

長岡技術科学大学大学院

工学研究科修士論文

題 目

DPOAE非線形特徴を用いた生体認証の  
短時間化に関する研究

指導教員 準教授 杉田 泰則

著者 電気電子情報工学専攻

14316089 張 東望西

提出期日 平成30年2月9日

# 目 次

<b>第 1 章 はじめに</b>	<b>1</b>
1.1 研究背景 . . . . .	1
1.2 研究目的 . . . . .	2
1.3 本論文の構成 . . . . .	2
<b>第 2 章 DPOAE 信号を利用した認証</b>	<b>3</b>
2.1 歪成分耳音響放射(DPOAE: Distortion Product OtoAcoustic Emission) . . . . .	3
2.1.1 DPOAE の非線形特徴 . . . . .	4
2.2 認証システム . . . . .	5
2.2.1 認証システムの評価指標 . . . . .	6
2.2.2 ユークリッド距離に基づいた最尤推定法(MLE: Maximum Likelihood Estimation) . . . . .	7
2.2.3 誤差逆伝播法ニューラルネットワーク(Back Propagation Neural Network: BPNN) . . . . .	8
2.3 まとめ . . . . .	10
<b>第 3 章 提案手法</b>	<b>12</b>
3.1 非線形システム同定を用いたDPOAE非線形特徴の抽出 . . . . .	12
3.2 提案手法1 :Volterra モデルによる特徴抽出 . . . . .	13
3.2.1 Volterra 級数 . . . . .	13
3.2.2 Volterra モデルを用いたシステム同定 . . . . .	14
3.2.3 提案手法1の特徴ベクトル . . . . .	15
3.3 提案手法2 :Functional Link Artificial Neural Network (FLANN) による特徴抽出 . . . . .	16

3.3.1	FLANN の構成	16
3.3.2	チェビシェフ多項式に基づいた FLANN	17
3.3.3	FLANN を用いたシステム同定	17
3.3.4	提案手法2の特徴ベクトル	18
3.4	まとめ	19
<b>第 4 章 実験</b>		<b>20</b>
4.1	DPOAE を含む測定信号の録音条件	20
4.2	特徴ベクトルの抽出	22
4.3	各刺激音周波数の特徴ベクトルによる提案手法の認証精度評価	24
4.4	複数周波数の特徴ベクトルを用いた提案手法の認証	25
4.4.1	実験条件	25
4.4.2	認証精度の比較	26
4.4.3	認証時間の比較	28
4.5	まとめ	29
<b>第 5 章 おわりに</b>		<b>30</b>
<b>謝辞</b>		<b>31</b>
<b>参考文献</b>		<b>32</b>

# 第1章 はじめに

本章では、本論文の研究背景および目的、本論文の構成について述べる。

## 1.1 研究背景

近年、様々なサービスの普及に伴ってサービスを受ける利用者を特定するための個人認証技術が注目されている。人間の生理的特性を利用する生体認証は、個人認証手段の中でも紛失や忘却等の様々な脆弱性に対して頑強である。生理的特性は具体的に、声紋[1]、指紋[2][3]、静脈[4]、虹彩[5]、顔[6]等があり、いずれも長期間にわたって特性の変化が生じず、第三者との類似性が少ないものである。

しかし、スマートデバイスの普及により、これらの特性が容易に複製される恐れが高まっている。認証では、複製されたものを他人が使用するなりすましの検知が困難であることから、用いる特性は複製が困難であることが望ましい。なりすましを防止する方法として、耳の音響特性を用いた耳音紋[7]の認証に関する研究が行われている。耳音紋はマイク一体型イヤホンによって観測され、外耳道伝達関数(ECTF: Ear Canal Transfer Function)[8]と歪成分耳音響放射(DPOAE: Distortion Product Otoacoustic Emission)[9][10][11]を用いる手法が一般的である。DPOAE[12]とは、周波数の異なる2つの刺激音を耳に入力することで、蝸牛の非線形性によって生じる信号であり、聴覚機能を評価する客観的指標とされる。そのため、乳幼児などの聴覚機能検査に利用されている。耳介や外耳道の形状に依存するECTFと比較して、DPOAEを用いた生体認証は、形状だけでなくDPOAEの非線形性により聴覚機能を表現することが可能である。

しかしながら、従来のDPOAEを用いた生体認証は、特徴抽出時間が長いことが欠点である。顔認証などでは一枚の画像から個人差を表す特徴を抽出するのに対して、DPOAEは特徴抽出のために多くの録音回数を必要とする。特徴抽出時間が長いことは認証全体の長時間化に繋がるため、短時間で高精度な判定が求められる認証システムにとっては大きな問題である。また、従来のDPOAEを用いた生体認証は特徴の次元数が非常に少なく、次元数を増加させるに従って録音回数も増加する。次元数が少ない特徴では多数のユーザ認証に対応することが困難である。

## 1.2 研究目的

短時間かつ精度を損なわない認証の実現を目的とし、少ない録音回数のDPOAE信号から多くの特徴を抽出する手法を提案する。本論文では、DPOAE信号の「録音時間」と特徴の「抽出時間」の和にDPOAE信号「録音回数」を掛けたものを認証時間と定義し、個人を判定する時間は含まない事とする。本論文では、認証時間を削減するために非線形システム同定を用い、非線形性を有するDPOAE信号をモデル化する。Volterraモデルを適用した非線形システム同定はシステムの非線形性を線形パラメータで表現できる。従って、提案する特徴抽出手法では同定後の線形パラメータを特徴として利用する。これにより、少ない測定回数のDPOAE信号から高次元の特徴を抽出できる。

また、提案する特徴抽出手法では非線形モデルとしてVolterraモデルとFunctional Link Artificial Neural Network(FLANN)[13]を導入する。VolterraモデルはDPOAE信号の特徴表現に非常に有効であると報告されている[14]。対してFLANNはVolterraモデルに比べ計算量が少ないため短時間化が期待される。

それぞれの非線形モデルによって抽出した特徴を基に認証実験を行い、従来法と同等程度の認証精度で、認証を短時間化できることを示す。

## 1.3 本論文の構成

本論文の構成は以下の通りである。2章では、DPOAE信号を利用した認証システムとその問題点について述べる。3章では、2章で述べた問題を解決するために、非線形システム同定を用いた特徴抽出手法について述べる。4章では、被験者から測定したDPOAE信号を用いた認証評価結果を示す。提案する特徴抽出手法を用いてVolterraモデル、FLANNそれぞれで各被験者の特徴を求め、従来の特徴抽出手法との認証精度と認証時間を比較することで本研究の有用性を示す。最後に、5章では本論文の結論を示す。

## 第 2 章 DPOAE 信号を利用した認証

本章では従来の DPOAE を用いた生体認証 [9] を基に、DPOAE から認証に利用する従来の特徴抽出手法と認証システムについて説明する。以降、文献 [9] の特徴抽出手法を従来手法と呼ぶ。2.1 節では、本研究で用いる生理的特性である DPOAE について述べる。また、DPOAE から得られる特徴と従来手法についても説明し、従来手法の問題点を示す。2.2 節では一般的な認証システムの構成と認証の評価手法について述べる。

### 2.1 歪成分耳音響放射 (DPOAE: Distortion Product OtoAcoustic Emission)

人間の聴覚器官の構造を図 2.1 に示す。外耳に到来した信号は中耳を経由し、内耳の内部に位置する蝸牛によって電気信号へ変換され、聴神経によって脳へ伝播される。人間はこのような経路で音を知覚し、蝸牛は音の伝播に重要な役割を担っている。蝸牛内はリンパ液で満たされており、リンパ液は蝸牛に到来した信号によって振動する。このリンパ液の振動により、蝸牛内の外有毛細胞が収縮・伸展し、電気信号に変換される。耳音響放射 (OAE: OtoAcoustic Emission) はこの外有毛細胞の働きの副産物として発生する音で、外耳に向かって放射される。

OAE は音信号に関係なく外耳道に放射される自発耳音響放射 (SOAE: Spontaneous OtoA-

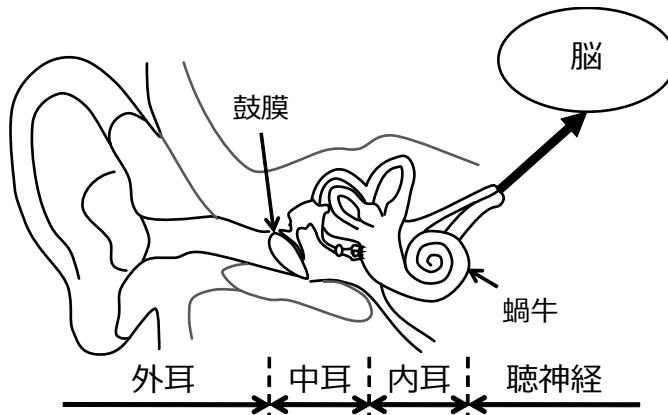


図 2.1 聴覚器官の構造

coustic Emission) と, 音刺激によって誘発される誘発耳音響放射 (EOAE: Evoked OtoAcoustic Emission) に分類される. EOAE には, トーンバーストやクリックにあたる音刺激により誘発する短音刺激誘発耳音響放射 (TEOAE: Transient Evoked OtoAcoustic Emission) と, 本研究に用いる歪成分耳音響放射 (DPOAE: Distortion Product OtoAcoustic Emission)[12] がある. DPOAE は異なる周波数の 2 つの音を含む刺激に応答して蝸牛から放出される音である. 蝸牛内の外有毛細胞の働きは非線形であるため, 入力周波数の整数倍の和と差で相互変調歪が生成され, 歪み積が形成される. したがって, DPOAE は蝸牛内の外有毛細胞の働きを評価することができ, 主観的な聴覚検査を実施することが困難な, 乳幼児などの聴覚検査に利用されている.

ここで, 外部から与える刺激音対の周波数をそれぞれ  $f_1, f_2 (f_1 < f_2)$  とする. DPOAE の音圧は刺激音対の周波数に関係し, 周波数比  $f_2/f_1 = 1.22$  であるときに最大となることが確認されている. また, DPOAE の音圧や位相は刺激音の音圧によって非線形に変化すると報告されている [15].

### 2.1.1 DPOAE の非線形特徴

式 (2.1) に放射される DPOAE の周波数  $f_{dp}$  を示す.

$$f_{dp} = \begin{cases} nf_1 \pm mf_2 & (n, m = 1, 2, \dots) \\ mf_2 - nf_1 \end{cases} \quad (2.1)$$

放射される DPOAE の周波数のうち,  $2f_1 - f_2$  成分は他の非線形成分と比較し音圧が大きいため, 安定して出現する. また,  $2f_1 - f_2$  成分など DPOAE の周波数  $f_{dp}$  の音圧は周波数  $f_2$  に対応する聴覚レベルを反映する.

従来手法では, 聴覚レベルの個人差に着目している. この手法では, 周波数比を一定として周波数対  $f_1, f_2$  を離散的に変化させ, 各周波数対において  $2f_1 - f_2$  成分の音圧  $L_{dp}$  を観測する. 横軸に  $f_2$  の周波数を, 縦軸に音圧  $L_{dp}$  を取った図は DP-グラムと呼ばれ, 個人の離散的な聴覚能力を表現する. 図 2.2 に 4 名の被験者の DP-グラムを示す. 図 2.2 に示すように, 従来手法は 21 の周波数対で音圧  $L_{dp}$  を観測しており, 従来手法の特徴ベクトル  $\mathbf{v}_e$  は式 (2.2) で表される.

$$\mathbf{v}_e = [L_{dp(f_2=1000)} L_{dp(f_2=1250)} \cdots L_{dp(f_2=6000)}] \quad (2.2)$$

以上のように, 従来手法の特徴ベクトルは DPOAE の非線形性から離散的な聴覚能力を表現することができる. しかしながら, 従来手法は特徴ベクトルの次元数に合わせて DPOAE

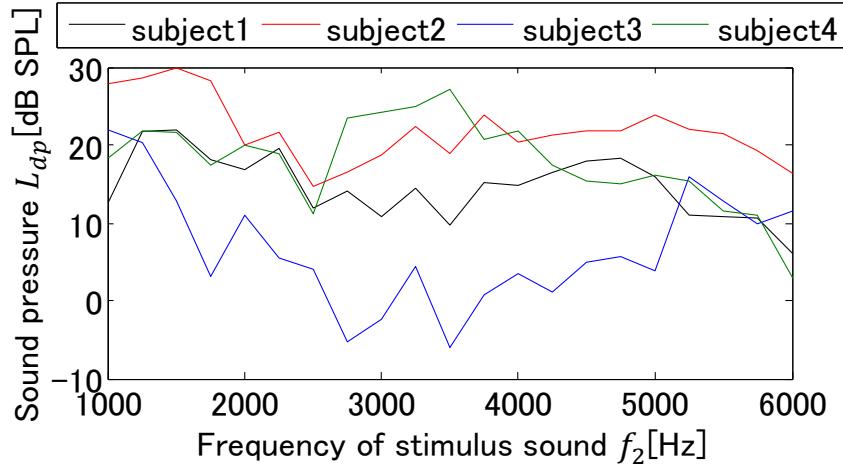


図 2.2 DP-グラム (被験者数 4 名)

を測定する回数が増加し、特徴抽出時間が長いことが欠点である。特徴抽出時間が長いことは認証全体の長時間化に繋がるため、短時間で高精度な判定が求められる認証システムにとっては大きな問題である。また、従来手法は特徴の次元数が非常に少なく、次元数を増加させるに従って測定回数も増加する。次元数が少ない特徴では、多数のユーザ認証に対応することが困難である。

したがって、従来手法の改善には、少ない測定回数で高次元の特徴ベクトルの抽出が必要であるといえる。

## 2.2 認証システム

一般に、認証システムは 1) 認証データの測定部、2) 前処理部、3) 特徴抽出部、4) 本人を判定する認証部から構成される。

既存研究では、測定部にて DPOAE を含む信号を取得しており、この信号を以後測定信号と呼ぶ。また、前節で述べたように従来手法は、測定信号から 21 次元の特徴ベクトルを抽出している。次節では、認証システムの評価指標、文献 [9] と本研究で用いる認証システムについて説明する。

### 2.2.1 認証システムの評価指標

生体認証では、あらかじめ登録した特徴ベクトルと照合時に取得した特徴ベクトルとの類似度から、認証部により本人判定が行われる。あるユーザ本人の特徴ベクトルは、事前に登録した本人の特徴ベクトルに対しては類似度が高くなり、他人のベクトルに対しては類似度が低くなる。よって判定する際は、類似度に閾値を設定し、本人と他人を判別する必要がある。

図 2.3 に類似度の分布例を示す。閾値を設定した判定を行うと、本人が誤って他人と判断される場合や他人が誤って本人として判定される場合が発生する。それぞれの確率は本人拒否率 (FRR: False Rejection Rate) と他人受入率 (FAR: False Acceptance Rate) と定義される。FRR と FAR はトレードオフの関係にあり、一方のみ向上させることはできない。

ここで、認証システムは等価エラー率 (EER: Equal Error Rate) によって評価される。EER は FRR と FAR が等しくなるエラー率であり、小さいほど認証精度が高いといえる。高い認証精度を実現するには適切な閾値が必要であり、閾値は実験を通して設定される。

認証部に、入力する特徴間の距離と最尤推定を利用する手法や、機械学習を利用する手法 [16] が報告されている。次節において、本研究で用いるユークリッド距離に基づいた最尤推定法と誤差逆伝播法ニューラルネットワークについて説明する。

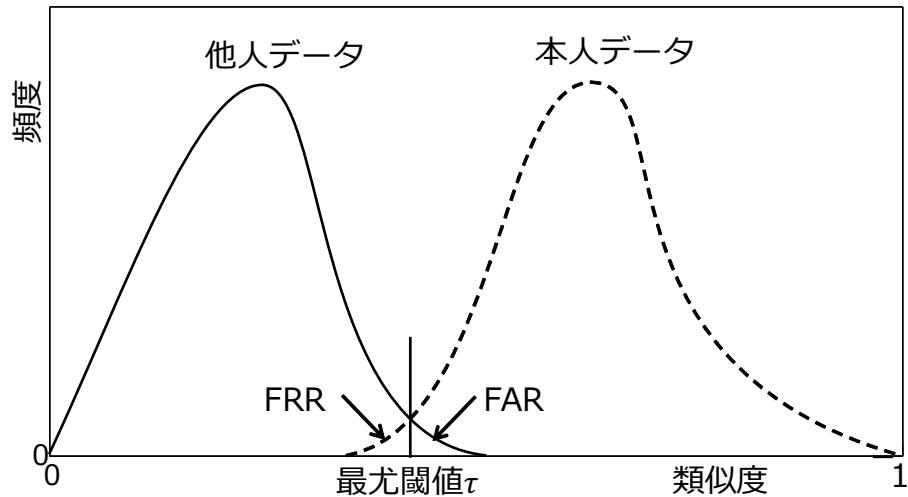


図 2.3 生体認証の評価

## 2.2.2 ユークリッド距離に基づいた最尤推定法 (MLE: Maximum Likelihood Estimation)

最尤推定 (MLE: Maximum Likelihood Estimation) は確率分布を既知として尤度関数と最尤推定量を求め、最尤推定値を計算する方法である。確率分布は既知であるが、パラメータ  $\theta$  を母数とする未知の母集合を考える。確率分布はパラメータ  $\theta$  に依存するため、 $f(sd; \theta)$  で表す。母集合から  $M$  個の標本データを抽出したときのデータが  $\mathbf{sd} = sd_1, sd_2, \dots, sd_M$  を取る確率は以下のように表すことができる。

$$L(\theta) = L(\mathbf{sd}; \theta) = \prod_{i=1}^M f(sd_i; \theta) f(sd_2; \theta) \cdots f(sd_M; \theta) \quad (2.3)$$

ここで、 $L(\theta; \mathbf{sd})$  は尤度関数であり、得られたデータ  $\mathbf{sd}$  は既知であるため  $\theta$  の関数となる。

推定値として複数の候補が考えられる場合、ある候補値  $\theta'$  に対して、 $L(\hat{\theta}) > L(\theta)$  が成立する  $\hat{\theta}$  が常にあるとき、 $\hat{\theta}$  は最尤推定値である。母集合から得られるデータの組み合わせを考慮し、 $\mathbf{sd}$  を確率変数で書き直すと、尤度関数  $L(\theta) = f(SD_1; \theta)f(SD_2; \theta) \cdots f(SD_M; \theta)$  を最大にするような最大推定量  $\hat{\Theta} = \Theta(SD_1, SD_2, \dots, SD_M)$  が存在すれば、この最尤推定値として  $\hat{\theta}$  が計算される。

前節でも述べたように、EER を導出するためには FRR 及び FAR を導出する必要があり、本人データと本人のテンプレートとの差を  $\Delta SD_{hh}$ 、他人のテンプレートとの差を  $\Delta SD_{hk}$  が必要であるともいえる。文献 [9] は式 (2.4) に示すユークリッド距離で  $\Delta SD$  を算出している。

$$\Delta SD = |SD^1 - SD^2| = \sqrt{\sum (SD^1 - SD^2)^2} \quad (2.4)$$

$\Delta SD_{hh}$ 、 $\Delta SD_{hk}$  の頻度はヒストグラム化される。MLE を用いることで、 $\Delta SD_{hh}$ 、 $\Delta SD_{hk}$  のヒストグラムから、本人データと本人のテンプレート間の確率密度関数  $\phi_{GEN}(\Delta SD_{hh})$ 、本人データと他人のテンプレート間の確率密度関数  $\phi_{IMP}(\Delta SD_{hk})$  が推定可能である。既存研究はそれぞれのヒストグラムをガウス分布と仮定し、確率密度関数を決定している。 $\phi_{GEN}(\Delta SD_{hh})$ 、 $\phi_{IMP}(\Delta SD_{hk})$  は累積密度関数に変換し、交差点が EER となる。

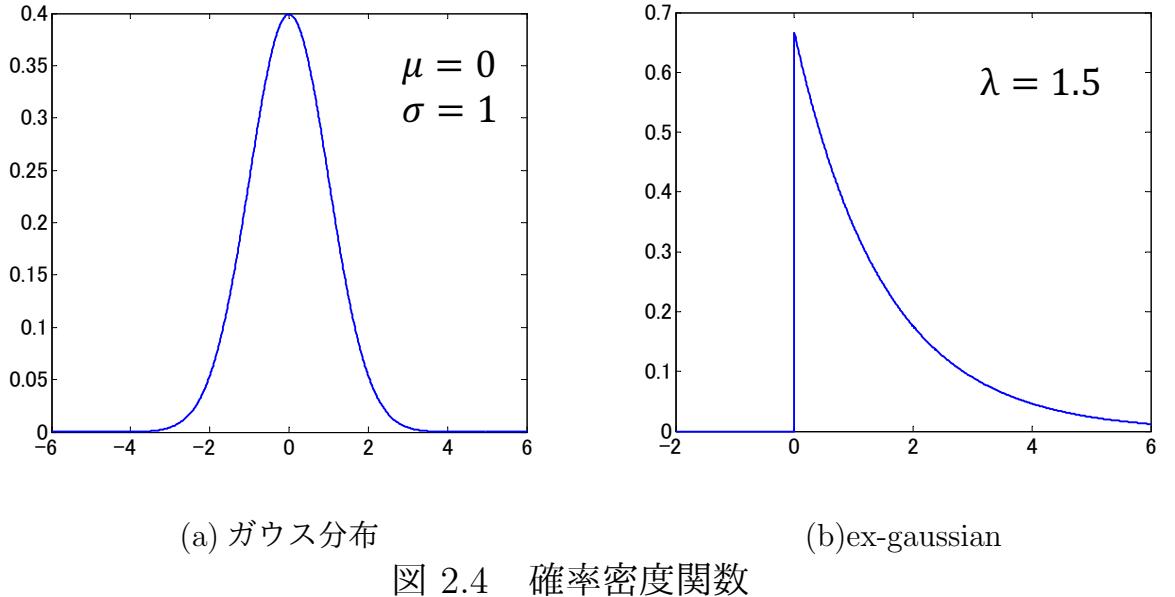
ここで、ガウス分布の確率密度関数は以下の式 (2.5) であり、図 2.4(a) に分布を示す。

$$f(sd) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(sd - \mu)^2}{2\sigma^2}\right) \quad (2.5)$$

ガウス分布の推定値は  $\theta = [\mu, \sigma^2]$  であるから、式 (2.3) から最尤推定量は以下の式 (2.6) と

なる。

$$\mu = \frac{1}{M} \sum_{i=1}^M sd_i = \bar{d} \quad \sigma^2 = \frac{1}{M} \sum_{i=1}^M (sd_i - \mu)^2 = \frac{1}{M} \sum_{i=1}^M (sd_i - \bar{d})^2 \quad (2.6)$$



また、図 2.4(b) のような式 (2.7) の ex-Gaussian 分布で、従来手法の認証評価が可能である [16].

$$f(sd) = \frac{\lambda}{\sqrt{\pi}} \exp^{\lambda\mu + \frac{1}{2}\lambda^2\sigma^2} \exp^{-\lambda sd} \operatorname{erfc} \left( \frac{\mu + \lambda\sigma^2 - sd}{\sqrt{2}\sigma} \right) \quad (2.7)$$

$$\operatorname{erfc}(sd) = 1 - \operatorname{erf}(sd) = \frac{2}{\pi} \int_x^\infty e^{-t^2} dt$$

このような複雑な確率分布では、最尤推定量  $\partial L / \partial \theta = 0$  とし最尤推定量を解析的に求め、計算を簡略化するため、対数尤度  $\ln L(\theta)$  を利用して求めることが一般的である。

### 2.2.3 誤差逆伝播法ニューラルネットワーク (Back Propagation Neural Network: BPNN)

ニューラルネットワーク (NN: Neural Network) とは人間や生物の脳神経系によるネットワークを模したモデルのことである。NN は多数の複雑に結合されたニューロンを利用す

ることで、人間や生物の神経系をコンピュータ上で模している。式 (2.8) にニューロンモデルの基本式を示す。

$$y_i = f \left( \sum_i w_{ij} y_j \right) \quad (2.8)$$

$y_i$  は  $i$  番目のニューロンからの信号、 $w_{ij}$  は  $j$  番目のニューロンから  $i$  番目のニューロンに対する結合加重を表す。ここで式 (2.8) における関数  $f(x)$  は活性化関数であり、単位ステップ関数やシグモイド関数が用いられる。シグモイド関数は以下の式 (2.9) で定義できる。

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (2.9)$$

次に認証部として用いられる NN の階層構造を図 2.5 に示す。図に示されるように、入力層、出力層、1 層の中間層から構成される 3 階層型 NN である。入力層ユニット  $I$  と中間層ユニット  $J$  及び中間層ユニット  $J$  と出力層ユニット  $K$  の間は、それぞれ結合加重  $w_{ij}^{(IJ)}$  と  $w_{jk}^{(JK)}$  で構成される。NN を用いることでパターン認識が可能となるが、そのためには NN の結合加重を適切に決定しなければならない。そのためには NN の学習が必要であり、ここでは本研究で使用する逆誤差伝播 (BP: Back Propagation) 法 [17] について説明する。

BP 法とは、ある入力パターンを認識するための適切な結合強度を求める最適化問題に対して、NN からの出力と教師信号との差異を調べ、誤差が小さくなるように結合強度を

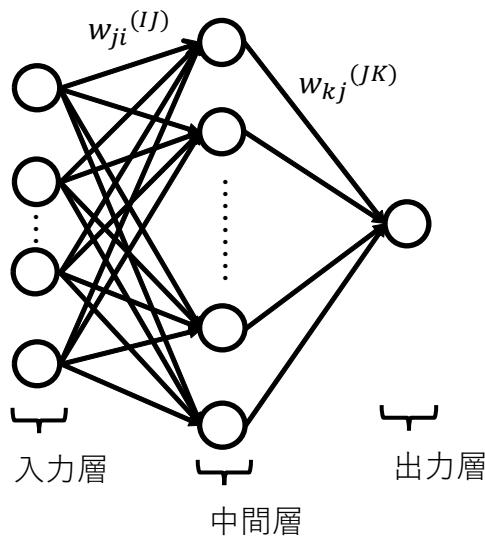


図 2.5 認証に適した階層型ニューラルネットワーク

変化させる学習方法である。この過程を出力層から入力層に向かって繰り返し、識別に適した状態に収束させることが可能である。

ここで、あるユーザを認証する NN の構造を図 2.5 に示す。学習用の入力パターンを与える教師信号として、本人のデータならば”1”，他人のデータならば”0”を与えることで、ユーザの特徴を学習することができる。教師信号と NN からの出力値との誤差二乗和を減少させるため、次式を用いて各ユニット間の結合加重は更新される。

$$\Delta w_{ij}^{(IJ)}(n) = -\eta \frac{\partial E}{\partial w_{ij}(n)} + \alpha \Delta w_{ij}(n-1) \quad (2.10)$$

$\Delta w_{ij}^{(IJ)}(n)$  は学習  $n$  回後における結合加重の更新量、 $\eta$  は学習係数、 $E$  は教師信号と出力層ユニットの誤差二乗和、 $\alpha$  は慣性係数、 $\Delta w_{ij}^{(IJ)}(n-1)$  は学習  $(n-1)$  回後における結合加重の更新量を表している。中間層ユニット  $J$  と出力層ユニット  $K$  の間の結合加重  $\Delta w_{jk}^{(JK)}(n)$  も同様に更新される。

これを  $S$  人のユーザを判定するために拡張する場合、同様の NN を並列に処理する必要がある。図 2.6 にユーザ数  $S$  での NN の構造を示す。このような NN に対して、学習したユーザ以外のユーザのテスト用入力パターンと教師信号として”1”を与えた場合、FAR が評価できる。一方、学習したユーザのテスト用の入力パターンと教師信号として”1”を与えた場合、FRR が評価できる。

## 2.3 まとめ

本章では、DPOAE から特徴ベクトルを抽出する従来手法と認証システムについて述べた。DPOAE は入力した刺激音対の周波数の歪成分として現れる誘発音である。DPOAE の  $2f_1 - f_2$  周波数成分の音圧を特徴ベクトルとする従来手法は、特徴ベクトルの次元数と測定回数が同値であるため、特徴抽出に長い時間を必要とする。さらに、認証部として本研究で利用する、NN と既存研究の認証部であるユークリッド距離を用いた MLE について示した。

次章では、従来手法の問題点を解決する、提案の特徴抽出手法である、非線形システム同定を用いた DPOAE 非線形特徴の推定について述べる。

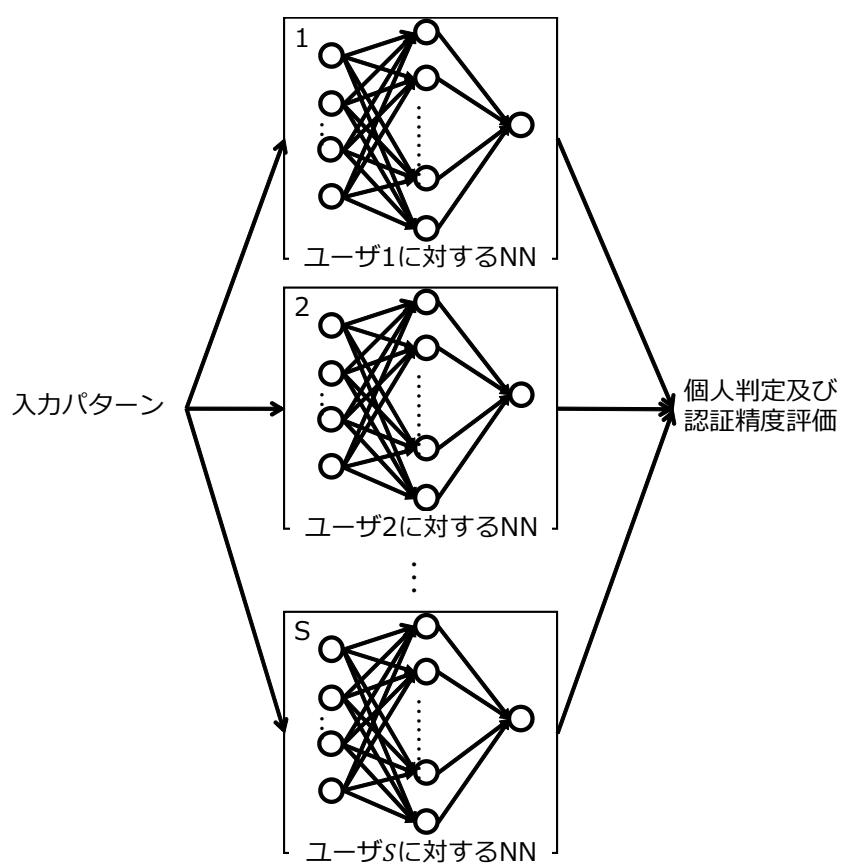


図 2.6  $S$ 人のユーザを認証するNNの構成

## 第3章 提案手法

2章で述べたように、従来手法は抽出時間の長さが問題である。本章では従来手法の問題点を解決する手法について述べる。以降、本研究で提案する特徴抽出手法を提案手法と呼ぶ。3.1節では、提案手法の特徴ベクトルであるDPOAEの非線形成分の抽出について述べる。3.2節では、Volterraモデルを用いた特徴抽出手法である提案手法1について述べる。同様に、3.3節ではFLANNを用いた特徴抽出手法である提案手法2について述べる。

### 3.1 非線形システム同定を用いたDPOAE非線形特徴の抽出

DPOAEは図3.1に示すような構成で測定される。2.1節で述べたように、DPOAEから蝸牛内の外有毛細胞の非線形性を評価できることから、測定系を非線形システムと置き換えることができる。したがって、イヤホンから離散出力する刺激音対 $x(n)$ に対して、マイクロホンで得られる離散測定信号 $d(n)$ は、 $x(n)$ の非線形成分を含むと考えることが可能である。

提案手法では、このような未知の非線形システムである測定系を同定し、モデル化する。一般的な非線形システム同定の構成を図3.2に示す。同定する際に更新されるパラメータは、測定系の非線形性を表現する値を持つため、提案手法ではこのパラメータを基に特徴ベクトルを形成する。

同定において、システムの非線形性を表現する様々な非線形モデルが提案されている。提案手法1ではVolterraモデル、提案手法2ではFLANNを非線形モデルに用いる。次節以降で、それぞれのモデルの詳細について述べる。



図3.1 DPOAEの測定系

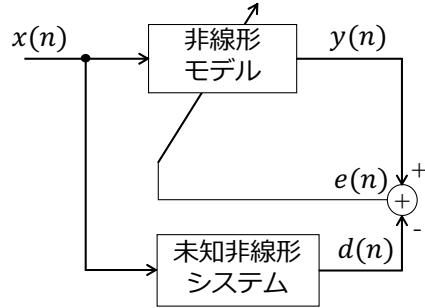


図 3.2 一般的なシステム同定のブロック図

## 3.2 提案手法 1 :Volterra モデルによる特徴抽出

Volterra モデルは代表的な非線形モデルであり, Volterra 級数展開におけるパラメータをディジタルフィルタのパラメータとして扱う. そのため, 歪の種類によらず全ての歪をモデル化することが可能である.

### 3.2.1 Volterra 級数

Volterra 級数は一般に非線形システムをモデル化でき, DPOAE の特徴表現に非常に有効とされる [14]. Volterra 核の記憶長を  $N$  とすると, Volterra 級数展開は式 (3.1) で表すことができる.

$$\begin{aligned}
 y(n) &= \sum_{k_1=0}^{N-1} h_1(k_1) x(n - k_1) \\
 &+ \sum_{k_1=0}^{N-1} \sum_{k_2=0}^{N-1} h_2(k_1, k_2) x(n - k_1) x(n - k_2) + \dots \\
 &+ \sum_{k_1=0}^{N-1} \dots \sum_{k_{P_V}=0}^{N-1} h_{P_V}(k_1, \dots, k_{P_V}) x(n - k_1) \dots x(n - k_{P_V})
 \end{aligned} \tag{3.1}$$

ここで,  $h_{P_V}(k_1, \dots, k_p, \dots, k_{P_V})$  は  $P_V$  次の Volterra 核である. この Volterra 核は, 対称性があることから, Volterra 核の変数  $k_p$  を任意に入れ替え可能である. ただし,  $p = 1, \dots, P_V$  である. 2 次 Volterra 核での関係を以下に示す.

$$h_2(k_1, k_2) = h_2(k_2, k_1) \tag{3.2}$$

この Volterra 核のパラメータ数は Volterra 次数  $P_V$  によって記憶長  $N$  のべき乗で増加する。そのため、式 (3.1) の出力信号  $y(n)$  を求めるためには膨大な計算量が必要である。

### 3.2.2 Volterra モデルを用いたシステム同定

図 3.3 に Volterra モデルで DPOAE の測定系を同定するブロック図を示す。ここで、図 3.3 の  $H_p$  は Volterra 演算子として式 (3.3) のように定義する。

$$H_p = \sum_{k_1=0}^{N-1} \cdots \sum_{k_p=0}^{N-1} h_p(k_1, \dots, k_p) x(n - k_1) \cdots x(n - k_p) \quad (3.3)$$

よって、出力信号  $y(n)$  は時式で表される。

$$y(n) = \sum_{p=1}^{P_V} H_p \quad (3.4)$$

Volterra モデルを用いた同定では、非線形システムが対象でありながら、各次数のフィルタは線形として扱えるため、従来の適応フィルタと同様の更新アルゴリズムを拡張することが可能である。そのため、本研究では LMS アルゴリズム [18] によって、誤差信号  $e(n)$  の二乗期待値を最小化するように更新する。LMS アルゴリズムは最急降下アルゴリズムによって  $p$  次 Volterra 核  $h_p$  は以下の式 (3.5) ように更新される。

$$h_p(k_1, \dots, k_p; n+1) = h_p(k_1, \dots, k_p; n) + \mu_p x(n - k_1) \cdots x(n - k_p) e(n) \quad (3.5)$$

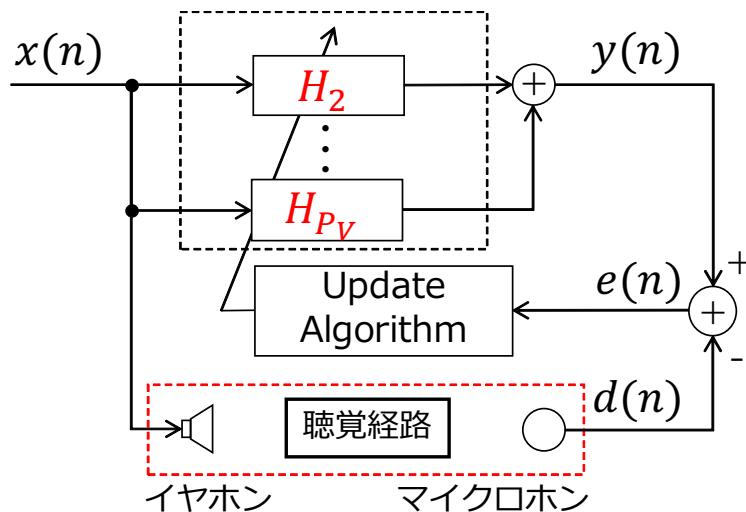


図 3.3 Volterra モデルを用いた DPOAE のシステム同定(提案手法 1)

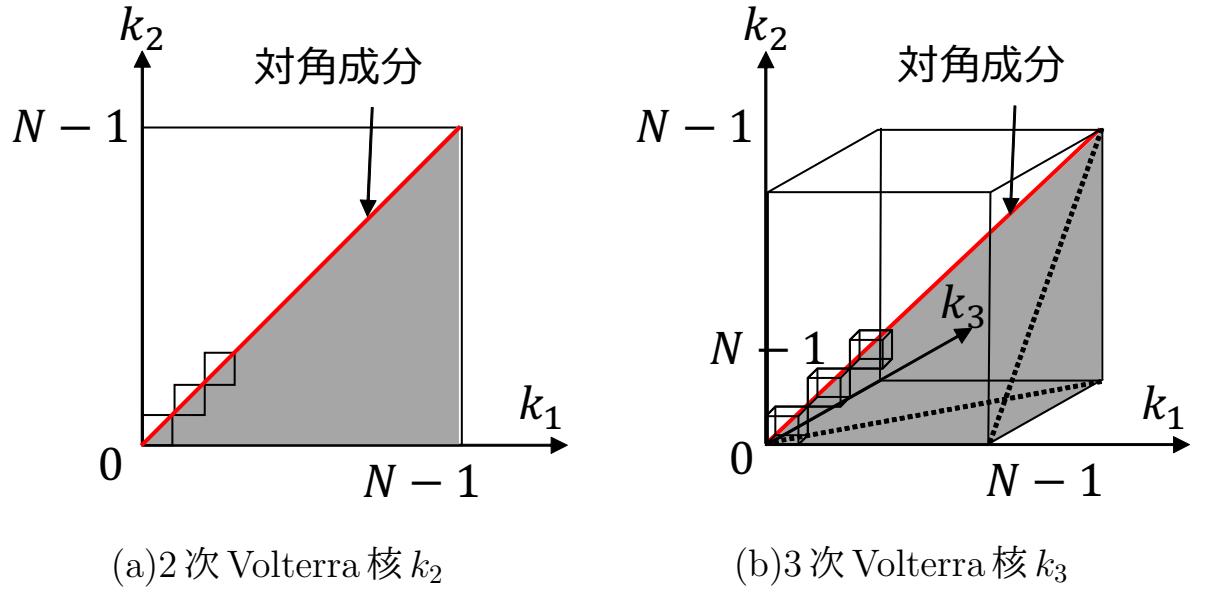


図 3.4 Volterra 核の構造

ただし,  $\mu_p$  はステップサイズであり, Volterra 核の更新量を決定する正の定数である.

本研究において, 線形項の1次 Volterra 核  $h_1$  は刺激音対を近似する. 刺激音対は, DPOAE の非線形成分に比べ音圧が大きいことから, 線形項を更新するように働く. そこで本研究では1次 Volterra 演算子  $H_1$  を含まないモデル構成とする. 非線形項のみで測定系を同定することで, DPOAE の非線形性を Volterra 核によって効率的にモデリングできる.

### 3.2.3 提案手法 1 の特徴ベクトル

前節で述べたように, 提案手法 1 では Volterra 核  $h_2(k_1, k_2) \cdots h_{P_V}(k_1, k_2, \dots, k_{P_V})$  によって DPOAE の非線形性を表現する. ただし, 3.2.1 節で述べた Volterra 核のパラメータ数の問題から, 特徴ベクトルのサイズが膨大になる. 図 3.4 に, 2 次及び 3 次 Volterra 核  $k_2, k_3$  を示す. Volterra モデルの対称性から, 非線形を表現するために必要なパラメータ数は 2 次の場合で  $N(N+1)/2$  個となる. 本研究では, さらに特徴ベクトルのサイズを小さくするため, 各 Volterra 核の対角成分を取り出す. よって, 提案手法 1 の特徴ベクトル  $\mathbf{v}_V$  は以下の式 (3.6) で表され,

$$\mathbf{v}_V = [h_2(k_1, k_2) \cdots h_{P_V}(k_1, k_2, \dots, k_{P_V})] \quad (3.6)$$

$P_V - 1 \times N$  のサイズとなる. Volterra モデルの拡張次数  $P_V$  については, 次章で述べる.

### 3.3 提案手法2 :Functional Link Artificial Neural Network (FLANN)による特徴抽出

非線形な環境で複雑なタスクを実行するための強力な学習手法である Artificial Neural Networks(ANN) は適切な誤差関数の最適化、非線形関数の近似に優れた性能がある [21]. Functional Link Artificial Neural Network (FLANN) は、MLP よりも収束が速く、少ない計算量で関数近似およびパターン分類が可能な非線形のモデルである [19]. また、Volterra モデルに比べ少ない係数で非線形性をモデルリングできることから、計算量の削減が期待される. 非線形システム同定に対して、入力信号を拡張する多項式として、チェビシェフ多項式、三角多項式、ルジャンドル多項式を使用する FLANN が報告されている [19][21][20]. FLANN を用いたシステム同定について次節以降で詳しく述べる.

#### 3.3.1 FLANN の構成

記憶長  $N$  で拡張次数  $P_F$  の FLANN の構造を図 3.5 に示す. 最近の  $N$  個の要素を持つ入力列  $X(n)$ ,  $q$  次の関数展開信号列  $T_q(n)$  は次のように表される.

$$X(n) = [x(n) \ x(n-1) \cdots x(n-N+1)] \quad (3.7)$$

$$T_q(n) = [t_q(x(n)) \ t_q(x(n-1)) \cdots t_q(x(n-N+1))] \quad (3.8)$$

ただし、 $0 \leq q \leq P_F$  である. 式 (3.7) 式 (3.8) のように、 $x(n)$  を関数展開することで、 $P_F + 1$  個の関数展開信号  $t_q(x(n))$  を生成する. 本研究では、チェビシェフ多項式により関数展開

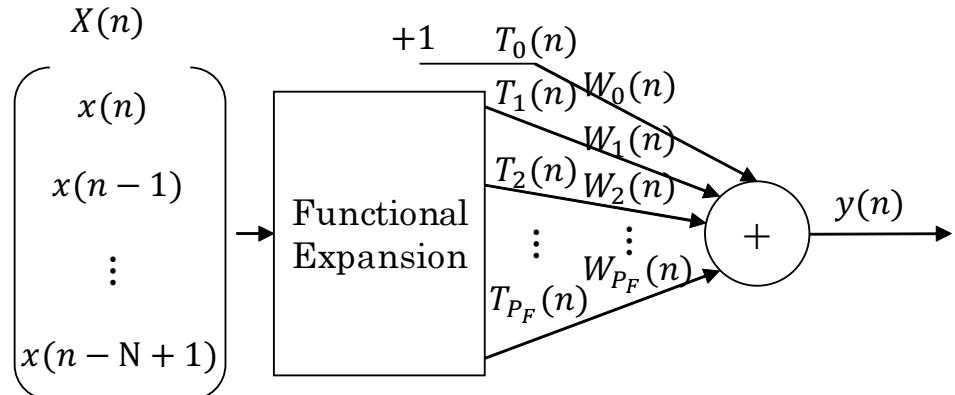


図 3.5 FLANN の構造

するが、次節で選択理由に関して説明する。また式 (3.9) に示すように、 $P_F + 1$  個の展開要素は重み  $W_q(n)$  で線形結合されることで 1 つの出力が生成される。

$$y(n) = \sum_{i=0}^{P_F} T_q(n) W_q(n) \quad (3.9)$$

$q$  次の重み  $W_q$  を次式に示す。

$$W_q(n) = [w_q(n) \ w_q(n-1) \cdots w_q(n-N+1)]^T \quad (3.10)$$

### 3.3.2 チェビシェフ多項式に基づいた FLANN

本研究では、チェビシェフ多項式によって関数展開する。チェビシェフ多項式を用いる場合、式 (3.8) の各要素は式 (3.11) に展開される。

$$t_q(x(n)) = 2x(n) t_{q-1}(x(n)) - t_{q-2}(x(n)) \quad (3.11)$$

関数展開信号  $t_q(x(n))$  の始めの数項を以下の式 (3.12) に示す。

$$\begin{aligned} t_0(x(n)) &= 1 \\ t_1(x(n)) &= x(n) \\ t_2(x(n)) &= 2x(n)^2 - 1 \\ t_3(x(n)) &= 4x(n)^3 - 3x(n) \\ t_4(x(n)) &= 8x(n)^4 - 8x(n)^2 + 1 \end{aligned} \quad (3.12)$$

ここで、DPOAE の非線形成分は、式 (2.1) に示したように刺激音周波数  $f_1, f_2$  のべき乗で表すことができる。チェビシェフ多項式は、展開次数が刺激音周波数のべき乗に対応するため、他の多項式と比較して DPOAE の非線形成分を表現するのに適している。ルジャンドル多項式も同様の特徴を持っているが、実験を通してチェビシェフ多項式のほうがモデルとして優れている事を確認したため、本研究ではチェビシェフ多項式を採用している。

### 3.3.3 FLANN を用いたシステム同定

図 3.6 に FLANN で DPOAE の測定系を同定するブロック図を示す。FLANN での同定も Volterra モデルと同様に、LMS アルゴリズム [18] によって誤差信号  $e(n)$  の二乗期待値を最小化するように更新する。LMS アルゴリズムは最急降下アルゴリズムによって  $q$  次の重み  $W_q$  は以下の式 (3.13) ように更新される。

$$W_q(n+1) = W_q(n) + \mu_q T_q(n) e(n) \quad (3.13)$$

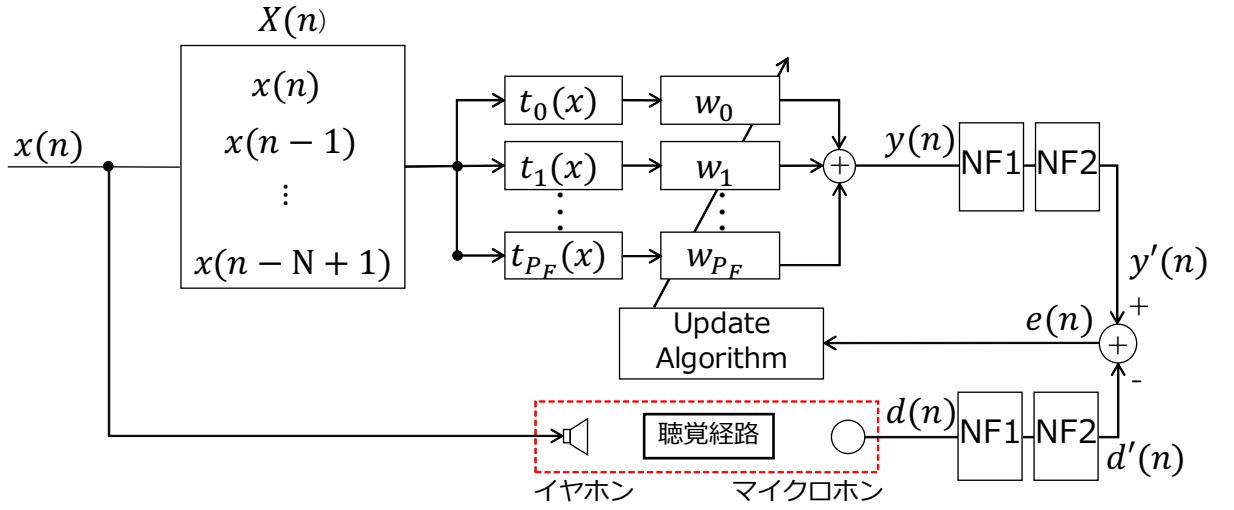


図 3.6 FLANN を用いたシステム同定のブロック図

ただし、 $\mu_q$  はステップサイズである。

ここで、提案手法 2 も提案手法 1 と同様に、線形成分の近似を妨げ、DPOAE の非線形性を効率的にモデリングする必要がある。しかし、チェビシェフ多項式による FLANN では式 (3.11) 及び式 (3.12) に示したように、 $q = 1$  だけでなく  $q = 3, 5, \dots$  の展開信号も線形項含むため、提案手法 1 のようにモデルを組み替えることが容易ではない。

そこで、提案手法 2 では線形の刺激音の成分の近似を妨げるため、出力信号  $y(n)$  に対して  $Q = 10$  で中心周波数が  $f_1, f_2$  の 2 つのノッチフィルタを通す。

ノッチフィルタ通過後の信号を  $y'(n)$  とし、同一のノッチフィルタを測定信号  $d(n)$  に対しても通過させ、その信号を  $d'(n)$  とする。よって、誤差信号  $e(n)$  は次式で表される。

$$e(n) = y'(n) - d'(n) \quad (3.14)$$

### 3.3.4 提案手法 2 の特徴ベクトル

前節で述べたように、提案手法 2 の重み  $W_q$  はノッチフィルタによって DPOAE の非線形成分を近似する。 $W_2 \dots W_{P_F}$  は非線形成分を含むが、 $W_1$  は線形成分のみを表すパラメータであり、特徴にはなりえない。 $W_0$  も直流成分を表すパラメータであり、非線形成分との関連がないため、本研究では特徴として利用しない。提案手法 2 の特徴ベクトル  $\mathbf{v}_F$  を以下

の式 (3.15) に示す.

$$\mathbf{v}_F = [W_2 \cdots W_{P_F}] \quad (3.15)$$

これにより,  $\mathbf{v}_F$  のサイズは  $P_F - 1 \times N$  となる. FLANN の拡張次数  $P_F$  については, 次章で述べる.

### 3.4 まとめ

本章では, 従来手法の問題点を解決する提案手法について述べた. 提案手法は, DPOAE の非線形性を非線形システム同定でモデル化し, 同定で更新されるパラメータを特徴とする. 提案手法 1 は, DPOAE の特徴表現に有効とされる Volterra モデルによって同定する手法である. 提案手法 2 は, Volterra モデルに比べパラメータ数の少ない FLANN によって同定する手法である. 次章では, 被験者から取得した DPOAE の測定信号を基に, 特徴抽出及び認証実験を行い, 従来手法と提案手法の認証精度と認証時間の結果を示す. また, 提案手法の有用性を検証した結果を示す.

## 第 4 章 実験

3章では、非線形システム同定を用いて DPOAE の非線形性を抽出する手法を提案した。本章では、被験者から取得した測定信号を用いて認証評価実験を行い、提案手法による生体認証の有用性を確認する。

認証評価実験では、提案手法の特徴抽出手法としての有用性を確認するため、従来手法と提案手法の認証精度と認証時間を比較を行う。以下の節より実験の概要を述べる。

### 4.1 DPOAE を含む測定信号の録音条件

本節では、認証評価実験に使用する測定信号の取得について説明する。録音条件を表 4.1 に示し、ブロック図を図 4.1 に示す。健全な聴力を持つ被験者 12 名に、被験者が静止した状態で刺激音対を再生し、各被験者の測定信号を録音した。刺激音対の生成、測定には MATLAB を用い、オーディオインターフェース (Roland, UA-1010) を介して再生・録音した。それぞれの刺激音は、ヘッドホンアンプ (Audio-Technica, AT-HA2) によって被験者の耳元で音圧が 75dB SPL となるよう増幅し、イヤーチップを装着した被験者の左耳で再生した。また、低雑音マイクロホンシステム (Etymotic Research, ER-10B+) によって録音および増幅し、オーディオインターフェースへ入力した。

刺激音周波数は、文献 [9] に従い 250Hz 間隔で 21 パターンの組み合わせとした。測定信号は、DPOAE の発生遅延が 20ms 程度 [12] であることを考慮し、後ろから 4800 サンプル

表 4.1 測定信号の録音条件

測定環境	無響室
被験者	12 名
各被験者の録音回数	4 回
サンプリング周波数	48kHz
刺激音圧	75dB SPL
刺激音サンプル数	5280
刺激音周波数 $f_2$	1kHz-6kHz(int. 250Hz)
刺激音周波数比 $f_2/f_1$	1.22

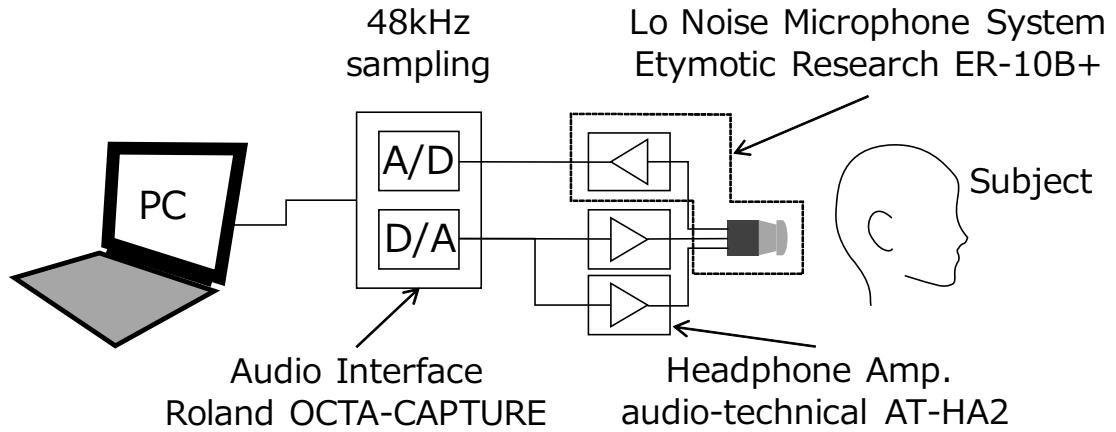


図 4.1 測定信号の録音ブロック図

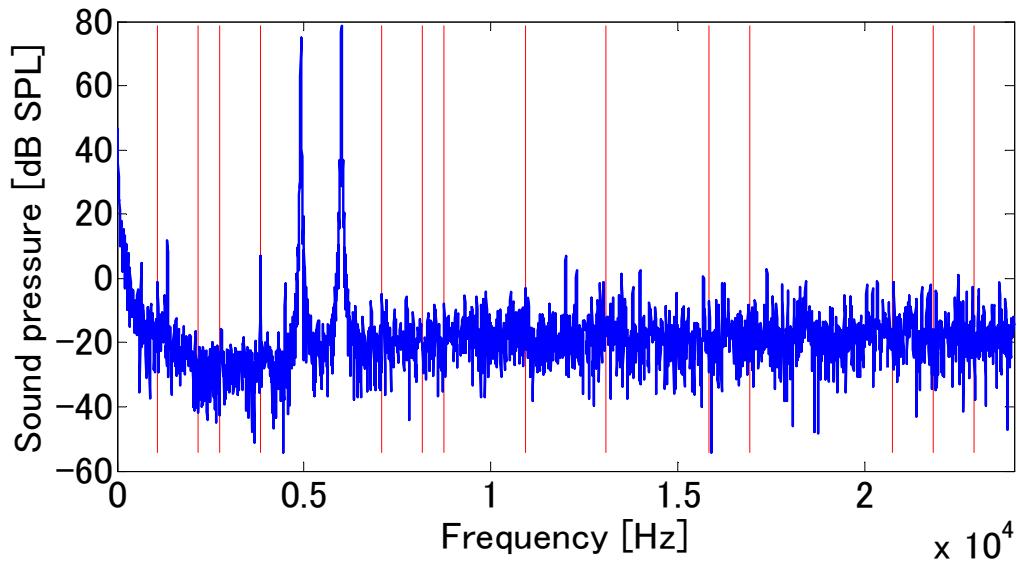


図 4.2 測定信号の周波数スペクトル

分を矩形窓で取り出した。測定信号の信号対雑音電力比を改善するために、10回分の結果で同期加算処理を行った。残響を考慮し、刺激音の再生間隔は約1秒のインターバルを設けた。また、被験者は4回の録音ごとにイヤーチップの着脱を行った。

ある被験者の測定信号(刺激音周波数  $f_2 = 6000[\text{Hz}]$ )の周波数スペクトルの結果を図4.2に示す。ここで、図4.2内の赤線はDPOAEの非線形成分を表す。周波数スペク

トルから、DPOAE の非線形成分の内、 $10918\text{Hz}(f_1 + f_2)$ ,  $1082\text{Hz}(f_2 - f_1)$ ,  $3836\text{Hz}(2f_1 - f_2)$ ,  $7082\text{Hz}(2f_2 - f_1)$  成分が良好に観測されたことが分かる。これにより、特徴ベクトルを抽出する時、DPOAE の非線形成分を大まかに同定するためには 3 次まで考慮すれば良い。

## 4.2 特徴ベクトルの抽出

前節で録音した各被験者の測定信号から、提案手法によって特徴ベクトルを抽出した。提案手法 1 および提案手法 2 のシステム同定の条件を表 4.2, 表 4.3 に示す。前節で録音した測定信号は、刺激音対の最大値を基準に  $\pm 1$  の範囲で正規化する。提案手法 1 および提案手法 2 ともに測定信号長で繰り返し同定し、記憶長は 128 とした。提案手法 1 の Volterra 拡張次数は計算量の問題と前節で述べた理由から 3 次とし、FLANN は Volterra モデルに比べ計算量が少ないとから提案手法 2 は 3 次及び 5 次で拡張する。提案手法 2 で使用した 2 つの IIR 型ノッチフィルタはフィルタ次数 2 で、中心周波数は刺激音周波数とした。

刺激音周波数  $f_2 = 6000[\text{Hz}]$  での提案手法 1 と提案手法 2 の同定誤差の例を図 4.3 に示す。

表 4.2 提案手法 1 システム同定条件

サンプリング周波数	48kHz
適応アルゴリズム	LMS
記憶長	128
拡張次数	3
ステップサイズ	0.0001

表 4.3 提案手法 2 システム同定条件

サンプリング周波数	48kHz
適応アルゴリズム	LMS
記憶長	128
拡張次数	3, 5
線形項ステップサイズ	0.004
非線形項ステップサイズ	0.0005
ノッチフィルタ設計条件	
フィルタ次数	2
鋭さ	10
中心周波数	刺激音周波数 $f_1, f_2$

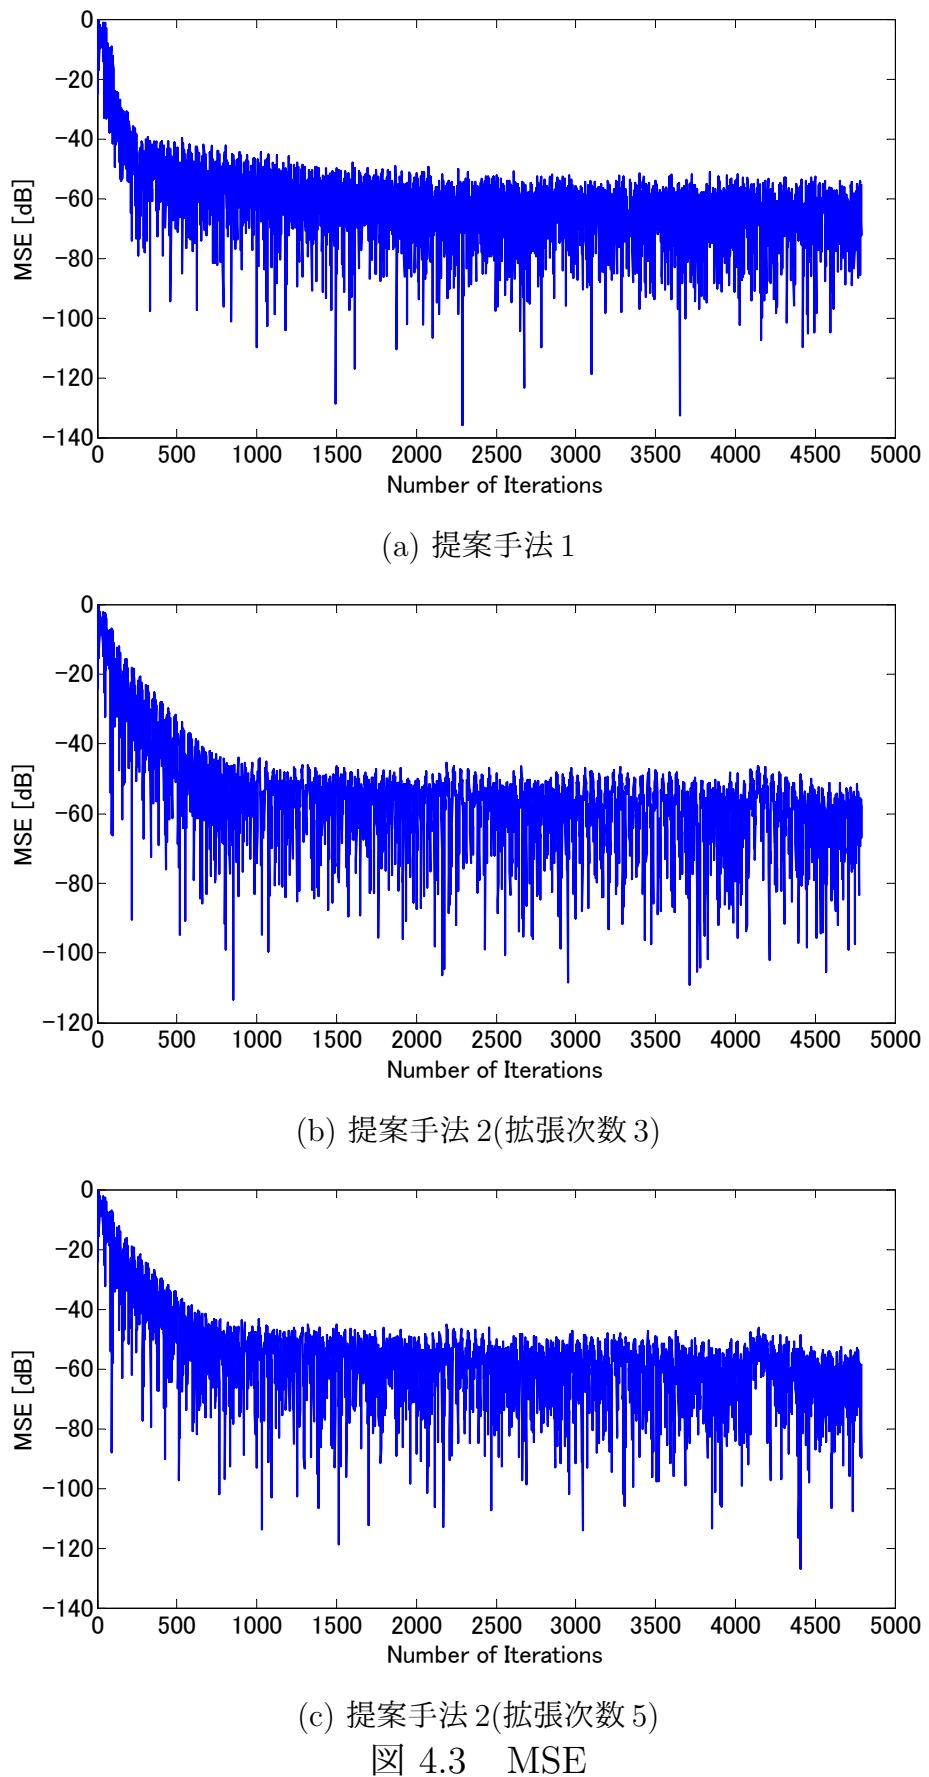


図 4.3 MSE

本研究では、二乗平均誤差 (MSE: Mean Squared Error) で誤差を示す。繰り返し同定することで MSE が減少しており、DPOAE の非線形性を同定できていることが分かる。同定の条件であるステップサイズは、MSE が -40dB 以下まで落ち込むように決定した。

### 4.3 各刺激音周波数の特徴ベクトルによる提案手法の認証精度評価

提案手法の各刺激音周波数から抽出した特徴ベクトルによって認証し、刺激音周波数による認証精度の差について評価した。4.1 節で録音した測定信号から抽出した特徴ベクトルの内、2 回分を学習用データ、残りの 2 回分をテスト用データとした。認証部は 2.2 節で述べたようにユークリッド距離に基づいた最尤推定法を使用した。最尤推定法の確率密度関数は文献 [9] にあるガウス分布を用いる。

図 4.4 に各刺激音周波数の認証精度を示す。いずれの刺激音周波数であっても約 70% の認証精度を示している。刺激音周波数によって認証精度の差が生じているが、周波数と精度の相関は弱いと考えられる。提案手法 1 は提案手法 2 と比較して全ての刺激音周波数において高い認証精度を示した。これは、チェビシェフ多項式を用いた FLANN の関数展開

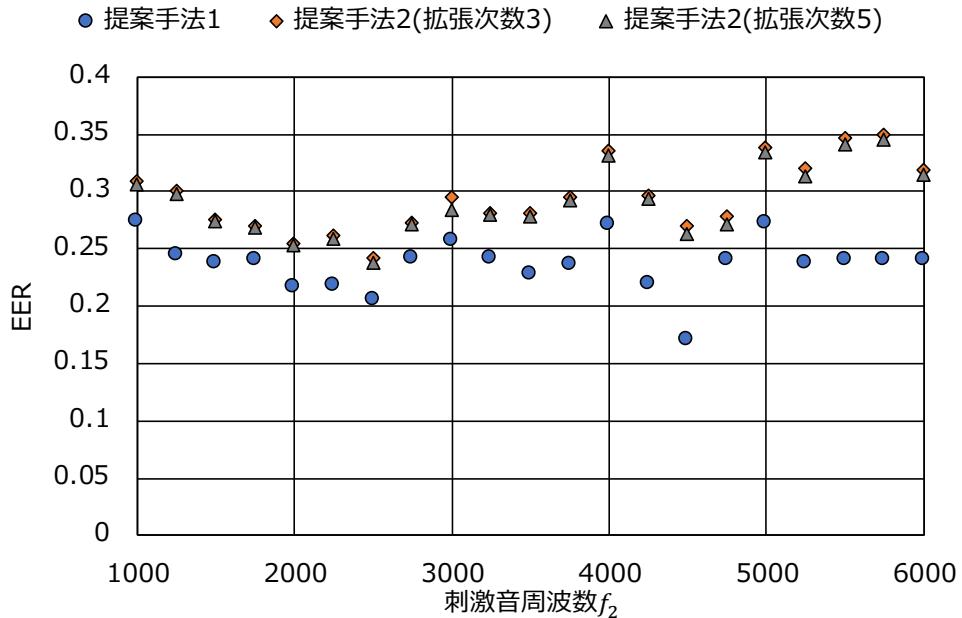


図 4.4 各刺激音周波数の特徴ベクトルによる認証精度

が Volterra モデルを近似したものであるからと考えられる。提案手法 2 の拡張次数の精度差を見ると、5 次での拡張した結果がわずかに上回った。この要因としては、4.1 節でも述べたように、録音した測定信号は 3 次までの非線形成分が良好に観測されたが、さらに高次の非線形成分も個人差があったためと考えられる。また、チェビシェフ多項式は 5 次で展開した場合、その関数拡張信号は 3 次の項を持つ。このことから、精度向上を図るのならば、拡張次数を大きく設定する必要があると考えられる。

以上の結果を基に、複数の刺激音周波数における特徴ベクトルを組み合わせ、認証評価を行う。

## 4.4 複数周波数の特徴ベクトルを用いた提案手法の認証

前節では、各刺激音周波数の特徴ベクトルから認証精度の検討を行った。この結果を基に、提案手法の特徴ベクトルを組み合わせた場合と従来手法の認証結果を比較する。本研究の検討項目は、認証精度と認証時間である。次に実験の詳細について述べる。

### 4.4.1 実験条件

まず、提案手法の実験条件について述べる。複数の刺激音周波数の特徴ベクトルを組み合わせることは、測定信号の録音回数が増加することを意味する。提案手法 1 の結合特徴ベクトル  $\mathbf{v}'_V$  は、 $f_n$  個の刺激周波数の特徴ベクトル  $\mathbf{v}_V$  を水平方向に結合する。提案手法 2 の結合特徴ベクトル  $\mathbf{v}'_F$  も同様である。

これらの結合特徴ベクトルの組み合わせ数  $f_n$  を変化させ、ユークリッド距離に基づいた最尤推定法及び NN で構成した認証部で評価することで、測定信号の録音回数を制限した場合での認証精度を検討する。

前節と同様に結合特徴ベクトルは、2 回分を学習用データ、残りの 2 回分をテスト用データとした。表 4.4 に構成した NN の条件を示す。

表 4.4 認証評価 NN の条件

学習回数	$2 \times 10^5$
学習係数	$10^{-2}$
バッチサイズ	6

表 4.5 組み合わせの対象となる刺激音周波数

認証精度 (降順)		1	2	3	4	5	6	7	8	9	10
音周波数	提案手法 1	4500	2500	2000	2250	4250	3500	3750	5250	1500	1750
	提案手法 2	2500	2000	2250	4500	1750	2750	1500	4750	3250	3500
	提案手法 2	2500	2000	2250	4500	1750	2750	4750	1500	3500	3250

NN の入力層と中間層のユニット数は結合特徴ベクトルの次元数にあわせ、拡張次数 3 の場合  $256 \times fn$  で、拡張次数 5 の場合  $512 \times fn$  とし、教師信号と学習データの MSE が  $10^{-3}$  となるまで学習を繰り返した。最尤推定法はガウス分布と ex-Gaussian それぞれの確率密度関数で近似する。

ここで、組み合わせ数は  $fn = 1, 3, 5, 10$  の 4 つの条件で、前節の結果から、高精度であった刺激音周波数の特徴ベクトルを対象とする。表 4.5 に、対象とした刺激音周波数  $f_2$  を示す。

続いて、従来手法の実験条件について述べる。従来手法の特徴ベクトル  $v_e$  は、2.1 節で示したように 1000Hz から 6000Hz まで 21 の刺激音周波数  $f_2$  から抽出している。この特徴ベクトルは、測定信号の全信号長をハン窓に通して  $2^{16}$  サンプルで FFT 処理し、得られた音圧レベルである。従来手法の特徴ベクトルも、2 回分を学習用データ、残りの 2 回分をテスト用データとした。また、認証部は提案手法と同様である。ただし、NN の入力層と中間層のユニット数は特徴ベクトル  $v_e$  の次元数にあわせ、21 に定めた。

認証時間の評価は、コア i5、クロック周波数 3.30GHz、メモリ 16GB のコンピュータを使用した。以降に、認証精度及び認証時間についての結果を示す。

#### 4.4.2 認証精度の比較

図 4.5 に従来手法及び提案手法それぞれの特徴ベクトルによる認証精度を示す。横軸は、特徴ベクトルに用いた刺激音周波数の組み合わせ数  $fn$  を表し、縦軸は EER を示す。

まず、最尤推定法の結果について述べる。図 4.5 で刺激音周波数の組み合わせ数  $fn = 21$  である従来手法は、ガウス分布と ex-gaussian 共に提案手法を上回る認証精度である。提案手法 1 のガウス分布では、組み合わせ数による精度の変化は小さいことが分かる。よって提案手法 1 の特徴ベクトルは、組み合わせ数を増やさずとも個人差を表現可能であり、いずれの組み合わせ数であっても従来手法と同等程度の認証精度を示した。提案手法 2 のガ

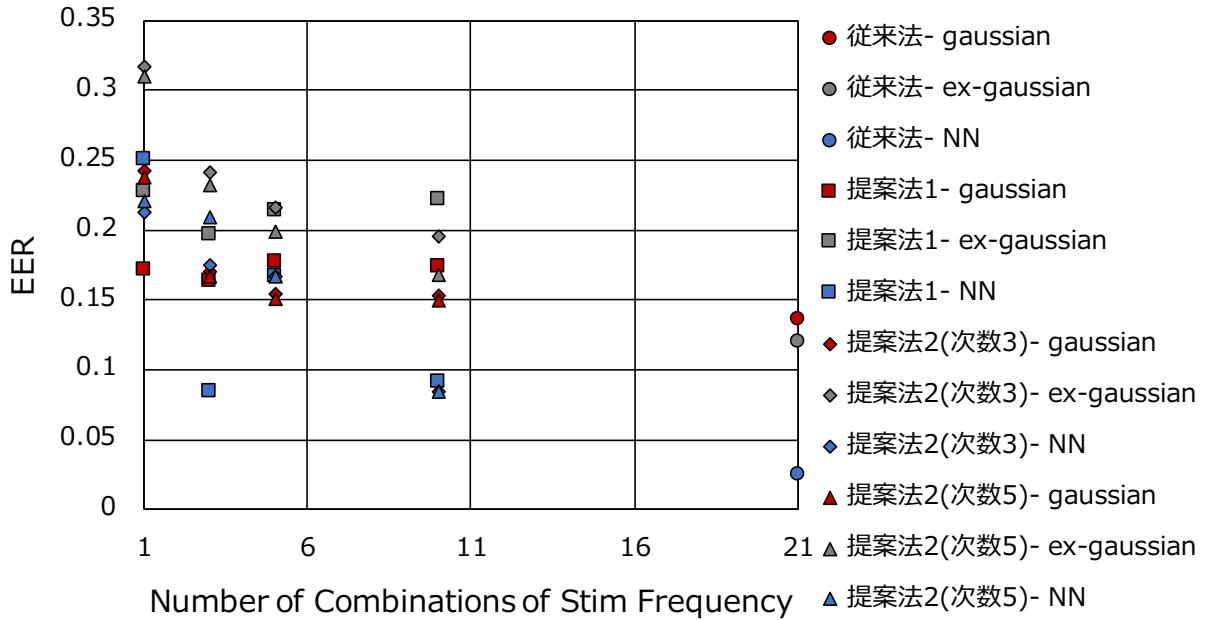


図 4.5 各刺激音周波数の特徴ベクトルによる認証精度

ガウス分布では、図 4.4 で低かった認証精度が、組み合わせ数を増やすことで向上した。したがって、提案手法 2 の特徴ベクトルは、各刺激音周波数では個人差が十分に表現できていないことが考えられるが、組み合わせ数を増やすことで従来手法と同等程度の認証精度を示した。また、提案手法の ex-gaussian では、ガウス分布と比べ精度が悪くなってしまっていることが分かる。従来手法では有効であった ex-gaussian 分布は、提案手法は分布の形状から精度の低下を招くといえる。

続いて、NN の結果について述べる。NN では、従来手法及び提案手法いずれも、組み合わせ数を増加することで良好な認証精度を示した。従来手法と比較すると、提案手法は約 5% 精度が劣化した。提案手法で精度が劣化した要因としては、NN の層数が考えられる。本研究で使用した NN の入力層と中間層のユニット数は、特徴ベクトルの次元数から従来手法と提案手法で大きく異なる。しかし、NN の層数に関してはどちらも同じである。多くの層で NN を構築した場合、その表現力は広がるため、高次元の特徴ベクトルを持つ提案手法の層数を適切に設定する必要があると考えられる。また、層数にあわせ各中間層のユニット数の検討が必要である。

表 4.6 従来手法と提案手法による認証時間の比較

		特性測定 時間 [s]	特徴抽出 時間 [s]	組み合わせ数	認証時間 [s]
従来手法		1.00	0.00	21	21.0
提案手法 1		1.00	3.70	1,3,5,10	4.70, 14.1, 23.1, 47.0
提案手法 2	3 次	1.00	0.148	1, 3, 5, 10	1.15, 3.44, 5.74, 11.5
	5 次	1.00	0.160	1, 3, 5, 10	1.16, 3.48, 5.80, 11.6

表 4.7 更新 1 回あたりの計算量

		パラメータ数	加減算数	乗除算数
提案手法 1		2113536	2113535	6324224
提案手法 2	3 次	512	517	517
	5 次	768	773	733

#### 4.4.3 認証時間の比較

表 4.6 に従来手法及び提案手法それぞれの特徴ベクトルによる認証時間を示す。従来手法は抽出時間は計算時間の短い FFT 処理であるため、本研究では 0s と仮定する。提案手法 1 は組み合わせ数が 3 以下の場合は、従来手法より優れるが、それ以上では反対に従来手法に劣ることが分かる。3.2.3 節で述べたように特徴ベクトルは Volterra 核の対角成分から成る。しかし本研究では、DPOAE の非線形性を正確に推定するため、対角成分を除く Volterra 核も更新している。本研究で示した Volterra モデルと比較して非線形性の表現力が低下する問題が生じるが、対角成分の Volterra 核のみを更新することで認証時間を減少することが可能であると考えられる。一方、提案手法 2 は組み合わせ数を  $fn = 10$  とした場合であっても、従来手法より計算コストが 50% 減少した。これは、パラメータ数の少なく、計算量の少ない FLANN を適用したためである。表 4.7 に 1 度の更新あたりの計算量の比較を示す。

前節より、ガウス分布による最尤推定法において提案手法間の認証精度差は小さい。したがって、認証精度と認証時間を踏まえると、提案手法 2 は従来手法の半分の認証時間で同等の精度を示すため、特徴抽出法として有用であるといえる。

## 4.5 まとめ

本章では、提案手法の有用性を確認するため、測定信号から抽出した特徴ベクトルを用いて認証評価実験を行い、従来手法及び提案手法の認証精度と認証時間を比較した。まず、刺激音周波数ごとにおける特徴ベクトルを用いて評価した。その結果、周波数の変化による認証精度差が小さかったため、周波数と認証精度の相関が弱いことを示した。次に、提案手法の認証時間と認証精度について評価するため、提案手法の刺激音周波数の特徴ベクトルを組み合わせた。認証精度が高い刺激音周波数を組み合わせた結果、どちらの提案手法も組み合わせ数に応じて認証精度が向上し、組み合わせ数 10 では従来手法と同等程度の精度となった。

組み合わせ数を 10 以下としたとき、提案手法の認証時間は従来手法に比べて短縮された。しかし、認証精度を向上するために組み合わせ数が多い場合、提案手法 1 は従来手法より認証時間が長くなってしまった。この原因として、特徴抽出に用いる Volterra モデルのパラメータの更新が挙げられ、これを解決するために、特徴ベクトルとして取り出す対角成分以外を更新しなければ良いと考えられる。

組み合わせ数 10 では提案手法に認証精度の差が小さい事から、提案手法 2 は従来手法の半分の認証時間で同等の精度を示した。したがって、提案手法は特徴抽出法として有用であるといえる。

## 第 5 章 おわりに

本論文では、認証精度を損なわず、従来手法の問題点である認証時間の長さを軽減することを目的に、少ない録音回数の DPOAE 信号から多くの特徴を抽出する手法を提案した。第 1 章では、近年求められている生理的特徴、従来の DPOAE を用いた生体認証の問題について述べ、本論文の研究目的について述べた。第 2 章では、本研究の生理的特徴である DPOAE について述べ、これを用いて特徴抽出する従来手法について説明した。第 3 章では、本論文の提案手法である、非線形システム同定を使用した特徴抽出手法について述べた。提案手法 1 は、代表的な非線形モデルである Volterra モデルを用いる手法であり、線形成分である刺激音の近似を避けるために線形項を除いた構造である。提案手法 2 は、Volterra モデルより計算量が少ない FLANN を用いる手法であり、線形成分はノッチフィルタによって除去される。第 4 章では、12 名の被験者で録音した DPOAE 信号を用いて認証評価実験により、提案手法の有用性を確認した。まず、入力する刺激音周波数による認証精度の変化を評価した結果、どちらの提案手法も周波数により精度差が生じ、また従来手法の精度に比べ悪化した。悪化した精度の向上のため、高精度であった周波数の特徴を組み合わせて認証することで、組み合わせ数と認証精度・認証時間の関係について検討した。その結果、どちらの提案手法においても、組み合わせ数を増やすことで精度が向上した。特に提案手法 2 で特徴抽出し、組み合わせ数を 10 とした場合では、従来手法の半分の認証時間で、同等程度の認証精度を達成した。しかし提案手法 1 では、従来手法より認証時間が長くなってしまった。この要因としては、特徴抽出に用いる Volterra モデルで更新するパラメータ数の多さが挙げられる。この問題を解決するために、特徴ベクトルとして取り出す対角成分以外を更新しなければ良いと考えられる。

## 謝辞

本研究を行うにあたり、適切なご指導ご鞭撻頂いた、杉田泰則准教授に深く感謝いたします。また、本論文を執筆するにあたり、副査をご担当いただき多くの助言を賜りました本学電気系岩橋政宏教授ならびに圓道知博准教授に感謝いたします。また、苦楽をともにしてきた信号処理応用研究室の皆様に感謝の意を表します。最後に、私をここまで育て、支えて下さった両親に深く感謝いたします。

平成30年2月

## 参考文献

- [1] M. H. George, R.A. King, "A Robust Speaker Verification Biometric", Proceedings of IEEE 29th Annual 1995 International Carnahan Conference On Security Technology, pp. 41-46, 1995.
- [2] R. S. Germain, A. Califano, S. Colville, "Fingerprint Matching using Transformation Parameter Clustering", IEEE Computational Science and Engineering, Vol. 4, No. 4, pp. 42-49, 1997.
- [3] A. K. Jain, S. Prabhakar, L. Hong, "A Multichannel Approach to Fingerprint Classification", IEEE Transaction on Pattern Analysis and Machine Intelligence, Vol. 21, No.4, pp.348-359, 1999.
- [4] N. Miura, A. Nagasaka, T. Miyatake, "Feature Extraction of Finger-vein Patterns based on Repeated Line Tracking and Its Application to Personal Identification", Machine Vision and Applications, Vol. 15, No. 4, pp. 194-203, 2004.
- [5] Y. Zhu, T. Tan, Y. Wang, "Biometric Personal Identification based on Iris Patterns", Proceedings of 15th International Conference on Pattern Recognition, Vol. 2, pp. 801-804, 2000.
- [6] A. M. Martinez, H. Jia, "Support Vector Machines in Face Recognition with Occlusions", Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Neural Networks, Vol. 14, pp. 795-803, 2001.
- [7] A. H. M. Akkermans, T. A. M. Kecenaar and D. W. E. Schobben, "Acoustic Ear Recognition for Person Identification", Fourth IEEE Workshop on Automatic Identification Advanced Technologies, pp. 219-223, 2005.
- [8] S. Yano, T. Arakawa, T. Koshinaka, H. Imaoka and H. Irisawa, "Improving Acoustic Ear Recognition Accuracy for Personal Identification by Averaging Biometric Data and Spreading Measurement Errors over a Wide Frequency Range", IEICE Transactions on Fundamentals of Electronics , Vol. J100-A, No. 4, pp. 151-168, 2017.

- [9] N. J. Grabham, M. A. Swabey, P. Chambers, M. W. Lutman and N. M. White, "An Evaluation of Otoacoustic Emissions as a Biometric", IEEE Transactions on Information Forensics and Security, Vol. 8, No. 1, pp. 174-183, 2013.
- [10] P. Chambers, N. J. Grabham. J. Chad and S. P. Beeby, "The Biometric Potential of Transient Otoacoustic Emissions", International J-Biometrics, Vol. 1, No. 3, pp. 349-364, 2009.
- [11] M. A. Swabey, S. P. Beeby, A. D. Brown and J. Chad, "Using Otoacoustic Emissions as a Biometric", Proceedings of International Conference on Biometric Authentication 2004, pp. 600-606, 2004.
- [12] D. T. Kemp, "Stimulated Acoustic Emissions from within the Human Auditory System", J-Acoustical Society of America, Vol. 64, No. 5, pp. 1386-1391, 1978.
- [13] J. C. Patra, R. N. Pal, B. N. Chatterji, G. Panda, "Identification of Nonlinear Dynamic Systems Using Functional Link Artificial Neural Networks", IEEE Transactions on Systems Man and Cybernetics, Vol. 29, pp. 254-262, 1999.
- [14] A. R. D. Thornton, "Maximum Length Sequences and Volterra Series in the Analysis of Transient Evoked Otoacoustic Emissions", British J-Audiology, Vol. 31, No. 5, pp. 493-498, 1997.
- [15] D. Zelle, L. Lorenz, J. P. Thiericke, A. W. Gummer, E. Dalhoff, "Input-Output Functions of the Nonlinear-Distortion Component of Distortion-Product Otoacoustic Emissions in Normal and Hearing-Impaired Human Ears", J-Acoustical Society of America, Vol. 141, No. 5, pp. 3203-3219, 2017.
- [16] 張東望西, 杉田泰則, "DPOAE 信号を用いた個人認証に関する検討", 電子情報通信学会信越支部大会, 2017.
- [17] D. E. Rumelhart, G. E. hinton, R. J. Willianms, "Learning Representations by Back-Propagating Errors", J-Nature, Vol. 323, No. 9, pp.533-536, 1986.
- [18] T. Koh, E. Powers, "Second-Order Volterra Filtering and its Application to Nonlinear System Identification", IEEE Transactions on Acoustics, Speech, and Signal Processing, Vol. 33, No. 6, pp. 1445-1455, 1985.

- [19] S. Mishra, G. Panda, S. Meher "Chebyshev Functional Link Artificial Neural Networks for Denoising of Image Corrupted by Salt and Pepper Noise", International J-Recent Trends in Engineering, Vol. 1, No. 1, pp. 413-417, 2009.
- [20] A. Carini, S. Cecchi, M. Gasparini, G. Sicuranza, "Introducing Legendre Nonlinear Filters", Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing, pp. 7989-7993, 2014.
- [21] J. C. Patra, R. N. Pal, B. N. Chatterji, G. Panda, "Identification of Nonlinear Dynamic Systems Using Functional Link Artificial Neural Networks", IEEE Transactions Systems Man and Cybernetics, Part B, Vol. 29, pp. 254-262, 1999.