

平成 21 年度  
博士学位論文

# 係数比例型適応アルゴリズムの 特性改善に関する研究

Improvement for Proportionate Type  
Adaptive Algorithm

1106003 佐伯 幸郎

指導教員 福本 昌弘

高知工科大学大学院 工学研究科 基盤工学専攻

# 要 旨

## 係数比例型適応アルゴリズムの 特性改善に関する研究

佐伯 幸郎

適応信号処理は、適応アルゴリズムに対する研究の発展、ハードウェア技術の進歩などの背景から理論だけでなく様々なアプリケーションとして用いられ、今日における我々の生活において必要不可欠な技術となっている。近年では、適応信号処理が用いられているエコーキャンセラやノイズキャンセラなどに対する高性能化への要求拡大から適応アルゴリズムにはこれまでには困難とされていた数百から数千といった長いフィルタ長への対応が必要とされている。

一般的に適応アルゴリズムはフィルタ長が長くなるに従い推定にかかる時間が増大し、推定精度は観測雑音の影響から低くなる。そのため、長いフィルタ長に適した適応アルゴリズムの研究は今なお活発に議論が行われている新しい分野である。この問題に対するアプローチとして係数比例型の適応アルゴリズムという新しい手法が注目されている。これは、長いフィルタ長が必要となるシステムはそのシステムのスパース性が非常に高いという事実に着目したアルゴリズムであり、この手法に基づいた様々な係数比例型適応アルゴリズムが提案されている。

本論文では、このような背景を鑑みて係数比例型適応アルゴリズムを収束速度、推定精度、演算量、観測雑音に対する影響などの観点から考察し、それらに基づき収束特性に影響を及ぼすステップサイズ、結合量など係数比例型適応アルゴリズムのパラメータを動的に決定する新しい係数比例型適応アルゴリズムの提案、あるいは改良を行い、その基本的性質及び有効性について論じている。

まず、係数比例型適応アルゴリズムとして最も使われている基本的な構造である係数比例型学習同定法に基づく適応アルゴリズムに対し、統一的な規範の下ステップサイズを制御する手法について提案を行う。本手法では様々な存在する係数比例型学習同定法に対してアルゴリズムの差異を考慮せず収束特性を向上させることが可能である。また、係数比例型学習同定法の拡張である係数比例型アフィン射影アルゴリズムに対し、同様のステップサイズ制御法を用いた場合についても考察を行う。アフィン射影への拡張を行うことで、係数比例型学習同定法が本質的に持っている有色性信号に対する収束特性の低下を防ぐことが可能となる。

最後に、係数比例型が抱える非スパースなシステムの対応として学習同定法と係数比例型を組み合わせる手法について提案を行い、この結合度について出力誤差のみから調整を行うことができる新しいアルゴリズムの提案を行う。

これらの提案アルゴリズムについて計算機シミュレーションを行い収束特性の比較、確認を行うことで提案手法の有効性を示している。

**キーワード** 適応信号処理, 係数比例型適応アルゴリズム, 可変ステップサイズ

# Abstract

## Improvement for Proportionate Type Adaptive Algorithm

SAIKI Sachio

With the development of hardware technology and research for adaptive algorithms, adaptive signal processing used not only theoretical technology but also in many practical applications. Nowadays, with increase in the demand for higher quality performance, a kind of long adaptive filter is frequently encountered in practical application, such as the network echo cancellation and acoustic echo cancellation.

Generally speaking, increase of adaptive filter length causes degradation of convergence speed, because their convergence speed is inversely proportional to the adaptive filter length. Furthermore, because of the effect of disturbance noise, the convergence quality of the adaptive filter is degraded. Much effort has been made to find new adaptive algorithms to solve these problems. Recently, a new adaptation paradigm, proportionate adaptation, was developed in a novel perspective. Its main philosophy comes from a fact that most of these long impulse responses are sparse in nature

This dissertation presents some results of my researches on efficient adaptive algorithms based on the proportionate adaptation for adaptive signal processing systems.

Firstly, variable step-size approach for proportionate NLMS algorithms is proposed in order to improve convergence quality. Next, a method based on variable step size approach proposed in previous section is extended into the proportionate affine projection algorithms to improve the estimate accuracy of sparse impulse response for correlated

input signals. At last, novel adaptive combination technique for CtPNLM algorithm is proposed to realize a non parametric CtPNLMS and extend a sparseness time varying system.

***key words***     Adaptive signal processing, proportionate type adaptive algorithm

# 目次

第 1 章	序論	1
1.1	研究背景 . . . . .	1
1.2	論文の構成 . . . . .	4
第 2 章	適応信号処理	5
2.1	適応信号処理とその発展 . . . . .	5
2.2	パラメータ推定問題 . . . . .	7
2.3	代表的な適応アルゴリズム . . . . .	8
2.3.1	最急降下法と LMS アルゴリズム . . . . .	8
2.3.2	学習同定法 (NLMS) . . . . .	11
2.3.3	Recursive Least-Square (RLS) アルゴリズム . . . . .	11
2.3.4	アフィン射影アルゴリズム . . . . .	13
2.4	適応信号処理の適用例 . . . . .	14
2.4.1	適応ノイズキャンセラ . . . . .	14
2.4.2	自動等化器 . . . . .	14
2.5	まとめ . . . . .	16
第 3 章	スパースなシステムに対する適応信号処理	17
3.1	システムのスパース性 . . . . .	18
3.2	PtNLMS アルゴリズム . . . . .	18
3.2.1	PNLMS アルゴリズム . . . . .	19
3.2.2	IPNLMS アルゴリズム . . . . .	20
3.2.3	MPNLMS アルゴリズム . . . . .	20
3.2.4	PNLMS++アルゴリズム, CPNLMS アルゴリズム . . . . .	21

## 目次

3.3	まとめ	21
第 4 章	ステップサイズの算出法に依存しない可変ステップサイズ係数比例型アル ゴリズム	22
4.1	準備	22
4.2	可変ステップサイズ PtNLMS アルゴリズム	23
4.3	PtNLMS アルゴリズムにおける最適ステップサイズ	24
4.4	可変ステップサイズへの拡張	25
4.5	運用法	25
4.6	演算量	27
4.7	NLMS における最適制御との比較	27
4.8	計算機シミュレーション	28
4.8.1	シミュレーション条件	28
4.8.2	シミュレーション結果	31
4.9	係数比例アフィン射影アルゴリズム	33
4.10	PAPA における最適ステップサイズ	34
4.11	計算量	38
4.12	計算機シミュレーション	38
4.12.1	シミュレーション条件	38
4.12.2	シミュレーション結果	39
4.13	まとめ	40
第 5 章	動的に結合量を調整する結合係数比例型 NLMS アルゴリズム	50
5.1	結合係数比例型 NLMS アルゴリズム	50
5.1.1	CtPNLMS アルゴリズム	51
5.1.2	CtPNLMS アルゴリズムにおける結合度の影響	52
5.1.3	スパース性を基に調整する結合係数比例型 NLMS アルゴリズム	53

## 目次

5.2	動的に結合量を調整する CtPNLMS アルゴリズム . . . . .	54
5.3	計算機シミュレーション . . . . .	55
5.3.1	シミュレーション条件 . . . . .	55
5.3.2	シミュレーション結果 . . . . .	57
5.3.3	スパース性の変化に対する追従性 . . . . .	58
5.4	まとめ . . . . .	59
第 6 章	結論	66
	謝辞	68
	参考文献	69
付録 A	関連業績	73
A.1	査読付き論文誌 . . . . .	73
A.2	国際会議 . . . . .	73
A.3	国内会議 . . . . .	74



# 目次

1.1	ITU-T G.168 で定められた Hybrid 8 におけるインパルス応答 . . . . .	3
2.1	システム同定のモデル . . . . .	8
2.2	適応ノイズキャンセラ . . . . .	15
2.3	適応ノイズキャンセラにおけるパラメータ推定 . . . . .	15
2.4	デジタル伝送系 . . . . .	16
2.5	デジタル伝送系 . . . . .	16
4.1	VSS-PtNLMS アルゴリズムの流れ図 . . . . .	26
4.2	入力信号 (音声信号) . . . . .	29
4.3	観測雑音 (音声信号) . . . . .	29
4.4	未知系のインパルス応答 (スパース) . . . . .	30
4.5	未知系のインパルス応答 (セミスパース) . . . . .	30
4.6	収束特性の比較 (スパースな場合) . . . . .	42
4.7	収束特性の比較 (セミスパースな場合) . . . . .	42
4.8	最適ステップサイズとの比較 (MPNLMS) . . . . .	43
4.9	収束特性の比較 (入力:音声, 観測雑音:白色) . . . . .	43
4.10	収束特性の比較 (入力:音声, 観測雑音:音声) . . . . .	44
4.11	収束特性の比較 (入力:音声, 観測雑音:音声) . . . . .	44
4.12	統計量の測定区間による違い . . . . .	45
4.13	ステップサイズの推移 . . . . .	45
4.14	シミュレーションで用いる未知系, 入力信号 . . . . .	47
4.15	収束特性の比較 (白色ガウス雑音) . . . . .	48
4.16	収束特性の比較 (音声信号) . . . . .	49

## 図目次

5.1	スパースなインパルス応答 ( $\xi(w) = 0.96$ ) . . . . .	60
5.2	スパースなシステムに対する収束特性の比較 . . . . .	60
5.3	セミスパースなインパルス応答 ( $\xi(w) = 0.68$ ) . . . . .	61
5.4	セミスパースなシステムに対する収束特性の比較 . . . . .	61
5.5	非スパースなインパルス応答 ( $\xi(w) = 0.21$ ) . . . . .	62
5.6	非スパースなシステムに対する収束特性の比較 . . . . .	62
5.7	スパースなシステムに対する収束特性の比較 . . . . .	63
5.8	$\beta(i)$ の変化 ( $\beta(0) = -0.7$ ) . . . . .	63
5.9	セミスパースなシステムに対する収束特性の比較 . . . . .	64
5.10	$\beta(i)$ の変化 ( $\beta(0) = -0.7$ ) . . . . .	64
5.11	$\beta(i)$ の変化 ( $\beta(0) = 0.0$ ) . . . . .	65
5.12	スパース性が変化に対する追従性 . . . . .	65

# 表目次

4.1	VSS-SPAPA . . . . .	46
5.1	ACPNLMS . . . . .	56

# 第 1 章

## 序論

### 1.1 研究背景

近年，半導体技術の目まぐるしい発展に伴いこれまで実時間での実行は不可能と考えられていた様々なデジタル信号処理技術が実現に向け着実に進化を遂げている．デジタル信号処理において最も頻出し処理速度を決定するといっても過言でない乗算器は低コスト，高速かつ高精度な DSP と呼ばれるハードウェアを用い簡易に使えるようになりその応用範囲や有用性が益々高まっている．デジタル信号処理は古典的ともいえる音声，通信，画像などの工学的用途に留まらず，医学，天文学など多くの分野での応用も進められている [1–4]．このような背景を鑑みると，デジタル信号処理の重要性は今後ますます増えていくと考えられる．

このデジタル信号処理技術の中で，近年，適応信号処理と呼ばれる分野が注目を集めている．適応信号処理とは適応フィルタを用いたデジタル信号処理であるが，適応アルゴリズムを用いて適応フィルタの係数を所望する最適フィルタを推定していくシステムである．つまり，フィルタ係数が可変で自己調整が可能なデジタルフィルタを用いる信号処理である．適応フィルタにおいてその性能を決定するものが適応アルゴリズムであるが，対象とするシステム・アプリケーションに求められる適応アルゴリズムを導出することは適応信号処理において非常に重要な問題である．例えば，音声などを対象とするシステムにおいては有色性の高い信号に対しても推定性能が劣化しにくいアルゴリズムを用いるべきであり，時間変動がある，若しくは激しいシステムに対しては高い収束速度を持ちかつシステムの変動に対しても追従可能であるアルゴリズムが適していると言える．

## 1.1 研究背景

適応信号処理の応用例が広がっていく一方，これまで対象としえなかった長大なフィルタ長を必要とする分野に対する適応アルゴリズムが要求されるようになった．これは，従来の適応アルゴリズムではフィルタ長が大きくなるにつれ収束特性が特に速度の点で大きく低下してしまう問題が存在するからである．例えば，適応アルゴリズムにおいてその演算量と性能のバランスから最も使われている学習同定法のサンプル毎の収束率  $R$  は

$$R = \frac{10}{\log 10} \cdot \frac{1}{N} \alpha (2 - \alpha) \quad (1.1)$$

である [5]．ただし， $N$  はフィルタ長， $\alpha$  はステップサイズである．式 (1.1) より，フィルタ長と収束率は反比例の関係であり，フィルタ長  $N$  が大きくなるにつれ，収束率は小さくなる，即ち収束速度は低くなることがわかる．

このフィルタ長と収束速度の問題に対し，比較的大きなフィルタ長が必要とされる，ネットワークやアコースティックエコーキャンセラ等のアプリケーションに対して対象システムのスパース性という特徴を生かした適応アルゴリズムが近年活発に研究が行われている．ここで，システムがスパースであるとは，システム全体のインパルス応答に対して大きな振幅が占める割合が非常に少なくそれ以外のインパルス応答が 0 または非常に小さいというものである [6]．例えば，ITU-T G.168 [7] では Voice over IP ネットワーク等で用いられるネットワークエコーキャンセラの評価指標としてネットワークパスを図 1.1 のよう定めている．図 1.1 では全インパルス応答に対し 50% 程度が振幅を持っている．実際にはネットワークエコーはパケットスイッチやジッタの影響等の大きな時間的に変動に対応する必要があるため，エコーキャンセラとしてはこの数倍の長さを持つフィルタを用意しておかなければならず，対象システムのスパース性という点では非常に高くなる．このスパース性を収束速度の向上に積極的に利用した適応アルゴリズムがこれまでにいくつか提案されており [6]，これらのアルゴリズムを実用的なアプリケーションへ適用する試みとして VoIP ゲートウェイに対するネットワークエコーキャンセラ，テレビ会議システム，ハンズフリー携帯電話へのアコースティックエコーキャンセラなどその応用範囲を広げている．

これまでに提案されているスパースなシステムに対する収束特性の向上法の多くは，適応アルゴリズムとして良く知られている学習同定法に対して通常，全てのフィルタ係数に対し

## 1.1 研究背景




図 1.1 ITU-T G.168 で定められた Hybrid 8 におけるインパルス応答

fig.1.1 Impulse response of Hybrid 8 defined in ITU-T G.168

て同一の値を用いるステップサイズと呼ばれる値を係数ごとに異なるステップサイズを用いることを基礎としている。これは、値の大きな係数が収束するためには小さな係数を持つタップに対し、より多くの推定の繰り返しが必要であるという事実から、収束速度を向上させるため大きな係数をもつタップには大きなステップサイズを割り当てるといった考え方によるものである。この構造をはじめて学習同定法に適用したものとして、Duttweiler により提案された Proportionate NLMS(PNLMS) アルゴリズムがある [5]。PNLMS アルゴリズムは NLMS アルゴリズムに対して過去に推定されているタップ係数から係数更新時のタップ毎のステップサイズを算出する手法である。この PNLMS アルゴリズムを基にした様々な改善法がこれまでに提案されている。

本論文では、このような背景を鑑みて係数比例型適応アルゴリズムを収束速度、推定精度、演算量、観測雑音に対する影響などの観点から考察し、それらに基づき収束特性に影響を及ぼすステップサイズ、結合度など係数比例型適応アルゴリズムのパラメータを動的に決定する新しい係数比例型適応アルゴリズムの提案、あるいは改良を行い、その基本的性質及び有効性について論ずる。

## 1.2 論文の構成

まず，第 2 章では適応信号処理のこれまでの歴史と発展について述べ，その必要性について言及する．また，代表的な適応アルゴリズムについて紹介を行う．第 3 章では，係数比例型学習同定法について解説を行っている．第 4 章では，様々にある係数比例型学習同定法について，アルゴリズムによる差異を考慮せずかつ高い収束速度を得ながら，推定精度を大幅に向上できるステップサイズの算出法に依存しない可変ステップサイズ係数比例型 NLMS アルゴリズムについて述べ，さらに同様の手法を係数比例アフィン射影に適用する手法について述べる．第 5 章では係数比例型学習同定法が本質的に持つ非スパースなシステムへの適用として動的に結合量を調整する結合係数比例型 NLMS アルゴリズムについてである．最後に，第 6 章で本論文のまとめを行い今後の研究課題について言及する．

## 第 2 章

# 適応信号処理

本章では，適応信号処理の歴史的背景と適応信号処理の基本的概念であるパラメータ推定問題について述べ，同時に代表的な適応アルゴリズムのその導出仮定について説明を行う．次いで，適応信号処理の応用例として，適応ノイズキャンセラ，自動等化器の説明を行い，パラメータ推定問題の重要性について述べる．

なお，以降の議論において， $M \times N$  行列  $A$  を  $A_{MN}$ ， $M \times 1$  ベクトル  $b$  を  $b_M$  と表記する．また， $T$  は行列あるいはベクトルの転置を表す．

### 2.1 適応信号処理とその発展

適応信号処理は 1960 年 Widrow と Hoff により研究が始められて以来，デジタル通信の分野で特に重要な位置を占めるようになってきた．Widrow と Hoff は適応スイッチング回路の研究で Widrow-Hoff の LMS アルゴリズム (Least Mean Square Algorithm，以下 LMS アルゴリズムと表記) とよばれる適応アルゴリズムの提案を行っている [8]．LMS アルゴリズムは最急降下法に基づき，平均 2 乗誤差を最小にするようフィルタ係数を修正する方式であり，特に演算量が少なくハードウェア構成がシンプルであるという理由から現在もなお代表的な適応アルゴリズムとして使用されている．一方，1967 年に野田と南雲は学習同定法の提案を行った [9]．学習同定法は LMS アルゴリズムの係数修正項をフィルタの入力状態ベクトルのノルムで正規化したもので，Normalized LMS(以下 NLMS と表記) アルゴリズムともよばれている．このアルゴリズムは正規化を行うため，演算量の点においては LMS アルゴリズムより多くなるものの，収束特性や他のアルゴリズムと比較した演算量な



## 2.1 適応信号処理とその発展

どの観点から優れた適応アルゴリズムということができる。

これらのアルゴリズムは信号の統計的性質が未知の場合、あるいは推定すべきパラメータが時間とともに変動する時変な場合に対してもパラメータの推定が可能であるという特徴を有している。しかしながら、LMS や NLMS といったアルゴリズムは対象とする信号が有色信号である場合、収束速度が著しく劣化するという欠点が知られている。

このような、入力信号が有色である場合においても良好な収束特性を得ることができるアルゴリズムとして、逐次最小 2 乗法 (Recursive Least Square, 以下 RLS と表記) が提案された [10]。このアルゴリズムは対象とする信号のエルゴード性の仮定の下に成り立つ。また、未知システムのパラメータが変動しない場合、RLS アルゴリズムはカルマンフィルタと等価となる。カルマンフィルタは Wiener フィルタを時間領域についての定式化に基づいて変化したものであり、多くの研究がなされている。RLS アルゴリズムは推定すべきパラメータの個数を  $N$  とすれば、1 サンプル当たりの演算量は  $N$  の 2 乗に比例 ( $O(N^2)$ ) するために、ハードウェア化は困難とされているが、未知パラメータが時間的に不変であるときには非常に良好な収束特性を示す。また、未知パラメータが変動する場合においても忘却係数の導入により追従性の確保が行えることが知られている。このように、適応アルゴリズムでは演算量と収束速度は一般にトレードオフの関係にあるといえる。

ここで、適応アルゴリズムの代表的な応用例を基に考えると、特に有色信号入力時においても良好な収束特性を示し、演算量が少なくハードウェア構成が容易であり、更にパラメータの時間的な変動にも追従が可能な適応アルゴリズムが望ましいことがわかる。

一方、複数の入力信号を処理速度の高速化に利用するのではなく、収束速度の向上に利用したのが雛元、前川の提案した拡張された学習同定法 [11]、尾関、梅田が提案したアフィン射影算法 [12] である。この 2 つの手法は多次元部分空間への直交射影演算に基づいた算法であり、有色信号入力時においても高速な収束特性を得られるが 1 サンプル当たりに要する演算量が非常に多くなるという問題点がある。

## 2.2 パラメータ推定問題

入出力データからその未知システムの構造とパラメータを推定することはシステム同定と呼ばれる．本論文では未知システムの構造を FIR(有限インパルス応答) 型と仮定し，パラメータ推定問題として扱う．

時刻  $i$  における入力信号  $x(i)$  に対して，適応フィルタの状態ベクトル，係数ベクトルを

$$\mathbf{x}_N(i) = [x(i), x(i-1), \dots, x(i-N+1)]^T \quad (2.1)$$

$$\mathbf{h}_N(i) = [h_0(i), h_1(i), \dots, h_{N-1}(i)]^T \quad (2.2)$$

とする．適応フィルタの入出力関係は

$$y(i) = \mathbf{h}_N^T \mathbf{x}_N(i) \quad (2.3)$$

で与えられる．また，所望信号を

$$d(i) = \mathbf{w}_N^T \mathbf{x}_N(i) \quad (2.4)$$

とすると，出力誤差は

$$e(i) = d(i) - y(i) \quad (2.5)$$

となる．ただし  $\mathbf{w}_N$  は未知系のインパルス応答である．

ここで，式 (2.4) で表されているようにインパルス応答が有限である場合，FIR フィルタと未知システムの関係が

$$\mathbf{w}_N(i) = \mathbf{h}_N(i) \quad (2.6)$$

であれば出力は等しくなる．したがって，未知システムのインパルス応答が有限で，インパルス応答長がわかっていると仮定すれば，同じ入力に対して完全に同一の出力を得る FIR フィルタを得られる可能性がある．

一方，未知システムのインパルス応答が無限に続く場合，同じ入力に対して同一の出力を得る FIR フィルタを得ることはできない．しかしながら，インパルス応答が時間とともに減衰する場合を考慮すると，インパルス応答の最初の  $N$  個がわかればよい適用例は多い．また， $N$  を限りなく大きくとれば，未知システムとの入出力関係に非常に近い FIR フィル

## 2.3 代表的な適応アルゴリズム

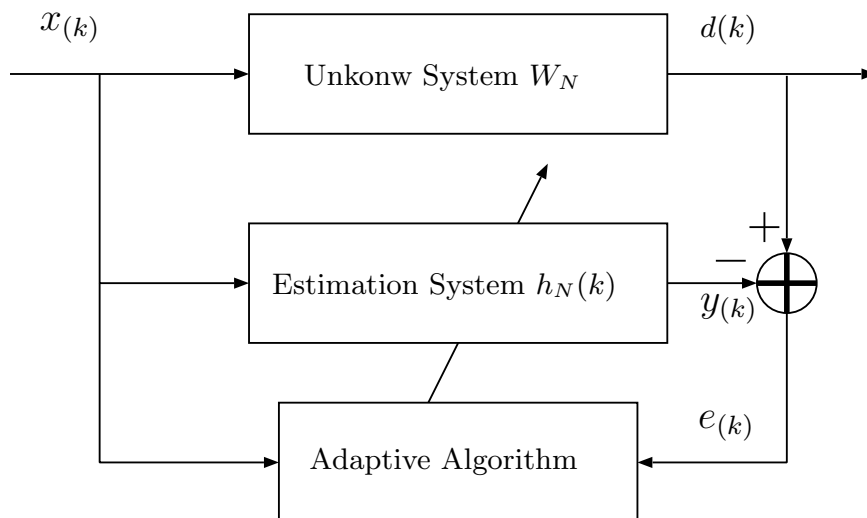


図 2.1 システム同定のモデル

Fig.2.1 Model of System Identification.

タを得ることができる。これらのことから，未知システムを FIR 型と仮定する妥当性を得ることが可能である。このような未知システムに非常に近い FIR フィルタは，後述する評価量を最小とすることにより得ることができる。

図 2.1 にシステム同定のモデルを示す。一般に，係数を修正するためのアルゴリズムを適応アルゴリズム，適応アルゴリズムを含む FIR フィルタを適応フィルタ，または推定システムと呼ぶ。

## 2.3 代表的な適応アルゴリズム

### 2.3.1 最急降下法と LMS アルゴリズム

係数修正のために使用する評価量  $J$  はパラメータ推定の目的からいえば，未知システムと推定システムのパラメータの距離を直接評価量とすることが重要であるが，未知システム

## 2.3 代表的な適応アルゴリズム

のパラメータは未知であるため，一般には未知システムと推定システムの差の2乗平均値

$$\begin{aligned} J &= E[\{d(i) - y(i)\}^2] \\ &= E[e(i)^2] \end{aligned} \quad (2.7)$$

が評価量として使用される．この評価量  $J$  を適応フィルタ  $\mathbf{h}_N$  に関する2次関数で表すと

$$J = \mathbf{h}_N^T E[\mathbf{x}_N(i)\mathbf{x}_N^T(i)]\mathbf{h}_N - 2\mathbf{h}_N^T E[\mathbf{x}_N(i)d(i)] + E[d(i)^2] \quad (2.8)$$

が得られる．したがって， $J$  を最小にする最適係数ベクトルを  $\mathbf{h}_N(opt)$  とし，評価量  $J$  を  $\mathbf{h}_N$  で偏微分することにより

$$\frac{\partial J}{\partial \mathbf{h}_N} = 2E[\mathbf{x}_N(i)\mathbf{x}_N^T(i)]\mathbf{h}_N - 2E[\mathbf{x}_N(i)d(i)] \quad (2.9)$$

となり，最適係数ベクトル  $\mathbf{h}_N(opt)$  は

$$\mathbf{h}_N(opt) = E[\mathbf{x}_N(i)\mathbf{x}_N^T(i)]^{-1} E[\mathbf{x}_N(i)d(i)] \quad (2.10)$$

となる．これはウィナーホッフの解とよばれている．ただし， $E[\mathbf{x}_N(i)\mathbf{x}_N^T(i)]$  は正則であると仮定する．しかしながらウィナーホッフの解では平均操作と逆行列演算を必要としリアルタイム処理には不向きである．また，逆行列の補題を用い，この平均操作と逆行列演算を逐次的に効率良く行う RLS アルゴリズムも提案されているが，これらの方法は相関行列の正則性が必要となり場合によっては数値的不安定性を招くおそれが生じる．

一方，Widrow は最急降下法に基づき瞬時自乗誤差  $e(i)^2$  を評価量とした LMS アルゴリズムを提案した．ここで最急降下について簡単に説明する．式 (2.7) で与えられている  $J$  に関する任意の  $\mathbf{h}_N$  におけるこう配ベクトルを

$$\mathbf{g}_N = 2E[\mathbf{x}_N(i)\mathbf{x}_N^T(i)]\mathbf{h}_N - 2E[\mathbf{x}_N(i)d(i)] \quad (2.11)$$

とする．こう配ベクトル  $\mathbf{g}_N(i)$  は係数  $\mathbf{h}_N(i)$  におけるこう配であり， $J$  に関する等高線上の法線方向を向いている．ただし， $\mathbf{g}_N(i)$ ， $\mathbf{h}_N(i)$  はそれぞれ  $\mathbf{g}_N$ ， $\mathbf{h}_N$  の  $i$  番目の修正時のものである．また，式 (2.8) はパラメータ  $\mathbf{h}_N$  の2次形式となっていることから，評価量  $J$  を最小にする  $\mathbf{h}_N$ ： $\mathbf{h}_N(opt)$  は唯一存在する．したがって，任意の点  $\mathbf{h}_N(0)$  を初期値とすれ

## 2.3 代表的な適応アルゴリズム

ば,  $h_N(0)$  を  $-g_N(0)$  方向に移動することにより  $h_N(1)$  における  $J$  を  $h_N(0)$  における  $J$  よりも小さくすることができる. すなわち  $J$  が最小になる方向に進むことにより  $h_N(i)$  を  $h_N(opt)$  に近付けることができる. 以上のことを考慮すると係数修正式は

$$h_N(i) = h_N(i-1) - \alpha(i)g_N(i) \quad (2.12)$$

となる. ここで  $\alpha(j)$  はステップサイズと呼ばれている.

上記のように最急降下法ではパラメータ推定を行うために信号の2次統計量 (入力自己相関行列  $E[x_N(i)x_N^T(i)]$ , 相互相関ベクトル  $E[x_N(i)d(i)]$ ) が必要である. しかしながらこれらの統計量を用いる場合, 前述のようにリアルタイム処理には適していない. したがって, 式 (2.7) における平均操作を取り除き, 瞬時自乗誤差を評価量  $J$

$$\begin{aligned} J &= [d(i) - y(i)]^2 \\ &= h_N^T(i)x_N(i)x_N^T(i) - 2h_N^T(i)x_N(i)d(i) + d(i)^2 \end{aligned} \quad (2.13)$$

として用いることにより, リアルタイム処理への対応という問題を解決した LMS アルゴリズムが考案された.

この評価量  $J$  に対するこう配ベクトル  $g_N(i)$  は式 (2.13) を  $h_N(i)$  に関して偏微分することにより

$$\begin{aligned} g_N(i) &= 2x_N(i)x_N^T(i)h_N(i) - 2x_N(i)d(i) \\ &= -2x_N(i)\{d(i) - x_N^T(i)h_N(i)\} \\ &= -2x_N(i)e(i) \end{aligned} \quad (2.14)$$

で与えられることから, LMS アルゴリズムの係数更新式は

$$h_N(i+1) = h_N(i) + \alpha \cdot x_N(i)e(i) \quad (2.15)$$

と表される. ただし  $\alpha$  はステップサイズである. 式 (2.15) からわかるように, LMS アルゴリズムは演算量が少なくハードウェアの構成が容易であるために現在でも広く利用されている. しかしながら, 有色性の信号を入力信号として用いた場合, 固有値の広がりから収束速度が低下するといった欠点もある. また, 入力信号によってステップゲイン  $\alpha$  を適切に設定しなければ動作が不安定にあるといった問題もある.

## 2.3 代表的な適応アルゴリズム

### 2.3.2 学習同定法 (NLMS)

LMS とは別に野田，南雲により学習同定法が提案されている．学習同定法は Normalized LMS とされるように LMS アルゴリズムの修正方向ベクトルを入力信号ベクトルのノルムの自乗で正規化することにより得られる．したがって学習同定法の係数更新式は

$$\mathbf{h}_N(i+1) = \mathbf{h}_N(i) + \alpha \frac{\mathbf{x}_N(i)}{\|\mathbf{x}_N(i)\|^2} e(i) \quad (2.16)$$

と表すことができる．ただし  $\alpha$  はステップサイズであり， $\|\cdot\|$  はベクトルのユークリッドノルムを表し，2乗和の平方根と定義する．学習同定法は LMS アルゴリズムに比べやや演算量が増えるものの，比較的演算量が少なくハードウェアの構成が容易であるという理由から，LMS アルゴリズムと同様に広く利用されている適応アルゴリズムの1つである．式 (2.16) と LMS アルゴリズムの係数更新式である式 (2.15) を比較すると，NLMS アルゴリズムは係数更新ごとに LMS アルゴリズムのステップサイズを入力信号のユークリッドノルムとした可変ステップサイズ LMS アルゴリズムと見ることができる．また，式 (2.16) におけるステップサイズ  $\alpha$  を 1 と置いた場合，

$$\mathbf{h}_N(i+1) = \mathbf{x}_N(i) [\mathbf{x}_N(i)^T \mathbf{x}_N(i)]^{-1} \mathbf{x}_N(i)^T [\mathbf{w}_N - \mathbf{h}_N(i)] \quad (2.17)$$

と表され，直交射影に基づく適応アルゴリズムという捉え方もできる．つまり，ベクトル  $[\mathbf{w}_N - \mathbf{h}_N(i)]$  を  $\mathbf{x}_N(i)$  の張る空間へ直交射影することにより，係数ベクトル  $\mathbf{h}_N(i+1)$  を得る．NLMS アルゴリズムはステップサイズを  $0 < \alpha < 2$  で設定することで収束性を保証できることが明らかになっている．NLMS アルゴリズムも LMS アルゴリズムと同様に有色性の信号に対し収束速度が低下する問題点がある．

### 2.3.3 Recursive Least-Square (RLS) アルゴリズム

LMS や学習同定法といった係数修正を行うのにその時刻における入力信号ベクトルのみを用いる手法では有色の入力信号に対して自己相関行列の固有値の広がりから著しく収束速度が劣化することが知られている．適応信号処理の応用例で使用される多くの信号が有色性

## 2.3 代表的な適応アルゴリズム

であることを考慮すると，この種の信号に対する収束速度の高速化は当然の要求といえる．

RLS アルゴリズムはこの種の要求に応えるアルゴリズムであり，指数重みコスト関数

$$J(i) = \sum_{t=0}^i \lambda^t |e(i-t)|^2, \quad (2.18)$$

を用いた最小二乗問題の解法である．

係数重みベクトルの最適値は以下の正規方程式となる．

$$\Phi(i) = \sum_{t=1}^i \lambda^{i-t} \mathbf{x}(t) \mathbf{x}^T(t) = \lambda \Phi(i-1) + \mathbf{x}(i) \mathbf{x}^T(i), \quad (2.19)$$

$$\mathbf{z}(i) = \sum_{t=1}^i \lambda^{i-t} d(t) \mathbf{x}(t) = \lambda \mathbf{z}(i-1) + d(i) \mathbf{x}(i), \quad (2.20)$$

$$\Phi(i) \mathbf{h}(i) = \mathbf{z}(i). \quad (2.21)$$

ここで， $\lambda$  は指数重みや忘却係数と呼ばれる過去の信号の影響を制限するために用いられるパラメータで，一般的には 1 に非常に近い 1 以下の値が用いられる．式 (2.21) を  $\mathbf{h}(i)$  について解くと

$$\mathbf{h}(i) = \Phi^{-1}(i) \mathbf{z}(i). \quad (2.22)$$

となる．ここで再帰的に相関行列  $\Phi(i)$  に対し逆行列の補助定理を用いることで再帰的な逆行列を得ることが可能になる．例えば，指数重み付き RLS アルゴリズムにおける係数ベクトルの更新式は以下ようになる．

$$\mathbf{S}(n) = \frac{1}{\lambda} \left[ \mathbf{S}(n-1) + \frac{\Psi(n) \Psi^T(n)}{\lambda + \Psi^T(n) \Psi(n)} \right], \quad (2.23)$$

$$\mathbf{h}(n+1) = \mathbf{h}(n) + \mathbf{S}(n) e(n), \quad (2.24)$$

$$\Psi(n) = \mathbf{S}(n-1) \mathbf{X}(n). \quad (2.25)$$

RLS アルゴリズムは係数更新を開始してからの全ての入力信号の情報を係数更新に利用していると言える．そのため，LMS アルゴリズムや次に述べるアフィン射影アルゴリズムなどに比べ高い収束速度を実現できる．

## 2.3 代表的な適応アルゴリズム

### 2.3.4 アフィン射影アルゴリズム

アフィン射影算法はフィルタ係数を修正するために，ある時刻  $i$  における入力信号ベクトル  $\mathbf{x}_N(i)$  のみならず，適当な数の過去の入力信号ベクトルをも加えた，複数個の入力ベクトルを用いている．これらの係数修正手順は，

$$\mathbf{h}_N(i+1) = \mathbf{h}_N(i) + A_{PN}(i)^+ \cdot \mathbf{e}_P(i) \quad (2.26)$$

$$\begin{aligned} \mathbf{e}_P(i) &= d_P(i) - A_{PN}(i) \cdot \mathbf{h}_N(i) \\ &= A_{PN}(i)[\mathbf{w}_N - \mathbf{h}_N(i)] \end{aligned} \quad (2.27)$$

で与えられる．なお， $P$  は射影次数をあらわし，過去の入力信号ベクトル数を意味する．ここで， $A_{PN}(i)$  は

$$A_{PN}(i) = [\mathbf{x}_N(i-P+1), \mathbf{x}_N(i-P+2), \dots, \mathbf{x}_N(i)]^T \quad (2.28)$$

で定義され， $A_{PN}(i)^+$  は  $A_{PN}(i)$  の Moore-Penrose 型一般逆行列であり

$$A_{PN}(i)^+ = [A_{PN}(i) \cdot A_{PN}(i)^T]^{-1} \cdot A_{PN}(i)^T \quad (2.29)$$

と表すことができる．

ここで，式 (2.26)，式 (2.27) より

$$\mathbf{h}_N(i+1) - \mathbf{h}_N(i) = A_{PN}(i)^+ A_{PN}(i)[\mathbf{w}_N - \mathbf{h}_N(i)] \quad (2.30)$$

が成り立つ．幾何学的な見地から考察すると式 (2.30) の右辺中の行列  $[A_{PN}(i)^+ A_{PN}(i)]$  は  $A_{PN}(i)$  の行ベクトルが張る部分空間  $S[A_{PN}(i)^T]$  への直交射影行列である．したがって，式 (2.30) は  $\mathbf{h}_N(i+1)$  が  $\mathbf{w}_N$  を  $S[A_{PN}(i)^T]$  へ直交射影することによって得られる点であることを意味している．

このように，係数修正を行うのに複数個の入力信号ベクトルを用いることにより，有色信号入力時にも収束特性の高速化が可能となる．しかしながら，式 (2.30) からわかるように，この方式は1サンプルごとに一般逆行列の計算を繰り返さなければならず，ブロック長が大きくなるにつれてフィルタ係数の修正を行うための演算量は膨大なものになってしまうという問題がある．



## 2.4 適応信号処理の適用例

現在，適応信号処理の理論は様々な分野でその研究，利用がされている．本節では，適応信号処理の応用例の代表的なものとして，適応ノイズキャンセラ，自動等化器をシステムのモデル図を用いながら説明する．ただし， $W(z)$ ， $H(z)$ ， $C(z)$  は離散時間伝達関数を表している．

### 2.4.1 適応ノイズキャンセラ

所望信号が雑音の影響を受けている場合，雑音の影響をできる限り排除し，所望信号に近い信号を得るという信号処理は応用範囲が広いと考えられる．

図 2.2 は適応ノイズキャンセラの基本的なモデルである．もし 2.2 のように雑音だけを観測可能であるならば，適応ノイズキャンセラによって効率よく所望信号だけを取り出すことが可能である．また，図 2.2 は 2.3 のようにパラメータ推定問題としてとらえることができる．主入力として，所望信号  $x(i)$  と雑音  $\hat{n}(i)$  の和，すなわち主入力信号  $v(i)$  が入力されるとする．所望信号  $x(i)$  が参照入力に混入しない場合（雑音  $n(i)$  と無相関），参照入力  $n(i)$  に対し適当な線形処理を施し，主入力信号  $v(i)$  から減産することにより所望信号  $x(i)$  のみを取り出すことができる．この場合，推定システムの伝達関数  $H(z)$  と未知システムの伝達関数  $W(z)$  が等しければ推定システムの出力信号  $y(i)$  と主入力における雑音  $\hat{n}(i)$  が等しくなり完全に雑音を除去することができる．すなわち，あるシステム  $W(z)$  の構造が既知であるならば，適応フィルタ  $H(z)$  により  $W(z)$  のパラメータを推定することにより， $y(i)$  を  $\hat{n}(i)$  に近付け  $e(i)$  を最小にすることが可能である．このことから，適応ノイズキャンセラにおけるパラメータ推定の重要性が示される．

### 2.4.2 自動等化器

通信を行う際，信号が受信点に到達するまでに，伝送路ひずみ，雑音などの影響を受ける．このような状況下において，信号の劣化を受信点で保証するために自動等化器を用い

## 2.4 適応信号処理の適用例




図 2.2 適応ノイズキャンセラ

Fig.2.2 Adaptive Noise Canceller.

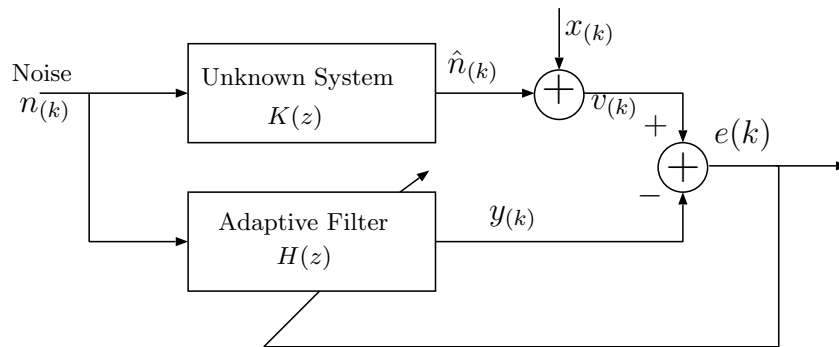


図 2.3 適応ノイズキャンセラにおけるパラメータ推定

Fig.2.3 Parameter Estimation on Adaptive Noise Canceller.

る．自動等化器では実際に通信を行う前に，あらかじめトレーニング信号等のテスト信号を送信する．したがって，トレーニング期間では送信される信号つまり所望信号が既知であるため，自動等化器からの出力信号と，トレーニング信号の差をとることにより，等化器の係数を修正する．また，トレーニング期間を一定間隔で設けることにより，伝送路の時間的変動に対しても等化器のパラメータを追従させることが可能となる．図 2.4 に自動等化器を用いたデジタル伝送系を示す．なお， $C(z)$  は伝送路を表す．このように，自動等化器もノ

## 2.5 まとめ




図 2.4 デジタル伝送系

Fig.2.4 Digital Communication System.

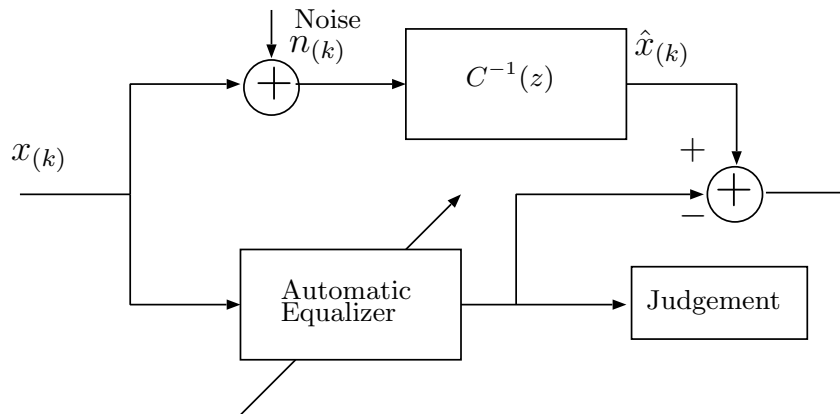


図 2.5 デジタル伝送系

Fig.2.5 Parameter Estimation on Digital Communication System.

イズキャンセラと同様，パラメータ推定問題に帰着する．そのようすを図 2.5 に示す．

## 2.5 まとめ

本章では適応信号処理の歴史とその発展について述べ，いくつかの代表的な適応アルゴリズムについての説明を行った．また，適応信号処理の具体的な適用例として，適応ノイズキャンセラ，自動等化器について述べ適応信号処理の必要性を明らかにした．

## 第 3 章

# スパースなシステムに対する適応信号処理

従来の適応アルゴリズムは，適応フィルタのフィルタ長が増加するに従い，収束速度の低下が起こる．即ち，推定の対象とするインパルス応答長が長いほど適応アルゴリズムの収束速度は低くなる．幸いなことに，実際の必要とするインパルス応答長が大きなシステムでもその構造はインパルス応答の大部分が 0 や非常に小さな値で占められているスパースなシステムであることが多い．この事実を元に，スパース構造を持つ長いインパルス応答長をもつシステムに対する収束速度の向上を目的とする適応アルゴリズムがいくつか提案された．例えば，エコーなどで発生するバルクディレイと呼ばれるインパルス応答の初期部分に存在する遅延に相当する箇所を推定する手法 [13–15] やインパルス応答が存在するアクティブな箇所を推定し，そのタップのみ係数更新を行う手法 [16, 17] や選択的に更新箇所を変化させていくパーシャルアップデート [18–25] と呼ばれる手法等がある．係数比例型 (Proportionate Type) の適応アルゴリズムはこのような背景から近年研究され始めたものであり，既存の収束速度向上法のように事前にアクティブなタップを設定する必要がなく，かつ動的に適応フィルタのタップ毎に異なるステップサイズを与えることができるアルゴリズムである．

本章では，はじめに PtNLMS アルゴリズムの収束特性を決定する大きな要因である，システムのスパース性について説明を行う．次いで，係数比例型の適応アルゴリズムのなかで NLMS を基礎としたいいくつかの係数比例型アルゴリズム (Proportionate Type NLMS, PtNLMS) の説明を行う．

### 3.1 システムのスパース性

## 3.1 システムのスパース性

システムのスパース性とはシステム全体のインパルス応答に対し、振幅の大きい部分がどの程度集結しているかを表す。インパルス応答が一箇所に集中しているような場合、そのシステムは高いスパース性を有するという。インパルス応答がデルタ関数であるシステム、すなわち遅延のみのシステムは完全にスパースなシステムである。システム  $w$  のスパース性を評価する指標  $\xi(w)$  として本論文では [26] で提案されている

$$\xi(w) = \frac{L}{L - \sqrt{L}} \left( 1 - \frac{\|w\|_1}{\sqrt{L}\|w\|_2} \right) \quad (3.1)$$

を用いる。ただし  $L$  は 2 以上であるシステムの応答長で  $\|w\|_1$  ,  $\|w\|_2$  はそれぞれ

$$\|w\|_1 = \sum_{n=0}^{L-1} |w(n)| \quad (3.2)$$

$$\|w\|_2 = \sqrt{\sum_{n=0}^{L-1} w^2(n)} \quad (3.3)$$

で計算される  $L_1$  ,  $L_2$  ノルムを表す。 $\xi(w)$  はスパース性が高いシステムほど 1 へ、またスパース性が低下するごとに 0 へと近づく。

## 3.2 PtNLMS アルゴリズム

LMS アルゴリズムの係数更新式 (2.15) に対し、適応フィルタの各係数に対してステップサイズを適用できるステップサイズ行列  $G_{NN}$  を適用すると

$$\mathbf{h}_N(i+1) = \mathbf{h}_N(i) + \alpha G_{NN}(i) \mathbf{x}_N(i) e(i) \quad (3.4)$$

となる。ただし、 $G_{NN}$  は

$$G_{NN}(i) = \text{diag}\{g_0(i), g_1(i), \dots, g_{N-1}(i)\} \quad (3.5)$$

で表される対角行列である。

式 (3.4) に対し NLMS アルゴリズムと同様に入力信号のノルムで正規化を行うことで [5] で提案された最初の PNLMS アルゴリズムである

$$\mathbf{h}_N(i+1) = \mathbf{h}_N(i) + \alpha G_{NN}(i) \frac{\mathbf{x}_N(i)}{\|\mathbf{x}_N\|^2} e(i) \quad (3.6)$$

## 3.2 PtNLMS アルゴリズム

となる．しかしながら，インパルス性の高い入力信号に対してアルゴリズムが不安定になるという問題が指摘されている [27]．そこで，現在提案されている PtNLMS アルゴリズムは分母にステップサイズ行列で重みを付けたノルム  $[\mathbf{x}_N^T(i)G_{NN}\mathbf{x}_N(i)]$  に置き換えた係数更新式

$$\mathbf{h}_N(i+1) = \mathbf{h}_N(i) + \rho \frac{e(i)G_{NN}(i)\mathbf{x}_N(i)}{\mathbf{x}_N^T(i)G_{NN}(i)\mathbf{x}_N(i)} \quad (3.7)$$

を基礎としている．ただし， $\rho$  は係数全体に作用するステップサイズである．

なお，PtNLMS によっては右辺第 2 項の分母に正規化パラメータである  $\delta$  が加えられているものもあるが，これは推定開始直後における安定性や小さな入力に対するアルゴリズムの安定性を向上させるものであり，議論を簡単化するため本論文では考慮しない．式 (3.7)，(2.16) を比較すると PtNLMS アルゴリズムでは NLMS アルゴリズムに対しステップサイズ行列  $G_{NN}$  が存在するという違いがある．

式 (3.7) を元に， $G_{NN}$  の算出法の違いから様々な PtNLMS アルゴリズムが提案されている．代表的な PtNLMS アルゴリズムを以降説明する．

### 3.2.1 PNLMS アルゴリズム

PNLMS アルゴリズムのステップサイズ行列算出は

$$\gamma_n(i) = \max[|h_n(i)|, \eta \max\{\delta_\eta, |h_0(i)|, \dots, |h_{N-1}(i)|\}] \quad (3.8)$$

$$g_n(i) = \frac{\gamma_n(i)}{\sum_{n=0}^{N-1} |\gamma_n(i)|} \quad (3.9)$$

である [5]．ただし， $\delta_\eta$  は推定開始時における安定性を与えるパラメータであり， $\eta$  は非常に小さな値をもつフィルタ係数の更新により起こるアルゴリズムの発散を回避するためのパラメータである．PNLMS アルゴリズムの基本的な考え方は，現在までに推定されているフィルタ係数の大小関係から係数更新時における，タップごとのステップサイズを決定するということである．PNLMS は対象とするシステムがスパースな場合には NLMS よりも高速な収束を実現できる．しかしながら，対象とするシステムが非スパースなシステムであった場

## 3.2 PtNLMS アルゴリズム

合には、収束速度が NLMS より劣る場合があることが明らかになっている。また、推定の初期における収束後は NLMS よりも大幅に収束速度が劣化してしまうという問題もある。

### 3.2.2 IPNLMS アルゴリズム

PNLMS に対する非スパースなシステムへの対応や、収束速度劣化の問題に対し、NLMS と PNLMS を直接的に結合した IPNLMS が提案されている [28]。IPNLMS アルゴリズムのステップサイズ行列算出は

$$g_n(i) = \frac{1 - \beta}{2N} + (1 + \beta) \frac{|h_n(i)|}{2\|\mathbf{h}\|_1} \quad (3.10)$$

である。ただし  $\beta$  は NLMS と PNLMS の結合割合を調整するパラメータであり  $-1 \leq \beta < 1$  である。IPNLMS は  $\beta = -1$  の場合に NLMS と等価となり、1 に近づくほど PNLMS に近づく。 $\beta$  の設定値が収束特性に与える影響として、 $\beta$  が小さいほど非スパースな場合でも収束速度の劣化は起きにくくなるが収束速度の向上効果は小さくなり、同様に  $\beta$  が大きいほど収束速度の向上効果は大きくなるが、非スパースなシステムに対する収束速度劣化の抑止効果が下がるということが挙げられる。

### 3.2.3 MPNLMS アルゴリズム

PNLMS アルゴリズムでは初期の収束後の収束速度劣化が問題となる。これは、PNLMS アルゴリズムは値が大きい係数に対して大きすぎる、小さい係数に対しては小さすぎる係数修正を与えてしまうからである。この問題に対し、収束特性の解析からステップサイズ行列を算出する際に PNLMS で使われる直接係数推定値の大きさを対数での大きさとした  $\mu$ -law PNLMS アルゴリズムが提案されている [29, 30]。

MPNLMS アルゴリズムのステップサイズ行列算出は PNLMS の式 (3.8) を

$$\begin{aligned} \gamma_n(i) = \max[ & F(|h_n(i)|), \\ & \eta \max\{\delta_\eta, F(|h_0(i)|), \dots, F(|h_{N-1}(i)|)\} \end{aligned} \quad (3.11)$$

### 3.3 まとめ

としたものである．ただし，

$$F(|h_n(i)|) = \ln(1 + \mu|h_n(i)|) \quad (3.12)$$

であり， $\mu$  は正の整数である．

#### 3.2.4 PNLMS++ アルゴリズム，CPNLMS アルゴリズム

PNLMS++ アルゴリズムは初期収束後の PNLMS アルゴリズムの収束特性を改善するために文献 [27] で提案されたもので，時刻  $i$  が奇数の場合には PNLMS アルゴリズムで係数更新を， $i$  が偶数の場合には NLMS アルゴリズムで更新を行うものである．PNLMS++ アルゴリズムは NLMS アルゴリズム程度の収束特性は最低でも確保できる利点があるが，推定初期における収束速度の劣化原因となることが分かっている．

また，Composite PNLMS (CPNLMS) アルゴリズムも PNLMS++ アルゴリズムと同様に NLMS アルゴリズムと PNLMS アルゴリズムを切り替える手法であるが，CPNLMS アルゴリズムでは収束速度の検出を行い，PNLMS アルゴリズムの収束速度の低下を検出すると NLMS アルゴリズムに切り替える手法である．CPNLMS アルゴリズムは PNLMS アルゴリズムの初期収束後の速度低下を改善する効果的な手法であるが，収束速度が低下したと判断する効果的な閾値の決定法が存在しないことが大きな問題である．

### 3.3 まとめ

本章では，スパースなシステムに対する収束速度向上法であり，学習同定法に基づいた係数比例型適応アルゴリズムである，係数比例型学習同定法について，その枠組みの算出過程を述べ，アルゴリズムの主要な部分であるステップサイズ行列の算出手法についてこれまで提案されているいくつかのアルゴリズムについて紹介を行った．同時に，これらのアルゴリズムの収束特性を決定付ける重要な要因であるシステムのスパース性について，その定義および，スパース性の尺度を計算する手法について紹介を行った．



## 第 4 章

# ステップサイズの算出法に依存しない可変ステップサイズ係数比例型アルゴリズム

PtNLMS が用いられるエコーキャンセラ等のシステムは比較的時間変動が大きく，高速な追従性が必要とされるため高い推定精度と収束速度の両立が求められる．一般的に，LMS アルゴリズムや学習同定法などの適応アルゴリズムではステップサイズを推定状況に合わせて調整を行う可変ステップサイズの手法を用いることでこの要求に応えることができる．

本章では，PtNLMS アルゴリズムに対する収束特性の向上手法として，この可変ステップサイズを PtNLMS アルゴリズムに適用した，可変ステップサイズ型 PtNLMS アルゴリズム（VSS-PtNLMS）について述べる．また，PtNLMS アルゴリズムの拡張である PAPA に同様の可変ステップサイズを用いた手法について述べる

### 4.1 準備

以降の説明において使用する記号を再度定義しておく．

時刻  $i$  における入力信号  $x(i)$  に対して，適応フィルタの状態ベクトル，係数ベクトルを

$$\mathbf{x}_N(i) = [x(i), x(i-1), \dots, x(i-N+1)]^T \quad (4.1)$$

$$\mathbf{h}_N(i) = [h_0(i), h_1(i), \dots, h_{N-1}(i)]^T \quad (4.2)$$

とする．ここで， $N$  は適応フィルタのインパルス応答長であり， $^T$  は転置を表す．適応フィ

## 4.2 可変ステップサイズ PtNLMS アルゴリズム

ルタの入出力関係は

$$y(i) = \mathbf{h}_N^T \mathbf{x}_N(i) \quad (4.3)$$

で与えられる．また，所望信号を

$$d(i) = \mathbf{w}_N^T \mathbf{x}_N(i) + v(i) \quad (4.4)$$

とすると，出力誤差は

$$e(i) = d(i) - y(i) \quad (4.5)$$

となる．ただし  $\mathbf{w}_N$  は未知系のインパルス応答， $v(i)$  は観測雑音である．

## 4.2 可変ステップサイズ PtNLMS アルゴリズム

NLMS アルゴリズムの拡張である PtNLMS アルゴリズムでは可変ステップサイズの手法を用いることで収束特性の向上が可能であると考えられるが，先に示したとおり，PtNLMS は係数更新の過程において非線形な最大値演算，対数演算等を用いるものが多く，また，アルゴリズムを適用するシステムにより大きくその収束性を変化させてしまう等，収束特性の解析から最適ステップサイズを算出することが困難である．そこで，PtNLMS アルゴリズムに対し，ステップサイズ行列の算出法に依らない統一的な可変ステップサイズ PtNLMS アルゴリズムの提案を行う．本手法の導出過程において，PtNLMS アルゴリズムの最適ステップサイズは NLMS における最適ステップサイズと同一であり，アルゴリズムごとのステップサイズ行列の算出法の違いを考慮せず適用可能であることを示し，計算機シミュレーションにより代表的な PtNLMS アルゴリズムに対し提案手法を適用しその有効性に付いて確認を行う．

提案するアルゴリズムは PtNLMS においてステップサイズ行列の算出方法に係わらず可変ステップサイズの適用が可能であることを示す．また，同様の方法を用いた NLMS アルゴリズムにおけるステップサイズの最適制御との関係についても述べる．

### 4.3 PtNLMS アルゴリズムにおける最適ステップサイズ

PtNLMS の係数更新式 (3.7) において，時刻  $i$  における最適なステップサイズ  $\alpha$  は推定後の定常解析を仮定すると，係数更新後の出力誤差

$$e'(i) = d(i) - \mathbf{h}_N^T(i+1)\mathbf{x}_N(i) \quad (4.6)$$

の 2 乗期待値

$$E[e'^2(i)] = E[d^2(i)] - E[\{\mathbf{h}_N^T(i+1)\mathbf{x}_N(i)\}^2] \quad (4.7)$$

が最小となるものである．ただし  $E[\cdot]$  は期待値を表す．所望信号に雑音が存在しない場合，推定系が未知系を正確に推定すれば  $\mathbf{w}_N = \mathbf{h}_N(i+1)$  となり係数更新後の出力誤差の期待値は  $E[e'^2(i)] = 0$  となる．所望信号に雑音が重畳されている場合は

$$E[e'^2(i)] = E[\{\mathbf{x}_N^T(i)[\mathbf{w}_N - \mathbf{h}_N(i+1)]\}^2] + E[v^2(i)] \quad (4.8)$$

となり

$$E[e'^2(i)] = E[v^2(i)] \quad (4.9)$$

を満たせばよいことがわかる．

式 (4.6) に式 (3.7) を代入すると

$$\begin{aligned} e'(i) = & \mathbf{x}_N^T(i)[\mathbf{w}_N \\ & - (\mathbf{h}_N(i) + \alpha \frac{e(i)G_{NN}(i)\mathbf{x}_N(i)}{\mathbf{x}_N^T(i)G_{NN}(i)\mathbf{x}_N(i)})] + v(i) \end{aligned} \quad (4.10)$$

となる．また式 (4.10) に式 (4.5) を代入すると

$$e'(i) = e(n) - \mathbf{x}_N^T(i)\alpha \frac{e(i)G_{NN}(i)\mathbf{x}_N(i)}{\mathbf{x}_N^T(i)G_{NN}(i)\mathbf{x}_N(i)} \quad (4.11)$$

となり

$$e'(i) = [1 - \alpha]e(i) \quad (4.12)$$

とできる．雑音が存在しない場合は  $E[e'^2(i)] = 0$  とする  $\alpha$  が最適ステップサイズであるため， $\alpha = 1$  が最適ステップサイズである．

#### 4.4 可変ステップサイズへの拡張

所望信号に雑音が存在する場合は式 (4.12) の期待値をとり，式 (4.9) を代入した

$$E[v^2(i)] = [1 - \alpha]^2 E[e^2(i)] \quad (4.13)$$

を  $\alpha$  について解くと PtNLMS アルゴリズムにおける最適ステップサイズ

$$\alpha = 1 - \sqrt{\frac{E[v^2(i)]}{E[e^2(i)]}} \quad (4.14)$$

を得る．式 (4.14) とその導出過程から PtNLMS における最適ステップサイズはステップサイズ行列  $G_{NN}(i)$  に依存せず，観測雑音，出力誤差のみに関係することがわかる．

#### 4.4 可変ステップサイズへの拡張

最適ステップサイズ  $\alpha$  の算出式 (4.14) には出力誤差，観測雑音の期待値  $E[e^2(i)]$ ， $E[v^2(i)]$  が存在する．ここで， $E[e^2(i)]$  は推定状態によって変化するため各サンプル毎に算出する必要がある．まず，出力誤差，観測雑音の期待値を

$$E[e^2(i)] = \sigma_e^2(i) \quad (4.15)$$

$$E[v^2(i)] = \sigma_v^2(i) \quad (4.16)$$

とする．次に  $\sigma_e^2(i)$  を短時間平均である  $\hat{\sigma}_e^2(i)$  に置き換え，最適ステップサイズ  $\alpha$  を各時刻における  $\hat{\sigma}_e^2(i)$  から算出する可変ステップサイズ  $\alpha(i)$  とする．以上から，VSS-PtNLMS アルゴリズムのステップサイズ  $\alpha(i)$  は

$$\alpha(i) = 1 - \sqrt{\frac{\sigma_v^2(i)}{\hat{\sigma}_e^2(i)}} \quad (4.17)$$

となる．式 (4.17) から，推定初期においては  $\hat{\sigma}_e^2(i)$  は大きな値となり  $\alpha(i)$  は大きくなるため高い収束速度を実現する．また，推定が進むと  $\hat{\sigma}_e^2(i)$  は減少し  $\alpha(i)$  も小さくなるため結果として推定誤差は小さくなる．

#### 4.5 運用法

VSS-PtNLMS の運用時にはいくつかの考慮が必要となる．式 (4.17) から常に  $\hat{\sigma}_e^2(i) \geq \sigma_v^2(i)$  が成立する必要がある．ここで， $\hat{\sigma}_e^2(i)$  は逐次推定値であるため，瞬間的な観測雑音の

## 4.5 運用法




図 4.1 VSS-PtNLMS アルゴリズムの流れ図

Figure 4.1 Flow diagram of VSS-PtNLMS algorithm.

増加等の要因でも安定して動作させるために

$$\alpha(i) = \begin{cases} 1 - \sqrt{\frac{\sigma_v^2(i)}{\hat{\sigma}_e^2(i)}}, & \hat{\sigma}_e^2(i) \geq \sigma_v^2(i) \\ 0, & \text{otherwise} \end{cases} \quad (4.18)$$

とする．また， $\sigma_v^2(i)$  は観測雑音が白色かつ定常であれば無音区間等を用い正確に推定できるが，音声等の非定常信号であれば，時間平均などに置き換える必要がある．提案手法の流れ図を図 4.1 に示す．

提案手法を用いる際の問題点として観測雑音の分散  $\sigma_v^2(i)$  の推定の正確性が挙げられる．提案手法では  $\sigma_v^2(i)$  が正確に推定できているならば  $\alpha(i)$  は最適なステップサイズとなる．しかしながら， $\sigma_v^2(i)$  が不正確であれば収束特性に影響が出る． $\sigma_v^2(i) \gg E[v^2(i)]$  の場合， $\alpha(i)$  は最適値に対して小さくなり，収束速度が最適ステップサイズを用いたものに対し低くなる．一方，推定精度は推定を繰り返すことで高くなる．また， $\sigma_v^2(i) \ll E[v^2(i)]$  の場合に

## 4.6 演算量

は，収束速度は高くなるが，最終的な推定精度は最適値を用いたものに対し低くなる．この観測雑音の正確性が収束特性に与える影響については，次章において計算機シミュレーションを通じて確認を行う．

## 4.6 演算量

VSS-PtNLMS でオリジナルの PtNLMS に対して増加する演算量は  $1 - \sqrt{\frac{\sigma_v^2(i)}{\hat{\sigma}_e^2(i)}}$  を算出する減算 1，除算 1，2 乗根の演算 1 である．また， $\hat{\sigma}_e^2(i)$  の逐次推定に必要な演算量のみであり（4.8 で用いた例であれば減算 1，積算 3 である）係数更新全体の演算量に比較して少ない演算量となる．

## 4.7 NLMS における最適制御との比較

NLMS アルゴリズムにおけるステップサイズの最適制御を行う方法として文献 [31] で提案される手法がある．文献 [31] では係数更新後の誤差信号の期待値を最小とするという考え方は提案手法と同様であり，NLMS アルゴリズムの係数更新式 (2.16) におけるステップサイズ  $\alpha$  を

$$\alpha(i) = 1 - \frac{\sigma_v^2(i)}{\hat{\sigma}_e^2(i)} \quad (4.19)$$

とし，2つの適応フィルタを用い逐次誤差信号，観測雑音の分散を算出しながらステップサイズの制御を行う．式 (4.19) と PtNLMS アルゴリズムの最適ステップサイズ制御式 (4.17) を比較すると，係数更新後の誤差を最小とするステップサイズの算出法の違いにより右辺第 2 項が分散を直接用いているか 2 乗根をとっているかの差はあるが，ほぼ同様の制御式となっていることがわかる．また，式 (4.11) から (4.12) の算出を行う際に，ステップサイズ行列  $G$  は消去され，結果として PtNLMS アルゴリズムにおける最適ステップサイズは NLMS アルゴリズムと同様となることがわかる．

### 4.8 計算機シミュレーション

本章では、可変ステップサイズを用いた PtNLMS アルゴリズムの性能を評価するために計算機シミュレーションを行う。

#### 4.8.1 シミュレーション条件

シミュレーションはシステム同定を用いて行う。入力信号  $x(i)$  として、

1. 白色信号：平均零，分散  $1/60$  の正規乱数
2. 音声信号：成人男性の声を 8kHz でサンプリングした分散  $1/60$  の信号 (図 4.2 参照)

観測雑音  $v(i)$  を

1. 白色信号：平均零の正規乱数
2. 音声信号：入力信号とは独立な，成人女性の声を 8kHz でサンプリングした信号 (図 4.3 参照)

の 2 種類の信号とした。

また，シミュレーションに用いるインパルス応答として

1. スパース性の高いシステム ( $\xi(w) = 0.96$ ) (図 4.4 上側参照)
2. セミスパースなシステム ( $\xi(w) = 0.68$ ) (図 4.5 上側参照)

を用いシミュレーションを行った。

未知系，推定系のインパルス応答長はともに  $N = 512$  とし，シミュレーションで用いた全サンプルでの所望信号と観測雑音の比を  $10 \log_{10} \left( \sum_k d^2(k) / \sum_k v^2(k) \right) = 30\text{dB}$  (定常信号を用いた場合の  $S/N=30\text{dB}$  に相当) とした。またサンプル数 40000 でインパルス応答に遅延時間を与え変化させている (図 4.4，4.5 下側参照)。

収束特性の評価は正規化推定 2 乗誤差ノルム

$$10 \cdot \log_{10} \frac{\|\mathbf{w}_N - \mathbf{h}_N\|^2}{\|\mathbf{w}_N\|^2} \quad [\text{dB}] \quad (4.20)$$

## 4.8 計算機シミュレーション




図 4.2 入力信号（音声信号）

Figure 4.2 Wave form of speech input.




図 4.3 観測雑音（音声信号）

Figure 4.3 Wave form of speech noise.

を用い，収束特性の比較のために PtNLMS として PNLMS，IPNLMS，MPNLMS と上記 3 つのアルゴリズムに対して可変ステップサイズを適用した VSS-PNLMS，VSS-IPNLMS，VSS-MPNLMS アルゴリズムを用いる．それぞれのアルゴリズムで必要となるパラメータを [5, 28, 29] に従い  $\delta_\gamma = 0.01$ ， $\eta = 0.01$ ， $\alpha = -0.5$ ， $\varphi = 1000$  とした．また，ステップサ



## 4.8 計算機シミュレーション




図 4.4 未知系のインパルス応答（スパース）

Figure 4.4 Impulse Response case of Sparse).




図 4.5 未知系のインパルス応答（セミスパース）

Figure 4.5 Impulse Response (case of Semi-Sparse).

イズ  $\alpha$  は収束が最も速い 1.0 にした .

可変ステップサイズを算出する際必要となる時刻  $i$  における出力誤差の分散  $\sigma_e^2(i)$  の推定値  $\hat{\sigma}_e^2(i)$  は , 1 次の IIR フィルタを用いて

$$\hat{\sigma}_e^2(i) = (1 - b) \sum_{k=0}^{\infty} b^k e^2(i - k) \quad (4.21)$$

## 4.8 計算機シミュレーション

により求めた．ただし， $b$  は IIR フィルタの係数であり， $b = 0.999$  とした．式 (4.21) は雑音の影響を受けた信号から求めているため，観測雑音の分散を時間平均から算出する場合，瞬間的に  $\hat{\sigma}_e^2(i) \geq \sigma_v^2(i)$  を満たさない可能性がある．この点について，4.5 において述べた運用法を用いることで実用上問題が起こることはないことも結果で示す．

### 4.8.2 シミュレーション結果

まず，提案手法の動作を確認するためにスパース，セミスパースなシステムにおいて入力信号，観測雑音に白色信号を用いたシミュレーション結果を図 4.6，4.7 に示す．ただし，観測雑音の分散  $\sigma_v^2(i)$  は既知とし，結果は 100 回試行した平均である．図 4.6，4.7 から提案手法はシステムのスパース性に依らず，PNLMS，IPNLMS，MPNLMS いずれの手法に対しても収束速度を維持しながら推定精度を大幅に向上でき，可変ステップサイズにおいて期待される効果が得られていることが確認できる．また，未知系が変化した場合においてもシステムが不安定になること無く推定が行われていることが分かる．以上の結果から提案手法は対象とするシステムに依らず適用可能であり，またいずれの PtNLMS アルゴリズムであっても一般性を失わず提案手法の有効性を評価可能と考えられるため，以降のシミュレーションはスパースなシステムについては MPNLMS アルゴリズムについてのみ行う．

ここで，先ほどと同様の条件下の MPNLMS において各時刻において係数誤差ノルム  $\|w_N - h_N(i)\|$  が最小となるようステップサイズを  $0.01 \leq \alpha(i) \leq 1$  の範囲で 0.01 ずつ変化させた場合 (Optimal) と提案手法 (Proposed) での可変ステップサイズ  $\alpha(i)$  の推移例を図 4.8 に示す．図 4.8 から，提案手法では多少の誤差はあるが最適ステップサイズと同程度のステップサイズを算出でき，提案手法が定常信号における最適ステップサイズの算出に有効であることが確認できる．

次に，入力信号に音声信号，観測雑音に白色信号を用いた場合の収束特性を図 4.9 に示す．ただし，観測雑音の分散  $\sigma_v^2(i)$  は既知としている．図 4.9 から提案手法では非定常な信号が入力された場合でも可変ステップサイズを用いないものと比較し，推定精度の向上が確認できる．また，単語間の無音区間など著しく S/N が悪化する場合において，提案手法を用い

#### 4.8 計算機シミュレーション

ないものは推定精度が急激に悪化しているが、提案手法では推定精度の悪化を抑えられていることが確認できる。

最後に入力信号、観測雑音ともに音声信号を用いたシミュレーション結果を図 4.10 に示す。ただし、PtNLMS アルゴリズムが主に用いられるネットワークエコーキャンセラではこのような非定常雑音はあまり考慮しなくて良いことを記しておく。ただし、本シミュレーションでは

$$\text{ERLE} = 10 \log_{10} \frac{E[d^2(k)]}{E[e^2(k)]} [\text{dB}] \quad (4.22)$$

を評価量とする結果も同時に図 4.11 に示した。また、観測雑音の分散  $\sigma_v^2(i)$  としてシミュレーションで使った  $M$  個の全サンプルの 2 乗平均  $\frac{1}{M} \sum_k^M v^2(k)$  を既知のものとして与えている。これは、実アプリケーションにおいてはシステム動作前に観測雑音のみを観測し、長時間での平均値を使うことで実現できる。図 4.10, 4.11 より、入力信号、観測雑音ともに非定常な信号を提案手法で用いた場合、観測雑音の非定常性による収束特性への影響が大きく現れることが確認でき、非定常信号が観測雑音として存在する場合の問題点がわかる。まず、観測雑音の 2~3 秒、6~7 秒等に存在する無音区間に着目すると、提案手法である可変ステップサイズを用いたものは推定精度が向上せずグラフ上では水平方向への直線となり、対して固定ステップサイズである従来のものはこの区間において推定精度を大幅に向上していることが確認できる。これは、観測雑音の分散として全サンプルの平均を既知のものとして用いているため、平均値に対して大きく差がある区間において、最適ステップサイズの算出に影響がでているためと考えられる。つまり、観測雑音の減少から誤差信号が小さくなった場合であっても最適ステップサイズの前提としている観測雑音が実際より大きいためステップサイズを大きくできないと考えられる。ここで、観測雑音の分散を全サンプルでの平均とせず、出力誤差の分散と同様に式 (4.21) で示される逐次推定法を用い推定した場合の結果を図 4.12 に示す。図 4.12 から、提案手法において、観測雑音の分散を逐次的に推定している “Sequential Estimation” では MPNLMS、観測雑音を全サンプルの平均で算出した “Time Average” と比較すると、収束速度が最も速くなるステップサイズが 1 である MPNLMS と同等の初期収束を保ちながら、全サンプルの平均値を用いた結果より最大

#### 4.9 係数比例アフィン射影アルゴリズム

で 20dB ほどの推定精度の改善が確認できる．ここで，本シミュレーションにおける前半 5 秒間のステップサイズの推移を図 4.13 に示す．図 4.13 から，観測雑音が非常に小さくなる区間では誤差信号の分散が小さくなるため，Time Average ではステップサイズがほぼ 0 になっていることが確認できる．適応アルゴリズムでは一般的に観測雑音が小さい場合には大きなステップサイズを用い高い収束速度で推定が行えるが，Time Average ではこのようなステップサイズの制御を行えていない．一方，逐次推定を用いたものは，観測雑音が小さい区間では大きなステップサイズとなり，2 秒や 4 秒前後で出現する大きな観測雑音の区間ではステップサイズを極めて小さくなる．このことから，提案手法を非定常な観測雑音下で用いる場合には，観測雑音の分散の正確性がアルゴリズム全体の大きな要因となることがわかる．また，本シミュレーションを通して，観測雑音として時間平均を用いたもので，雑音の瞬時値が平均値から大きく離れた場合であっても式 (4.18) の方法を用いることで追従性は犠牲になるが，ステップサイズを 0 とすることでアルゴリズムの安定性を損なわないことが確認でき，実用上は問題は無いと考える．

#### 4.9 係数比例アフィン射影アルゴリズム

PNLMS アルゴリズムにおける最適ステップサイズ行列  $G(i)$  は入力信号が白色雑音であることを仮定している．PNLMS アルゴリズムは LMS アルゴリズムや NLMS アルゴリズムと同じように，音声などの特に有色性の強い信号に対して入力信号の自己相関行列の固有値の広がりにより起因した収束速度の低下が起こる．係数比例アフィン射影算法 (Proportionate Affine Pojection Algorithm, PAPA) は NLMS アルゴリズムに対するアフィン射影アルゴリズムと同様な PNLMS アルゴリズムに対する自然な拡張であり，有色性の高い入力信号に対して演算量を大幅に増やすことなく，高い収束速度を実現する手法である．アフィン射影アルゴリズムでは現在の入力信号ベクトルだけでなく，過去の  $P$  個の入力信号ベクトルを係数修正時の情報として用いる．PAPA も NLMS アルゴリズムと PNLMS アルゴリズムの関係と同様に，アフィン射影アルゴリズムに対し，ステップサイズ行列を適用したもので

#### 4.10 PAPA における最適ステップサイズ

あり，PNLMS アルゴリズムよりも有色性の高い信号に対して高い収束速度が期待できる．  
本節では過去 [33] で提案した VSS-PAPA の紹介を行う．

PAPA の係数更新式は

$$\mathbf{h}(i+1) = \mathbf{h}(i) + \alpha G(i)X(i) [X^T(i)G(i)X(i) + \delta I]^{-1} \mathbf{e}(i) \quad (4.23)$$

である．ただし， $X(i)$  は，入力信号行列

$$X(i) = [\mathbf{x}(i), \mathbf{x}(i-1), \dots, \mathbf{x}(i-P+1)] \quad (4.24)$$

であり， $\alpha$ ， $\delta$ ， $I$  はそれぞれ，ステップサイズ，正規化パラメータ， $P \times P$  の単位行列である．

#### 4.10 PAPA における最適ステップサイズ

PAPA も先に述べた PtNLMS と同様に係数更新式中に  $G(i)$  が存在する．そのため，一般的な収束特性の解析を用いた最適ステップサイズの算出が困難である．

アフィン射影アルゴリズムは，係数更新後の出力誤差が 0 となり，かつ現在の係数ベクトルに可能な限り近い係数更新を行う最小摂動に基づき導出される [2, 3, 27]．

ここで，係数更新後の出力誤差ベクトル  $\mathbf{r}(i)$  は以下のように定義される [27]．

$$\begin{aligned} \mathbf{r}(i) &= \mathbf{d}(i) - X^T(i)\mathbf{h}(i+1) \\ &= X^T(i)\tilde{\mathbf{h}}(i+1) + \mathbf{v}(i), \end{aligned} \quad (4.25)$$

$$\tilde{\mathbf{h}}(i) = \mathbf{w} - \mathbf{h}(i). \quad (4.26)$$

ただし， $\tilde{\mathbf{h}}(i)$  は係数誤差ベクトル， $\mathbf{v}(i)$  は

$$\mathbf{v}(i) = [v(i) \ v(i-1) \ \dots \ v(i-P+1)]^T \quad (4.27)$$

である観測雑音ベクトルである．

アフィン射影アルゴリズムは観測雑音等の外乱が存在しない場合には，それぞれの係数更新において， $\mathbf{r}(i)$  を消去する最速の収束かつ推定誤差が 0 となる最小摂動を満たす．この条件下では最適ステップサイズは 1 となる．しかしながら，実際のアプリケーションでは内外

#### 4.10 PAPA における最適ステップサイズ

部からの雑音に起因した観測雑音  $v(i)$  が存在するため，適応アルゴリズムにおける係数誤差は 0 とならない．このような環境下において  $r(i)$  を 0 にする適応フィルタの更新法として文献 [34] において式 (4.28) で表される，係数更新後の推定誤差を 0 とする手法が提案されている．

$$X^T(i)\tilde{\mathbf{h}}(t+1) = \mathbf{0}. \quad (4.28)$$

ただし， $\mathbf{0}$  は  $P \times 1$  の零ベクトルである．式 (4.25)，(4.28) より，観測雑音の存在する環境下において係数更新後の推定誤差を 0 とするためには

$$\mathbf{r}(i) = \mathbf{v}(i) \quad (4.29)$$

としなければならないことが分かる．実際のアプリケーションでは，観測雑音  $v(i)$  は事前に知ることはできないが，期待値を推定することは可能である．そのため，最適ステップサイズは以下の方法で得ることができる．

まず，

$$E[r_p^2(i)] = E[v_p^2(i)], \quad p = 0 \cdots P-1 \quad (4.30)$$

を仮定する．ただし， $r_p(i)$  は  $\mathbf{r}(i)$  の  $p$  番目の要素であり， $v_p(i)$  は  $\mathbf{v}(i)$  の  $p$  番目の要素である．ここで， $v_p(i) = v(t-p)$  である．可変ステップサイズ PAPA は式 (4.23) に  $P \times P$  の時変なステップサイズ行列  $\alpha(i)$  を導入した，

$$\mathbf{h}(t+1) = \mathbf{h}(i) + G(i)X(i) [X^T(i)G(i)X(i)]^{-1} \alpha(i) \mathbf{e}(i) \quad (4.31)$$

となる．式 (4.31) の両辺を  $w$  から減算を行うと，

$$\tilde{\mathbf{h}}(t+1) = \tilde{\mathbf{h}}(i) - G(i)X(i) [X^T(i)G(i)X(i)]^{-1} \alpha(i) \mathbf{e}(i) \quad (4.32)$$

を得る．(4.32) の両辺に  $X^T(i)$  を乗算し，また係数更新前後の誤差の関係から，

$$r_p(i) = [1 - \alpha_p(i)] e_p(i) \quad (4.33)$$

となる．ただし， $\alpha_p(i)$  は対角行列  $\alpha(i)$  の  $p$  番目の対角要素， $e_p(i)$  は  $\mathbf{e}(i)$  の  $p$  番目の要素である．この結果は PAPA との関係という点で大変興味深いものである．式 (4.33) から，

#### 4.10 PAPA における最適ステップサイズ

推定誤差  $r(i)$  は  $G(i)$  と独立であり，ステップサイズ  $\alpha(i)$  と誤差ベクトル  $e(i)$  からのみ決定される．つまり，この関係から PAPA に対してシンプルな可変ステップサイズの導入が可能である．以下は，アフィン射影アルゴリズムに対して可変ステップサイズを導入した [35] と同様となる．

まず，式 (4.33) の両辺の 2 乗期待値をとり，式 (4.30) と結合し

$$E[r_p^2(i)] = [1 - \alpha_p(i)]^2 E[e_p^2(i)] = E[v^2(t-p)] \quad (4.34)$$

を得る．式 4.34 を  $\alpha_p(i)$  について解くことで， $p$  番目の時変なステップサイズ  $\alpha_p(i)$  は

$$\alpha_p(i) = 1 - \sqrt{\frac{\sigma_v^2(t-p)}{\sigma_{e_p}^2(i)}} \quad (4.35)$$

と表すことができる．ただし， $\sigma_v^2(t-p)$ ， $\sigma_{e_p}^2(i)$  はそれぞれ  $v(t-p)$ ， $e_p(i)$  の分散である．

(4.35) より，フィルタの過渡応答においては， $\sigma_{e_p}^2(i)$  が大きくなり算出される  $\alpha_p(i)$  も大きくなり，結果，高い収束速度が期待できる．また，フィルタの収束が最適値近辺に近づいてくると， $\sigma_{e_p}^2(i)$  は小さくなるため  $\alpha_p(i)$  も小さくなり，この結果，高い推定精度を得られる．

本手法を実際に運用するためには，先に述べた VSS-PtNLMS アルゴリズムと同様にいくつかの考慮が必要である．まず，可変ステップサイズを算出するために必要な  $\sigma_{e_p}^2(i)$ ， $\sigma_v^2(i)$  であるが， $e_p^2(i)$  は実際に観測可能な信号であるため， $\sigma_{e_p}^2$  は指数窓を用いた逐次推定値  $\hat{\sigma}_{e_p}^2(i)$

$$\hat{\sigma}_{e_p}^2(i) = \lambda_1 \hat{\sigma}_{e_p}^2(t-1) + (1 - \lambda_1) e_p^2(i), \quad (4.36)$$

に置き換えることで推定できる．ただし  $\lambda_1$  は

$$\lambda_1 = 1 - 1/(K_1 N), \quad (K_1 \in \mathbb{Z}^+, K_1 \geq 1) \quad (4.37)$$

である． $K_1$  に大きな値を用いることで  $\sigma_{e_p}^2(i)$  の滑らかな推定が可能となるが，適応フィルタの追従性は低下する．観測雑音の分散  $\sigma_v^2(i)$  は実際のアプリケーションでは音声における無音区間などから推定した  $\hat{\sigma}_v^2(i)$  を用いる．観測雑音の推定については雑音推定専用の追加の適応フィルタを用いる方法等も提案されている [36] ．

#### 4.10 PAPA における最適ステップサイズ

次に， $\alpha_p(i)$  の算出結果によるアルゴリズムの安定性の問題がある．提案する算出法では，推定による理論値との差からステップサイズが負の値やアルゴリズムの安定条件以上の大きなステップサイズを算出し，アルゴリズムが発散する危険性がある．そこで， $\alpha_p(i)$  の値を  $0 \leq \alpha_{\min} \leq \alpha_p(i) \leq \alpha_{\max} \leq 2$ . に制限することで，アルゴリズムの安定性を保証する．また， $\alpha_{\min}$ ， $\alpha_{\max}$  を適切に設定することで  $\hat{\sigma}_v^2$  が正確に推定できない場合にもアルゴリズムの安定性を保つことができる．この点については次節において議論を行う．

最後に，ステップサイズ行列  $G(i)$  の算出法である．アフィン射影アルゴリズムは NLMS アルゴリズムの拡張であるため，様々な PtNLMS アルゴリズムから決定することが可能である．そこで，本論文では PtNLMS アルゴリズムの中でも演算量，収束特性の点で良好な性能を持つ，SPNLMS アルゴリズムをアフィン射影に拡張し，可変ステップサイズの導入を行った可変サイズセグメント係数比例アフィン射影アルゴリズム（以下，VSS-SPAPA と表記）を定義する．ここで，VSS-SPAPA におけるステップサイズ行列  $G(i)$  を恒等行列とすると，VSS-SPAPA は VSS-APA と同一になることを記しておく．

本論文において定義した VSS-SPAPA は文献 [37] において提案されている Set-membership PAPA (SM-PAPA) におけるステップサイズの算出法と似ている．SM-PAPA はステップサイズ  $\alpha_p(i)$  を

$$\alpha_{sm,p}(i) = \begin{cases} 1 - \gamma/|e_p(i)|, & \text{if } |e_p(i)| > \gamma \\ 0, & \text{otherwise.} \end{cases} \quad (4.38)$$

と算出する．ここで， $\gamma$  は予め設定する必要があるパラメータであり，観測雑音により制限される値である．そのため，事前に対象システムの平均的な情報がなければ，推定精度の向上が期待できないという欠点があり，実アプリケーションにおいては提案手法がより有効性が高いと考えられる．

ここで，正確でない観測雑音の分散が適応アルゴリズムに与える影響について考察を行う．この条件下では， $\hat{\sigma}_v^2(i) \gg \sigma_v^2(i)$ ， $\alpha_p(i)$  が式 (4.35) で算出される最適値に対して小さくなる．この結果  $\alpha_p(i)$  がすぐに  $\alpha_{\min}$  となることから収束速度は低下する．しかし，この場合でも推定を繰り返すことで推定精度は向上していく．次に， $\hat{\sigma}_v^2(i) \ll \sigma_v^2(i)$  の場合を考



## 4.11 計算量

えると、先の場合とは逆になり、 $\alpha_p(i)$  は最適値よりも常に大きくなり、初期の収束速度は  $\alpha_p(i)$  が  $\alpha_{\max}$  に近くなるため高くなると考えられる。これらのことから、 $\hat{\sigma}_v^2(i)$  が多少の不正確さを持っている場合でも、VSS-APA よりも収束特性は良くなるものといえる。また、本章において行う計算機シミュレーションにおいても提案手法は  $\hat{\sigma}_v^2(i)$  の推定誤差にたいして、高い耐性を持っていることが確認できている。

本章において提案する可変ステップサイズ SPAPA をまとめると、表 4.1 となる。

## 4.11 計算量

既存のアフィン射影アルゴリズムと比較した場合、本提案手法では 4 種類の計算量の増加が存在する。まず、ステップサイズ行列  $G(i)$  を算出するための  $2N + 2$  回の乗算、 $N$  回の加算、さらに  $3N$  回の比較演算である。次に、 $G(i)X(i)$  を算出するための  $PN$  の乗算が必要である。また、 $\hat{\sigma}_{e_p}^2(i)$  を推定し  $\alpha(i)$  を算出するための  $4P + 6$  回の乗算、 $P$  回の平方根演算、 $2P + 2$  回の加算が必要である。最後に、 $\alpha(i)e(i)$  を算出するための  $P$  回の乗算がある。その他の演算はアフィン射影アルゴリズムと同様であるため、結果として VSS-SPAPA を用いる際、増加する演算量は  $(P + 2)N + 5P + 8$  回の乗算と  $P$  回の平方根演算である。実際のネットワークエコーキャンセラなどで用いられる射影次数  $P$  は 2 から 8 であり、 $O(N)$  のオーダで演算量の増加が発生する。しかしながら、この演算量増加に見合うと考えられる性能向上が次節において確認できる。

## 4.12 計算機シミュレーション

### 4.12.1 シミュレーション条件

提案手法の有効性を確認するために、様々な計算機シミュレーションをシステム同定を用いて行う。比較対象の適応アルゴリズムとして、APA, SPAPA, VSS-APA を用い、未知系  $w$  として図 4.14(a) で示されるネットワークエコーパスを用いる。観測雑音には白色ガウス雑音を用いている。未知系、適応フィルタのインパルス応答長  $N$  は 512 とし、係数比例

## 4.12 計算機シミュレーション

型の適応アルゴリズムにはパラメータ  $\delta_{\rho}, \rho$  にそれぞれ,  $\delta_{\rho} = 0.01, \rho = 1/N$  を与えている．また提案手法で用いるパラメータ  $\lambda_1, \lambda_2, \alpha_{\min}, \alpha_{\max}$  にはそれぞれ,  $\lambda_1 = 1 - 1/2N, \lambda_2 = 1 - 1/4N, \alpha_{\min} = 0.005, \alpha_{\max} = 1.0$  を与えている．

収束特性の評価として

$$\text{Misalignment} = 10 \cdot \log_{10} \|w_N - h_N(i)\|^2 / \|w_N\|^2 \quad (4.39)$$

で算出される正規化推定 2 乗誤差を用いる

### 4.12.2 シミュレーション結果

まず, 入力信号として平均 0, 分散 1 の白色ガウス雑音を用い, S/N を 20dB とした結果を図 4.15 に示す．図 4.15(a) は APA, SPAPA には収束速度が最も高い  $\alpha = 1.0$  を, また, 射影次数  $P$  は  $P = 1$  を設定し, 15000 サンプルのシミュレーションを行った結果である．すなわち, 本条件下のシミュレーション結果は APA は NLMS と, SPAPA は SPNLMS アルゴリズムと等価である．また, 図 4.15(b) は (a) と同一の条件下において, 射影次数を 2, 4, 8 と変化させ, 40000 サンプルまでシミュレーションを行った結果である．

図 4.15 から, SPAPA(SPNLMS) アルゴリズムは APA(NLMS) アルゴリズムより同一のステップサイズを用いた際には収束速度が高く, 収束後の推定精度はほぼ同一となることがわかる．また, 提案手法である VSS-SPAPA(VSS-SPNLMS) は初期の収束速度は SPNLMS アルゴリズムとほぼ同一であり, かつ収束後の推定精度で図 4.15(b) から約 18dB 程度の向上が確認できる．同様の推定精度を SPNLMS アルゴリズムで得るためには, ステップサイズ  $\alpha$  を 0.005 程度に設定しなくてはならず, 収束速度が大幅に低下してしまうことがわかる．一方, VSS-NLMS アルゴリズムでは提案手法と同等の推定精度を得ることができるが, 初期の収束速度においては提案手法と比べ大幅に低下している．これは, 提案手法が -20dB の推定精度を得るのに必要なサンプルが約 900 であるのに対し, VSS-NLMS アルゴリズムでは約 2200 サンプルとなっていることから確認できる．図 4.15(b) から, 提案手法では, 白色ガウス雑音を用いた場合には, 射影次数を 2 から 8 に変化させた場合で

#### 4.13 まとめ

も，収束特性にはほとんど影響がないことがわかる．この結果から，SPNLMS で用いるステップサイズ行列  $G(i)$  は白色雑音の入力に対してはほぼ最適なものであるということができ，提案手法は最適な収束速度と推定精度を最小のコストで実現できるといえる．

次に，入力信号として 4.14(b) で示される 8kHz でサンプリングされた音声信号を用いシミュレーションを行う．観測雑音は平均 0 の白色ガウス雑音を用い，S/N は 20dB に調整している．図 4.16(a) にシミュレーション結果を示す．ただし，射影次数は  $P = 8$  としている．図 4.16(a) より，VSS-SPAPA では収束が最も早いステップサイズを  $\alpha$  を 1.0 とした SPAPA とほぼ同じ推定初期における収束速度を保ちながら 15 秒後の地点では 15dB ほどの推定精度の改善が見られる．また，この条件では VSS-APA は同時刻において VSS-SPAPA ほどの推定精度には到達していないため，収束速度，推定精度の点において VSS-SPAPA が優れているといえる．図 4.16(b) に同様の条件下において，射影次数を 2, 4, 8 と変化させた結果を示す．先に示した入力信号に AR(1) を用いたものと比べ，音声信号が入力信号である場合には射影次数の増加に伴い適応アルゴリズムの収束特性が改善されていくことがわかる．

これらのシミュレーション結果から提案手法はシミュレーションで用いた異なる入力信号いずれであっても，スパースなシステムに対するシステム同定において，既存の適応アルゴリズムより高速かつ高精度の収束特性を実現できるといえる．

#### 4.13 まとめ

本章ではスパースなシステムに対する学習同定法の収束速度向上法である Proportionate-Type NLMS に対し最適ステップサイズがステップサイズ行列の算出法に依らず決定可能であることを示し，計算機シミュレーションにより提案手法を用いた PtNLMS について，いずれのアルゴリズムでも収束特性が向上していることを確認した．また，係数比例アフィン射影に対しても同様の手法を適用し，その効果を確認した．

本章で示した方式は現在も活発に議論が行われている他の PtNLMS においても利用が可

#### 4.13 まとめ

能であると考えられ、広い発展性が望める。また、実装と言う点においても提案手法は演算量の増加が少なく、シンプルなアルゴリズムであるため容易に実装可能であり、エコーキャンセル等の実際のアプリケーションへの適用が期待できる。計算機シミュレーションを通して明らかになった入力信号に非定常信号を用いた際に起こる収束特性の悪化については文献 [32] のような小さな入力信号への対策を行うことにより更に収束特性が向上可能と考えられる。また、非定常な観測雑音の環境下では文献 [31] で用いられるような観測雑音の分散そのものを逐次推定する手法を適用することにより、本手法の更なる適用可能な範囲の拡大が期待できる。

#### 4.13 まとめ




図 4.6 収束特性の比較（スパースな場合）

Figure 4.6 Comparison of convergence properties (in case of sparse).




図 4.7 収束特性の比較（セミスパースな場合）

Figure 4.7 Comparison of convergence properties (in case of semi-sparse).

#### 4.13 まとめ




図 4.8 最適ステップサイズとの比較 (MPNLMS)

Figure 4.8 Comparison of the optimal and proposed step size (MPNLMS).




図 4.9 収束特性の比較 (入力:音声, 観測雑音:白色)

Figure 4.9 Comparison of convergence properties (MPNLMS).

#### 4.13 まとめ




図 4.10 収束特性の比較（入力:音声，観測雑音:音声）

Figure 4.10 Comparison of convergence properties.




図 4.11 収束特性の比較（入力:音声，観測雑音:音声）

Figure 4.11 Comparison of convergence properties.

#### 4.13 まとめ




図 4.12 統計量の測定区間による違い

Figure 4.12 Comparison of convergence properties.




図 4.13 ステップサイズの推移

Figure 4.13 Transition of variable step size.



表 4.1 VSS-SPAPA

---



---

Initialization:

$$\mathbf{h}(0) = \mathbf{0}; \quad \hat{\sigma}_v^2(0) = 0; \quad \hat{\sigma}_{\hat{y}}^2(0) = 0; \quad \hat{\sigma}_d^2(0) = 0;$$

$$\delta = PM\sigma_x^2, \quad (M \in \mathbb{Z}^+, M \geq 1)$$

$$\lambda_1 = 1 - 1/(K_1 N), \quad (K_1 \in \mathbb{Z}^+, K_1 \geq 1)$$

$$\lambda_2 = 1 - 1/(K_2 N), \quad (K_2 \in \mathbb{Z}^+, K_2 \geq K_1)$$

$$\text{for } p = 0, 1, \dots, P-1$$

$$\hat{\sigma}_{e_p}^2(0) = 1;$$

For all  $t$ :

$$\bar{g}_n(i) = \begin{cases} 400|w_n(i)|, & |w_n(i)| < 0.005 \\ 2, & \text{otherwise.} \end{cases}$$

$$L_{\max} = \max\{\delta_\rho, \bar{g}_0(i), \dots, \bar{g}_{N-1}(i)\}$$

$$\gamma_n(i) = \max\{\bar{g}_n(i), \rho L_{\max}\}$$

$$g_n(i) = \gamma_n(i) / \left[ \frac{1}{N} \sum_{i=0}^{N-1} \gamma_i(i) \right]$$

$$G(i) = \text{diag}\{g_0(i), g_1(i), \dots, g_{N-1}(i)\}$$

$$\hat{\mathbf{y}}(i) = X^T(i)\mathbf{h}(i)$$

$$\mathbf{e}(i) = \mathbf{d}(i) - \hat{\mathbf{y}}(i)$$

$$\text{for } p = 0, 1, \dots, P-1$$

$$\hat{\sigma}_{e_p}^2(i) = (1 - \lambda_1)\hat{\sigma}_{e_p}^2(t-1) + \lambda_1\hat{e}_p^2(i)$$

$$\alpha_p(i) = 1 - \sqrt{\hat{\sigma}_v^2(t-p)/\hat{\sigma}_{e_p}^2(i)}$$

$$\text{if } \alpha_p(i) < \alpha_{\min}, \quad \alpha_p(i) = \alpha_{\min},$$

$$\text{if } \alpha_p(i) > \alpha_{\max}, \quad \alpha_p(i) = \alpha_{\max},$$

$$\alpha(i) = \text{diag}\{\alpha_0(i), \dots, \alpha_{P-1}(i)\}$$

$$\mathbf{h}(t+1) = \mathbf{h}(i) + G(i)X(i) [X^T(i)G(i)X(i) + \delta\mathbf{I}]^{-1} \alpha(i)\mathbf{e}(i)$$


---



---

#### 4.13 まとめ




図 4.14 (a) シミュレーションで用いたネットワークエコーパス (b) 入力信号 (音声信号)

Figure 4.14 (a) Impulse response used in simulation. (b) Wave form of speech input.

#### 4.13 まとめ




図 4.15 収束特性の比較 (白色ガウス雑音)

Figure.4.15 Comparison of VSS-SPAPA to the related algorithms.




図 4.16 収束特性の比較 (音声信号)

Figure.4.16 Comparison of VSS-SPAPA to the related algorithms using speech signal.

## 第 5 章

# 動的に結合量を調整する結合係数比例型 NLMS アルゴリズム

係数比例型 NLMS アルゴリズムは収束速度の向上という点に於いて効果的な手法である。しかしながら、対象とするシステムのスパース性にその向上効果が依存するばかりでなく、場合によっては従来の学習同定法に対しても劣ってしまうという大きな問題点がある。

本章ではより実用的な係数比例型学 NLMS アルゴリズムとして、従来の学習同定法と係数比例型とを結合し、対象システムのスパース性が低い場合であっても収束速度を学習同定法程度まで保証できる結合係数比例型学習同定法について説明を行い、結合係数比例型において重要なパラメータである結合量を誤差信号のみに基づき動的に調整を行う新しいアルゴリズムの提案を行う。

### 5.1 結合係数比例型 NLMS アルゴリズム

係数比例型 NLMS アルゴリズムの収束速度向上効果はスパース性が高いシステムにはより効果的に、スパース性が低いシステムの場合は効果が低い、若しくは通常の学習同定法よりも収束速度が低くなるといった対象システムのスパース性に大きく依存していることが既に明らかになっている。

実アプリケーションでの運用において、対象システムのスパース性があらかじめ保証できる場合には問題は無いが、環境の変化や時間変動等様々な要因で対象システムの特性が大きく変化するような状況下では、スパース性への依存が問題となる。

## 5.1 結合係数比例型 NLMS アルゴリズム

スパース性が低いシステムへの対処法として，PNLMS アルゴリズムと NLMS アルゴリズムを結合した 3 章において説明した，PNLMS++ アルゴリズム，CPNLMS アルゴリズム，IPNLMS アルゴリズム等が提案されている．これは，適応フィルタの係数更新の際に，PNLMS アルゴリズムと NLMS アルゴリズムを結合する点では同一だが，PNLMS++，CPNLMS は PNLMS アルゴリズムと NLMS アルゴリズムを一定の法則の下で切り替える手法であり，NLMS アルゴリズムでの更新時には収束速度の向上効果を得ることができない．一方，IPNLMS アルゴリズムは結合パラメータを用い，それぞれの割合を調整し係数更新を行うことで，非スパースなシステムにおいて収束速度が悪化してしまう問題に対処しながら，収束速度の向上効果も期待できるアルゴリズムである．

本節ではまず，この IPNLMS アルゴリズムを一般化した Combined-Type PNLMS(CtPNLMS) アルゴリズムについて説明を行う．

### 5.1.1 CtPNLMS アルゴリズム

CtPNLMS アルゴリズムにおける係数更新は

$$\mathbf{h}_N(i+1) = \mathbf{h}_N(i) + \alpha \frac{e(i)G_{NN}(i)\mathbf{x}_N(i)}{\mathbf{x}_N^T(i)G_{NN}(i)\mathbf{x}_N(i)} \quad (5.1)$$

である．ただし

$$g_n(i) = \frac{1-\beta}{2N} + \frac{(1+\beta)}{2} \cdot \text{PtNLMS} \quad (5.2)$$

であり， $\beta$  は結合割合を調整するパラメータで  $-1 < \beta < 1$  である．ここで，式 (5.2) における PtNLMS は第 3 章において述べたものであり，

$$\text{PtNLMS} = \frac{|h_n(i)|}{\|\mathbf{h}_N\|_1} \quad (5.3)$$

とすると，PNLMS に基づいた PNLMS アルゴリズムに，

$$\text{PtNLMS} = \frac{F(|h_n(i)|)}{F(\|\mathbf{h}_N(i)\|)} \quad (5.4)$$

ただし，

$$F(|h_n(i)|) = \ln(1 + \mu|h_n(i)|) \quad (5.5)$$

とすると，MPNLMS に基づいた [38] で提案されている IMPNLMS アルゴリズムとなる．

## 5.1 結合係数比例型 NLMS アルゴリズム

### 5.1.2 CtPNLMS アルゴリズムにおける結合度の影響

CtPNLMS アルゴリズムは事前に結合量  $\beta$  を設定しておくことで、NLMS アルゴリズムと PtNLMS アルゴリズムの結合割合を調整する。PNLMS アルゴリズムを PtNLMS アルゴリズムとして用いた IPNLMS アルゴリズムではこの値を-0.7 程度に設定している [28]。これは、係数更新において 85% は NLMS アルゴリズムを、残り 15% のみ PtNLMS アルゴリズムを用いる値であるが、後にシミュレーションで示すよう、収束速度の向上効果は高いといえる。

この値は、文献 [28] 中のシミュレーションの結果から決定されたものであり、対象とするシステムがどのようなスパース性を持っていたとしても結合量を予め考慮せずに使える汎用性が高い値であるが、実際には対象システムのスパース性が高い場合には、PNLMS アルゴリズムの速度向上効果を低下させる要因に、スパース性が低い場合には NLMS アルゴリズムに対して、PNLMS アルゴリズムの係数更新が含まれているため、収束速度が NLMS アルゴリズムよりも低下してしまうといった問題がある。これは、どのような PtNLMS アルゴリズムを選んだとしても起こり得る問題であるといえる。

図 5.2、5.6 においてスパース性が異なるシステムに対し PNLMS, NLMS, IPNLMS アルゴリズムを用いたシステム同定におけるシミュレーション結果を示す。ただし、図 5.2 は図 5.1 で示される、スパース性が 0.96 のもの図 5.6 は図 5.5 で示されるスパース性が 0.21 のもので、入力信号、観測雑音は白色雑音、S/N は 30dB である。全てのアルゴリズムのステップサイズは最も収束速度が高い 1.0 を用い、IPNLMS アルゴリズムの結合度  $\beta$  は-0.7 を用いている。また、結果は 100 回の試行を行った平均である。

図 5.2 より、スパース性が高いシステムにおいては推定初期においては PNLMS アルゴリズムが最も収束が早く、IPNLMS アルゴリズムは NLMS アルゴリズムよりも高い収束速度をもつ。次に、図 5.4 より、図 5.2 と比較し、スパース性が低下すると PNLMS アルゴリズムは推定初期においては高速であるが、それ以降は大幅に収束速度が低下し、収束に要する時間は最もかかっていることがわかる。またこの条件下では IPNLMS アルゴリズムは常

## 5.1 結合係数比例型 NLMS アルゴリズム

に NLMS アルゴリズムよりも良好な収束である．図 5.6 から，スパース性が低いシステムにおいては NLMS アルゴリズムが最も収束が早く，PNLMS アルゴリズムではほぼ収束をしていない．また，IPNLMS アルゴリズムは NLMS アルゴリズムと比較すると，ほぼ同じであり  $\beta = -0.7$  を用いることで最低でも NLMS アルゴリズム程度の収束は補償できることがわかる．

### 5.1.3 スパース性を基に調整する結合係数比例型 NLMS アルゴリズム

CtPNLMS アルゴリズムにおける，問題点は事前に設定を行い固定的に用いる結合パラメータ  $\beta$  である．この問題に対し，SC-IPNLMS アルゴリズム [38]，IMPNLMS アルゴリズム [39] において適応フィルタが推定している係数を基に，未知系のスパース性  $\xi(i)$  を式 (3.1) に従い

$$\xi(i) = \frac{N}{N - \sqrt{N}} \left( 1 - \frac{\|\mathbf{h}_N(i)\|_1}{\sqrt{N}\|\mathbf{h}(i)\|_2} \right) \quad (5.6)$$

と推定し，得られた結果から結合パラメータを逐次変化させていく手法が提案されている．文献 [38] では，この  $f$  を

$$2\xi(i) - 1 \quad (5.7)$$

と定めているが，これは一定の条件下において様々なスパース性の未知系を生成し，そのスパース性と収束速度が最速となる  $\beta$  の関係から得られた関数であり，一般性を持つとはいえない．また，文献 [39] では IPNLMS アルゴリズムに対し，ステップサイズ行列  $G$  の算出を

$$g_n(i) = \left[ \frac{1 - 0.5\xi(i)}{L} \right] \frac{1 - \beta}{2N} + \left[ \frac{1 + 0.5\xi(i)}{L} \right] (1 + \beta) \frac{|h_n(i)|}{2\|\mathbf{h}\|_1} \quad (5.8)$$

と置き換え，結合パラメータ  $\beta$  を直接制御はしないが，結果として未知系のスパース性に応じて NLMS と PNLMS の割合を調整する．しかしながら，手法もスパース指標 0 から 1 に対し 1 次線形に割合を決定しているものであり，また外乱などの影響を軽減するために割り当て可能な範囲を 0.5 までに制限するなど，最適な割り当てを行うとはいえない．



## 5.2 動的に結合量を調整する CtPNLMS アルゴリズム

CtPNLMS アルゴリズムの結合パラメータの決定に対し，本節では動的に結合量を調整する CtPNLMS アルゴリズム (Adaptive Combined PNLMS，以下 ACPNLMS と略記) を提案する．以下にその詳細を記す．

時刻  $i$  における所望信号  $d(i)$  を

$$d(i) = \mathbf{w}_N \mathbf{x}_N(i) \quad (5.9)$$

とする．NLMS アルゴリズムと PtNLMS アルゴリズムで構成された二つの適応フィルタからの出力をそれぞれ

$$y_{\text{NLMS}}(i) = \hat{\mathbf{h}}_N(i) \mathbf{x}_N(i) \quad (5.10)$$

$$y_{\text{PtNLMS}}(i) = \check{\mathbf{h}}_N(i) \mathbf{x}_N(i) \quad (5.11)$$

とし，所望信号との誤差信号をそれぞれ

$$e_{\text{NLMS}}(i) = d(i) - y_{\text{NLMS}}(i) \quad (5.12)$$

$$e_{\text{PtNLMS}}(i) = d(i) - y_{\text{PtNLMS}}(i) \quad (5.13)$$

と定義する．提案手法では，この誤差信号を基にパラメータ  $\beta(i)$  を

$$\beta(i) = \begin{cases} \beta(i-1) - \psi, & |e_{\text{NLMS}}(i)| > |e_{\text{PtNLMS}}(i)| \quad \wedge \quad \beta(i-1) - \psi \geq -1.0 \\ \beta(i-1) + \psi, & |e_{\text{NLMS}}(i)| < |e_{\text{PtNLMS}}(i)| \quad \wedge \quad \beta(i-1) + \psi \leq 1.0 \\ \beta(i-1), & \text{otherwise} \end{cases} \quad (5.14)$$

と更新する．これは，学習同定法と PtNLMS アルゴリズムの推定結果を誤差信号の絶対値の大きさからそれぞれのアルゴリズムにおける収束量を比較し，より適した結合度に近づけていく方式である．ただし， $\psi$  は更新量を決定するパラメータであり， $0 < \psi \leq 2$  である． $\psi$  が大きいほど，精度は低いが早く最適な結合度に近づく，また  $\psi$  が小さいほど最適な結合度への調整には時間がかかるが，精度は高くなる．このことから，定常的な未知系には小さな  $\psi$  を，変動が激しいシステムには大きめの値をといた設定は必要となる．

一般的に適応信号処理において誤差信号の時間的な大小関係を収束判定に用いることは，入力信号や観測雑音の変動にも影響を受けるため適切ではないと考えられる．しかしなが

### 5.3 計算機シミュレーション

ら，本手法は同一の条件下における 2 種類の適応アルゴリズムから得られる誤差信号を比較するため，収束の程度を判定する指標となり得る．これは，誤差信号の 2 乗期待値  $E[e^2(i)]$  は適応フィルタの各係数ごとの推定誤差の 2 乗和  $\sum_{k=0}^{N-1} \hat{h}_k^2(i)$  と入力信号の分散  $\sigma_x^2$  を掛け合わせたものと観測雑音の分散  $\sigma_v^2$  の和

$$E[e^2(i)] = \sigma_x^2 \sum_{k=0}^{N-1} \hat{h}_k^2(i) + \sigma_v^2 \quad (5.15)$$

となるためである [40]．

最後に，更新された結合パラメータを用い，適応フィルタの更新を行う．

$$\mathbf{h}_N(i+1) = \mathbf{h}_N(i) + \alpha \frac{e(i)G_{NN}(i)\mathbf{x}_N(i)}{\mathbf{x}_N^T(i)G_{NN}(i)\mathbf{x}_N(i)} \quad (5.16)$$

$$g_n(i) = \frac{1 - \beta(i)}{2N} + \frac{(1 + \beta(i))}{2} \cdot \text{PtNLMS} \quad (5.17)$$

$$\dot{\mathbf{h}}_N(i+1) = \mathbf{h}_N(i) + \alpha \frac{\mathbf{x}_N(i)}{\|\mathbf{x}_N(i)\|^2} e_{\text{NLMS}}(i) \quad (5.18)$$

$$\ddot{\mathbf{h}}_N(i+1) = \mathbf{h}_N(i) + \alpha \frac{G_{NN}(i)\mathbf{x}_N(i)}{\mathbf{x}_N^T(i)G_{NN}(i)\mathbf{x}_N(i)} e_{\text{PtNLMS}}(i) \quad (5.19)$$

提案手法では， $\beta(i)$  の初期値と更新量  $\psi$  を決定しておく必要がある．この点については次節において，シミュレーションを通じ説明を行う．

本章において提案した ACPNLMS アルゴリズムをまとめると，表 5.1 となる．

## 5.3 計算機シミュレーション

本章において提案を行った ACPNLM アルゴリズムの有効性を確認するために，計算機シミュレーションを行う．

### 5.3.1 シミュレーション条件

提案手法では，PtNLMS として PNLMS アルゴリズムを用いる．比較対象とし，PNLMS，IPNLMS，NLMS を用いている．ここで，PNLMS を用いた ACPNLMS において  $\beta(i)$  の

### 5.3 計算機シミュレーション

表 5.1 ACPNLMS

Initialization:

$$\mathbf{h}_N(0) = \mathbf{0}; \dot{\mathbf{h}}_N(0) = \mathbf{0}; \ddot{\mathbf{h}}_N(0) = \mathbf{0}; \beta(0) = any$$

For all  $i$ :

$$d(i) = \mathbf{w}_N \mathbf{x}_N(i)$$

$$y(i) = \mathbf{h}_N(i) \mathbf{x}_N(i)$$

$$y_{\text{NLMS}}(i) = \dot{\mathbf{h}}_N(i) \mathbf{x}_N(i)$$

$$y_{\text{PtNLMS}}(i) = \ddot{\mathbf{h}}_N(i) \mathbf{x}_N(i)$$

$$e(i) = d(i) - y(i)$$

$$e_{\text{NLMS}}(i) = d(i) - y_{\text{NLMS}}(i)$$

$$e_{\text{PtNLMS}}(i) = d(i) - y_{\text{PtNLMS}}(i)$$

$$\beta(i) = \begin{cases} \beta(i-1) - \psi, & |e_{\text{NLMS}}(i)| > |e_{\text{PtNLMS}}(i)| \quad \wedge \quad \beta(i-1) - \psi \geq -1.0 \\ \beta(i-1) + \psi, & |e_{\text{NLMS}}(i)| < |e_{\text{PtNLMS}}(i)| \quad \wedge \quad \beta(i-1) + \psi \leq 1.0 \\ \beta(i-1), & \text{otherwise} \end{cases}$$

$$\dot{\mathbf{h}}_N(i+1) = \mathbf{h}_N(i) + \alpha \mathbf{x}_N(i) [\|\mathbf{x}_N(i)\|^2]^{-1} e_{\text{NLMS}}(i)$$

Calculation by Selected PtNLMS Algorithm

$$\ddot{\mathbf{h}}_N(i+1) = \mathbf{h}_N(i) + \alpha G_{NN}(i) \mathbf{x}_N(i) [\mathbf{x}_N^T(i) G_{NN}(i) \mathbf{x}_N(i)]^{-1} e_{\text{PtNLMS}}(i)$$

$$g_n(i) = \{1 - \beta(i)\}/2N + \{1 + \beta(i)\}/2 \cdot \text{PtNLMS}$$

$$G(i) = \text{diag}\{g_0(i), g_1(i), \dots, g_{N-1}(i)\}$$

$$\mathbf{h}_N(i+1) = \mathbf{h}_N(i) + \alpha G_{NN}(i) \mathbf{x}_N(i) [\mathbf{x}_N^T(i) G_{NN}(i) \mathbf{x}_N(i)]^{-1} e(i)$$

変動が行われない IPNLMS と等価であり， $\beta(i) = -1.0$  と固定すると NLMS アルゴリズムと等価になる．未知系として，本章で既に示した図 5.1，図 5.3，図 5.5 をそれぞれ，スパース，セミスパース，非スパースであるシステムとして用いる．また，未知系は任意の時刻において 50 サンプル右（過去の時刻方向）に変化する．入力信号には白色ガウス雑音を用い，S/N は 30dB としているが，未知系にスパース性の変化を与えた際，観測信号のパワーも変化するためそのつど 30dB になるよう調整を行っている．結果は 100 回試行の平均であり，

### 5.3 計算機シミュレーション

収束特性の評価は正規化推定 2 乗誤差 ノルム

$$\text{Misalignment} = 10 \cdot \log_{10} \frac{\|w_N - h_N\|^2}{\|w_N\|^2} \quad [\text{dB}] \quad (5.20)$$

を用いる．各アルゴリズムにおけるパラメータは各結果ごとに提示する．

#### 5.3.2 シミュレーション結果

まず，提案手法の動作を確認するため，スパースなシステムにおいてシミュレーションを行う．ここでは， $\beta(0)$  の初期値として IPNLMS アルゴリズムと同一の  $\beta(0) = -0.7$  を与え，更新量  $\psi$  は  $\psi = 0.01$  としている．また，未知系は 15000 サンプル時に変化を与えている．シミュレーションの結果を図 5.7 に示す．また，併せて  $\beta(i)$  の値を図 5.8 に示す．図 5.7, 5.8 より，ACPNLMS アルゴリズムは初期値として  $\beta(i) = -0.7$  を与えているが，収束が進むにつれ， $\beta(i)$  がスパースなシステムに対して適している大きな値へと変化をし，結果として IPNLMS アルゴリズムより高速な収束を実現できていることがわかる．また，システムの変動にはスパース性の変化は含まれていないため，変動後はそれまでに算出していた  $\beta(i)$  を基に収束が始まるため，より高速な収束を実現できている．この変化は，PtNLMS アルゴリズムを用いる実際のアプリケーションで頻出することが考えられるため，本手法の有効性は高いといえる．次に，図 5.3 で示されるセミスパース性の高いシステムにおいて，同様のシミュレーションを行う．図 5.9, 5.10 にシミュレーション結果を示す．図 5.9, 5.10 より，提案手法である ACPNLMS アルゴリズムは IPNLMS アルゴリズムと比較し収束特性においてほぼ差が無いことがわかる．これは，5.10 から分かるように結合パラメータの値がほぼ-0.7 から-0.6 になっているため，IPNLMS アルゴリズムにおいて  $\beta = -0.7$  と設定しているものとほぼ同一のアルゴリズムとなっているためである．また，IPNLMS アルゴリズムにおいて様々な値を試した場合でも，本条件下では-0.7 程度の  $\beta$  が最適であった．ここで，同一の条件の下  $\beta(0)$  を  $\beta(0) = 0.0$  とし，再度シミュレーションを行った結果の  $\beta(i)$  の変化を図 5.11 に示す．図 5.11 より， $\beta(0) = 0.0$  とした場合であっても， $\beta(i)$  は-0.7 から-0.6 の間に収束していくことが分かり，初期値を最適値から大きく外し

### 5.3 計算機シミュレーション

ている場合であっても最適な値へと  $\beta(i)$  は調整されることが確認できる。

#### 5.3.3 スパース性の変化に対する追従性

PtNLMS アルゴリズムが用いられる実際のアプリケーションを考えた場合、ネットワークエコーキャンセラにおいて回線品質が低下する、ノイズキャンセラやアコースティックエコーキャンセラにおいて、騒音源との距離が変化するなど一時的にシステムの特性が大きく変化することは十分に考えられる。既存の結合パラメータが固定な CtPNLMS アルゴリズムでは、スパース性の変化に対して、パラメータを変化させることができない。そのため、対処法とし IPNLMS アルゴリズムでは比較的 NLMS アルゴリズムの割合が高い  $\beta = -0.7$  を値としても用いることで、非スパースな場合であっても NLMS 程度の収束速度を保障している。しかしながら、これは通常対象とする非常にスパース性が高いシステムに対しては本章で述べたよう収束速度の大幅な低下を招いている。ACPNLMS アルゴリズムでは、システムのスパース性に依らず誤差信号の大小のみで結合パラメータを動的に更新していくため、スパース性の変化に対しても結合パラメータの動的更新が有効に働くと考えられる。図 5.12 に未知系を 15000 サンプルにおいてセミスパースなもの図 5.3 からスパースなもの図 5.1 に変化させたシミュレーションの結果を示す。ただし、 $\beta(0) = -0.7$  とし、 $\psi = 0.01$  としている。図 5.12 より、ACPNLMS アルゴリズムはセミスパースなシステムに対しては IPNLMS アルゴリズムと同様の（ただし、本条件下では最適の）収束特性を示し、かつスパースなシステムに対しては IPNLMS アルゴリズム以上の収束速度を実現していることが確認できる。これは、システムの変化に対し結合パラメータが追従して値を変化できているためといえる。このことから、提案手法はスパース性が時間的に変動するようなシステムに対しても有効であるといえる。

## 5.4 まとめ

本章では，PtNLMS アルゴリズムが本質的に抱えるスパース性が低いシステムに対する収束速度低下という問題に対し提案されている NLMS アルゴリズムと PtNLMS アルゴリズムの結合手法を CtPNLMS アルゴリズムとして定義を行い，それぞれのアルゴリズムの結合量を調整する結合パラメータを動的に調整する ACPNLMS アルゴリズムの提案を行った．また，計算機シミュレーションから提案手法の有効性を確認し，初期値と更新量を与える影響についても考察を行った．

## 5.4 まとめ




図 5.1 スパースなインパルス応答 ( $\xi(w) = 0.96$ )

Figure 5.1 Sparse impulse response.




図 5.2 スパースなシステムに対する収束特性の比較

Figure 5.2 Comparison of NLMS, PNLMS and IPNLMS on sparse system.

## 5.4 まとめ




図 5.3 セミスパースなインパルス応答 ( $\xi(w) = 0.68$ )

Figure 5.5 Quasi sparse impulse response.




図 5.4 セミスパースなシステムに対する収束特性の比較

Figure 5.6 Comparison of NLMS, PNLMS and IPNLMS on quasi sparse system.



## 5.4 まとめ




図 5.5 非スパースなインパルス応答 ( $\xi(w) = 0.21$ )

Figure 5.5 Dispersive impulse response.




図 5.6 非スパースなシステムに対する収束特性の比較

Figure 5.6 Comparison of NLMS, PNLMS and IPNLMS on dispersive system.

## 5.4 まとめ




図 5.7 スパースなシステムに対する収束特性の比較

Figure 5.7 Comparison of ACPNLMS and IPNLMS on sparse system.




図 5.8  $\beta(i)$  の変化 ( $\beta(0) = -0.7$ )

Figure 5.8 Transition of  $\beta(i)$ .

## 5.4 まとめ




図 5.9 セミスパースなシステムに対する収束特性の比較

Figure 5.9 Comparison of ACPNLMS and IPNLMS on sparse system.




図 5.10  $\beta(i)$  の変化 ( $\beta(0) = -0.7$ )

Figure 5.10 Transition of  $\beta(i)$  ( $\beta(0) = -0.7$ ).

## 5.4 まとめ




図 5.11  $\beta(i)$  の変化 ( $\beta(0) = 0.0$ )

Figure 5.11 Transition of  $\beta(i)$  ( $\beta(0) = 0.0$ ).




図 5.12 スパース性が変化に対する追従性

Figure 5.12 Tracking performance for sparsity changing.

## 第 6 章

# 結論

本論文では、係数比例型適応アルゴリズムについて収束速度、推定精度、演算量、観測雑音に対する影響などの観点から考察し、それらに基づき収束特性に影響を及ぼすステップサイズ、結合度など係数比例型適応アルゴリズムのパラメータを動的に決定する新しい係数比例型適応アルゴリズムの提案、改良を行い、その基本的性質及び有効性について論じた。

係数比例型の適応アルゴリズムは対象とするシステムのインパルス応答の大部分がほぼ 0 で占められ、振幅を有するアクティブな場所が一つの箇所に集中しているスパースなシステムにおいて、既存の適応アルゴリズムでは一つのステップサイズと呼ばれるパラメータを用いていたものを、適応フィルタの係数ごとに個別のステップサイズを用いることで収束速度の向上を行うものである。

本論文中で提案した手法は、適応フィルタが本質的に抱える収束速度と推定精度のトレードオフ、有色性入力信号に対する収束特性の低下を効率的に解決することが可能であり、実アプリケーションにおいて有効といえる。

第 2 章では、まず、適応信号処理の歴史とその発展について述べ、いくつかの代表的な適応アルゴリズムについて導出を行い、アルゴリズムごとの特徴について解説を行った。また、適応信号処理におけるパラメータ推定問題について適応信号処理が用いられる実際のアプリケーションを例として説明を行い、その重要性を論じた。

第 3 章では、スパースなシステムに対する収束速度向上法であり、学習同定法に基づいた係数比例型適応アルゴリズムである、係数比例型学習同定法について、その枠組みの算出過程を述べ、アルゴリズムの主要な部分であるステップサイズ行列の算出手法についてこれまで提案されているいくつかのアルゴリズムについて紹介を行った。同時に、これらのアル

ゴリズムの収束特性を決定付ける重要な要因であるシステムのスパース性について、その定義および、スパース性の尺度を計算する手法について紹介を行った。

第4章では、Proportionate-Type NLMS に対し最適ステップサイズがステップサイズ行列の算出法に依らず決定可能であることを示し、計算機シミュレーションにより提案手法を用いた PtNLMS について、いずれのアルゴリズムでも収束特性が向上していることを確認した。また、本手法をアフィン射影に拡張を行うことで学習同定法が困難としている有色性の高い入力信号に対しての収束特性の向上手法の提案を行い、計算機シミュレーションによりその有効性を確認した。提案手法では既存のアフィン射影アルゴリズムに対し、いずれの条件下でも収束特性が向上できることが明らかになった。

第5章では、PtNLMS アルゴリズムが抱えるスパース性が低いシステムにおける収束速度の低下への対応として提案されているいくつかの手法を、結合型 PtNLMS アルゴリズムと定義を行い、結合パラメータを動的に変化させ、事前の調整を行う必要がないアルゴリズムの提案を行い、その有効性を確認した。

本論文において提案した手法はいずれも実用性という点で優れていると考えられ、実際のアプリケーションに用いることでさらにその有効性を確認できると考えられる。しかしながら、実際に用いられる信号処理技術は未だハードウェアコストの制限から固定小数点による実装が主である。このような制約が導入された場合、数値の表現可能範囲が大幅に制約されるため、逐次推定を行う場合には誤差の蓄積が多くなるなど予期しない問題やアルゴリズムの性能自体が悪化することが考えられる。この点においては更なる検証および実証が必要であると考えられる。最後に、本研究の成果を基に、より適応信号処理が広範囲な領域へとその用途を広げ、適応信号処理分野が発展していくことに期待し、本論文のまとめとしたい。

# 謝辞

本研究を遂行するにあたって，丁寧なご指導を賜りました高知工科大学 情報学群 教授 福本昌弘先生に深く感謝の意を表します．また，本論文の作成にあたり，貴重なご指導，ご助言を頂きました，同学群教授 島村和典先生，坂本明雄先生，准教授 浜村昌則先生，講師 吉田真一先生に感謝いたします．また，学生時代から妻鳥貴彦先生には主に宴会を中心としてお世話になりました．土佐山田での生活を語る上で無くてはならない存在となりました．これからもよろしくお願い致します．そして，これまで８年間の研究室での生活で公私ともにお付き合いのあった皆様に感謝を表したいと思います．

最後に同僚である福富英次様，学生時代から１０年間もの長い間，同級生，違う研究室の人，同じ研究室の人としてお世話になりました．これからも良き友人としてお付き合いいただければと思います．

# 参考文献

- [1] B. Widrow and S.D. Stearns, Adaptive signal processing, Prentice-Hall, Upper Saddle River, NJ, 1985.
- [2] S. Haykin, Adaptive Filter Theory, 4th ed, Prentice-Hall, Upper Saddle River, NJ, 2003.
- [3] P.S.R. Dinz, Adaptive filtering: algorithms and practical implementation, Kluwer Academic Publishers, Norwell, MA, USA, 1997.
- [4] 辻井重男, 適応信号処理, 昭晃堂, Japan, 1995.
- [5] D.L. Duttweiler, “Proportionate normalized least-mean-squares adaptation in echo cancelers,” IEEE Trans. Speech Audio Processing, vol.8, no.5, pp.508–518, Sept. 2000.
- [6] Y. Huang, J. Benesty, and J. Chen, Sparse Adaptive Filters, ch. 4, Springer-Verlag New York Inc., Secaucus, NJ, USA, 2005.
- [7] ITU-T, “ITU-T recommendation G.168: Digital network echo cancellers,” 2007.
- [8] Widrow B. and Hoff M.E., “Adaptive switching circuit,” IREWESCON Conv. Rec., pp.96-104, 1960.
- [9] 野田淳彦, 南雲仁一, “システムの学習的同定法, 計測と制御,” 7-9, pp.597-605, Sept, 1968.
- [10] L.Ljung and T.Soderstorm, “Theory and Practice of Recursive Identification,” MIT Press, 1983.
- [11] 雛元孝夫, 前田禎男, “拡張された学習同定法,” 電学論, vol.95-C, pp.227-234, Oct.1975.
- [12] 尾関和彦, 梅田哲夫, “アフィン空間への直交射影を用いた適応フィルタアルゴリズムとその諸性質,” 信学論 (A), vol.J67-A, no.2, pp.126-132, Feb.1984.



## 参考文献

- [13] D.L. Duttweiler, “Subsampling to estimate delay with application to echo canceling,” *IEEE Trans. Acoust., Speech, Signal Processing*, vol.31, no.5, pp.1090–1099, Oct 1983.
- [14] Y. Cheng and D.M. Etter, “Analysis of an adaptive technique for modeling sparse systems,” *IEEE Trans. Acoust., Speech, Signal Processing*, vol.37, no.2, pp.254–263, Feb 1989.
- [15] O. Tanrikulu, “Method and apparatus for fast network bulk delay and span estimation for line echo cancellation,” August 2004.
- [16] J. Homer, “Detection guided NLMS estimation of sparsely parametrized channels,” *IEEE Trans. Circuits Syst. II*, vol.47, no.12, pp.1437 – 1442, Dec. 2000.
- [17] J. Homer, I. Mareels, and C. Hoang, “Enhanced detection-guided NLMS estimation of sparse FIR-modeled signal channels,” *IEEE Trans. Circuits Syst. I*, vol.53, no.8, pp.1783– 1791, Aug. 2006.
- [18] S. Douglas, “Adaptive filters employing partial updates,” *IEEE Trans. Circuits Syst. II*, vol.44, no.3, pp.209–216, Mar 1997.
- [19] T. Aboulnasr and K. Mayya, “Selective coefficient update of gradient-based adaptive algorithms,” *Proc. IEEE International Conference on Acoustics, Speech, and Signal Processing, (ICASSP ’97)*, Munich, Germany, pp.1929–1932, Apr. 1997.
- [20] O. Tanrkulu, B. Baykal, A.G. Constantinides, and J.A. Chambers, “Residual echo signal in critically sampled subband acoustic echo cancelers based on IIR and FIR filterbanks,” *IEEE Signal Processing Lett.*, vol.45, pp.901–912, 1997.
- [21] T. Schertler, “Selective block update of NLMS type algorithms,” *Proc. IEEE International Conference on Acoustics, Speech, and Signal Processing, (ICASSP ’98)*, Seattle, WA, pp.1717–1720, May 1998.
- [22] T. Aboulnasr and K. Mayyas, “Complexity reduction of the NLMS algorithm via selective coefficient update,” *IEEE Trans. Signal Processing*, vol.47, no.5, pp.1421–

## 参考文献

- 1427, May 1999.
- [23] K. Dogancay and O. Tanrikulu, “Selective-partial-update NLMS and affine projection algorithms for acoustic echo cancellation,” Proc. IEEE International Conference on Acoustics, Speech, and Signal Processing, (ICASSP ’00), Istanbul, Turkey, pp.448–451, June 2000.
- [24] K. Dogancay and O. Tanrikulu, “Adaptive filtering algorithms with selective partial updates,” IEEE Trans. Circuits Syst. II, vol.48, no.8, pp.762–769, Aug 2001.
- [25] A. Tandon, M.N.S. Swamy, and M.O. Ahmad, “Partial-update  $L_\infty$ -norm based algorithms,” IEEE Trans. Circuits Syst. I, vol.54, no.2, pp.411–419, Feb 2007.
- [26] P.O. Hoyer, “Non-negative matrix factorization with sparseness constraints,” J. Mach. Learn. Res., vol.5, pp.1457–1469, 2004.
- [27] S. Gay, “An efficient, fast converging adaptive filter for network echo cancellation,” Proc. of the 32nd Asilomar Conference on Signals, Systems and Computers, (ACSSC’98), Pacific Grove, Calif, USA, pp.394–398, Nov 1998.
- [28] J. Benesty and S.L. Gay, “An improved PNLMS algorithm,” Proc. IEEE International Conference on Acoustic, Speech and Signal Processing, (ICASSP’02), Orlando, USA, pp.1881–1884, May 2002.
- [29] H. Deng and M. Doroslovački, “Improving convergence of the PNLMS algorithm for sparse impulse response identification,” IEEE Signal Processing Lett., vol.12, no.3, pp.181–184, March 2005.
- [30] H. Deng and M. Doroslovachi, “Proportionate adaptive algorithms for network echo cancellation,” IEEE Trans. Signal Processing, vol.54, no.5, pp.1794 – 1803, May 2006.
- [31] 高橋潔, 笹瀬巖, 森真作, “収束遅延を改善するための観測雑音の推定方法と可変ステップアルゴリズムの提案”, 信学論 (A), vol.J-76-A, no.12, pp1704-1713, Dec. 1993.
- [32] 福本昌弘, 久保田一, 辻井重男, “安定性を保証した確率的最速な学習同定法”, 信学論

## 参考文献

- (A) , vol.J78-A, no.7, pp778-787, July 1995.
- [33] Ligang Liu, Masahiro FUKUMOTO, Sachio SAIKI, and Shiyong Zhang, “A Variable Step-Size Proportionate Affine Projection Algorithm for Identification of Sparse Impulse Response” , EURASIP Journal on Advances in Signal Processing, vol. 2009, Article ID 150914, 10 pages, 2009.
- [34] J. Benesty, H. Rey, L.R. Vega, and S. Tressens, “A nonparametric VSS NLMS algorithm,” IEEE Signal Processing Lett., vol.13, no.10, pp.581–584, Oct 2006.
- [35] C. Paleologu, J. Benesty, and S. Ciochina, “A variable step-size affine projection algorithm designed for acoustic echo cancellation,” IEEE Trans. Acoust., Speech, Signal Processing, vol.16, no.8, pp.1466–1478, Nov. 2008.
- [36] J. Tanpreeyachaya, I. Takumi, and M. Hata, “Performance improvement of variable stepsize NLMS,” IEICE Trans. Fundam. Electron. Commun. Comput. Sci., vol.E78-A, no.8, pp.905–914, Aug. 1995.
- [37] S. Werner, J.A. Apolinario, and P.S.R. Diniz, “Set-membership proportionate affine projection algorithms,” EURASIP J. Audio, Speech, and Music Process., vol.2007, no.1, pp.1–10, 2007.
- [38] Ligang Liu, Masahiro FUKUMOTO, and Sachio SAIKI, “ An improved mu-law proportionate NLMS algorithm ”, Proc. IEEE International Conference on Acoustic, Speech and Signal Processing (ICASSP2008), pp.2997-3000, Las Vegas, USA, Mar. 2008
- [39] A.W.H. Khong and P.A.A. Naylor, “Efficient use of sparse adaptive filters,” Proc. 40th Asilomar Conf. on Signals, Systems and Computers (ACSSC '06), Pacific Grove, Calif, USA, pp.1375–1379, Oct-Nov 2006.
- [40] M. Nekuui and M. Atarodi, “A fast converging algorithm for network echo cancellation,” IEEE Signal Processing Lett., vol.11, no.4, pp.427–430, April 2004.

# 付録 A

## 関連業績

### A.1 査読付き論文誌

1. 佐伯幸郎, 福本昌弘, “ ステップサイズ行列の算出法に依存しない可変ステップサイズ係数比例型 NLMS アルゴリズム ”, *Jornual of Research Institute of Signal Processing*, 条件付き採録 .
2. 佐伯幸郎, 福本昌弘, “ 動的に結合量を調整する結合係数比例型 NLMS アルゴリズム ”, 電子情報通信学会論文誌 A , 投稿中 .

### A.2 国際会議

1. Sachio SAIKI, Masahiro FUKUMOTO, Ligang Liu, “ Sound Field Reproduction System Exploiting Cross-talk Cancellation Adaptive Filter ”, In *Proc. International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS2009)*, TA2-D-4
2. Sachio SAIKI, Ligang Liu, Masahiro FUKUMOTO, “ An Improved VSS-IPNLMS Algorithm ”, In *Proc. of the International Conference on Next Era Information Networking, (NEINE'08)*, pp.151-156, Kochi, Japan, Dec. 2008
3. Sachio SAIKI, Masahiro FUKUMOTO, Ligang Liu, “ A Convergence Evaluation of the IPNLMS Algorithm Exploiting Variable Step Size ”, In *Proc. of the International Conference on Next Era Information Networking, (NEINE'07)*, pp.313-317,

### A.3 国内会議

Shanghai, China, Sep. 2007

4. Sachio SAIKI, Masahiro FUKUMOTO, and Ligang Liu, “ Improvement of convergence accuracy for BCGM-OR algorithm ”, In *Proc. of the International Conference on Next Era Information Networking (NEINE’06)*, pp.119-124, Kochi, Japan, Sep. 2006

### A.3 国内会議

1. 佐伯幸郎, 福本昌弘, 劉立剛, “ 適応的にパラメータを制御する可変ステップサイズ IPNLMS の推定精度の向上法 ”, In *Proc. of the 23rd SIP Symposium*, pp.207-211, Kanazawa, Japan, Nov. 2008
2. 佐伯幸郎, 福本昌弘, 劉立剛, “ 可変ステップサイズを用いた IPNLMS アルゴリズムの諸特性 ”, In *Proc. of the 22nd SIP SYMPOSIUM (SIP’07)*, pp.592-597, Sendai, Japan, Nov. 2007
3. Sachio SAIKI, Masahiro FUKUMOTO, “ Improvement of the IPNLMS Algorithm Exploiting Variable Step Size”, *IEICE Technical Report*, SIP2007-68, pp.25-28 Aug. 2007