quad (3.6)$$

式(3.6)の右辺第1項を I_1 、第2項を I_2 とすると、部分積分を繰り返すことによって次式を得る。

$$\begin{aligned} I_1 = & \left[\frac{d^2 \gamma_i^1}{dt^2} \frac{d^3 \gamma_j}{dt^3} \right]_{t_0^i}^{t_{via}^i} - \left[\frac{d \gamma_i^1}{dt} \frac{d^4 \gamma_j}{dt^4} \right]_{t_0^i}^{t_{via}^i} \\ & + \left[\gamma_i^1 \frac{d^5 \gamma_j}{dt^5} \right]_{t_0^i}^{t_{via}^i} - \int_{t_0^i}^{t_{via}^i} \gamma_i^1 \left(\frac{d^6 \gamma_j}{dt^6} \right) dt \end{aligned} \quad (3.7)$$

$$I_2 = \left[\frac{d^2 \gamma_i^2}{dt^2} \frac{d^3 \gamma_j}{dt^3} \right]_{t_{via}^i}^{t_f^i} - \left[\frac{d \gamma_i^2}{dt} \frac{d^4 \gamma_j}{dt^4} \right]_{t_{via}^i}^{t_f^i} + \left[\gamma_i^2 \frac{d^5 \gamma_j}{dt^5} \right]_{t_{via}^i}^{t_f^i} - \int_{t_{via}^i}^{t_f^i} \gamma_i^2 \left(\frac{d^6 \gamma_j}{dt^6} \right) dt \quad (3.8)$$

ところで質点系のダイナミクスを考えたとき、そのトルク変化最小解は関節角座標での躍度最小解であり5次多項式となり式(3.9)が成り立つ。

$$\frac{d^6 \gamma_j}{dt^6} = 0 \quad (3.9)$$

また境界条件より考えて式(3.10)も成立している。

$$\begin{aligned} \gamma_i^1 &= \frac{d \gamma_i^1}{dt} = \frac{d^2 \gamma_i^1}{dt^2} = 0 \quad (t = t_0^i) \\ \gamma_i^2 &= \frac{d \gamma_i^2}{dt} = \frac{d^2 \gamma_i^2}{dt^2} = 0 \quad (t = t_f^i) \\ \gamma_i^1 &= \gamma_i^2, \quad \frac{d \gamma_i^1}{dt} = \frac{d \gamma_i^2}{dt}, \quad \frac{d^2 \gamma_i^1}{dt^2} = \frac{d^2 \gamma_i^2}{dt^2} \quad (t = t_{via}^i) \end{aligned} \quad (3.10)$$

故に

$$I_1 + I_2 = 0 \quad (3.11)$$

となり、この場合も式(3.5)が成り立ち $\frac{d^3 \gamma_i}{dt^3}$ と $\frac{d^3 \gamma_j}{dt^3}$ が直交していることがわかる。

(2) 軌道の一般フーリエ級数展開と完備性

次に、3.3.1.1節のアルゴリズムで生成される補償軌道の列が完備で次のように表すことができることを示す。ただし、 θ_{data} は与えられた軌道であり、 $\ddot{\theta}_{data}$ は与えられた軌道の躍度を表す。

$$\ddot{\theta}_{data} = \sum_{i=1}^{\infty} c_i \ddot{\phi}_i \quad (3.12)$$

ただし、補償軌道 $\ddot{\gamma}_i$ を正規化した正規直交関数を $\ddot{\phi}_i$ とする。また、考えている関数

空間の内積を躍度の積分によって次のように定義する.

$$(f, g) \equiv \int_0^{t_f} \left(\frac{d^3 f}{dt^3} \right) \left(\frac{d^3 g}{dt^3} \right) dt$$

$$\varphi_i \equiv \frac{1}{\sqrt{m_i}} \gamma_i$$

$$m_i \equiv \|\gamma_i\|^2 \equiv (\gamma_i, \gamma_i) = \int_0^{t_f} \left(\frac{d^3 \gamma_i}{dt^3} \right)^2 dt = \int_{t_0^i}^{t_f} \left(\frac{d^3 \gamma_i}{dt^3} \right)^2 dt$$

c_i はフーリエ式係数であり, 次式のように定義されるものである.

$$c_i = (\theta_{data}, \varphi_i) \quad (3.13)$$

いま n 個の経由点とそれに伴って生成された補償軌道 $\varphi_i (i = 1, \dots, n)$ を考え次の様な級数の部分和を定義する.

$$\theta_{sub} \equiv a_1 \varphi_1 + a_2 \varphi_2 + a_3 \varphi_3 + \dots + a_n \varphi_n \quad (3.14)$$

ここで, 下式のような 2 乗誤差を考える.

$$\begin{aligned} J &= \int_0^{t_f} \left(\frac{d^3 \theta_{data}}{dt^3} - \frac{d^3 \theta_{sub}}{dt^3} \right)^2 dt \\ &= \int_0^{t_f} \left(\frac{d^3 \theta_{data}}{dt^3} \right)^2 dt - \sum_{i=1}^n c_i^2 + \sum_{i=1}^n (c_i - a_i)^2 \end{aligned} \quad (3.15)$$

J は $a_i = c_i$ で最小 2 乗誤差を与える. そこで $a_i = c_i$ と選ぶと, $J \geq 0$ より, 次の不等式が与えられる.

$$\|\theta_{data}\|^2 \geq (c_1^2 + c_2^2 + c_3^2 + \dots + c_n^2) \quad (3.16)$$

θ_{data} は, 与えられた軌道であり, $\|\theta_{data}\|^2$ は躍度の 2 乗ノルムを与えており, それは有界の値である. 故に無限級数 $\sum_{i=1}^{\infty} c_i^2$ も収束することがわかる.

$$\infty > \|\theta_{data}\|^2 \geq \sum_{i=1}^{\infty} c_i^2 \quad (3.17)$$

したがって c_n^2 は 0 に収束する.

$$\lim_{n \rightarrow \infty} c_n^2 = 0 \quad (3.18)$$

ところで, フーリエ式係数の 2 乗は式 (3.19) のように表すことができ, それは,

補償軌道の躍度の2乗積分となる。

$$c_i^2 = \int_0^{t_f} \left(\frac{d^3 \gamma_i}{dt^3} \right)^2 dt = \int_{t_0^i}^{t_f^i} \left(\frac{d^3 \gamma_i}{dt^3} \right)^2 dt \quad (3.19)$$

いま、式(3.3)、(3.4)の速度・加速度に従って躍度の2乗積分 c_i^2 を計算すると、次式のように与えられる。

$$c_i^2 = 20 \{ \delta \theta_i \}^2 \left(\frac{1}{t_{via}^i} + \frac{1}{t_f^i - t_{via}^i} \right)^5 \quad (3.20)$$

$$\text{ただし、} \{ \delta \theta_i \}^2 = \max_{0 < t < t_f} \{ \theta_{data}(t) - \{ \gamma_1(t) + \gamma_2(t) + \dots + \gamma_{i-1}(t) \} \}^2$$

t_{via}^i は、上式の最大値を満足する t である。

しかも、式(3.20)の右辺の後半部について次式の関係が言える。

$$\left(\frac{1}{t_{via}^i} + \frac{1}{t_f^i - t_{via}^i} \right)^5 \geq \left(\frac{4}{t_f} \right)^5 > 0$$

故に、 $c_n \rightarrow 0$ から n が十分大きいとき、 $\{ \delta \theta_n \}^2$ が十分小さくなる必要がある。つまり、

$$\left| \theta_{data}(t_{via}^n) - \{ \gamma_1(t_{via}^n) + \gamma_2(t_{via}^n) + \dots + \gamma_{n-1}(t_{via}^n) \} \right| < \varepsilon$$

ところで、 t_{via}^n の定義から考えて明らかに次式が成り立つ。

$$\begin{aligned} & \left| \theta_{data}(t) - \{ \gamma_1(t) + \gamma_2(t) + \dots + \gamma_{n-1}(t) \} \right| \\ & \leq \left| \theta_{data}(t_{via}^n) - \{ \gamma_1(t_{via}^n) + \gamma_2(t_{via}^n) + \dots + \gamma_{n-1}(t_{via}^n) \} \right| \end{aligned}$$

ただし、 $0 < t < t_f$

つまり、式(3.21)が任意の t ($0 < t < t_f$)について成り立つ。

$$\left| \theta_{data}(t) - \sum_{i=1}^{n-1} c_i \varphi_i(t) \right| < \varepsilon \quad (3.21)$$

故に、部分級数 $\sum_{i=1}^{n-1} c_i \varphi_i(t)$ は与えられた軌道 $\theta_{data}(t)$ に一様収束することがわかる。

次に再度式(3.15)の J の計算を考える。まず、 θ_{sub} の連続性について検討すると、式(3.3)、(3.4)の速度・加速度に従って γ_i を構成すると、4階微分まで運動時間内において連続であることが計算によって確かめられる。また、5階微

分が不連続となる点は、推定された経路点時刻においてであることがわかる。故に J を連続な区分に分割して部分積分を使って計算し、連続の条件を使って整理すると次式のように与えられる。

ここでは、与えられた軌道 θ_{data} は少なくとも 6 階微分まで可能で、かつ連続と考える。

$$\begin{aligned}
 J &= \sum_{i=0}^{K-1} \int_{t_i}^{t_{i+1}} \left(\frac{d^3\theta_{data}}{dt^3} - \frac{d^3\theta_{sub}}{dt^3} \right)^2 dt \\
 &= \left[\left(\frac{d^2\theta_{data}}{dt^2} - \frac{d^2\theta_{sub}}{dt^2} \right) \left(\frac{d^3\theta_{data}}{dt^3} - \frac{d^3\theta_{sub}}{dt^3} \right) \right]_0^{t_f} \\
 &\quad - \left[\left(\frac{d\theta_{data}}{dt} - \frac{d\theta_{sub}}{dt} \right) \left(\frac{d^4\theta_{data}}{dt^4} - \frac{d^4\theta_{sub}}{dt^4} \right) \right]_0^{t_f} \\
 &\quad + \sum_{i=0}^{K-1} \left[(\theta_{data} - \theta_{sub}) \left(\frac{d^5\theta_{data}}{dt^5} - \frac{d^5\theta_{sub}}{dt^5} \right) \right]_{t_i}^{t_{i+1}} \\
 &\quad - \sum_{i=0}^{K-1} \int_{t_i}^{t_{i+1}} (\theta_{data} - \theta_{sub}) \left(\frac{d^6\theta_{data}}{dt^6} - \frac{d^6\theta_{sub}}{dt^6} \right) dt \tag{3.22}
 \end{aligned}$$

ただし、 $K-1$ は経路点の数であり、 t_i は経路点の時間であり、 $t_0 = 0$ 、 $t_K = t_f$ である。

ところで、始点、終点での θ_{data} 、 θ_{sub} の速度・加速度は 0 であり、位置に関しては各経路点で θ_{data} 、 θ_{sub} は一致している。また、 θ_{sub} は高々時間 t の 5 次多項式であり、次式が成り立つ。

$$\frac{d^6\theta_{sub}}{dt^6} = 0 \tag{3.23}$$

従って、 θ_{data} 、 θ_{sub} 、 $\frac{d^6\theta_{sub}}{dt^6}$ が連続であることから J は次式により与えられる。

$$J = - \int_0^{t_f} (\theta_{data} - \theta_{sub}) \frac{d^6\theta_{data}}{dt^6} dt \tag{3.24}$$

いま、 $\frac{d^5\theta_{sub}}{dt^5}$ が $0 \leq t \leq t_f$ でリプシッツ条件を満たすと仮定するとリプシッツ定数 L が存在する。

$$\left| \frac{d^6 \theta_{data}}{dt^6} \right| \leq L \quad (3.25)$$

また、式 (3.21) での一様収束の議論から n を大きくとれば微小量 δ に対して次式が成り立つ。

$$|\theta_{data} - \theta_{sub}| \leq \delta \quad (3.26)$$

従って式 (3.25) と式 (3.26) より次の不等式が得られる。

$$\left| \int_0^{t_f} (\theta_{data} - \theta_{sub}) \frac{d^6 \theta_{data}}{dt^6} dt \right| \leq L \cdot \delta \cdot t_f \quad (3.27)$$

ところで、 L と t_f は θ_{data} が与えられると定まる言わば定数である。よって、 n を十分大きくすれば δ を十分に小さくすることができ、次式を得ることができる。

$$0 \leq \int_0^{t_f} \left(\frac{d^3 \theta_{data}}{dt^3} - \frac{d^3 \theta_{sub}}{dt^3} \right)^2 dt \leq \varepsilon' \quad (3.28)$$

故に、正規直交列 $\left\{ \frac{d^3 \varphi_n}{dt^3} \right\}$ が完備であることが言える。つまり、3.3.1.1 節で提案したモデルによって構成されるフーリエ級数は完備であり、十分な数の経由点によって与えられた軌道を完全に再現できることが示された。上述した証明は煩雑さを避けるため単関節の場合を述べたが、多関節の場合にも同様の議論ができ各関節の和に関して式 (3.28) が成立することが言える。

(3) フーリエ多項式の構成方法

ここで考えているような経由点の認識問題では、比較的少ない有限個 l の経由点によって与えられた軌道データを良く近似する必要がある。ここでは、3.3.1.1 節で提案した方法が上で議論したように完備な正規直交列を与えているだけでなく、有限個の経由点 (直交関数) を考えた場合には、近似的ではあるが最も誤差が小さくなる経由点の選択方法であることを述べる。

いま l 個の経由点とそれに伴って生成された補償軌道 φ_i^m ($i = 1, \dots, l$) を考え次の様な級数の部分和を定義する。ただし、 m ($m = 1, \dots, M$) は m 番目の関節を示す。

$$\theta_{sub}^m \equiv c_1^m \varphi_1^m + c_2^m \varphi_2^m + c_3^m \varphi_3^m + \dots + c_l^m \varphi_l^m \quad (3.29)$$

与えられた軌道の躍度 $\ddot{\theta}_{data}^m$ と $\ddot{\theta}_{sub}^m$ の 2 乗誤差は式 (3.15) の計算と同様に次式で

与えられる。

$$\sum_{m=1}^M \left| \int_0^{t_f} \left(\frac{d^3 \theta_{data}^m}{dt^3} \right)^2 dt - \left\{ (c_1^m)^2 + (c_2^m)^2 + (c_3^m)^2 + \dots + (c_l^m)^2 \right\} \right| \quad (3.30)$$

式 (3.30) の {} 内の第 1 項はデータが与えられれば一定であるから、少ない有限個の正規直交関数によって θ_{data}^m の躍度を近似するには

$$\sum_{m=1}^M \left\{ \left\{ (c_1^m)^2 + (c_2^m)^2 + (c_3^m)^2 + \dots + (c_l^m)^2 \right\} \right\}$$

を最大化する方法が良いアルゴリズムとなる。ところで、

$$(c_i^m)^2 = \int_{t_0^i}^{t_f^i} \left(\frac{d^3 \gamma_i^m}{dt^3} \right)^2 dt$$

であるから、上で述べたことを言い換えれば、各補償軌道の躍度の 2 乗積分和が大きくなるように経路点を抽出するのが与えられた軌道の躍度を近似する良いアルゴリズムとなる。

しかしながら、この問題は、経路点の数 l があらかじめ与えられていないとき、経路点の数・位置の組み合わせが無限に存在することになり、厳密に解くのは困難である。ここでは、3.3.1.1 節で述べたような逐次的な方法を考えるから、各経路点の抽出時に躍度の 2 乗積分が最大となるようにして、躍度の 2 乗積分和が最大となる近似解を得ることをめざす。

いま、式 (3.3)、式 (3.4) の速度・加速度に従って躍度の 2 乗積分を計算すると、経路点通過時間 t_{via}^i の関数として式 (3.20) と同様に次のように与えられる。

$$J(t_{via}^i) = \sum_{m=1}^M (c_i^m(t_{via}^i))^2 = \sum_{m=1}^M \left\{ 20 \left\{ \delta \theta_i^m(t_{via}^i) \right\}^2 \left(\frac{1}{t_{via}^i} + \frac{1}{t_f^i - t_{via}^i} \right)^5 \right\} \quad (3.31)$$

ただし、ここでは $\delta \theta_i^m$ は下式で定義される級数の部分和に対する残差軌道である。

$$\delta \theta_i^m(t_{via}^i) = \theta_{data}^m(t_{via}^i) - \left\{ \gamma_1^m(t_{via}^i) + \gamma_1^m(t_{via}^i) + \dots + \gamma_{i-1}^m(t_{via}^i) \right\}$$

ここでは、残差軌道の 2 乗和 $\sum_{m=1}^M \left\{ \delta \theta_i^m(t_{via}^i) \right\}^2$ を最大とするような経路点時間 t_{via}^i が式 (3.31) を最大とする近似解であることを述べる。式 (3.31) を t_{via}^i で微分

すると次式が得られる。

$$\frac{dJ}{dt^i_{via}} = \left(\frac{1}{t^i_{via}} + \frac{1}{t^i_f - t^i_{via}} \right)^5 \cdot \sum_{m=1}^M 20 \delta \theta_i^m(t^i_{via}) \left\{ 2 \frac{d\delta \theta_i^m(t^i_{via})}{dt} + 5 \delta \theta_i^m(t^i_{via}) \left(\frac{1}{t^i_f - t^i_{via}} - \frac{1}{t^i_{via}} \right) \right\} \quad (3.32)$$

式 (3.32) の右辺が 0 となるのは、次式が成り立つ場合である。

$$\sum_{m=1}^M \left\{ 2 \delta \theta_i^m(t^i_{via}) \frac{d\delta \theta_i^m(t^i_{via})}{dt} + 5 \{ \delta \theta_i^m(t^i_{via}) \}^2 \left(\frac{1}{t^i_f - t^i_{via}} - \frac{1}{t^i_{via}} \right) \right\} = 0 \quad (3.33)$$

式 (3.33) の左辺は、第 1 項が 0 となり、かつ、経路点通過時間が運動時間の中間に位置する場合に 0 となる。 $\sum_{m=1}^M \{ \delta \theta_i^m(t^i_{via}) \}^2$ が最大値をとる時間は、式 (3.33) の左辺第 1 項が 0 となる時間に対応する。よって、運動時間の中央付近で $\sum_{m=1}^M \{ \delta \theta_i^m(t^i_{via}) \}^2$ の最大値を探ることが式 (3.33) の良い近似解を得る 1 つの方法である。実際に図 3.5 に示すような運動で式 (3.31) が極大となる点と残差軌道の 2 乗和が最大となる点がほぼ一致することを数値計算によって確認している。従って前述した経路点抽出モジュールは近似的ではあるが、与えられた軌道の躍度を少ない有限個の直交関数で近似するために、適切な点を抽出するモデルであることがわかる。

以上理論的な考察より経路点推定モデルは、意図する文字を再構成するための最小の数の経路点を抽出するモデルであることが示された。

ここで述べたモデルは、経路点での計測された速度・加速度を用いない。速度・加速度が与えられている場合には、3.3.1.1 節の Step 3 で始点・終点での速度・加速度の境界条件を 0 とせずに計測データの残差軌道のそれを境界条件とすることもできる。ただし、このとき各軌道の躍度は厳密に直交しないが、擬似的な直交性は成り立ち、上の議論を、この場合にも応用できる。

3.3.2 経路点推定モデルに基づいた書字運動モデル

我々が提案している書字運動モデルは、図 3.4 に示すように、前節で述べた経路

点抽出方式を理論的基礎とする経路点推定モデルと、運動軌道生成のための最適化規範に基づいた軌道生成モデルからなる。軌道生成モデルにおける補償軌道の生成（図2.5のStep 4）を質点系モデルで行ったときは、経路点の時間が特定されているとすると、スプライン関数（桜井，1981）によって生成することができる。本論文での数値実験では、経路点の時間は経路点推定モデルによって抽出された時間に特定されたとして軌道の生成を行うが、スプライン関数を使うのではなく、図3.3の中で示されるような軌道生成方式によって補償軌道の生成がなされる。ただし、経路点は式（3.31）を最小化する経路点から順番に選択されて逐次加算的に補償軌道の生成が行われる。

このモデルでは、もし脳内に文字毎に対応した表現があるとしたら、経路点推定モデルは、文字軌道をロバストで簡単な表現に変換するための変換モデルと解釈できる。ある運動パターンを人間が熟練した動作として獲得するとき、人間はこの運動パターンをどのような表現に変換して脳内に記憶するのであろうか。ボールに手を延ばすような簡単な到達運動について考えて見ると，“ボールに手を延ばす”運動の目的が、手先のある位置（始点）からボールのある位置（終点）まで、ある運動時間で手を延ばすと言う運動計画の条件に展開され、次にそれを実現するための関節トルク、筋張力に変換され、最終的に運動軌道として実現されるといった運動計画の階層構造が考えられるが、このとき、運動の始点・終点などは視覚情報として与えられることから言っても内部表現されている可能性が大きい。これは、上述

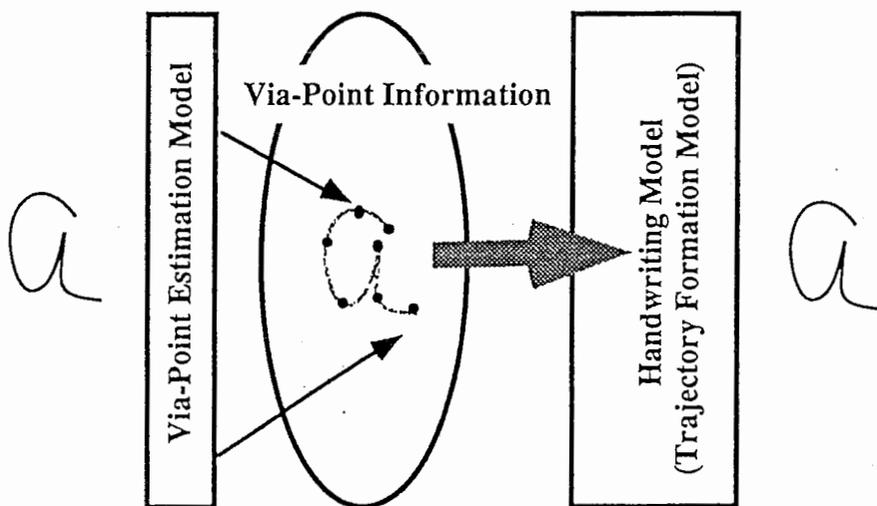


図 3.4 書字運動モデル

Fig 3.4 Handwriting model.

したトルク変化最小規範や躍度最小規範と言った最適化規範によって運動軌道が計画されていると考えるならば、軌道生成のための最適化問題は腕の始点と終点位置、および運動の時間を境界条件として解かれることになる。つまり、この境界条件を表現として持つことが、到達運動における最も簡単でロバストな表現と考えることが自然である。この到達運動との類似性から、複雑な運動である書字運動についても、書字運動の境界条件を文字軌道の表現として考えることが可能である。そして、この境界条件が経路点推定モデルで抽出する経路点情報に対応する。

提案した書字運動のモデルは最適化規範に基づいた軌道生成モデルであり、軌道を生成するための境界条件を軌道生成のための最適化規範に基づいた理論的な基準に従って与えている点が他のモデル (Hollerbach, 1981; Morasso & Mussa Ivaldi, 1982; Edelman & Flash, 1987) とは全く異なる。

3.4 様々なデータに対する経路点の推定結果

3.3節で述べた経路点推定モデルを、腕の運動と調音器官の運動データに適用し、提案したモデルによって適切な経路点が推定できることを示す。3.4.1節、3.4.2節では、被験者の運動をOPTOTRAK (3次元位置計測装置) によって計測し、その計測結果を使って数値実験を行った。この数値実験で使う順・逆モデルは2関節マニピュレータの数式モデルであり、パラメータは第2章と同様である。

3.4.1 経路点を与えた運動における推定

被験者に経路点を指定した運動の測定データから経路点推定モデルによって経路点を推定し、その結果と実際に指定した経路点を比較する。運動は始点、終点と1つの経路点を指定した運動である。2種類の軌道T3-P1-T5, T3-P2-T5について実験した。図3.5に目標の始点T3, 終点T5, 経路点P1, P2, および実験によって得た軌道と推定した経路点を示す。図3.5からわかるように推定された経路点は目標の経路点周辺にばらついており、経路点推定モデルが実際の経路点に近い点を推定できることが示されている。

また、図3.6, 図3.7に図3.5で示した運動T3-P2-T5の手先の接線方向の速度と曲率を示す。推定された経路点は、ピークとなる曲率から少しずれた、終点方向

に近い点を推定しているし、速度で見ても極小点から少し後にずれた点を推定している。これは経由点を与えてトルク変化最小基準で軌道生成したとき生成された軌道のどこに曲率の極大点が位置するかについて一般的に得られる傾向（Uno et al., 1989）であり、以上の実験結果から今回の経由点推定モデルが運動の経由点を推定するという意味において妥当な方法であることがわかる。

逆方向の運動T5-P2-T3は、ダイナミクスの影響によってT3-P2-T5を完全には時間逆転した運動とはならない。この運動の傾向は曲率の最大点が指定した経由点よりもかなり運動の終点方向に近くなる。推定された経由点は、順方向の場合と同様に、速度や曲率の極値と異なって、かつ、指定した経由点に近い点である。経由点推定モジュールは関節角座標の躍度最小モデルを使った軌道生成を行っており、キネマティックな関係だけで経由点が抽出されているとみなせるが、実際にはトルク変化最小解の良い近似モデルと考えるほうが妥当である。実際に関節角での躍度最小軌道を使わずに、経由点の抽出毎に軌道生成モジュールでトルク変化最小軌道を生成しながら経由点を推定しても結果はほとんど同じになる。

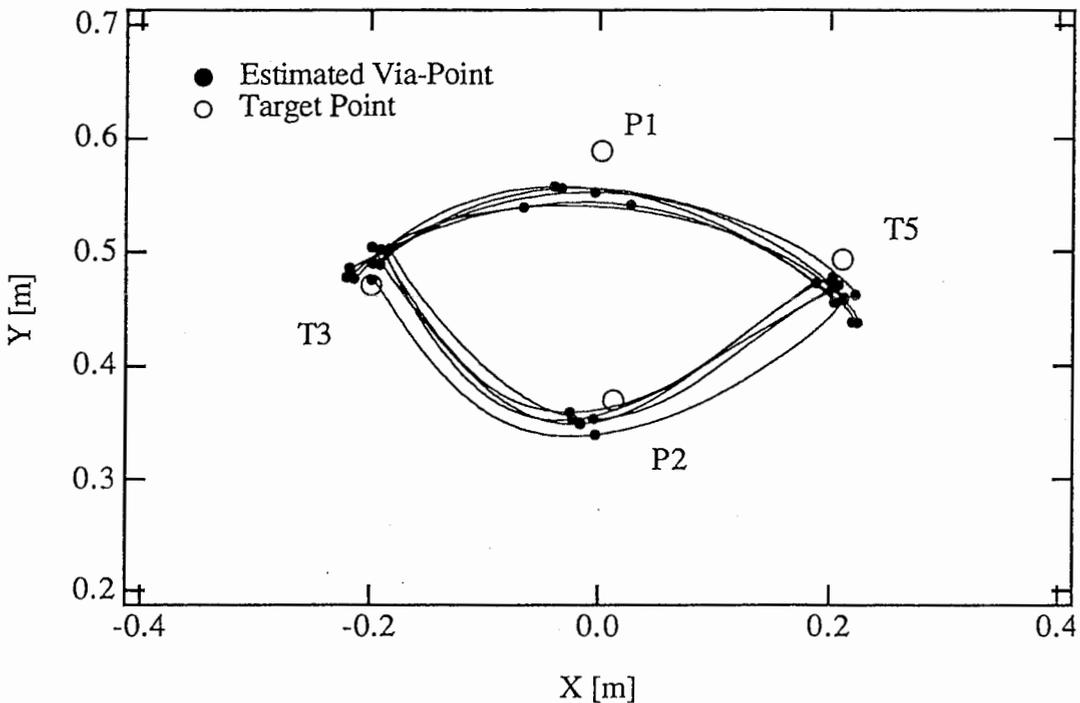


図 3.5 経由点のある運動での経由点推定結果

Fig 3.5 A result of via-point estimation in a movement with a via-point.

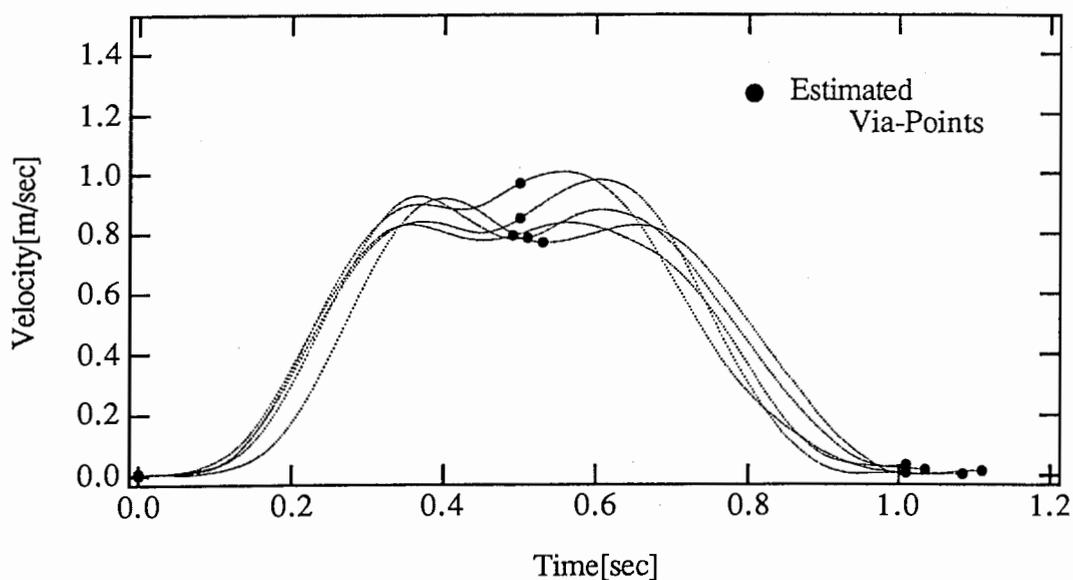


図 3.6 接線速度における推定経路点の位置

Fig 3.6 Estimated via-point position in tangential velocity curve.

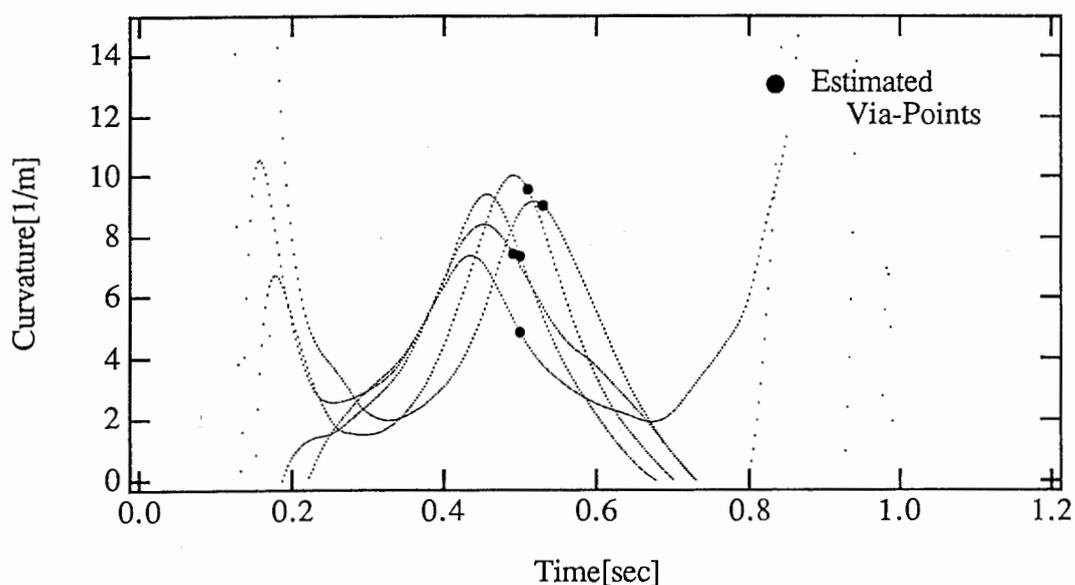


図 3.7 曲率における推定経路点の位置

Fig 3.7 Estimated via-point position in curvature curve.

図 3.5 ~ 図 3.7 での腕のダイナミクスの値は第 2 章で示した値と同じである。また、経路点推定のための誤差の閾値は 0.08 とした。

3.4.2 書字運動における経路点の推定

実際の書字運動軌道から推定される経路点について、その点における速度・曲率を検討する。図3.8～10に続け文字の書字運動結果と推定された経路点および速度と曲率のデータを示す。推定された経路点は、2種類に大別される。1つは、速度の極小点あるいは曲率の極大点の近傍に推定される点と、もう1つは、速度や曲率の極値をとる点とは無関係の位置に推定される点である。前者の経路点は、上で示した経路点1つの場合と同様に、推定される経路点は速度や曲率の極値の近傍で少しずれた位置が推定されている。一般に、速度・曲率の極値は軌道の特徴点とみなされることが多いが、ここで提案したモデルはそれをある程度裏付けているといえる。最小化原理に基づいた方法で、速度・加速度のような比較的取り扱いの難しい計測データを使わずに、位置データだけによって速度・曲率（加速度）の極小・極大点と関連する特徴点を推定できている。

ところで、速度の極小となる点や曲率の極大となる点だけを使うと元の軌道を再現できないことを確認している。このことは上の第2のグループの経路点が重要であることを示している。つまり、我々が提案した経路点推定モデルは、速度や曲率の極値といった指標とは異なる最小化原理に基づいた方法によって、それらの純粋にキネマティックな指標では推定できない点を抽出でき、しかも、再構成される軌

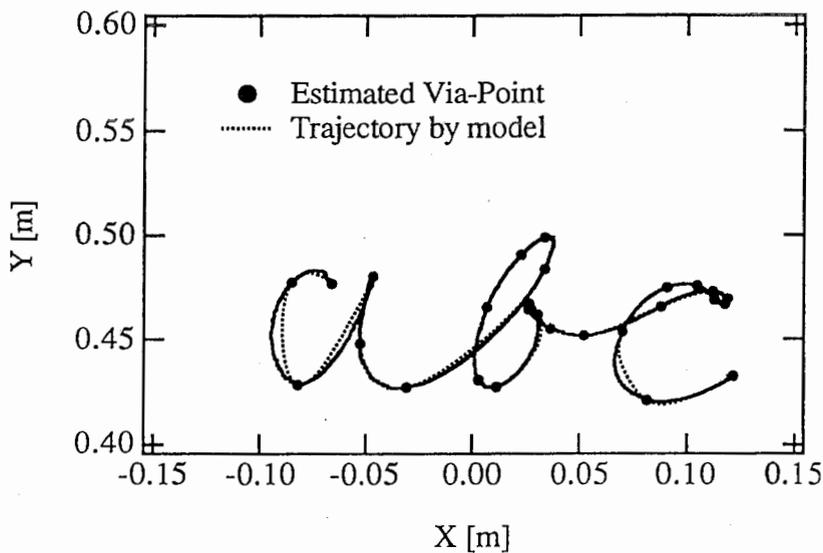


図3.8 書字運動における推定された経路点

Fig 3.8 Estimated via-points in a cursive handwriting.

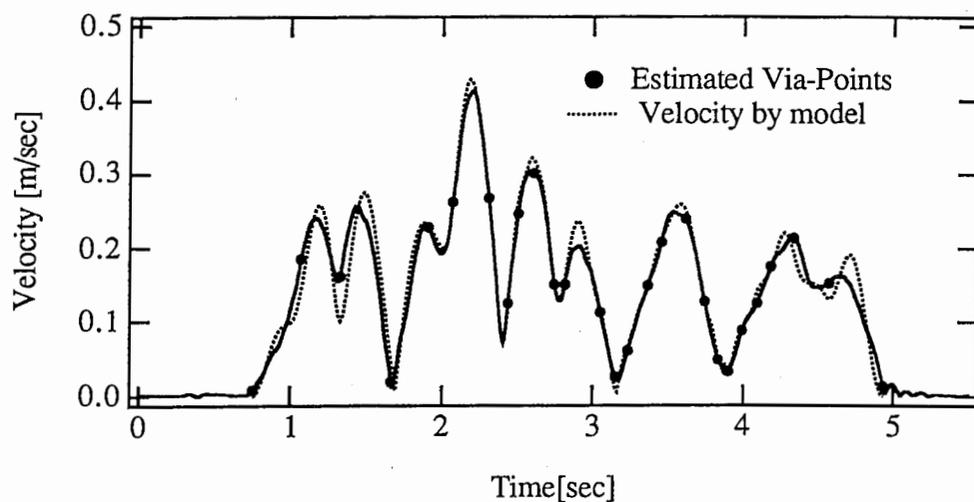


図 3.9 書字運動における接線速度と推定された経由点の位置
 Fig 3.9 Estimated via-point positions in tangential velocity curve
 in a cursive handwriting.

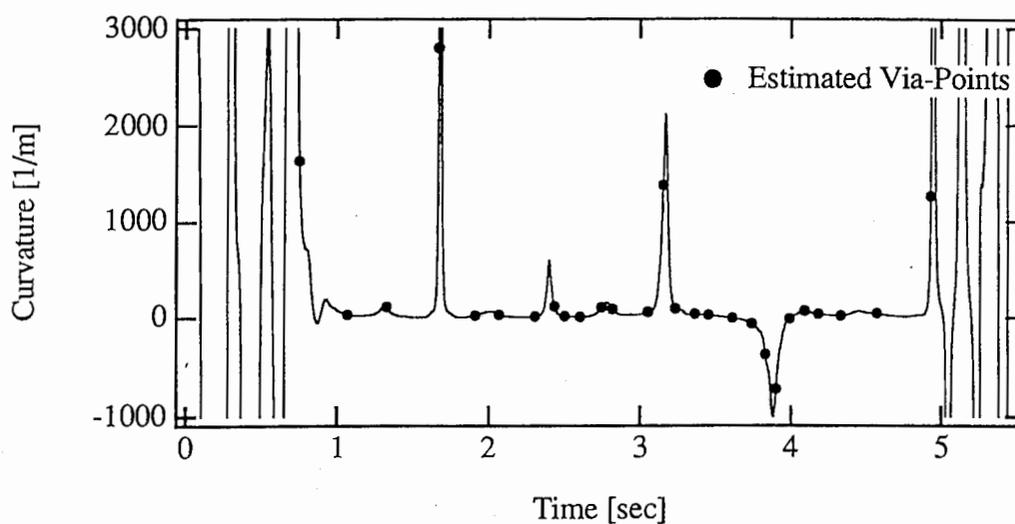


図 3.10 書字運動における曲率と推定された経由点の位置
 Fig 3.10 Estimated via-point positions in curvature curve
 in a cursive handwriting.

図 3.8 ~ 図 3.10 での腕のダイナミクスの値は第 2 章で示した値と同じである。また、
 経由点推定のための誤差の閾値は 0.01 とした。軌道生成に使った滑らかさのパラメータ
 は、 $\lambda = 0.1$ 、滑らかさのオペレータの繰り返し回数は 100 回とした。

道の誤差に従って経由点の数をコントロールすることが可能である。

経由点の個数の多少について一般的な議論は困難であるが、元の軌道を再現するという観点からすれば、経由点推定モデルは重要な点を正しく抽出していると考えられる。

図 3.8 に示すように連続文字の場合、推定された経由点は文字の区切りとなる点を推定しており連続文字の認識に経由点推定モデルが応用可能であることを示している。なお、推定した経由点によって再生された軌道は破線で示してある。

また、図 3.11 ~ 図 3.13 に続け文字 "def" に対して経由点を推定した結果を示す。結果は、続け文字 "abc" のときと同様である。以下に、続け文字に対して経由点推定モデルを適用した場合に推定される点の特色をまとめる。(1) 経由点推定モデルで推定される点によって元々の軌道を再現することが可能である。(2) 推定された点は、続け文字の区切りとなる点を推定しており、文字認識における文字の区切り点の候補としての可能性も高い。(3) 推定される点は、速度・曲率の極値に相当する点と、ほぼその中間点に対応する点の2種類に分類される。(速度の極値に対応する点は、y 方向の速度のゼロ交差点によく対応している。これは、Hollerbach (1981) のモデルで重要視されている点に相当する。ただし、上でも指摘しているように、ゼロ交差点だけで文字を再現することは、この計画原理では可能ではなく速度・曲率の極値に対応しない第2のグループの点が重要である。)

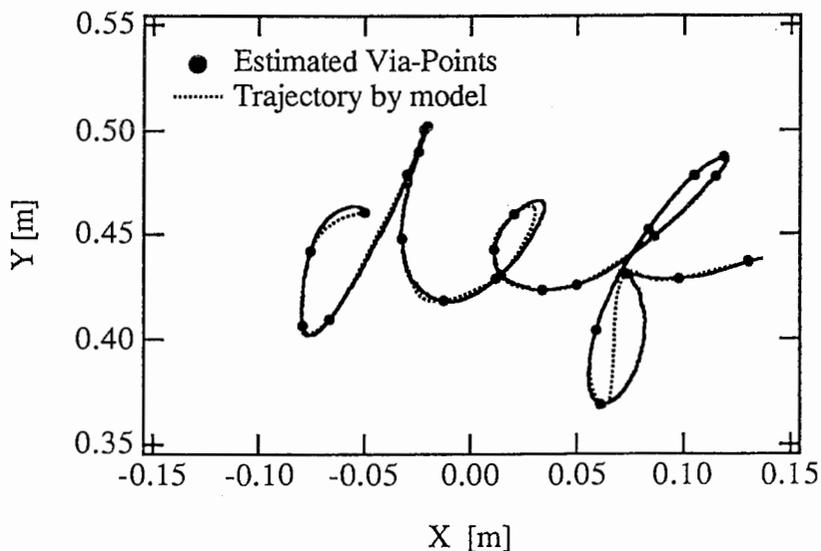


図 3.11 書字運動における推定された経由点

Fig 3.11 Estimated via-points in a cursive handwriting.

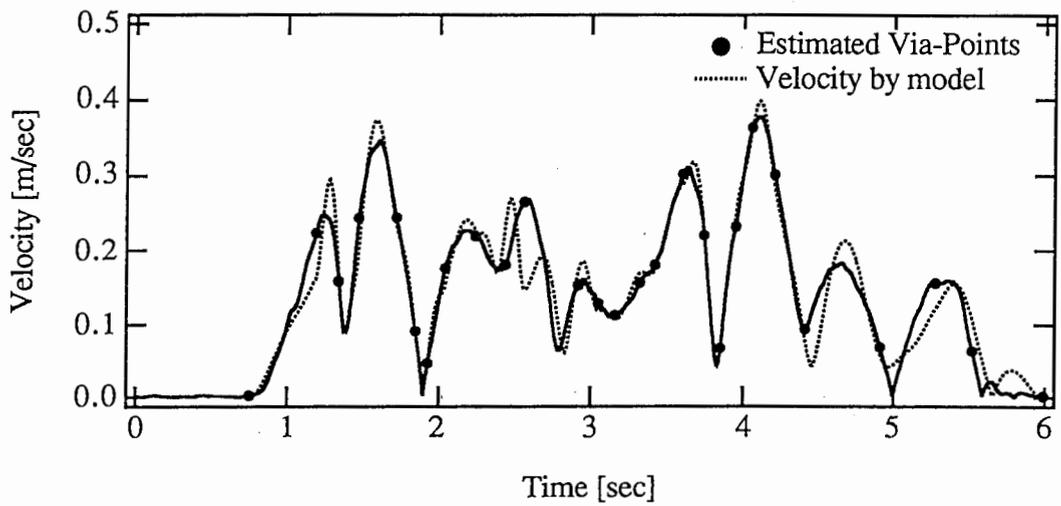


図 3.12 書字運動における接線速度と推定された経由点の位置
 Fig 3.12 Estimated via-point positions in tangential velocity curve
 in a cursive handwriting.

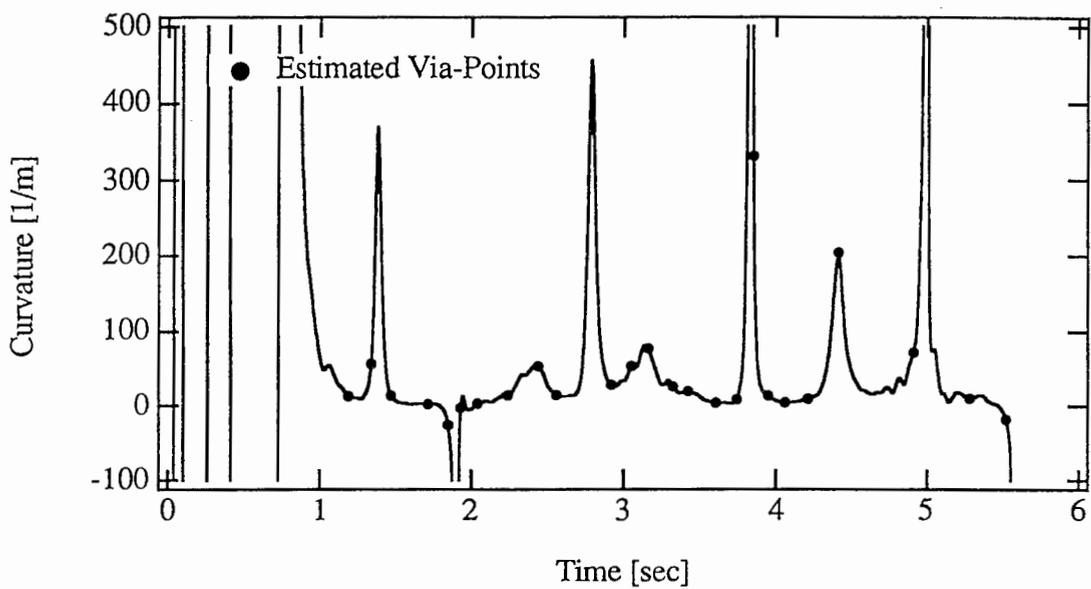


図 3.13 書字運動における曲率と推定された経由点の位置
 Fig 3.13 Estimated via-point positions in curvature curve
 in a cursive handwriting.

なお、使用したパラメータの値は、図 3.8～図 3.10 と同様である。

3.4.3 音声データによる経路点推定モデルの検証

3.4.1, 3.4.2節で我々の提案した経路点推定モデルが腕の運動における経路点を推定できること、また、速度や曲率といった指標から推定される点ではないことを明らかにした。ここでは、我々のモデルが単に腕の運動だけでなく、顎や舌といった調音器官の運動にも適用が可能であることを示し、このモデルが与えられた軌道の特徴量（経路点）を推定する一般的なモデルであることを示す。このことはこのモデルは音声→調音器官軌道→音声の変換のための適当な生成モデル（平山ら、1992）があればデータの圧縮技術としても使えることを示しており、その利用価値は音声データの場合は特に顕著であると期待される。図3.14に示した実線は調音器官の運動における位置の時系列データである。黒丸は経路点推定モデルによって推定された経路点である。破線は推定された経路点と生成モデルを使って再生した軌道である。ただし、この場合は、生成モデルには運動のダイナミクスを使わない作業座標での躍度最小モデルを使っており、経路点の推定も作業座標平面で行っている。表3.1に推定された経路点をサンプル点と考えたときの平均サンプルピッチを示す。かなり大きなサンプルピッチでも元の軌道を再現できていることがわかる。

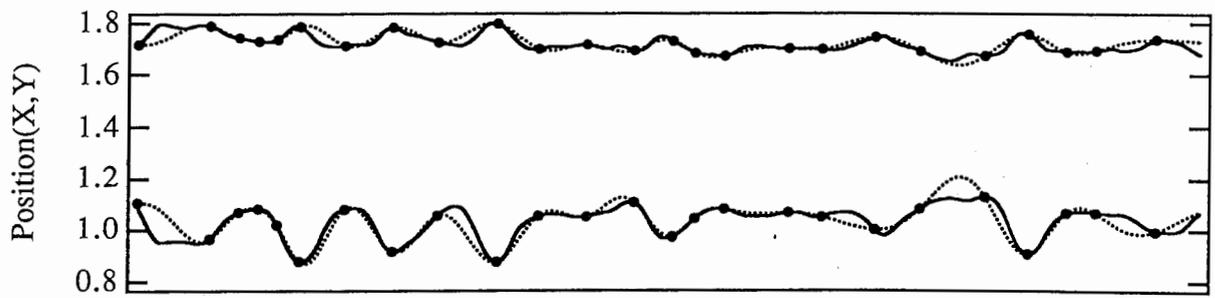
実際に推定された点が、調音器官の運動を何らかの意味で代表する点であるかどうかについては、第4章で議論する。ここでは、軌道生成モデルを特定することによって、我々の提案している経路点推定モデルが、調音器官の運動に対しても与えられた軌道を再構成するために必要な点を抽出することができ、かつ、再構成された軌道は、元々の軌道を良く再現していることを強調しておく。

表3.1 各調音器官の平均サンプルピッチ

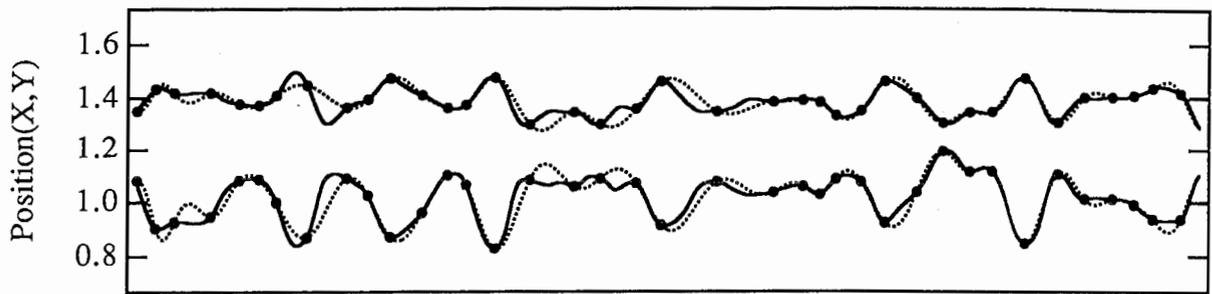
Table 3.1 Average of sample pitch for each articulator.

Articulator	Average of sample pitch
Jaw	178 msec
Lower lip	110 msec
Tongue tip	170 msec
Tongue blade	91 msec

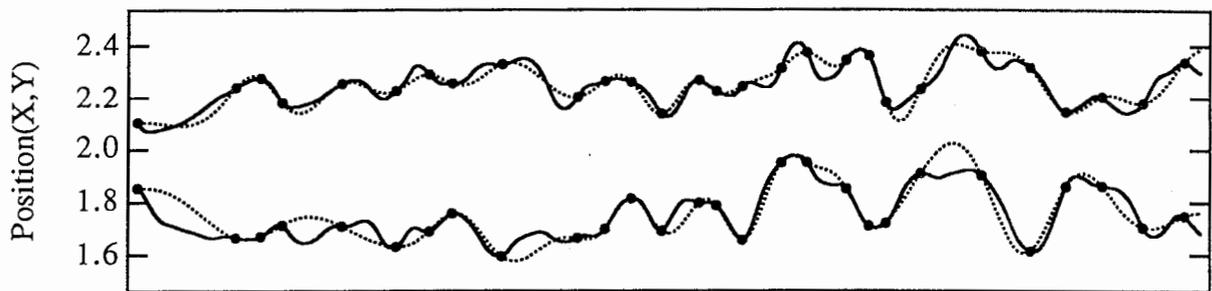
経路点を推定するために使った誤差の閾値は各調音器官共に0.03 である。



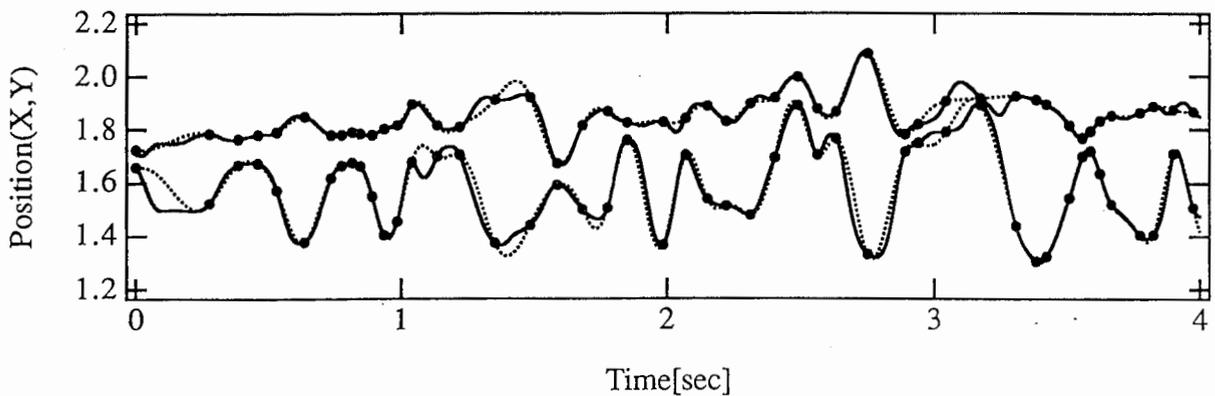
(a) Jaw.



(b) Lower lip.



(c) Tongue blade.



(d) Tongue tip.

図 3.14 音声データにおける経路点の推定結果

Fig 3.14 A result of via-point estimation for articulator motion.

3.5 文字の生成実験結果

次に推定した経路点を軌道生成モデルに入力して文字を生成した結果を示す。図 3.15, 16 に計測された軌道と速度および推定された経路点を使って軌道を生成し直したときの軌道と速度を示す。比較してわかる様に計測データと生成された軌道はほとんど同じであり、かつ速度プロフィールも非常に良く再現されている。

また、この書字運動モデルは与えられた経路点を正確に通過しない運動、いわゆる”なまけた”運動も生成することが可能であり、その結果を図 3.17 に示す。これは、図 2.5 の Step4 において経路点での拘束条件を完全には満たさないようにして生成した軌道であり、図 3.17 左側は経路点に到達しないようにした例であり、右側は経路点を行き過ぎるようにして生成した結果である。

なお、使用したパラメータの値は、図 3.8 ~ 図 3.10 と同様である。

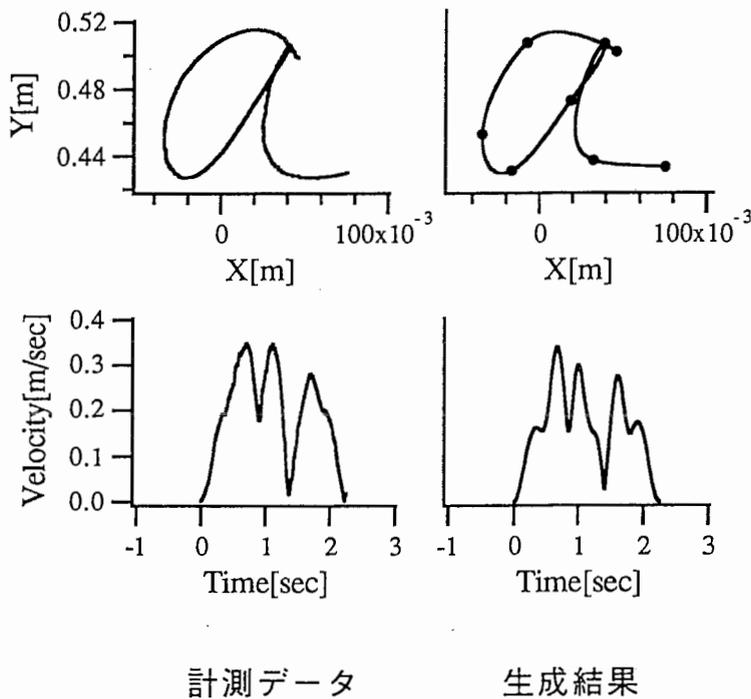


図 3.15 1 文字の生成結果

Fig 3.15 Character(a) generated by a cursive handwriting model.

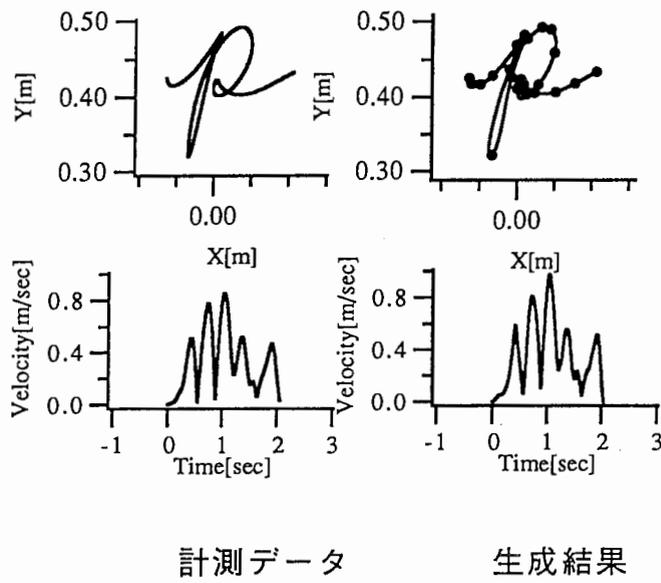


図 3.16 1文字の生成結果

Fig 3.16 Character(p) generated by a cursive handwriting model.

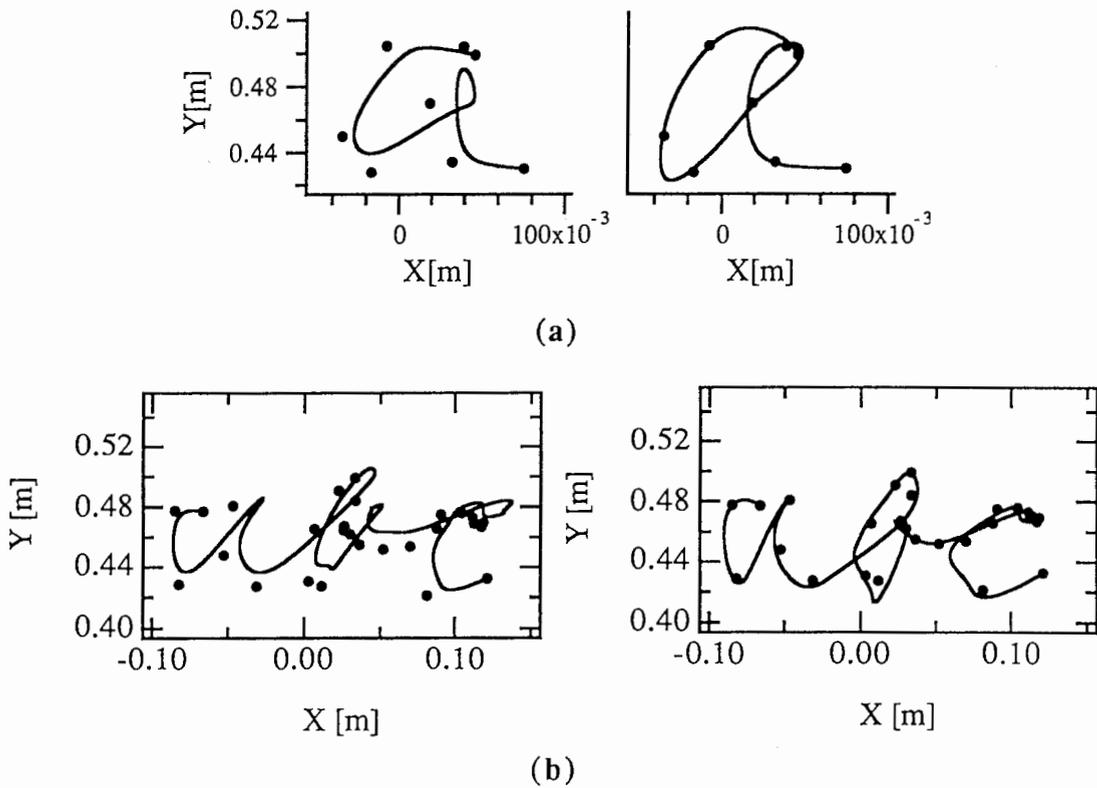


図 3.17 経由点を正確には通過しない書字運動

Fig 3.17 Handwriting motion that does not exactly pass through via-point targets.

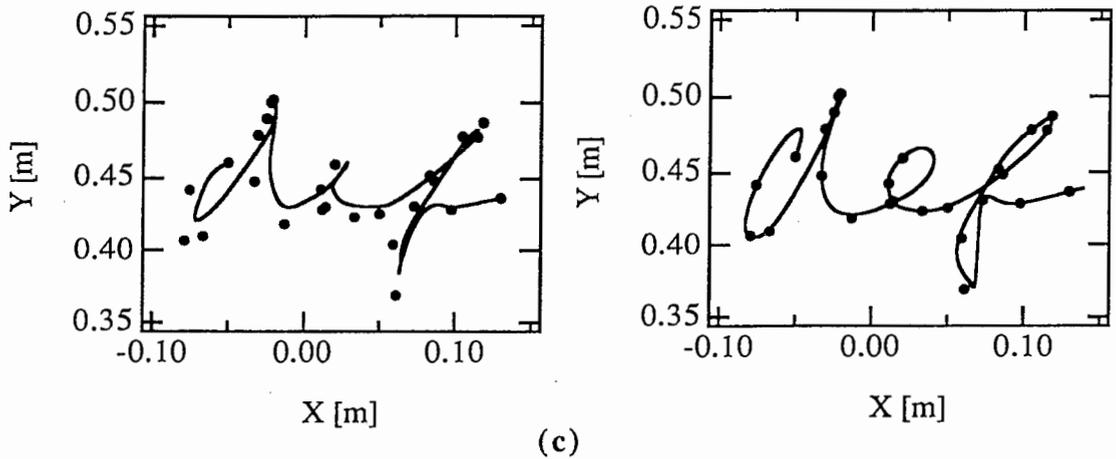


図 3.17 経路点を正確には通過しない書字運動

Fig 3.17 Handwriting motion that does not exactly pass through via-point targets.

3.6 書字運動モデルの考察

ここで提案した書字運動のモデルは、脳のモデルとして考えたとき2つの意味がある。1つは表現の問題であり、人が文字を書くときシンボルをどのようなパラメータに変換・表現するかである。このモデルでは、単純な表現：経路点を持つだけで書字運動が行えることを示している。これは目標点に手を延ばすような運動でのパラメータの表現の延長上にあるという意味で自然で合理的である。第2は運動計画の原理である。この書字運動モデルにおける計画の原理は、トルク変化最小規範である。この規範は、多関節腕の運動計画の原理として提案され、簡単な到達運動において、この規範が人間の運動をよく再現・予測することが知られている。書字運動モデルでは、経路点として表現された情報を、この規範によって到達運動のときと同様に最適化問題の拘束条件として運動計画を行っているに過ぎない。つまり、このモデルは運動を規定するパラメータの表現と運動の計画原理の2つの点において、腕の到達運動と全く同じに書字運動が実現できることを示唆している。この点は、最小化原理に基づいたEdelman & Flash (1987) の書字運動モデルと基本的に異なる。彼らのモデルでは、文字は stroke のつながりとして表現され、計画の原理は、

躍度最小基準からsnap（躍度の微分）最小基準へと複雑化されている。

我々の提案したモデルの当否は、文字と経路点をいかに対応させるかにかかっている。本論文では、同じ最小化規範に基づいた経路点推定モデルによって、言わば文字の学習過程ともみなせる計算によって文字から経路点への変換が可能なことを理論と実験によって示した。シンボルとパラメータの対応は当然Edelman & Flash（1987）のモデルにおいても実現されなければならない問題であり、彼らが経路点の選択で指摘した、経路点選択の合理的理由は、シンプルでロバストなパラメータ表現の実現のためにはどのようなモデルにおいても明示されなければならない。この点においても、我々のモデルは合理的な選択基準によって経路点を選択し、それによって文字が再現されることを示している。また、工学的にも、次の3点において提案したモデルの意義は大きいと考えられる。連続文字の認識において、経路点推定モデルによって推定される経路点は、文字の区切りの候補を抽出しており、連続文字認識において困難とされる文字の区切りの曖昧さを軽減する期待がある。第2に、推定された経路点は、文字を再構成するという意味で、非常によい文字の特徴量であり、書字運動モデルと合わせて手書き連続文字認識への展開が可能である。簡単な文字認識モデルによって手書き連続文字の認識を単語辞書を用いずに実現できることを第4章において示す。第3に経路点抽出モデルは、調音器官のデータに対してもよく特徴点を選択しており、音声データの圧縮技術としての期待がある。この点に関しても、第4章において議論する。

3.7 おわりに

本章において、我々は文字を多経路点の運動軌道と捉えて、既に提案しているダイナミクスモデルを使った腕の最適軌道を生成する神経回路網を拡張して最小化原理に基づいた文字の生成と、その経路点を推定するモデルを提案し、数値実験によって人間の書字運動の計測データと良く一致する結果を得た。我々の提案した書字運動モデルには、経路点時間の最適化は考慮されておらず、推定された経路点の時間を用いている。この時間の最適化をはかることは、今後の課題の1つである。

第 4 章

最小化原理を応用した運動パターン認識

----- 連続文字の認識と音韻時刻の推定

4.1 はじめに

手書き連続文字の認識の問題には、2つの基本的な困難がある。第1は、文字の形の多様性であり、第2は、連続文字の区切りの曖昧さである。（図4.1参照）第1の困難は、文字の形が多種多様であっても、比較的安定不変な、より縮約された情報、つまり、適切な文字の特徴を抽出することで解決すべきであろう。第2の困難は、統一的な原理に基づいて小数個の適切な区切り点候補を抽出することで大幅に軽減できる。

我々は既に運動軌道の経由点を推定する経由点推定モデルを第3章で述べた。このモデルは、運動制御の計算論的研究で得られた運動軌道生成モデルを特定することによって、元の軌道を再構成するのに必要な経由点を抽出するモデルである。これによって連続文字認識の2つの困難が軽減できる可能性がある。なぜなら経由点推定モデルは、ある軌道生成モデルによって元の文字軌道を再現するのに必要な情報を抽出しており、しかも、情報圧縮比は非常に大きいので、経由点の空間的・時間的配置の情報は、望ましい一定不変の表現により近づいた文字の特徴であると期待される。また、すでに連続文字の場合、経由点推定モデルが文字と文字の区切りに経由点を推定することを実験的に確認している。人が続け文字を書くとき文字と文字の間に経由点を置くとすれば、我々の提案した経由点推定モデルは文字の区切り点に経由点を抽出することが期待できる。通常、推定される経由点の数はデータ点の数に比べれば非常に少ない数であり、推定された経由点を区切り点の候補とすることで、文字の区切りの曖昧さに関する処理を大幅に軽減できる可能性がある。

本章では、経由点推定モデルの利点に着目した手書き連続文字認識システムを提案する。実際のデータについて、ユークリッド距離を評価関数としたテンプレート照合によって連続文字認識が可能であることを示す。

また、提案した経由点推定モデルは、時系列データの特徴を抽出するモデルであり、腕の運動のみならず調音器官の運動にも適用が可能である。推定された経由点の時刻が音韻が発話される時刻とよく対応し、推定した経由点を使って再構成された調音器官の運動軌道が、元の軌道とよく一致することを実験データから示す。

945 990 255 599 999 999 999 999
 999 999 999 999 999 999 999 999
 999 999 999 999 999 999 999 999
 999 999 999 999 999 999 999 999
 999 999 999 999 999 999 999 999
 999 999 999 999 999 999 999 999
 999 999 999 999 999 999 999 999

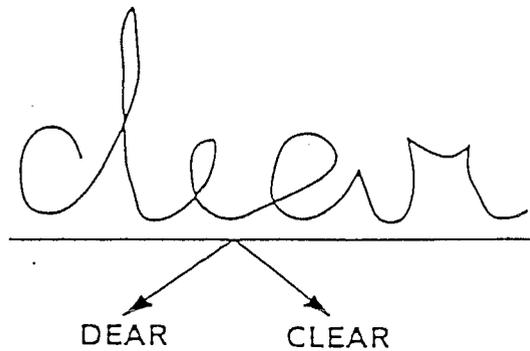


図 4.1 文字の多様性と区切りの曖昧さ

Fig 4.1 Character shape variability and segmentation ambiguity.

(Edelman et al.(1990)より)

4.2 従来の研究

パターン認識の研究は古くから行われており、理論的な解析も行われている（飯島, 1963; 大津, 1981）。オンラインの手書き文字認識においても非常に多くの研究（Tappert, Suen & Wakahara, 1990）が行われているし、神経回路網を応用した文字認識システムも最近活発に研究が行われており、数字の認識システムとしてHinton, Williams & Revow (1992), Le Cun, et al. (1989) などのシステムが提案されている。また、続け文字の認識に関しても Fukusima & Imagawa (1993) や、文字切り出しに関する長石 (1993) などの研究がある。また、漢字の認識システムには森 (1990) などがある。

ここでは、以下の節で述べる我々のアプローチと関連の深い研究について概括する。ここで概括する文字認識のアプローチは、第3章2節で述べた書字運動モデルに基づいた認識のアプローチをとっているものである。

Hollerbach (1981) の書字運動のモデルに基づいた認識モデルとして、Hoffman, Skrzypek & Vidal (1993) や、Rumelhart (1993) などがある。これらのモデルは、基本的にHollerbach (1981) の理論で指摘されている、文字を構成するのに重要な点、つまり鉛直方向の速度のゼロ交差点を文字の特徴点とするシステムである。実際にはゼロ交差点以外の点も文字の特徴点としたシステムである。Hoffman, Skrzypek & Vidal (1993) のシステムは、1文字の認識システムであり、複数の神経回路網によって認識された結果を統合して最終的な認識結果を出力するものである。一方、Rumelhart (1993) のモデルは、続け文字の認識システムであり、TDNN型の神経回路網（Waibel et al., 1989; Lang et al., 1990; Keeler, Rumelhart, Loew, 1991）を応用したシステムである。

Morasso & Mussa Ivaldi (1982) に対応するシステムとしては、Morasso (1989), Morasso, Pareto & Pagliano (1992) のモデルがある。これは、Morassoらの書字運動のモデルと自己組織化を組み合わせたモデルである。基本的には文字をストロークに分割するところに彼らの書字運動のモデルが応用されている。ストローク分割は、具体的には速度の極小点あるいは曲率の極大点において分割される。

最後に、Edelman & Flash (1987) に対応する研究としては、Edelman, Ullman & Flash (1990) の認識モデルがある。このモデルでは、Edelman & Flash (1987) の書字運動に基づいた区切りとなる点を軌道から経験的に抽出し、その点を言わば特徴

点として文字の認識を行うものである。つまり、第3章の図3.1に示した4つの基本ストロークをプロトタイプとしてもち、与えられた文字をこのプロトタイプに分類し、その結果から文字を認識するシステムである。

これらのモデルは、書字運動のモデルでの成果を使った文字認識モデルであり、パターンの認識にパターンの生成が重要であることを示唆したモデルである。しかしながら、これらのモデルも、生成のモデルにおける言わば知識を認識のモデルに間接的に応用したに過ぎない。我々は、第2章、第3章で述べた生成モデルを認識モデルに積極的に取り込んだ連続文字の認識システムを提案する。

4.3 書字運動モデルによる連続文字の認識

本節では経路点推定モデルと書字運動モデルを使ったオンラインの連続文字認識について述べる。

4.3.1 文字認識における書字運動モデルの必要性

人間が文字を認識するときどのような情報を使って、パターン認識を行っているのだろうか。Kawato (1989), Kelso & Pandya (1989), Haken, Kelso, Fuchs & Pandya (1990) らは、パターンを生成することと認識することが何らかの意味で双対の関係にあると指摘している。つまり、認識の観点から考えると、パターン認識のプロセスはパターンを生成するプロセスに大きく関係していると言う指摘である。

実際に認識の機構に生成の機構が深く関わっていると言う心理学における研究成果がある。Babcock & Freyd (1988) は、手書きの文字を認識するときに、文字を生成するプロセスに関する情報が捉えられ、認識に利用されることを実験によって示した。彼女らの実験においては、実際の文字とは無関係の仮想の文字を作り、その文字を生成するストロークの順番を指定して、被験者に書かせる。ただし、最後のストロークに関しては、書く方向を、上からと下からの2種類を生成させ、実際に文字を書いた被験者とは異なるグループの被験者にその文字を提示して、書き手と同じ方向に最後のストロークを書くことを、この被験者グループに要求する。結果は、提示した文字のストローク方向と再生された文字のストローク方向に強い相関があった。このことは、認識プロセスにおいて生成の知識が使われていることを示

唆していると言える。特に Freyd (1983) は、手書き文字の認識に関して次の2点を指摘している。(1) 人は書字動作の知識を、認識のプロセスで利用可能な形式で持っている。(2) 人は文字が生成された順番やそのストロークの方向に対して敏感である。また、もっと広く人間が認識するときにはダイナミックな情報を利用していると言及している (Freyd, 1992)。

また、Corrieu & De Falco (1989) も幼稚園児に対する実験で文字の認識に生成の知識が利用されていることを示している。彼らは幼稚園児に文字を教えるのに、大きく分けて、単に視覚的に提示する方法と、提示した文字を構成する方法も含めて教える方法を行い、その後文字を提示して、その認識率を調べた。結果は、後者の方法の方が高い認識率を示した。これも文字の認識に生成の情報が使われていることを示唆しているといえる。

文字のパターン認識だけでなく、音声に関しての指摘もある。Liberman & Mattingly (1985) は心理学的モデル”音声知覚の運動説”を提案している。このモデルも音声の認識に生成機構が関連しているとした説である。この説では音声認識において、音響信号の特徴ではなく、この音響信号を実現した調音器官(顎, 唇, 舌など)の運動(つまり音声の生成プロセス)が手がかりになっていると主張している。

つまり、上の3つの研究では、文字や音声の認識に運動(書字運動・調音器官の運動)パターンの生成が重要な役割を果たしていることが示唆されている。

4.3.2 文字認識における書字運動モデルの役割

”パターン認識の基本的な考え方は、入力パターンと標準パターンとの距離を測り、近ければ近いほど入力パターンは標準パターンと確実に同じものであると判断することである。そのためにパターンから取り出した特徴の組から成る特徴空間を考えて、そこに距離の概念を導入する。(長尾, 1983)”つまり、どのような特徴・距離を考えるかがパターン認識の重要な問題となり、特に特徴空間をいかに定義するかがかぎとなる。

前章で提案した経路点抽出の方法の基本思想は、与えられた軌道を再構成するのに必要な特徴を抽出することである。しかも経路点の抽出は、簡単なパラメータ(誤差の閾値)でコントロールすることができ情報の損失を極力押さえることが可

能である。逆に言うと、元の軌道を再現する観点からの情報損失を最小化する特徴の抽出モデルは、人間の書字動作を再現することが可能なモデルが同定された結果によって構成されたモデルであり、パターン認識の基本である特徴の抽出に、書字運動モデルが重要な役割を果たしている。また、次節で提案する経路点推定モデルを基本とした文字認識のシステムは、認識プロセスに生成のプロセスが大きく影響を与えているシステムであり、この意味において、前述した心理学のモデルとも合致した認識モデルを構成していると考えられる。

4.3.3 文字認識システム

以上の考察に基づいて、テンプレートマッチングによる簡単な文字認識のシステムを構成した。全体の文字認識システムは、図4.2のようであり、入力された続け

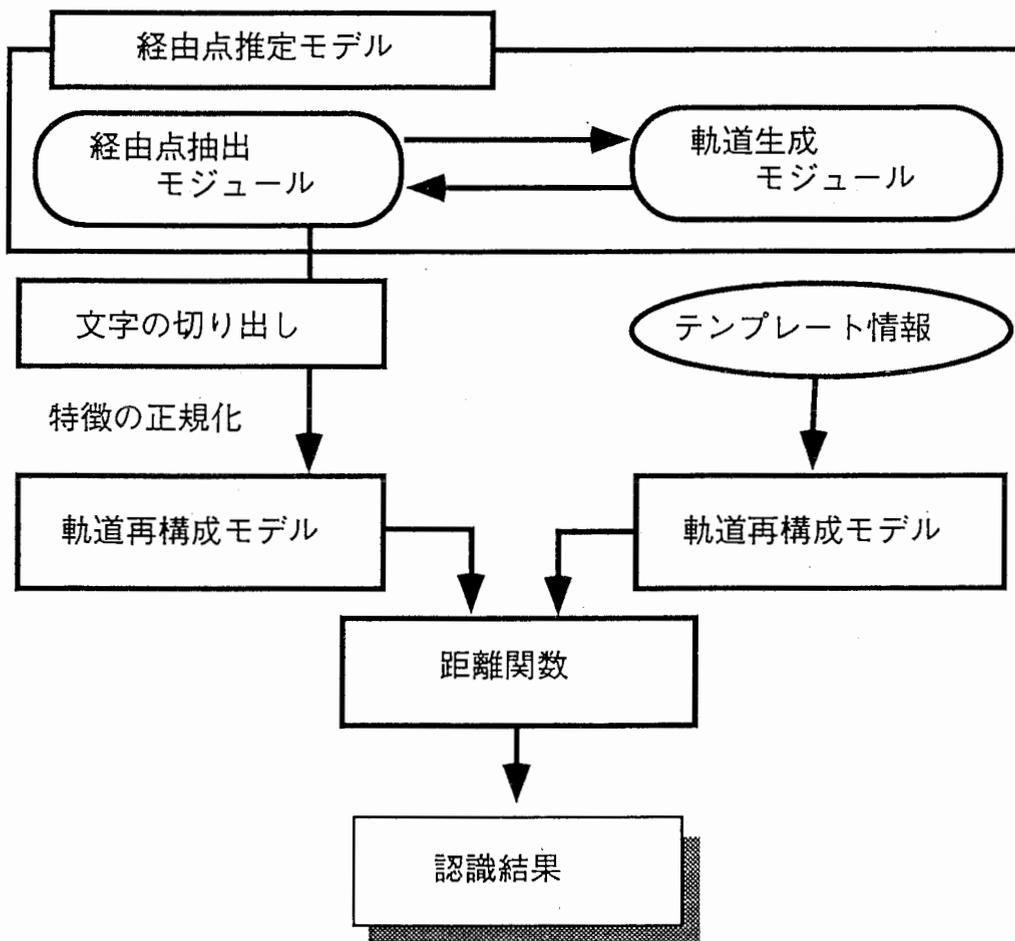


図4.2 連続文字の認識システム

Fig 4.2 Recognition system for cursive handwriting.

文字は、経路点推定モデルによって、その特徴が抽出される。ここでの特徴は、運動の経路点のX、Y座標と通過時間によって表されるものである。次に抽出された特徴は、時間とX-Y座標系において正規化される。テンプレート情報には、各文字を構成するために必要な経路点情報が、やはり時間とX-Y座標系に対して正規化されて記憶される。従って、入力された軌道の特徴とテンプレートの特徴は正規化された情報であり、ある種の距離によってパターン認識が可能となるが、経路点推定モデルでは陽に特徴の個数をコントロールしておらず、テンプレートの特徴との対応を取ることが難しい。故に、再度、特徴を軌道再構成モデルに入力し軌道生成を行い、テンプレートの情報によって生成された軌道と与えられた軌道から抽出された特徴によって生成された軌道のユークリッド距離によってパターン認識を行う方法を試みた。以下に文字認識システムについて（1）特徴と文字の区切り点、（2）正規化、（3）軌道再構成モデル、（4）距離関数および（5）文字の切り出し方法について述べる。

（1）特徴と文字の区切り点

アルファベットの筆記体のように続けて書かれた文字の認識における困難の1つは、文字の切り出しの難しさであることが指摘されている。これは文字の多様性の困難さと結びついている。つまり、区切り点を間違えることによって違う文字、違う単語を認識してしまう。この意味において、区切りの候補とする点は十分な数でなければならないし、効率から言えば必要最小が望ましい。ここで提案する文字認識システムでの区切りの候補点は、続け文字を経路点推定モデルに入力して、推定された経路点であり、1文字も続け文字も同様に扱われる。つまり、推定された経路点は、続け文字を再構成するのに必要十分の点が抽出されていることになる。

前述したように、Morasso, Pareto & Pagliano (1992) は、文字をストローク毎に分けるためにペン速度の極小となる点（曲率極大点に相当）をストロークの切れ目とする方法によって区切り点を同定しているが、我々の提案している経路点推定モデルでは、彼らが同定している速度の極小点あるいは曲率の極大点と、それら極大・極小とは無関係の2つに大別される経路点群を推定している。実際に区切り点が速度最小とならない場合がある。しかも、提案している書字運動モデルでは、速度の極小点あるいは曲率の極大点に相当する点だけでは、文字を再構成しないことを確認している。つまり、ここで提案するような書字運動モデルに基づいた文字認識シ

システムでは、単に速度の極小点あるいは曲率の極大点では、文字認識が達成されない。

また、Edelman, Ullman & Flash (1990) は、彼らの書字運動モデルに基づいた区切り点（コントロールポイント）を軌道から抽出している。しかしながら、彼らのコントロールポイントの抽出方法は、書字動作の解析結果から得られた言わば経験的な方法であり、コントロールポイントの抽出に陽に書字運動モデルを使ってはいない。この点が我々の提案する続け文字の認識システムと大きく異なる点である。

Rumelhart (1993) , Hoffman et al., (1993) は、Hollerbach (1981) のOscillation理論に基づいた文字認識システムを提案しているが、彼らが使っている特徴点は、基本的には鉛直方向の速度のゼロ交差点と、ゼロ交差点の間の点を神経回路網への入力としている。これは、図4.3に示すように我々の提案している経路点推定モデルによって抽出される点とほぼ対応する点である。しかもHollerbachのOscillation理論による書字運動のモデルでは、ゼロ交差点の間の点を特徴点とすることは必ずしも自明ではない。これに対して、経路点推定モデルの抽出する特徴点は、第3章で述べたように理論的背景のあるモデルであり、抽出された点は与えられた文字を再構成する観点において意味があり、かつ必要十分な数の特徴点である。図4.3には運動時間におけるX座標の位置、Y座標の位置を示した。よって、鉛直方向の速度のゼロ交差点は、Y座標の位置の極値に相当する点であり、図からわかるように、我々の提案した経路点推定モデルが、このゼロ交差点に対応する点を抽出していることがわかる。しかも、経路点推定モデルでは、Rumelhart (1993) , Hoffman et al., (1993) が入力として使っているようなゼロ交差点の間の点に相当する点も推定していることがわかる。

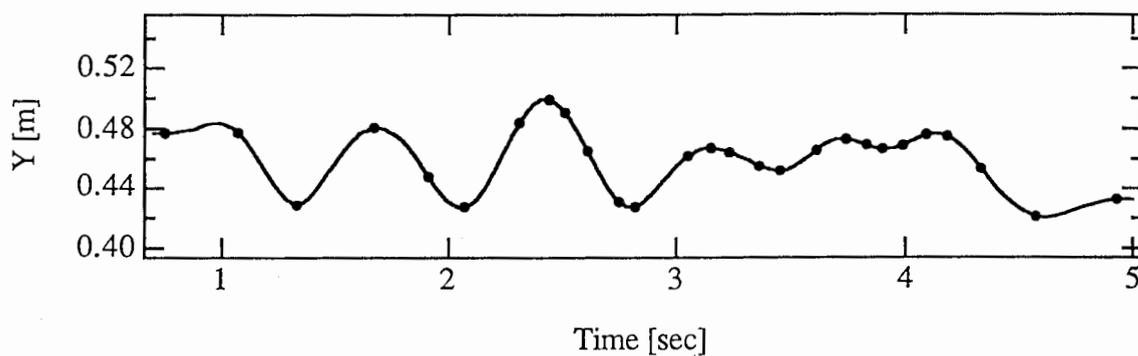
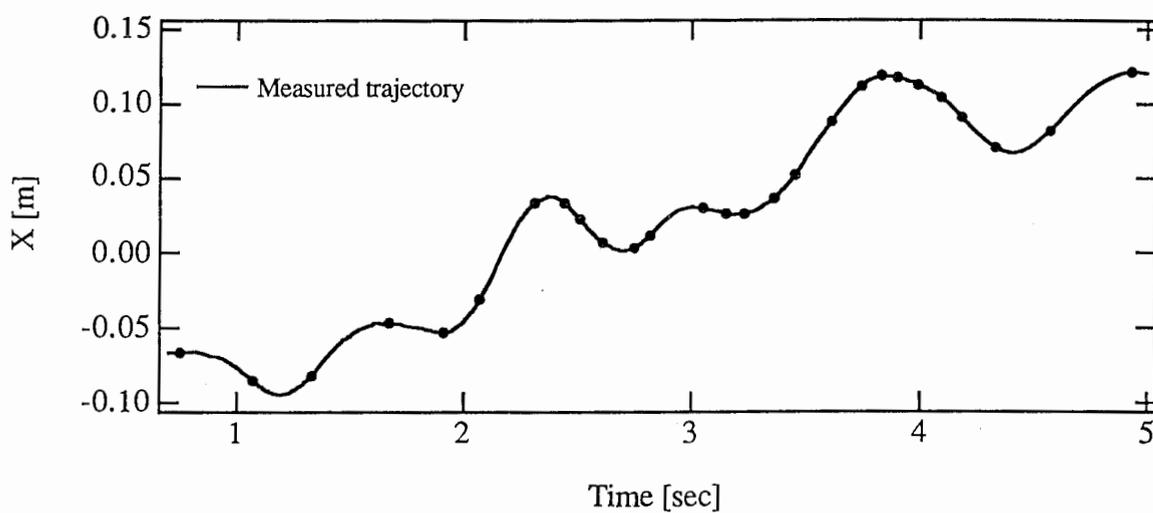
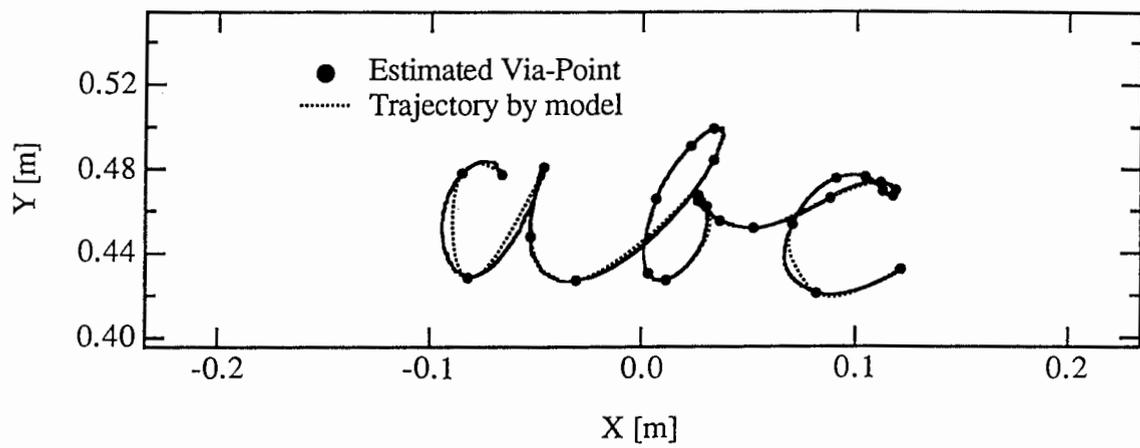
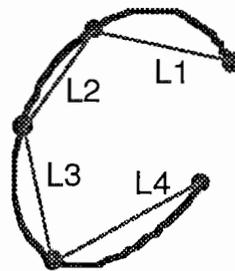


図 4.3 抽出される特徴点
 Fig 4.3 Extracted feature points.

(2) 正規化

パターン認識においては、得られた特徴を正規化して、標準パターンと比較する必要がある。パターンの正規化は、パターン認識において特徴抽出と同様に重要であり理論的検討も行われている（飯島，1962；甘利，1966）。ここでは、文字の大きさと運動時間だけの正規化だけを考える。ここで扱う特徴である経由点の情報には3つの要素がある。それは作業座標 (X,Y)と経由点の通過時間である。作業座標 (X,Y)の正規化は、文字の大きさの正規化をとる意味で、経由点間の距離の総和で正規化を行う。



● Estimated Via-Points

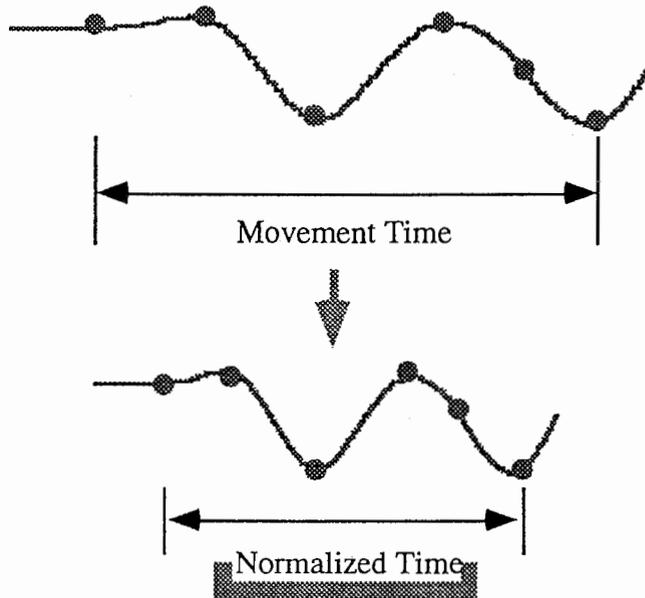


図 4.4 文字の正規化

Fig 4.4 Normalization of a character.

$$\tilde{X}_{via}^i = \tilde{X}_{via}^{i-1} + \frac{X_{via}^i - X_{via}^{i-1}}{\sum_{i=1}^N \sqrt{(X_{via}^i - X_{via}^{i-1})^2 + (Y_{via}^i - Y_{via}^{i-1})^2}} \quad (3.1)$$

$$\tilde{Y}_{via}^i = \tilde{Y}_{via}^{i-1} + \frac{Y_{via}^i - Y_{via}^{i-1}}{\sum_{i=1}^N \sqrt{(X_{via}^i - X_{via}^{i-1})^2 + (Y_{via}^i - Y_{via}^{i-1})^2}} \quad (3.2)$$

ただし、経路点の数は(N - 1)個で、 (X_{via}^i, Y_{via}^i) は与えられた軌道での経路点の座標を表し、 $(\tilde{X}_{via}^i, \tilde{Y}_{via}^i)$ は正規化された経路点の座標である。i = 0が始点を、i = Nが終点を表す。 $(\tilde{X}_{via}^0, \tilde{Y}_{via}^0) = (0, 0)$ とする。

また、経路点の時間については次のように正規化する。

$$\tilde{T}_{via}^i = \frac{T_{via}^i - T_{via}^0}{T_{via}^N - T_{via}^0} \quad (3.3)$$

ただし、 T_{via}^i は、元々の運動での経路点時間で、 \tilde{T}_{via}^i ($0 \leq \tilde{T}_{via}^i \leq 1$)は正規化された時間である。

(3) 軌道再構成モデル

ここで図4.2の文字認識システムで使う軌道再構成モデルについて説明する。認識システムにおいては、一般に特徴軸は上で述べたように何らかの正規化を必要とする。文字認識のようなパターン認識においては、正規化は与えられた文字の拡大・縮小に相当する。しかも正規化の操作によって特徴情報の損失があってはいけない。この意味において、軌道生成モデルは情報損失なく元の軌道を拡大・縮小できなければならないが、トルク変化最小規範に基づいた軌道生成モデルのようにダイナミクスに依存したモデルであると、少なくとも時間に対しては拡大・縮小は困難である。よって、ここではこのような要求を満足し、かつトルク変化最小規範に基づいた軌道生成モデルの近似モデルとなるような軌道再構成モデルを考える。このようなモデルとしては第2章で述べた躍度最小化規範が考えられる。このモデルは、身体の前でかつ小さな運動であればトルク変化最小規範モデルの近似モデルと考えられる。よって、ここでは経路点から軌道を再構成する軌道再構成モデルとして躍度最小規範を選ぶ。

(4) 距離関数 (テンプレートとの照合)

距離関数は、テンプレートと入力された文字との距離を演算するものであり、正規化された特徴点情報を使って軌道再構成モデルによって生成された軌道に対する各正規化時間の座標軸毎のユークリッド2乗距離の和である。

$$D = \int_0^{t_{normal}} \left\{ (\tilde{X}(t) - \tilde{X}_T(t))^2 + (\tilde{Y}(t) - \tilde{Y}_T(t))^2 \right\} dt \quad (3.4)$$

ただし、 t_{normal} ($=1$) は正規化された運動時間であり、 $(\tilde{X}_T(t), \tilde{Y}_T(t))$ はテンプレートの正規化された特徴によって再構成された軌道であり、 $(\tilde{X}(t), \tilde{Y}(t))$ は入力された軌道の正規化した特徴によって再構成された軌道である。

ここで提案した距離関数は、式(3.4)で示したように、入力された軌道とテンプレートの軌道の正規化された特徴を使って再構成した軌道どうしの比較であり、抽出した特徴自身の距離関数を使っていない。これは、経路点推定モデルによって推定される特徴はすべて、(X軸, Y軸, 時間軸)の組として抽出され、しかも各軌道毎の特徴の数は定まっておらず、特徴間での対応をとることが難しいことが第1の理由である。故に、特徴を損失することのない再構成された軌道に関する距離関数(3.4)によってテンプレートとの距離を定義している。逆に言うと、軌道の再構成モデルを使うことによって、上で述べた特徴の対応付けと言った問題を回避していると言える。

(5) 文字の切り出し方法

入力された軌道とテンプレートとを照合するための文字の切り出し方法について述べる。入力された軌道の経路点(特徴)を区切り候補点として処理する。テンプレートとの照合は、基本的に区切り点(特徴点) $V1$ から区切り点 $V2$ までを切り出して、 $V1$ を始点、 $V2$ を終点として、 $V1$ と $V2$ の間に含まれる特徴点によって再構成された軌道と、テンプレートの特徴点によって再構成された軌道とを比較することによって行われる。文字の切り出し、照合の方法は、以下のようなものである。与えられた軌道の特徴は、始点側から番号が付けられているものとする。

Step 0: $V1 = S$, $i = -N_i$, $j = 0$ とする。ただし、 S は特徴点を示す番号であり、文字の切り出し処理の最初は $S = 0$ (始点) とする。 N_i は文字の始点の位置を S の前後に振るためのパラメータである。

Step 1: 特徴 $V1+i$ から特徴 $V1+i+N_c+j$ までを切り出し、特徴を正規化し、軌道の再構

成を行い、テンプレートとの照合を行う。ただし、 N_c は1文字に含まれる特徴の数の最小の値を示し、適当な値を設定する。 V_{l+i} が負の時は0とする。

Step 2: $j=j+1$ として j が N_j になるまでStep 1を繰り返す。 N_c+N_j で1文字に含まれる特徴の数の最大の値を示し、 N_j に適当な値を設定する。

Step 3: $i=i+1$, $j=0$ として Step 1, Step 2を i が N_i になるまで繰り返す。

Step 4: Step 1~Step 3でのテンプレートとの照合結果において、距離関数の値の小さなものから m 個を文字の候補とする。

Step 5: 次に各 m 個の文字の終点となる特徴の番号を S として、上記各Stepを繰り返す。残りの特徴点の数が N_c 以下になるまで処理を続ける。

例えば、 $m=3$ として3文字が切り出されたとすると、3文字の単語の候補は27 (= $3 \times 3 \times 3$) 候補となる。この各候補に含まれている文字毎の距離関数の和を各候補の距離関数の値とし、その値の最も小さな候補を認識された単語とする。

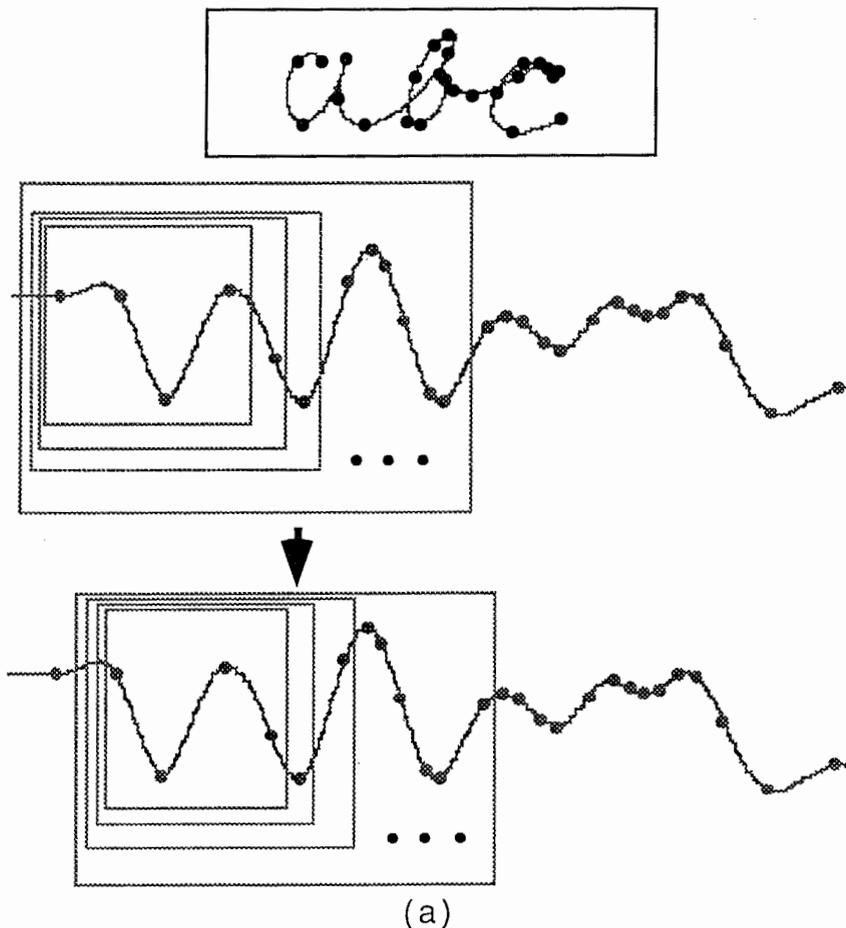
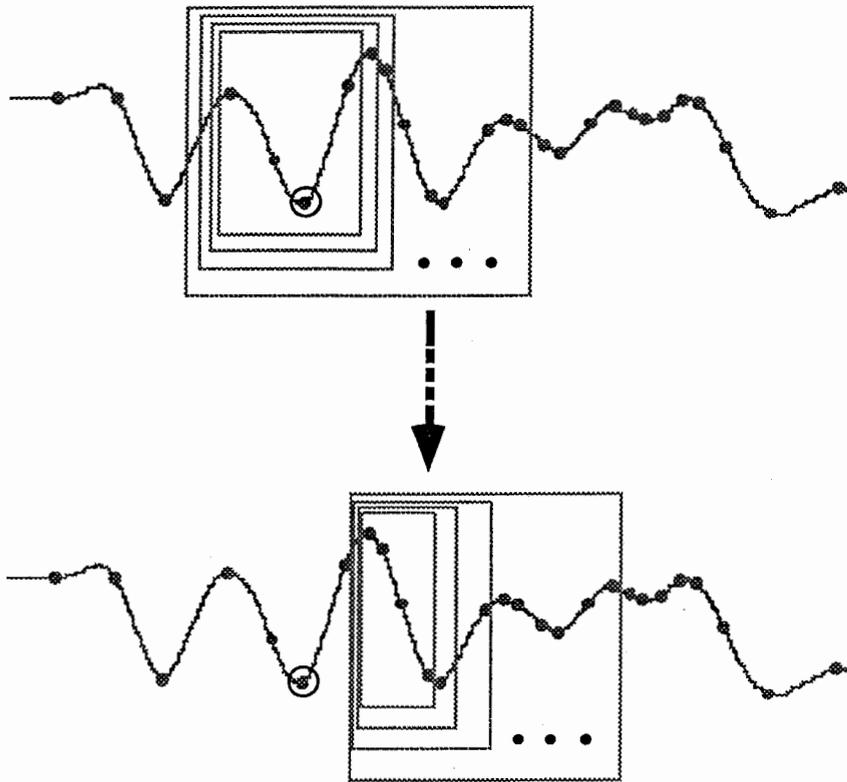


図 4.5 文字の切り出し方法

Fig 4.5 Segmentation method



(b)

図 4.5 文字の切り出し方法

Fig 4.5 Segmentation method

(a) 上図：最初の経由点から4個の経由点を最初の文字の切り出しとし、次に1つずつ経由点を増やし、四角のウィンドウで囲ったなかの経由点を各々文字の切り出しとしている。最終的には12個の経由点を最大ウィンドウとしている。

(a) 下図：始点となる経由点を1つ移動して、後の処理は同様に行う。

(b) 上図：○を前の文字の切り出し点として、それより2個前の経由点を始点として切り出し処理を行っている。

(b) 下図：始点を順番に1個ずつ動かして、○印のある経由点より2個後に動かして、切り出し処理を行う。

なお、ここで使った切り出しのための定数は実際に用いた値とは異なる。

4.3.4 文字認識結果

本節では文字認識結果について示す。図4.6にテンプレートの一部とした計測データと抽出された特徴の例を示す。●印が抽出された特徴を示す。図4.7に躍度最小モデルで再構成されたテンプレートの軌道を示す。図4.6の計測データとほぼ同じ軌道が再構成されており、躍度最小モデルによって正規化された軌道がテンプレートとして利用可能であることがわかる。今回の実験では、i,j,t,xといったペンの垂直方向の移動の必要な文字は除外している。

続け文字の認識結果を図4.8に示す。このとき使ったテンプレートは図4.7に示した36軌道である。図4.8の右側が左側の文字列を認識した結果であり、数字はそのときの距離関数の値で、括弧の中の数字は各文字の最初の経由点と最終の経由点の番号を表す。図には各々距離関数の値の小さなものから3つの候補を示した。3つの単語とも正しい認識結果を示していることがわかるが、goodに関しては、3番目の候補にgooaと誤認識している。この例のように'a'と'd'あるいは'c'のように文字の一部が同じような形であったり、'e'と'l'のように大きさだけが異なるような文字は認識することが比較的難しい。

本報告では、我々の提案した書字運動モデルを応用した比較的簡単な文字認識システムによって、連続文字の認識が可能であることを示したが、'e'と'l'に表されるような正規化の問題など幾つか今後の課題がある。

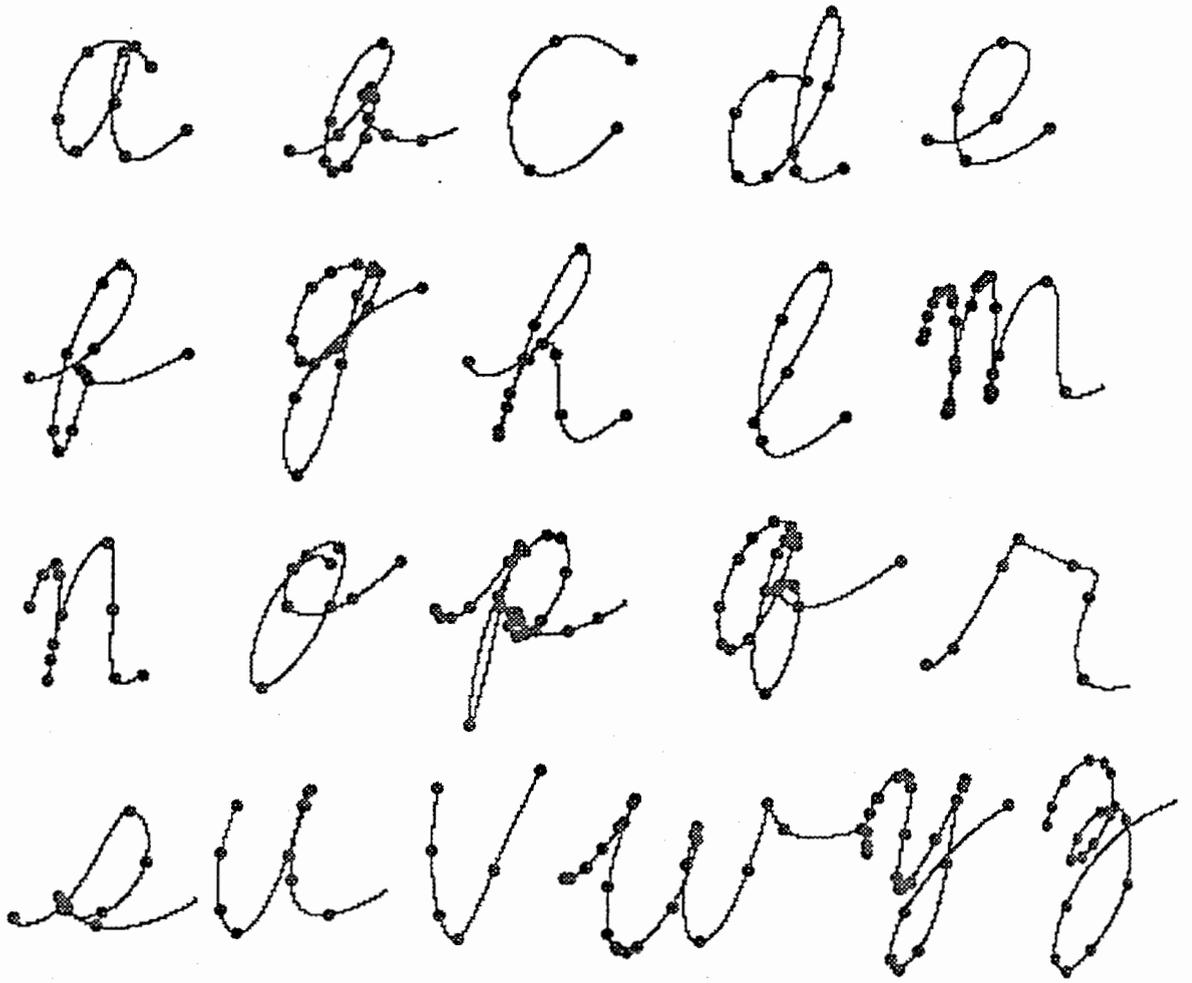


図 4.6 計測文字と特徴点

Fig 4.6 Measured characters and feature points

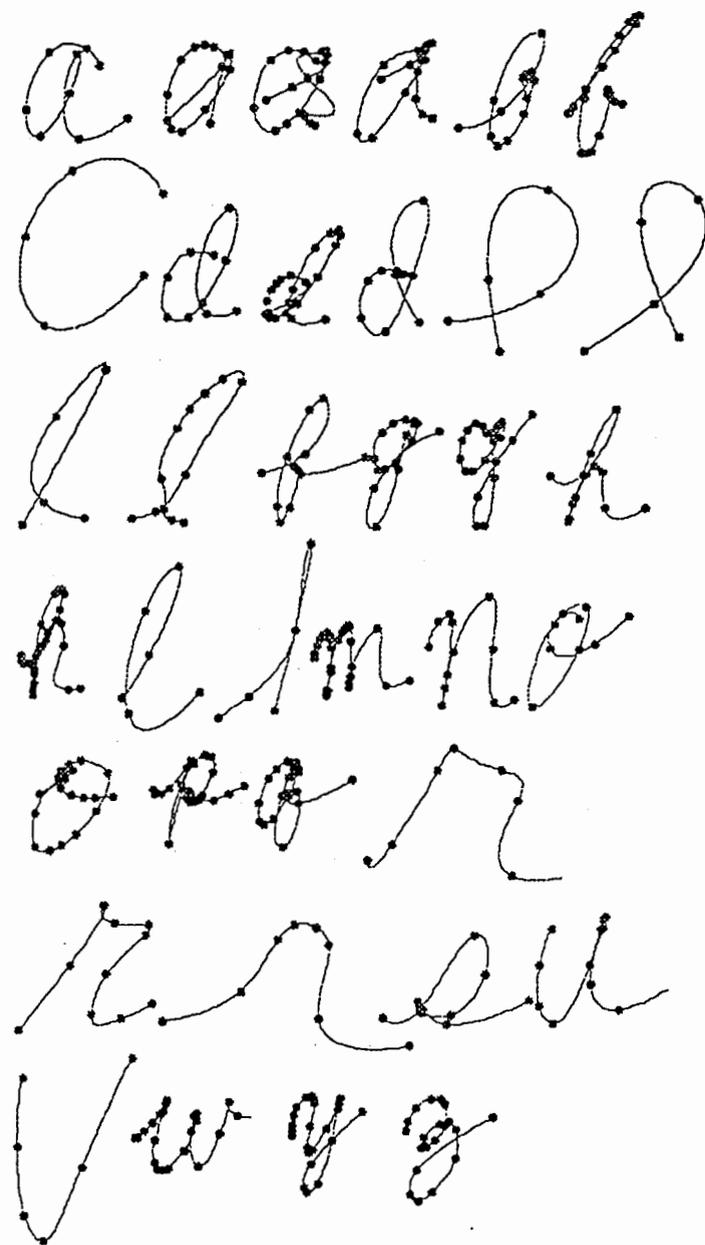
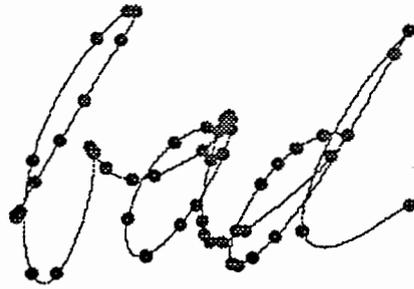


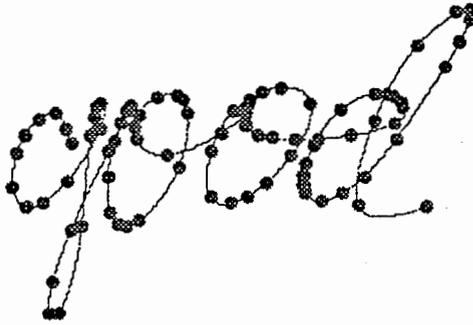
図 4.7 躍度最小モデルで再構成されたテンプレートの軌道
 Fig 4.7 Template trajectories generated by the minimum jerk model.



1:BAD : 0.004072
 (0,17) (18,35) (36,52)
 2:BAD : 0.004155
 (0,18) (18,35) (36,52)
 3:BAD : 0.004179
 (0,17) (18,35) (35,52)



1:DEAR : 0.018376
 (0,8) (9,18) (19,31) (30,51)
 2:DEAR : 0.018791
 (0,8) (9,18) (19,31) (30,50)
 3:DEAR : 0.019001
 (0,8) (9,18) (19,30) (30,51)



1:GOOD : 0.007163
 (0,21) (20,38) (39,58) (59,84)
 2:GOOD : 0.007692
 (0,21) (20,38) (39,59) (60,84)
 3:GOOA : 0.007916
 (0,21) (20,38) (39,58) (58,82)

図 4.8 続け文字の認識結果

Fig 4.8 Recognition results.

使用したパラメータ：

- 1文字に含まれる特徴点（経由点）の最小数 : 3点
- 1文字に含まれる特徴点（経由点）の最大数 : 25点
- 始点となる経由点の前後への移動点数 : 1点

4.4 調音器官運動からの音韻推定

音声認識における特徴抽出は、音声波を適切な言語情報に変換する写像を実現するために、元々の情報量が損失することのないような物理量を捉えることであると考えられる。音声における特徴抽出の方法には、幾つかのアプローチ（白井，1990）がとられている。ここでは、書字運動モデルで示した経路点抽出モデルを応用した音声生成系からのアプローチによる特徴の抽出方法を提案する。提案するモデルは、基本的には上述した経路点推定モデルにおいて、腕の運動を調音器官の運動に置き換えたモデルであり、調音器官の運動から、その運動の経路点を推定し、それを運動の特徴点とするモデルである。この特徴点と音声波を比較することによって、このモデルによって推定された特徴点が、音韻の時刻とよく一致していることを実験的に示し、音声認識における特徴として将来展開が可能であることを示す。

4.4.1 音韻推定モデル

ここで提案する音韻を推定するモデルは、第3章で示した経路点推定モデルを調音器官の運動に応用したものである。調音器官の運動に対しても腕の運動で示されたような調音器官のダイナミクスに依存するような最適化規範に基づいた運動軌道の生成モデルが提案（Kawato, 1989; 平山ら, 1992）されている。調音器官は、一般に複雑であり、そのモデル化は困難であるが、平山ら（1992）は実際に神経回路網モデルによって調音器官の運動データを学習することによって調音器官のダイナミクスモデルを構成している。しかしながら、ここでは簡単のため腕の運動と同様にトルク変化最小規範や運動指令変化最小規範の近似モデルと考えられる躍度最小規範による軌道生成モデルを考える。

第3章で示した経路点推定モデルを調音器官に応用するにあたり幾つかの方法が考えられる。

- (1) 各調音器官を独立に考えて、各調音器官毎に経路点を推定する方法。抽出される経路点の時刻は、完全に独立であり、各々の調音器官によって異なる。（図4.9）
- (2) 各調音器官が完全に協調して運動するとして、再構成された各調音器官と与えられた各調音器官の運動の誤差の総和が最大となる点を運動の経路点

とする方法。抽出される経路点は、完全に同期しており、各調音器官とも同じ時刻に経路点が抽出される。(図4.10)

- (3) (1)と(2)の中間的な方法で、各調音器官が協調して(2)と同様に運動の誤差の総和が最大となる時刻を運動の経路点の候補とし、次に各々の調音器官に対して定めた誤差の閾値と比較して、その値を越えているときは経路点とし、越えていないときは経路点としない方法。抽出される経路点は、同期しているものとしていないものが含まれる。(図4.11)

以上3つの方法の良否は、実際の調音器官の運動データと音響データから解析されなければならないが、軌道生成が調音器官のダイナミクスに制約されたものであるとすれば、(3)の方法は、それを考慮している。

また、軌道生成モデルに躍度最小モデルでなく、荷重付き躍度最小モデル(Kawato, 1989)を応用することによって、より積極的に調音器官のダイナミクスを考慮した経路点の推定が可能になると考えられる。

4.4.2 音韻の推定結果

実際の調音器官の運動データから経路点を推定した実験結果を示す。図4.9～図4.11は連続音"Sam sat on top of the potato cooker"の音響データ、スペクトログラム、および調音器官の運動(垂直方向)を示したものである。縦の実線が音響データとスペクトログラムから解析した音韻時刻であり、●印が提案したモデルによって推定した経路点である。経路点は上で述べた(1)～(3)の方法によって各々推定した。図からわかるように、音韻時刻と推定した経路点の時刻が良く一致していることがわかり、我々の提案している経路点の推定方法が調音器官の運動においても適切であることがわかる。しかしながら、図4.11の破線は推定した経路点を使って再構成した各調音器官の運動軌道を示しているが必ずしも与えられた軌道と一致していない部分もある。経路点を抽出するための閾値を小さくすることで再構成された軌道を与えられた軌道とほとんど一致させることができる。しかしながら、逆に閾値を小さくすると抽出される経路点の数が増える負の効果もある。これは、軌道生成モデルにダイナミクスが考慮されていないなど幾つかの問題が考えられるが、1つの問題として、次のような点が上げられる。第3章の図3.2の経路点抽出モジュールでは、まず経路点が抽出され、次に抽出された経路点を通る軌道が生成

Sam sat on top of the potato cooker...

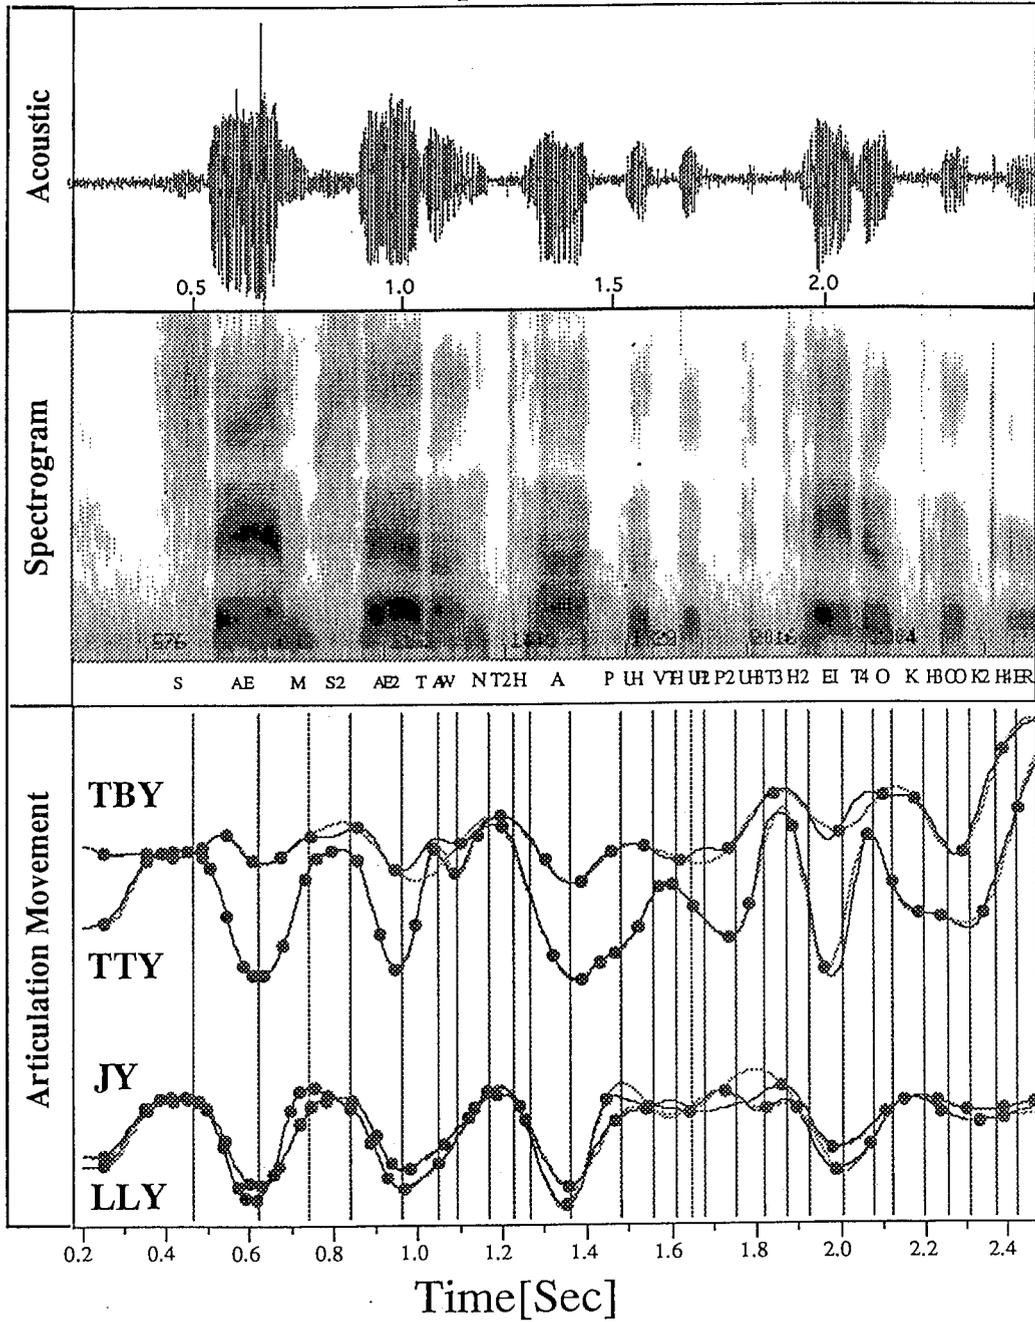


図 4.9 音韻時刻の推定結果 (1)

Fig 4.9 Estimation result of phoneme time (1).

経由点推定のために使った誤差の閾値は、各調音器官共に0.01である。

(データは (株) ATR 人間情報通信研究所のEric Vatikiotis-Bateson客員研究員より提供頂いた。)

Sam sat on top of the potato cooker...

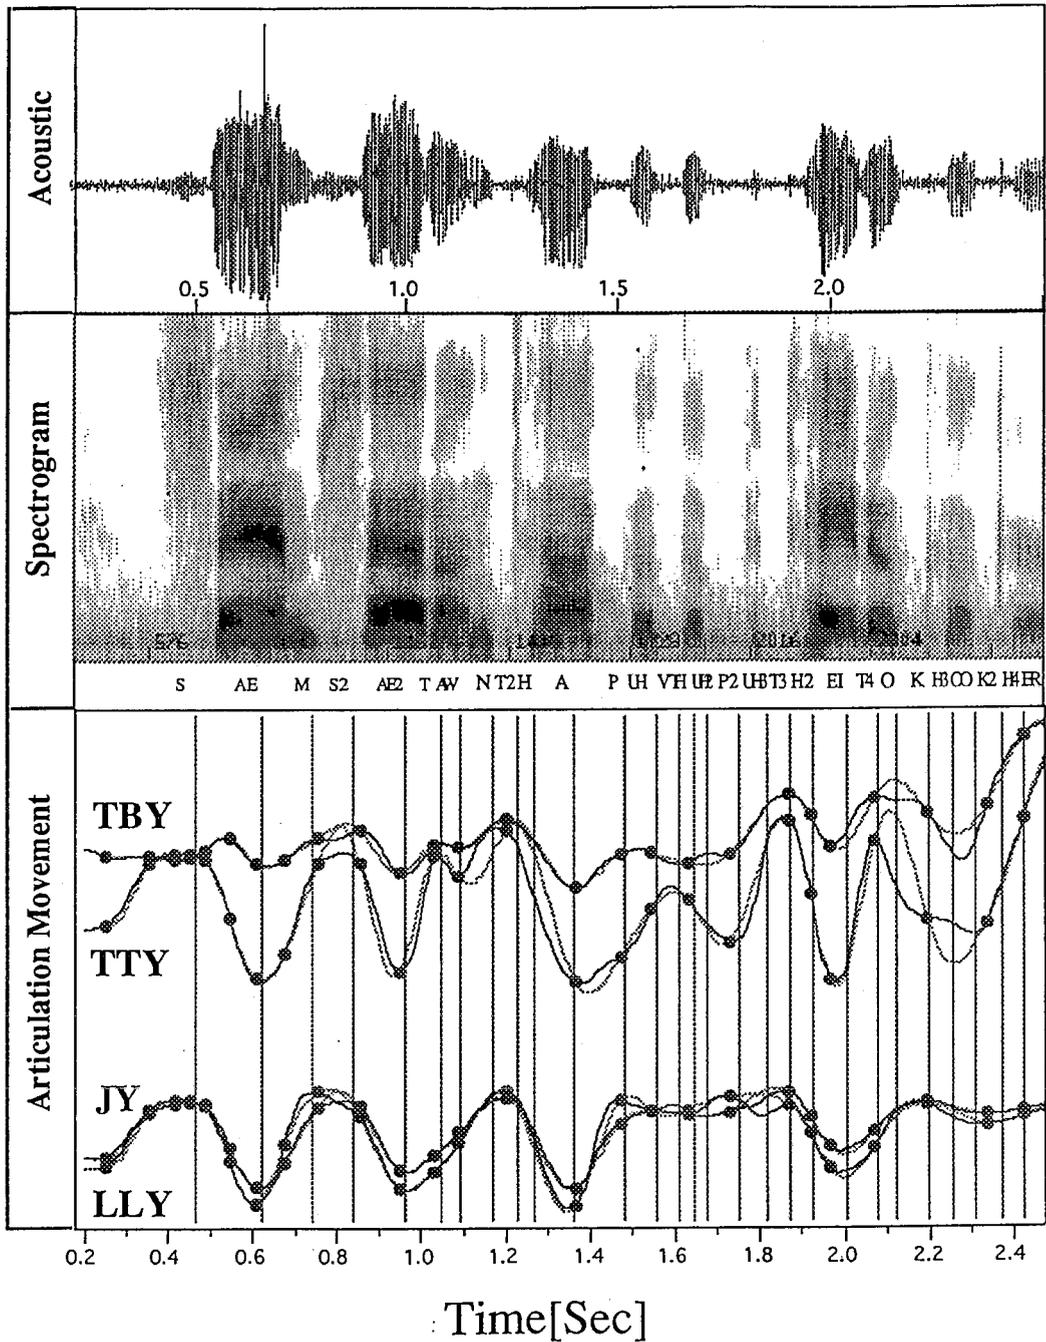


図 4.10 音韻時刻の推定結果 (2)

Fig 4.10 Estimation result of phoneme time (2).

経路点推定のために使った各調音器官の和に対する誤差の閾値は0.04である。

(データは(株)ATR 人間情報通信研究所のEric Vatikiotis-Bateson客員研究員より提供頂いた。)

Sam sat on top of the potato cooker...

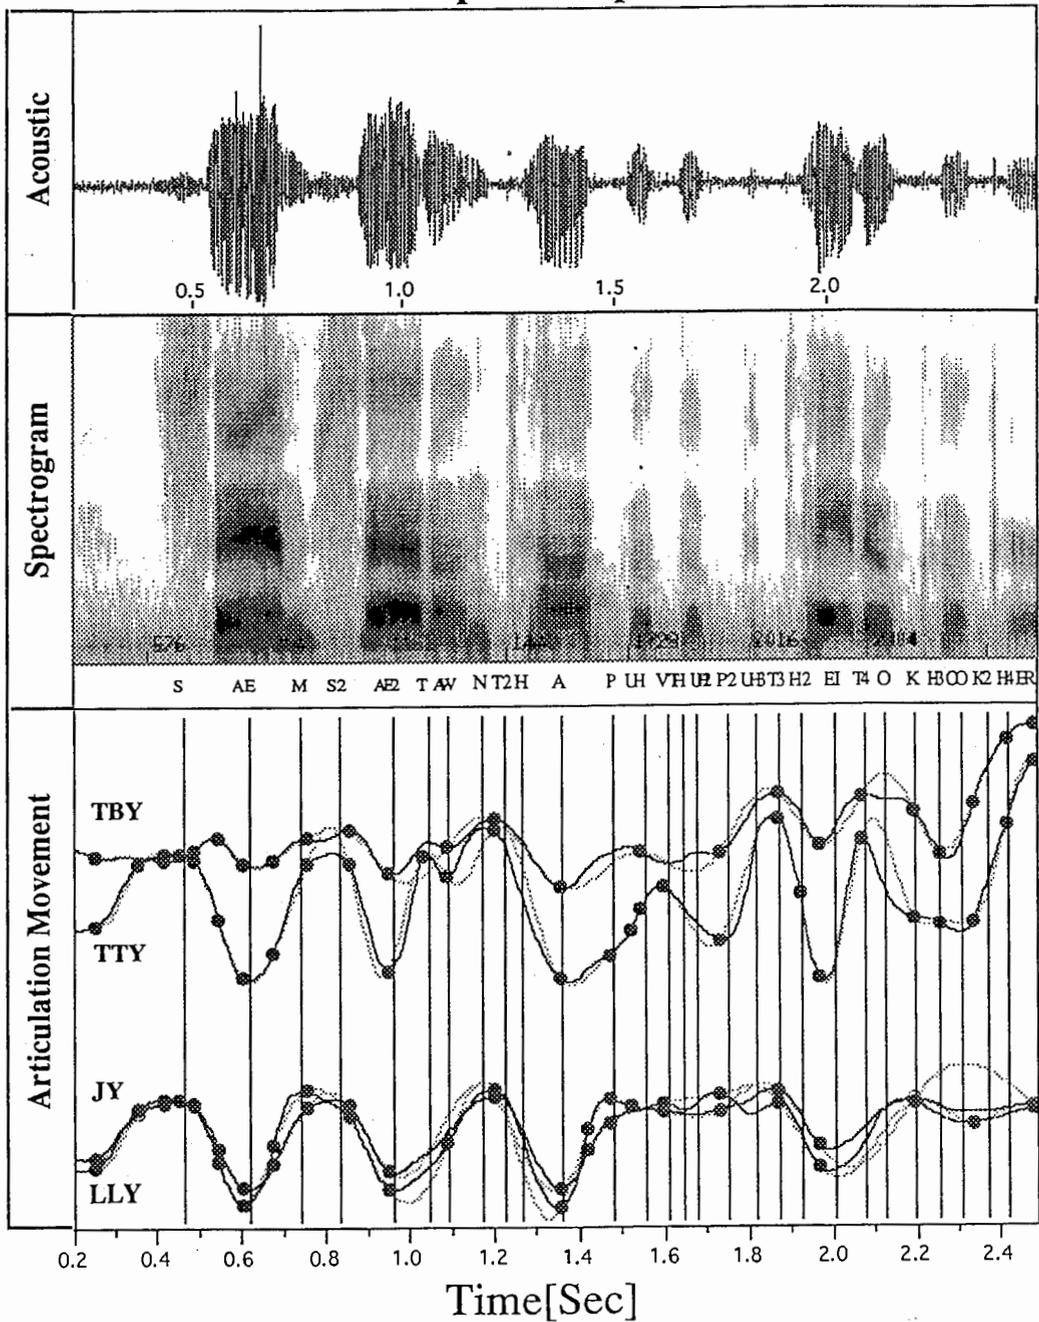


図 4.1.1 音韻時刻の推定結果 (3)

Fig 4.11 Estimation result of phoneme time (3).

経由点推定のために使った各調音器官に対する誤差の閾値は0.01であり、各調音器官の和に対する誤差の閾値は0.04である。

(データは(株)ATR人間情報通信研究所のEric Vatikiotis-Bateson客員研究員より提供頂いた。)

Sam sat on top of the potato cooker...

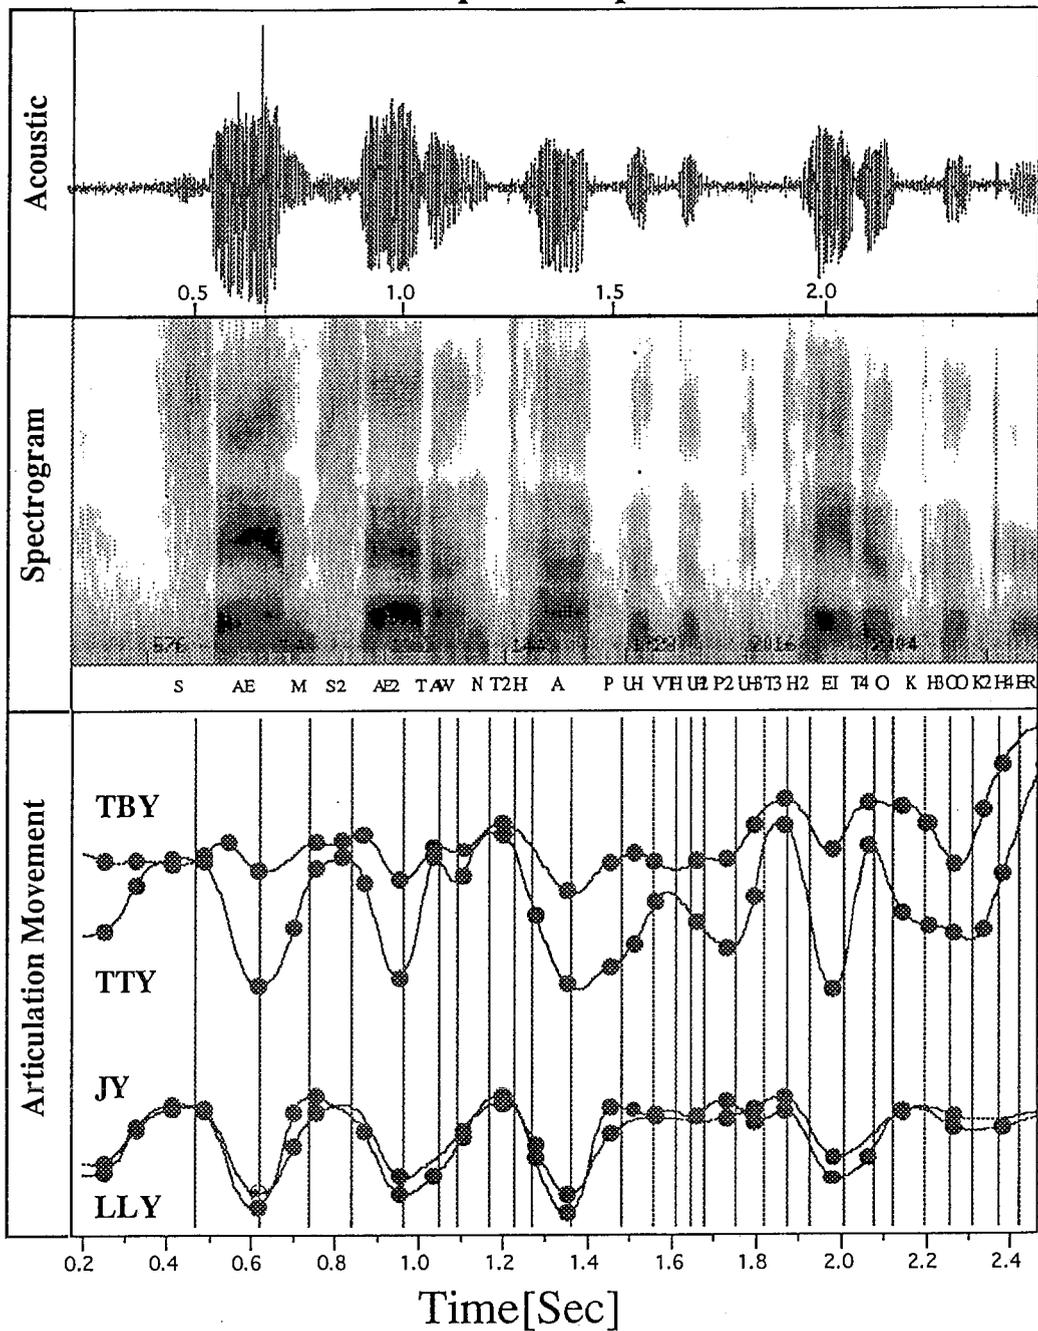


図 4.1 2 音韻時刻の推定結果

Fig 4.12 Estimation result of phoneme time.

経路点推定のために使った各調音器官に対する誤差の閾値は0.001であり、各調音器官の和に対する誤差の閾値は0.004である。

(データは(株)ATR 人間情報通信研究所のEric Vatikiotis-Bateson客員研究員より提供頂いた。)

され、既に生成されている軌道にこの軌道が足し込まれる。つまり、軌道生成が逐次加算的に生成される。これによって経由点推定位置の誤差あるいは欠落が生じるものと考えられる。これを解消するために、逐次加算的な軌道生成をやめ、経由点抽出モジュールでの経由点抽出毎に軌道生成モジュールで既に抽出されている経由点すべてを考慮した軌道生成をする方法を行った。その結果は、図 4.12 に●印で示す。この場合も、良く音韻位置と推定した経由点に対応していることがわかる。しかも、再構成された軌道は与えられた軌道をほぼ完全に再現している。(図 4.12 に再構成した軌道は示していないが、ほぼ実線と同様である。)

4.4.3 音韻推定モデルの応用

音韻推定モデルは、調音器官の運動の経由点推定モデルであり、音響信号を入力とした音声認識システムには、すぐには使えない。しかしながら、Shirai & Kobayashi (1991), Papcun et al., (1992), 平山ら (1992, 1993) や誉田ら (1993) の研究で行われているような調音器官から音響信号への写像・逆写像関係が明らかになれば、音響信号から調音器官へのマッピングが行われ、我々の提案したモデルによって調音器官から音韻との対応が可能となり、これによって音声認識への発展が期待される。図 4.13 に示したシステムは、調音器官から音響信号への写像・逆写像モデルを使った音声認識のモデルである。

また上で示したように我々の提案しているモデルは、与えられた軌道を精度良く再構成することが可能である。従って音響信号→調音器官→音響信号のモデルに、我々の音韻推定モデルを付加することによって音響信号を調音器官の運動の特徴に圧縮し、かつ音響信号に復元できる。これは高効率の情報圧縮アルゴリズムを構成していると言える (表 3.1)。

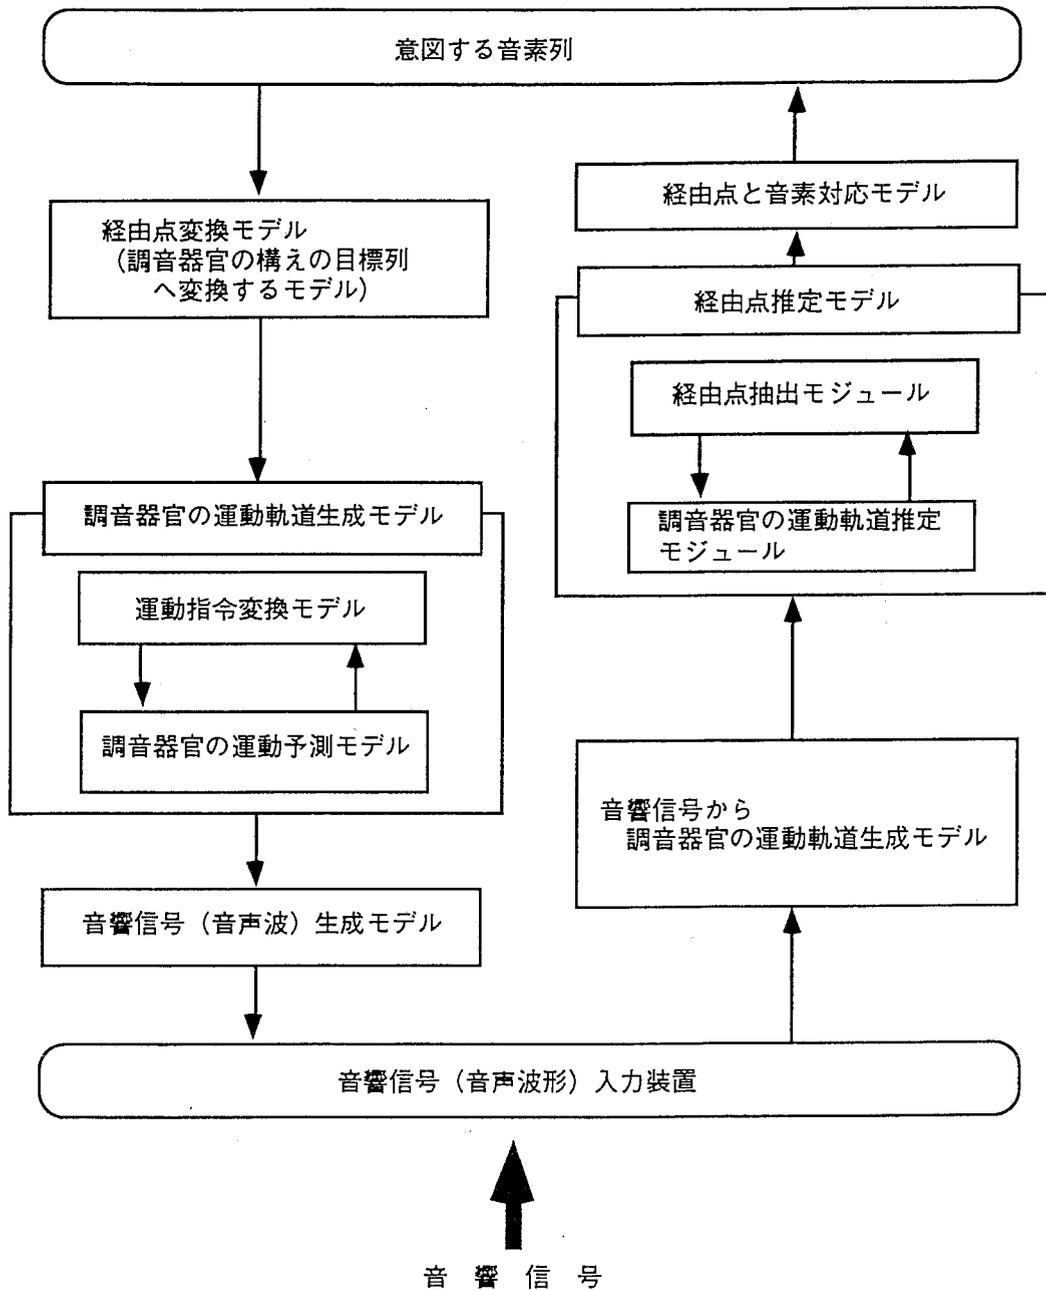


図 4.13 音声認識システム

Fig 4.13 A speech recognition system.

4.5 おわりに

本章において、我々は既に提案している最小化原理に基づいた書字運動モデルおよび経路点推定モデルを応用した文字認識システムを提案し、これによって連続文字の認識が可能であることを示した。また、この経路点推定モデルが調音器官の運動にも応用できることを示し、推定された点が音韻と良く対応することを示した。

文字認識に関しては、大量のデータに対して適用することによって実用化への課題を検討する必要がある。また、音声に関しては、音韻と推定される経路点の関係を、やはり、数多くの事例で確認すること、および、音声認識への可能性を検討することが今後の重要な研究課題である。

第5章

新しい情報量規準とCross Validation
による汎化能力の推定

-----神経回路網モデルの
実現に関する一手法

5.1 はじめに

前章までに、我々はヒトの運動制御に関する計算論的アプローチの成果である運動規範に基づいた運動パターンの生成と認識に関する表現とアルゴリズムを主として議論してきた。最後にMarr (1982) の第3の水準であるハードウェアの水準についての議論をする。ここでは前章までに述べたモデルを神経回路網で実現することを念頭において、汎化能力の高い神経回路網モデルを選択する問題について述べる。

神経回路網モデルは、バックプロパゲーションによる学習方法の開発などをきっかけに、様々な分野でその有効性が確認されている。また、理論的にも3層の神経回路網モデルにおいて、十分な中間層ユニットを使えば任意の関数が任意の精度で近似できることが保証されている (Irie & Miyake, 1988; 舟橋, 1988)。しかしながら、神経回路網モデルのサイズ (ユニットの数) を、どの程度にしたら未知のデータに対しても、良い近似を与えるか (以下汎化能力と呼ぶ) については明確ではない。離散の問題に対しては、汎化を数学的に保証する定理 (Baum & Haussler, 1989; Abu-Mostafa, 1989) が与えられている。つまり、あらかじめ、神経回路網のサイズが決まっているとき、その荷重の個数の数倍の入力データについて、正しい出力を得るように学習すれば、未知のデータに対しても正しい出力をだすというものである。しかし、連続の問題で、入出力データの対の集合が与えられているとき、このデータから汎化能力の高い神経回路網モデルのサイズを決定する方法は、確立されていない。モデルのサイズが小さければ、与えられたデータの入出力関係を十分表現することができないし、逆に、モデルのサイズが大き過ぎれば、与えられたデータの入出力関係は良く表現するが、与えられたデータ以外の部分では、変動が大きく汎化能力が低くなる。この問題は、統計の分野ではモデル選択の問題として扱われており、AIC (Akaike Information Criterion) (Akaike, 1974; 赤池, 1976; 坂元, 石黒 & 北川, 1983) をはじめとして、幾つかの情報量規準 (Rissanen, 1978, 1983; Moody, 1991, 1992; Murata, Yoshizawa & Amai, 1992) が提案されている。AICは最尤推定量とその性質をうまく利用して導かれている情報量規準であるが、バックプロパゲーション学習などによる神経回路網モデルのシナプス荷重 (パラメータ) 推定においては、ロ

一カルミニマムや大きい条件数などの困難のために通常は、最尤推定量は得られない。そのためAICをそのまま適用することはできない。実際これらの情報量規準を神経回路網モデルの選択問題に適用した例についても報告（栗田，1989, 1990; 戸田，萩原 & 臼井, 1990; 麻生，1992）がされているが、各情報量規準によってペナルティ項である自由度の寄与が各々異なり、どの情報量規準が良い推定を与えてくれるのかは理論的には明らかでない。実験的に神経回路網の自由度と汎化能力を調べた研究もなされている（Morgan & Bourlard, 1990）。神経回路網モデルのような非線形モデルの選択においては、最尤推定量が与えられないことを前提に情報量規準を推定する必要がある。また、与えられたデータを分割して汎化能力を評価する方法、つまり、Cross Validation（竹内，1989）（以下CV）を使ったTishby et al.（1989）の報告もあるが、基本的には、与えられたデータをトレーニングセットとテストセットに分割して、テストセットで汎化能力を評価しており、与えられたデータを最大限使って学習した神経回路網モデルの選択方法にはなっていない。本章では最尤推定量が得られない場合の情報量規準をCross Validationを使った手法によって推定する方法を提案し、神経回路網モデルのサイズ選択の問題に適用した結果を示す。

5.2 Cross Validationを使った神経回路網モデルの選択方法

与えられたデータ N 個を使って、サイズの異なる神経回路の学習を行い、その中で汎化能力の高いモデルを選択する問題を考える。そのためにCross Validationの方法を使い与えられたデータ N 個を幾つかのデータセットに分割し学習することによって、以下に述べる情報量規準の自由度に依存するペナルティ項を推定し、情報量規準を計算し比較することによって汎化能力の高いモデルの選択を行う。定義と記号について以下にまとめる。

定義 記号

- K : モデルの自由度
- N : 与えられた全てのデータの個数
- l, m : 与えられたデータ N から抽出したデータの個数
- $X = (X_1, X_2, \dots, X_N)$: 確率変数
- $x = (x_1, x_2, \dots, x_N)$: 確率変数 X の実現値
- Z : X_i と同じ分布に従い X と独立な確率変数

$f(x/w)$: パラメータ w のときの x の密度関数

$f(x/w^*)$: 真の分布

w^* : 真のパラメータ

\tilde{w}_K^N : データ数 N 個の学習によって求めた自由度 K のパラメータ推定値
(自由度 K を省略して \tilde{w}^N とも記す.)

$l(w) = \sum_{i=1}^N \log f(x_i/w)$: 対数尤度

$l^*(w) = N E_Z[\log f(z/w)]$
 $= N \int f(z/w^*) \log f(z/w) dz$
: 平均対数尤度の N 倍

この平均対数尤度が大きいほど分布 f が真の分布に近い

$l^*(w^*) = N E_Z[\log f(z/w^*)]$
 $= E_X \left[\sum_{i=1}^N \log f(x_i/w^*) \right]$
 $= E_X[l(w^*)]$
: 真のパラメータでの平均対数尤度の N 倍

$l_n^*(K) = E_X[l^*(\tilde{w}_K^N)]$
 $= \int l^*(\tilde{w}_K^N) \prod_{i=1}^N f(x_i/w^*) dx$
: 期待平均対数尤度
学習によって求めたパラメータ推定値での平均対数尤度の N 倍の期待値であり, この値が大きい程モデルが良いことになる.

5.2.1 汎化能力の評価

神経回路網モデルの汎化能力をどのような評価規準によって測定するかが, 汎化能力の高いモデル選択を行う上で最も基本的であり, かつ重要な問題である. 神経回路網モデルにおいて汎化能力が高いモデルは, 回路網モデルの学習に使ったデータ以外の未知のデータに対しても, 学習に使ったデータと同程度の誤差で近似可能であることが要求される. 確率的に考えれば, 学習に使う入出力データ x は, 任意の確率分布 $g(x)$ に従っており, 未知の入出力データも, 同じ確率分布 $g(x)$ に従うデー

タである。各入出力データ x は入力部分 x_i と出力部分 x_o とからなる。入出力は決定論的に $x_o = h(x_i)$ などと関数関係で決っているのではなく、 $x = (x_i, x_o)$ の組が確率分布 g に従うと考える。汎化能力の高いモデル $f(x/w)$ は、確率分布 g に従う入出力データを良く近似することが必要である。逆に言えば、確率分布 g にもとづいて選ばれた入出力データをモデル f がどの程度良く近似するかを推定すれば汎化能力の高さを評価することができる。統計の分野で言う平均対数尤度の期待値、つまり期待平均対数尤度が、この値に相当する量であると考えられる。

また、実際に汎化能力を推定するときに与える入出力データ $x_i (i = 1, \dots, N)$ は、可能な限りその確率構造 g を反映するのに十分なデータを与えること (図 5.1) が本質的である。汎化能力は、学習に使わなかった未知の入出力データに対するモデル f と真の分布 g との近似の良さであるから、サンプルデータが確率空間において局所的に存在すること (図 5.2) は、汎化能力の推定値の誤差を大きくしてしまうことになる。以下に述べる情報量規準についても、入出力データは、その確率分布を反映するのに十分なデータと考えて議論を展開する。

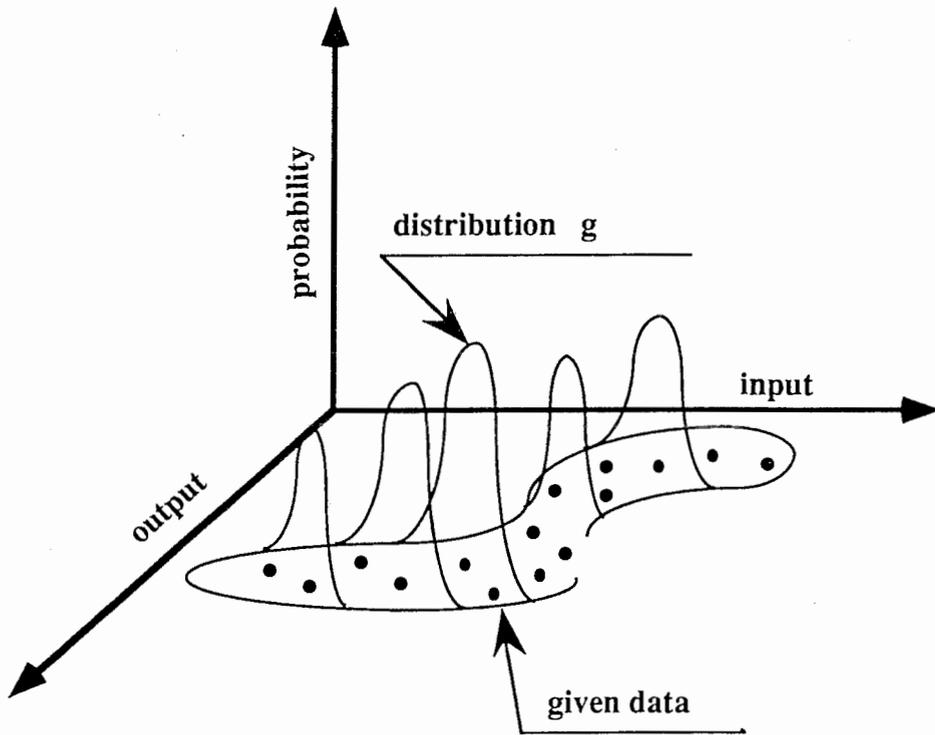


図 5.1 入出力空間と確率分布

Fig5.1 Input-output space and probability distribution

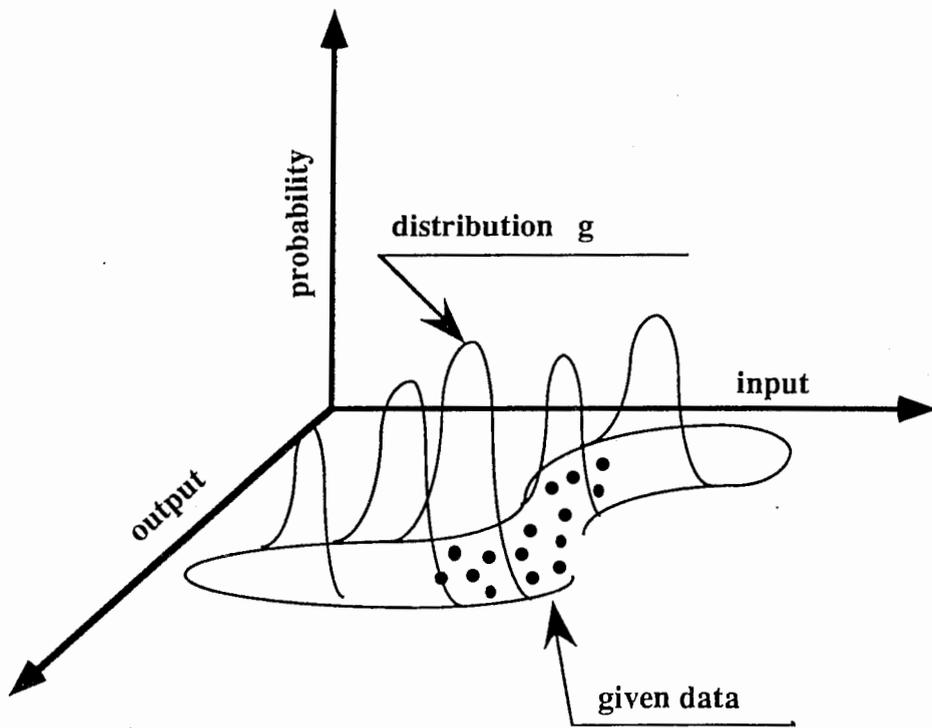


図 5.2 入出力空間と確率分布 (局所)

Fig5.2 Input-output space and probability distribution (local)

5.2.2 情報量規準の計算

AICの導出においては、最尤推定量が計算され、最大対数尤度が得られるものとして議論が展開されているが、神経回路網のような非線形モデルを考えた場合には、解析的に最尤推定量は計算されない。通常バックプロパゲーションやボルツマンマシンの学習則のような漸化的学習アルゴリズムに従ってシナプス荷重（パラメータ）推定を行うため、最尤推定量となるパラメータ推定値を得ることは困難だからである。

つまり神経回路網のような非線形モデルのモデル選択の問題に、AICを適用することは、AICの前提を満足していないという意味において、必ずしも良好な結果を与えてくれない。

本研究では、神経回路網のモデル選択の問題において、学習で得られたパラメータ推定値が、最尤推定量になっていないことを前提に情報量規準の導出を行い、モデル選択への適用について述べる。

まずAICの導出過程と同じ手順に従って、最尤推定量が得られない場合の情報量の計算を行う。自由度 K の神経回路網において、与えられたデータ N 個を使った学習によって得られたパラメータ推定値 \tilde{w}_K^N での期待平均対数尤度 $\ln^*(K)$ を最終的に求めることを目的に以下の展開を進める。以下の議論では、神経回路網の自由度は K とする。よって記号 K を省略して記す。

$$\ln^*(K) = E_X [l^*(\tilde{w}^N)] \quad (5.1)$$

\tilde{w}^N での平均対数尤度の N 倍 $l^*(\tilde{w}^N)$ を真のパラメータ w^* でテーラー展開を行う。

$$\begin{aligned} l^*(\tilde{w}^N) &= l^*(w^*) + (\tilde{w}^N - w^*) \left[\frac{\partial l^*}{\partial w} \right]_{w^*} \\ &\quad + \frac{1}{2} (\tilde{w}^N - w^*) \left[\frac{\partial^2 l^*}{\partial w^2} \right]_{w^*} (\tilde{w}^N - w^*)^T \\ &\quad + \varepsilon_Z (\tilde{w}^N - w^*) \end{aligned} \quad (5.2)$$

ただし、 $\varepsilon_Z (\tilde{w}^N - w^*)$ はテーラー展開した3次以上の項である。

w^* は真のパラメータであるから、 l^* は w^* で最大となるから式 (5.2) 右辺の第2項は0となる。

$$\left[\frac{\partial l^*}{\partial w} \right]_{w^*} = 0$$

よって式 (5.2) は次のようになる。

$$\begin{aligned} l^*(\tilde{w}^N) &= l^*(w^*) \\ &+ \frac{1}{2}(\tilde{w}^N - w^*) \left[\frac{\partial^2 l^*}{\partial w^2} \right]_{w^*} (\tilde{w}^N - w^*)^T \\ &+ \varepsilon_Z(\tilde{w}^N - w^*) \end{aligned} \quad (5.3)$$

次に対数尤度 $l(w^*)$ を \tilde{w}^N でテーラー展開する。

$$\begin{aligned} l(w^*) &= l(\tilde{w}^N) + (w^* - \tilde{w}^N) \left[\frac{\partial l}{\partial w} \right]_{\tilde{w}^N} \\ &+ \frac{1}{2}(w^* - \tilde{w}^N) \left[\frac{\partial^2 l}{\partial w^2} \right]_{\tilde{w}^N} (w^* - \tilde{w}^N)^T \\ &+ \varepsilon(w^* - \tilde{w}^N) \end{aligned} \quad (5.4)$$

ただし、 $\varepsilon(w^* - \tilde{w}^N)$ はテーラー展開した3次以上の項である。
ここで $\alpha_Z(\tilde{w}^N - w^*)$ 、 $\alpha(w^* - \tilde{w}^N)$ を次のように定義する。

$$\begin{aligned} \alpha_Z(\tilde{w}^N - w^*) &= E_X \left[\frac{1}{2}(\tilde{w}^N - w^*) \left[\frac{\partial^2 l^*}{\partial w^2} \right]_{w^*} (\tilde{w}^N - w^*)^T \right] \\ &+ E_X \left[\varepsilon_Z(\tilde{w}^N - w^*) \right] \end{aligned}$$

$$\begin{aligned} \alpha(w^* - \tilde{w}^N) &= E_X \left[(w^* - \tilde{w}^N) \left[\frac{\partial l}{\partial w} \right]_{\tilde{w}^N} \right] \\ &+ E_X \left[\frac{1}{2}(w^* - \tilde{w}^N) \left[\frac{\partial^2 l}{\partial w^2} \right]_{\tilde{w}^N} (w^* - \tilde{w}^N)^T \right] \\ &+ E_X \left[\varepsilon(w^* - \tilde{w}^N) \right] \end{aligned}$$

次に、 \tilde{w}^N での平均対数尤度の N 倍 $l^*(\tilde{w}^N)$ の期待値を考える。式 (5.3) と定義より、

$$E_X \left[l^*(\tilde{w}^N) \right] = E_X \left[l^*(w^*) \right] + \alpha_Z(\tilde{w}^N - w^*) \quad (5.5)$$

$l^*(\tilde{w}^*)$ は真のパラメータ w^* での平均対数尤度の N 倍であるから

$$E_X[l^*(w^*)] = l^*(w^*)$$

とおける。故に式 (5.5) は、式 (5.6) とかける。

$$E_X[l^*(\tilde{w}^N)] = l^*(w^*) + \alpha_Z(\tilde{w}^N - w^*) \quad (5.6)$$

また、 $l^*(\tilde{w}^*)$ の定義より

$$l^*(w^*) = E_X[l(w^*)] \quad (5.7)$$

であるから、式 (5.7) に式 (5.4) を代入して、 α_Z 、 α の定義を使って置き換える。

$$l^*(w^*) = E_X[l(\tilde{w}^N)] + \alpha(w^* - \tilde{w}^N) \quad (5.8)$$

式 (5.1) と式 (5.6) より

$$\ln^*(K) = l^*(w^*) + \alpha_Z(\tilde{w}^N - w^*) \quad (5.9)$$

式 (5.9) に式 (5.8) を代入して、 α_Z 、 α が定数であることから、式 (5.10) を得る。

$$\ln^*(K) = E_X[l(\tilde{w}^N) + \alpha_Z(\tilde{w}^N - w^*) + \alpha(w^* - \tilde{w}^N)] \quad (5.10)$$

ここでAICと同様に期待平均対数尤度の不偏推定量

$$l(\tilde{w}^N) + \alpha_Z(\tilde{w}^N - w^*) + \alpha(w^* - \tilde{w}^N)$$

の (-2) 倍を情報量規準 $IC(K, N)$ とする。

$$IC(K, N) = -2l(\tilde{w}^N) - 2\alpha_Z(\tilde{w}^N - w^*) - 2\alpha(w^* - \tilde{w}^N) \quad (5.11)$$

5.2.3 ペナルティ項の推定

前節で情報量規準 $IC(K, N)$ を新たに定義したが, $IC(K, N)$ は, AIC のペナルティ項に相当する $(\alpha_Z + \alpha)$ の項をデータより推定する必要がある. 以下にデータ数 N 個のときの $(\alpha_Z + \alpha)$ の推定について述べる. そのために, データ N 個から l, m 個のデータを抽出して学習することによって得られるパラメータ推定値 \tilde{w}^l, \tilde{w}^m を考える.

$l(\tilde{w}^m), l^*(\tilde{w}^m), l(\tilde{w}^N)$ を \tilde{w}^l で各々テーラー展開する.

$$\begin{aligned} l(\tilde{w}^m) &= l(\tilde{w}^l) + (\tilde{w}^m - \tilde{w}^l) \left[\frac{\partial l}{\partial w} \right]_{\tilde{w}^l} \\ &\quad + \frac{1}{2} (\tilde{w}^m - \tilde{w}^l) \left[\frac{\partial^2 l}{\partial w^2} \right]_{\tilde{w}^l} (\tilde{w}^m - \tilde{w}^l)^T + \varepsilon(\tilde{w}^m - \tilde{w}^l) \end{aligned} \quad (5.12)$$

$$\begin{aligned} l^*(\tilde{w}^m) &= l^*(\tilde{w}^l) + (\tilde{w}^m - \tilde{w}^l) \left[\frac{\partial l^*}{\partial w} \right]_{\tilde{w}^l} \\ &\quad + \frac{1}{2} (\tilde{w}^m - \tilde{w}^l) \left[\frac{\partial^2 l^*}{\partial w^2} \right]_{\tilde{w}^l} (\tilde{w}^m - \tilde{w}^l)^T + \varepsilon_Z(\tilde{w}^m - \tilde{w}^l) \end{aligned} \quad (5.13)$$

$$\begin{aligned} l(\tilde{w}^N) &= l(\tilde{w}^l) + (\tilde{w}^N - \tilde{w}^l) \left[\frac{\partial l}{\partial w} \right]_{\tilde{w}^l} \\ &\quad + \frac{1}{2} (\tilde{w}^N - \tilde{w}^l) \left[\frac{\partial^2 l}{\partial w^2} \right]_{\tilde{w}^l} (\tilde{w}^N - \tilde{w}^l)^T + \varepsilon(\tilde{w}^N - \tilde{w}^l) \end{aligned} \quad (5.14)$$

また $l^*(\tilde{w}^N)$ を \tilde{w}^l でテーラー展開して, その期待値をとる.

$$\begin{aligned} E_X[l^*(\tilde{w}^N)] &= E_X[l^*(\tilde{w}^l)] + E_X \left[(\tilde{w}^N - \tilde{w}^l) \left[\frac{\partial l^*}{\partial w} \right]_{\tilde{w}^l} \right] \\ &\quad + E_X \left[\frac{1}{2} (\tilde{w}^N - \tilde{w}^l) \left[\frac{\partial^2 l^*}{\partial w^2} \right]_{\tilde{w}^l} (\tilde{w}^N - \tilde{w}^l)^T \right] \\ &\quad + E_X[\varepsilon_Z(\tilde{w}^N - \tilde{w}^l)] \end{aligned} \quad (5.15)$$

ところで, いま, $R(w)$ をパラメータ w の次元 K と同じ次元 K をもつベクトルとし, 次式のように定義する.

$$R(w) = (R_1(w), R_2(w), \dots, R_K(w))$$

$$\frac{\partial l^*}{\partial w_p} = R_p(w) \frac{\partial l}{\partial w_p} \quad (p = 1, 2, \dots, K)$$

これは

$$N E_Z \left[\frac{\partial}{\partial w_p} \log f(z/w) \right] = R_p(w) \sum_{i=1}^N \left[\frac{\partial}{\partial w_p} \log f(x_i/w) \right]$$

である。ここで $R_p(w) = r(w)$ と仮定する。ただし、 $r(w)$ は w のスカラー関数である。ところで上式は、データ数 N が十分大きくなれば大数の法則より考えて、 w とは無関係に $R_p(w) = 1$ に収束する式であり、 $R_p(w) \equiv R_q(w)$ ($p \neq q$) となると考えられ、上で述べた $R_p(w) = r(w)$ の仮定が満足される。ここでは、 N が $R_p(w) = 1$ を満たす程大きくない場合も考慮してスカラーの定数値 r を用いて $R_p(w) = r$ と仮定する。よって、

$$\left[\frac{\partial l^*}{\partial w} \right] = r \left[\frac{\partial l}{\partial w} \right] \quad (5.16)$$

上述した仮定は $(\alpha_Z + \alpha)$ の近似推定のための2つの仮定のうちの第1のものである。この仮定のもとで、両辺を w で偏微分する。

$$N E_Z \left[\frac{\partial^2}{\partial w^2} \log f(z/w) \right] = r \left[\sum_{i=1}^N \frac{\partial^2}{\partial w^2} \log f(x_i/w) \right]$$

つまり

$$\left[\frac{\partial^2 l^*}{\partial w^2} \right] = r \left[\frac{\partial^2 l}{\partial w^2} \right] \quad (5.17)$$

が成立する。また一般的に n 次の偏微分に対しても次式が成立する。

$$\left[\frac{\partial^{(n)} l^*}{\partial w^{(n)}} \right] = r \left[\frac{\partial^{(n)} l}{\partial w^{(n)}} \right] \quad (5.18)$$

よって、式(5.13)を式(5.16)、式(5.17)、式(5.18)を使って書き直すと以下のようなになる。

$$\begin{aligned} l^*(\tilde{w}^m) &= l^*(\tilde{w}^l) + r(\tilde{w}^m - \tilde{w}^l) \left[\frac{\partial l}{\partial w} \right]_{\tilde{w}^l} \\ &\quad + r \frac{1}{2} (\tilde{w}^m - \tilde{w}^l) \left[\frac{\partial^2 l}{\partial w^2} \right]_{\tilde{w}^l} (\tilde{w}^m - \tilde{w}^l)^T \end{aligned}$$

$$+ r \varepsilon(\bar{w}^m - \bar{w}^l)$$

よって式 (5.12) を使って整理すると式 (5.19) が得られる。

$$r = \frac{l^*(\bar{w}^m) - l^*(\bar{w}^l)}{l(\bar{w}^m) - l(\bar{w}^l)} \quad (5.19)$$

また、式 (5.15) を式 (5.16), 式 (5.17), 式 (5.18) を使って書き直すと以下のようなになる。

$$\begin{aligned} E_X[l^*(\bar{w}^N)] &= E_X[l^*(\bar{w}^l)] + E_X\left[r(\bar{w}^N - \bar{w}^l)\left[\frac{\partial l}{\partial w}\right]_{\bar{w}^l}\right] \\ &\quad + E_X\left[r \frac{1}{2}(\bar{w}^N - \bar{w}^l)\left[\frac{\partial^2 l}{\partial w^2}\right]_{\bar{w}^l}(\bar{w}^N - \bar{w}^l)^T\right] \\ &\quad + E_X[r \varepsilon(\bar{w}^N - \bar{w}^l)] \end{aligned} \quad (5.20)$$

式 (5.20) を式 (5.14) を使って整理すると次式を得る。

$$E_X[l^*(\bar{w}^N)] = E_X[l^*(\bar{w}^l)] + E_X[r \{l(\bar{w}^N) - l(\bar{w}^l)\}]$$

上式を整理すると式 (5.21) を得る。

$$\begin{aligned} E_X[l^*(\bar{w}^N)] &= E_X[l(\bar{w}^N)] \\ &\quad + E_X[(r - 1)\{l(\bar{w}^N) - l(\bar{w}^l)\}] \\ &\quad - E_X[l(\bar{w}^l) - l^*(\bar{w}^l)] \end{aligned} \quad (5.21)$$

故に $(\alpha_Z + \alpha)$ は式 (5.10) より考えて次式で与えられる。

$$\begin{aligned} \alpha_Z(\bar{w}^N - w^*) + \alpha(w^* - \bar{w}^N) &= E_X[(r - 1)\{l(\bar{w}^N) - l(\bar{w}^l)\}] \\ &\quad - E_X[l(\bar{w}^l) - l^*(\bar{w}^l)] \end{aligned} \quad (5.22)$$

5.2.4 平均対数尤度の近似計算

最後に l^* の計算について考える。いま十分大きなデータセット N が与えられているとする。 N から m ($m < N$) を抽出して、学習を行ったとき、これによって得られたパラメータ推定値 \bar{w}^m での平均対数尤度は、データセット N から m を抜いたデー

タセットに対する \bar{w}^m での対数尤度の平均で十分良く近似できると期待される。前述したように平均対数尤度は汎化能力を評価できる値と考えられるが、この平均対数尤度は有限個 N のデータセットで考えると、この場合 m 個をトレーニングセットに使った残りの $(N-m)$ 個のテストセットに対する対数尤度の平均と考えられる。つまり、 \bar{w}^m での平均対数尤度の N 倍を次式のように与える。

$$l^*(\bar{w}^m) = N E_Z [\log f(z/\bar{w}^m)]$$

$$\cong \frac{N}{N-m} \sum_{i=m+1}^N \log f(x_i/\bar{w}^m)$$

ここで $\sum_{i=m+1}^N \log f(x_i/\bar{w}^m)$ を $l(\bar{w}^m, N-m)$ で表記すれば、

$$l^*(\bar{w}^m) \cong \frac{N}{N-m} l(\bar{w}^m, N-m) \quad (5.23)$$

この近似が $(\alpha_Z + \alpha)$ の近似推定のための2つの仮定のうちの第2のものである。

5.2.5 情報量規準 $IC(K, N)$

よって、 l^* が、式 (5.23) の近似式で計算されるものとする、データ N での情報量規準 $IC(K, N)$ は式 (5.11)、式 (5.22) より下式のように与えられる。

$$IC(K, N) = -2 \left\{ l(\bar{w}^N) - E_X [l(\bar{w}^N)] \right\}$$

$$- 2 E_X [r l(\bar{w}^N)]$$

$$+ 2 E_X [(r-1) l(\bar{w}^l)]$$

$$+ 2 E_X \left[l(\bar{w}^l) - \frac{N}{N-l} l(\bar{w}^l, N-l) \right] \quad (5.24)$$

ただし、

$$r = \frac{\frac{N}{N-m} l(\bar{w}^m, N-m) - \frac{N}{N-l} l(\bar{w}^l, N-l)}{l(\bar{w}^m) - l(\bar{w}^l)} \quad (5.25)$$

式 (5.24)、式 (5.25) が我々の一般的な情報量規準の式を与える。これはデータ N での情報量規準が、与えられたデータ N 個から抽出した l 個のデータによる

学習で求めたパラメータ \tilde{w}^l と、同様にデータ N 個から抽出した m 個の学習で得たパラメータ \tilde{w}^m 、与えられたデータ N 個全てを使った学習で得たパラメータ \tilde{w}^N および与えられたデータ N 個によって計算することができることを意味する。

最後に実際の計算方法、つまり式 (5.24) の期待値の計算に関して考える。ここでは、 N 個のデータを l 個、 m 個のデータ数毎に等分割し、その各々のデータ集合に対してパラメータ推定を行い、そのパラメータの組み合わせに従って、期待値の中身について計算を行い、組み合わせの数で平均をとり、これを期待値の計算として近似する。この意味においては $E_X[l(\tilde{w}^N)]$ は $l(\tilde{w}^N)$ で代表させることになり、結局、情報量規準 $IC(K, N)$ は式 (5.26) で定式化される。また近似精度を上げるために、この計算に bootstrap (Efron, 1979) 的手法を応用することもできる。

$$\begin{aligned}
 IC(K, N) = & -2E_X[r l(\tilde{w}^N)] \\
 & + 2E_X[(r-1) l(\tilde{w}^l)] \\
 & + 2E_X\left[l(\tilde{w}^l) - \frac{N}{N-l} l(\tilde{w}^l, N-l)\right] \quad (5.26)
 \end{aligned}$$

5.2.6 仮定に関する検討

5.2.5 節で汎化能力を推定するための情報量規準を示した。本節では、情報量規準の導出に用いた 2 つの仮定について特に情報量規準の推定誤差の観点からの考察を行う。

(1) 第 1 の仮定について

第 1 の仮定は基本的に 2 つの内容を含んでいる。1 点は、下式に示すようにベクトル $R_p(w)$ をスカラー $r(w)$ としている点である。

$$\frac{\partial l^*}{\partial w_p} = R_p(w) \frac{\partial l}{\partial w_p} \quad \Rightarrow \quad \frac{\partial l^*}{\partial w_p} = r(w) \frac{\partial l}{\partial w_p} \quad (A)$$

ただし、 $p = 1, 2, \dots, K$

$$R(w) = (R_1(w), R_2(w), \dots, R_K(w))$$

K : パラメータの数 (自由度)

第 2 の内容としては、上式の $r(w)$ を w によらない定数としている点である。

$$r(w) = r \tag{B}$$

この第1の仮定に含まれる2点の内容は、5.2.3節でも触れたように、データ数 N が十分大きいときには大数の法則より $R_p(w)$ つまり $r(w)$ は漸近的に定数1となる値であり、仮定 (A), (B) を満足することがわかる。このときは、同様な意味において下式 (C) もパラメータ w とは無関係に成立する。

$$\frac{\partial^{(n)} l^*}{\partial w_p^{(n)}} = r \cdot \frac{\partial^{(n)} l}{\partial w_p^{(n)}} \tag{C}$$

つまり、データ数 N が十分に大きいときには、この第1の仮定 (A), (B) は、パラメータを制約することなく成立し、我々の情報量規準は、テーラー展開の高次項を含めた近似精度の高い計算式を与える。

一方、 N が十分大きな数でないとき、(A), (B) の仮定は必ずしも成立するとは言えない。つまり、 r は K 次元のベクトルであり、かつパラメータ w の関数と考えられ、当然 (C) 式も成立しない。このときの我々の提案している情報量規準の誤差について考察する。

$$\frac{\partial l^*}{\partial w_p} = R_p(w) \cdot \frac{\partial l}{\partial w_p}$$

として、 $l^*(\tilde{w}^m)$ の \tilde{w}^l でのテーラー展開を考える。 R_p は w の関数であり K 次元のベクトルとする。ただし、ここではテーラー展開2次までを示すが、以下の議論は高次を含めて成り立つ議論である。いま r^* を適当なスカラー定数とすると、

$$\begin{aligned} l^*(\tilde{w}^m) &= l^*(\tilde{w}^l) + (\tilde{w}^m - \tilde{w}^l) \left[\frac{\partial l^*}{\partial w} \right]_{\tilde{w}^l} + \frac{1}{2} (\tilde{w}^m - \tilde{w}^l) \left[\frac{\partial^2 l^*}{\partial w^2} \right]_{\tilde{w}^l} (\tilde{w}^m - \tilde{w}^l)^T \\ &= l^*(\tilde{w}^l) + r^* (\tilde{w}^m - \tilde{w}^l) \left[\frac{\partial l}{\partial w} \right]_{\tilde{w}^l} \\ &\quad + r^* \frac{1}{2} (\tilde{w}^m - \tilde{w}^l) \left[\frac{\partial^2 l}{\partial w^2} \right]_{\tilde{w}^l} (\tilde{w}^m - \tilde{w}^l)^T \\ &\quad + (\tilde{w}^m - \tilde{w}^l) F_1(\tilde{w}^l) + \frac{1}{2} (\tilde{w}^m - \tilde{w}^l) F_2(\tilde{w}^l) (\tilde{w}^m - \tilde{w}^l)^T \end{aligned}$$

ただし、 r^* はスカラー定数

F_1 は K 次元のベクトルであり、その p 番目の要素 $\{F_1(\tilde{w}^l)\}_p$ は次のように与えられる。

$$\{F_1(\tilde{w}^l)\}_p = (R_p(\tilde{w}^l) - r^*) \left[\frac{\partial l}{\partial w_p} \right]_{\tilde{w}^l}$$

また、 F_2 は $K \times K$ 次元の行列であり、その (q, p) 要素 $\{F_2(\tilde{w}^l)\}_{qp}$ は下式で与えられる。

$$\{F_2(\tilde{w}^l)\}_{qp} = \left[\frac{\partial R_p}{\partial w_q} \right]_{\tilde{w}^l} \left[\frac{\partial l}{\partial w_p} \right]_{\tilde{w}^l} + (R_p(\tilde{w}^l) - r^*) \left[\frac{\partial^2 l}{\partial w_q \partial w_p} \right]_{\tilde{w}^l}$$

$$p, q = 1, 2, \dots, K$$

よって上式を整理すると次式が得られ、この右辺第1項が、5.2.5節で定義した r に相当する。

$$r^* = \frac{l^*(\tilde{w}^m) - l^*(\tilde{w}^l)}{l(\tilde{w}^m) - l(\tilde{w}^l)} - \frac{1}{l(\tilde{w}^m) - l(\tilde{w}^l)} \left\{ (\tilde{w}^m - \tilde{w}^l) F_1(\tilde{w}^l) + \frac{1}{2} (\tilde{w}^m - \tilde{w}^l) F_2(\tilde{w}^l) (\tilde{w}^m - \tilde{w}^l)^T \right\}$$

次に同じ r^* を考えて $l^*(\tilde{w}^N)$ を \tilde{w}^l でテーラー展開して、上の r^* を代入すると次式になる。

$$\begin{aligned} l^*(\tilde{w}^N) &= l^*(\tilde{w}^l) + (\tilde{w}^N - \tilde{w}^l) \left[\frac{\partial l^*}{\partial w} \right]_{\tilde{w}^l} + \frac{1}{2} (\tilde{w}^N - \tilde{w}^l) \left[\frac{\partial^2 l^*}{\partial w^2} \right]_{\tilde{w}^l} (\tilde{w}^N - \tilde{w}^l)^T \\ &= l^*(\tilde{w}^l) + \frac{l^*(\tilde{w}^m) - l^*(\tilde{w}^l)}{l(\tilde{w}^m) - l(\tilde{w}^l)} \left\{ l(\tilde{w}^N) - l(\tilde{w}^l) \right\} \\ &\quad - \frac{l(\tilde{w}^N) - l(\tilde{w}^l)}{l(\tilde{w}^m) - l(\tilde{w}^l)} \left\{ (\tilde{w}^m - \tilde{w}^l) F_1(\tilde{w}^l) + \frac{1}{2} (\tilde{w}^m - \tilde{w}^l) F_2(\tilde{w}^l) (\tilde{w}^m - \tilde{w}^l)^T \right\} \\ &\quad + \left\{ (\tilde{w}^N - \tilde{w}^l) F_1(\tilde{w}^l) + \frac{1}{2} (\tilde{w}^N - \tilde{w}^l) F_2(\tilde{w}^l) (\tilde{w}^N - \tilde{w}^l)^T \right\} \end{aligned}$$

よって、我々の情報量規準は一般的に以下のように与えられる。

$$IC(K, N)$$

$$= -2l(\tilde{w}^N)$$

$$\begin{aligned}
& - 2E_X \left[\left\{ \frac{l^*(\tilde{w}^m) - l^*(\tilde{w}^l)}{l(\tilde{w}^m) - l(\tilde{w}^l)} - 1 \right\} (l(\tilde{w}^N) - l(\tilde{w}^l)) \right] \\
& + 2E_X [l(\tilde{w}^l) - l^*(\tilde{w}^l)] \\
& + 2E_X \left[\frac{l(\tilde{w}^N) - l(\tilde{w}^l)}{l(\tilde{w}^m) - l(\tilde{w}^l)} \left\{ (\tilde{w}^m - \tilde{w}^l) F_1(\tilde{w}^l) + \frac{1}{2} (\tilde{w}^m - \tilde{w}^l) F_2(\tilde{w}^l) (\tilde{w}^m - \tilde{w}^l)^T \right\} \right] \\
& - 2E_X \left[(\tilde{w}^N - \tilde{w}^l) F_1(\tilde{w}^l) + \frac{1}{2} (\tilde{w}^N - \tilde{w}^l) F_2(\tilde{w}^l) (\tilde{w}^N - \tilde{w}^l)^T \right]
\end{aligned}$$

式 (5.24) と上式の比較により、上式の第4, 5項が仮定 (A), (B) が成立しないときの5.2.5節で提案した情報量規準 $IC(K, N)$ の誤差に相当する。そして、この誤差項を最小化するためには、 \tilde{w}^N と \tilde{w}^l が互いに近傍に位置すること、あるいは、 \tilde{w}^N と \tilde{w}^m が互いに近傍に位置すれば第4, 5項が0に収束し、誤差を最小化できることがわかる。つまり、この場合は、 \tilde{w}^N と \tilde{w}^l が互いに近傍に位置すること、あるいは、 \tilde{w}^N と \tilde{w}^m が互いに近傍に位置することがパラメータ推定値に対する制約条件となる。

(2) 第2の仮定について

次に第2の仮定による情報量規準の推定誤差について考察する。ある程度学習の進んだパラメータ推定値に対する平均対数尤度の近似値を考えると、式 (5.23) におけるデータ数 N と m の比が最も影響すると考えるのが妥当である。式 (5.23) の意味としては、パラメータ \tilde{w}^m がデータ m に依存して決定されているため、 \tilde{w}^m に対する平均対数尤度はデータ m に対しては偏っている。そのために、与えられたデータ N から偏りのあるデータ m を除いて、かつ、残りの $(N-m)$ 個のデータが5.2.1節で述べている確率分布 g を十分に反映しているとする仮定での近似式と考えられる。つまり、第2の近似式は情報量規準の誤差を最小化するためには、パラメータ推定値の制約を要請していると言うよりも、データ数 N が m に比べて十分に大きいことを要請している近似式である。

(3) 情報量規準 $IC(K, N)$ の適用について

パラメータ推定値と我々の情報量規準の関係をまとめる。パラメータはいま述べたような条件を満足すれば、パラメータ空間のどの位置に存在しても、その点での

汎化能力の推定が可能であり、かつその値は意味をもつ。しかし、同じ自由度で最も汎化能力の高いモデルを選択するためには、パラメータ推定値が最適値になっていることが要請される。このことは、神経回路網の学習の打ち切りの規準が汎化能力の高いモデルを選択するためには重要であることを意味している。最後に課題で述べるが、我々の提案している情報量規準 $IC(K, N)$ は、神経回路網の学習の打ち切りの規準としても応用できるモデルでもある。

5.3 神経回路網モデルのサイズ選択への適用結果

5.2章までで展開した理論はボルツマンマシン、回帰結合を持った神経回路モデル、多層前向き神経回路モデルなど教師信号との誤差が計算できて、ある種の学習アルゴリズムが与えられている任意の神経回路モデルについて適用できる。特に本章では、理論の有効性を示すために3層神経回路モデルとバックプロパゲーション学習則を例として用いる。

5.3.1 3層神経回路網モデルに対する $IC(K, N)$

本節では図5.3に示すような構造の、多入力1出力の3層神経回路網モデルの中間層のユニットの数を変更して、つまりモデルの自由度を変え、最も汎化能力の高い回路モデルを選択する問題を考える。特に今回のシミュレーションで使ったユニットは、入力層は線形関数、中間層はシグモイド関数、および出力層のユニットとしては線形関数を用いている。

神経回路網モデルの出力 y と、教師信号 T との関係を次のように考える。

$$T = y + \varepsilon$$

$$= \sum_j^H w_{j1}^{23} S_j \left(\sum_i^M w_{ij}^{12} x_i + \theta_j \right) + \varepsilon$$

ただし、 w_{ij}^{12} : 入力層第 i ユニットから中間層第 j ユニットへの荷重

w_{j1}^{23} : 中間層第 j ユニットから出力層ユニットへの荷重

M : 入力層ユニットの数

H : 中間層ユニットの数

S_j : 中間層第jユニットのシグモイド関数

θ_j : 中間層第jユニットの閾値

誤差 ε を平均 0, 分散 σ^2 の正規分布とする.

$$\varepsilon \sim N(0, \sigma^2)$$

次に N 個の入出力データの組 $(X_k, Y_k) (k=1, \dots, N)$ に対して, 尤度関数を計算する.

$$\begin{aligned} l(w_{ij}^{12}, w_{j1}^{23}) &= \log \prod_{k=1}^N \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(T_k - y_k)^2}{2\sigma^2}\right\} \\ &= -\frac{N}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{k=1}^N (T_k - y_k)^2 \end{aligned}$$

学習で得られたパラメータ, 閾値を \tilde{w}_{ij}^{12} , \tilde{w}_{j1}^{23} , $\tilde{\theta}_j$ とすれば, 誤差 ε の分散 σ^2 の

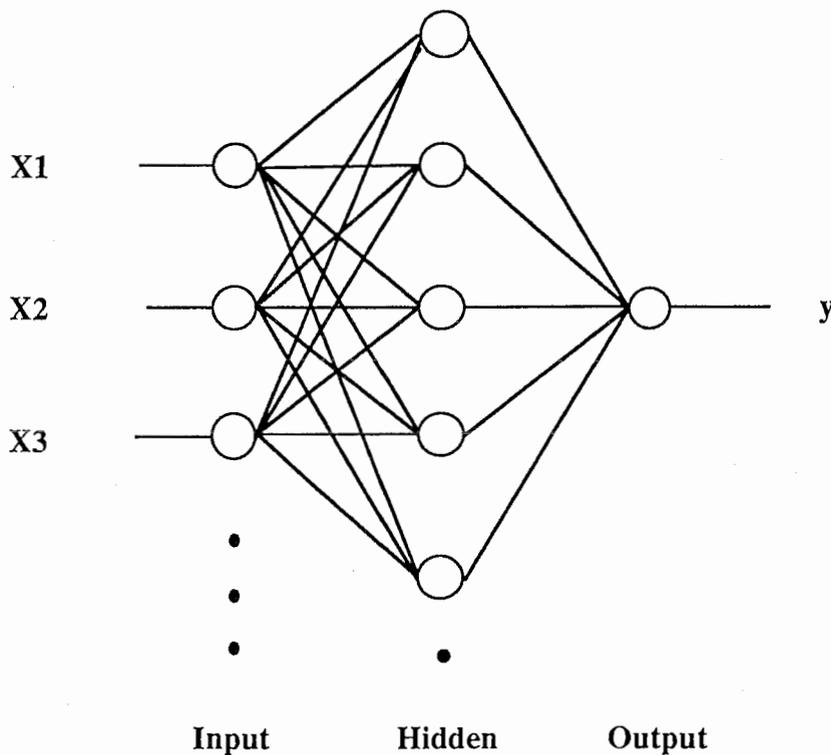


図 5.3 3層神経回路網モデルの構造

Fig 5.3 Structure of 3 layered neural network model

推定量は下式で求めることができる（竹内，1989）。

$$\sigma^2 = \frac{1}{N} \sum_{k=1}^N (T_k - \bar{y}_k)^2$$

故に，次式となる。

$$l(\bar{w}_{ij}^{12}, \bar{w}_{j1}^{23}) = -\frac{N}{2} \log\left(\frac{2\pi}{N} \sum_{k=1}^N (T_k - \bar{y}_k)^2\right) - \frac{N}{2}$$

$$\text{ただし } \bar{y} = \sum_j^H \bar{w}_{j1}^{23} S_j \left(\sum_i^M \bar{w}_{ij}^{12} x_i + \bar{\theta}_j \right)$$

結局，図 5.3 の構造の神経回路網の自由度を閾値も含めたシナプス荷重の数（入力ユニット数 M +出力ユニット数 1 +閾値ユニット 1 ）*(中間層ユニット数 H)と考えると， $IC((M+1+1)H, N)$ は 2 乗誤差の和を計算することで式 (5.24)，式 (5.25) より求めることができる。

5.3.2 適用結果

以下に 2 つの例題について，この情報量規準を適用した結果を示す。

(1) 例 1

例 1 は運動制御の逆ダイナミクス問題であって，教師信号として次式を与えている。

$$T = \frac{15\ddot{\theta} + 10\text{sigmoid}(5\dot{\theta}) + 9.8\sin(\theta)}{\cos(\theta)}$$

入力データとしては $\pm 75\pi / 180$ 区間の一様乱数データを 800 個与えている。

またこの例で使った神経回路網モデルの中間層ユニットは閾値項を 0 としている。

図 5.4 で示している $IC(4H, 800)$ は， $r=1$ として，800 個のデータの中から任意の 100 個のデータをサンプルした 1 セットによって学習して得たパラメータを \bar{w}^1 ，

800 個のデータを使って学習したパラメータを \bar{w}^N として， $IC(K, N)$ の計算

をしている。このシミュレーションでは $IC(K, N)$ の推定式に含まれている期

待値の演算はやっておらず，単に，前述した 100 個のデータ 1 セットの値によっ

て，期待値の演算を代表させている。検証のために，学習に使っていない未知のデ

ータ 800 個のデータに対して，

$$\text{test_data} = (-2) l(\bar{w}_{4H}^{800})$$

を計算してプロットしている。この場合中間層4ユニットが最も汎化能力の高い回路モデルとして選択される。 *test_data* と IC の値に若干の誤差はあるが、ほぼ *test_data* の大小関係と IC の大小関係の傾向は一致しており、このシミュレーションにおいて IC が汎化能力の高いモデルを選択するのに有効な情報量規準であることがわかる。

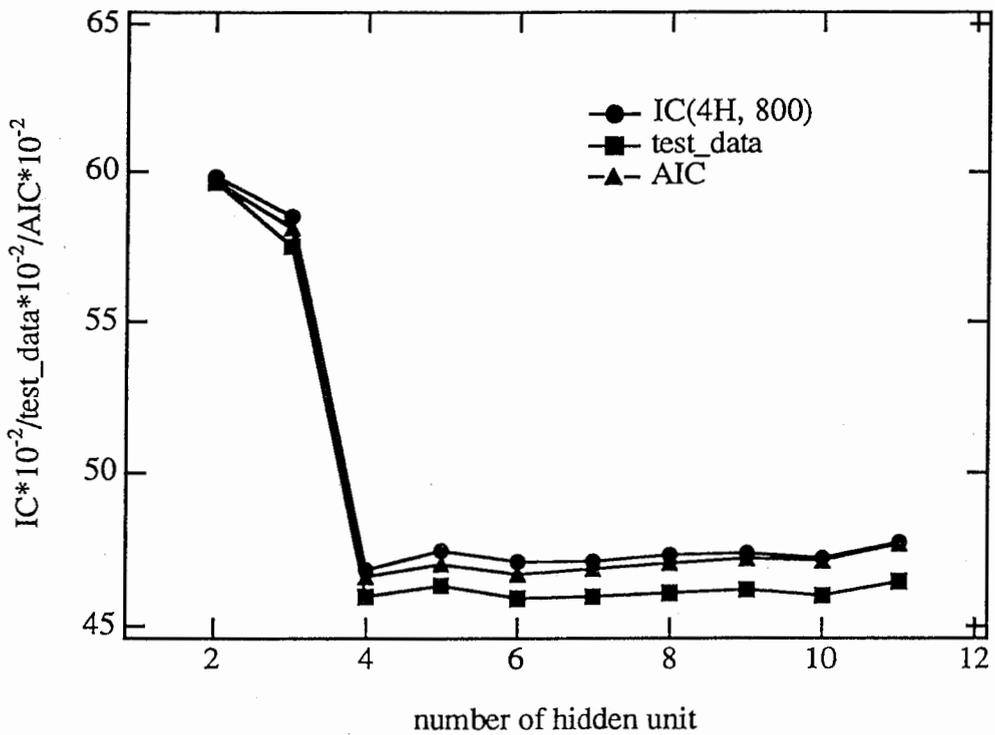


図 5.4 情報量規準と汎化能力 (1)

Fig5.4 Information criterion and generalization capability(1)

(2) 例2

例2では教師信号として次式を与えている.

$$T = \frac{0.3}{1 + \exp(-12.5(x - 10))} + \frac{0.2}{1 + \exp(-12.5x)} + \frac{0.1}{1 + \exp(-0.125(x + 10))} + \varepsilon$$

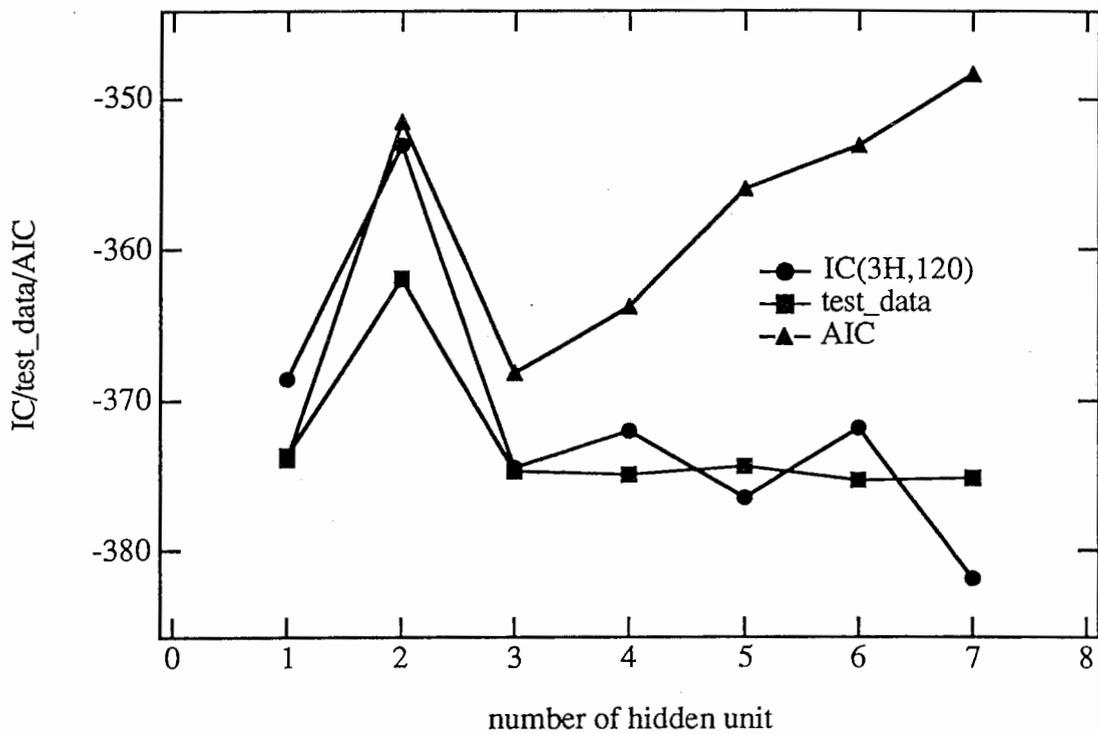


図5.5 情報量規準と汎化能力(2)

Fig 5.5 Information criterion and generalization capability(2)

ε は平均0, 標準偏差0.005の正規分布に従う誤差である. データとしては±15の区間の一様乱数データ120個を与えている. このシミュレーションでは, 120個のデータを30データ毎に4分割して, 各々のデータセットに対して学習して各々 \tilde{w}^{30} を求めている. また60データ毎に2分割したデータに対して学習することによって \tilde{w}^{60} を求めている. この場合 \tilde{w}^{30} を \tilde{w}^l , \tilde{w}^{60} を \tilde{w}^m としている. 図5.5には, これらのデータセットから計算した情報量規準 $IC(3H, 120)$ を示している.

(入力ユニット1, 出力ユニット1, 閾値項定数入力ユニット1) また, (1)と同様にこの規準の検証のために, 同じ分布に従う未知のデータ2400個のデータに対して

$$test_data = (-2) \frac{120}{2400} l(\tilde{w}_{3H}^{120})$$

を計算したものをプロットしている. 実際に汎化能力の程度を表す $test_data$ と IC は良く一致しており IC が汎化能力を示す情報量規準であることがこのことからわかる. また, この例においては, 中間層ユニットが7ユニットのモデルが最も汎化能力の高いモデルとして選択され, その結果は $test_data$ の結果とほぼ一致する. しかしながら AIC については, この例においては, 中間層1ユニットの回路モデルを選択することになり, 実際のデータである $test_data$ とは異なる結果を与える. つまり, 多層前向き神経回路網モデルのように厳密に最尤推定量が求められない非線形モデルの選択においては, 今回提案したような方法によって, 汎化能力の高いモデルの選択をすることが有効であることがわかる. 今回我々が提案した神経回路網モデルの情報量規準の推定方法は, AIC が要求している最尤推定量を必要としていない. この点が, AIC に比べて計算量の多い本方法の有効な点である. 特に多くの神経回路網モデルのような非線形モデルにおいては, 有限時間内で, 最尤推定量を得ることは非常に困難なことである. したがって最尤推定量を要請せずに情報量規準を推定できることは, 広いクラスの非線形モデルについて有益であると考えられる.

5.4 おわりに

我々は神経回路網モデルのような非線形モデルの選択問題, つまりどの程度の数のユニットやシナプス荷重を準備したら汎化能力の高いモデルとなるか, という問題に対して, 最尤推定量が求められない場合について Cross Validation を使って情報量

規準を求める方法を提案した。またシミュレーション実験の結果から、この規準によって与えられたデータを最大限に使うことで汎化能力の高い神経回路網モデルの選択が可能であることを示した。この方法は、非線形モデルのように最尤推定量が有限時間内で求めることが困難な問題では有効な方法である。また、例として示したバックプロパゲーションなどの学習方式によらず、尤度関数が計算可能な問題に対して適用することが可能な一般的方法である。

我々の提案している情報量規準の計算量に関して、他の情報量規準との比較で定性的に論じておく。神経回路網モデルのような非線形モデルで、解析的に最尤推定量を得ることが困難な問題においては、AICなどのように最尤推定量に基づいた情報量規準は、その条件を満足するために多大の時間を要するのが通常であるし、逆に、最尤推定量の制約を満足しないパラメータ推定値でその情報量規準を計算した場合には、その誤差は大きくなると考えられる。一方Ishiguroら (Ishiguro & Sakamoto, 1990; 北川ら, 1993) は、bootstrapの手法を応用して、最尤推定量を必要としない情報量規準を提案しているが、この方法は制約条件を緩和しているが、bootstrapの手法を応用しているために非常に多くのbootstrapサンプルに対してパラメータ推定を行う必要があり、その計算量は多大であるが、誤差の少ない情報量規準を推定できると期待される。我々の提案している情報量規準は、複数のサンプル集合に対してパラメータ推定を行う必要があるが、その数はbootstrapサンプル集合の数ほど多くない。また、最尤推定量を要求するほど厳しくないパラメータに関する制約条件で、誤差の少ない情報量規準を推定できる。この意味において我々の情報量規準が、有効な方法であることがわかる。

今後の課題としては少なくとも次の2点がある。まず神経回路網の学習において、学習をどのタイミングで打ち切ることが、汎化能力の高い回路網モデルを得るために必要なのかという問題がある。これも本論文で展開した方法と本質的に同じ方法で解決できると思われる。これが第1の課題である。第2には、本論文で示した簡単な例ではなく、現実世界の大規模な問題について、ここで提案した方法の有効性を示すことである。より現実的な問題で推定できるパラメータは最尤推定量からのずれが、簡単な例より大きいと思われるから、本方法の有効性がより際立つと期待している。

第 6 章

結 言

6.1 研究成果の要約

本研究は、運動制御に関する計算論的アプローチの成果である運動規範に基づいた運動パターンの生成と認識に関して、筆者がこれまで行ってきた研究成果をまとめたものである。以下にその成果を要約する。

第1章では、運動規範（トルク変化最小規範）に基づいた運動パターンの生成と認識に関する本研究の背景を述べ、それらの問題点を明らかにした。本研究の基本的な考え方を示し、本論文の構成について記述した。

第2章では、制御対象の順・逆ダイナミクスモデルを使った最適化モデル（FIRM: Forward-Inverse Relaxation Model）を提案し、これによるトルク変化最小規範に基づいた人の腕の最適軌道を生成するモデルを示し、数値実験と人間による計測実験の結果から、このモデルによって生成される軌道が、トルク変化最小規範の最適解に非常に近く、かつ、人間の軌道に定性的に近いことを示した。そして、従来のモデルに対する以下の3点の批判を克服するモデルであることを示した。（1）時間を空間的に表現したモデルである。（2）解を得るために時間逆方向の計算を必要とする。（3）最適解を得るために多くの繰り返し計算を必要とする。また、このモデルが簡単に経由点のある運動に対しても拡張され、有効であることを示した。最後に、このモデルの理論的検討を行い、ある種の非線形最適化問題の一般的解法であることを示し、本モデルが他の工学的な問題に対しても応用が可能であることを述べた。

第3章では、第2章で提案した軌道生成モデルを応用した書字運動モデルを提案した。この書字運動モデルでは、文字を複数の経由点を通る運動によって生成された軌道と考え、経由点の集合を文字の表現形式とし、軌道生成モデルFIRMをアルゴリズムとするモデルである。このモデルの表現形式である経由点は、与えられた文字軌道から推定されるが、そのための経由点推定モデルを提案した。このモデルは、やはりトルク変化最小規範に基づいたモデルであり、理論的にこのモデルが、与えられた軌道を再構成するに必要十分な数の経由点を選択するモデルであることを示した。また、実験によって、経由点推定モデルが抽出する点が、運動の経由点

に対応していることを示し、抽出された点が、従来から指摘されていた曲率の最大点や速度の極小点に対応する点を含んでいることを明らかにした。実際に連続文字の軌道にこのモデルを適用して、推定される点が文字の区切り点の候補として有効であることを実験的に示した。また、経路点推定モデルは調音器官の運動に対しても適用され、与えられた軌道を再現する観点から考えて、非常に妥当な点を推定しており、かつ、情報圧縮の面からも有効であることを示した。

第4章では、経路点推定モデルと書字運動モデルを使った手書き連続文字の認識モデルを提案した。経路点推定モデルによって抽出された経路点を文字の区切りの候補として、文字の区切りから文字の区切りの間の経路点を正規化して、再構成し、テンプレートとの比較を行うパターン認識システムによって、連続文字の認識が行えることを示した。また、調音器官に適用した結果が、音韻の時刻と良く一致していることを音響信号とスペクトラムの解析結果から示した。そして、“音声知覚の運動説”に基づいて、音声認識にも文字認識と同様に軌道生成モデルを考慮した音声知覚モデルが可能であることを指摘した。

第5章では、第4章までに述べたモデルを神経回路網で実現する際の方法論を議論した。汎化能力の高い神経回路網を選択する問題に対して、AIC (Akaike Information Criterion) を基本とした新しい情報量規準を提案した。この規準は、神経回路網モデルのような非線形モデルの選択問題において、パラメータの最尤推定量を得ることが困難な問題に対して有効であり、数値実験によって汎化能力の高いモデルが選択できることを示した。

6.2 今後の研究課題

本研究の今後の研究課題を述べる。

第2章では、関節でのトルクを滑らかにするように運動計画する規範であるトルク変化最小規範に従った軌道生成モデルを提案したが、生体系では関節でのトルクを発生させるためには筋の張力を計算しなければならず、トルク変化最小規範は、筋張力変化最小規範や運動指令（運動の制御信号）変化最小規範と言った、より生体系に即したモデルに発展してきている。このような規範に対し、提案したモデルの実現の可能性を検討し、脳のモデルとしての妥当性を研究していくことが今後の課題の1つである。特に、人の関節には多くの筋が作用しており冗長なシステムを

構成している。その筋張力を決めることは不良設定の問題を解かなければならず、理論的にも重要な課題である。また、順モデルと逆モデルが完全な逆関数の関係がないときの本モデルの有効性の確認、平滑化操作のクラスの定義および一般的な評価関数に対する拡張などが第2章で提案した軌道生成のモデルに対する今後の研究課題である。

第3章で提案した書字運動モデルでは、経由点時間の最適化は考慮されておらず、推定された経由点の時間を用いている。この時間の最適化をはかることは、今後の課題の1つである。

第4章では、第3章で提案した書字運動モデルおよび経由点推定モデルを応用した比較的簡単な文字認識システムに応用して連続文字の認識の可能性を示したが、例えば、'e'と'l'に表される正規化などの問題を解決すると共に、大量のデータに対して適用することによって実用化への課題を検討する必要がある。

また、本章では、経由点推定モデルが調音器官の運動にも応用できることを示し、推定された点が音韻と良く対応することを示したが、音韻と推定される経由点の関係を、やはり、数多くの事例で確認すること、および、音声認識への可能性を検討することが今後の重要な研究課題である。

第5章では、神経回路網モデルに対する新しい情報量規準を提案したが、今後の課題として、まず神経回路網の学習において、学習をどのタイミングで打ち切ることが、汎化能力の高い回路網モデルを得るために必要なのかという問題がある。本論文で提案した方法と本質的に同じ方法で解決できるかどうか検討する必要がある。第2の課題として、本論文で示した簡単な例ではなく、現実世界の大規模な問題について、本論文で提案した方法の有効性を示す必要がある。より現実的な問題で推定できるパラメータは最尤推定量からのずれが、簡単な例より大きいと思われるから、本方法の有効性がより際立つことが示されると期待できる。

6.3 むすび

本論文では、主として脳の計算論的アプローチからの成果であるトルク変化最小規範に基づいたモデルを提案してきた。これらのモデルが当初の”脳に学んだ情報処理機構”として、工学的分野である制御やパターン認識において僅かながらも貢献できることを筆者は期待している。各々のモデルに対する課題は6.2節で述べた

が、最も大きな課題は、これらのモデルの応用や実用化に対する検討であると考えられる。特にパターン認識の分野での信頼のあるシステムを構成するためには、本研究での成果は、その緒についたに過ぎない。また、脳の計算論的な面から考えても、提案したモデルの妥当性は大きな研究課題であるし、人間の筋骨格系のような冗長なシステムに則したモデルの発展が重要であると考えている。

謝 辞

本論文をまとめるにあたり東京工業大学総合理工学研究科知能科学専攻 小林重信 教授には丁寧なる御指導と、御教示を賜りました。ここに、慎んで深謝の意を表します。また、論文をまとめるに際し、東京工業大学総合理工学研究科システム科学専攻 原辰次 教授、原口 誠 助教授、同像情報工学研究所 長橋 宏 助教授、さらに同精密工学研究所 小林隆夫 助教授には、有益な御討論、御助言を賜りました。ここに記し、深く感謝致します。また、統計的モデル選択について有益な御助言を頂いた統計数理研究所の田辺國士 教授、伊庭幸人 博士をはじめとする皆様に感謝します。

本研究は、筆者が（株）ATR視聴覚機構研究所および（株）ATR人間情報通信研究所に在籍中に行われたものであり、研究の機会を与えて頂いた（株）ATR視聴覚機構研究所 淀川英司社長（現 工学院大学教授）、同認知機構研究室 中根一成室長（現 NTT ヒューマンインターフェース研究所グループリーダー）および（株）ATR人間情報通信研究所 東倉洋一社長、同第3研究室 川人光男室長に感謝致します。

特に川人光男室長には、本研究が緒についたおりから、終始有益な御議論および適切な御教示を賜りました。ここに、慎んで深謝の意を表します。また、本研究の途上において貴重な御討論および御協力を頂いた同第3研究室内の宇野洋二 主任研究員、安藤広志 研究員、片山正純 研究員（現（株）三洋電機）、早川秀樹 研究員、平山亮 研究員、五味裕章 研究員、小池康晴 研究員、鈴木敏 研究員、今水寛 客員研究員、Frank Pollick客員研究員、渡辺洋 研究員および大須理英子 研究員の 諸氏に心から感謝致します。特に小池康晴 研究員および同第4研究室 Eric Vatikiotis-Bateson客員研究員には、貴重なデータを提供頂いた。付記して感謝の意を表します。また、同第六研究室 佐藤雅昭 主任研究員には、貴重な御議論を頂きました。心から感謝致します。ならびに多くの御助言を頂いた（株）ATR人間情報通信研究所の皆様にも心から感謝致します。

なお、筆者の出向元である（株）川崎製鉄システム・エレクトロニクス事業部開発部 守谷正一 部長、同千葉製鉄所制御技術部 前田正和 部長をはじめとする（株）川崎製鉄の皆様には多大な御援助を頂きました。諸氏にも心から御礼申し上げます。

[参考文献]

- Abend, W., Bizzi, E., & Morasso, P. (1982). Human arm trajectory formation. *Brain*, **105**, 331-348.
- Abu-Mostafa, Y. S. (1989). The Vapnik-Chervonenkis Dimension : Information versus Complexity in Learning. *Neural Computation*, **1**, 312-317.
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, **AC-19**(6), 716-723.
- 赤池弘次 (1976). 情報量規準AICとは何か —その意味と将来への展望. *数理科学* (pp. 5-11). サイエンス社.
- 甘利俊一 (1966). パターン信号の特徴空間における正規化理論. *電子情報通信学会誌*, **49**(7), 1342-1350.
- 麻生秀樹 (1992). 期待損失最小化学習のための評価基準について. *神経回路学会第3回全国大会*, (pp. 34-35).
- Babcock, M. K., & Freyd, J. J. (1988). Perception of dynamic information in static handwritten forms. *American journal of psychology*, **101**(1), 111-130.
- Baum, E. B., & Haussler, D. (1989). What size net gives valid generalization ? *Neural Computation*, **1**, 151-160.
- Bryson, A., & Ho, Y. (1975). *Applied optimal control*. New York: Wiley.
- Corrieu, P., & De Falco, S. (1989). Segmental vs. dynamic analysis of letter shape by preschool children. *European Bulletin of Cognitive Psychology*, **9**(2), 189-198.
- Dornay, M., Uno, Y., Kawato, M., & Suzuki, R. (1992). Simulation of optimal movements using the minimum-muscle-tension-change model. In J. E. Moody, S. J. Hanson, & R. P. Lippmann (Eds.), *Advances in Neural Information Processing Systems 4* (pp. 627-634). San Mateo, CA: Morgan Kaufmann Publishers.
- Edelman, S., & Flash, T. (1987). A Model of Handwriting. *Biological Cybernetics*, **57**, 25-36.
- Edelman, S., Ullman, S., & Flash, T. (1990). Reading cursive handwriting by alignment of letter prototypes. *International Journal of Computer Vision*, **5**(3), 303-331.
- Efron, B. (1979). Bootstrap Methods : Another Look at the Jackknife. *The Annals of Statistics*, **7**(1), 1-26.

- Flash, T., & Hogan, N. (1985). The coordination of arm movements ; An experimentally confirmed mathematical model. *The Journal of Neuroscience*, *5*(7), 1688-1703.
- Freyd, J. J. (1983). Representing the dynamics of a static form. *Memory & Cognition*, *11*, 342-346.
- Freyd, J. J. (1992). Five hunches about perceptual processes and dynamic representations. In D. E. Meyer & S. Kornblum (Eds.), *Attention and Performance XIV* (pp. 99-119). Cambridge, MA: MIT Press.
- Fukushima, K., & Imagawa, T. (1993). Recognition and Segmentation of Connected Characters With Selective Attention. *Neural Networks*, *6*, 33-41.
- 船橋賢一 (1988). ニューラルネットワークの capability について. *信学技法*, MBE 88-52, 127-134.
- 二見亮弘, & 星宮 望 (1990). 階層構造の神経回路モデルによる時系列パターンの発生と認識. *信学技法*, NC90-6, 39-46.
- Haken, H., Kelso, J. A. S., Fuchs, A., & Pandya, A. S. (1990). Dynamic pattern recognition of coordinated biological motion. *Neural Networks*, *3*, 395-401.
- 早川秀樹, 川人光男, & 乾敏郎 (1991). 単眼立体視における陰影による形状知覚の計算論的モデル. *信学技法*, NC91-9, 63-70.
- 早川秀樹, 川人光男, & 乾敏郎 (1992). 陰影による形状知覚の階層的計算モデル. *電子情報通信学会論文誌 D-II*, J75-D-II(11), 1940-1947.
- Hinton, G. E., Williams, C. K. I., & Revow, M. D. (1992). Combining Two Methods of Recognizing Hand-Printed Digits. In I. Aleksander & J. Taylor (Eds.), *Artificial Neural Networks*, 2 (pp. 53-60). Elsevier Science Publishers B. V.
- 平山亮, Vatikiotis-Bateson, E., 川人光男, & Jordan, M. I. (1992). 筋電信号を用いた調音器官筋骨格系ダイナミクスモデル. *電子情報通信学会論文誌 D-II*, J75-D-II(8), 1430-1439.
- Hirayama, M., Vatikiotis-Bateson, E., Honda, K., Koike, Y., & Kawato, M. (1993). Physiologically based speech synthesis. In C. L. Giles, S. J. Hanson, & J. D. Cowan (Eds.), *Advances in Neural Information Processing Systems 5* San Mateo, CA: Morgan Kaufmann Publishers.
- Hoff, B., & Arbib, M. A. (1992). Models of trajectory formation and temporal interaction of reach and grasp. *Journal of Motor Behavior* (submitted to).
- Hoffman, J., Skrzypek, J., & Vidal, J. J. (1993). Cluster Network for Recognition of

- Handwritten, Cursive Script Characters. *Neural Networks*, 6, 69-78.
- Hollerbach, J. M. (1981). An oscillation theory of handwriting. *Biological Cybernetics*, 39, 139-156.
- 誉田雅彰, & 鏑木時彦 (1993). ニューラルネットワークを用いた調音・音響マッピングの推定. *信学技法*, SP92-144, 57-64.
- 飯島泰蔵 (1962). パターンの正規化に関する基礎理論 (典型的な 1 次元パターンの場合). *電気試験所彙報*, 26(5), 368-388.
- 飯島泰蔵 (1963). パターン認識の理論. *電子通信学会誌*, 46(11), 1582-1591.
- Irie, B., & Miyake, S. (1988). Capabilities of Three-layerd perceptrons. In *IEEE International conference on Neural Networks*, (pp. 641-648). San Diego.
- Ishiguro, M., & Sakamoto, Y. (1990). EFIC : An Estimator - Free Information Criterion. Research Memorandum #381. The Institute of Stastical Mathematics.
- Jordan, M. I. (1989). Indeterminate motor skill learning problems. In M. Jeannerod (Eds.), *Attention and Performance XIII* (pp. 99-119). Cambridge, MA: MIT Press.
- Jordan, M. I., & Rumelhart, D. E. (1992). Forward models : Supervised learning with a distal teacher. *Cognitive Science*, 16.
- 嘉納秀明 (1987). システムの最適理論と最適化. コロナ社.
- 川人光男 (1986). 随意運動制御における適応と学習. *日本ロボット学会誌*, 4(4), 184-193.
- Kawato, M. (1989). Motor theory of speech perception revisited from minimum torque-change neural network model. In *8th Symposium on Future Electron Devices*, (pp. 141-150). Tokyo, Japan.
- Kawato, M., Furukawa, K., & Suzuki, R. (1987). A hierarchical neural - network model for control and learning of voluntary movement. *Biological Cybernetics*, 57, 169-185.
- Kawato, M. (1990a). Computational schemes and neural network models for formation and control of multijoint arm trajectory. In T. Miller, R. S. Sutton, & P. J. Werbos (Eds.), *Neural networks for control* (pp. 197-228). Cambridge, MA: M.I.T. Press.
- Kawato, M., Maeda, Y., Uno, Y., & Suzuki, R. (1990b). Trajectory formation of arm movement by cascade neural network model based on minimum torque-change criterion. *Biological Cybernetics*, 62, 275-288.
- 川人光男, & 乾敏郎 (1990). 視覚大脳皮質の計算理論. *電子情報通信学会論文誌 DII*, 73-DII(8), 1111-1121.
- Keeler, J. D., Rumelhart, D. E., & Loew, W. (1991). Integrated segmentation and recognition of

- hand-printed numerals. In J. E. Moody & D. S. Touretzky (Eds.), *Advances in Neural Information Processing Systems 3* San Mateo, CA: Morgan Kaufmann Publishers.
- Kelso, J. A. S., & Pandya, A. S. (1989). Dynamic pattern generation and recognition. In D. Zeltzer, N. Badler, & B. Barsky (Ed.), *NSF Workshop on "Mechanics, Control and Animation of Articulated Figures"*, M. I. T., Cambridge, MA: Morgan Kaufmann Publishers.
- 北川源四郎, 石黒真木夫, & 坂元慶行 (1993). 情報量規準AICとEIC. *信学技法*, IT92-133, 49-62.
- 小池康晴, 本多清志, 平山亮, 五味裕章, E. Bateson, & 川人光男 (1992). 筋電信号を用いた人腕のフォワードダイナミクスモデル. *信学技法*, NC91-146, 107-114.
- 小池康晴, & 川人光男 (1993). 神経回路網モデルを用いた表面筋電信号からの人腕の軌道生成. *信学技法*, NC92-125, 237-244.
- 栗田多喜夫 (1989). ニューラルネットにおけるモデル選択の試み. *信学技法*, PRU 89-16, 17-22.
- 栗田多喜夫 (1990). 情報 規準による 3層ニューラルネットの隠れ層のユニット数の決定法. *電子情報通信学会論文誌 D-II*, J73-D-II(11), 1872-1878.
- Lang, K. J., Waibel, A. H., & Hinton, G. E. (1990). A time-delay neural network architecture for isolated word recognition. *Neural Networks*, 3.
- Le Cun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. *Neural Computation*, 1, 541-551.
- Lieberman, A. M., & Mattingly, I. G. (1985). The motor theory of speech perception revised. *Cognition*, 21, 1-36.
- 前田芳晴, 川人光男, 宇野洋二, & 鈴木良次 (1989). カスケード構造の神経回路モデルによるヒト上肢多関節運動軌道の生成. *信学技法*, MBE88-169, 79-84.
- Marr, D. (1982). *Vision*. New York: Freeman. 乾 敏郎, 安藤広志, (邦訳) (産業図書).
- Massone, L., & Bizzi, E. (1989). A neural network model for limb trajectory formation. *Biological Cybernetics*, 61, 417-425.
- Mermelstein, P., & Eden, M. (1964). Experiments on computer recognition of connected handwritten words. *Information and Control*, 7, 255-270.
- 三井武友 (1981). 微分方程式の境界値問題とニュートン法. *数理科学* 218 (pp. 41-46). サイエンス社.

- Moody, J. E. (1991). Note on generalization, regularization, and architecture selection in nonlinear learning systems. In B. H. Juang, S. Y. Kung, & C. A. Kamm (Eds.), *Neural Networks for Signal Processing* (pp. 1-10). Piscataway, NJ.: IEEE Press.
- Moody, J. E. (1992). The effective number of parameters: An analysis of generalization and regularization in nonlinear learning systems. In J. E. Moody, S. J. Hanson, & R. P. Lippmann (Eds.), *Advances in Neural Information Processing Systems 4* (pp. 847-854). San Mateo, CA: Morgan Kaufmann Publishers.
- Morasso, P., & Mussa Ivaldi, F. A. (1982). Trajectory formation and handwriting: A computational model. *Biological Cybernetics*, **45**, 131-142.
- Morasso, P. (1989). Neural models of cursive script handwriting. In *Proceedings of the International Joint Conference on Neural Networks, VII* (pp. 539-542). Washington, DC.
- Morasso, P., Pareto, A., & Pagliano, S. (1992). Neural models for handwriting recognition. In S. Impedovo & J. C. Simon (Eds.), *From Pixels to Features III: Frontiers in handwriting recognition* (pp. 423-440). Elsevier Science Publishers B.V.
- Morgan, N., & Bourlard, H. (1990). Generalization and parameter estimation in feedforward nets: some experiments. In D. S. Touretzky (Eds.), *Advances in Neural Information Processing Systems 2* (pp. 630-637). San Mateo, CA: Morgan Kaufmann Publishers.
- 森 吉弘 (1990). PDPモデルによる手書き漢字認識. *電子情報通信学会論文誌 D-II*, **J73-D-II(8)**, 1268-1274.
- Murata, N., Yoshizawa, S., & Amari, S. (1992). Neural Information Criterion - Determining the number of hidden units for an artificial neural network model. METR 92-05. The university of Tokyo.
- 中村雅之, 宇野洋二, 鈴木良次, & 川人光男 (1990). 逆ダイナミクス内部モデルを用いた腕の最適軌道生成. *信学技法*, **NC89-63**, 13-18.
- 長石道博 (1993). 視覚の誘導場を用いた手書き文字切り出しの検討. *信学技法*, **PRU 92-120**, 17-24.
- 長尾真 (1983). *パターン情報処理*. コロナ社.
- Ojika, T., & Kasue, Y. (1979). Initial-value adjusting model for the solution of nonlinear multipoint boundary-value problems. *J. Math. Anal. Appl.*, **69**, 359-371.
- 大津展之 (1981). パターン認識における特徴抽出に関する数理的研究. *電子技術総合研究所研究報告 第818号*.
- Papcun, J., Hochberg, J., Thomas, T. R., Laroche, T., Zacks, J., & Levy, S. (1992). Inferring

- articulation and recognition gestures from acoustics with a neural network trained on x-ray microbeam data. *Journal of Acoustical Society of America*, **92**(2), Pt. 1.
- Poggio, T., Torre, V., & Koch, C. (1985). Computational vision and regularization theory. *Nature*, **317**, 314-319.
- Rissanen, J. (1978). Modeling by shortest data description. *Automatica*, **14**, 465-471.
- Rissanen, J. (1983). A universal prior for integers and estimation by minimum description length. *The Annals of Statistics*, **11**(2), 416-431.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning Representations by Back Propagating Errors. *Nature*, **323**(9), 533-536.
- Rumelhart, D. E. (1993). Theory to practice: A case study - recognizing cursive handwriting. In E. B. Baum (Eds.), *SIAM Frontier Series* (pp. 177-196). Philadelphia:
- 坂元慶行, 石黒真木夫, & 北川源四郎 (1983). 情報量統計学. 共立出版.
- 桜井 明 編著 (1981). スプライン関数入門. 東京電機大学出版局.
- 白井克彦 (1990). 音声認識における特徴抽出. *電子情報通信学会誌*, **73**(12), 1269-1275.
- Shirai, K., & Kobayashi, T. (1991). Estimation of articulatory motion using neural networks. *Journal of Phonetics*, **19**, 379-385.
- Simard, P., & Le Cun, Y. (1992). Reverse TDNN: An architecture for trajectory generation. In J. E. Moody, S. J. Hanson, & R. P. Lippmann (Eds.), *Advances in Neural Information Processing Systems 4* San Mateo, CA: Morgan Kaufmann Publishers.
- 竹内 啓 (1976). 情報統計量の分布とモデルの適切さの規準. *数理科学* (pp. 12-18). サイエンス社.
- 竹内啓編. (1989). 統計学辞典. 東洋経済新報社.
- 高木貞治 (1983). 解析概論 (改訂第3版). 岩波書店.
- Tappert, C. C., Suen, C. Y., & Wakahara, T. (1990). The state of the art in on-line handwriting recognition. *IEEE Transactions on pattern analysis and machine intelligence*, **12**(8), 787-808.
- Tishby, N., Levin, E., & Solla, S. (1989). Consistent Inference of Probabilities in Layered Networks: Predictions and Generalization. In *Proceedings of the International Joint Conference on Neural Networks, II* (pp. 403-409). Washington, D. C: IEEE.
- 戸田尚宏, 萩原克幸, & 白井支朗 (1990). 多層ニューラルネットワークによるデータフィッティング - 情報統計量による構造決定 -. *信学技法*, **NC 89-100**, 61-66.
- 宇野洋二, 川人光男, & 鈴木良次 (1988). ロボットマニピュレータの最適軌道に対する繰返し学習制御. *計測自動制御学会論文誌*, **24**(8), 837 - 843.

- Uno, Y., Kawato, M., & Suzuki, R. (1989). Formation and control of optimal trajectory in human arm movement - minimum torque-change model. *Biological Cybernetics*, **61**, 89-101.
- 宇野洋二, 鈴木良二, & 川人光男 (1989). 腕の運動軌道を再現する筋張力変化最小モデル. 第4回生体生理工学シンポジウム論文集, (pp. 299-302).
- Waibel, A., Hanazawa, T., Hinton, G. E., Shikano, K., & Lang, K. (1989). Phoneme recognition using time-delay neural networks. *IEEE Transactions on Acoustics, Speech and Signal Processing*.
- Yasuhara, M. (1975). Experimental studies of handwriting process. *Rep. Univ. Electro-comm*, 25-2(Sci. & Tech. Sect), 233-254.

[本論文に対する原著論文]

< 学術論文 >

- 和田安弘, & 川人光男 (1991). 新しい情報量規準と Cross Validation による汎化能力の推定. 電子情報通信学会論文誌 D-II, J74-D-II(7), 955-965.
- 和田安弘, & 川人光男 (1992). 制御対象の順・逆モデルを含む神経回路網による腕の軌道生成. 電子情報通信学会論文誌 D-II, J75-D-II(5), 991-999.
- Wada, Y., & Kawato, M. (1993). A neural network model for arm trajectory formation using forward and inverse dynamics models. *Neural Networks* (in print).
- 和田安弘, 小池康晴, & 川人光男 (1993). 連続書字運動の計算論的モデル. 電子情報通信学会論文誌 (印刷中) .

< その他学術論文 >

- Hayakawa, H., Nishida, S., Wada, Y., & Kawato, M. (1993). A computational model for shape estimation by integration of shading and edge information. *Neural Networks* (submitted).

< 国際会議 >

- Wada, Y., & Kawato, M. (1991). Estimation of generalization capability by combination of new information criterion and cross validation. In *International Joint Conference on Neural Networks (IJCNN-91)*, II (pp. 1-6). Seattle, WA.
- Wada, Y., & Kawato, M. (1992). A neural network model for trajectory formation of arm movement by using forward and inverse dynamics models. In I. Aleksander & J. Taylor (Eds.), *Artificial Neural Networks*, 2 (pp. 575-578). Brighton, UK: Elsevier Science Publishers B. V.
- Wada, Y., Koike, Y., Eric Vatikiotis-Bateson, & Kawato, M. (1993). A computational model for cursive handwriting based on the minimization principle. (to appear in *Advances in Neural Information Processing Systems* 6).

< 研究会・全国大会等 >

- 和田安弘, & 川人光男 (1990). 新しい情報量規準による汎化能力をもった神経回路モデルの選択. 信学技報, NC90-20, 53-60.
- 和田安弘, & 川人光男 (1990). Cross Validation による最適に汎化する回路サイズの選択. 神経回路学会平成2年全国大会, (pp. O1-3).
- 和田安弘, & 川人光男 (1990). Cross Validation による汎化能力をもった神経回路モデルサイズの選択. 第5回生体・生理工学シンポジウム, 185-188.
- 和田安弘, & 川人光男 (1991). 制御対象の順・逆モデルを使った最適化手法による腕の最適軌道を生成する神経回路網. 信学技報, NC91-34, 31-38.
- 和田安弘, & 川人光男 (1992). 最小化原理に基づいた腕の軌道生成. 第2回インテリジェント・シンポジウム (FANシンポジウム), (pp. 341-346).
- 和田安弘, & 川人光男 (1992). 順・逆ダイナミクスモデルに基づく文字の生成と認識. 信学技報, NC92-48, 29-36.
- Vatikiotis-Bateson, E., 平山 亮, 和田安弘, & 川人光男 (1993). 音声生成の計算論的モデル - データとモデル化に関する考察. 信学技報, SP92-142, 41-48.
- 和田安弘, 小池康晴, & 川人光男 (1993). 最小化原理に基づいた書字運動モデル. 信学技報, NC92-124, 229-236.
- 和田安弘, 小池康晴, Vatikiotis-Bateson, E., & 川人光男 (1993). 最小化原理を応用した運動パターン認識. 信学技報, NC93-23, 85-92.

< 機関誌等 >

- Wada, Y., & Kawato, M. (1992). A new information criterion combined with cross-validation method to estimate generalization capability. *Systems and Computers in Japan*, 23(4), 92-104.
- Wada, Y., & Kawato, M. (1993). Trajectory formation of arm movement by a neural network with forward and inverse dynamics models. *Systems and Computers in Japan* (in print).
- Wada, Y., & Kawato, M. (1992). A neural network model for arm trajectory formation using forward and inverse dynamics models. No.TR-H-001 ATR Human Information Processing Research Laboratories.
- Wada, Y., & Kawato, M. (1992). A new information criterion combined with cross-validation method to estimate generalization capability. No.TR-H-003 ATR Human Information Processing Research Laboratories.

和田安弘 (1993). 非線形最適化による運動パターンの生成と認識. 数理科学 363 (pp. 37-42). サイエンス社.

<付録 1> 4階微分までの連続性

ここでは、本文第3章の3.3.1.2節の(2)軌道の一般フーリエ級数展開と完備性の項で述べた4階微分までの連続性についての計算結果を示しておく。

各経由点の時間において、位置・速度・加速度が連続であることは、 θ_{sub} の構成方法から明らかである。

今、始点での時刻を t_0 とし、経由点での時刻を t_{via} とし、終点での時刻を t_{final} とする。また経由点での補償する位置の誤差を $\delta\theta$ とし、始点～経由点の軌道を γ とし、経由点～終点を軌道 γ' とする。

このときの経由点での3階微分(躍度)、4階微分(スナップ)、5階微分は次のようになり、4階微分まで連続であることがわかる。

3階微分(躍度) :

$$\frac{d^3}{dt^3}\gamma(t_{via}) = 30 \frac{\delta\theta \{2(t_{via} - t_0) - (t_f - t_0)\}}{\{(t_f - t_0) - (t_{via} - t_0)\}^2 (t_{via} - t_0)^2}$$

$$\frac{d^3}{dt^3}\gamma'(t_{via}) = 30 \frac{\delta\theta \{2(t_{via} - t_0) - (t_f - t_0)\}}{\{(t_f - t_0) - (t_{via} - t_0)\}^2 (t_{via} - t_0)^2}$$

4階微分(スナップ) :

$$\frac{d^4}{dt^4}\gamma(t_{via}) = 120 \frac{\delta\theta}{\{(t_f - t_0) - (t_{via} - t_0)\}^2 (t_{via} - t_0)^2}$$

$$\frac{d^4}{dt^4}\gamma'(t_{via}) = 120 \frac{\delta\theta}{\{(t_f - t_0) - (t_{via} - t_0)\}^2 (t_{via} - t_0)^2}$$

5階微分 :

$$\frac{d^5}{dt^5}\gamma(t_{via}) - \frac{d^5}{dt^5}\gamma'(t_{via}) = 20 \frac{\delta\theta (t_f - t_0)^5}{\{(t_f - t_0) - (t_{via} - t_0)\}^5 (t_{via} - t_0)^5}$$

< 付録 2 > 速度の極小点だけによる軌道生成

与えられた軌道の接線方向の速度の極小となる点を経由点として、トルク変化最小規範によって軌道生成を行った結果を示す。軌道生成を行ったのは、第3章の図3.8と図3.11と同じ連続文字である。各々破線が計測された軌道、速度を示し、

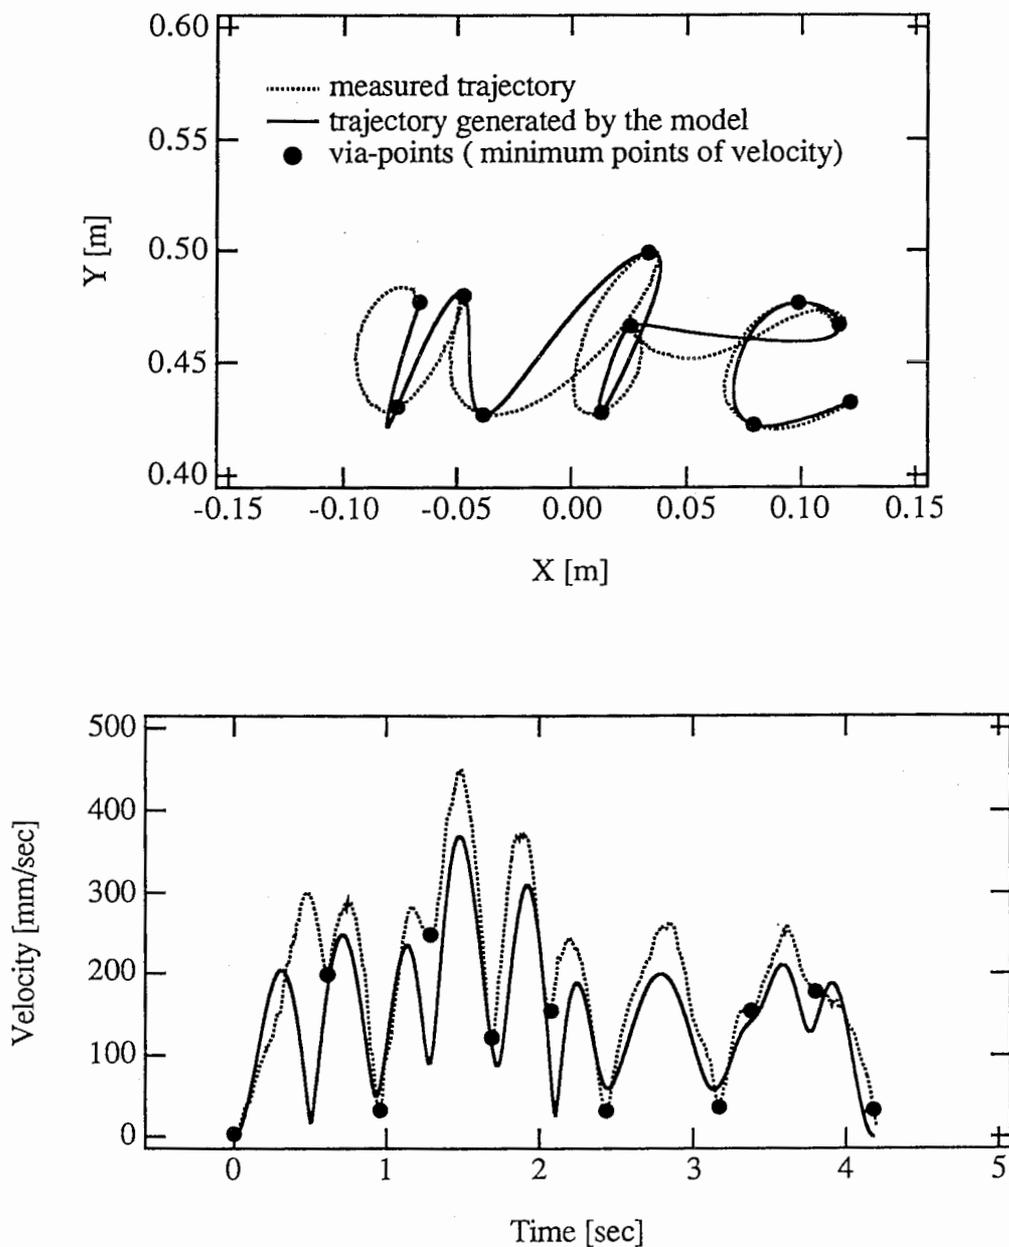


図 付-2.1 速度極小点を経由点とした軌道生成 (ABC)

Fig A-2.1 Trajectory generated by using minimum points of velocity (ABC).

実線が生成された軌道である。生成に使った経路点が●で示してあり、これは速度の極小点に対応する。どちらの例からもわかるように、ここで使った経路点では元の軌道を再現することは出来ず、本文で述べたように速度の極小点や曲率の最大点とは対応しない経路点のグループが軌道を再生する意味で重要であることがわかる。

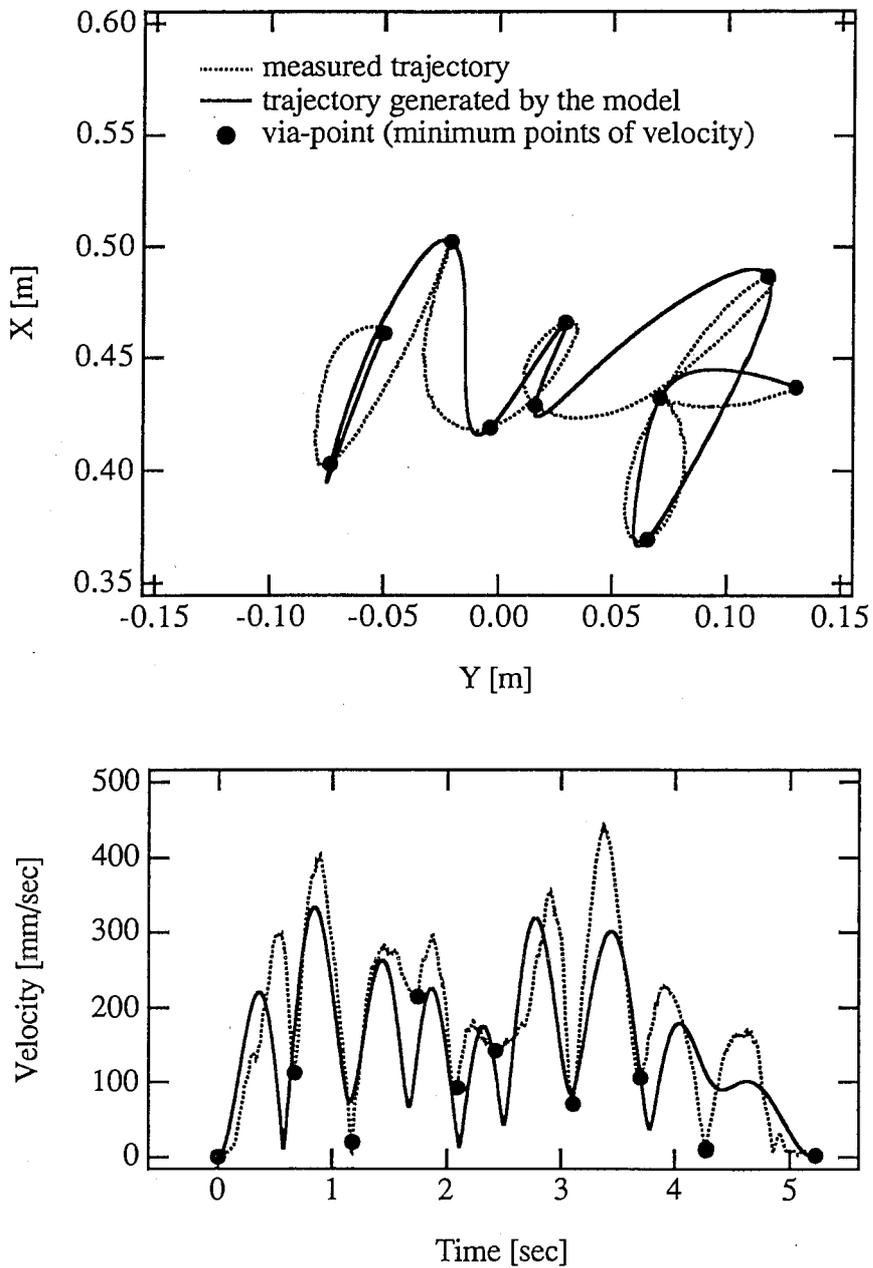
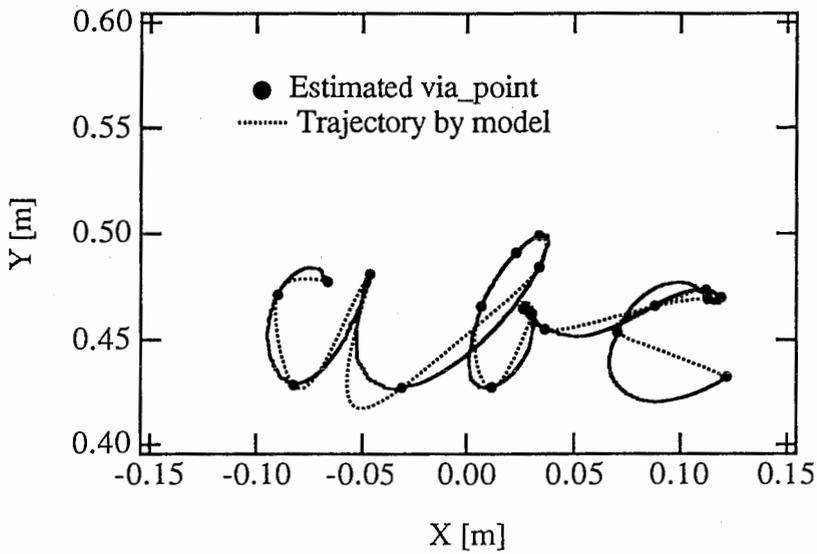


図 付-2.2 速度極小点を経路点とした軌道生成 (DEF)

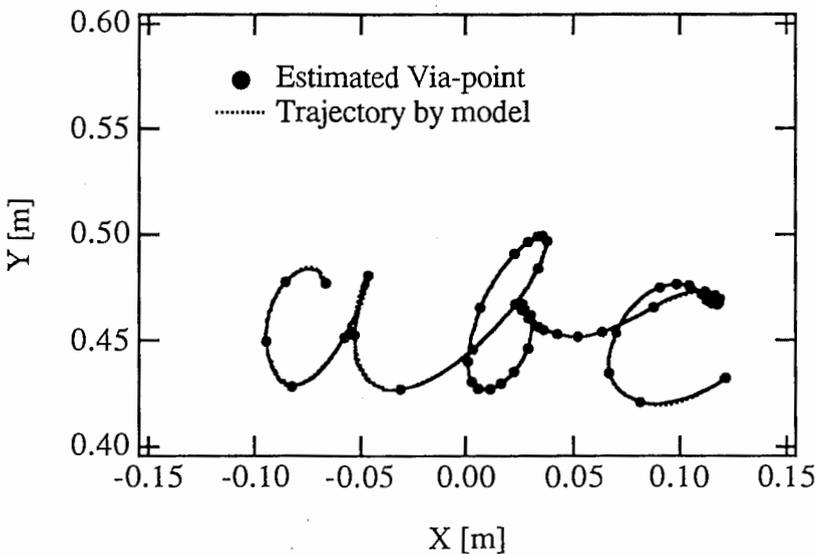
Fig A-2.2 Trajectory generated by using minimum points of velocity (DEF).

<付録 3> 閾値の違いによる推定される経路点の変化

図付-3.1に書字運動における異なる閾値に対する推定される経路点の違いを示した。(a)の閾値が0.02で、(b)の閾値が0.001である。閾値を小さくすることによって、再生される軌道が与えられた軌道をよく再現し、また、経路点の数も多く抽出されることがわかる。



(a) Threshold : 0.02



(b) Threshold : 0.001

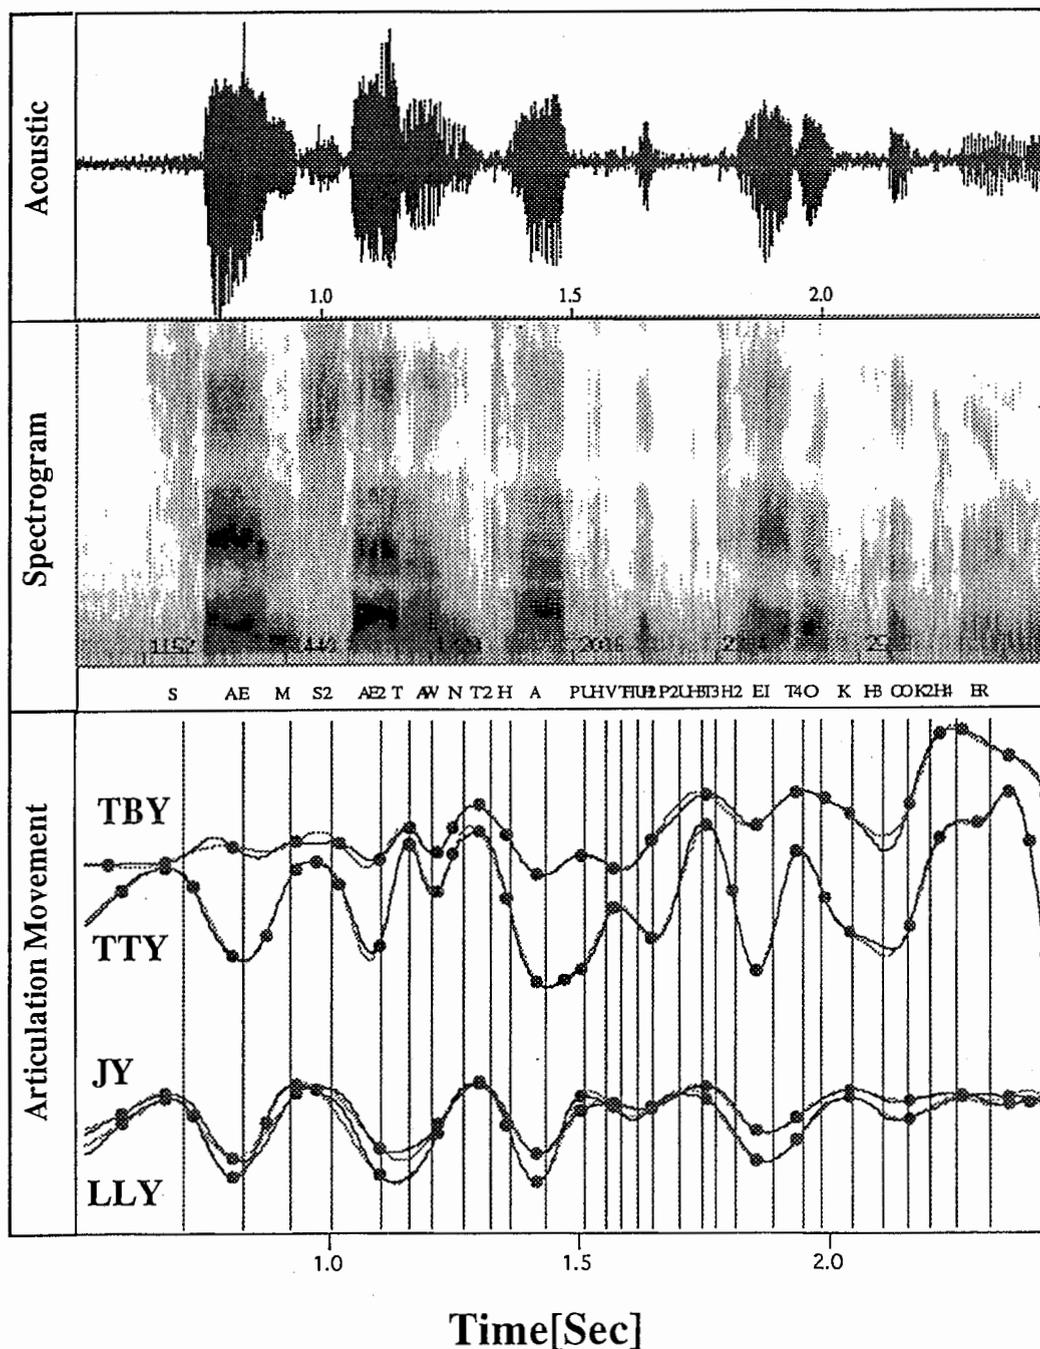
図付-3.1 異なる閾値による経路点の推定

Fig A-3.1 Estimated Via-points for different thresholds.

<付録 4> 調音器官の速い運動における音韻時刻の推定

下図に図4.9～図4.12に示した調音器官の運動より速い運動に対して、音韻時間の推定を行った例を示す。第4章で示した結果とほぼ同様に音韻時間を推定できていることがわかる。

Sam sat on top of the potato cooker...



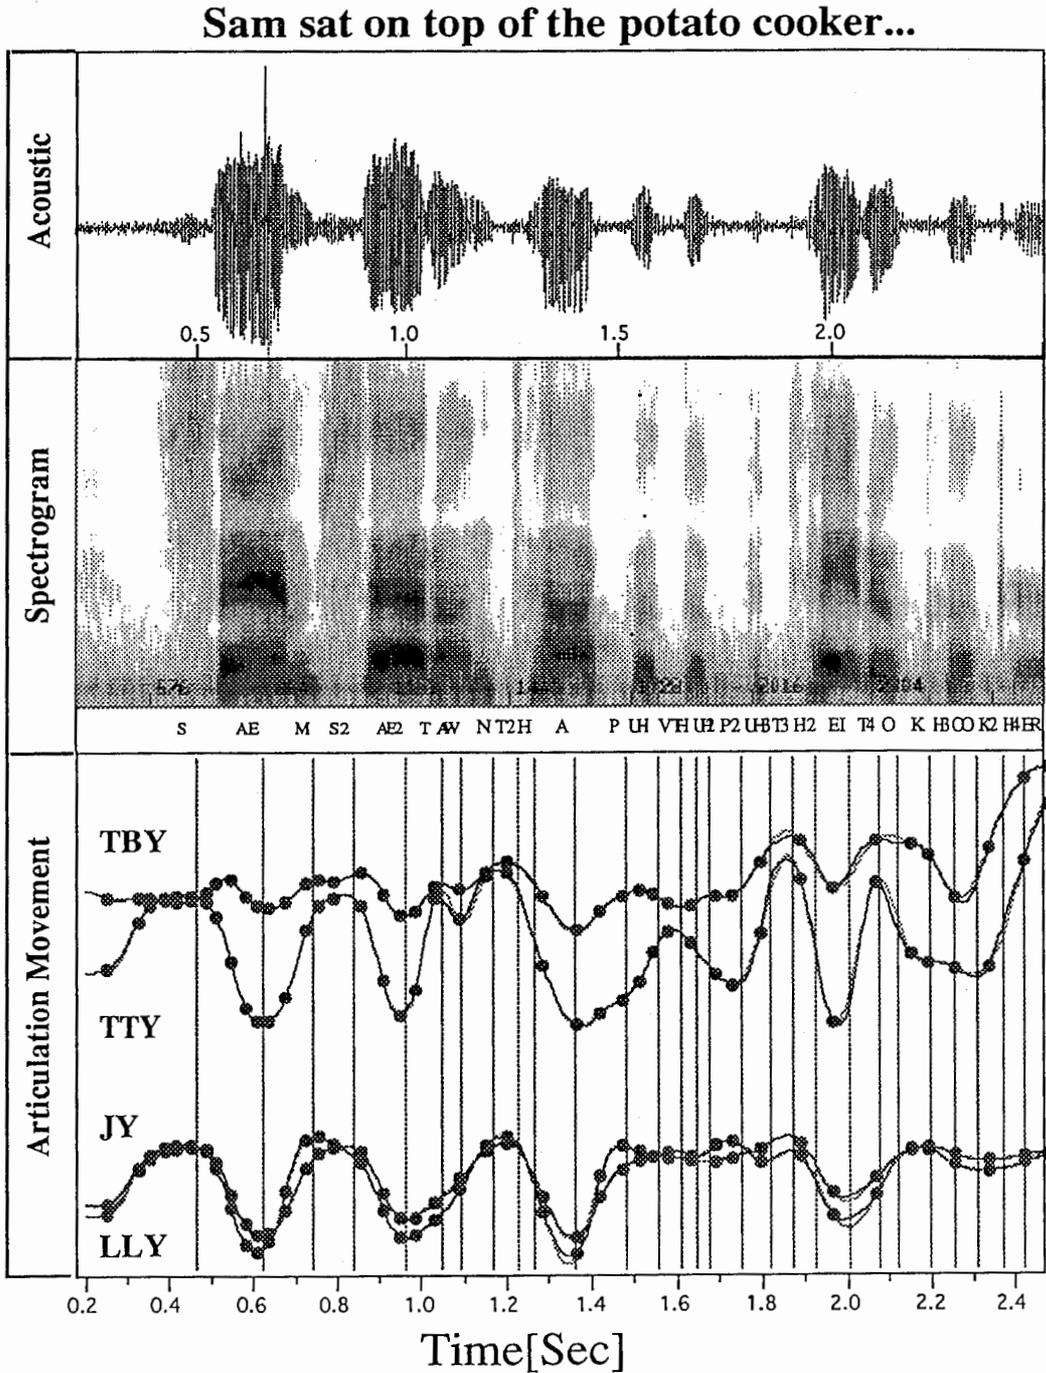
図付-4.1 音韻時間の推定結果（速い運動）

Fig A-4.1 Estimation result of phoneme time (fast movement).

閾値の設定は、図4.12と同様である。

<付録 5> 閾値の変化による音韻時刻の推定について

音韻時刻推定における閾値の設定値を変更した場合の、経由点の推定結果を図付-5.1と図付-5.2に示す。図付-5.1は本文の図4.10の閾値の設定を0.01にした

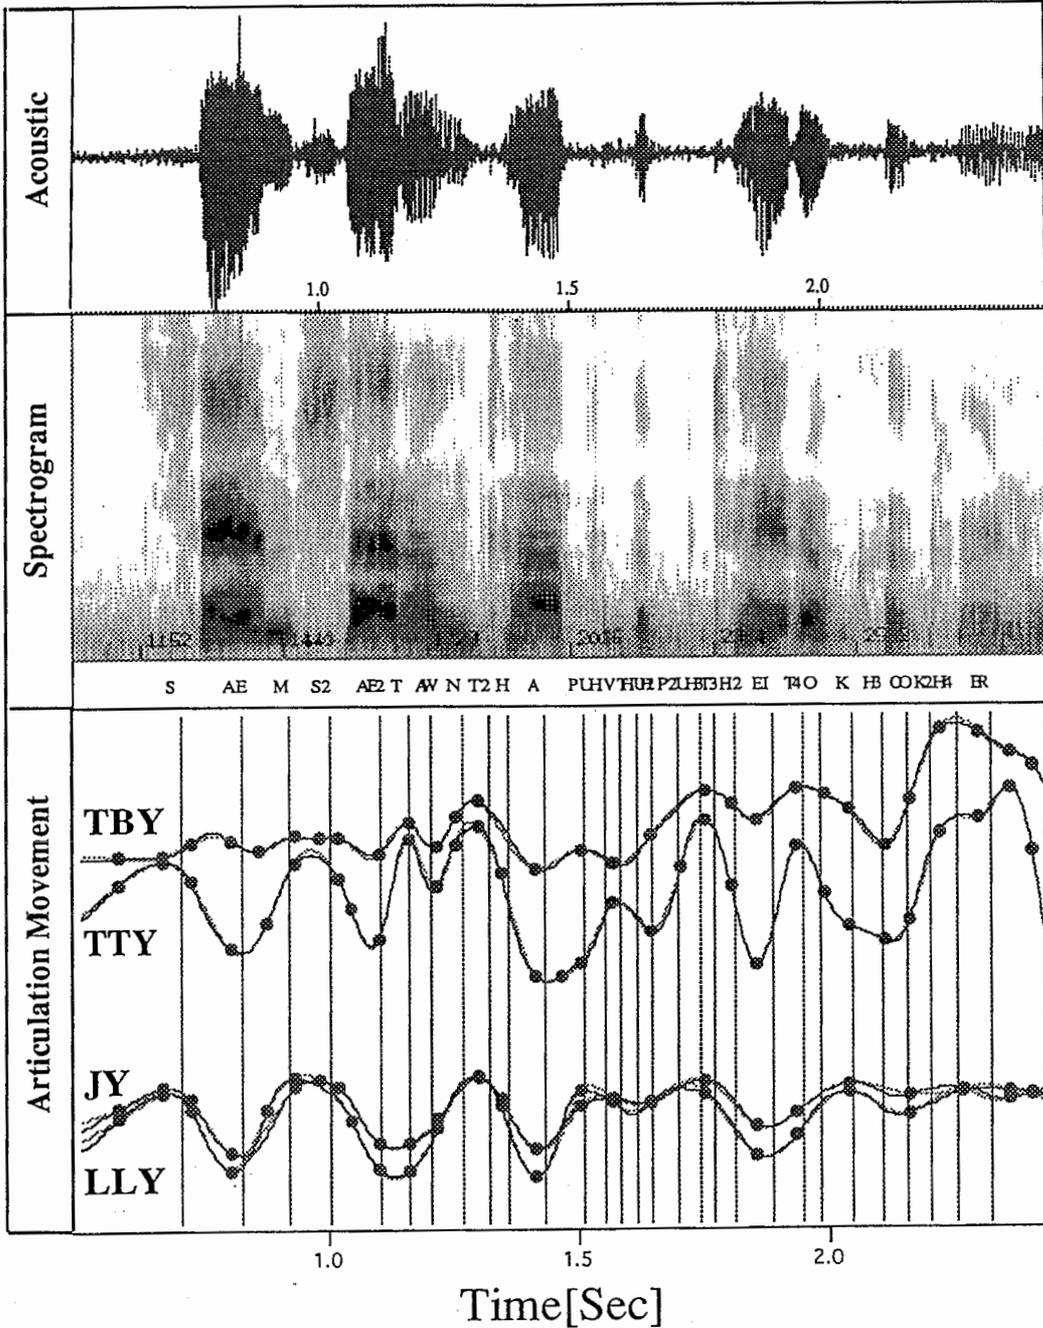


図付-5.1 音韻時間の推定結果

Fig A-5.1 Estimation result of phoneme time.

ものであり、図付-5.2は、図付-4.1の各調音器官の誤差の和に対する閾値を0.002に、各調音器官に対する閾値を0.0005にしたものである。どちらの場合も閾値を小さく設定することによって抽出される経由点の数が増える傾向にあることがわかる。

Sam sat on top of the potato cooker...



図付-5.2 音韻時間の推定結果

Fig A-5.2 Estimation result of phoneme time.

<付録 6> IC(K, N) と AIC との関係

本文で提案した情報量規準と AIC との関係についてまとめる。

本文式 (5.3) と式 (5.4) のテーラー展開の高次項を無視する。また大数の法則より $N \rightarrow \infty$ のとき

$$\frac{1}{N} \left[\frac{\partial^2 l}{\partial w^2} \right]_{w^*} = \frac{1}{N} \sum_{i=1}^N \left[\frac{\partial^2}{\partial w^2} \log f(x_i/w) \right]_{w^*} \rightarrow E_Z \left[\frac{\partial^2}{\partial w^2} \log f(z/w) \right]_{w^*}$$

$$\frac{1}{N} \left[\frac{\partial l}{\partial w} \right]_{w^*} = \frac{1}{N} \sum_{i=1}^N \left[\frac{\partial}{\partial w} \log f(x_i/w) \right]_{w^*} \rightarrow E_Z \left[\frac{\partial}{\partial w} \log f(z/w) \right]_{w^*}$$

が成り立つ。よって $N \rightarrow \infty$ のとき、 $\tilde{w}^N \rightarrow w^*$ を仮定すると、

$$\begin{aligned} (w - \tilde{w}^N) \left[\frac{\partial l}{\partial w} \right]_{\tilde{w}^N} + \frac{1}{2} (w - \tilde{w}^N) \left[\frac{\partial^2 l}{\partial w^2} \right]_{\tilde{w}^N} (w - \tilde{w}^N)^T \\ \rightarrow N(w - \tilde{w}^N) E_Z \left[\frac{\partial}{\partial w} \log f(z/w) \right]_{w^*} \\ + \frac{1}{2} N(w - \tilde{w}^N) E_Z \left[\frac{\partial^2}{\partial w^2} \log f(z/w) \right]_{w^*} (w - \tilde{w}^N)^T \end{aligned}$$

が成り立つ。ところで

$$E_Z \left[\frac{\partial}{\partial w} \log f(z/w) \right]_{w^*} = 0$$

であるから、 $w = w^*$ とおくと、結局以下のようになる。

$$\begin{aligned} (w^* - \tilde{w}^N) \left[\frac{\partial l}{\partial w} \right]_{\tilde{w}^N} + \frac{1}{2} (w^* - \tilde{w}^N) \left[\frac{\partial^2 l}{\partial w^2} \right]_{\tilde{w}^N} (w^* - \tilde{w}^N)^T \\ \rightarrow \frac{1}{2} N(w^* - \tilde{w}^N) E_Z \left[\frac{\partial^2}{\partial w^2} \log f(z/w) \right]_{w^*} (w^* - \tilde{w}^N)^T \quad (A6-1) \end{aligned}$$

つまり、

$$\alpha(w^* - \tilde{w}^N) \rightarrow \alpha_Z(\tilde{w}^N - w^*)$$

となる。

式 (A6-1) はパラメータ \tilde{w}^N が最尤推定量になっている場合には、

$$E_X \left[\sqrt{N}(w^* - \bar{w}^N) E_Z \left[\frac{\partial^2}{\partial w^2} \log f(z/w) \right]_{w^*} \sqrt{N}(w^* - \bar{w}^N)^T \right] = -K$$

つまり、パラメータ \bar{w}^N が最尤推定量になっている場合には、本文式 (5.3), 式 (5.4) の $\varepsilon_Z, \varepsilon$ を無視すると,

$$\alpha_Z(\bar{w}^N - w^*) + \alpha(w^* - \bar{w}^N) = -K$$

となり式 (5.11) より考えて、 $IC(K, N)$ は AIC と同じ情報量規準を与える。

<付録 7> 第1の仮定について

仮定として本文式 (A), 式 (B) 式のかわりに式 (A7-1), 式 (A7-2) を考える.

$$\frac{\partial^2 l^*}{\partial w_q \partial w_p} = R_{qp}^2(w) \cdot \frac{\partial^2 l}{\partial w_q \partial w_p}$$

$$\Rightarrow \frac{\partial^2 l^*}{\partial w_q \partial w_p} = r^2(w) \cdot \frac{\partial^2 l}{\partial w_q \partial w_p} \quad (\text{A7-1})$$

$$r^2(w) = r \quad (\text{A7-2})$$

ただし, $p, q = 1, 2, \dots, K,$

$R_{qp}^2(w)$ は $K \times K$ 次元行列,

$r^2(w)$ は w に関するスカラー関数,

r はスカラー定数.

このとき $\left[\frac{\partial l^*}{\partial w_p} \right]_{\tilde{w}^l}$ を下のように定義する.

$$\left[\frac{\partial l^*}{\partial w_p} \right]_{\tilde{w}^l} \equiv \frac{N}{N-l} \sum_{i=l+1}^N \left[\frac{\partial}{\partial w_p} (\log f(x_i/w)) \right]_{\tilde{w}^l} \quad (\text{A7-3})$$

($p = 1, 2, \dots, K$)

これによって, 本文で (A), (B) を仮定に与えて導出したのと同様にして, この仮定による情報量規準を求めることができる. この仮定によって求めた情報量規準は, 本文の議論で言えば,

$F_1(\tilde{w}^l)$ の項は, 消去され w の1階偏微分項として式(A7-3)によって計算されることになる.

$F_2(\tilde{w}^l)$ の項は, 新しい仮定により, 下式で与えられる.

$$\{F_2(\tilde{w}^l)\}_{qp} = (R_{qp}^2(\tilde{w}^l) - r^*) \left[\frac{\partial^2 l}{\partial w_q \partial w_p} \right]_{\tilde{w}^l}$$

つまり, 式 (A7-1), 式 (A7-2), 式 (A7-3) を仮定したときは, 本文式 (A), 式 (B) を仮定した場合よりも誤差を低減できる可能性がある.