

同期型学習アルゴリズムによる 格子形予測器とNLMS 適応フィルタのブロック更新法

徳井 直樹¹, 中山 謙二², 平野 晃宏²

¹ 石川工業高等専門学校 電気工学科, ² 金沢大学工学部

Block Implementation of a Joint Lattice Predictor and NLMS Algorithm with a Synchronized Learning Algorithm

Naoki Tokui¹, Kenji Nakayama² and Akihiro Hirano²

¹Department of Electronics Engineering, Ishikawa College of Technology

Ta-1 Kitachujo, Tsubata, Kahoku, Ishikawa 929-0392, Japan

²Faculty of Engineering, Kanazawa University

2-40-20 Kodatsuno, Kanazawa, Ishikawa 920-8667, Japan

E-mail: tokui@ishikawa-nct.ac.jp

Abstract In order to achieve fast convergence and less computation for adaptive filters, a joint method combining a whitening process and the NLMS algorithm is a hopeful approach. When a lattice predictor is used for the whitening process, the reflection coefficients change sample by sample following the input signal. However, updating the filter coefficients is not synchronized with the reflection coefficient updating resulting in unstable behavior. We analyzed effects of this, and proposed the “Synchronized Learning Algorithm” to solve this problem. Asynchronous error between them is removed, and fast convergence and small residual error were obtained. This algorithm, however, requires $O(ML)$ computations, where M is an adaptive filter length, and L is a lattice predictor length. It is still large compared with the NLMS algorithm. In order to achieve less computation while the fast convergence is maintained, a block implementation method is proposed. The reflection coefficients are updated at some period, and are fixed during this interval. Simulation using speech signal shows that a learning curve of the proposed block implementation a little slower than the our original algorithm, but can save the computational complexity.

Keywords: adaptive filter, lattice predictor, synchronized learning algorithm, block implementation

1. まえがき

デジタル LSI 技術の発達により, 適応フィルタはエコーキャンセラやノイズキャンセラなどに広く応用されるようになってきた。実際の応用において適応フィ

ルタに求められる特性として, 非定常な有色入力に対する高速な収束特性, 数値的計算上の安定性, 及び処理に要する計算量が少ないことなどがあげられる。計算量や数値的な安定性の点から正規化 LMS(NLMS)などの勾配法がよく用いられる。しかし, 勾配法は入

力信号の相関行列における固有値広がりの影響を受けやすく、有色入力に対して収束特性が悪化する。

これを改善する一つの方法として、入力信号の白色化と FIR 適応フィルタを組み合わせた 2 ステージ適応フィルタがある [1]。この方法は、入力信号を白色化して FIR 適応フィルタに入力することで、勾配法における入力信号の固有値広がりの影響を回避できる。入力信号の白色化は FIR フィルタのタップ係数への入力時系列の直交化に相当する。2 ステージ適応フィルタの構成を図 1 に示す。この第 1 ステージの直交化に格子形予測器を用いる方法は、入力信号の自己回帰 (AR) モデルを推定し予測誤差を白色化し、第 2 ステージの FIR 適応フィルタに入力することにより、勾配法における収束特性を改善する [1]—[5]。しかし、格子形予測器の反射係数が入力信号に依存して更新されることで、第 2 ステージの適応フィルタ係数の更新に影響する [6, 7]。

我々は、予測誤差フィルタの反射係数変動が FIR 適応フィルタの係数更新に与える影響について理論的に解析し、この解析結果に基づき反射係数とフィルタ係数の更新を整合させる同期形学習アルゴリズムを提案した [8, 9]。この提案した方法では、反射係数の変動による適応フィルタの重み係数に与える影響を完全に補正可能である。しかし、反射係数から構成される行列の計算と重み係数補正に要する計算量はフィルタ長 M と格子形予測器の次数 L の積に比例する。

本論文では、最も処理量を要する同期形学習アルゴリズム部分をブロック更新処理する方法を提案する。このブロック更新法によって、同期形学習アルゴリズムを必要としないサンプル期間の実現と必要なサンプル期間中の処理量を軽減することが可能となる。音声を入力信号とした計算機シミュレーションにより提案方法の有効性と安定性を確認する。

2. 格子形予測器によって入力信号の白色化を行う適応フィルタの同期形学習アルゴリズム

図 2 に示す L 次の格子形予測器によって入力信号の白色化を行う M 次の適応フィルタ [1, 8, 9] について




図 1 2 ステージ適応フィルタ

Fig. 1 Two-stage adaptive filter




図 2 格子形予測器を用いた 2 ステージ適応フィルタ

Fig. 2 Two-stage adaptive filter using lattice predictor

説明する。

2.1 格子形予測器の反射係数更新

図 2 の第 1 ステージにおける格子形予測器 1 段あたりの予測誤差の更新は、

$$f_m(n) = f_{m-1}(n) + \kappa_m^*(n)b_{m-1}(n-1) \quad (1)$$

$$b_m(n) = b_{m-1}(n-1) + \kappa_m(n)f_{m-1}(n) \quad (2)$$

$$m = 1, 2, \dots, L-1$$

$$f_0(n) = b_0(n) = u(n) \quad (3)$$

である。ここで、 $*$ は複素共役である。 m 段目の反射係数 κ_m は、前段の前向き予測誤差 $f_{m-1}(n)$ と後向き予測誤差 $b_{m-1}(n-1)$ から次のように求まる。

$$\kappa_m(n) = -\frac{2E[b_{m-1}(n-1)f_{m-1}^*(n)]}{E[|f_{m-1}(n)|^2 + |b_{m-1}(n-1)|^2]} \quad (4)$$

期待値の計算は、音声信号などの非定常入力信号への対応が難しいので、忘却係数 ($0 < \gamma < 1$) を用いたリーク積分とする。

$$\begin{aligned} \kappa_{N,m}(n) &= \gamma\kappa_{N,m}(n-1) + \\ & b_{m-1}(n-1)f_{m-1}^*(n) \end{aligned} \quad (5)$$

$$\begin{aligned} \kappa_{D,m}(n) &= \gamma\kappa_{D,m}(n-1) + \\ & (|f_{m-1}(n)|^2 + |b_{m-1}(n-1)|^2) \end{aligned} \quad (6)$$

$$\kappa_m(n) = -2\frac{\kappa_{N,m}(n)}{\kappa_{D,m}(n)} \quad (7)$$

格子形予測誤差フィルタは前向き及び後向き予測誤差 $f_m(n), b_m(n)$ を出力する。入力信号に対する予測次数、すなわち格子形予測器の段数が十分であれば予測誤差は白色化される [3, 4]。

2.2 FIR 適応フィルタのフィルタ係数更新

出力 $y(n)$ は、第 1 ステージの後向き予測誤差 $b(n)$ と、フィルタ係数 $w(n)$ を畳み込んで得られる。

$$\mathbf{b}(n) = [b_0(n), \dots, b_{M-1}(n)]^T \quad (8)$$

$$\mathbf{w}(n) = [w_0(n), \dots, w_{M-1}(n)]^T \quad (9)$$

$$y(n) = \mathbf{w}^H(n)\mathbf{b}(n) \quad (10)$$

ここで、 T は行列及びベクトルの転置を、 H はエルミート変換を表す。

適応フィルタの係数 $w(n)$ の更新には勾配法を用いる。ここでは正規化 LMS アルゴリズムとする。正規化は適応フィルタの各タップ入力である後向き予測誤差 $b(n)$ の自乗和により行う。未知システムの入力 $u(n)$ と適応フィルタの出力 $y(n)$ より誤差は、

$$e(n) = d(n) - y(n) \quad (11)$$

となる。これらを用いて適応フィルタの係数更新は次のようになる。

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \frac{\alpha}{\|\mathbf{b}(n)\|^2 + \delta} \mathbf{b}(n)e(n) \quad (12)$$

ここで、正の定数 δ ($0 < \delta \ll 1$) を用いる。

2.3 反射係数 κ を含む伝達関数の表現

図 2 のフィルタ出力信号 $y(n)$ は、式 (10) より、

$$y(n) = w_0^*(n)b_0(n) + w_1^*(n)b_1(n) + \dots + w_{M-1}^*(n)b_{M-1}(n) \quad (13)$$

である。ここで、後向き予測誤差 $b(n)$ は、入力信号

$$\mathbf{u}(n) = [u(n), u(n-1), \dots, u(n-M+1)]^T \quad (14)$$

と反射係数で構成されるため、

$$\mathbf{b}(n) = \mathbf{K}^H(n)\mathbf{u}(n) \quad (15)$$

と表される。ここで、前向き予測誤差 $f(n)$

$$\mathbf{f}(n) = \mathbf{J}^H(n)\mathbf{u}(n) \quad (16)$$

より、行列 $\mathbf{J}(n)$ と行列 $\mathbf{K}(n)$ の要素は次式で求めることができる [9]。

$$J_{l,m}(n) = J_{l,m-1}(n) + \kappa_m^*(n)K_{l-1,m-1}(n-1) \quad (17)$$

$$K_{l,m}(n) = \kappa_m(n)J_{l,m-1}(n) + K_{l-1,m-1}(n-1) \quad (18)$$

これより、行列 $\mathbf{K}(n)$ は対角要素が 1 の上三角行列の帯行列であり、非対角要素は反射係数で構成される。また、第 $L+2$ 列目から第 M 列目の要素は、それぞれ前前行列の要素を 1 サンプル遅延したものである。

$$\mathbf{K}(n) = \begin{bmatrix} 1 & K_{0,1}(n) & \dots & K_{0,L}(n) & 0 & \dots \\ 0 & 1 & \ddots & \vdots & K_{0,L}(n-1) & \ddots \\ \vdots & 0 & \ddots & K_{L-1,L}(n) & \ddots & \ddots \\ \vdots & \ddots & \ddots & 1 & K_{L-1,L}(n-1) & \ddots \\ \vdots & \ddots & \ddots & \ddots & 1 & \ddots \\ 0 & \dots & \dots & 0 & \dots & \ddots \end{bmatrix} \quad (19)$$

式 (10) と (15) より出力信号 $y(n)$ は、

$$y(n) = \mathbf{w}^H(n)\mathbf{K}^H(n)\mathbf{u}(n) \quad (20)$$

と表される。ここで、 $\mathbf{w}^H(n)\mathbf{K}^H(n)$ は格子形予測器によって入力信号の白色化を行う適応フィルタのインパルス応答、すなわち伝達特性に相当する。

2.4 同期形学習アルゴリズム [8, 9]

反射係数 $\kappa(n)$ 、及び反射係数による行列 $\mathbf{K}(n)$ は、入力信号を白色化する方向に更新される。一方、適応フィルタ係数 $w(n)$ は、式 (12) と (15) で示されるように一つ前のサンプルの行列 $\mathbf{K}(n-1)$ に対して誤差を小さくするように更新されている。したがって、式 (11) 及び (20) で求められる誤差 $e(n)$ の減少を保証できない。この反射係数更新と適応フィルタ係数更新のズレに対する影響は、文献 [9] の 3. および 6.1 に示されている。我々が提案した“同期形学習アルゴリズム”は、反射係数 κ の更新によって変化する適応フィルタのインパルス応答をフィルタ係数の補正により整合させる方法である。

ここで、 $\mathbf{K}(n)$ を用いて更新された $w(n+1)$ と $\mathbf{K}(n)$ を用いて適応フィルタの出力と誤差を表現する。

$$\tilde{y}(n+1) = \mathbf{w}^H(n+1)\mathbf{K}^H(n)\mathbf{u}(n+1) \quad (21)$$

$$\tilde{e}(n+1) = d(n+1) - \tilde{y}(n+1) \quad (22)$$

$\tilde{e}(n+1)$ は、 $w(n+1)$ によって $\tilde{e}(n)$ より減少する。先に説明したように、 $n+1$ サンプル時には $w(n+1)$ と $\mathbf{K}(n)$ は組み合わせられることはなく、式 (20) に示されるように $w(n+1)$ と $\mathbf{K}(n+1)$ が用いられる。こ

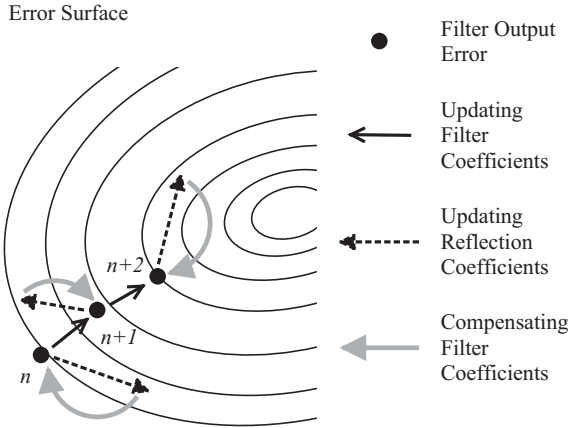


図3 同期形学習アルゴリズムと誤差曲面

Fig. 3 A synchronized learning algorithm in error surface

の式 (21) は直接計算することができないため、誤差に影響する。

そこで、 $w(n+1)$ を補正して式 (21) と等価な出力を得ることにする。補正したフィルタ係数を $\hat{w}(n+1)$ として、次式で与えられる出力 $\hat{y}(n+1)$ と式 (21) の $\tilde{y}(n+1)$ を等しいと置く。

$$\hat{y}(n+1) = \hat{w}^H(n+1)K^H(n+1)u(n+1) \quad (23)$$

これより次の関係を得る。

$$K(n+1)\hat{w}(n+1) = K(n)w(n+1) \quad (24)$$

$$\hat{w}(n+1) = K(n+1)^{-1}K(n)w(n+1) \quad (25)$$

$n+1$ サンプル時において、 $w(n+1)$ の代わりに $\hat{w}(n+1)$ を用いることにより反射係数変動の影響をなくすることができる。

これらの関係は図3に示すように、反射係数の更新により変動した位置を元に戻すようにフィルタ係数を補正し、次のサンプルで誤差が減少する方向にフィルタ係数を更新する。この方法は、反射係数の更新に対して“同期”してフィルタ係数を補正するため、“同期形学習アルゴリズム”と称する。ここで反射係数の更新により、伝達関数が変動し誤差曲面上を移動するように説明した。ところが誤差曲面上の座標が適応フィルタ係数で決定される場合、誤差曲面の等高線図が移動している。これでは図示し難いために、座標が等高線図に対して相対的に移動しているように見えることを利用して説明している。

表1 サンプル間隔において必要とされる計算量の比較

Table 1 Comparison of computational complexity required within a sampling period

	乗算	加算
同期法	$2ML + 3M + 9L + 2$	$2ML + 3M + 5L$
NLMS	$3M + 2$	$3M$
RLS	$3M^2 + 4M$	$2M^2 + 3M$

2.5 計算量の比較

1 サンプルの時間内でフィルタ係数の更新とフィルタ処理に必要な計算量を比較する。フィルタ次数を M 、予測器次数を L としたとき、1 サンプル間隔における計算量を表1に示す。

3. ブロック更新法による同期形学習アルゴリズム

同期形学習アルゴリズムでは、反射係数 $\kappa(n)$ により構成される行列 $K(n)$ の更新に同期して補正重み係数 $\hat{w}(n)$ の計算する。この補正は毎サンプル必要となるため演算量が多い [8, 9]。そこで予測器のブロック更新法 [10] によって演算量の軽減する方法を提案する。

3.1 反射係数のブロック更新化

入力信号の AR モデル係数が既知である場合、反射係数 $\kappa(n)$ を算出して固定した値にすることができる。すると、式 (19) の行列 $K(n)$ の要素は変動しないため補正重み係数 $\hat{w}(n)$ を用いる必要がない。

そこで、反射係数の更新を間隔 S サンプル毎に行うブロック更新法を用いることで、行列 $K(n)$ の要素が前サンプルから更新されない期間を設ける。

このブロック更新法によって反射係数を更新した時、行列 $K(n)$ の第1行2列目から第 L 行 $L+1$ 列目までの要素は、式 (17) と (18) により前サンプルから更新される。行列 $K(n)$ の更新した要素に対応する重み係数 $[w_0(n), \dots, w_L(n)]^T$ は、式 (24) により補正される。

次のサンプルは、前サンプルから更新される行列 $K(n)$ の要素が第2行3列目から第 $L+1$ 行 $L+2$ 列目になる。すると、重み係数 $[w_0(n), \dots, w_{L+1}(n)]^T$ が、式 (24) により補正される。

このように、行列 $K(n)$ の要素と補正重み係数 $\hat{w}(n)$ を計算する範囲はブロック更新法によって反射係数が




図4 反射係数のブロック更新化

Fig. 4 Block update of reflection coefficients

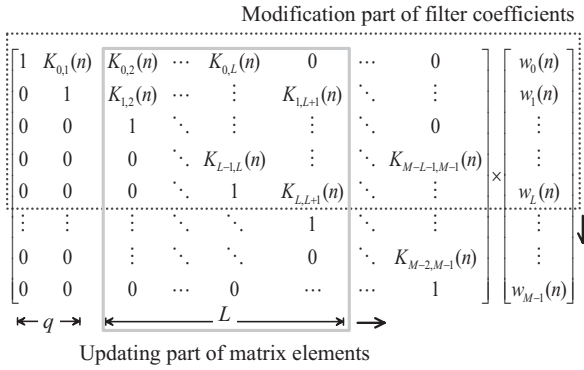


図5 行列要素の更新と重み係数の補正

Fig. 5 Updating of matrix elements and correction of filter coefficients

更新されてからのサンプル数 q で決定される。図4は、更新後のサンプル数によって、それぞれ斜線であらわしている、行列 $K(n)$ の要素の更新量と補正重み係数 $\hat{w}(n)$ の補正量が変化の様子を示している。また、更新後のサンプル数 q による行列 $K(n)$ の要素の更新範囲と重み係数 $w(n)$ の補正範囲の様子を図5に示す。2.3で説明したように、行列 $K(n)$ の第 $L+2$ 列目から第 M 列目の要素は、前列の1サンプル前の要素を複写している。このため、行列 $K(n)$ の要素の更新は、反射係数更新から L サンプルの間であり、反射係数更新さら $L+1$ サンプル後は計算する必要がない。また、補正重み係数 $\hat{w}(n)$ は、行列 $K(n)$ の要素が前サンプルから変化していない範囲は、計算量を削減することができる。よって、反射係数更新から $M+1$ サンプル後は、行列 $K(n)$ の要素は前サンプルから変化しないため、同期形学習アルゴリズムによる重み係数の補正は必要ない。

この更新間隔 S は、1以上の任意の整数を取ることができる。 $S < L$ や $S < M$ の場合、図4における $K(n)$ や $\hat{w}(n)$ の斜線部分が重なるため、計算量は殆ど削減されない。 $S \geq M$ の場合は、固定化されるサンプルが増えるため計算量が削減される。ところが、

表2 反射係数のブロック更新と行列 $K(q)$ の計算量

Table 2 Computational complexity of matrix $K(q)$ with block updating

q	乗算	加算
0	L^2	L^2
$1, \dots, L$	$L^2 - q^2$	$L^2 - q^2$
$L+1, \dots$	0	0

表3 反射係数のブロック更新と補正重み係数 $\hat{w}(q)$ の計算量

Table 3 Computational complexity of correction of filter coefficients $\hat{w}(q)$ with block updating

q	乗算	加算
0	L^2	L^2
$1, \dots, L$	$L^2 + 2qL - q^2/2$	$L^2 + 2qL$
$L+1, \dots, M-L-1$	$3L^2/2 + qL$	$L^2 + 2qL$
$M-L, \dots, M-1$	$2ML - L^2/2 - qL$	$2ML - L^2$
M, \dots	0	0

反射係数は入力信号を白色化するために更新されている。音声などの非定常信号の場合、反射係数が更新されないことで、入力信号の白色化が不適切になる可能性がある。このため、不適切な白色化によって収束特性が悪化することが懸念される。本論文では、4.でシミュレーションによって収束特性を検討する。

反射係数のブロック更新後 q サンプルと、行列 $K(q)$ の要素の計算に必要な1サンプル間隔における計算量を表2に示す。また、同様に、反射係数のブロック更新後 q サンプルと、補正重み係数 $\hat{w}(q)$ に必要な1サンプル間隔における計算量を表3に示す。表2及び3は、 $S \geq M$ の場合である。同期型学習アルゴリズムでは、行列 $K(n)$ の計算量が L^2 、補正重み係数 $\hat{w}(n)$ の計算量が $2ML - L^2$ が必要である[9]。表3では補正重み係数 $\hat{w}(n)$ の計算量の最大値が $ML + L^2$ であることから、ブロック更新法を行わない場合に比べて乗算回数を約半分にする事ができる。

3.2 格子形予測器の二重化

2.で示したように、格子形予測器の m 段目の反射係数 $\kappa_m(n)$ は $m-1$ 段の前向き、および後向き予測

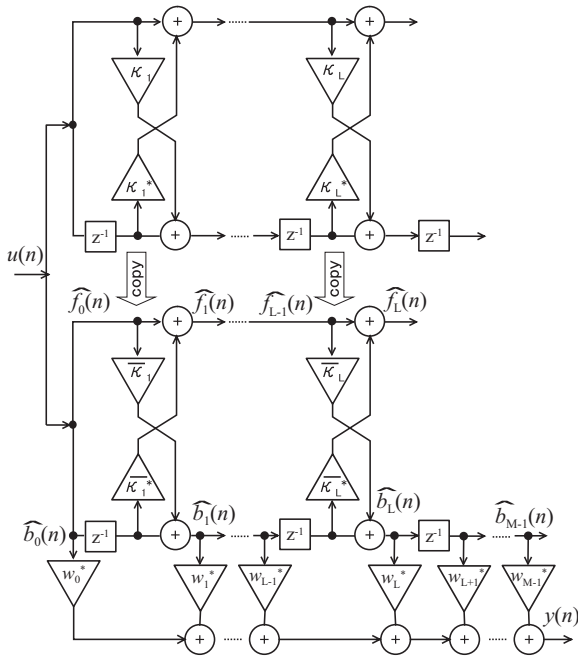


図 6 二重化格子形予測器構成

Fig. 6 Double lattice-based structure

誤差, $f_{m-1}(n)$, $b_{m-1}(n-1)$ から計算される。反射係数が入力信号を正しく推定する値からずれてしまった場合、後向き予測誤差の直交化が悪化する。後向き予測誤差の直交化が悪化した影響は、反射係数の更新によって格子形予測器の後段へと伝搬する。3.1 で提案した反射係数のブロック更新法では、反射係数の更新間隔 S により、直交化が悪化した場合に影響時間が長くなる。

そこで、図 6 に示すように、入力信号から反射係数を毎サンプル推定する格子形予測器と、反射係数を S サンプル毎に複写されて後向き予測誤差を出力する格子形予測器の二重化構成とする。二重化に必要な計算量は、乗算器、加算器ともに $2L$ である。

図 6 上段の格子形予測器は、式 (5), (6) と (7) によって反射係数 $\kappa(n)$ を更新する。図 6 下段の格子形予測器は、ブロック更新処理によって S サンプル毎に固定された反射係数 $\bar{\kappa}(n)$ が与えられる。この固定された反射係数 $\bar{\kappa}(n)$ によって、

$$\widehat{f}_m(n) = \widehat{f}_{m-1}(n) + \bar{\kappa}_m^*(n) \widehat{b}_{m-1}(n-1) \quad (26)$$

$$\widehat{b}_m(n) = \widehat{b}_{m-1}(n-1) + \bar{\kappa}_m(n) \widehat{f}_{m-1}(n) \quad (27)$$

$$m = 1, 2, \dots, M-1$$

$$\widehat{f}_0(n) = \widehat{b}_0(n) = u(n) \quad (28)$$

となる。この予測誤差は、式 (15) と同様に

$$\widehat{\mathbf{b}}(n) = \widehat{\mathbf{K}}^H(n) \mathbf{u}(n) \quad (29)$$

表 4 サンプル間隔における計算量

Table 4 Comparison of computational complexity required within a sampling period

乗算	
ブロック更新法	
最大: $q = M - L$	$ML + L^2/2 + 3M + 11L + 2$
最小: $q = M, \dots$	$3M + 11L + 2$
非ブロック更新法	
	$2ML + 3M + 9L + 2$
加算	
ブロック更新法	
最大: $q = M - L$	$2ML - L^2 + 3M + 7L$
最小: $q = M, \dots$	$3M + 7L$
非ブロック更新法	
	$2ML + 3M + 5L$

(q : 反射係数更新後サンプル数)

と表すことができる。 $\widehat{\mathbf{K}}^H(n)$ は式 (19) と同様に求められる。“同期形学習アルゴリズム” [8, 9] により、

$$\widehat{\mathbf{y}}(n) = \widehat{\mathbf{w}}^H(n) \widehat{\mathbf{K}}^H(n) \mathbf{u}(n) \quad (30)$$

適応フィルタの出力 $\widehat{\mathbf{y}}(n)$ が得られる。ここで、 $\widehat{\mathbf{w}}(n)$ は補正されたフィルタ係数で、

$$\widehat{\mathbf{K}}(n) \widehat{\mathbf{w}}(n) = \widehat{\mathbf{K}}(n-1) \mathbf{w}(n) \quad (31)$$

$$\mathbf{w}(n-1) = \widehat{\mathbf{w}}(n) + \frac{\alpha}{\|\widehat{\mathbf{b}}(n)\|^2 + \delta} \widehat{\mathbf{b}}(n) e(n) \quad (32)$$

より求められる。

3.3 計算量の比較

1 サンプルの時間内でフィルタ係数の更新とフィルタ処理に必要な計算量を比較する。これは、 $S \geq M$ の場合である。提案した反射係数ブロック更新法は、表 2 および表 3 に示すように、反射係数を更新してからのサンプル数 q によって計算量が変動する。計算量は、 $q = M - L$ が最大値となる。計算量の最小値は、 $q = M, \dots$ である。表 4 に今回提案したブロック更新法と非ブロック更新法 [8, 9] の計算量を示す。

4. シミュレーション

本論文で提案した反射係数ブロック更新法による同期形学習アルゴリズムの有効性を確認するために、




図 7 音声信号

Fig. 7 Voice signal




図 8 10 次 IIR-LPF のインパルス応答

Fig. 8 Impulse response of 10th-order IIR-LPF

図 7 に示す日本音響学会編集の研究用連続音声データベースから作成した音声信号を入力に用いてシミュレーションを行った。この音声信号のサンプリング周波数は 8KHz である。比較のため、反射係数を毎サンプル更新する同期形学習アルゴリズムについてもシミュレーションを行った。未知システムには、10 次 IIR-LPF を用いた。各々のインパルス応答と周波数（振幅）特性を図 8, 9 に示す。

適応フィルタのフィルタ長 $M = 50$ ，格子形予測器の次数 $L = 20$ とした。適応フィルタのパラメータは、 $\alpha = 1$ ， $\delta = 0.001$ ， $\gamma = 0.999$ とした。

図 7 の音声信号が入力の収束特性は、図 10 に示す。図中の“Synchronized”は毎サンプル反射係数を更新する同期形学習アルゴリズムを用いた方法である。“Block”は提案した反射係数ブロック更新法による方法で、ブロック長 $S = 100$ ， $S = 1000$ ，及び $S = 2000$ である。誤差評価は未知システムのインパルス応答の自乗平均で正規化し dB 表示している。

“Synchronized”で示した同期形学習アルゴリズムを用いた方法による特性に比べて、提案した反射係数




図 9 10 次 IIR-LPF の周波数特性

Fig. 9 Frequency response of 10th-order IIR-LPF

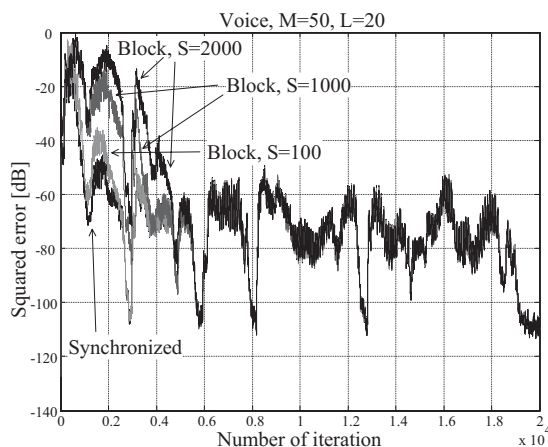


図 10 音声信号に対する収束特性

Fig. 10 Convergence property for voice signal

ブロック更新法による方法“Block”はブロック長が長いほど、初期部分の収束速度が遅くなっている。初期部分では、すべての反射係数が初期値 0 のために、格子形予測器は遅延器のみの構成、NLMS と同等になるためである。

また、反射係数ブロック更新法によって格子形予測器で使用される反射係数は固定され、同期形学習アルゴリズムが休止している区間は、3.1 で述べたように入力信号の白色化が不適切になっている可能性がある。しかし、反射係数ブロック更新法による方法“Block”は、同期形学習アルゴリズムによる特性“Synchronized”に近似した後、その特性はほぼ一致している。これより、格子形予測器によって入力信号の白色化を行う適応フィルタにおいて、その伝達特性が収束した後は、反射係数の更新間隔の影響を受けていないといえる。これは、複数の音声信号を使ったシミュレーションにおいても同様の結果が得られたが、特性図については紙面の関係で割愛する。

5. まとめ

本論文では、格子形予測器と NLMS 適応フィルタの同期形学習アルゴリズムにおいて、計算量の削減方法として反射係数ブロック更新法を提案した。反射係数ブロック更新法は、反射係数により構成される行列 $K(n)$ の要素を固定化することで、補正重み係数の計算に必要な演算量を軽減した。ただし、計算量の削減は更新間隔 S をフィルタ長 M より長くした場合に有効である。反射係数を固定化すると後向き予測誤差の直交性が悪化するため、格子形予測器の二重化により毎サンプル更新を行う予測器から、定期的に反射係数を複写されて後向き予測誤差を出力する予測器を構成した。音声信号を入力として未知システムを推定するシミュレーションを行い、推定誤差と安定性を反射係数ブロック更新法を有無による比較を行った。初期収束特性は、反射係数ブロック更新長に応じて遅くなった。しかし、毎サンプル更新する方法の特性に到達した後、つまり、伝達関数が収束した後は安定している。これは、シミュレーションで用いた $1/4$ 秒に 1 回程度の更新では、音声信号による非定常性やブロック更新間隔の影響が殆どなく、本ブロック更新法が有効であるといえる。

参考文献

- [1] S. Haykin: Adaptive filter theory, Prentice-Hall, 4th Edition, 2002.
- [2] B. Friedlander: Lattice filters for adaptive processing, Proc. IEEE, Vol. 70, No. 8, pp.829–867, Aug., 1982.
- [3] S.H. Leung and C.C. Chu: Adaptive LMS filter with lattice prefilter, Electron. Lett., Vol. 33, Iss. 1, pp.34–35, 2nd Jan., 1997.
- [4] J.H. Yoo, S.H. Cho and D.H. Youn: A lattice/transversal joint(LTJ) structure for an acoustic echo canceller, 1995 IEEE Symposium on Circuits and Systems, Vol. 2, pp.1090–1093, 1995.
- [5] J.J. Shynk: Frequency-domain and multirate adaptive filtering, IEEE SP Magazine, pp.14–37, Jan., 1992.
- [6] J.D. Markel and A.H. Gray, (鈴木 久喜 訳): 音声の線形予測, コロナ社, 1980.
- [7] M. Haseyama and H. Kitajima: Inherent matrix identities on ARMA lattice filter realization algorithm and their application, IEEE Trans. Signal Process., Vol. 45, No. 9, pp.2395–2398, 1997.
- [8] N. Tokui, K. Nakayama and A. Hirano: A synchronized learning algorithm for reflection coefficients and tap weights in a joint lattice predictor and transversal filter, Proceedings 2001 IEEE International Confer-

ence on Acoustics, Speech, and Signal Processing, Vol. 6, pp.3741–3744, May, 2001.

- [9] 徳井直樹, 中山謙二, 平野晃宏: ラチス形予測器と FIR フィルタによる 2 ステージ適応フィルタの収束性解析と学習アルゴリズム, 信学論 A, Vol. J85-A, No. 11, pp.1157–1167, 2002.
- [10] N. Tokui, K. Nakayama and A. Hirano: Block implementation of a synchronized learning algorithm in adaptive lattice filters, Proceedings 2003 IEEE International Conference on Acoustics, Speech, and Signal Processing, Vol. 6, pp.349–352, Apr., 2003.

徳井 直樹 1987 年長岡技科大・工・電子機器卒。1989 年同大大学院修士課程了。2002 年金沢大学大学院自然科学研究科博士後期課程了。博士(工学)。1989 年石川工業高等専門学校電気工学科助手, 2003 年同助教授となり現在に至る。最近の研究テーマは主として直交化適応フィルタ。電子情報通信学会, 信号処理学会, IEEE 各会員。

中山 謙二 1971 年東工大・工・電子卒。1971 年～1972 年同大学研究生。1983 年工博(東工大)。1972 年日本電気(株)入社。伝送通信事業部および C & C システム研究所に勤務し, 通信用各種フィルタ及びデジタル信号処理の研究開発に従事。1988 年金沢大・工・電気情報工学科助教授, 1990 年同教授, 1997 年同大学大学院自然科学研究科・数理情報科学専攻教授, 2000 年同大学・工・情報システム工学科(新設)教授となり現在に至る。最近の研究テーマは主として適応信号

処理及びニューラルネットワーク。1987 年 9 月 IEEE Circuits & Devices Mag. 論文賞受賞。著書「S C 回路網の設計と応用」(東海大学出版会)他。電子情報通信学会会員, IEEE シニア会員, INNS 会員。

平野 晃宏 1987 年金沢大・工・電子卒。1989 年同大大学院修士課程了。2000 年工博(金沢大)。1989 年 NEC 入社。研究開発グループにてエコーキャンセラの研究開発に従事。1998 年金沢大・工・電気・情報工学科助手, 2000 年同大学・工・情報システム工学科(新設)助手, 2001 年同講師となり現在に至る。最近の研究テーマは主として適応信号処理およびニューラルネットワーク。1995 年信学会学術奨励賞受賞。電子情報通信学会, IEEE 各会員。

(2003 年 5 月 2 日受付, 2003 年 8 月 15 日再受付)