

2012 年度修士論文

携帯端末の加速度センサを用いた 歩行認証に関する研究

指導： 甲藤 二郎 教授
小松 尚久 教授

2013 年 2 月 8 日

早稲田大学 理工学術院 基幹理工学研究科 情報理工学専攻

5111B025-5 笠原 弘樹

目次

第 1 章	序論	1
1.1	研究の背景と目的	1
1.2	本論文の構成と概要	3
第 2 章	歩行認証	5
2.1	歩行時の加速度データ	5
2.2	従来研究	8
2.2.1	歩行認証に関する研究	8
2.2.2	歩行動作に関する研究	10
第 3 章	提案手法	13
3.1	歩行認証システム	13
3.1.1	前処理 (Preprocessing) 部	14
3.1.2	特徴抽出 (Feature Extraction) 部	18
3.1.3	ベクトル量子化 (Vector Quantization) [18]	19
3.1.4	距離計算 (Distance Calculation) 部	19
3.2	LPC ケプストラム [12]	20
3.2.1	ケプストラム分析	20
3.2.2	LPC ケプストラム	22
3.3	複数フレームを用いた認証	24
3.3.1	統計量を用いた認証	24
3.3.2	k 数決法を用いた認証	24
3.4	歩行認証の要因	25
第 4 章	評価実験	27
4.1	評価実験概要	27
4.2	通常歩行における歩行認証実験	28
4.2.1	従来特徴量との比較	29
4.2.2	パラメータ調査	32
4.2.3	複数フレームを用いた認証	35
	統計量を用いた認証	35
	k 数決法を用いた認証	38
4.2.4	保持状態評価実験	40

4.2.5	経年変化評価実験	43
4.3	成りすまし歩行における認証実験	45
第 5 章	結論	49
5.1	まとめ	49
5.2	今後の課題と検討	50
	謝辞	51
付録 A	携帯端末に搭載されているセンサ	53
A.0.1	測位センサ	53
A.0.2	加速度センサ	55
A.0.3	地磁気センサ	57
付録 B	データ取得アプリケーション	59
B.1	アプリケーションの構成	59
付録 C	ベクトル量子化	63
C.1	ベクトル量子化	63
C.2	クラスタリングアルゴリズム	64
	参考文献	67
	関連業績	69

第 1 章

序論

1.1 研究の背景と目的

国内における携帯電話の人口普及率は、電気通信事業者協会が毎月公開している契約者数の推移 [1] などから、2012 年 11 月現在ほぼ 100 % に達している。普及率からみると、携帯電話はほとんどの人にとって日常生活に欠かせない機器になったと言える。また、SNS や twitter などのソーシャルメディアの進展により、ネットワークを介した社会的なインタラクションが急速な勢いで広まっている。例えば、2011 年 3 月に発生した震災時においても、twitter をプラットフォームとする情報発信が被災者に対して有用な情報を提供していることが報告されている。このソーシャルメディアの担い手として PC のみならず携帯端末（携帯電話など）がインターネット関連のアプリケーションの充実に伴って、役割を増してきている。

一方、ライフログに関する研究が盛んに行われている。ライフログとは生活行動（移動、買い物、食事など）の記録のことである。ライフログを収集し分析することで、人物の趣味や嗜好や移動パターンを導き出せることが期待されている。ライフログを収集する手段として携帯端末を用いることによって、その普及率と相まって、多くの人の端末ユーザ属性、サービス履歴、内蔵される各種センサによって得られる位置情報履歴など、ライフログを容易かつ正確に収集できるようになった。

このような状況を踏まえ、本研究では、携帯端末から取得したセンサ情報（位置、加速度、地磁気、角速度など）から人の移動に関わる情報（移動経路、移動手段、路面状態等）や、歩き方等の違いから個人を識別する本人確認情報を把握し、複合的に分析することで新しいサービスの提供を目指している。

携帯端末には、スケジュールや電話帳などの様々な個人情報や、電子商取引などで用いる暗号鍵などが記録されており、端末の紛失によりそれらの情報が他人に悪用される危険性がある。これらの情報を保護するために、一般的にはパスワードや物理的なキーが用いられているが、情報を参照するたびに、煩雑な動作を行う必要があるため、パスワードや物理的なキーを設定しない要因にもなっている。そのため、ユーザの所有や記憶に依存しない、身体的な特徴や特性を用いたバイOMETリック個人認証が注目されている。バイOMETリック個人認証は、身体的特徴を用いる認証と、行動的特徴を用いる認証に分類できる。

- 身体的特徴を用いる認証

指紋，顔，虹彩などの個人に特有な身体的特徴を用いる認証．他人に不正利用される危険性が低く，認証精度が高い．しかし，ユーザ自身の身体の特徴そのもを利用するため，ユーザの心理的抵抗が強い．

- 行動的特徴を用いる認証

音声，筆跡，歩行動作，キーストロークなどの行動的特徴を用いる認証．物理的コピーによる悪用の心配が少なく，ユーザへの心理的抵抗は弱い．しかし，ユーザの行動を特徴としているために，認証精度がやや低い．

行動的特徴を用いた個人認証では，身体的特徴を用いた個人認証のように，時間軸上の一点において本人確認を行わないのとは異なり，日常的な動作と同時に本人確認が行えるため，認証時だけでなく認証後も連続的に本人確認を行うことができる．また，ユーザへの心理的抵抗が弱いことが利点として挙げられる．本論文では，携帯端末向けの個人認証手法として，行動的特徴である人物の歩行動作における加速度データに着目し，携帯端末に搭載されている加速度センサを用いた歩行認証を提案する．

1.2 本論文の構成と概要

[第 1 章] 序論

研究を行うにあたっての背景，目的と，本論文の構成を述べる．

[第 2 章] 歩行認証

携帯端末の加速度センサから取得されるデータや，関連研究について述べる．

[第 3 章] 提案手法

LPC ケプストラムを用いた歩行認証手法を提案するとともに，複数フレームによる認証について述べる．

[第 4 章] 評価実験

提案手法の有効性を定量的，定性的に評価した結果と考察を述べる．

[第 5 章] 結論

本論文のまとめと今後の検討について述べる．

第 2 章

歩行認証

2.1 歩行時の加速度データ

携帯端末はユーザが日常的に所持するものであり，常に携帯端末に搭載されているセンサでユーザの行動によるセンサ情報が取得されている．近年，監視システムやアクセスコントロールのための個人認証システムとして歩容認証が検討されている [2][3][4][5]．カメラから得られる動画像を処理することで，個人の認証が可能であることが示されており，歩き方は個人によって異なることが確認されている．また，加速度センサを搭載した端末を振るという簡単な動作特徴のみを用いて認証を行う手法が検討されており，個人の動作における加速度データを用いて個人を認証することが可能であることが確認されている [6][7]．そこで本研究では，歩行認証のために携帯端末に搭載されている加速度センサを使用する．ここで使用する加速度センサとは，センサ自体の速度変化を検出するセンサである．重力加速度も検出できるので，人や物体の動きや地震などの振動を検出することもできる．また，3軸の加速度センサであれば水平状態の検出も可能である．個人の歩き方の違いが歩行中の加速度に現れると考え，所持している携帯端末の加速度センサから得られる加速度データに着目した．

携帯端末に搭載されている3軸加速度センサから取得される歩行における加速度データの一例とそのグラフを Tab.2.1 と Fig.2.1 に示す．本研究では，端末を腰に固定しているため，x, y, z の3軸がそれぞれどの方向を指しているのかわかるが，センサの向きにより3軸それぞれの成分が変化してしまう問題がある．そこで，式 (2.1) を用いて3軸を合成した値 r を求め，センサが受けた加速度の大きさを用いて認証を行う．Fig.2.1 に示した3軸の加速度データに対して式 (2.1) を用いて合成した3軸合成加速度データを Fig.2.2 に示す．

また，歩行時の加速度データの一例として，3名の被験者の平地，階段昇降における加速度データを Fig.2.3 に示す．左から順番に被験者 A・B・C，上から順番に平地歩行・階段昇り・階段降りである．Fig.2.3 から，歩行時の加速度データは被験者によっても違いが表れ，また歩行している場所（歩行状態）によっても違いが表れることがわかる．

$$r = \sqrt{x^2 + y^2 + z^2} \quad (2.1)$$

Table 2.1 Acceleration of Three-Axis

Time	X Acceleration	Y Acceleration	Z Acceleration
11493.45	0.036224	-0.44528	-0.41658
11493.46	-0.09056	-0.57959	-0.32602
11493.47	-0.18112	-0.72449	-0.21735
11493.48	-0.16301	-0.79694	-0.12679
11493.49	-0.09056	-0.8875	-0.09056
11493.5	0.072449	-0.94183	-0.09056
11493.51	0.108673	-0.95995	-0.65204
11493.52	0.126785	-1.01428	-0.83316

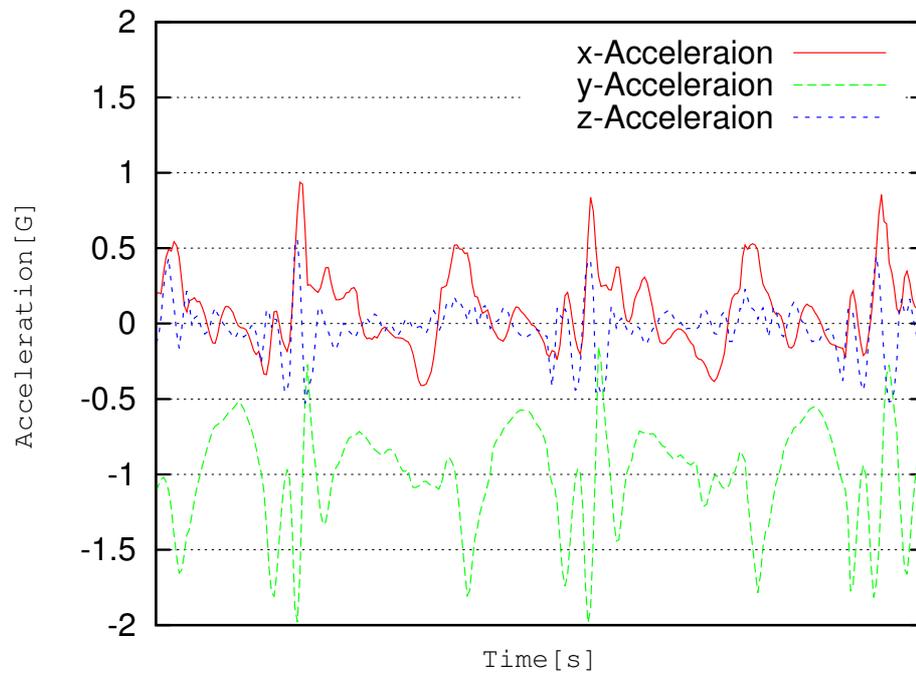


Figure 2.1 Acceleration of Three-Axis

2.1 歩行時の加速度データ

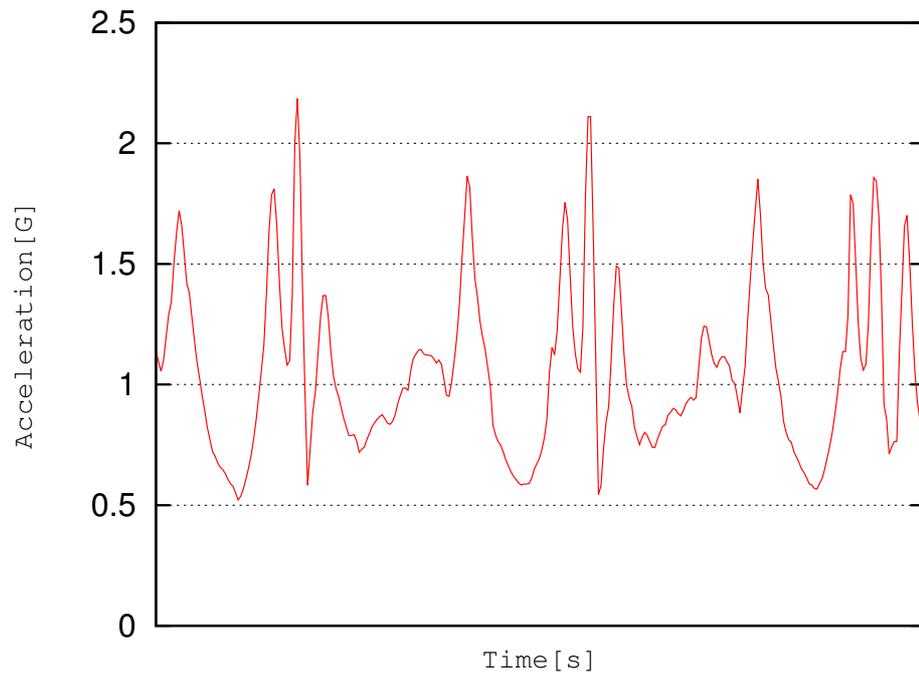


Figure 2.2 Composition Acceleration of Three-Axis

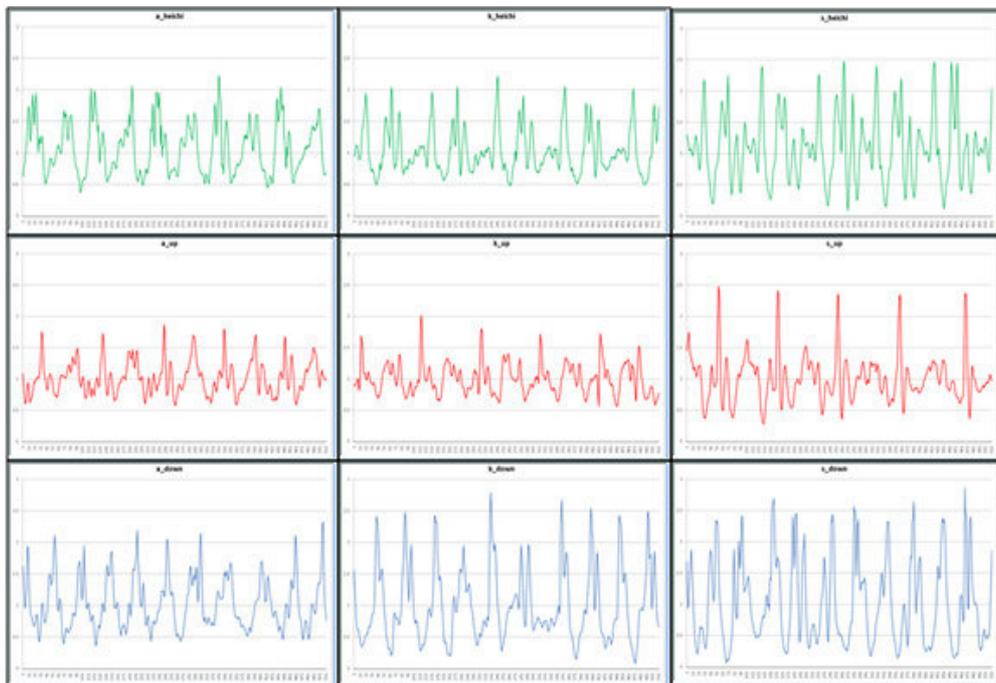


Figure 2.3 Difference of Person and Walking States

2.2 従来研究

2.2.1 歩行認証に関する研究

歩行動作における加速度データを用いて個人認証や個人識別を行っている研究では、平均値や標準偏差、歩調を特徴量として用いる研究がなされている [8][10][11]. Jennifer ら [10] の個人識別の研究においては各軸の平均値や標準偏差、平均絶対値や歩調などを用いて約 90% の個人識別率が得られている. Davrondzhon ら [11] の個人認証の研究においては、Fig.2.4 のような認証システムを設計し、足首に装着した加速度センサを用いて約 20 名の被験者の加速度データを取得し、特徴量としてヒストグラム類似度を用いた結果、EER が約 5% となる認証性能が得られている. しかし、これらの特徴量については、認証精度・識別率のみを評価しているが、個人認証に対しての特徴量の有効性については確認していない. そのため、当該特徴量が個人性を適切に抽出できているか確認する必要がある. 特徴空間において本人データ同士は近く、他人データ同士は離れるような特徴量が有効であるので、まず特徴空間上での分布を確認する必要があると考えた.

また、白井ら [8] の研究においては、Fig.2.5 に示すように、個人を識別する特徴量として、LPC ケプストラムが有効である可能性が示されており、伊藤ら [9] の研究において、歩行状態の識別に LPC ケプストラムが有効であることを示している. ケプストラム分析により、スペクトルの微細構造とスペクトル包絡を分離して抽出できる. スペクトルの微細構造は、歩行データの時間波形における周期情報を表す. 微細構造は、細かく変動する要素で、歩行データの取得時期や取得環境などの要因の違いによる影響を受けやすい. 一方で、スペクトル包絡は歩行データの時間波形における振幅情報を表すため、個人毎の特徴が歩行データの振幅情報に現れる場合、スペクトル包絡を用いることが有効であると考えられる. スペクトル包絡は、周波数軸上に緩やかに変化する要素でもある. このため、スペクトル包絡は、歩行データの取得時期や取得環境の影響を受けづらいと考えられる. 以上から、スペクトル包絡を抽出できるケプストラム分析による特徴量が歩行認証に有効であると考えた.

そこで本研究では、従来の特徴量と比較することにより、筆者らが提案している LPC ケプストラムを歩行認証に用いる有効性を評価した結果を報告する.

2.2 従来研究

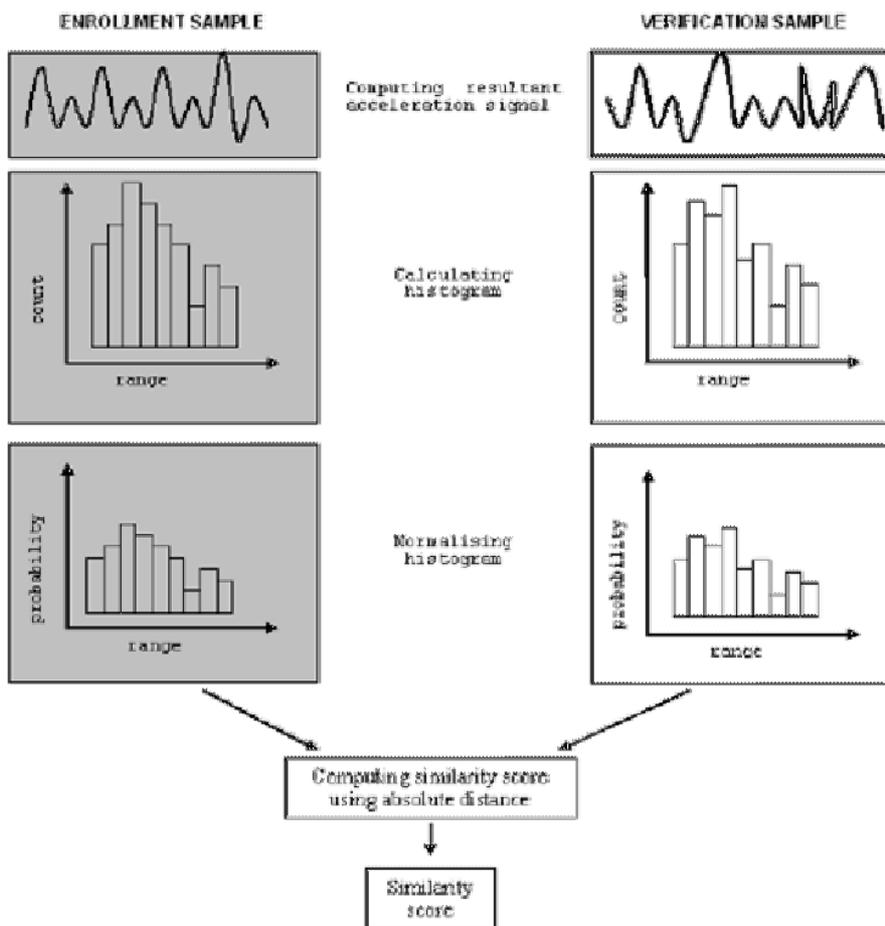


Figure 2.4 The Process of Applying Histogram Similarity Method

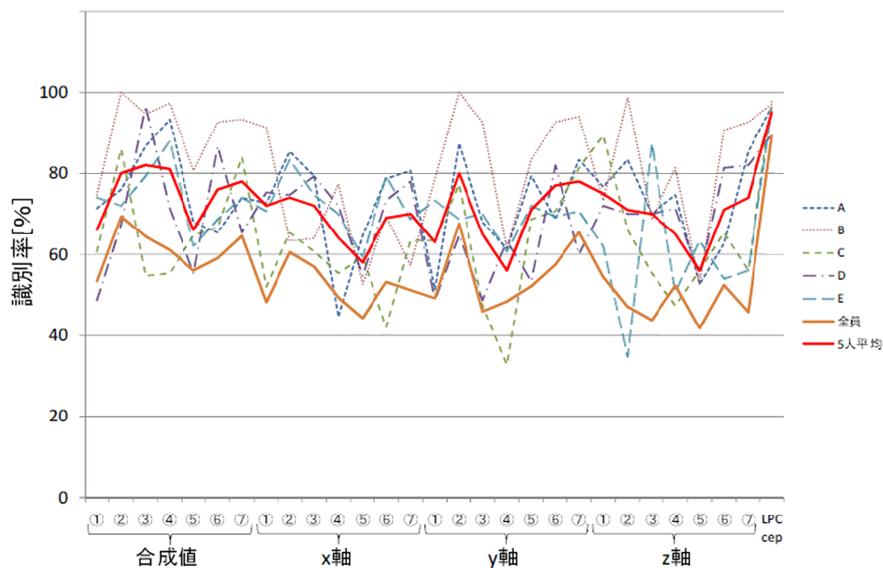


Figure 2.5 The Result of Walking States Classification

2.2.2 歩行動作に関する研究

加速度計を用いた歩行評価を東京慈恵医大の高田らが行った研究 [16] がある。歩行評価とはリハビリテーションの臨床場面において、ビデオやセンサ等により、歩行の訓練効果や、回復過程などを評価することを指す。この研究では、小型三次元加速度計により測定された加速度データの再現性を検討し、床反力計と小型三次元加速度計の波形を比較することで、小型三次元加速度計の歩行評価における臨床的有効性を検討する。なお、小型三次元加速度計は腰背部に固定し、床反力計の上を自由歩行することでデータを測定する。

同一被験者が同じ条件下で測定した 2 回の自由歩行における加速度の再現性を級内相関関係係数で統計学的に検討した。結果は信頼区間 95 % で上下方向が $\alpha=0.62\sim 0.98$ 、前後方向が $\alpha=0.46\sim 0.99$ と一貫性が高かった。しかし、左右方向は $\alpha=0.16\sim 0.93$ であり、かなりのばらつきが生じる。この研究では左右方向に再現性がないとされている。歩行において左右方向の加速度に再現性がないことから、左右方向の加速度は歩行状態の識別に有効でない可能性が考えられる。

床反力波形と加速度波形を比較検討することで加速度波形の時間因子（歩行時間、立脚時間）を測定している。加速度波形と床反力計による波形を Fig.2.6 に示す。Fig.2.6 において波形は上から左右方向加速度、上下方向加速度、前後方向加速度、床反力を示している。図中で、HC (heel contact) とは踵接地、TO (toe off) は爪先離地を表している。この HC、TO を用いて歩行周期、立脚時間を求めている。左右どちらかの足の HC から次の足の HC までを歩行周期と呼び、HC からその足の TO までを立脚時間と呼ぶ。その結果、歩行周期、立脚時間は被験者間で差はあるものの、同一被験者においてはほぼ一定の値を示している。なお、加速度波形から求められる歩行周期と、床反力波形から求められる歩行周期は統計学的に高い一貫性があることを示している。

2.2 従来研究

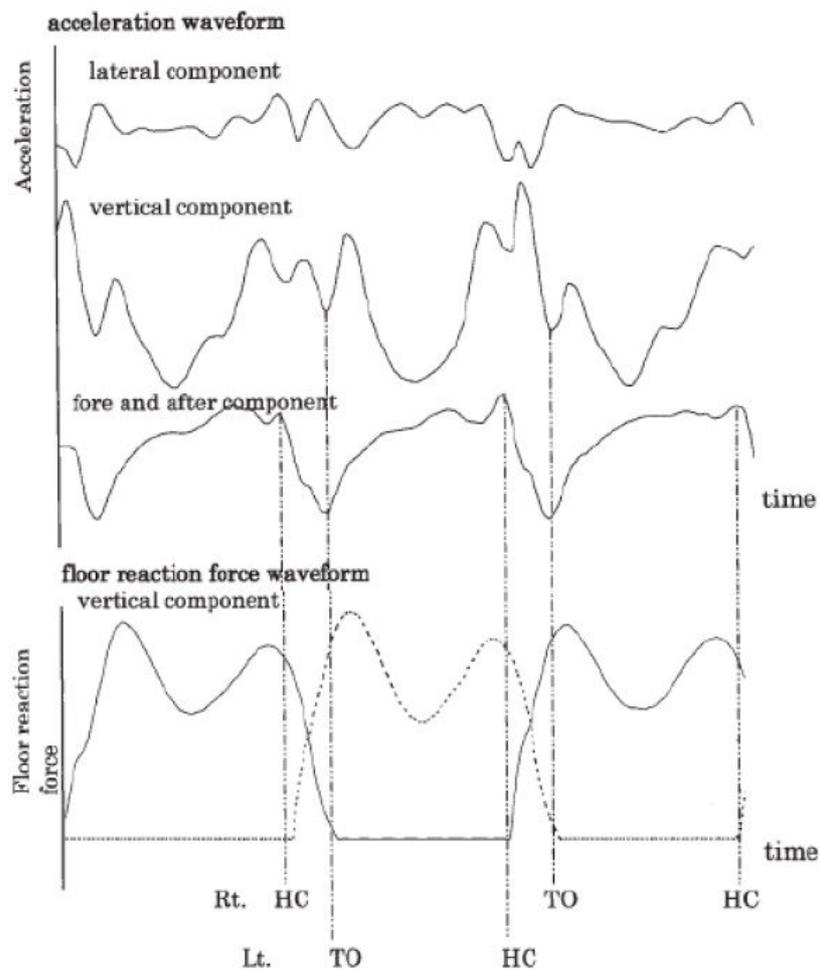


Figure 2.6 床反力波形と加速度波形 [16]

また、第一福祉大学の研究 [17] では、通常時の歩行動作におけるパラメータの再現性と、歩行能力の性差について評価している。分析対象としたパラメータは

- 歩幅（踵接地位置から反対脚の踵接地位置までの距離）
- 歩隔（左右の踵部の開き幅）
- 足角（進行方向と脚軸のなす角度）
- 歩調（一側脚の踵接地から反対脚の踵接地までの所要時間）
- 歩行速度
- 歩行率（1 分間の歩数）

である。なお、実験は GAITRite（マット型歩行解析装置）を用いて、上記のパラメータを取得している。被験対象者は男性 18 名、女性 24 名の計 42 名であり、データ取得の日程は、最初にデー

タを取得し、1日において、2回目のデータを取得している。

結果、歩行時における測定値の再現性は、歩幅、ステップ時間、歩行速度、歩行率の4項目については級内相関関係数 $\alpha = 0.9$ 以上の高い値を示した。また、歩行時における測定値の性差については、歩調、歩行率に差が見られた。女性の方が、歩調が短く、歩行率が多かった。

上記で述べた既存研究の他にも様々な特徴量が提案されているが、歩行認証において適切な特徴量という決定的なものはないのが現状である。また、経年変化や天候による地形変化など環境要因を考慮した検討は十分になされていない。そこで、本研究では、音声処理の分析手法であるLPCケプストラムを特徴量として適用し、歩行認証における有効性を示す。

第 3 章

提案手法

本章では、LPC ケプストラムを用いた歩行認証手法を提案するとともに、LPC ケプストラムについて述べる。

3.1 歩行認証システム

本研究では、パターン認識技術を用いて Fig.3.1 のような歩行認証システムを設計し、個人認証の認証能力を評価した。

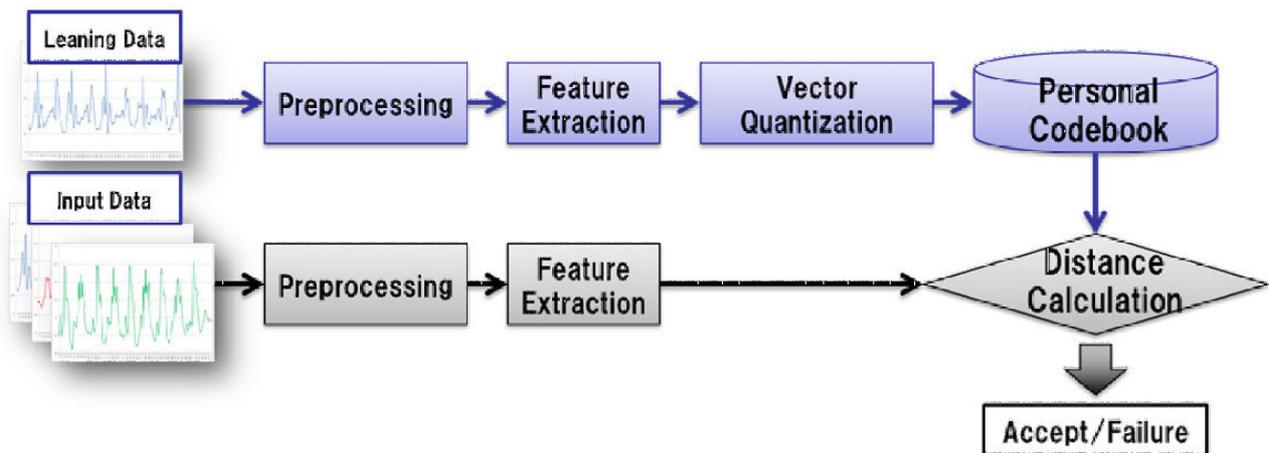


Figure 3.1 Authentication System

前処理 (Preprocessing) 部では、端末から取得される加速度情報を特徴量を抽出しやすい形に変換する。特徴抽出 (Feature Extraction) 部では、前処理部で変換したデータの特徴量の算出を行う。学習時には、事前にいくつかの歩行データから特徴量を抽出し、LBG+Splitting アルゴリズムを用いたベクトル量子化 (Vector Quantization) を用いて個人毎のコードブック (Personal Codebook) を作成する。認証時には、入力された歩行データから特徴量を抽出し、距離計算 (Distance Calculation) 部において、各コードブックとの距離を求め、本人・他人の判定基準となる閾値と比較を行うことで認証する。そこで本研究では、Fig.3.1 のような歩行認証システムを実装し、その認証結果を用いて認証性能を評価した。

3.1.1 前処理 (Preprocessing) 部

前処理部では、携帯端末から取得される加速度情報を特徴抽出しやすい形に変換する。本研究では、3軸加速度の合成、定常状態の抽出、線形補間、丸め処理をそれぞれ行う。

- 3軸加速度の合成

携帯端末の加速度センサからは x , y , z の3軸の加速度データが取得される。ここで、加速度センサを腰などに固定し、あらかじめセンサがどの向きにあったかわかる場合は x , y , z の3軸がそれぞれどの方向を指しているのか分かるが、もしセンサがどの向きにあったか分からない場合は、軸が持つ向きの情報が失われてしまう。そこで、Fig.3.2のように x , y , z の3軸を合成した値 r を見ることで、センサが受けた加速度の大きさだけが情報として残り、センサの向きに影響されずに同じ値を得ることができる。

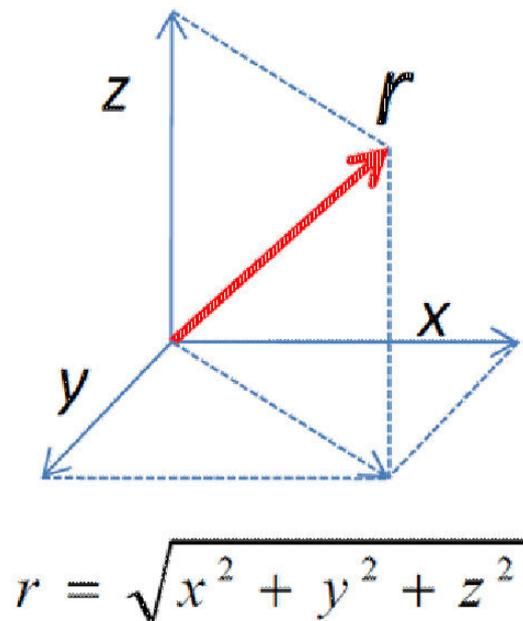


Figure 3.2 The Method of Composition Acceleration of Three-Axis

3.1 歩行認証システム

- 定常状態の抽出

歩き始めてから数歩後のデータから歩き終わる数歩前までの周期性を持ったデータを定常状態、歩き始めと歩き終わる直前のデータを過渡状態と本研究では定義する。過渡状態の歩行データには定常状態の歩行データとは異なり、個人に依らない不安定なデータが存在する可能性があると考えられる。

本研究では、過渡状態の歩行データを除外し、歩行が安定している定常状態における歩行データのみを解析対象とする。今後はこの過渡状態にも着目し、歩行認証に有効であるか検討を行いたい。

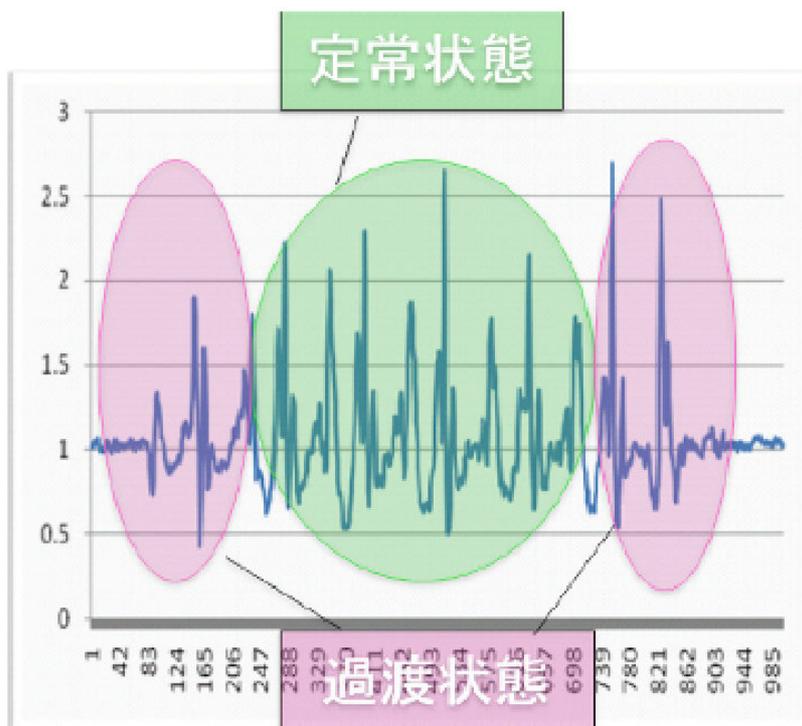


Figure 3.3 Extraction a Steady State

- 線形補間

携帯端末から取得される加速度データはデータ取得間隔を 100Hz と設定して取得しているものの、実際に端末から取得される加速度データは正確に 100Hz では取得できていない。そこで本研究では、取得された加速度データを 100Hz 間隔になるように線形補間を行う。ここで、新たに補間する点 (x, y) は、元の加速度データの2点 $((x_0, y_0)$ と (x_1, y_1)) を直線で結んだ x の1次関数として、Fig.3.4 のように補間する。なお、線形補間するには、式 (3.1) を用いる。

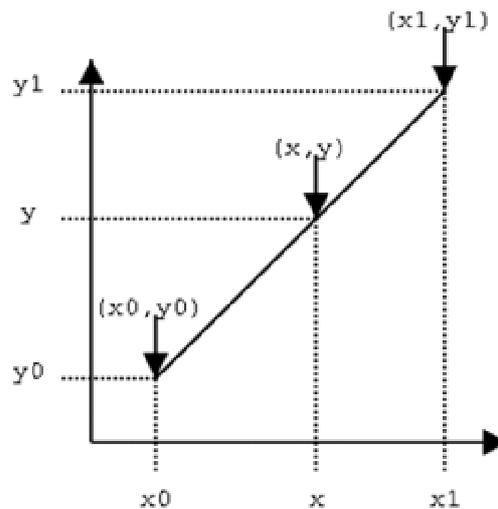


Figure 3.4 The Method of Linear Interpolation

$$y = y_0 + (x - x_0) \frac{y_1 - y_0}{x_1 - x_0} \quad (3.1)$$

- 丸め処理

携帯端末から取得される加速度データは、端末の所有者の歩行動作とは異なる微細な振動が検出されてしまっていると考えられる。そこで本研究では、0.1s 毎の加速度の平均値を取ることで丸め処理を行い、歩行動作における加速度を抽出する。携帯端末から取得される3軸の加速度を合成することで3軸合成加速度を算出し、線形補間を行い、丸め処理を行ったものを Fig.3.5 に示す。

3.1 歩行認証システム

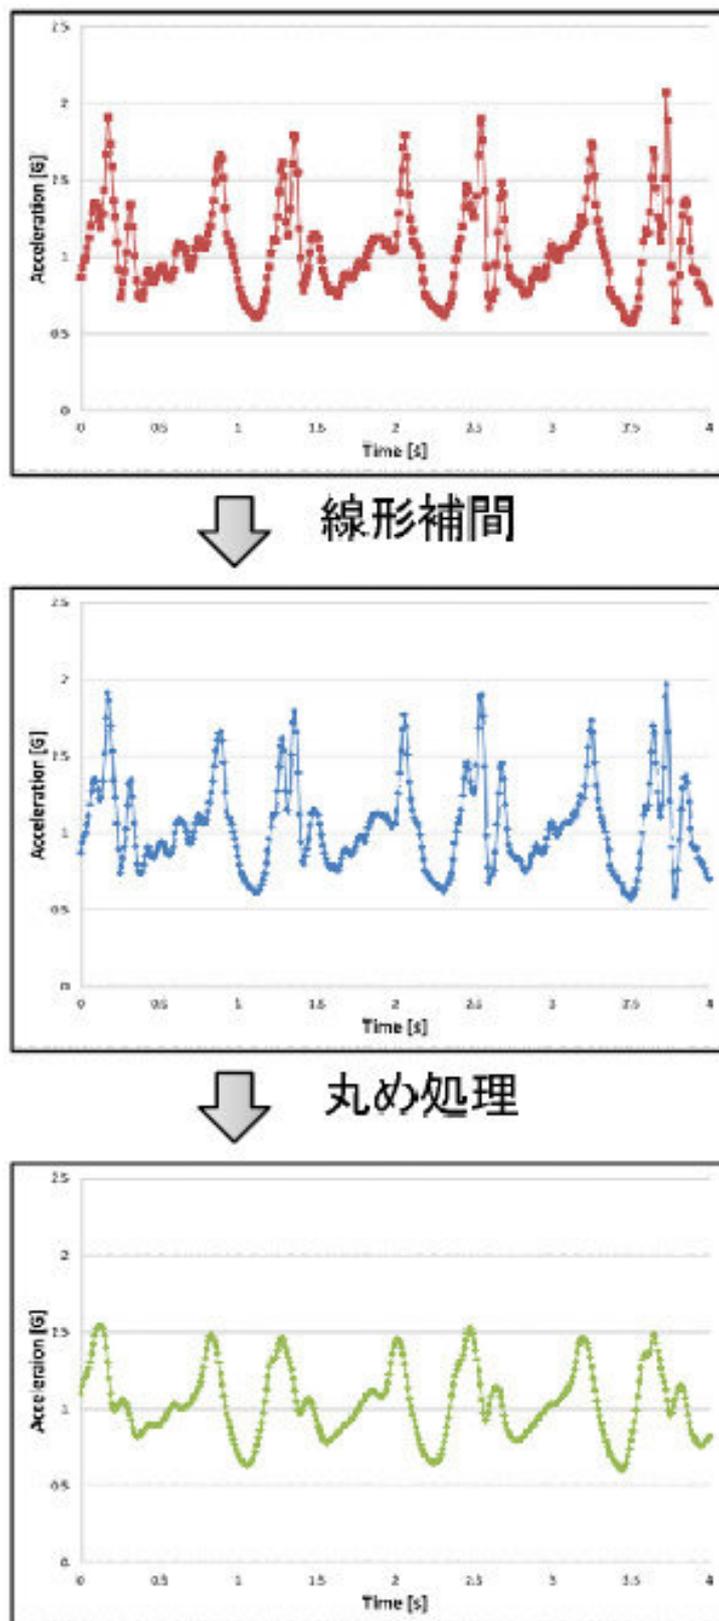


Figure 3.5 An Example of Preprocessing

- フレーム長とスライド幅

フレーム長とは、特徴量を抽出するために必要なサンプル数のことである。歩行認証を実際にサービス化することを考えると、可能な限りリアルタイムな認証が必要となる。フレーム長が小さければ小さいほどリアルタイムな認証が可能になる。またスライド幅とは、フレーム長同士の重複部分の長さのことである。フレーム長を重複されることにより、加速度データからより多くの特徴量を抽出することができる。スライド幅を小さくすれば特徴量が多く抽出でき、スライド幅が大きければ特徴量の抽出は少なくなる。

3.1.2 特徴抽出 (Feature Extraction) 部

■従来研究に用いられる特徴量 本研究では、LPC ケプストラムを特徴量とした歩行認証手法を提案するが、その有効性を確認するために従来研究で用いられる特徴量についても歩行認証を行い、認証性能の比較を行った。比較対象の特徴量は平均、標準偏差、最大値、最小値の計4種類とした。

- 平均

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.2)$$

- 標準偏差

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x})^2} \quad (3.3)$$

- 最大値

$$\max = \max\{x_i, i = 1, 2, \dots, n\} \quad (3.4)$$

- 最小値

$$\min = \min\{x_i, i = 1, 2, \dots, n\} \quad (3.5)$$

■LPC ケプストラム 本研究では、個人認証における特徴量として、音声処理でよく用いられるLPC ケプストラムを用いる。LPC ケプストラムについては3.2章で詳しく解説する。

3.1 歩行認証システム

3.1.3 ベクトル量子化 (Vector Quantization) [18]

ベクトル量子化とは、K 個の信号をまとめてひとつの K 次元ベクトル、すなわち K 次元信号空間内の一点とし、あらかじめ定められたいくつかの代表パターン (コードブック) で近似する処理である。また本研究では、クラスタリングアルゴリズムとして、LBG+Splitting アルゴリズムを用いている。LBG アルゴリズムは、適当な初期コードブックから出発し、学習系列に分割条件と代表点条件を繰り返し適用し、良好なコードブックに収束させる設計アルゴリズムである。LBG アルゴリズムにより設計されたコードブックの良否を満足させるために、初期コードブックの生成方法として Splitting アルゴリズムを用いた。この Splitting アルゴリズムを LBG アルゴリズムと組み合わせることによって 1 レベルのコードブックから出発して順次 2, 4, 8, ... レベルのコードブックを設計することができる。

3.1.4 距離計算 (Distance Calculation) 部

距離計算部では、各コードブックとのユークリッド距離 d を式 (3.6), (3.7) を用いて算出し、最小となるユークリッド距離を求める。ユークリッド距離算出の概要図を Fig.3.6 に示す。ただし、 m は特徴量の次元数、 c は個人コードブック、 n はベクトル量子化レベル、 v は認証用データとする。

$$d = \min\{d_i, i = 1, 2, \dots, n\} \quad (3.6)$$

$$d_i = \sqrt{\frac{1}{m} \sum_{j=1}^m (c_{i-j} - v_j)^2} \quad (3.7)$$

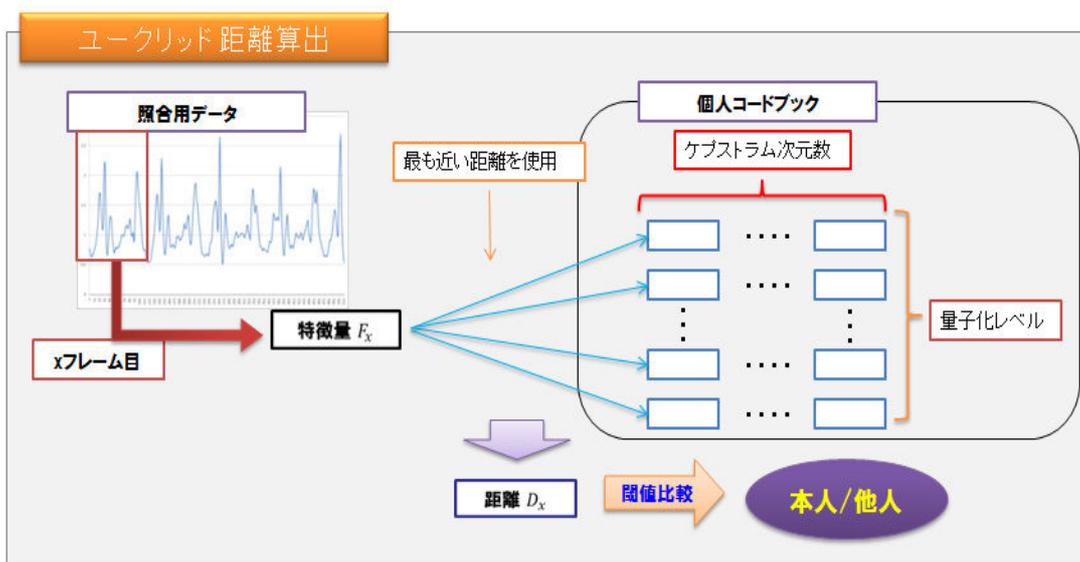


Figure 3.6 Outline of Distance Calculation

3.2 LPC ケプストラム [12]

3.2.1 ケプストラム分析

入力信号（歩行データの時間波形）を $x(t)$ とした場合，ケプストラム (cepstrum) $c(\tau)$ は，波形のスペクトル $|X(\omega)|$ の対数の逆フーリエ変換として定義され，スペクトル包絡と微細構造を近似的に分離して抽出できる特徴がある．スペクトル包絡は，時間波形における大局的な特徴を表し，微細構造は，時間波形における基本周期を表す．ケプストラム分析によるスペクトル上の微細構造とスペクトル包絡の抽出手順を Fig.3.7 に示す．

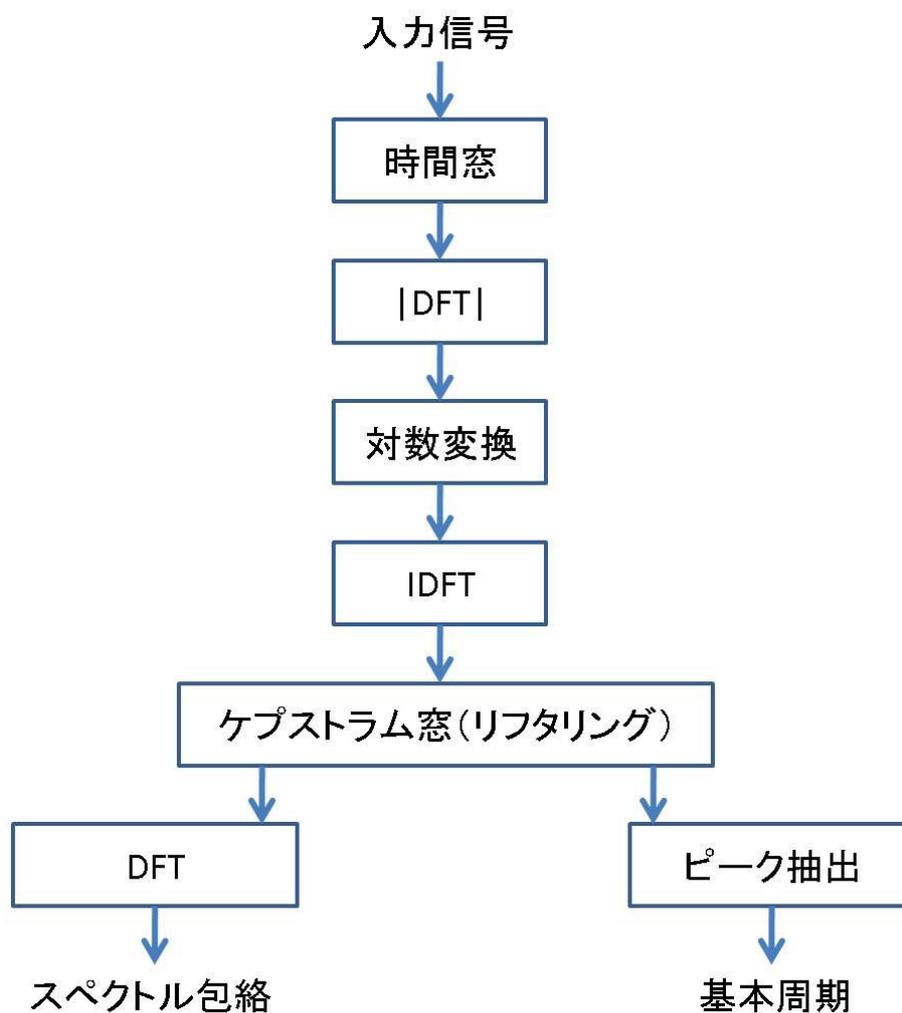


Figure 3.7 ケプストラム分析の手順

歩行データの時間波形 $x(t)$ を，2つの信号 $g(t)$ と $h(t)$ で表すことを考える．ただし， $g(t)$ は周期信号であり， $h(t)$ はインパルス応答である． $x(t)$ はこれらの2つの信号の畳み込みとして次のように与えられる．本研究では，加速度センサから取得した離散データのため，入力信号は式

3.2 LPC ケプストラム [12]

3.9 のように表される.

$$x(t) = \int_0^t g(\tau)h(t - \tau)d\tau \quad (3.8)$$

$$x[n] = \sum_{k=-\infty}^{\infty} g[k]h[n - k] \quad (3.9)$$

$$X(\omega) = G(\omega)H(\omega) \quad (3.10)$$

ただし, $X(\omega)$, $G(\omega)$ および $H(\omega)$ はそれぞれ, $x[n]$, $g[n]$, および $h[n]$ のフーリエ変換である.

$g[n]$ が周期関数の場合には, $|X(\omega)|$ はその周期の逆数の周波数ごとの線スペクトルとなる. よって, 入力信号の波形の一部を切り出してその標本値系列をフーリエ変換して求めた $|X(\omega)|$ は, 周波数軸上に等間隔の鋭いピークを持つ. その対数 $\log |X(\omega)|$ を求めると,

$$\log |X(\omega)| = \log |G(\omega)| + \log |H(\omega)| \quad (3.11)$$

となる. 次に, 式に対して周波数 ω を変数としてフーリエ逆変換する. これがケプストラムであり, フーリエ変換を F の記号で表すと

$$c(\tau) = F^{-1} \log |X(\omega)| = F^{-1} \log |G(\omega)| + F^{-1} \log |H(\omega)| \quad (3.12)$$

となる. これを次式で示すように, 逆離散フーリエ変換 (IDFT) で求める場合は, 波形の標本化の場合と同様に折り返しが生じるので, N (サンプル数) を十分大きくとる必要がある.

$$c_n = \frac{1}{N} \sum_{k=0}^{N-1} \log |X(k)| e^{j \frac{2\pi}{N} kn} \quad (3.13)$$

ケプストラムとは, スペクトルを逆変換するという意味を含めて, spectrum をもじって作った造語であり, その横軸は frequency をもじってケフレンシー (quefrequency) と呼ばれる. ケフレンシーの単位は, 周波数領域の逆変換であるため, 時間になる.

また, フーリエスペクトル $X(\omega)$ が複素数である場合, 位相情報を保持するためには, その複素対数をとる必要がある. フーリエスペクトル $X(\omega)$ の複素対数の逆フーリエ変換は, 複素ケプストラムと呼ばれている. ここで, 複素数 X の複素対数を

$$\log(X) = \log |X| + i \arg(x) \quad (3.14)$$

と定義すれば, $X(\omega)$ の複素ケプストラム c_n は

$$c_n = F^{-1} \log X(\omega) = F^{-1} \log |X(\omega)| + i \arg X(\omega) \quad (3.15)$$

と定義される. 最初のスペクトルの振幅と位相に関する情報を保持しており, 信号 $x(t)$ の再構築が可能であるのに対し, ケプストラム (実数ケプストラム) はスペクトルの振幅に関する情報しか用いない.

式 (3.11) 右辺第一項は、スペクトル上の微細構造，すなわち比較的細かい周期のパターンであり，第2項はスペクトル包絡，すなわち周波数による変化のゆるやかなパターンを表す．逆フーリエ変換した際に，高ケフレンシー部のピークから基本周期が求まり，低ケフレンシー部のみを用いてフーリエ変換することによってスペクトル包絡が求まる．なお，高ケフレンシー成分を分離する操作を，フィルター (filter) をもじってリフター (lifter) と呼ぶ．

ケプストラム分析は複数の手法があるが，ここでは LPC ケプストラム分析について紹介する．

3.2.2 LPC ケプストラム

線形予測分析 (LPC) は，離散時間系において，ある時点の値がそれ以前の値の線形結合で表現できるという仮定に基づき波形を予測するものである．時間離散的信号 x_t において，現時点の標本値 x_t ，これに隣接する過去の p 個の標本値との間の線形予測値を \hat{x}_t とすると， \hat{x}_t は次のように表される．

$$\hat{x}_t = \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + \cdots + \alpha_p x_{t-p} \quad (3.16)$$

線形予測係数 α は標本値 x_t と線形予測値 \hat{x}_t の間の誤差が最小となるように定める．この LPC で求めた線形予測係数を次式に代入する．

$$H(z) = \frac{1}{1 + \sum_{i=1}^p \alpha_i z^{-i}} = \frac{1}{A(z)} \quad (3.17)$$

LPC ケプストラム分析では式を信号のスペクトル密度とみなし，

$$X(\omega) = H(z)|_{z=e^{j\omega t}} \quad (3.18)$$

とおいたときのケプストラムを算出する．このため，Fig.3.7 の DFT，対数変換，IDFT をそれぞれ，両側 z 変換，複素対数，逆両側 z 変換でおきかえることによって，ケプストラムの概念を複素ケプストラムの概念に拡張する．まず，ケプストラム係数を c_n と表し，その z 変換を次式 (3.19) で表す．

$$C(z) = \sum_{n=1}^{\infty} c_n z^{-n} \quad (3.19)$$

$H(z)$ を対数変換する．

$$C(z) = \log H(z) = \log \frac{1}{A(z)} \quad (3.20)$$

両辺を z^{-1} で微分すると

$$\frac{dC(z)}{dz^{-1}} = \frac{\frac{d \frac{1}{A(z)}}{dz^{-1}}}{\frac{1}{A(z)}} = -\frac{\frac{dA(z)}{dz^{-1}} \cdot \frac{1}{A^2(z)}}{\frac{1}{A(z)}} = -\frac{1}{A(z)} \cdot \frac{dA(z)}{dz^{-1}} \quad (3.21)$$

両辺に $A(z)$ をかけて

$$\frac{dC(z)}{dz^{-1}} \cdot A(z) = -\frac{dA(z)}{dz^{-1}} \quad (3.22)$$

3.2 LPC ケプストラム [12]

逆両側 z 変換で置き換えると

$$\left(\sum_{n=1}^{\infty} nc_n z^{-n+1}\right)\left(1 + \sum_{i=1}^p \alpha_i z^{-i}\right) = -\left(\sum_{m=1}^p m\alpha_m z^{-m+1}\right) \quad (3.23)$$

$$\sum_{n=1}^{\infty} nc_n z^{-n+1} = -\sum_{m=1}^p m\alpha_m z^{-m+1} - \left(\sum_{m=1}^{\infty} mc_m z^{-m+1}\right)\left(\sum_{i=1}^p \alpha_i z^{-i}\right)$$

z^{-1} に関する両辺の多項式の係数が等しいことから

$$nc_n = -n\alpha_n - \sum_{m=1}^{n-1} mc_m \alpha_{n-m}$$

よって,

$$c_n = -\alpha_n - \sum_{m=1}^{n-1} \binom{m}{n} c_m \alpha_{n-m}$$

場合分けを行うと

$$\left. \begin{aligned} c_1 &= -\alpha_1 \\ c_n &= -\alpha_n - \sum_{m=1}^{n-1} \binom{m}{n} c_m \alpha_{n-m} \quad (1 < n \leq p) \\ c_n &= -\sum_{m=1}^p \binom{m}{n} c_m \alpha_{n-m} \quad (p < n) \end{aligned} \right\} \quad (3.24)$$

ただし, p は, LPC 係数の数を表す.

LPC ケプストラム分析では, LPC による線形波形モデルに対してケプストラム分析を行うため, 元の波形に対するケプストラム分析よりも, スペクトルのピーク特性が抽出しやすいという利点がある. 本研究では, 歩行データの特徴量として, この LPC ケプストラム係数と用いた.

3.3 複数フレームを用いた認証

1つのフレームから得られる特徴量から算出されるユークリッド距離を用いて認証を行うと、フレーム毎の特徴量に少しばらつきがあるために、認証性能があまり高くないと考えられる。そこで本研究では、複数フレームを用いた認証として、統計量を用いた認証と、本研究で提案するk数決法を用いた認証を行う。

3.3.1 統計量を用いた認証

任意個のフレームのそれぞれの特徴量からユークリッド距離を算出し、算出された任意個のユークリッド距離の平均値、最大値、最小値を任意個のフレームの代表コードブックの距離として算出し、本人・他人の判定基準となる閾値と比較を行うことで認証する。この手法により、1フレーム毎でばらつきがある特徴量を統計量を用いることで、ばらつきをおさえることができ、認証性能が高くなると考えられる。

3.3.2 k数決法を用いた認証

また、本研究では、k数決法を用いて歩行認証を行う手法を提案する。k数決法とは、任意個のフレームのそれぞれの特徴量からユークリッド距離を算出し、算出された任意個のユークリッド距離をそれぞれ本人・他人の判定基準となる閾値と比較し、任意個の中でk個以上のフレームにおいて閾値を満たした場合に、その任意個のフレームは本人と判定する手法である。この手法により、本人の入力データにも関わらずユークリッド距離が大きくなってしまいうような外れ値の影響を除外して認証に用いることができ、認証精度が高くなると考えられる。

3.4 歩行認証の要因

歩行認証における加速度データに影響をおよぼす要因を以下に示す。

■**移動状態の影響** 人物が電車やバス、飛行機などの乗り物に乗っている状態では、乗り物自体の振動により歩行動作に影響を与えると考えられる。本研究では、屋外で歩行しているという条件下で検討を行う。

■**歩行状態の影響** 人物が平地や階段の昇降、坂の昇降をすることで歩行動作に影響を与えると考えられる。階段や坂を昇る歩行動作では身体の揺れが小さいため、小さい加速度が得られる反面、階段や坂を降りる歩行動作では通常の歩行と比べて身体の揺れが大きいため、大きな加速度が得られる。また、階段や路面は起伏に富んでおり、一定ではない。例えば、階段は建築基準法により定義されているが、細かく決められていない。そのため、段差の高さ、踊り場、路面の幅が異なる階段が存在する。路面状態も地質やコンクリート整備の有無、天候状況により変化する。

■**保持状態による変化の影響** 携帯端末を保持する場所（ポケットやカバンなど）より取得データが変化する可能性がある。

■**個人内変化の影響** 経年変化や疲労状態、精神状態の変化が歩行動作に影響を与えると考えられる。経年変化とは、時間の経過による変化のことである。歩行動作は肉体の成長とともに変化する可能性がある。例えば、身長伸びや筋肉量の増大により、歩調が大きくなり歩き方が変化する事が挙げられる。また、宮崎大学の福井らの研究 [20] から感情（中立、悲しみ、喜び、怒り）の変化により歩き方が変化する事が報告されている。よって、日々の精神状態や疲労状態により歩き方が変わる可能性がある。

以上の要因の影響に強い特徴量が歩行認証に有効であると考えられる。ケプストラム分析は、スペクトルの微細構造とスペクトル包絡を分離して安定した特徴抽出ができる。スペクトルの微細構造は、歩行データの時間波形における周期情報を表す。微細構造は、細かく変動する要素で、歩行データの取得時期や取得環境などの違いによる影響を受けやすいと仮定した。一方、スペクトル包絡は、歩行データの時間波形における振幅情報を表すため、各個人の特徴が歩行データの振幅情報に表れる場合、スペクトル包絡を用いることが有効である。スペクトル包絡は、周波数軸上に緩やかに変化する要素でもある。このため、スペクトル包絡は、歩行データの取得時期や取得環境の影響を受けづらいと仮定した。以上から、スペクトル包絡を抽出できるケプストラム分析による特徴量が有効であると考えた。

第 4 章

評価実験

4.1 評価実験概要

本研究では、実装した歩行認証システムを用いて、通常歩行と成りすまし歩行における評価実験を行った。学習時には、任意の被験者の全歩行データの中の半分のデータに対して、各特徴量を抽出し、特徴量毎に LBG+Splitting アルゴリズムを用いたベクトル量子化を行うことで、個人のコードブックを作成する。認証用データとしては、学習に用いていない残りの半分のデータを使用する。その後、学習用データと認証用データを入れ替えて評価するクロスバリデーションを行った。

本研究では、認証性能の評価尺度として、バイオメトリクス性能評価尺度として一般的な、他人受入率 (False Match Rate, FMR)、本人拒否率 (False Non-Match Rate, FNMR) を利用した。本人拒否率が高いと利用者が認証されない可能性が高いため、フラストレーションを引き起こし、他人受入率が高いと、他人を認証してしまい、詐欺などを引き起こす。FMR と FNMR の関係を表す ROC (Receiver Operating Characteristic) 曲線を用いて、本人・他人判定の基準となる閾値を変化させた際の精度を評価した。この曲線が原点に近くなれば近くなるほど認証性能が高いことを示す。また、本人拒否率と他人受入率が等しくなったときの値を EER (Equal Error Rate) といい、認証性能評価の指標として良く用いられる。EER が小さいほど認証性能が高いことを示す。

4.2 通常歩行における歩行認証実験

通常歩行における歩行認証について評価実験を行った。通常歩行におけるデータ取得実験の実験諸元を Tab.4.1 に示す。iPhone4S に搭載されている 3 軸加速度センサを用いて、被験者 20 名について 1 人あたり 100 秒間の歩行データを取得した。端末は右腰に固定し、平らな道を歩くことでデータの取得を行う。データの取得間隔を表すサンプリング周波数は 100Hz (0.01 秒毎に計測) とした。

Table 4.1 Outline of Experiment

Date	2012.10.06
Terminal	iPhone4S
Sampling Frequency	100Hz
Mounting Position	Right side of Waist
Acquisition Time	100sec/person
Number of Subject	20 person

4.2 通常歩行における歩行認証実験

4.2.1 従来特徴量との比較

従来研究で用いられている平均値，標準偏差，最大値，最小値の4種類の特徴量とLPCケプストラムの計5種類の特徴量を1フレーム毎に算出し，評価実験を行った．評価結果のROC曲線をFig.4.1に，EERをTab.4.2に示す．また，標準偏差を用いた場合のユークリッド距離のヒストグラムをFig.4.2に，LPCケプストラムを用いた場合のユークリッド距離のヒストグラムをFig.4.3に示す．図の縦軸は各データ区間における，全体のデータ数に対する出現頻度の割合を表す．標準偏差を用いた場合には，本人-本人間距離の分布と本人-他人間距離の分布が大きく重なっている．標準偏差だけでなく，他の従来の特徴量についても同様の様子が見られた．よって従来研究に用いられる特徴量は単一の特徴量としては，歩行認証に有効でない可能性が考えられる．LPCケプストラムを用いた場合には，本人-本人間距離が小さく，本人-他人間距離が大きくなり，分布が多少重なっているが，きれいに分かれている．これらの結果から，従来研究に用いられている4種の特徴量の中では，最小値を用いた場合に認証性能が高くなるが，LPCケプストラムを用いた場合が最も認証性能が高いことがわかる．

Table 4.2 Difference of Feature Value

Authentication Method	EER
Average	37.5%
Standard Deviation	27.2%
Maximum	31.7%
Minimum	26.3%
LPC Cepstrum	24.2%

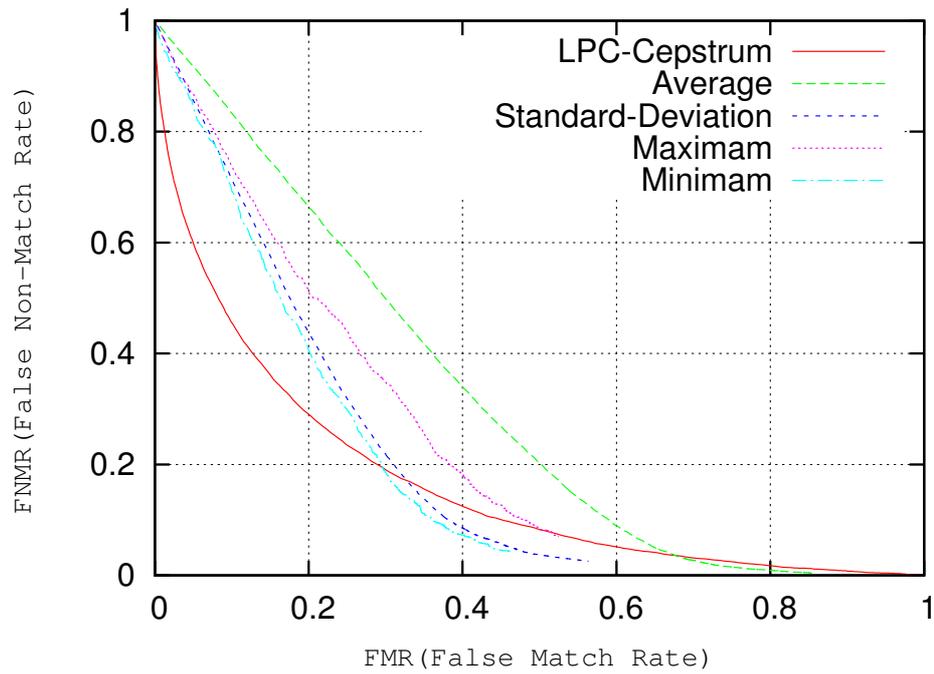


Figure 4.1 Difference of Feature

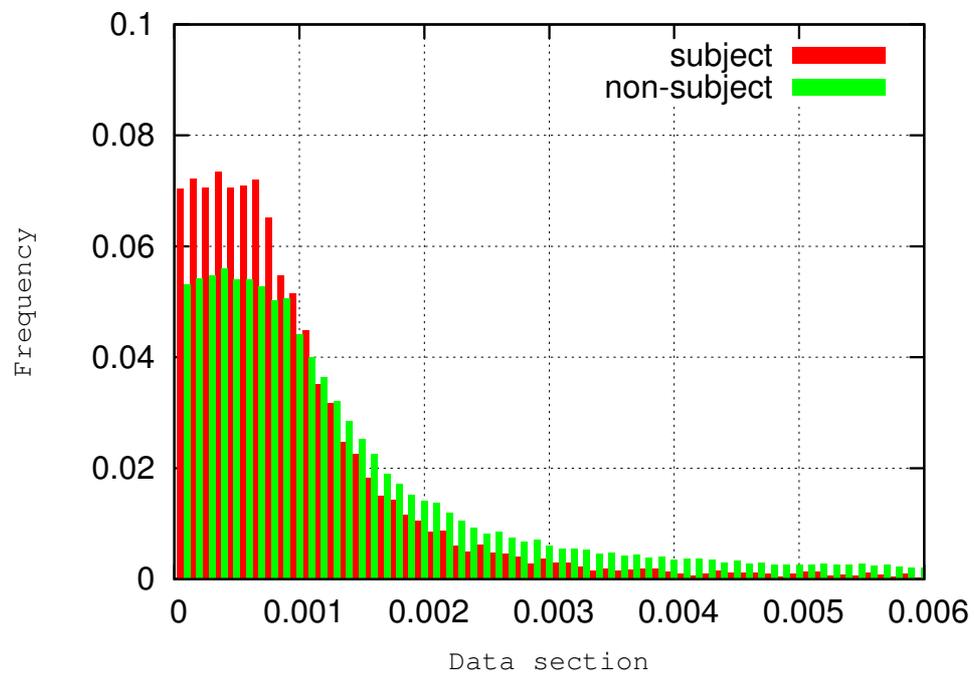


Figure 4.2 Histogram of Euclid of Standard Deviation

4.2 通常歩行における歩行認証実験

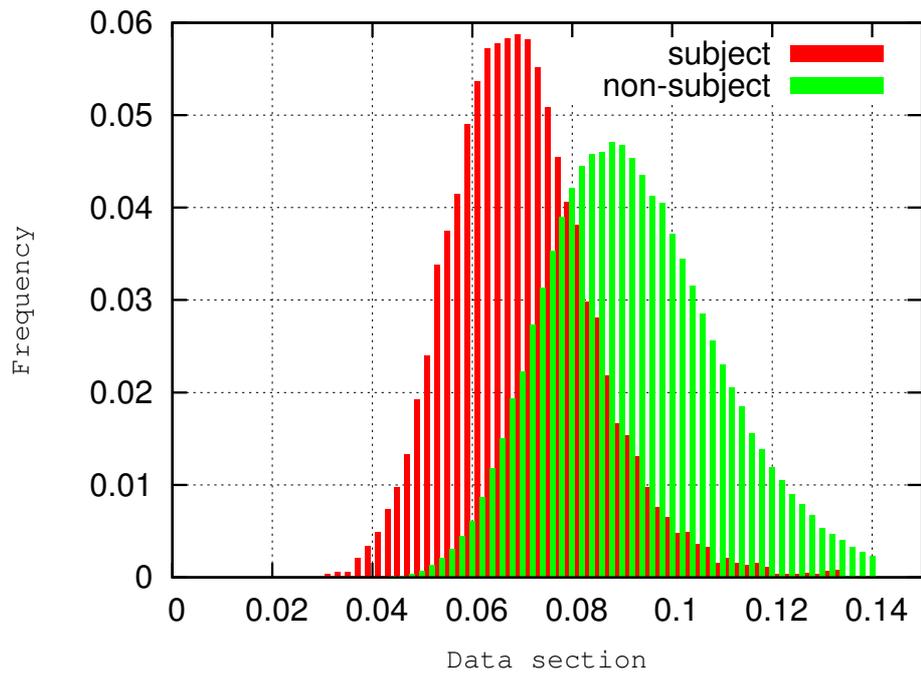


Figure 4.3 Histogram of Euclid of LPC-Cepstrum

4.2.2 パラメータ調査

LPC ケプストラムを用いて歩行認証をする上で、以下の3つのパラメータを設定する必要がある。

- フレーム長

特徴量を算出する際の、1フレームに含まれるサンプル数。例えば、フレーム長が256サンプルであれば、2.56秒毎に特徴量を算出することになる。また本研究では、フレームを16サンプルずつスライドさせて特徴量の算出を行った。

- LPC ケプストラム次元数

LPC ケプストラムを算出するの次元数。次元数が多いとより細かい特徴を得ることができるが、計算の負荷が増大する。

- ベクトル量子化レベル

学習データをいくつの段階に量子化するかを表す。量子化レベルが高い（細かい）ほど、元の学習データとの誤差が小さくなるが、計算の負荷が増大する。

そこで、フレーム長、ケプストラムの次元数、ベクトル量子化レベル3つのパラメータにおける認証性能の比較を行った。基本的には、フレーム長を256、ケプストラムの次元数を30、ベクトル量子化レベルを32として、評価対象のパラメータを変化させることでパラメータの調査を行う。評価結果のROC曲線をそれぞれ、Fig.4.4, Fig.4.5, Fig.4.6に示す。

フレーム長は大きければ大きいほど認証性能は高くなるが、大きすぎると認証時間に多くの時間を要するために余り実用的とは考えられない。ケプストラムの次元数は、5次元とした場合に性能が低くなるが、そのほかの次元数では性能に大きな変化は見られない。これは、LPC ケプストラムの低次元部分に、歩行動作の個人による違いがあることを表している。ベクトル量子化レベルは、16レベル、32レベルとした場合に最も認証性能が高くなり、64レベル以上とすると認証性能は少し低下する。以後の検討では、フレーム長を256、ケプストラム次元数を30、ベクトル量子化レベルを32として評価実験を行うこととする。

4.2 通常歩行における歩行認証実験

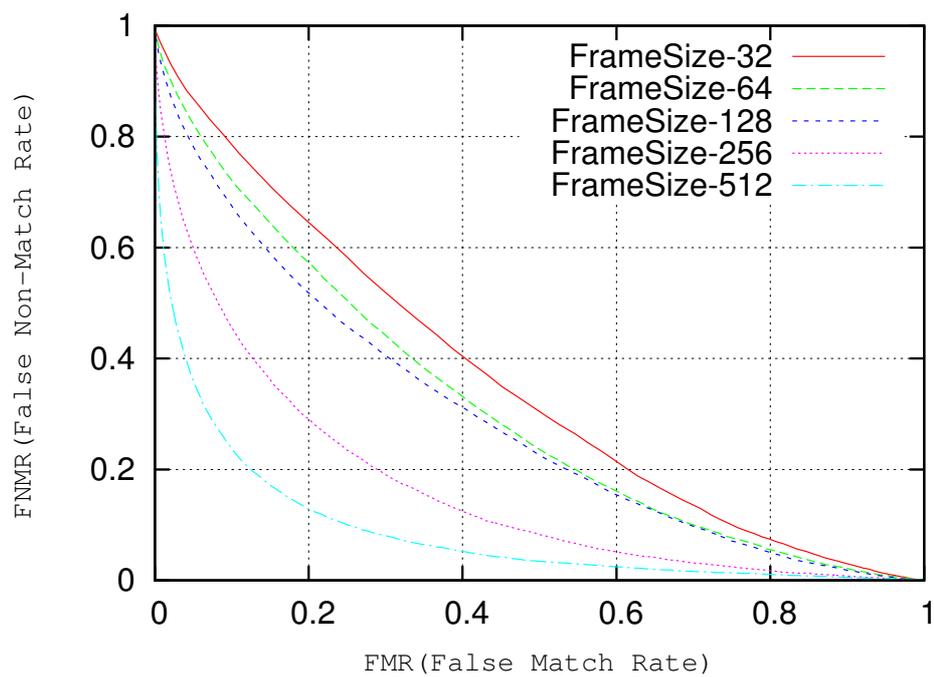


Figure 4.4 Difference of Frame-Size

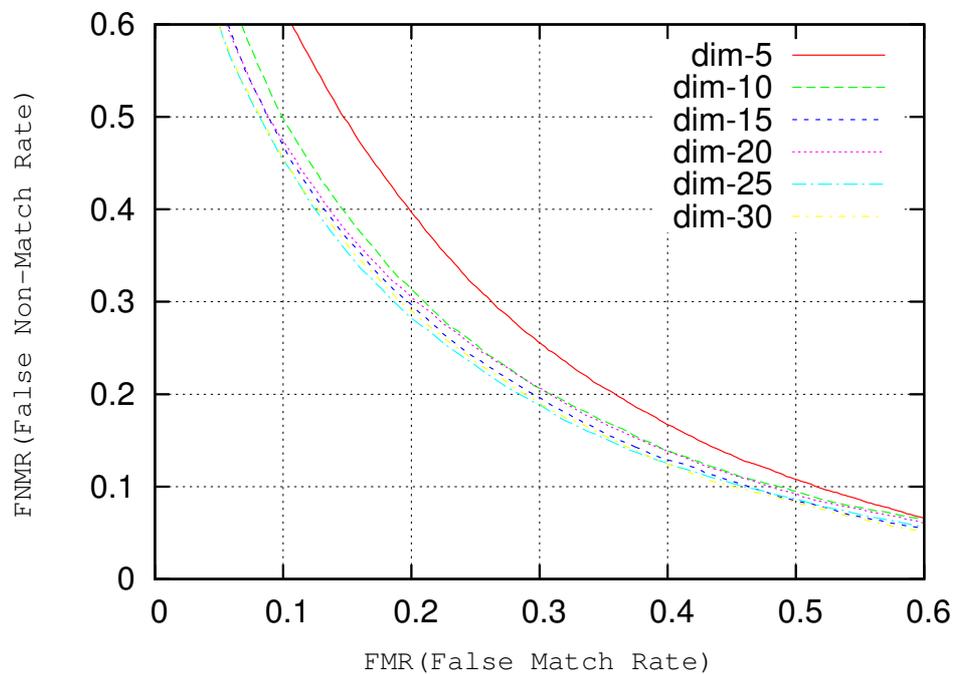


Figure 4.5 Difference of Dimension of LPC-Cepstrum

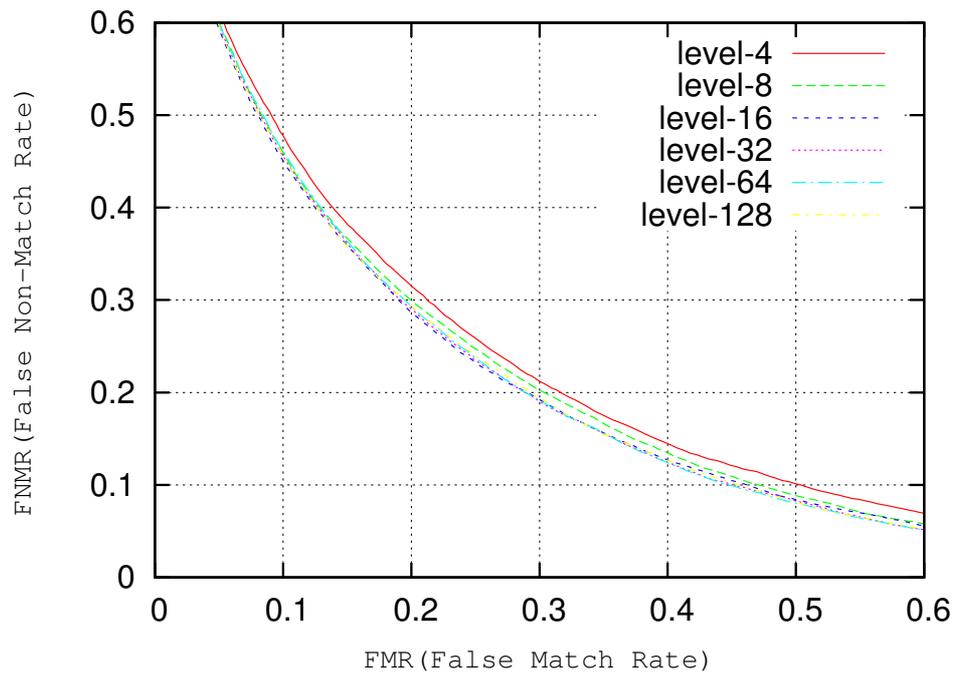


Figure 4.6 Difference of Level of Vector Quantization

4.2 通常歩行における歩行認証実験

4.2.3 複数フレームを用いた認証

ここまでの検討では、1つのフレームから得られる特徴量から算出されるユークリッド距離を用いて認証を行っている。しかし、1つのフレームのみで認証を行うと、フレーム毎の特徴量にばらつきがあるために、認証性能があまり高くない。そこで本研究では、複数フレームを用いた認証を行う。

統計量を用いた認証

評価結果のROC曲線をFig.4.9に、EERをTab.4.3に示す。16フレームの平均値を用いた場合にEERが15.5%となり、最も認証性能が高い結果になった。また、1つのフレームのみで認証を行った場合と、16フレームを用いて認証を行った場合の本人-本人間のユークリッド距離(subject)と、本人-他人間のユークリッド距離(non-subject)をそれぞれFig.4.7, Fig.4.8に示す。縦軸は各データ区間における、全体のデータ数に対する出現頻度の割合を表す。Fig.4.7の1つのフレームのみで認証した場合と比較して、Fig.4.8の16フレームを用いて認証した場合が分布の重なりが小さくなり、認証性能が高くなることが分かる。

Table 4.3 Authentication Using Multi-Frames

Authentication Method	EER
1-Frame	24.3%
16-Frame-Ave	15.5%
16-Frame-Max	20.0%
16-Frame-Min	17.5%

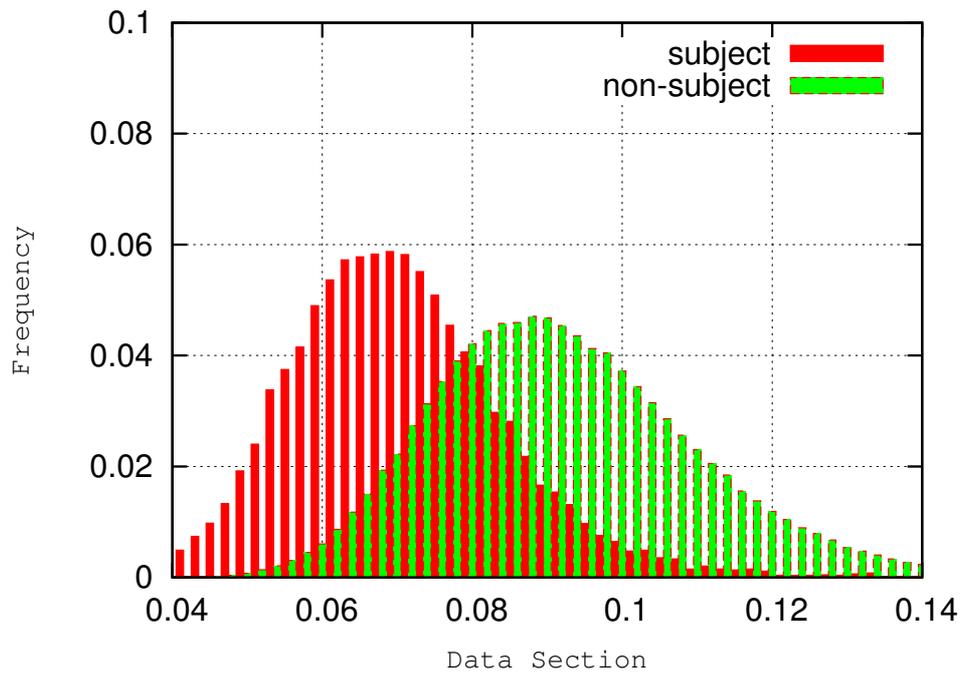


Figure 4.7 Histogram of One-Frame Authentication

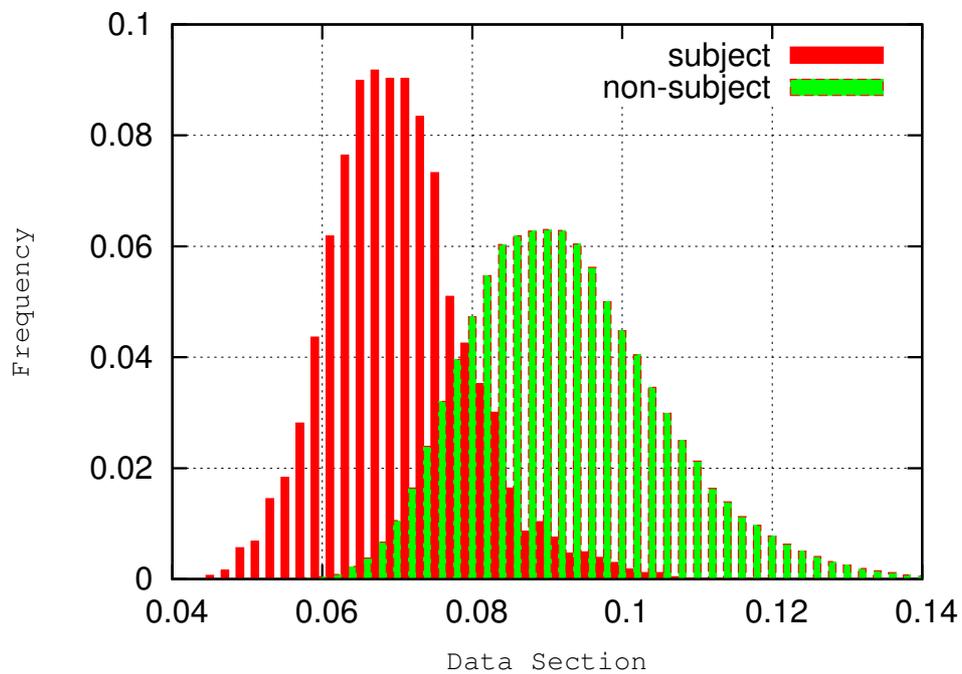


Figure 4.8 Histogram of 16-Frames Authentication

4.2 通常歩行における歩行認証実験

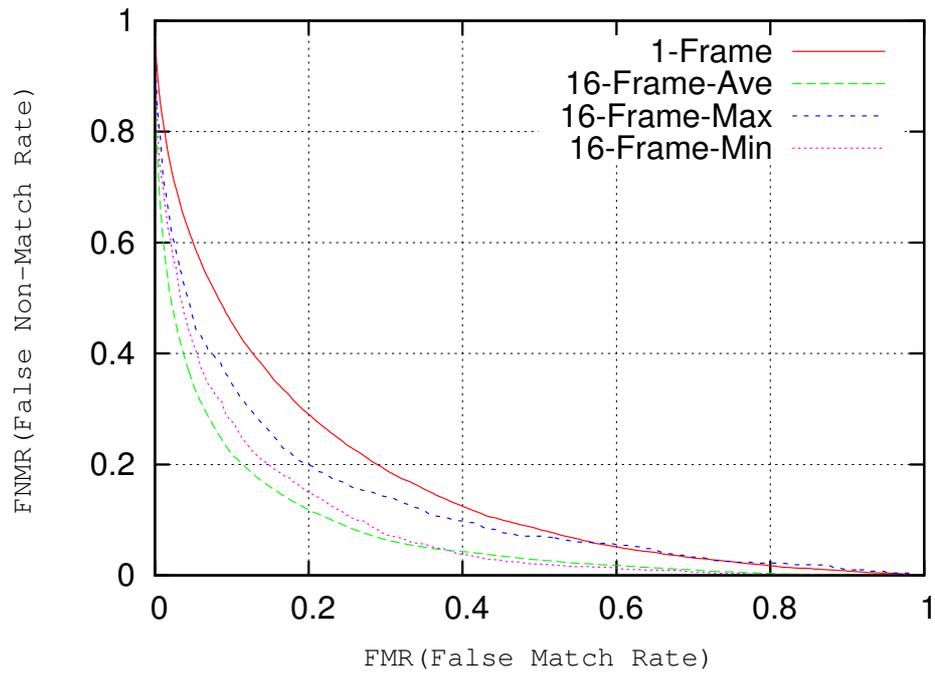


Figure 4.9 Authenticaiton Using Multi-Frames

k 数決法を用いた認証

本研究で提案する k 数決法による歩行認証を行った。本研究では、フレーム数は 16 個とし、 $k = 1, 2, 3, 5, 8$ として認証を行った。また、4.2.3 において最も認証性能が高い 16 フレームの平均値との比較を行った。評価結果の ROC 曲線を Fig.4.10 に、EER を Tab.4.4 に示す。16 フレームの平均値 (16-Frame-Ave) と比較して、k 数決法により認証を行う方が、認証性能が高くなった。また、k 数決法においては、 $k = 2$ とした場合 (2-Majority) に、EER が 12.6% となり、認証性能が最も高い結果になった。16 フレームの平均値を用いた場合では、本人-本人間のユークリッド距離が大きくなってしまいうような外れ値が多少存在し、その影響を受けるために認証性能が低くなると考えられる。よって、歩行認証においては k 数決法が有効であると考えられる。しかし、k 数決法の中で、 $k = 2$ とした場合が最も認証性能が高くなったのは、本研究において設定したパラメータや特徴量の下での結果である。今後パラメータを変更したり、他の特徴量を用いる場合には k の値は、設定した条件毎に調査する必要がある。

Table 4.4 Authentication Using k-Majority Method

Authentication Method	EER
16-Frame-Ave	15.5%
1-Majority	13.8%
2-Majority	12.6%
3-Majority	13.7%
5-Majority	13.8%
8-Majority	14.4%

4.2 通常歩行における歩行認証実験

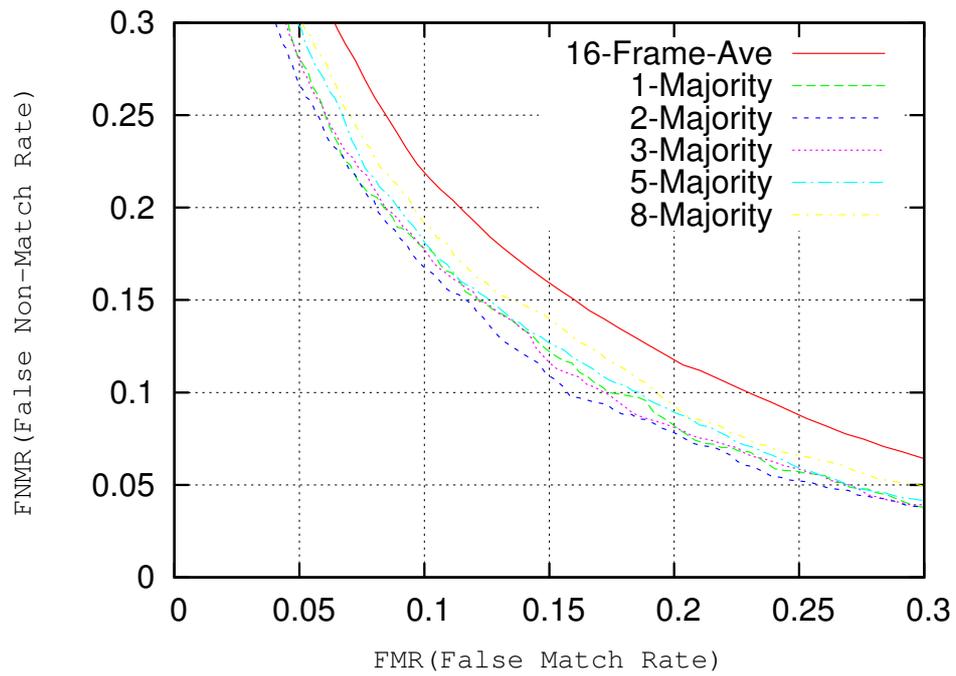


Figure 4.10 Authentication Using k-Majority Method

4.2.4 保持状態評価実験

保持状態の影響について調査を行うため、評価実験を行った。保持状態毎のデータ取得実験の実験諸元を Tab.4.5 に示す。右腰に固定、ズボンの右前ポケット、ズボンの右後ポケット、胸ポケット、画面を見るように手に持つ、の計5種類の保持状態について、各100秒間の歩行データの取得を行った。各保持状態の加速度データを Fig.4.11 に示す。右腰に固定、右前ポケット、右後ポケットの場合には、足の動きの影響を受けるため、加速度が大きくなる。しかし、胸ポケットの場合には、足の動きの影響を受けず、身体の動きのみの影響を受けるため加速度が小さくなる。また、手に持つ場合には、足の動きの影響を受けないだけでなく、身体の動きの影響も手に持つことで緩和され、5種類の保持状態の中で最も加速度が小さくなる。

Date	2012.01.05
Terminal	iPhone4S
Sampling Frequency	100Hz
Mounting Position	Right side of Waist
Acquisition Time	100sec/retainment
Number of retainment	5 retainments

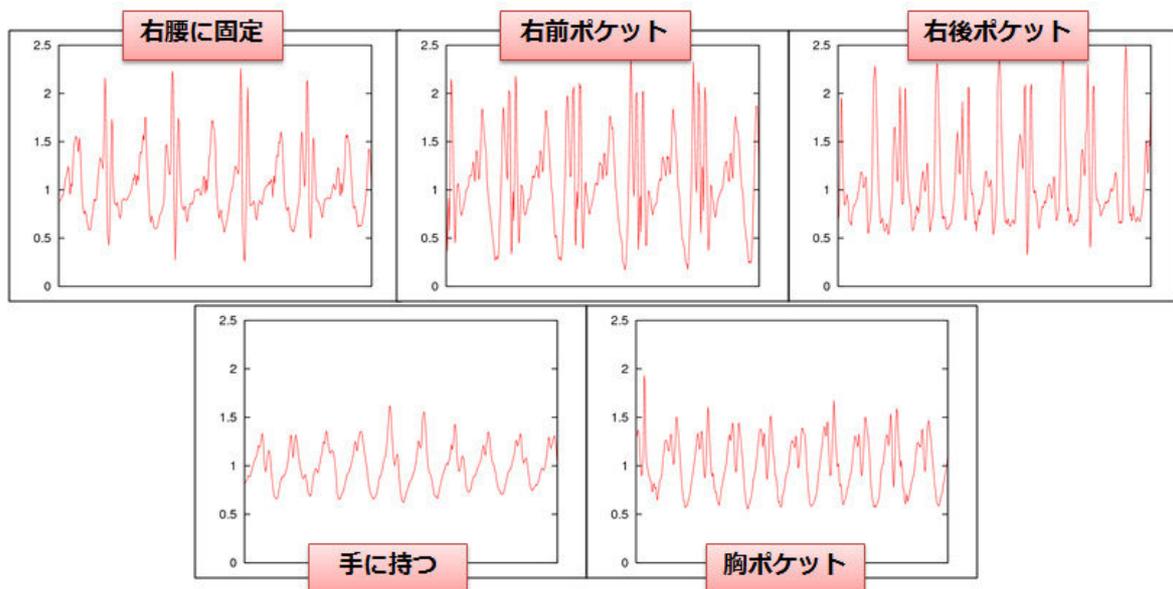


Figure 4.11 Acceleration of Retainments

4.2 通常歩行における歩行認証実験

評価結果のヒストグラムを Fig.4.12, Fig.4.13 に示す. 縦軸は各データ区間における, 全体のデータ数に対する出現頻度の割合を表す. 右腰に固定してデータ取得を行った場合を本人 (subject) のデータとする. また比較のため, 他人 (non-subject) として本人以外の歩行データを 1 名分用いた. 右腰に固定以外の保持状態 4 種類 (other retainments) を 1 つの他の保持状態のデータとした場合のヒストグラムは Fig.4.12 のようになる. ここで, 限定保持状態 (limited retainments) をズボンの右前ポケット・右後ろポケットと定義し, 本人のデータと限定保持状態, 他人のユークリッド距離のヒストグラムは Fig.4.13 のようになる. 限定保持状態のように, 足の動きの影響を受ける保持状態の場合は, 比較的本人のユークリッド距離と類似しており, 手や胸ポケットのように足の影響を受けない保持状態では, 本人のユークリッド距離と類似していないため, 他人と判定されてしまう恐れがある. 今後は, 前処理部において正規化の処理を行うなどを行うことにより, 保持状態の違いによる影響を軽減することが必要となると考えられる.

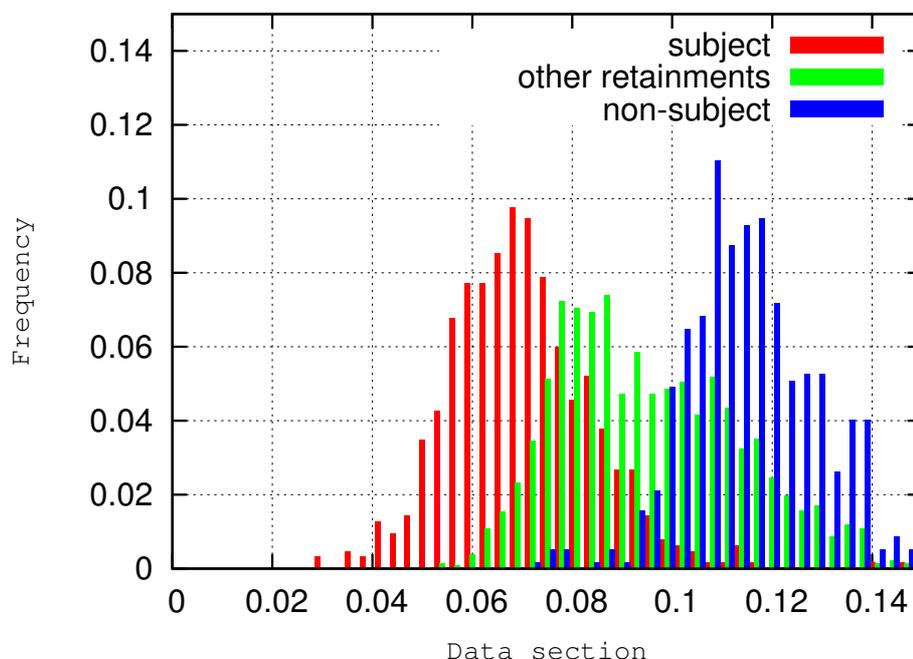


Figure 4.12 Histogram of Difference of Retainments

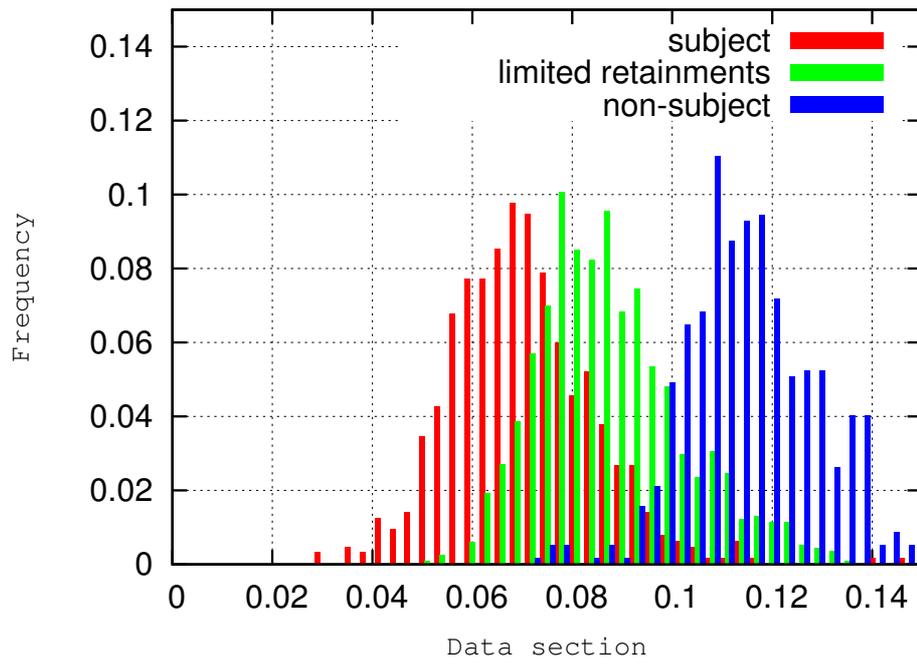


Figure 4.13 Histogram of Difference of Retainments

4.2 通常歩行における歩行認証実験

4.2.5 経年変化評価実験

経年変化の影響について調査を行うため、評価実験を行った。経年変化の影響を調査するためのデータ取得実験の実験諸元を Tab.4.6 に示す。通常歩行における評価実験と同様に、右腰に携帯端末を固定して 100 秒間のデータ取得を行った。認証手法には 4.2.3 で提案した k 数決法 ($k = 2$) を用いた。

Table 4.6 Outline of Experiment for Aged Deterioration

Date	2012.10.06 & 2013.1.5
Terminal	iPhone4S
Sampling Frequency	100Hz
Mounting Position	Right side of Waist
Acquisition Time	100sec/person
Authentication Method	k-Majority

通常の本人-本人間のユークリッド距離 (subject) と経年変化後の本人-本人間のユークリッド距離 (aged deterioration) を Fig.4.14 に示す。縦軸は各データ区間における、全体のデータ数に対する出現頻度の割合を表す。k 数決法を用いて認証を行った結果の ROC カーブを Fig.4.15 に、EER を Tab.4.7 示す。経年変化の影響は大きくないと推測されるが、この多少の違いが経年変化によるものなのか、取得時の健康状態や季節・天候によるものなのかは本研究では調査できなかった。今後は定期的に歩行データを取得することで、経年変化による影響なのか、他の要因によるものなのか調査する必要があるが、経年変化のみの影響を調査することは難しいと考えられる。

Table 4.7 Tolerance of Spoofing

The Kind of Walk	EER
Nomal Walk	10.1%
Aged Deterioration Walk	13.2%

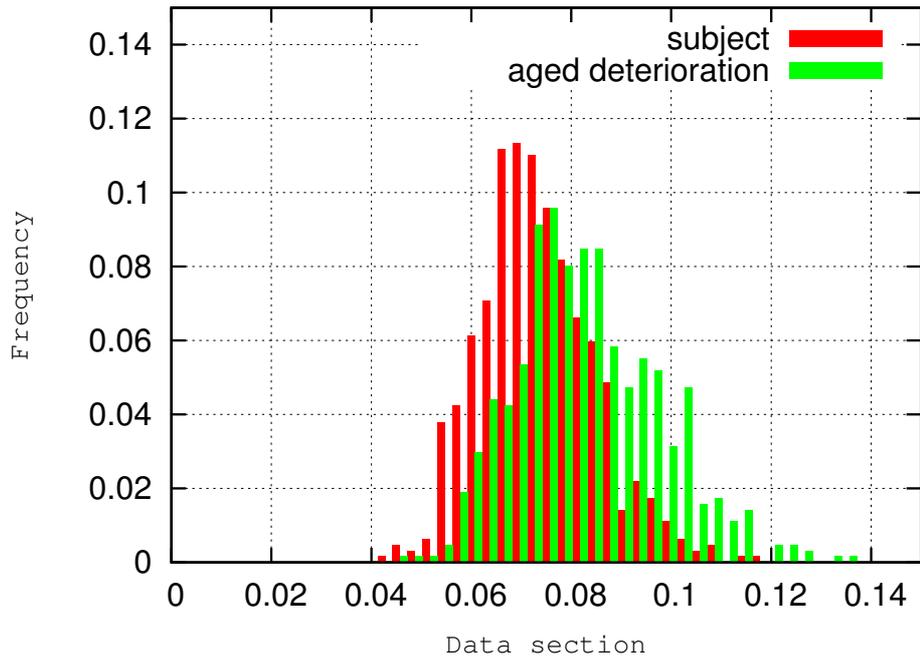


Figure 4.14 Histogram of Deference of Aged Deterioration

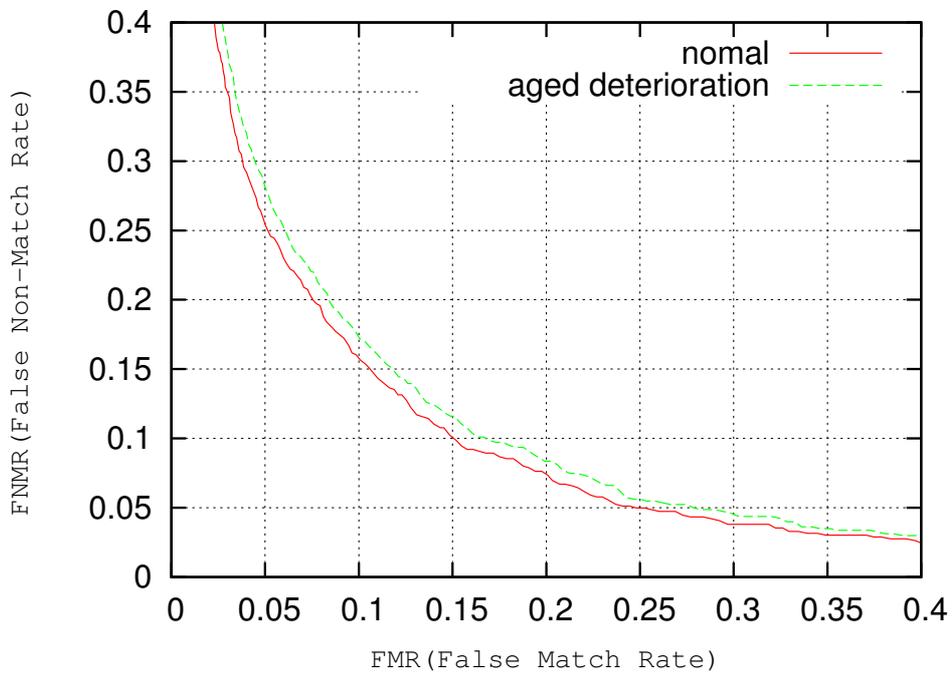


Figure 4.15 Tolerance of Aged Deterioration

4.3 成りすまし歩行における認証実験

歩行認証において、ユーザの歩行動作を見て真似をすることでユーザ本人に成りすまし、悪用する可能性が考えられる。そこで本研究では、歩行認証の成りすまし耐性について調査を行うため、評価実験を行った。成りすまし歩行におけるデータ取得実験の実験諸元を Tab.4.8 に示す。被験者7名について、同じ歩幅（60cm）、同じ歩調（100 歩/分）で歩行し、1 人あたり 100 秒間の歩行データの取得を行った。認証手法には 4.2.3 で提案した k 数決法 ($k = 2$) を用いた。

Date	2012.11.14
Terminal	iPhone4S
Sampling Frequency	100Hz
Mounting Position	Right side of Waist
Acquisition Time	100sec/person
Number of Subject	7 person
Authentication Method	k-Majority

評価結果の ROC 曲線を Fig.4.16 に、EER を Tab.4.9 に示す。通常歩行において認証を行った結果の EER は 10.1% となり、成りすまし歩行において認証を行った結果の EER は 22.5% となる。また、通常歩行と成りすまし歩行における本人-本人間のユークリッド距離 (subject) と、本人-他人間のユークリッド距離 (non-subject) をそれぞれ Fig.4.17, Fig.4.18 に示す。縦軸は各データ区間における、全体のデータ数に対する出現頻度の割合を表す。Fig.4.17 の通常歩行における分布に比べて、Fig.4.18 の成りすまし歩行における分布は、本人-本人間距離と本人-他人間距離の分布の重なりが大きくなってしまっている。そのため、Fig.4.16 や Tab.4.9 でわかるように、成りすまし歩行における認証では大きく認証性能が低下した。

認証性能が大きく低下した原因として以下の 2 点が考えられる。1 つ目は、LPC ケプストラムがピッチを顕著に抽出する特徴量であるために、歩調・歩幅を固定したことの影響を受け、性能が大きく低下したと考えられる。2 つ目は、歩調・歩幅を固定したことにより歩行における個人性が失われたと考えられる。歩行には人それぞれの歩き方があるが、歩調・歩幅を固定することで固有の歩き方を強制的に失わせてしまう結果となった。本研究の結果からは歩行認証の成りすまし耐性が低いと考えられるが、本人とする被験者に普段と違う歩き方をしているために、正確な成りすまし耐性の評価とは言えない。また、歩行している姿を見るだけでは、歩調・歩幅を正確に計測することは難しいと考えられる。そこで、今後の検討課題として、本人とする被験者は通常通りに歩行し、それを他人とする被験者が真似して歩くことで歩行データを取得し、認証を行うことで、より正確な歩行認証の成りすまし耐性を評価したい。

Table 4.9 Tolerance of Spoofing

The Kind of Walk	EER
Nomal Walk	10.1%
Spoofing Walk	22.5%

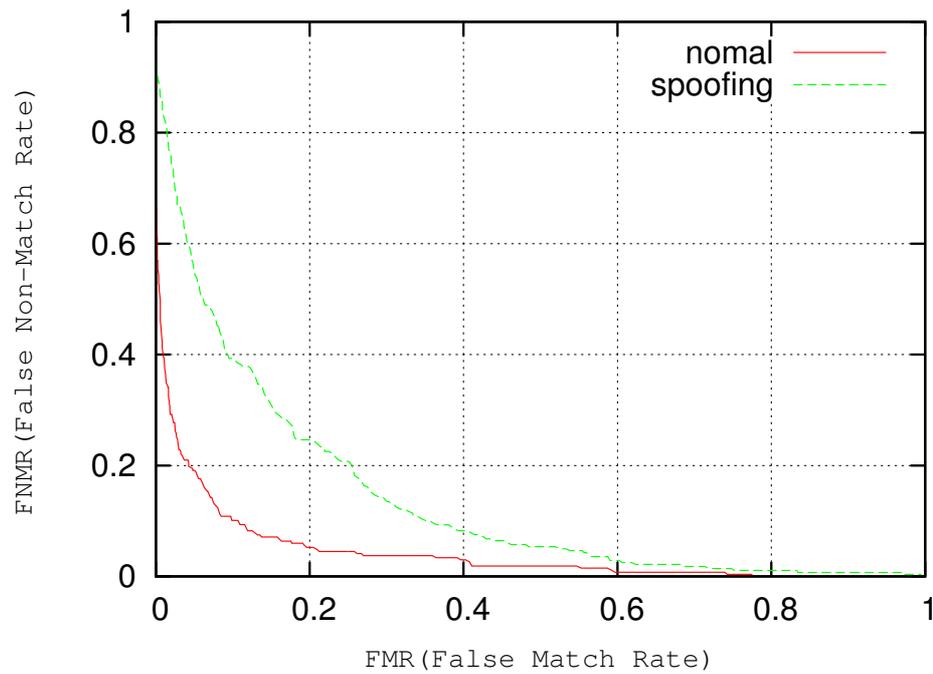


Figure 4.16 Tolerance of Spoofing

4.3 成りすまし歩行における認証実験

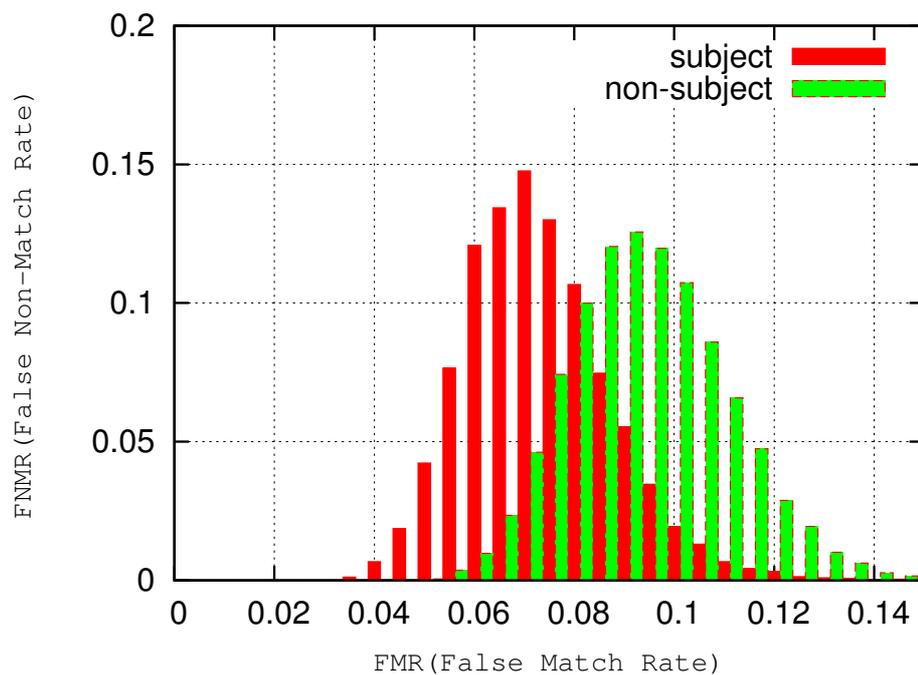


Figure 4.17 Histogram of Normal-Walk

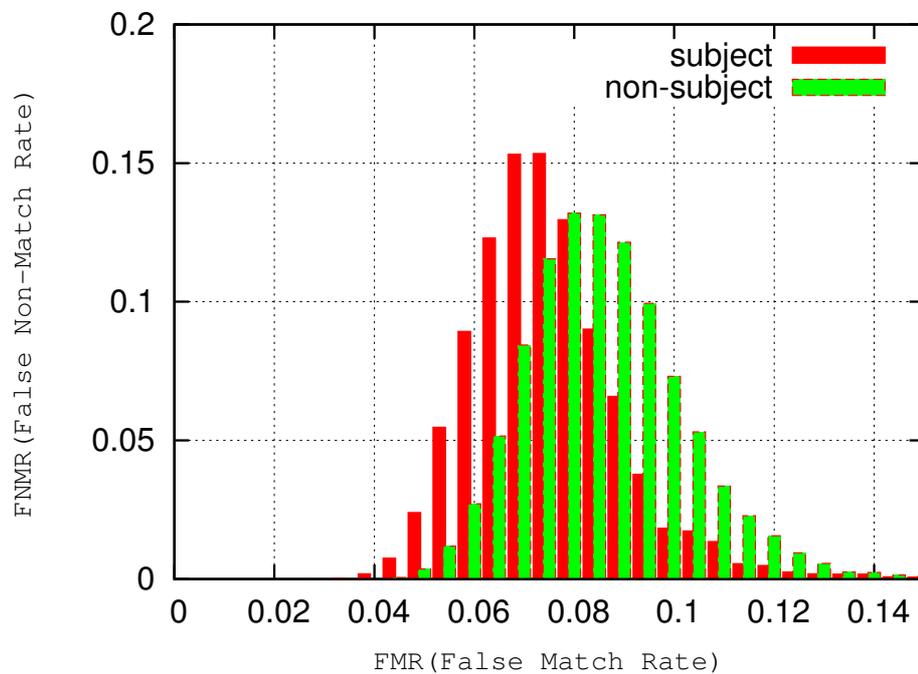


Figure 4.18 Histogram of Spoofing-Walk

第5章

結論

5.1 まとめ

本研究では、歩行時の携帯端末の加速度センサから得られる加速度データを用いた歩行認証の手法を提案し、その評価を行った。具体的には、歩行時の加速度データに音声処理で用いられるLPC ケプストラムを用いることを提案した。従来研究で用いられている統計量を中心とした特徴量と比較し、その有効性を、実装した歩行認証システムで認証を行い、ROC 曲線や EER を用いて定性的・定量的に評価した。また、LPC ケプストラムを用いて認証を行う上で必要となるパラメータの調査を行い、複数フレームを用いた認証である k 数決法の評価を行った。また、保持状態の影響、経年変化の影響、歩行認証の成りすまし耐性についても評価した。

■**従来特徴量との比較** 従来特徴量に用いられている4種の特徴量と比較して、LPC ケプストラムが歩行認証に有効であることが確認できた。

■**複数フレームを用いた認証** 複数フレームの平均値のような統計量を用いるよりも、本研究で提案する k 数決法を用いることが歩行認証に有効である。

■**保持状態・経年変化の影響** 保持状態においては、加速度の大きさが影響を受けてしまうため、正規化などの前処理をする必要があると考えられる。実験結果から経年変化の影響は大きくないと推測される。本研究で表れた少しいちがいは経年変化によるものか、取得時の健康状態などの影響によるものか調査したい。

■**成りすまし耐性** 成りすまし歩行における認証では、通常歩行における認証に比べて大きく認証性能が低下した。原因として、LPC ケプストラムが歩調・歩幅の影響を受けてしまうこと、歩調・歩幅を固定することで個人固有の歩き方が強制的に失われてしまうことが考えられる。以上から、LPC ケプストラムを用いた歩行認証の有効性を示した。

5.2 今後の課題と検討

今後、以下の項目について実施していく必要があると考えている。

■成りすまし耐性の調査 本研究では、歩幅・歩調を固定して歩行することで成りすまし歩行における歩行データを取得した。しかし、歩幅・歩調を固定して歩行することで、個人特有の歩き方が強制的に失われてしまうことが考えられる。そこで、本人とする被験者には通常通りに歩いて歩行データを取得し、本人とする被験者の歩き方を見て、他人とする被験者がそれを真似して歩くことにより成りすまし歩行における歩行データを取得する必要があると考えられる。これにより、本人とする被験者固有の歩き方を失うことなく、歩行データを取得することができるため、より成りすまし耐性について正確な評価を行うことができる。

■取得環境の影響の調査 本研究では、携帯端末 (iPhone4S) を右腰に専用のケースを用いて固定し、平地を歩行することで歩行データを取得した。しかし、環境要因 (天候、道の凹凸など) により歩行動作が変化し、保持状態 (端末を保持する場所) により歩行動作における加速度データが変化すると考えられる。そのため、取得環境によって歩行動作にどのように影響があるのかを調査し、その影響を考慮した上で歩行認証を行う手法を検討したい。

■特徴量の検討 本研究で、音声処理で用いられている特徴量の LPC ケプストラムが歩行認証において従来の特徴量と比較して、有効であると示した。今後は、バイオメトリクス認証で用いられている特徴量や、音声処理で用いられている他の特徴量を歩行認証に適用した場合の有効性を評価したい。

■身体的特徴による影響の調査 本研究では、特定の個人の特徴を抽出し認証に用いた。しかし、被験者が多くなるととも認証精度が低下することは避けられないと考えられる。今後は、被験者の身体的特徴 (身長、体重など) が歩行データにどのように表れるのか調査したい。

謝辞

本研究は私が早稲田大学理工学術院基幹理工学研究科情報理工学専攻修士課程に在籍中の研究の成果をまとめたものです。本研究を進めるにあたり、終始懇切丁寧な御指導、御助言を賜りました甲藤二郎教授、小松尚久教授に心から深く感謝の意を表します。また、日頃から有意義な検討及び討論をして頂いた、株式会社ソフトバンクテレコム 吉井英樹氏並びに、本学理工学研究員 鶴丸和宏氏、電気通信大学 市野将嗣氏、共同研究者である修士2年 上原聡介氏を始め、小松研究室、甲藤研究室の皆様に深く感謝いたします。

2013年2月8日

笠原 弘樹

付録 A

携帯端末に搭載されているセンサ

本章では、実験で用いた携帯端末に搭載されているセンサの基本原理を解説する。

A.0.1 測位センサ

■ GPS(Global Positioning System)

GPS(Global Positioning System)[22] は、アメリカ合衆国が軍事用に打ち上げた GPS 衛星のうち、上空にある数機の衛星からの信号を GPS 受信機で受け取り、現在位置を特定するシステムである。GPS の歴史は古く、1973 年に開発が始まり、1985 年までに合計 11 機が打ち上げられ、システムの試験が続けられた。1993 年には、24 機の GPS 衛星が配備され、同年 12 月に米国政府から運用開始が宣言され、民間利用が始まった。2010 年までに 31 機の GPS 衛星が運用されている。GPS 衛星の信号には、衛星に搭載された原子時計からの時刻のデータ、衛星の軌道情報などが含まれている。GPS 受信機にも正確な時刻を知ることができる時計が搭載されていれば、GPS 衛星からの電波を受信し、送信・受信の時刻差に電波の伝播速度（光の速度と同じ 30 万 km/s）を掛けることによって、その衛星からの距離がわかる。また、3 機の GPS 衛星からの距離がわかれば、空間上の一点が決定される。実際の GPS 受信機に搭載されている時計はクォーツなどを利用しているため、あまり正確ではない。時刻の誤差がたとえ 100 万分の 1 秒であったとしても（この精度で時計を維持することは非常に難しい）、距離の誤差は 300m にも及ぶ。そこで、4 機の GPS 衛星からの電波を受信し、GPS 受信機内部の時計の校正を行いつつ測位を行う。GPS 衛星は約 20000km の高度を一周約 12 時間で動く（静止衛星ではない）。軌道上に打ち上げられた 30 機ほどの衛星コンステレーションで地球上の全域をカバーでき、中軌道のため信号の送信電力としても有利である。また、ある地域からみた場合、衛星の配置が刻々と変化するため、地球上で測位誤差を平均化できる（地域によってはカバーする衛星の個数が常に少ない場合もある）。GPS は地上局を利用するロラン（LORAN）C とは異なり、受信機の上部を遮られない限り、地形の影響を受けて受信不能に陥ることが少ない。なお、ロランは、第 2 次世界大戦中に開発された初めての本格的な長距離電波航法システムで、その後継版のロラン C は、現在も主要海運国の沿岸を航行する商船にサービスを提供している。また、このアメリカ国防省が運営する GPS の他に、EU が中心となって進めているガリレオや、ロシアが開発している GLONASS といったグローバルナビゲーションポジショニングシステムが構築されつつある。日本において

も、GPS の補完として、日本で常に天頂付近に 1 機の衛星が見えるよう準天頂衛星を配置し、国内において高精度な衛星測位サービスを計画している。これらから、各国が安全保障の観点だけでなく、新しい公共インフラの 1 つとしてグローバルナビゲーションポジショニングシステムに取り組んでいることがわかる。なお、携帯電話に搭載されている GPS 機能では、携帯電話の通信機能を利用し、測位時間の短縮、測位精度の改善のため A-GPS(Assisted GPS) 機能を使うことが多いが、本来 GPS は、このような通信機能は不要であることに注意されたい。

■ WPS(Wi-Fi Positioning System)

WPS[23] は、Wi-Fi(Wireless Fidelity) 機器を使用して現在位置を短時間でリアルタイムに測定することができるテクノロジーである。WPS では周囲にある複数の無線 LAN アクセスポイントからの電波を受信し、その電測情報を用いて現在地を推定する。位置検出サービスとしては GPS が先行しているが、WPS の利点は検出速度と正確性にある。GPS は衛星を補足するまでに、ある程度の時間がかかるが、Wi-Fi は 0.1 秒ごとに自分の位置をはじめとした各種情報（ビーコン）を送受信するため、1 秒以内に受信を完了でき、電波受信のためビルの谷間や屋内や地下街のような GPS が機能しない場所でもフロアごとの位置測定が可能であることが特徴である。地図ナビゲーションだけではなく、様々な方法にこの技術が活用されている。しかし、WPS が GPS に対して不利な点もあり、当然のことながら Wi-Fi アクセスポイントがない場所では位置検出ができないため、海上や山など都市以外の場所では利用できない。また、都市についてもデータベースにある程度の Wi-Fi アクセスポイントを登録しておく必要がある。現状、実質的には都市型に限定した位置情報サービスであり、2010 年 6 月時点でのサービス提供エリアは、東京を含む首都圏のほか、国内の政令指定都市や県庁所在地が中心となっている。

WPS の測位は以下のような手順で行われる。

1. 前提として Wi-Fi ルーターのマックアドレスが事前に位置情報とともにサーバーに登録されている。
2. Wi-Fi 端末はルーターの信号を受信するとそのマックアドレスを取得する。
3. Wi-Fi 端末が複数の信号のマックアドレスを送信する。
4. サーバーが Wi-Fi 機器のおよその位置を割り出すことができる。

WPS の位置推定精度は、位置を問い合わせた場所の Wi-Fi 電測情報の状況 (アクセスポイントの密集度など) や、その時点でサーバー側に登録されている Wi-Fi 電測情報のデータベースの状況によって異なり、概ね 5m~100m 程度の範囲内で位置が推定される。

■ 基地局測位

基地局測位は、携帯電話と直接交信をする携帯電話網の末端にあたる装置である基地局を利用した測位技術である。基地局は主に電柱やビルの屋上、電話ボックス、地下鉄ホームの天井など

に設置されている。基地局測位では、基地局の識別情報と携帯端末自身が受信した基地局からの電波の強さ(電界強度)を基に、基地局から半径何メートルの範囲に対象端末があるかを測位している。GPS と比べて精度は劣るものの、基地局さえあれば屋内でも位置検索が可能であることが特徴である。

A.0.2 加速度センサ

加速度センサとは、センサ自体の1秒当たりの速度変化を検出するセンサである。重力加速度も検出できるので、人や物体の動きや地震などの振動を検出することができる。また、3軸の加速度センサであれば水平状態の検出も可能である。近年、加速度センサは多くの機器に組み込まれ普及している。例えば、自動車のエアバッグ、手ぶれ補正機能の付いたデジタルカメラ、ゲーム機のコントローラなどが挙げられる。これほどまでに加速度センサが普及した背景にはMEMS(Micro Electro Mechanical Systems)技術の発達がある。MEMS技術とは半導体技術を用いて、一枚のシリコン基板上に機能を集積化する技術である。加速度センサにこのMEMS技術を使用することにより、小型化、高精度化、低価格化が実現された。加速度センサは測定範囲によって低G加速度センサ、高G加速度センサに分類することができる。低G加速度センサは、±20G以下の汎用計測用センサを指し、腕や手の動きを検出するモーション・センサとして使用されている。また、MEMS技術により小型化、低廉化が進み、多くの民生機器に組み込まれるようになった。例えば、任天堂のゲーム機「Wii」のコントローラやiPhoneには低G3軸加速度センサが採用されている。一方、高G加速度センサは、±20G～±250Gの衝突衝撃検出用センサを指し、大型で高価なため主に産業機器に使用されている。自動車や飛行機の衝突検出実験等に使用され、エアバッグを膨らませる仕組みにも採用されている。

3軸加速度センサは1つの重りを使って各方向成分を検出する。3軸加速度センサはFig.A.1に示すように、ばね定数 k のばねに支えられた質量 m の重りを使って、ばねの変位量 x を基に加速度 a を検出する。

物体に働く力はニュートンの法則により $F = ma$ だが、ばねと重りの関係から $kx = ma$ が成立するので、加速度 a は $a = kx/m$ と置き換えられる。 k と m は既知なので、重りの移動距離 x が分かれば加速度 a が求められる。

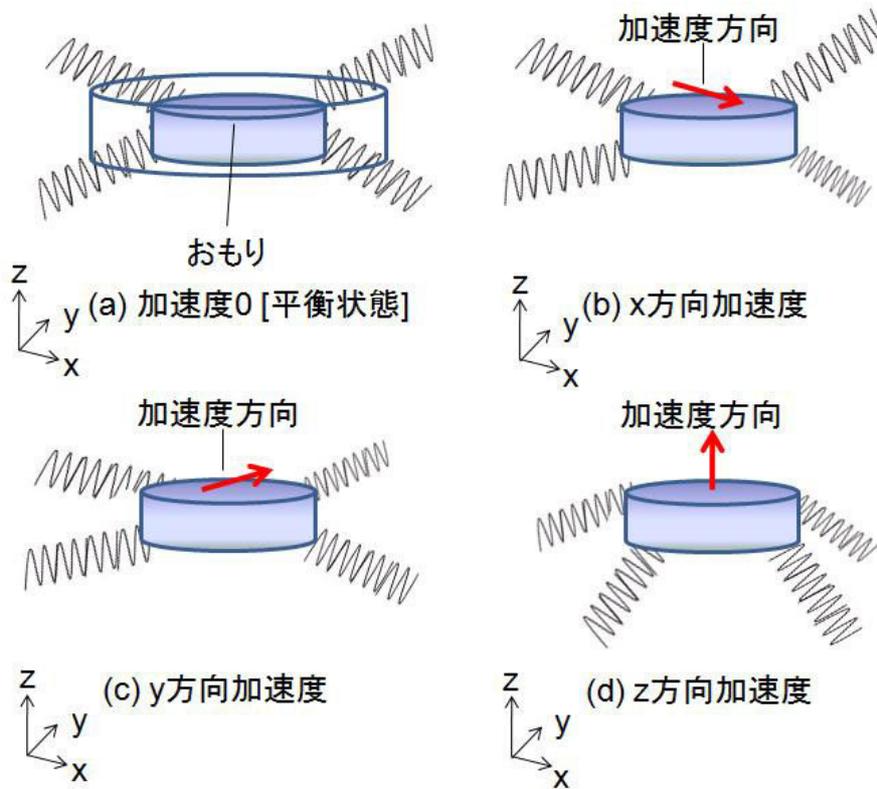


Figure A.1 3軸加速度センサの検出原理

MEMS 技術を用いた 3 軸加速度センサの場合，Fig.A.2 に示すようにおもりの側面にくし状のコンデンサが形成されており，電子回路により静電容量の変化を加速度に対応する電気信号に変換している [25].

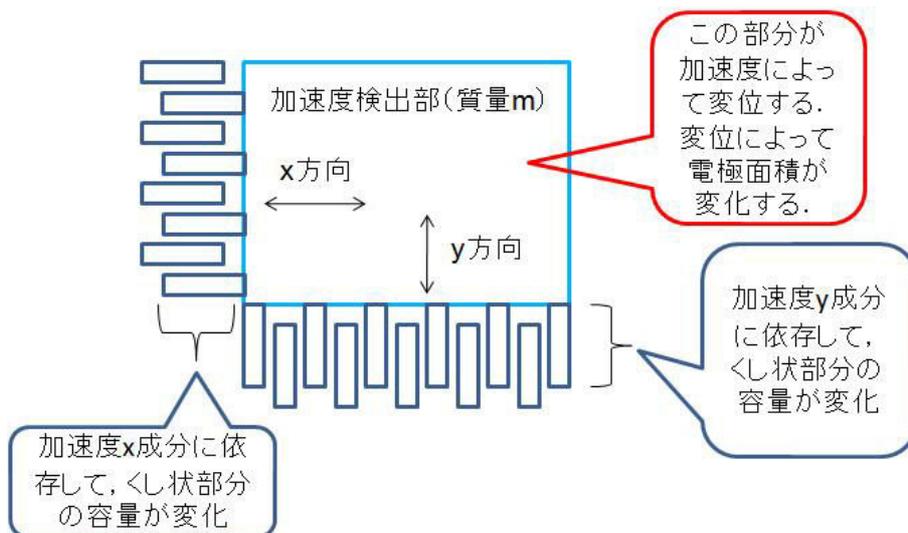


Figure A.2 MEMS 技術を用いた加速度センサの構造

A.0.3 地磁気センサ

電子コンパス [24] は地球の発する微弱な磁気を検知して方位を算出し、北方向を電氣的に示すコンパスである。電子コンパスは、方位磁石の代わりに地磁気を検知する磁気センサと、センサからの信号を増幅する IC と、信号から方位角を演算するソフトウェアからできており、針式に比べて揺れや振動での誤差が出にくいこと、コンパクトであることなどのメリットがある。

北の方向を知るためには、地磁気が水平方向にどちらを向いているかを調べる必要があり、2つの磁気センサを直角に組み合わせて、前後方向と左右方向の地磁気を検出し、その強さからどちらが北の方向なのかを計算する。電子コンパスが方位磁石と違うところは、影響を及ぼす周囲の磁気に強い点である。電子コンパスは、装置の中の磁気の影響を受けても、その磁気の影響の大きさを検出し、瞬時に分析することで磁気の影響を補正することができる。このことにより電子コンパスは、正しい方位を示すことが可能となる。また、電子コンパスに磁気の影響を与えるものの例としては、携帯電話では内部のスピーカーやメモリーカードなどがある。電子コンパス(地磁気センサ)には“2軸タイプ”と“3軸タイプ”がある。北の方向を検出するために、地磁気が水平方向にどちらを向いているかを調べる際、2つの磁気センサを組み合わせて、前後方向と左右方向の地磁気を検出するものを“2軸タイプ”と呼び、3つの磁気センサを組み合わせて、前後方向と左右方向に加えて上下方向の地磁気を検出するものを“3軸タイプ”と呼ぶ。“2軸タイプ”では、電子コンパスを地面に対して水平に持たなければならず、傾けて使うと正しく水平方向の地磁気を検知できないため、示す方位に誤差が含まれてしまう。また、周囲の磁気の影響を受けて方位に誤差が生じた場合は、磁気補正をする必要がある。例えば、電子コンパスを水平に数周回すことで、影響する磁気の大きさを検出して補正をすることができる。一方、“3軸タイプ”では、携帯電話を傾けて手に持っている場合など、電子コンパスが傾いた状態でも、傾きの角度を検知することができるため、その傾き分を差し引いて水平方向の地磁気を計算し、正しい方位を表示することが可能である。また、“3軸タイプ”には、磁気補正のためにわざわざ電子コンパスを回すなどの動作をしないでも、携帯電話をポケットから取り出したり、周りを見回したりする持った人の自然な動きを感知して、周りの余計な磁気を自動補正し、常に正しい方位を指し示すことのできる種類の電子コンパスもある。

付録 B

データ取得アプリケーション

本研究ではセンサデータ取得のために、米アップル製スマートフォン iPhone 上に、アプリケーションを実装した。本章では iPhone に実装したアプリケーションの概要と、各センサの出力データについて記載する。

B.1 アプリケーションの構成

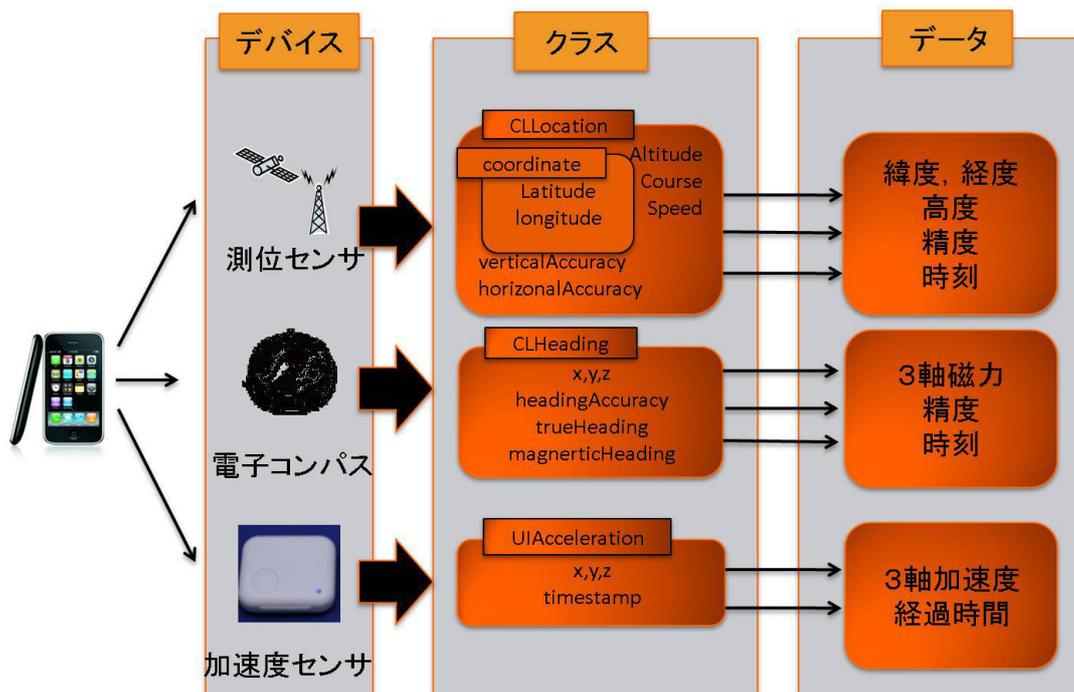


Figure B.1 LBG アルゴリズムにおける処理のフローチャート

Fig.B.1 に、iPhone においてセンサデータ取得のために作成した、アプリケーションの構成を示す。このアプリケーションは加速度センサ、測位センサ、電子コンパスからそれぞれデータを取得し、その取得したデータをデータの種類毎に 3つのファイルへ書き出す機能を実装している。測位センサと電子コンパスは、CoreLocation フレームワークの、CLLocationManager クラスがデバイス制御をしている。CLLocationManager は、測位センサ、または電子コンパスのデータ

が変化するたびにデータを取得し、測位センサのデータは CLLocation クラスの各プロパティに、電子コンパスのデータは CLHeading クラスの各プロパティに格納し、そこから取得したデータを取得する。加速度センサは UIAccelerometer クラスがデバイス制御をしており、updateInterval というプロパティにより、データの取得間隔を指定することができる。UIAccelerometer が取得したデータを UIAcceleration クラスのそれぞれのプロパティに格納し、そこから取得したデータを取得する。

■加速度センサ

加速度センサで得ることができるデータを以下の Tab.B.1 に示す。得られるデータは、x 軸・y 軸・z 軸それぞれの加速度 [G] と、経過時間 [s] である。3 軸の加速度センサを用いているため、x 軸・y 軸・z 軸それぞれの加速度を、最短間隔で 0.01 秒毎に取得することができる。加速度センサにおける x 軸・y 軸・z 軸の方向は以下の Fig.B.2 に示す。なお、加速度センサにおける timestamp は実行時の時刻ではなく、CPU 時間を基準とした経過時間である。

Table B.1 加速度センサ (UIAcceleration) から得られるデータ

プロパティ名	意味	単位	サンプルデータ
X	X 軸方向の加速度	[G]	-0.489
Y	Y 軸方向の加速度	[G]	-1.195
Z	Z 軸方向の加速度	[G]	-0.126
Timestamp	経過時間	[s]	13185.69

B.1 アプリケーションの構成

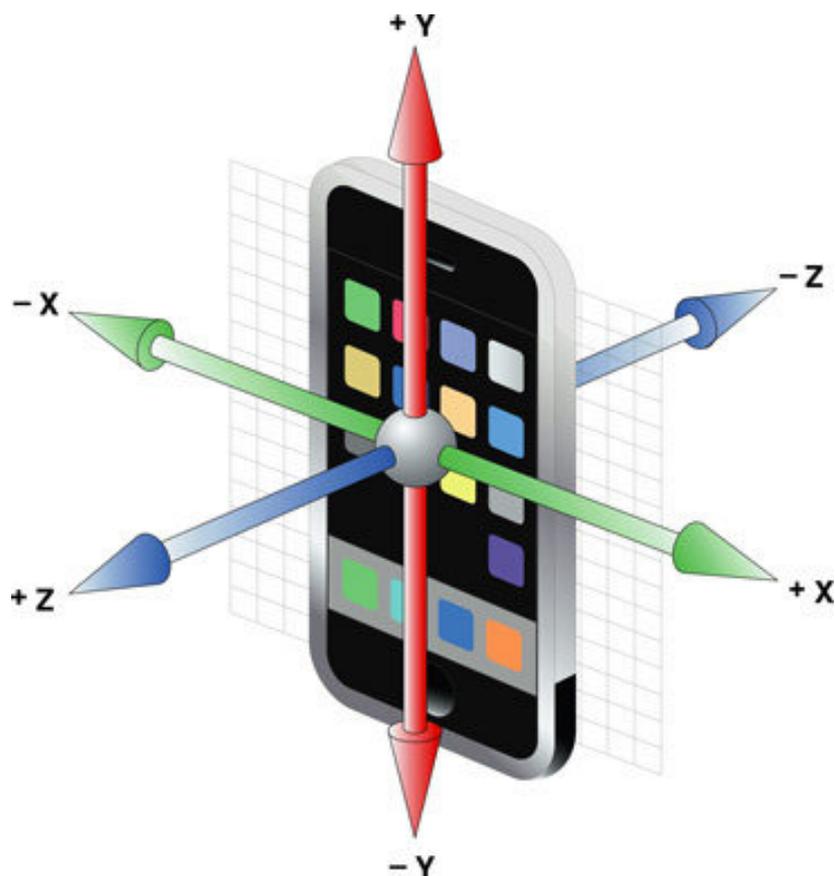


Figure B.2 iPhone に搭載されている 3 軸加速度センサの向き

■測位センサ

測位センサで得ることができるデータを Tab.B.2 に示す。測位センサには、GPS 測位、Wi-Fi 測位、基地局測位の 3 つがあり、指定した精度に応じて iPhone が自動的に測位方法を選択し、位置情報のデータを取得している。得られるデータは、時刻、緯度 [度]、経度 [度]、標高 [m]、水平方向の精度 [m]、標高の精度 [m]、デバイスが移動している方向 [度]、速度 [m/s] である。時刻は年月日時分秒で表示される。水平方向の精度とは、実際に取得された位置情報を中心として、そこから半径何 [m] の円の中にデバイスが実際に存在しているかどうかを表している。水平方向・標高の精度で負の数取得される場合は、その取得されたデータが無効であることを表している。移動している方向は、真北を 0 度として、東 90 度、南 180 度、のように表される。速度は、現在向いている方向のデバイスの瞬間の速度を表している。

■地磁気センサ

地磁気センサで得ることができるデータを Tab.B.3 に示す。iPhone に搭載されている電子コンパスは 3 軸地磁気センサを用いており、時刻、x 軸・y 軸・z 軸の磁力 [μ T]、磁北 [度]、真北 [度]、精度 [度] を取得することができる。時刻は年月日時分秒で表示される。磁気センサにおける

Table B.2 測位センサから得られるデータ

プロパティ名	意味	単位	サンプルデータ
Timestamp	時刻	-	2010/07/02 16:16:53.327
Latitude	緯度	[度]	35.706009
Longitude	経度	[度]	139.708647
Altitude	高度	[m]	59.000000
verticalAccuracy	垂直方向の精度	[m]	113.175757
horizontalAccuracy	水平方向の精度	[m]	76.356886
Course	移動している方向	[度]	176
Speed	速度	[m/s]	0.000000

x 軸・y 軸・z 軸の方向は加速度センサと同様で、Fig.B.2 の通りである。iPhone では、3 軸の磁力を元にして磁北を算出し、算出された磁北と観測地点の磁気偏角により真北を算出している。

精度は、得られる磁北と実際の磁北からの最大偏差を表している。この精度が負の値を示す場合は、強い磁場の影響をデバイスが受けた場合などで、データが無効であることを表している。磁北とは、方位磁針の N 極が指す方向であり、地球上の磁力は磁北に向かっている。現在の磁北の極点はカナダの北（北緯 78 度、西経 98 度）のあたりに存在し、この磁北点は年を経る毎に徐々にずれている。真北とは、北極点、すなわち地球の自転軸の北端（北緯 90 度地点）を指す方位であり、北極星のある方位である。この真北と磁北にはズレがあり、そのズレを磁気偏角という。磁気偏角は日本では 3 度～9 度の偏角があり、アメリカでは地域により 30 度～40 度の偏角があるところもある。

Table B.3 地磁気センサから得られるデータ

プロパティ名	意味	単位	サンプルデータ
Timestamp	時刻	-	2010/06/29 17:12:46.380
X	X 軸方向の磁力	[μ T]	18.625000
Y	Y 軸方向の磁力	[μ T]	-14.375000
Z	Z 軸方向の磁力	[μ T]	-34.437500
trueHeading	真北	[度]	227.934634
magneticHeading	磁北	[度]	235.000000
headingAccuracy	精度	[度]	10.000000

付録 C

ベクトル量子化

C.1 ベクトル量子化

本研究で使用したベクトル量子化について以下に示す。ベクトル量子化 (Vector Quantization) とは、 K 個の信号をまとめてひとつの K 次元ベクトル、すなわち K 次元信号空間内の一点とし、あらかじめ定められたいくつかの代表点 (量子化代表ベクトル) で近似するものである。

まず入力ベクトルを K 次元ベクトルとする。このとき、入力ベクトルが存在する信号空間は K 次元となる。この K 次元空間を $\mathbf{x} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_K)^T$ と書くことにする。ここで K 次元信号空間 R^K を互いに重なり合わない N の領域 P_1, P_2, \dots, P_N に分割し、各領域 P_i 内に量子化代表ベクトル $\mathbf{y} = (\mathbf{y}_{i1}, \mathbf{y}_{i2}, \dots, \mathbf{y}_{iK})^T$ を一つ定めておく。ここで、領域 P_1, P_2, \dots, P_N の集合を P と書き、分割と呼ぶ。こういった記法を用いると、「 K 次元 N レベルのベクトル量子化」は K 次元信号空間 R^K からコードブック C への写像 $Q(\cdot)$ として、次のように記述される。

ベクトル量子化の動作：

もし、入力ベクトル x が領域 P_i 内に所属しているならば、そのときベクトル量子化の動作は次式の写像 $Q(\cdot)$ として記述される。

$$\mathbf{Q}(\cdot) = \mathbf{y}_i \quad (\text{C.1})$$

式 (C.1) のベクトル量子化によるサンプル当りの平均ひずみ D は、入力ベクトル \mathbf{x} の確率密度関数 $p(\mathbf{x})$ が既知の場合には次式で与えられる。

$$\begin{aligned} D &= \frac{1}{K} \int_{R^K} d(Q(\mathbf{x})) \cdot p(\mathbf{x}) d\mathbf{x} \\ &= \frac{1}{K} \sum_{i=1}^N \int_{P_i} d(\mathbf{x}, \mathbf{y}_i) \cdot p(\mathbf{x}) d\mathbf{x} \end{aligned} \quad (\text{C.2})$$

次元数 K とレベル数 n とが指定されたとき、式 (C.2) の平均ひずみ D を最小とするベクトル量子化器のことを「最適なベクトル量子化器」と呼ぶ。式 (C.2) において、平均ひずみ D の大きさは領域 P_i や量子化代表ベクトル \mathbf{y}_i をどのように設定するかによって左右される。従って、ベクトル量子化器を最適化するためには、領域や量子化代表ベクトルを式 (C.2) の D を最小とするように定

めなければならない。このための必要条件は、以下に示すような二つの最適化条件に帰着する。

1. 代表点条件

K 次元信号空間 R^K の N 個の領域 P_1, P_2, \dots, P_N への分割 P が与えられたとき、式 (C.2) の平均ひずみを最小とする N 個の量子化代表ベクトル $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N$ はそれぞれ対応した領域 P_1, P_2, \dots, P_N の重心で与えられる。入力ベクトル \mathbf{x} の確率密度関数 $p(\mathbf{x})$ が既知の場合は、量子化代表ベクトル \mathbf{y}_i が次式で計算されることを意味する。

$$\mathbf{y}_i = \frac{\int_{P_i} \mathbf{x} \cdot p(\mathbf{x}) d\mathbf{x}}{\int_{P_i} p(\mathbf{x}) d\mathbf{x}} \quad (\text{C.3})$$

2. 分割条件

N 個の量子化代表ベクトル $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N$ から成るコードブック C が与えられたとき、式 (C.2) の平均ひずみ D を最小とする N 個の領域 P_1, P_2, \dots, P_N への K 次元信号空間 R^K の分割 P は、次のようにして与えられる。即ち、量子化代表ベクトル $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N$ に対応した領域 P_i は、 N 個の量子化代表ベクトルの中で \mathbf{y}_i とのひずみが最小となる入力ベクトル \mathbf{x} 、すなわち \mathbf{y}_i 以外のすべての量子化代表ベクトル $\mathbf{y}_j (j \neq i)$ に対して次式の不等式

$$d(\mathbf{x}, \mathbf{y}_i) \leq d(\mathbf{x}, \mathbf{y}_j) \quad (\text{C.4})$$

を満足する入力ベクトル \mathbf{x} の集合として与えられる。

また、この条件によって式 (C.1) の写像 $Q(\cdot)$ として定義された量子化動作を次のように書き換えることができる。

最適なベクトル量子化器の量子化動作：

入力ベクトル \mathbf{x} が \mathbf{y}_i 以外の全ての量子化代表ベクトル $\mathbf{y}_j (j \neq i)$ に対して式 (C.4) の不等式を満足するならば、その時最適なベクトル量子化器の量子化動作は、入力ベクトル \mathbf{x} から量子化ベクトル \mathbf{y}_i への写像として、 $Q(\mathbf{x}) = \mathbf{y}_i$ と記述される。また、本研究ではひずみ測定に、入力ベクトルと量子化代表ベクトルの間のユークリッド距離の 2 乗として定義された 2 乗ひずみ測定を用いている。

C.2 クラスタリングアルゴリズム

本研究では、クラスタリングアルゴリズムとして、LBG+splitting アルゴリズムを用いている。

■ LBG アルゴリズム

LBG アルゴリズムは、適当な初期コードブックから出発し、学習系列に分割条件と代表点条件を繰り返し適用し、良好なコードブックに収束させる設計アルゴリズムである。その処理の流れ

C.2 クラスタリングアルゴリズム

を図 C.1 に示し、手順を以下に示す.

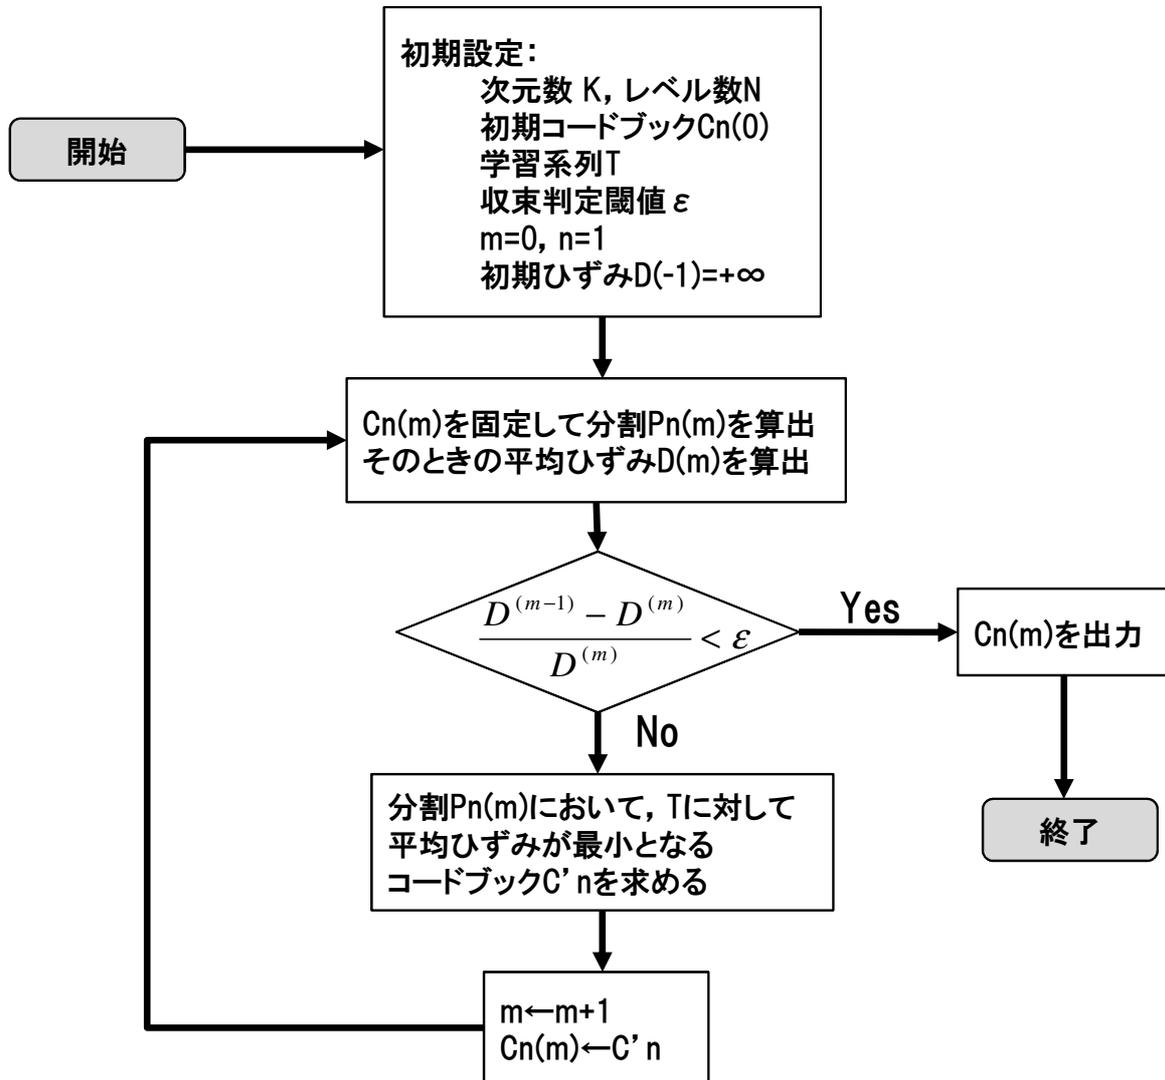


Figure C.1 LBG アルゴリズムにおける処理のフローチャート

1. 次元数 K , レベル数 N , N 個の初期量子化代表ベクトル $\mathbf{y}_1^{(0)}, \mathbf{y}_2^{(0)}, \dots, \mathbf{y}_N^{(0)}$ から成る初期コードブック $C_N^{(0)}$, L 個の K 次元学習ベクトル $\mathbf{x}_1^{(0)}, \mathbf{x}_2^{(0)}, \dots, \mathbf{x}_N^{(0)}$ からなる学習系列 T , 収束判定用しきい値 ϵ が与えられているとする. また, $m = 0$, 初期ひずみ $D^{(-1)} = \infty$ と設定する.
2. 量子化代表ベクトル $\mathbf{y}_1^{(m)}, \mathbf{y}_2^{(m)}, \dots, \mathbf{y}_N^{(m)}$ から成る初期コードブック $C_N^{(m)}$ の下で, 平均ひずみを最小とする N 個の領域 $P_1^{(m)}, P_2^{(m)}, \dots, P_N^{(m)}$ への学習系列 T の分割 $P_N^{(m)}$ を分割条件を適用してから定める. 即ち, 量子化代表ベクトル $\mathbf{y}_i^{(m)}$ に対応した領域 $P_i^{(m)}$ は N 個の量子化代表ベクトルの中で, $\mathbf{y}_i^{(m)}$ とのひずみが最小となる学習ベクトルの集合で与えられる. こうして, L 個の学習ベクトルが N 個の領域に分割される. また, 各領域に所属す

る学習ベクトルを, その領域内の量子化代表ベクトルで置き換えたときに生じる平均ひずみ $D^{(m)}$ を算出する.

3. もし, $(D^{(m-1)} - D^{(m)})/D^{(m)} < \epsilon$ ならば, 処理を停止して, $C_N^{(m)}$ を最終的に設計された N レベルのコードブックとして出力する. さもなければ次の手順へ進む.
4. N 個の領域 $P_1^{(m)}, P_2^{(m)}, \dots, P_N^{(m)}$ への学習系列 T の分割 $P_N^{(m)}$ の下で, 学習系列 T に対して平均ひずみを最小とする N 個の量子化代表ベクトル $\mathbf{y}_1^{(m)}, \mathbf{y}_2^{(m)}, \dots, \mathbf{y}_N^{(m)}$ から成るコードブック C'_N を代表点条件を適用して定める. 領域 $P_i^{(m)}$ に所属する学習ベクトルの平均ベクトルとして与えられる重心を, 量子化代表ベクトル \mathbf{y}'_i とする. さらに, $m \leftarrow m + 1$ とし, C'_N をコードブック $C_N^{(m)}$ として, 手順 2. へ戻る.

■ splitting アルゴリズム

LBG アルゴリズムにより設計されたコードブックの良否は, 初期コードブック $C_N^{(0)}$ と学習系列 T の選定法に強く依存する. 初期コードブック $C_N^{(0)}$ は想定される入力ベクトルの分布範囲を被覆していることが望ましい. この条件をある程度満足する初期コードブックの生成法として splitting アルゴリズムが知られている. このアルゴリズムは, N レベルのコードブック C_N の量子化代表ベクトル $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N$ を式 (C.5) のように微小なベクトル δ を用いて接近した二つのベクトルに分割することによって, 量子化代表ベクトル $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_{2N}$ からなる $2N$ レベルの初期コードブック $C_{2N}^{(0)}$ を生成するものである. この splitting アルゴリズムを LBG アルゴリズムと組み合わせることによって 1 レベルのコードブックから出発して順次 2, 4, 8, \dots レベルのコードブックを設計することが出来る.

$$\mathbf{y}_i = \mathbf{y}_i - \delta, \mathbf{y}_{i+N} = \mathbf{y}_i + \delta \quad (\text{C.5})$$

参考文献

- [1] TCA-社団法人電気通信事業者協会, “携帯電話・PHS 契約数,” <http://www.tca.or.jp/database/index.html>.
- [2] 杉浦一成, 榎原靖, 八木康史, “全方位カメラを用いた複数方向の観測による歩容認証,” 情報処理学会論文誌, Vol.1, No.2, pp.76-85, Jul.2008.
- [3] 榎原靖, 佐川立昌, 向川康博, 越後富夫, 八木康史, “周波数領域における方向変換モデルを用いた歩容認証,” 情報処理学会論文誌, Vol.48, No.SIG 1, pp.78-87, Feb.2007.
- [4] 小堀裕貴, 金井敦, “歩行画像による個人認証手法の検討,” 全国大会講演論文集, 第 72 回平成 22 年 (3), ”3-627”-”3-628”, 2010-03-08.
- [5] 堀隆之, 大谷淳, 榎沢順, “テンソル分解に基づく人物の歩行動作を用いた個人認証,” 電子情報通信学会技術研究報告. PRMU, パターン認識・メディア理解 108 (363), 87-92, 2008-12-11.
- [6] 中山亮介, 納富一宏, 斎藤恵一, “自己組織化マップを用いたジェスチャー認証手法-複数マップによる分析と評価-, ” バイオメディカル・ファジィ・システム学会誌, Vol.13, No.1, pp.29-34, 2011.
- [7] 井上隆之, 野崎秀鷹, 堂園浩, “ゲーム機における行動的特徴量を用いた生体認証方式の検討,” 情報処理学会研究報告. マルチメディア通信と分散処理研究会報告 2009 (20), 73-77, 2009-02-26.
- [8] 白井隼人, 吉井英樹, 小松尚久, “携帯端末のセンサ情報を用いたユーザ行動状態識別に関する研究 - LPC ケプストラムを用いた歩行状態の識別-, ” 電子通信情報学会技術研究報告, vol.110, no.450, pp.119-124, Mar.2011.
- [9] 伊藤智則, 上原聡介, 笠原弘樹, 市野将嗣, 吉井英樹, 鶴丸和宏, 甲藤二郎, 小松尚久, “加速度センサを用いた歩行状態識別におけるケプストラム分析の有効性に関する一考察,” 信学技報 LOIS2011-63, Jan.2012.
- [10] Jennifer R.Kwapisz, Gary M.Weiss, and Samuel A.Moore, “Cell Phone-Based Biometric Identification,” IEEE Biometrics, pp.1-7, Sep.2010.
- [11] Davrondzhon Gafurov, Kirsi Helkala, and Torkjel Sondrol, “Gait Recognition Using Acceleration from MEMS,” IEEE Availability, Reliability and Security, Apr.2006.
- [12] 古井貞熙, “デジタル音声処理,” 東海大学出版会, 1998.
- [13] 阿部匡信, “ライフログ活用技術の動向と研究所の取り組み,” NTT サイバーソリューション研究所, 2010.
- [14] 特定非営利活動法人 ITS Japan, “東日本大震災 自動車・通行実績情報を公開しました,” http://www.its-jp.org/news_info/6568.

- [15] 倉沢 央, 川原圭博, 大村 廉, 青山友紀, “センサ装着場所を考慮した 3 軸加速度センサを用いた姿勢推定手法,” 情報処理学会研究報告, UBI, vol.54, pp.15-22, May.2006.
- [16] 高田耕太郎, 安保雅博, “小型三次元加速度センサ計を用いた歩行評価の臨床的有効性の検討,” 東京慈恵医会医科大学リハビリテーション医学講座, 2004 年 6 月.
- [17] 村田 伸, 忽那龍雄, 北山智香子, “最適歩行と最速歩行の相違: GAITR いてによる解析,” 理学療法科学学会, vol.19, no.3, pp.217-222, Aug.2004.
- [18] Y.Linde, A.Buzo and R.M.Gray, “An Algorithm for Vector Quantizer Design,” IEEE Trans.Commun., Vol.COM-28, No.1, pp.88-95, 1980.
- [19] 小林隆夫, “音声のケプストラム分析, メルケプストラム分析,” 電子情報通信学会技術研究報告, DSP, no.98 vol.261, pp.33-40, Sep.1998.
- [20] 福井博章, “単一加速度センサを用いた感情識別,” 電子情報通信学会技術研究報告, NLP, no.389 vol.108, pp.109-114, Jan.2009.
- [21] 斎藤琴子, 丸山仁司, “敏捷性と歩行能力の関係—若年者と中高年者を比較して—,” 理学療法科学, no.1 vol.21, pp.7-11, 2006.
- [22] 野村総合研究所, “Uni-ID 導入事例,” <http://uni-id.nri.co.jp/case-study/japanairlines.html>
- [23] 土屋淳, 辻宏道, “GNSS 測量の基礎,” 日本測量協会, 2008.
- [24] 旭化成, “知ってる? 電子コンパス,” http://www.s3sensor.com/sens_a01
- [25] 上田智章, “加速度センサと角速度センサのしくみ,” Desing Wave Magazine, pp.70-73, 2007 年 8 月号.
- [26] 石井健太郎, 上田修功, 前田英作, 村瀬洋, “わかりやすいパターン認識,” オーム社, 1998.
- [27] 原島博, “画像情報圧縮,” オーム社, 1991.
- [28] 尾上守夫, “パターン識別,” アドコム・メディア株式会社, 2001.
- [29] Dave Mark, Jeff LaMarche, “はじめての iPhone3 プログラミング,” ソフトバンク クリエイティブ株式会社, 2009.
- [30] AppleDeveloper, “iOS Reference Library,” <http://developer.apple.com/library/iOS/#documentation/UIKit/Reference/UIAcceleration Class/Reference/UIAcceleration.html>

関連業績

【 学会発表 】

加速度データの LPC ケプストラムを用いた歩行状態の識別に関する一考察

2011 年 3 月

電子情報通信学会 ライフインテリジェンスとオフィス情報システム研究会 (LOIS)

白井隼人, 笠原弘樹, 伊藤智則, 吉井英樹, 小松尚久

加速度データの周期性に着目した歩行状態の識別に関する一考察

2011 年 5 月

電子情報通信学会 ライフインテリジェンスとオフィス情報システム研究会 (LOIS)

笠原弘樹, 伊藤智則, 吉井英樹, 鶴丸和宏, 小松尚久

加速度センサを用いた歩行状態識別におけるケプストラム分析の有効性
に関する一考察

2012 年 1 月

電子情報通信学会 ライフインテリジェンスとオフィス情報システム研究会 (LOIS)

伊藤智則, 上原聡介, 笠原弘樹, 市野将嗣, 吉井英樹, 鶴丸和宏, 甲藤二郎, 小松尚久

携帯端末のセンサ情報を用いた個人認証に関する検討

2012 年 8 月

電子情報通信学会 バイオメトリクス時限研究専門委員会 (BioX)

笠原弘樹, 市野将嗣, 吉井英樹, 鶴丸和宏, 甲藤二郎, 小松尚久

携帯端末の加速度センサを用いた歩行認証に関する検討

2013 年 1 月

電子情報通信学会 暗号と情報セキュリティシンポジウム (SCIS)

笠原弘樹, 市野将嗣, 吉井英樹, 鶴丸和宏, 甲藤二郎, 小松尚久

【 ポスター発表 】

携帯端末の加速度センサを用いた歩行認証に関する検討

2012 年 10 月

無線 LAN の QoS に関する第 3 回技術交流会

笠原弘樹, 甲藤二郎

加速度データの周期性に着目した歩行状態の識別に関する一考察

笠原 弘樹[†] 伊藤 智則[†] 吉井 英樹* 鶴丸 和宏[‡] 小松 尚久[†]

[†] 早稲田大学理工学術院基幹理工学研究所

[‡] 早稲田大学理工学研究所

〒169-8555 東京都新宿区大久保 3-4-1

*ソフトバンクテレコム株式会社

〒105-7316 東京都港区東新橋 1-9-1 東京汐留ビルディング

E-mail: [†] [‡] {kasahara, t_ito, tsuru, komatsu}@kom.comm.waseda.jp, *hideki.yoshii@tm.softbank.co.jp

あらまし 本稿では、携帯端末に搭載された 3 軸加速度センサを用いて、通常歩行（平地）、階段上り、階段下りの 3 種類の歩行状態の識別手法について述べる。提案する手法では、歩行状態の周期性に着目することを特徴としており、当該周期に基づいたウィンドウサイズを用いて特徴量を抽出する。さらに音声処理で用いられる分析手法である LPC ケプストラムを歩行の周期データに適用して単なる歩行周期の平均や分散といった統計量と比較を行うことで提案手法の有効性を評価した。

キーワード 加速度センサ, 歩行状態, パターン認識, LPC ケプストラム

A Study on the Walking States Classification Method using Cycles of Acceleration Data

Hiroki KASAHARA[†] Tomonori ITO[†] Hideki YOSHII*

Kazuhiro TSURUMARU[†] and Naohisa KOMATSU[‡]

[†] Faculty of Science and Engineering, Waseda University

[‡] Advanced Research Institute For Science And Engineering, Waseda University

3-4-1 Ohkubo, Shinjuku-ku, Tokyo, 169-8555 Japan

*SOFTBANK TELECOM Corporation

Tokyo Shiodome Building 1-9-1 Higashi-shimbashi, Minato-ku, Tokyo, 105-7316 Japan

E-mail: [†] [‡] {kasahara, t_ito, tsuru, komatsu}@kom.comm.waseda.jp, *hideki.yoshii@tm.softbank.co.jp

Abstract In this paper, we propose a method that classifies walking condition into three states, walking on the flat ground, going up stairs and going down, using a three dimensional acceleration sensor in a smart phone. In our approach, we focused on periodicity of a walking step and investigated statistical particularity of walking condition, such as average and dispersion, based on this periodicity. Also, we applied the LPC cepstrum into this classification and evaluated with typical statistical values.

Keyword acceleration sensor, walking states, pattern recognition, LPC cepstrum

1. まえがき

近年、携帯端末は端末の普及や高度化に伴い、単なる情報発信・情報収集に加えて生活や行動を支援する高機能ツールとして発展してきた。最近では、利用者のネット内外の活動記録であるライフログを活用し、利用者の属性情報に応じたコンテンツや広告を提供するサービスの進展に期待が集まっている。筆者らは、

携帯端末から取得したセンサ情報（位置、加速度、地磁気など）から人の移動に関わる情報（移動経路、移動手段など）や、本人確認情報（歩き方など）を把握し、複合的に分析することで新しいサービスの提供を目指している。

センサ情報からユーザの行動状態を識別する研究はこれまで数多くなされてきている[1][2]、小林ら[3]

は加速度センサ，GPS，マイクを複合的に使用し，パワースペクトルの尤度などを見ることで歩行，走行，停止，バス，車，自転車の計7種類の移動状態を概ね80%程度で識別できると示している．ここで，どの特徴量を元に識別を行うかということは非常に重要なことであり，この特徴量が最適であるという決定的なものはないのが現状である．白井ら[5]は，特徴量として音声処理で用いられる分析手法であるLPCケプストラム[6]が平均や分散といった統計量と比較して歩行状態の識別に有効である可能性を示した．そこで本検討では，LPCケプストラムの有効性について再度検討し，さらに歩行の周期性に着目し，当該周期に基づいたウィンドウサイズを用いて特徴量を抽出する．また，ベクトル量子化による識別手法を採用し定量的な評価を行った．なお，本検討の識別対象の行動は通常歩行（平地），階段上り，階段下りの3種類の歩行状態に絞り，使用するセンサを携帯端末に搭載された3軸加速度センサのみとした．

2. 提案手法

2.1. 識別器の設計

本検討では，パターン認識技術を用いた識別器を設計し，歩行状態の識別精度を評価した．パターン認識とは，入力したパターン（文字画像や時系列記号，センサから得た情報など）が予め定めたクラスのうちのどのクラスに対応するかを出力する処理である[7]．パターン認識による歩行状態識別システムを構成する場合，一般的に図1の形式が用いられる．

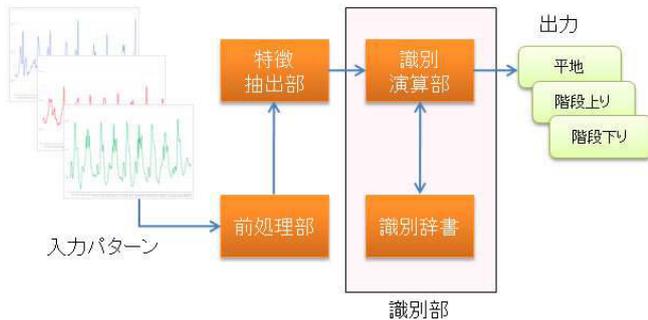


図1 認識系

前処理部では特徴を抽出しやすい形に出力し，特徴抽出部にて特徴の算出を行う．この特徴を事前にいくつかの歩行データから作成した識別辞書（コードブック）と比較することで，入力パターンがどの歩行状態に属するかを決定する．識別器の設計において，特徴抽出部は特に重要であり，認識系の性能を大きく左右する．また，特徴抽出方法によって，特徴空間における各歩行状態の分布の様子が変化する．このため，歩行データから歩行状態を適切に分類できる特徴を抽出

する必要があり，特徴量の性質や特徴空間での分布を明確にすることが望ましい．そこで，本検討では様々な手法により抽出した特徴量を評価した．

2.2. ケプストラム分析

ケプストラムは，波形の短時間振幅スペクトルの対数の逆フーリエ変換として定義され，スペクトルの包絡と微細構造を近似的に分離して抽出できるという特徴がある．スペクトル包絡は，時間波形における大局的な特徴を表し，微細構造は，時間波形における基本周期を表す．ここで，歩行データの時間波形を，2つの記号 $g(t)$ ， $h(t)$ で表すことを考える．ここで， $g(t)$ は周期信号であり， $h(t)$ はインパルス応答である．歩行データの時間波形を $x(t)$ とすると， $x(t)$ は，これら2つの信号の畳み込みで次のように与えられる

$$X(\omega) = G(\omega) \cdot H(\omega) \quad (1)$$

ただし， $X(\omega)$ ， $G(\omega)$ ， $H(\omega)$ はそれぞれ $x(t)$ ， $g(t)$ ， $h(t)$ のフーリエ変換である．また，この対数変換は次の式で表される．

$$\log|X(\omega)| = \log|G(\omega)| + \log|H(\omega)| \quad (2)$$

(2)式の右辺第1項は，スペクトルの微細構造を意味し，右辺第2項は，スペクトル包絡を意味する．このため，両者の逆フーリエ変換（ケプストラム）を取ることで，高次部分に基本周期が，低次部分にスペクトル包絡がそれぞれ表れ，フィルターを使用することで，基本周期とスペクトル包絡を分離できる．

2.3. LPC ケプストラム

線形予測分析（LPC）は，離散時間係において，ある時点の値がそれ以前のいくつかの値の線形結合で表現できるという仮定に基づき波形を予測するものである．時間離散的信号 x_t (t : 整数) において，現時点の標本値 x_t ，これに隣接する過去の p 個の標本値との間の線形予測値を \hat{x}_t とすると， \hat{x}_t は次のように表される．

$$\hat{x}_t = \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + \dots + \alpha_p x_{t-p} \quad (3)$$

線形予測係数 α は，標本値 x_t と線形予測値 \hat{x}_t の間の誤差が最小となるように定める．このLPCに基づいて予測した波形モデルは，次のようなスペクトルで表される．

$$H(z) = \frac{1}{1 + \sum_{i=1}^p \alpha_i z^{-i}} \quad (4)$$

LPCケプストラム分析では，この予測波形モデルを信号のスペクトル密度とみなし，

$$X(\omega) = H(z)|_{z=e^{j\omega}} d\omega \quad (5)$$

とおいたときのケプストラムを算出する．ケプストラム係数を C_n とすると， C_n は次のように表される．

$$C_n = \frac{1}{2\pi} \int_0^{2\pi} \log|X(\omega)| e^{in\omega} d\omega \quad (6)$$

LPCケプストラム分析では，LPCによる線形波形モ

デルに対してケプストラム分析を行うため、元の波形に対するケプストラム分析よりも、スペクトルのピーク特性が抽出しやすいという利点がある。本検討では、歩行データの特徴量として、このLPCケプストラム係数を用いた。図2、図3に歩行データの波形 $x(t)$ の一例とスペクトル $X(\omega)$ 、スペクトル包絡 $H(\omega)$ の一例を示す。

スペクトルの微細構造は、歩行データの時間波形における周期情報を表す。また、微細構造は、細かく変動する要素で、歩行データの取得時間や取得環境などの違いによる影響を受けやすい。一方、スペクトル包絡は、歩行データの時間波形における振幅情報を表すため、各歩行状態の特徴が歩行データの振幅情報に表れる場合、スペクトル包絡を用いることが有効である。また、スペクトル包絡は、周波数に比例して緩やかに変化する要素でもある。このため、スペクトル包絡は、歩行データの取得時期や取得環境などの違いによる影響を受けづらい。さらに、LPCケプストラムは、スペクトルのピーク部分を考慮したスペクトル包絡であり、安定した特徴を抽出することができる。以上から本検討ではLPCケプストラムによる特徴量に着目した。

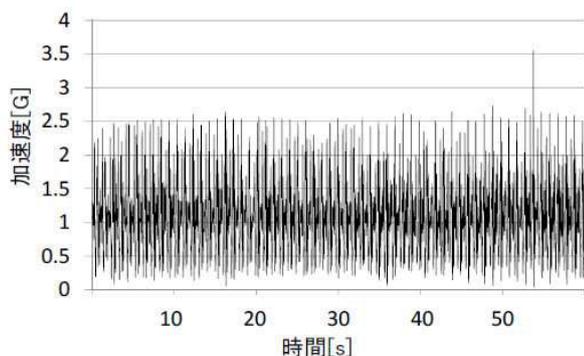


図2 歩行データの波形

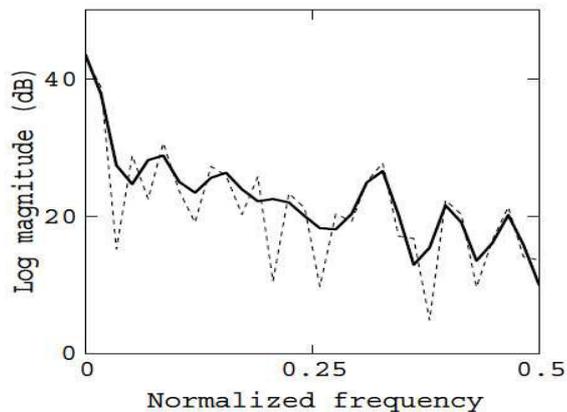


図3 スペクトル(破線)とスペクトル包絡(実線)例

3. 評価概要

3.1. 取得した歩行データ

表1に取得実験の諸元を示す。平地、階段上り、階

段下りの3種類の歩行状態について各100秒間、3軸加速度センサ(iPhone3GS)を用いてデータを取得した。サンプリング周波数は100Hz(0.01秒毎に計測)とし、階段については踊り場も含めて計測を行った。本検討では、各歩行状態から抽出される特徴量に着目するため、センサは右腰に固定して取得を行い、歩行者による違いも検討する必要があると考え、5人の被験者でデータ取得を行った。

表1 実験諸元

日時	2010年11月12日15時
天候	晴れ
使用端末	iPhone3GS
サンプリング周波数	100HZ
センサ装着位置	右腰に固定
測定データ	平地, 階段上り, 階段下り
取得秒数	各地形100秒間(1人あたり)
被験者数	5人

ここで、加速度センサを腰などに固定し、あらかじめセンサがどの向きにあったか分かる場合は x , y , z の3軸がそれぞれどの方向を指しているのか分かるが、もしセンサがどの向きにあったか分からない場合は、軸が持つ向きの情報が失われてしまう。そこで、図4のように x , y , z の3軸を合成した値 r を見ることで、センサが受けた加速度の大きさだけが情報として残り、センサの保持状態に関わらず行動状態を識別することを目標としているため、この合成後の値に着目する。

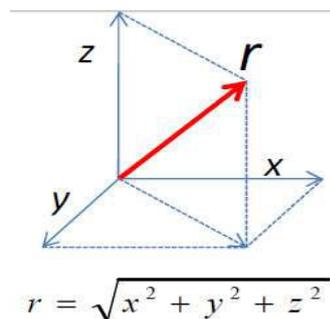


図4 3軸の値の合成方法

3.2. ウィンドウサイズ

ウィンドウサイズとは特徴量を抽出するために必要なデータ数のことである。歩行状態識別を実際にサービス化することを考えると、可能な限りリアルタイムな識別が必要となる。

3.2.1. 従来のウィンドウサイズ

従来の行動状態識別等の研究では主にデータ数(時間)単位でウィンドウサイズを決定し特徴量を抽出している研究が多くある。しかし、時間をウィンドウサイズの単位とすることで、ユーザの歩調の違いの影響を

受け、特徴量の分布に分散を生じさせてしまい、識別率の低下につながる考えた。

3.2.2. 提案するウィンドウサイズ

歩行データの周期性に着目し、当該周期に基づいたウィンドウサイズを用いて特徴量を抽出する。本検討では、ウィンドウサイズの境界を一定時間内の3軸合成加速度の最大値として、1つのウィンドウサイズを1歩と定義した。しかし、検出されたウィンドウサイズに含まれるデータ数はその都度変化してしまう。特徴量を抽出する上でデータ数を統一する必要があるため、本検討では線形補間を行うことで、1歩に含まれるデータ数を128データとした。歩数を単位として特徴量を算出することで、ユーザの身体的特徴等により変化する歩調の影響を少なくし、ユーザに依存しない特徴量が抽出できると考えた。

3.3. 特徴量

3.3.1. 従来の統計量

LPC ケプストラムとの比較のために、従来研究で用いられてきた特徴量（平均値、標準偏差、最大値、最小値、パワースペクトルの最大値、パワースペクトルの平均値、パワースペクトルの標準偏差）についても算出を行う。本検討で用いる特徴量と本稿で用いる特徴量番号の対応表を表2に示す。

表 2 特徴量対応表

①	平均値
②	標準偏差
③	最大値
④	最小値
⑤	パワースペクトルの最大値
⑥	パワースペクトルの平均値
⑦	パワースペクトルの標準偏差

3.3.2. LPC ケプストラム

3軸合成後の歩行データに対してLPCケプストラムを算出した。LPCケプストラムを算出する際には、LPC及びケプストラムの次元数、窓掛けや正規化の有無を定める必要がある。本検討ではいくつかの次元数についてLPCケプストラムを算出し、比較を行う。また、窓掛け・正規化の有無についても比較を行う。

3.4. 評価方法

3.3で挙げた8種類の特徴量を用いて識別器を構成し、特徴量ごとの識別率（TPR:True Positive ratio）を算出した。識別を行うためには、学習データと識別データを用意する必要がある。そこで、平地、階段上り、階段下りの各100間のデータをそれぞれ50秒間ずつに分け、それぞれ学習データと識別データの役割を変えることで識別を行った（クロスバリデーション）。学習

段階では、50秒ずつのデータセットに対して任意の特徴量を抽出し、LPG+Splittingアルゴリズムを用いたベクトル量子化[8]を行うことで、各歩行状態の特徴を表すコードブックを作成する。次に識別段階として、残りの50秒ずつのデータセットの各データを量子化した際の量子化誤差を歩行状態ごとに比較した。その際、対象と同じ歩行状態のコードブックとの量子化誤差が各歩行状態の中で最小の場合に正解とした。これを学習データと識別データの役割を入れ替えたものに対してもう一度行い、その合計結果の平均を最終的な結果として示した。

ここで、ベクトル量子化とは、入力データを任意個の代表パターン（コードブック）の値で近似する処理であり、LBG+Splittingアルゴリズムは、適当なコードブックから開始し、学習系列に分割条件と代表点条件を繰り返し適用することで良好なコードブックに収束させるコードブック設計アルゴリズムである。ベクトル量子化による評価手法は特徴量の順番を考慮しないため、今回は表2の特徴量とLPCケプストラムを順序に関係のない連続入力データとして扱った。このコードブックを用いて、同一歩行状態間と異なる歩行状態間における量子化誤差を算出したときに、量子化誤差が同一歩行状態間で小さく、異なる歩行状態間で大きくなる特徴量は歩行状態を分類する上で有効であると考えられる。本検討では評価指標として次式で示されるTPRを用いた。

$$TPR = \frac{\text{正しく識別できた数}}{\text{総データ数}} \times 100 \quad [\%] \quad (7)$$

4. 評価結果

4.1. LPC ケプストラムのパラメータ調査

LPCケプストラムを算出するためにはLPC及びケプストラムの次元数と窓掛け及び正規化の有無を定める必要がある。そこでLPC及びケプストラムの次元数、窓掛け及び正規化の有無による識別率の違いについて比較を行った。本検討では窓関数としてはハミング窓を採用した。被験者一人に対してLPCケプストラムを算出した識別結果を表3に示す。なお、ベクトル量子化時のレベル数は32とした。

表 3 LPC ケプストラムによる識別結果

	次元数				
	5	10	20	30	40
窓掛け・正規化なし	73%	87%	90%	95%	94%
窓掛け・正規化あり	73%	88%	91%	98%	98%

表3より次元数による違いに着目すると5次元のような低次元の場合より、30次元といったような高次元における識別率が高い結果を示した。また、窓がけ及

び正規化の有無については、処理をした場合に若干識別率が上がっていることが分かる。以降の検討では、ウィンドウサイズや他の特徴量との比較を行うため、次元数を 30 次元、窓掛け及び正規化ありとして LPC ケプストラムを算出することとする。

4.2. LPC ケプストラムの有効性

4.1 においては被験者 1 人の歩行状態ごとにコードブックを作成し、その被験者の識別データを用いて識別を行った。実際にアプリケーションとして実装する際には、キャリブレーションをすることで、個人ごとの差を埋めることが可能と考えられるが、多くの人に共通するコードブックを作成し、識別を行うのが理想である。そこで、5 人分の被験者データを歩行状態ごとに結合し、被験者共通のコードブック及び識別データを作成し、識別を行った。なお、ウィンドウサイズを 256 データ、スライド幅を 50 として各特徴量を抽出した。表 4 に特徴量ごとの識別結果を示す

表 4 特徴量ごとの識別結果(%)

	特徴量							LPC
	①	②	③	④	⑤	⑥	⑦	
識別率	53	69	64	61	56	59	64	86

表 4 が示すように、LPC ケプストラムは他の特徴量に比べて高い識別率を示していることが分かり、歩行状態を識別するのに有効な特徴量であると考えられる。ここで、同じ特徴量でも、被験者によって特徴分布に差が生まれていることが考えられる。加速度の標準偏差のヒストグラムを図 5、図 6 に示す。図 5 は一人の被験者の標準偏差のヒストグラム、図 6 は図 5 の被験者とは異なる被験者の標準偏差のヒストグラムを示したものである。これを見ると、図 5 に示す被験者では平地、階段上り、階段下りの分布がきれいに分かれているのに対し、図 6 に示す被験者では平地と階段下りが重なってしまっているのがわかる。このように被験者によって、歩行状態ごとの特徴量の分布の仕方が異なっているため、被験者を増やすとともに、識別率が低くなってしまうことが考えられる。どの被験者に対しても分布がきれいに分かれている特徴量を調査する必要がある。

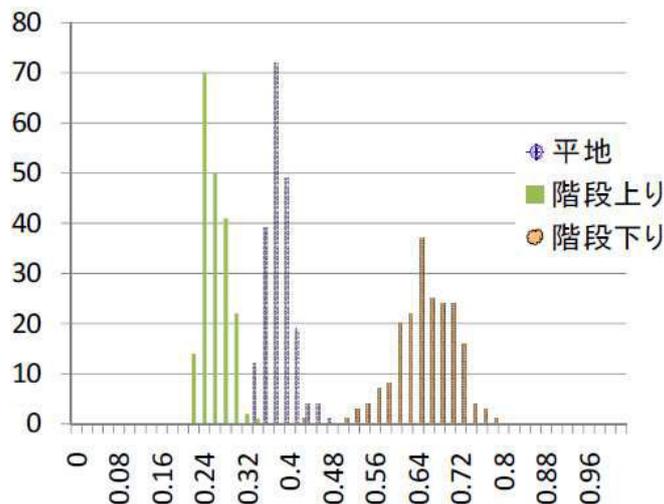


図 5 標準偏差によるヒストグラム

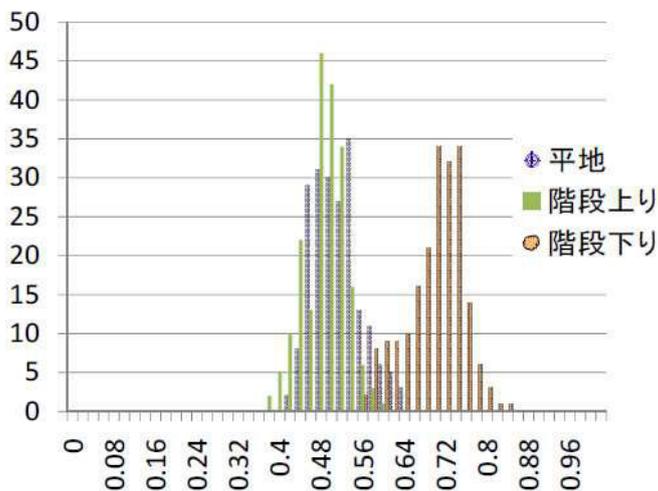


図 6 標準偏差によるヒストグラム

表 5 ウィンドウサイズごとの識別結果

		ウィンドウサイズ			
		データ数		歩数	
		64	128	1 歩	2 歩
特徴量	①	75%	65%	53%	58%
	②	70%	73%	68%	70%
	③	67%	73%	64%	70%
	④	57%	71%	56%	64%
	⑤	67%	71%	58%	67%
	⑥	71%	71%	68%	68%
	⑦	64%	79%	62%	70%
	LPC	86%	87%	62%	61%

4.3. 提案するウィンドウサイズの有効性

従来用いられているデータ数(時間)を単位としたウィンドウサイズで特徴量を抽出した場合と、本検討で提案する歩行の周期性に着目した歩数を単位としたウィンドウサイズで特徴量を抽出した場合についての比

較を行う。データ数単位とした場合は 64 データ, 128 データを, 歩数単位とした場合は 1 歩, 2 歩をウィンドウサイズとして特徴量を抽出し, 識別率を算出した。なお, スライド幅はウィンドウサイズと同じとした。表 5 にウィンドウサイズごとの識別率を示す。

表 5 が示すように, データ数単位をウィンドウサイズとして LPC ケプストラムを算出し, 識別した場合に識別率が高くなっている。しかし, 歩数単位をウィンドウサイズとした場合には LPC ケプストラムによる識別の識別率が他の従来の特徴量と同等になっており, データ数をウィンドウサイズとした場合と比べて大幅に識別率が低下している。これは, 歩行データを線形補間して正規化することにより, 時間軸の情報が失われてしまったために識別率が低下したと考えられる。従来の特徴量に関してはウィンドウサイズを歩数単位とした場合, 若干データ数単位とした場合に比べて低くなるが, 大きな変化は見られなかった。

5. まとめと今後の検討課題

5.1 まとめ

本検討では携帯端末の加速度センサから取得されるデータを用いて, 平地や階段上りといった歩行状態を識別する手法を提案し, その評価を行った。歩行の周期性に着目し, 歩数を単位とするウィンドウサイズによる特徴量の抽出の有効性の検討を行った。従来研究でしばしば用いられている統計量をベースとした特徴量の他に, 音声処理で用いられる LPC ケプストラムの適用を提案し, その有効性をベクトル量子化による定量的な評価手法で評価した。

統計量の特徴量とした場合では, 被験者ごとに識別率にばらつきが見られ, どの被験者にも高い識別率を示すようなものはなかった。しかし, LPC ケプストラムを特徴量とした場合にどの被験者に対しても高い識別率を示す結果となった。LPC ケプストラムが従来の特徴量を特徴量とした場合と比べて有効である可能性を確認できた。

ウィンドウサイズを歩数単位とした場合では, データ数を単位とした場合に比べて, 従来の特徴量を特徴量とした場合には識別率に大きな変化は見られなかったが, LPC ケプストラムを特徴量とした場合には大きく識別率が低下した。LPC ケプストラムを歩行状態識別の特徴量として用いる場合にはウィンドウサイズを歩数単位とするよりも, 従来の特徴量とした方がよいと考えられる。

5.2 今後の検討課題

本検討で使用したデータを取得するにあたり, すべて同じ日に同じ場所(平地, 階段上り, 階段下り)で計測を行った。階段にも段差の高さや幅によって取得

されるデータは異なると考えられる。また, 被験者による違いはもちろんであるが, 同じ被験者でも服装の違いなどから毎回同じデータになるとは限らない。そこで, そのような環境による誤差がどの程度存在するのか, 本検討で行ったような定量的な評価を行うことで確認する必要がある。

また, 本検討では, ウィンドウサイズをデータ数単位とすることと, 時間単位とすることの違いを明確にするためにウィンドウサイズをなるべく小さくして識別を行った。今後はウィンドウサイズを大きくすることで識別率がどのように変わるか検討を行う。また, 被験者を様々な身体的特徴(身長, 性別など)をもつ人を対象とし, 多人数の歩行データを用いた場合の提案手法の有効性について検討を行う。

文 献

- [1] Bao and Intille, "Activity recognition from user-annotated acceleration data," *Pervasive* 2004.
- [2] Sasank Reddy, "Using mobile phones to determine transportation modes," *ACM Transactions on Sensor Networks(TOSN 2010) vol.6 (2)*.
- [3] 小林亜令, 岩本健嗣, 西山智, "釈迦: 携帯電話を用いたユーザ移動状態推定・共有方式," *情報処理学会研究報告, vol.108, no.44, pp.115-120, 2008*.
- [4] 磯俊樹, "パターン認識技術に基づくコンテキスト利用型ユビキタスサービスシステムの研究," *NTT ドコモ, 2008*.
- [5] 白井隼人, 笠原弘樹, 伊藤智則, 吉井英樹, 小松尚久, "加速度データの LPC ケプストラムを用いた歩行状態の識別に関する一考察," *電気情報通信学技術研究報告, Vol.110, no.450, pp.119-124, 2011*.
- [6] 古井貞熙, "デジタル音声処理," *東海大学出版会, 1998*.
- [7] 石井健太郎, 上田修功, 前田英作, 村瀬洋, "わかりやすいパターン認識," *オーム社, 1998*.
- [8] Y.Linde, A.Buzo and R.M.Gray, "An Algorithm for Vector Quantizer Design," *IEEE Trans, Commun., Vol.COM28, No.1, pp88-95, 1980*.

携帯端末のセンサ情報を用いた個人認証に関する検討

笠原 弘樹[†] 市野 将嗣[‡] 吉井 英樹^{*}

鶴丸 和宏^{††} 甲藤 二郎[†] 小松 尚久[†]

[†] 早稲田大学理工学術院基幹理工学研究所

^{††} 早稲田大学理工学研究所

〒169-8555 東京都新宿区大久保 3-4-1

[‡] 電気通信大学 大学院情報理工学研究科総合情報学専攻 〒182-0021 東京都調布市調布ヶ丘 1-5-1

*ソフトバンクテレコム株式会社 〒105-7316 東京都港区東新橋 1-9-1

E-mail: [†] {kasahara,tsuru,komatsu}@kom.comm.waseda.ac.jp, [‡] ichino@inf.uec.ac.jp

*hideki.yoshii@tm.softbank.co.jp, [†] katto@katto.comm.waseda.ac.jp

あらまし 本稿では、携帯端末の搭載されたセンサ情報を用いて、個人認証を行う手法について述べる。初めに歩行動作において得られる加速度データに個人による違いが表れることを確認し、平均や標準偏差などの従来研究で用いている特徴量が有効であるかを確認した。さらに、個人認証における特徴量として、音声処理でよく用いられLPC ケプストラムを用いることの有効性を評価した。

キーワード 加速度センサ, 個人認証, パターン認識, LPC ケプストラム

A Study on the Personal Authentication Using Sensor Data of Mobile Terminal

Hiroki KASAHARA[†] Masatsugu ICHINO[‡] Hideki YOSHII^{*}

Kazuhiro TSURUMARU^{††} Jiro KATTO[†] and Jiro TSUSHIN[†]

[†] Graduate school of Fundamental Science and Engineering, Waseda University

^{††} Advanced Research Institute For Science And Engineering, Waseda University

3-4-1 Ohkubo, Shinjuku-ku, Tokyo, 169-8555 Japan

[‡] Department of Informatics, Graduate School of Informatics and Engineering, The University of
Electro-Communications 1-5-1 Chofugaoka, Chofu-shi, Tokyo, 182-8585 Japan

*SOFTBANK TELECOM Corp. 1-9-1 Higashishimbashi, Minato-ku, Tokyo, 105-7316 Japan

E-mail: [†] {kasahara,tsuru,komatsu}@kom.comm.waseda.ac.jp, [‡] ichino@inf.uec.ac.jp

*hideki.yoshii@tm.softbank.co.jp, [†] katto@katto.comm.waseda.ac.jp

Abstract In this Paper, we propose a method of personal authentication, using sensor data of a mobile terminal. First, we check the individual difference of acceleration data in the walking action and investigate the validity of the features used by conventional researches such as average and standard variation. We then apply the LPC cepstrum, which had been widely utilized in speech processing into this authentication task and check its validity.

Keyword acceleration sensor, personal authentication, pattern recognition, LPC cepstrum

1. まえがき

近年、携帯端末は急速に普及し、単なる情報発信・情報収集に加えて生活や行動を支援する高機能ツールとして発展してきた。最近では、利用者のネット内外の活動記録であるライフログを活用し、利用者の属性

情報に応じたコンテンツや広告を提供するサービスの進展に期待が集まっている。筆者らは、携帯端末から取得したセンサ情報（位置、加速度、地磁気など）から人の移動に関わる情報（移動経路、移動手段など）や、本人確認情報（歩き方など）を把握し、複合的に

分析することで新しいサービスの提供を目指している。

携帯端末には、スケジュールや電話帳などの様々な個人情報や、電子商取引などで用いる情報鍵などが記録されており、端末の紛失によりそれらの情報が他人に悪用される危険性がある。これらの情報を保護するために、一般的にはパスワードや物理的なキーが用いられているが、情報を参照するたびに、煩雑な動作を行う必要があるため、パスワードや物理的なキーを設定しない原因にもなっている。本検討では、携帯端末向けの認証手法として、人物の歩行時のセンサ情報を用いた歩行認証を提案する。

2. 提案手法

2.1. 歩行時の加速度データ

携帯端末はユーザが日常的に所持するものであり、常に携帯端末に搭載されているセンサでユーザの行動によるセンサ情報が取得されている。近年、監視システムやアクセスコントロールのための個人認証システムとして歩容認証が検討されている[1]。カメラから得られる画像を処理することで、個人の認証が可能であることが示されており、歩き方は個人によって異なることが確認されている。そこで本検討では、個人の歩き方の違いが歩行中の加速度に表れると考え、所持している携帯端末の加速度センサから得られる加速度データに着目した。

携帯端末に搭載されている3軸加速度センサから取得される歩行における加速度データを図1に示す。本検討では、端末を腰に固定して加速度を取得しているため、x, y, zの3軸がそれぞれどの方向を指しているのか分かるが、もしセンサがどの向きにあったかわからない場合は、軸が持つ向きの情報が失われてしまう。そこで、式(1)を用いて3軸合成した値rを求め、センサが受けた加速度の大きさをを用いて評価を行う。図1に示した3軸の加速度データに対して式(1)を用いて合成した3軸合成加速度データを図2に示す。

$$r = \sqrt{x^2 + y^2 + z^2} \quad (1)$$

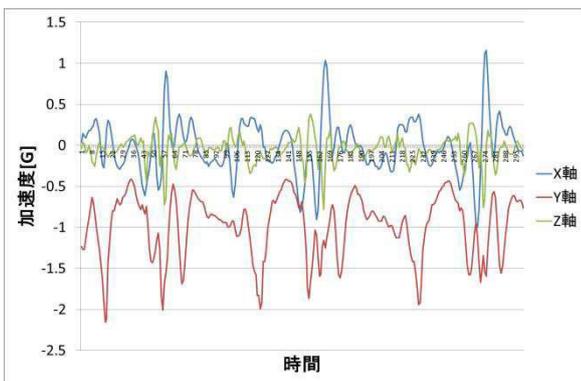


図1 加速度センサから取得されるデータ

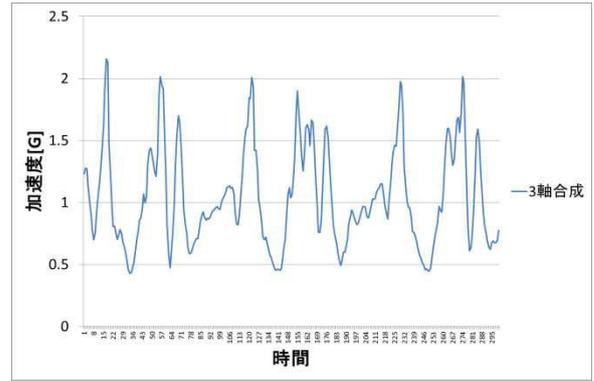


図2 3軸合成加速度

2.2. 従来研究

歩行における加速度データを用いて個人認証や個人識別を行っている研究では、平均値や標準偏差、歩調を特徴量として用いる研究なされている[2][3][4]。Jenniferら[3]の研究においては各軸の平均値や標準偏差、平均絶対値や歩調などを用いて、約90%の認証率が得られている。しかし、これらの特徴量については、認証確率のみを評価しているが、個人認証に対しての特徴量の有効性については確認していない。そのため、当該特徴量が個人性を適切に抽出できているか確認する必要がある。特徴空間において本人データ同士は近く、他人データ同士は離れるような特徴量が有効であるので、まず特徴空間上での分布を確認する必要があると考えた。また、白井ら[2]の研究において、個人を識別する特徴量として、LPCケプストラムが有効である可能性が示されており、また、伊藤ら[5]の研究において歩行状態の識別にLPCケプストラムが有効であることが示されている。ケプストラム分析は、スペクトルの微細構造とスペクトル包絡を分離して抽出できる。スペクトルの微細構造は、歩行データの時間波形における周期情報を表わす。微細構造は、細かく変動する要素で、歩行データの取得時期や取得環境などの違いによる影響を受けやすい。一方スペクトル包絡は歩行データの時間波形における振幅情報を表わすため、個人毎の特徴が歩行データの振幅情報に表れる場合、スペクトル包絡を用いることが有効であると考えた。スペクトル包絡は、周波数軸上に緩やかに変化する要素でもある。このため、スペクトル包絡は、歩行データの取得時期や、取得環境の影響を受けづらい。以上から、スペクトル包絡を抽出できるケプストラム分析による特徴量が有効であると考えた。

そこで本稿では、従来の特徴量が個人性を抽出できているかを評価するために、特徴空間上で本人と他人との分布が明確に分かれているかを確認し、さらに従来の特徴量と比較することにより、筆者らが提案しているLPCケプストラムを歩行認証に用いる有効性を

評価した結果を報告する。

2.3. 認証システム

本検討では、パターン認識技術を用いて、図3のような認証システムを設計し、個人認証の認証能力を評価した。

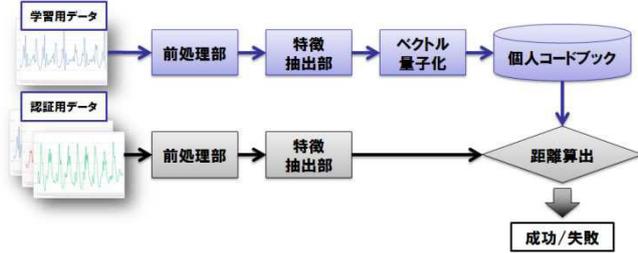


図3 認証システム

前処理部では、3軸加速度を合成して特徴量を抽出しやすい形に変換し、特徴抽出部にて特徴の算出を行う。学習時には、事前にいくつかの歩行データから特徴量を抽出し、ベクトル量子化を用いて個人毎のコードブックを作成する。照合時には、入力された歩行データから特徴を抽出し、各コードブックとのユークリッド距離 d を式(2)によって算出し、最小となるユークリッド距離を求める。ただし、 n は特徴量の次元数、 c は個人コードブック、 v は認証用データとする。認証システムにおいて、特徴抽出部は特に重要であり、認証性能を大きく左右する。そこで本検討では、特徴量の特徴空間上での分布の様子を調べるとともに個人コードブックとのユークリッド距離を比較することにより特徴量を評価した。

$$d = \sqrt{\frac{1}{n} \sum_{i=1}^n (c_i - v_i)^2} \quad (2)$$

3. LPC ケプストラム

入力信号を $x(t)$ とした場合、ケプストラム(cepstrum)は、短時間振幅スペクトル $X(\omega)$ の対数の逆フーリエ変換として定義され、スペクトル包絡と微細構造を近似的に分離して抽出できる特徴がある。スペクトル包絡は、時間波形における大局的な特徴を表し、微細構造は、時間波形における基本周期を表す。そこで、歩行データの時間波形 $x(t)$ を、2つの信号 $g(t)$ と $h(t)$ で表わすことを考える。ただし、 $g(t)$ は周期信号であり、 $h(t)$ はインパルス応答である。 $x(t)$ はこれらの2つの信号の畳み込みとして次の式(3)のように与えられる。

$$x(t) = \int_0^t g(\tau)h(t-\tau)d\tau \quad (3)$$

$$X(\omega) = G(\omega) \cdot H(\omega) \quad (4)$$

ただし、 $X(\omega)$ 、 $G(\omega)$ 、 $H(\omega)$ はそれぞれ $x(t)$ 、 $g(t)$ 、 $h(t)$ のフーリエ変換である。また、この $X(\omega)$ の対数変換は

$$\log|X(\omega)| = \log|G(\omega)| + \log|H(\omega)| \quad (5)$$

となる、右辺第1項は、スペクトル上の微細構造、すなわち比較的細かい周期のパターンであり、右辺第2項は、スペクトル包絡、すなわち周波数による変化のゆるやかなパターンを表わす。逆フーリエ変換した際に、高ケフレンシー部のみを用いてフーリエ変換することによってスペクトル包絡が求まる。

線形予測分析(LPC)は、離散時間系において、ある時点の値がそれ以前のいくつかの値の線形結合で表現できるという仮定に基づき波形を予測するものである。時間離散的信号 $x_t(t: \text{整数})$ において、現時点の標本値 x_t 、これに隣接する過去の p 個の標本値との間の線形予測値を \hat{x}_t とすると、 \hat{x}_t は次の式(6)のように表される。

$$\hat{x}_t = \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + \dots + \alpha_p x_{t-p} \quad (6)$$

線形予測係数 α は、標本値 x_t と線形予測値 \hat{x}_t の間の誤差が最小となるように定める。このLPCで求めた線形予測係数を次式に代入する。

$$H(z) = \frac{1}{1 + \sum_{i=1}^p \alpha_i z^{-i}} \quad (7)$$

LPC ケプストラム分析では、この予測波形モデルを信号のスペクトル密度とみなし、 $H(\omega) = H(z)|_{z=e^{j\omega}}$ とおいたときのケプストラムを算出する。このため、ケプストラム分析を算出する課程にあるDFT, 対数変換, IDFTをそれぞれ両側 z 変換, 複素対数, 逆両側 z 変換でおきかえることによって、ケプストラムの概念を複素ケプストラムの概念に拡張する。LPC ケプストラムは線形予測係数 α から次式で求まる。

$$\begin{cases} c_1 = -\alpha_1 \\ c_n = -\alpha_n - \sum_{m=1}^{n-1} \left(\frac{m}{n}\right) c_m \alpha_{n-m} \quad (1 < n \leq p) \\ c_n = -\sum_{m=1}^p \left(\frac{m}{n}\right) c_m \alpha_{n-m} \quad (p < n) \end{cases} \quad (8)$$

ただし、 p は、LPC 係数の数を表わす。

LPC ケプストラム分析では、LPC による線形波形モデルに対してケプストラム分析を行うため、元の波形に対するケプストラム分析よりも、スペクトルのピーク特性が抽出しやすいという利点がある。本検討では、歩行データの特徴量として、このLPC ケプストラム係数を用いた。

4. 評価実験

4.1. 実験概要

表1に取得実験の諸元を示す。3軸合成加速度センサ(iPhone3GS)を用いて被験者5名についてデータを取得した。サンプリング周波数は100Hz(0.01秒毎に計測)とした。

表 1 実験諸元

日時	2010年11月12日15時
天候	晴れ
使用端末	iPhone3GS
サンプリング周波数	100HZ
センサ装着位置	右腰に固定
取得秒数	100秒間(1人あたり)
被験者数	5人

4.2. 特徴量

4.2.1. 従来の特徴量

従来研究で用いられてきた特徴量(平均値, 標準偏差, 最大値, 最小値, パワースペクトルの最大値, パワースペクトルの平均値, パワースペクトルの標準偏差)について評価を行う. 本検討で用いる特徴量番号の対応表を表2に示す. 本検討では, ウィンドウサイズは200サンプル, スライド幅は50サンプルとして特徴量を抽出する. 例えば, 表2の平均値とはウィンドウ内にある200サンプルの平均値を意味する.

表 2 特徴量対応表

①	平均値
②	標準偏差
③	最大値
④	最小値
⑤	パワースペクトルの最大値
⑥	パワースペクトルの平均値
⑦	パワースペクトルの標準偏差

4.2.2. LPC ケプストラム

3軸合成後の加速度データに対してLPCケプストラムを算出した. LPCケプストラムを算出するには, LPC及びケプストラムの次元数, 窓かけや正規化の有無を定める必要がある. 白井ら[2]の研究において, 次元数が30次元, 窓かけ・正規化ありの場合が最も識別率が高かったため, 本検討においても, 次元数を30次元, 窓かけ・正規化ありとした. また, ウィンドウサイズを256サンプル, スライド幅を50サンプルとしてLPCケプストラムを算出して評価を行った.

4.2.3. 評価方法

4.2で挙げた, 従来用いられている特徴量7種類に, LPCケプストラムを加えた計8種類の特徴量を用いて, それぞれ個人毎のコードブックを作成し, 認証用データと個人コードブックとの距離を算出することで特徴量の評価を行う. 学習時には, 任意の被験者の全データ(100秒間)の中の半分(50秒間)のデータに対して, 各特徴量を抽出し, 特徴量毎にLBG+Splittingアルゴリズムを用いたベクトル量子化を行うことで, 個

人毎のコードブックを作成する. ベクトル量子化とは, 入力データを任意個の代表パターン(コードブック)の値で近似する処理であり, LBG+Splittingアルゴリズムは, 適当なコードブックから開始し, 学習系列に分割条件と代表点条件を繰り返し適用することで良好なコードブックに収束させるコードブック設計アルゴリズムである. 本稿では, ベクトル量子化レベルは2,4,8,16,32とした. 次に認証段階として, 認証用の入力データからウィンドウ毎に特徴量を算出し, 個人コードブックとのユークリッド距離を算出した. このコードブックを用いて, 1データ(ウィンドウ)毎に本人-本人間と, 本人-他人間のユークリッド距離を算出した際に, 本人-本人間距離が小さく, 本人-他人間距離が大きくなる特徴量が個人を認証する上で有効であると考えられる.

5. 評価結果

5.1. 従来の特徴量

4.2で挙げた7種類の特徴量についてユークリッド距離を算出した. 認証用の入力データは本人のデータが100データ, 他人のデータが800データあり, 1データずつ距離を算出する. 任意の被験者の加速度の平均値・標準偏差を用いて算出したユークリッド距離のヒストグラムを図4, 図5に示す. 図の縦軸は各データ区間における, 全体のデータ数に対する出現頻度の割合を表す. また, これらの距離の平均値をそれぞれ表3, 表4に示す.

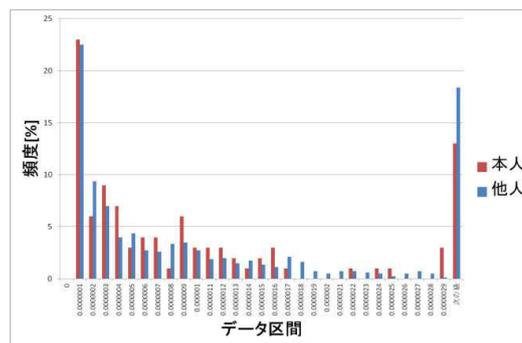


図 4 平均値のユークリッド距離

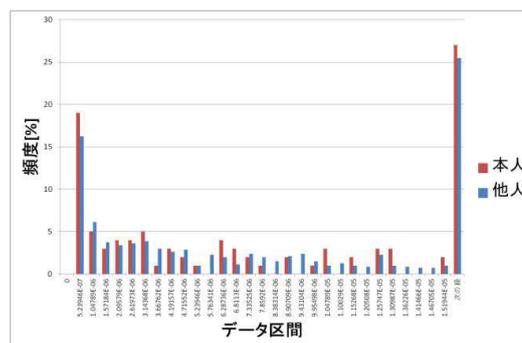


図 5 標準偏差のユークリッド距離

表 3 平均値のユークリッド距離

レベル	本人-本人	本人-他人
2	1.75×10^{-3}	2.10×10^{-4}
4	5.75×10^{-5}	7.02×10^{-5}
8	2.16×10^{-5}	2.89×10^{-5}
16	8.07×10^{-6}	1.28×10^{-5}
32	3.49×10^{-6}	7.37×10^{-6}

表 4 標準偏差のユークリッド距離

レベル	本人-本人	本人-他人
2	2.10×10^{-3}	2.19×10^{-3}
4	7.63×10^{-4}	8.50×10^{-4}
8	2.45×10^{-4}	3.17×10^{-4}
16	1.15×10^{-4}	1.60×10^{-4}
32	7.05×10^{-5}	1.03×10^{-4}

表 3, 表 4 のユークリッド距離の平均値を見ると, 本人-本人間距離が小さく, 本人-他人間距離が大きくなっており, 一見すると, 個人認証において有効な特徴量のように見える. しかし, 図 4, 図 5 のユークリッド距離のヒストグラムを見ると, 本人-本人間距離の分布と本人-他人間距離の分布が大きく重なっている. 平均値や標準偏差だけでなく, 他の従来の特徴量についても同様の様子が見られた. よって従来用いられている特徴量は単一の特徴量としては, 個人認証においては有効でない可能性が考えられる. しかし, 従来研究ではこれらの特徴量を複数組み合わせることである程度高い認証能力が得られている. 複数の特徴量を組み合わせた場合の特徴空間上での分布を確認し, 評価する必要があると考えられる.

ユークリッド距離の分布が重なってしまっている原因を確認するため, 例として, 平均値・標準偏差のデータ分布を図 6, 図 7 に示す. 標準偏差のデータ分布は, 本人と他人の間で偏りが見られるが, 重なっている区間が多く, また平均値は本人と他人の分布が大きく重なっている. このように特徴空間上で分布が重なっていると, 本人-本人間距離よりも本人-他人間距離の方が小さくなる場合が生じる. このためユークリッド距離のヒストグラム (図 4, 5) においても本人-本人間距離の分布と本人-他人間距離の分布が大きく重なっている

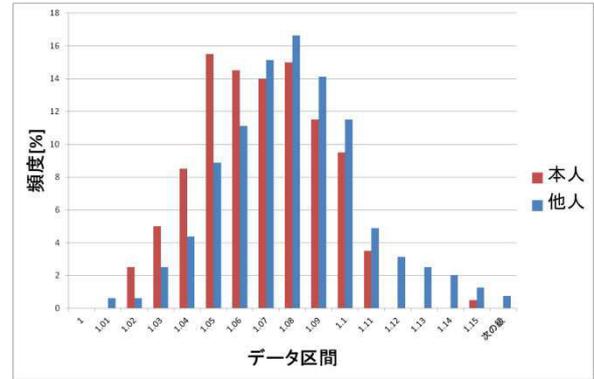


図 6 平均値のヒストグラム

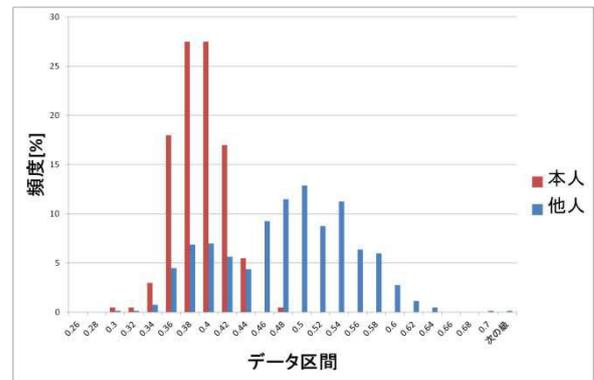


図 7 標準偏差のヒストグラム

5.2. LPC ケプストラム

特徴量として, LPC ケプストラムを用いた場合に算出されるユークリッド距離のヒストグラムを図 8, 図 9 に, ユークリッド距離の平均値を表 5 に示す. 図の縦軸は各データ区間における, 全体のデータ数に対する出現頻度の割合を表す. 図 8 は被験者 A を本人とした場合, 図 9 は被験者 B を本人とした場合である. 従来の特徴量と比較すると, LPC ケプストラムを用いた場合には, 表 5 のようにユークリッド距離の平均値が本人-本人間距離が小さく, 本人-他人間距離が大きくなり, 図 8, 図 9 のようにユークリッド距離が, 本人-本人間距離と本人-他人間距離の分布がきれいに分かれている. この結果から, 個人の認証において LPC ケプストラムが従来の特徴量と比較して, 有効であると考えられる.

表 5 LPC ケプストラムのユークリッド距離の平均値

レベル	本人-本人	本人-他人
2	1.00×10^{-1}	3.44×10^{-1}
4	8.72×10^{-2}	3.22×10^{-1}
8	7.70×10^{-2}	3.19×10^{-1}
16	6.65×10^{-2}	3.05×10^{-1}
32	5.74×10^{-2}	2.88×10^{-1}

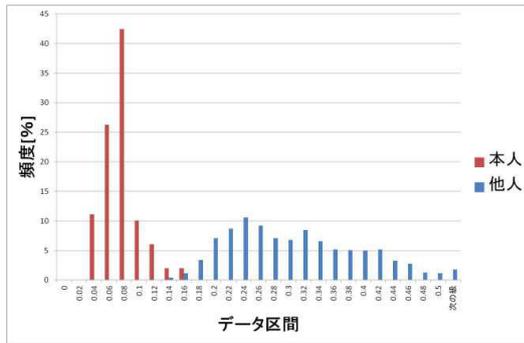


図 8 被験者 A のヒストグラム

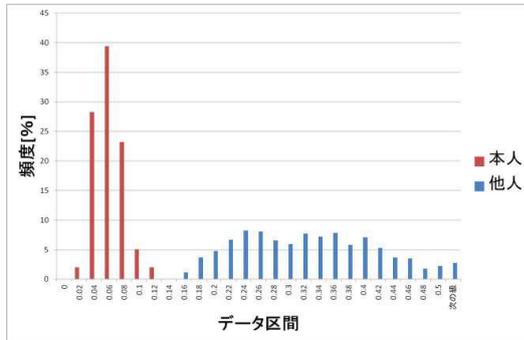


図 9 被験者 B のヒストグラム

6. まとめと今後の検討課題

6.1. まとめ

本検討では歩行時の携帯端末の加速度センサから得られる加速度データを用いた歩行認証の手法を提案し、その評価を行った。具体的には、歩行時の加速度情報を表わす特徴量に音声処理で用いられる LPC ケプストラムを用いることを提案し、従来研究で用いられている統計量をベースとした特徴量と比較し、その有効性をベクトル量子化による定量的な評価手法で評価した。

統計量を特徴量とした場合では、特徴空間における個人毎の分布が重なっており、特徴量単体で個人を認証することは難しいと考えられる。しかし、従来研究では、複数の特徴量を組み合わせることである程度の高い認証性能が得られている。複数の特徴量を組み合わせた場合の特徴空間上での分布を確認する必要があると考えられる。

LPC ケプストラムを特徴量とした場合は、従来研究で用いられる特徴量と比較すると、本人-本人間距離と本人-他人間距離の分布がきれいに分かれており、個人の認証における有効性が確認できた。

6.2. 今後の検討課題

6.2.1. データ取得

実用を考慮して特徴量を評価するためには、このような変化による誤差がどの程度存在するのか、本検討のように定性的・定量的に評価を行うことで、確認する必要がある。また、データ取得対象人数が 5 名と少数であり、かつ取得したデータもそれぞれ 100 秒間と

少ないため、さらに対象人数を増やし、データを多く取得し検討を行う必要があると考えられる。

6.2.2. パラメータ

本検討では、これまでの筆者らの検討を参考に特徴量を抽出する際のウィンドウサイズやスライド幅、LPC ケプストラムにおいても次元数などのパラメータを設定した。今後は個人認証において適切なパラメータを定める必要がある。そこで、パラメータを変化させた時の認証のしやすさを、定性的・定量的に評価する必要がある。

6.2.3. 歩行状態識別

本検討では、平地歩行における加速度データを用いて個人認証を行った。しかし、日常利用するシーンを考えると、平地歩行だけでなく様々な道（階段や坂など）を歩くことが考えられる。そこで、携帯端末に搭載されている他のセンサを用いて平地歩行を検出し、平地歩行に限定して認証を行う。渡邊ら[6]の研究において気圧センサを用いて歩行状態が識別可能であることが示されているため、今後は気圧センサを用いて歩行状態を識別し、平地歩行を検出した際に個人認証を行う手法を検討したい。

文 献

- [1] 杉浦一成, 榎原靖, 八木康史, “全方位カメラを用いた複数方向の観測による歩容認証,” 情報処理学会論文誌, Vol.1, No.2, pp.76-85, Jul.2008.
- [2] 白井隼人, 笠原弘樹, 伊藤智則, 吉井英樹, 小松尚久, “加速度データの LPC ケプストラムを用いた歩行状態の識別に関する一考察,” 信学技報 LOIS2010-85, Mar.2011.
- [3] Jennifer R.Kwapisz, Gary M.Weiss, and Samuel A.Moore, “Cell Phone-Based Biometric Identification,” IEEE Biometrics, pp.1-7, Sep.2010.
- [4] Davrondzhon Gafurov, Kirsii Helkala, and Torkjel Sondrol, “Gait Recognition Using Acceleration from MEMS,” IEEE Availability, Reliability and Security, Apr.2006.
- [5] 伊藤智則, 上原聡介, 笠原弘樹, 市野将嗣, 吉井英樹, 鶴丸和宏, 甲藤二郎, 小松尚久, “加速度センサを用いた歩行状態識別におけるケプストラム分析の有効性に関する一考察,” 信学技報 LOIS2011-63, Jan.2012.
- [6] 渡邊孝文, 上坂大輔, 村松茂樹, 小林亜令, 横山浩之, “気圧センサを利用した移動状態推定手法の提案,” 信学技報 MoMuc2011-30, Nov.2011.
- [7] 石井健太郎, 上田修功, 前田英作, 村瀬洋, “わかりやすいパターン認識,” オーム社, 1988.
- [8] 古井貞熙, “ディジタル音声処理,” 東海大学出版会, 1998.
- [9] Y.Linde, A.Buzo and R.M.Gray, “An Algorithm for Vector Quantizer Design,” IEEE Trans-on Commun., Vol.28, No.1, pp88-95, Jan.1980.

携帯端末の加速度センサを用いた歩行認証に関する検討

A Study of the Gait Authentication Using Acceleration of Mobile Terminal

笠原 弘樹* 市野 将嗣† 吉井 英樹‡
Hiroki KASAHARA Masatsugu ICHINO Hideki YOSHII
鶴丸 和宏§ 甲藤 二郎* 小松 尚久*
Kazuhiro TSURUMARU Jiro KATTO Naohisa KOMATSU

あらまし 本稿では、携帯端末に搭載された加速度センサを用いて個人認証を行う手法について述べる。歩行動作において得られる加速度データに個人による違いが表れることを確認し、従来研究で用いている平均や標準偏差などの統計量を中心とした特徴量が有効であるか確認した。さらに、個人認証における特徴量として、音声処理でよく用いられる LPC ケプストラムを用いることの有効性を評価した。次にそれらを踏まえ、パターン認識技術を用いた端末所有者の個人認証を行い、他人受入率 (False Match Rate, FMR) と本人拒否率 (False Non-Match Rate, FNMR) を算出することで認証性能の評価を行った。

キーワード 加速度センサ, 個人認証, パターン認識, LPC ケプストラム

1 まえがき

近年、携帯端末は急速に普及し、情報発信・情報収集に加えて生活や行動を支援する高機能ツールとして発展してきた。最近では、利用者のネット内外の活動記録であるライフログを活用し、利用者の属性情報に応じたコンテンツや広告を提供するサービスの進展に期待が集まっている。筆者らは、携帯端末から取得したセンサ情報 (位置, 加速度, 地磁気など) や、本人確認情報 (歩き方など) を把握し、複合的に分析することで新しいサービスの提供を目指している。

携帯端末には、スケジュールや電話帳などの様々な個人情報や、電子商取引などで用いる情報などが記録されており、端末の紛失によりそれらの情報が他人に悪用さ

れる危険性がある。これらの情報を保護するために、一般的にはパスワードや物理的なキーが用いられているが、情報を参照するたびに、煩雑な動作を行う必要があるため、パスワードや物理的なキーを設定しない原因にもなっている。そのため、ユーザの所有や記憶に依存しない、身体的な特徴や特性を用いたバイOMETリック個人認証が注目されている。バイOMETリック個人認証は、身体的特徴を用いる認証と、行動的特徴を用いる認証に分類できる。身体的特徴を用いた個人認証は時間軸上の一点を対象として本人確認を行うが、行動的特徴を用いた個人認証は、日常的な動作と同時に本人確認が行えるため、認証時だけでなく認証後も連続的に本人確認を行うことができる。また、ユーザへの心理的抵抗が弱いことが利点として挙げられる。そこで本検討では、携帯端末向けの個人認証手法として、行動的特徴である人物の歩行動作における加速度データに着目し、携帯端末に搭載されている加速度センサを用いた歩行認証を提案する。

2 歩行認証

2.1 歩行時の加速度データ

携帯端末はユーザが日常的に所持するものであり、常に携帯端末に搭載されているセンサでユーザの行動によるセンサ情報が取得されている。近年、監視システムや

* 早稲田大学理工学術院 基幹理工学研究所 情報理工学専攻, 〒 169-8555 東京都新宿区大久保 3-4-1, Advanced Research Institute For Science And Engineering, Waseda University, 3-4-1 Okubo, Shinjuku-ku, Tokyo, 169-8555 Japan

† 電気通信大学大学院 情報理工学研究所 総合情報学専攻, 〒 182-8585 東京都調布市調布ヶ丘 1-5-1, Department of Informatics, Graduate School of Informatics and Engineering, The University of Electro-Communications, 1-5-1 Chofugaoka, Chofu-shi, Tokyo, 182-8585 Japan

‡ ソフトバンクテレコム株式会社, 〒 105-7316 東京都港区東新橋 1-9-1, SOFTBANK TELECOM Corp., 1-9-1 Higashishimbashi, Minato-ku, Tokyo, 105-7316 Japan

§ 早稲田大学理工学研究所, 〒 169-8555 東京都新宿区大久保 3-4-1, Advanced Research Institute For Science And Engineering, Waseda University, 3-4-1 Okubo, Shinjuku-ku, Tokyo, 169-8555 Japan

アクセスコントロールのための個人認証システムとして歩容認証が検討されている [1]。カメラから得られる動画画像を処理することで、個人の認証が可能であることが示されており、歩き方は個人によって異なることが確認されている。そこで本検討では、個人の歩き方の違いが歩行中の加速度に現れると考え、所持している携帯端末の加速度センサから得られる加速度データに着目した。

携帯端末に搭載されている3軸加速度センサから取得される歩行における加速度データを Fig.1 に示す。本検討では、端末を腰に固定しているため、x, y, z の3軸がそれぞれどの方向を指しているのかわかるが、センサの向きにより3軸それぞれの成分が変化してしまう問題がある。そこで、式(1)を用いて3軸を合成した値 r を求め、センサが受けた加速度の大きさを用いて認証を行う。Fig.1 に示した3軸の加速度データに対して式(1)を用いて合成した3軸合成加速度データを Fig.2 に示す。

$$r = \sqrt{x^2 + y^2 + z^2} \quad (1)$$

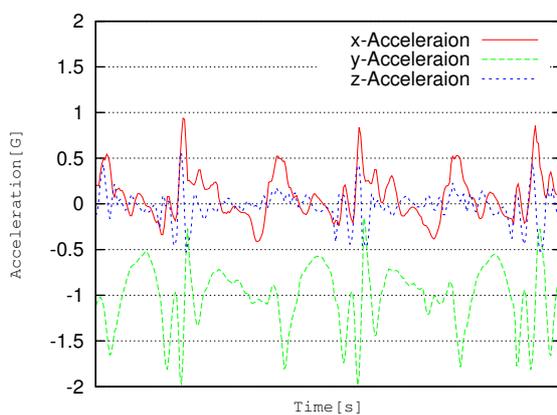


Figure. 1: Acceleration of Three-Axis

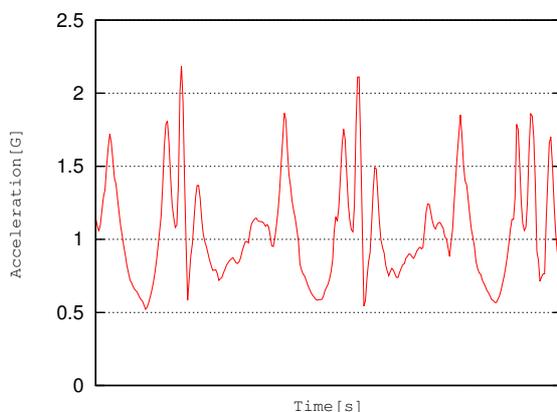


Figure. 2: Composition Acceleration of Three-Axis

2.2 従来研究

歩行動作における加速度データを用いて個人認証や個人識別を行っている研究では、平均値や標準偏差、歩調を特徴量として用いる研究がなされている [2][3][4]。Jennifer ら [3] の個人識別の研究においては各軸の平均値や標準偏差、平均絶対値や歩調などを用いて約 90% の個人識別率が得られている。しかし、これらの特徴量については、認証・識別確率のみを評価しているが、個人認証に対しての特徴量の有効性については確認していない。そのため、当該特徴量が個人性を適切に抽出できているか確認する必要がある。特徴空間において本人データ同士は近く、他人データ同士は離れるような特徴量が有効であるので、まず特徴空間上での分布を確認する必要があると考えた。また、白井ら [2] の研究において、個人を識別する特徴量として、LPC ケプストラムが有効である可能性が示されており、伊藤ら [5] の研究において歩行状態の識別に LPC ケプストラムが有効であることを示している。ケプストラム分析により、スペクトルの微細構造とスペクトル包絡を分離して抽出できる。スペクトルの微細構造は、歩行データの時間波形における周期情報を表す。微細構造は、細かく変動する要素で、歩行データの取得時期や取得環境などの要因の違いによる影響を受けやすい。一方で、スペクトル包絡は歩行データの時間波形における振幅情報を表すため、個人毎の特徴が歩行データの振幅情報に現れる場合、スペクトル包絡を用いることが有効であると考えられる。スペクトル包絡は、周波数軸上に緩やかに変化する要素でもある。このため、スペクトル包絡は、歩行データの取得時期や取得環境の影響を受けづらいと考えられる。以上から、スペクトル包絡を抽出できるケプストラム分析による特徴量が歩行認証に有効であると考えた。

そこで本検討では、従来の特徴量と比較することにより、筆者らが提案している LPC ケプストラムを歩行認証に用いる有効性を評価した結果を報告する。

2.3 歩行認証システム

本検討では、パターン認識技術を用いて Fig.3 のような歩行認証システムを設計し、個人認証の認証能力を評価した。

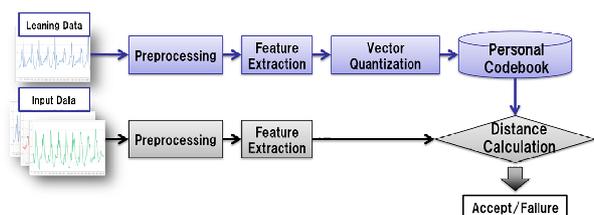


Figure. 3: Authentication System

前処理 (Preprocessing) 部では，端末から取得される加速度情報を用いて歩行動作を検出し，3軸加速度を合成して特徴量を抽出しやすい形に変換する．特徴抽出 (Feature Extraction) 部では，前処理部で変換したデータの特徴量の算出を行う．学習時には，事前にいくつかの歩行データから特徴量を抽出し，LBG+Splitting アルゴリズムを用いたベクトル量子化 (Vector Quantization) を用いて個人毎のコードブック (Personal Codebook) を作成する．ベクトル量子化とは，入力データを任意個の代表パターン (コードブック) の値で近似する処理であり，LBG+Splitting アルゴリズムは，適当なコードブックから開始し，学習系列に分割条件と代表点条件を繰り返し適用することで良好なコードブックに収束させるコードブック設計アルゴリズムである．認証時には，入力された歩行データから特徴量を抽出し，距離計算 (Distance Calculation) 部において，各コードブックとのユークリッド距離 d を式 (2)，(3) を用いて算出し，最小となるユークリッド距離を求める．ただし， m は特徴量の次元数， c は個人コードブック， n はベクトル量子化レベル， v は認証用データとする．認証システムにおいて特徴抽出部は特に重要であり，認証性能を大きく左右する．そこで本検討では，歩行認証システムを実装し，その認証結果を用いて認証性能を評価した．

$$d = \min\{d_i, i = 1, 2, \dots, n\} \quad (2)$$

$$d_i = \sqrt{\frac{1}{m} \sum_{j=1}^m (c_{i-j} - v_j)^2} \quad (3)$$

3 提案手法

3.1 LPC ケプストラム

入力信号を $x(t)$ とした場合，ケプストラム (cepstrum) は，短時間振幅スペクトル $X(\omega)$ の対数の逆フーリエ変換として定義され，スペクトル包絡と微細構造を近似的に分離して抽出できる特徴がある．スペクトル包絡は，時間波形における大局的な特徴を表し，微細構造は，時間波形における基本周期を表す．そこで，歩行データの時間波形 $x(t)$ を，2つの信号 $g(t)$ と $h(t)$ で表すことを考える．ただし， $g(t)$ は周期信号であり， $h(t)$ はインパルス応答である． $x(t)$ はこれらの2つの信号の畳み込みとして次の式 (4) のように与えられる．

$$x(t) = \int_0^t g(\tau)h(t-\tau)d\tau \quad (4)$$

$$X(\omega) = G(\omega)H(\omega) \quad (5)$$

ただし， $X(\omega)$ ， $G(\omega)$ および $H(\omega)$ はそれぞれ， $x(t)$ ， $g(t)$ ，および $h(t)$ のフーリエ変換である．この $X(\omega)$ の

対数変換は

$$\log |X(\omega)| = \log |G(\omega)| + \log |H(\omega)| \quad (6)$$

となる．次に式 (6) に対して周波数 ω を変数として逆フーリエ変換する．これがケプストラムであり，フーリエ変換を F の記号で表すと

$$c(\tau) = F^{-1} \log |X(\omega)| = F^{-1} \log |G(\omega)| + F^{-1} \log |H(\omega)| \quad (7)$$

となる．式 (6) 右辺第 1 項は，スペクトル上の微細構造，すなわち比較的細かい周期のパターンであり，第 2 項はスペクトル包絡，すなわち周波数による変化のゆるやかなパターンを表す．逆フーリエ変換した際に，高ケプレンシー部のピークから基本周期が求まり，低ケプレンシー部のみを用いてフーリエ変換することによってスペクトル包絡が求まる．

線形予測分析 (LPC) は，離散時間系において，ある時点の値がそれ以前の値の線形結合で表現できるという仮定に基づき波形を予測するものである．時間離散的信号 x_t において，現時点の標本値 x_t ，これに隣接する過去の p 個の標本値との間の線形予測値を \hat{x}_t とすると， \hat{x}_t は次のように表される．

$$\hat{x}_t = \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + \dots + \alpha_p x_{t-p} \quad (8)$$

線形予測係数 α は標本値 x_t と線形予測値 \hat{x}_t の間の誤差が最小となるように定める．この LPC で求めた線形予測係数を次式に代入する．

$$H(z) = \frac{1}{1 + \sum_{i=1}^p \alpha_i z^{-i}} \quad (9)$$

LPC ケプストラム分析では式を信号のスペクトル密度とみなし， $X(\omega) = H(z)|_{z=e^{j\omega t}}$ とおいたときのケプストラムを算出する．このため，ケプストラム分析を算出する過程にある DFT，対数変換，IDFT をそれぞれ，両側 z 変換，複素対数，逆両側 z 変換でおきかえることによって，ケプストラムの概念を複素ケプストラムの概念に拡張する．LPC ケプストラムは線形予測係数 α から次式で求まる．

$$\left. \begin{aligned} c_1 &= -\alpha_1 \\ c_n &= -\alpha_n - \sum_{m=1}^{n-1} \left(\frac{m}{n}\right) c_m \alpha_{n-m} \quad (1 < n \leq p) \\ c_n &= -\sum_{m=1}^p \left(\frac{m}{n}\right) c_m \alpha_{n-m} \quad (p < n) \end{aligned} \right\} \quad (10)$$

ただし， p は，LPC 係数の数を表す．

LPC ケプストラム分析では，LPC による線形波形モデルに対してケプストラム分析を行うため，元の波形に対するケプストラム分析よりも，スペクトルのピーク特

性が抽出しやすいという利点がある。本検討では、歩行データの特徴量として、この LPC ケプストラム係数とを用いた。

3.2 複数フレームによる認証

1 つのフレーム (ケプストラム分析の適用する範囲) から得られる特徴量から算出されるユークリッド距離を用いて認証を行うと、フレーム毎の特徴量に少しばらつきがあるために、認証性能があまり高くないと考えられる。そこで本検討では、複数フレームを用いた認証を行う。具体的には、任意個のフレームのそれぞれの特徴量からユークリッド距離を算出し、算出された任意個のユークリッド距離の平均値、最大値、最小値を任意個のフレームの代表コードブックの距離として算出し、本人・他人の判定基準となる閾値と比較を行うことで認証する。また、本検討では、 k 数決法を用いて歩行認証を行う手法を提案する。 k 数決法とは、任意個のフレームのそれぞれの特徴量からユークリッド距離を算出し、算出された任意個のユークリッド距離をそれぞれ本人・他人の判定基準となる閾値と比較し、任意個の中で k 個以上のフレームにおいて閾値を満たした場合に、その任意個のフレームは本人と判定する手法である。

4 評価実験

4.1 実験概要

本検討では、実装した歩行認証システムを用いて、通常歩行と成りすまし歩行における評価実験を行った。評価実験において、学習時には、任意の被験者の全データの中の半分のデータに対して、各特徴量を抽出し、特徴量毎に LBG+Splitting アルゴリズムを用いたベクトル量子化を行うことで、個人のコードブックを作成する。認証用データとしては、学習に用いていない残りの半分のデータを使用する。その後、学習用データと認証用データを入れ替えて評価するクロスバリデーションを行った。

本検討では、認証性能の評価尺度として、バイオメトリクス性能評価尺度として一般的な、他人受入率 (False Match Rate, FMR), 本人拒否率 (False Non-Match Rate, FNMR) を利用した。FMR と FNMR の関係を表す ROC (Receiver Operating Characteristic) 曲線を用いて、本人・他人判定の基準となる閾値を変化させた際の精度を評価した。この曲線が原点に近くなれば近くなるほど認証性能が高いことを示す。また、本人拒否率と他人受入率が等しくなったときの値を EER (Equal Error Rate) といい、認証性能評価の指標として良く用いられる。EER が小さいほど認証性能が高いことを示す。

4.2 通常歩行における歩行認証実験

通常歩行における歩行認証について評価実験を行った。通常歩行におけるデータ取得実験の実験諸元を Tab.1 に示す。iPhone4S に搭載されている 3 軸加速度センサを用いて、被験者 20 名について 1 人あたり 100 秒間の歩行データを取得した。データの取得間隔を表すサンプリング周波数は 100Hz (0.01 秒毎に計測) とした。

Table. 1: Outline of Experiment

Date	2012.10.06
Terminal	iPhone4S
Sampling Frequency	100Hz
Mounting Position	Right side of Waist
Acquisition Time	100sec/person
Number of Subject	20 person

4.2.1 従来特徴量との比較

従来研究で用いられている平均値、標準偏差、最大値、最小値の 4 種類の特徴量と LPC ケプストラムの計 5 種類の特徴量を 1 フレーム毎に算出し、評価実験を行った。評価結果の ROC 曲線を Fig.4 に、EER を Tab.2 に示す。従来研究に用いられている 4 種の特徴量の中では、最小値を用いた場合に認証性能が高くなるが、LPC ケプストラムを用いた場合が最も認証性能が高いことがわかる。

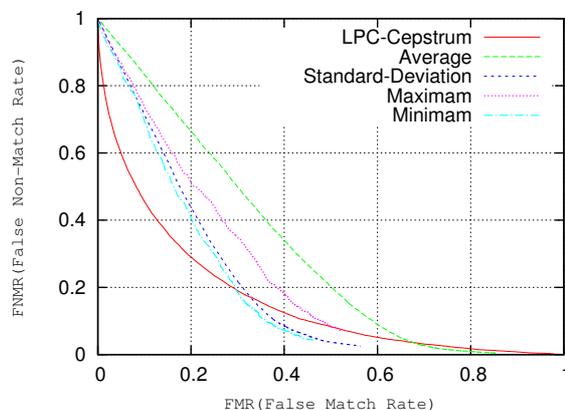


Figure. 4: Difference of Feature

4.2.2 パラメータ調査

LPC ケプストラムを用いて歩行認証をする上で、以下の 3 つのパラメータを設定する必要がある。

- フレーム長

特徴量を算出する際の、1 フレームに含まれるサンプル数。例えば、フレーム長が 256 サンプルで

Authentication Method	EER
Average	37.5%
Standard Deviation	27.2%
Maximum	31.7%
Minimum	26.3%
LPC Cepstrum	24.2%

あれば、2.56 秒毎に特徴量を算出することになる。また本検討では、フレームを 16 サンプルずつスライドさせて特徴量の算出を行った。

- LPC ケプストラム次元数

LPC ケプストラムを算出するの次元数。次元数が多いとより細かい特徴を得ることができるが、計算の負荷が増大する。

- ベクトル量子化レベル

学習データをいくつの段階に量子化するかを表す。量子化レベルが高い(細かい)ほど、元の学習データとの誤差が小さくなるが、計算の負荷が増大する。

そこで、フレーム長、ケプストラムの次元数、ベクトル量子化レベル 3 つのパラメータにおける認証性能の比較を行った。基本的には、フレーム長を 256、ケプストラムの次元数を 30、ベクトル量子化レベルを 32 とし、評価対象のパラメータを変化させることでパラメータの調査を行う。評価結果の ROC 曲線をそれぞれ、Fig.5、Fig.6、Fig.7 に示す。

フレーム長は大きければ大きいほど認証性能は高くなるが、大きすぎると認証時間に多くの時間を要するために余り実用的とは考えられない。ケプストラムの次元数は、5次元とした場合に性能が低くなるが、そのほかの次元数では性能に大きな変化は見られない。これは、LPC ケプストラムの低次元部分に、歩行動作の個人による違いがあることを表している。ベクトル量子化レベルは、16 レベル、32 レベルとした場合に最も認証性能が高くなり、64 レベル以上とすると認証精度は少し低下する。以後の検討では、フレーム長を 256、ケプストラム次元数を 30、ベクトル量子化レベルを 32 として評価実験を行うこととする。

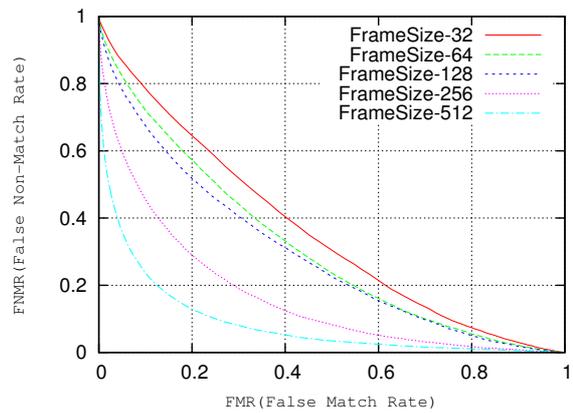


Figure. 5: Difference of Frame-Size

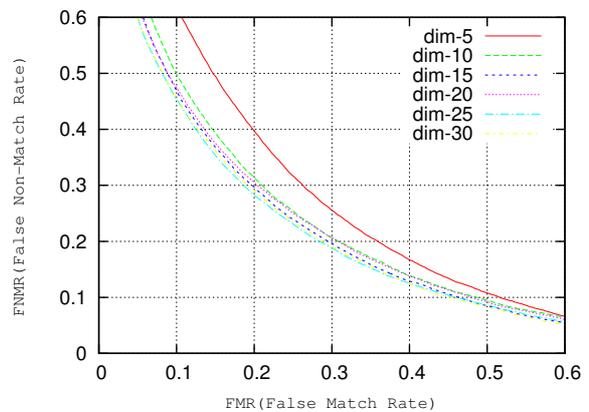


Figure. 6: Difference of Dimension of LPC-Cepstrum

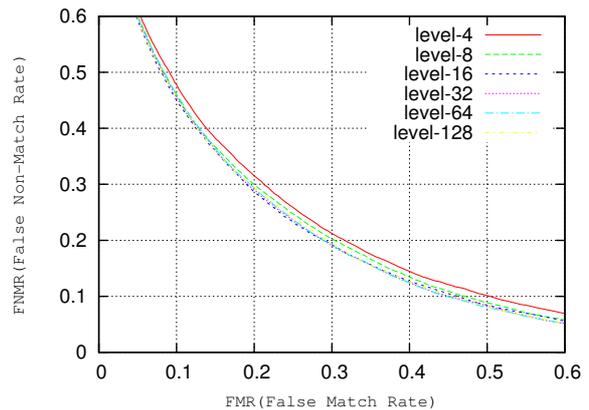


Figure. 7: Difference of Level of Vector Quantization

4.2.3 複数フレームを用いた認証

ここまでの検討では、1つのフレームから得られる特徴量から算出されるユークリッド距離を用いて認証を行っている。しかし、1つのフレームのみで認証を行うと、フ

フレーム毎の特徴量にばらつきがあるために、認証性能があまり高くない。そこで本検討では、複数フレームを用いた認証を行う。評価結果のROC曲線を Fig.8 に、EER を Tab.3 に示す。16 フレームの平均値を用いた場合に EER が 15.5% となり、最も認証性能が高い結果になった。また、1つのフレームのみで認証を行った場合と、16 フレームを用いて認証を行った場合の本人-本人間のユークリッド距離 (subject) と、本人-他人間のユークリッド距離 (non-subject) をそれぞれ Fig.9, Fig.10 に示す。縦軸は各データ区間における、全体のデータ数に対する出現頻度の割合を表す。Fig.9 の1つのフレームのみで認証した場合と比較して、Fig.10 の16 フレームを用いて認証した場合が分布の重なりが小さくなり、認証性能が高くなるのが分かる。

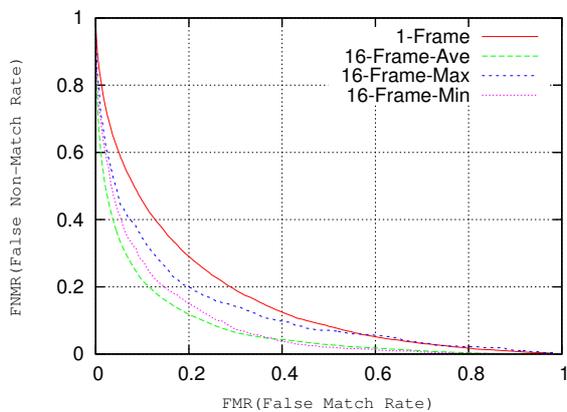


Figure. 8: Authenticaiton Using Multi-Frames

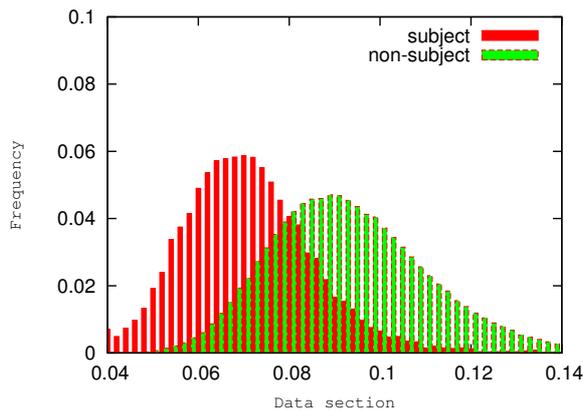


Figure. 9: Histogram of One-Frame Authentication

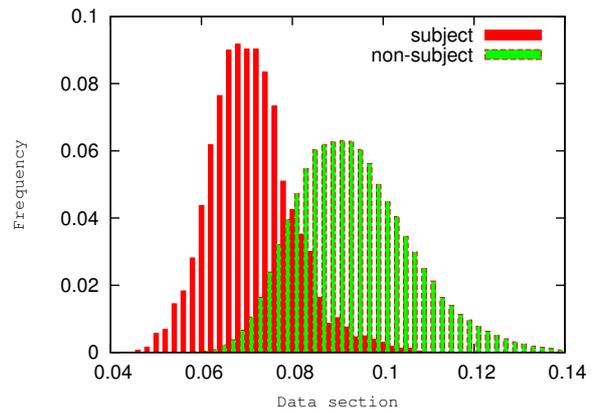


Figure. 10: Histogram of 16-Frames Authentication

Table. 3: Authenticaiton Using Multi-Frames

Authentication Method	EER
1-Frame	24.3%
16-Frame-Ave	15.5%
16-Frame-Max	20.0%
16-Frame-Min	17.5%

4.2.4 k 数決法

本検討で提案する k 数決法による歩行認証を行った。本検討では、フレーム数は 16 個とし、 $k = 1, 2, 3, 5, 8$ として認証を行った。また、4.2.3 において最も認証性能が高い 16 フレームの平均値との比較を行った。評価結果の ROC 曲線を Fig.11 に、EER を Tab.4 に示す。16 フレームの平均値と比較して、 k 数決法により認証を行う方が、認証性能が高くなった。また、 k 数決法においては、 $k = 2$ とした場合に、EER が 12.6% となり、認証性能が最も高い結果になった。

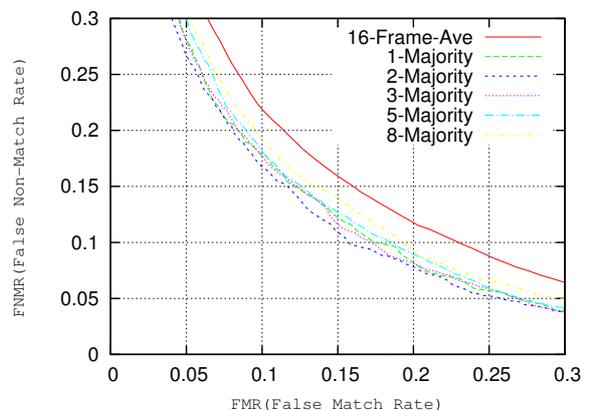


Figure. 11: Authentication Using k-Majority Method

Table. 4: Authentication Using k-Majority Method

Authentication Method	EER
16-Frame-Ave	15.5%
1-Majority	13.8%
2-Majority	12.6%
3-Majority	13.7%
5-Majority	13.8%
8-Majority	14.4%

4.3 成りすまし歩行における認証実験

成りすまし耐性について調査を行うため、評価実験を行った。成りすまし歩行におけるデータ取得実験の実験諸元を Tab.5 に示す。被験者7名について、同じ歩幅 (60cm)、同じ歩調 (100 歩/分) で歩行し、1人あたり 100 秒間の歩行データの取得を行った。認証手法には 4.2.4 で提案した k 数決法 ($k = 2$) を用いた。

Table. 5: Outline of Experiment for Spoofing

Date	2012.11.14
Terminal	iPhone4S
Sampling Frequency	100Hz
Mounting Position	Right side of Waist
Acquisition Time	100sec/person
Number of Subject	7 person
Authentication Method	k-Majority

評価結果の ROC 曲線を Fig.12 に、EER を Tab.6 に示す。通常歩行において認証を行った結果の EER は 10.1% となり、成りすまし歩行において認証を行った結果の EER は 22.5% となる。また、通常歩行と成りすまし歩行における本人-本人間のユークリッド距離 (subject) と、本人-他人間のユークリッド距離 (non-subject) をそれぞれ Fig.13、Fig.14 に示す。縦軸は各データ区間における、全体のデータ数に対する出現頻度の割合を表す。Fig.13 の通常歩行における分布に比べて、Fig.14 の成りすまし歩行における分布は、本人-本人間距離と本人-他人間距離の分布の重なりが大きくなってしまっている。そのため、Fig.12 や Tab.6 でわかるように、成りすまし歩行における認証では大きく認証性能が低下した。

認証性能が大きく低下した原因として以下の2点が考えられる。1つ目は、LPC ケプストラムがピッチを顕著に抽出する特徴量であるために、歩調・歩幅を固定したことの影響を受け、性能が大きく低下したと考えられる。2つ目は、歩調・歩幅を固定したことにより歩行における個性が失われたと考えられる。歩行には人それ

ぞれの歩き方があるが、歩調・歩幅を固定することで固有の歩き方を強制的に失わせてしまう結果となった。本検討の結果からは歩行認証の成りすまし耐性が低いと考えられるが、本人とする被験者に普段と違う歩き方をしているために、正確な成りすまし耐性の評価とは言えない。また、歩行している姿を見るだけでは、歩調・歩幅を正確に計測することは難しいと考えられる。そこで、今後の検討課題として、本人とする被験者は通常通りに歩行し、それを他人とする被験者が真似して歩くことで歩行データを取得し、認証を行うことで、より正確な歩行認証の成りすまし耐性を評価したい。

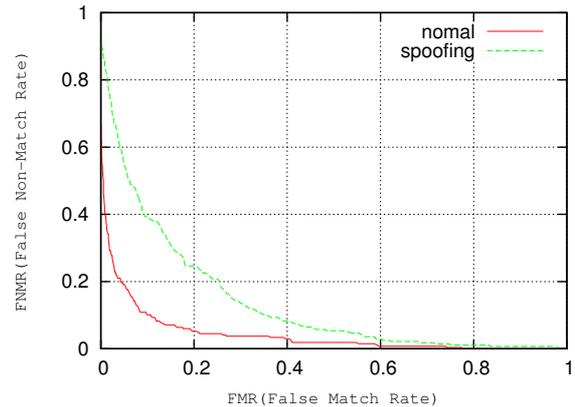


Figure. 12: Tolerance of Spoofing

Table. 6: Tolerance of Spoofing

The Kind of Walk	EER
Nomal Walk	10.1%
Spoofing Walk	22.5%

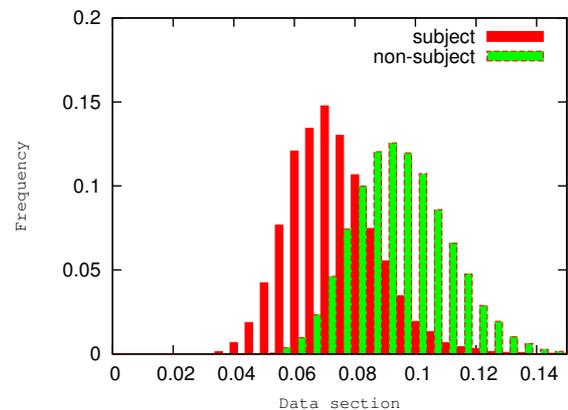


Figure. 13: Histogram of Nomal-Walk

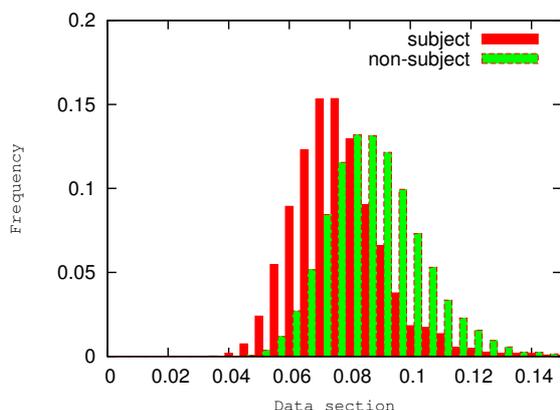


Figure. 14: Histogram of Spoofing-Walk

5 まとめと今後の検討課題

5.1 まとめ

本検討では歩行時の携帯端末の加速度センサから得られる加速度データを用いた歩行認証の手法を提案し、その評価を行った。具体的には、歩行時の加速度データに音声処理で用いられる LPC ケプストラムを用いることを提案した。従来研究で用いられている統計量を中心とした特徴量と比較し、その有効性を、実装した歩行認証システムで認証を行い、ROC 曲線や EER を用いて定性的・定量的に評価した。また、LPC ケプストラムを用いて認証を行う上で必要となるラメータの調査を行い、複数フレームを用いた認証である k 数決法の評価を行った。また、歩行認証の成りすまし耐性についても評価した。

複数フレームを用いて認証を行う場合には、任意個のフレームの平均値のような統計量を用いるよりも、本検討で提案する k 数決法を用いた方が認証性能が高くなることがわかった。また、 k 数決法においては $k = 2$ とした場合が最も認証性能が高くなることがわかった。

成りすまし歩行における認証では、通常の歩行における認証に比べて大きく認証性能が低下した。原因として、LPC ケプストラムが歩調・歩幅の影響を受けてしまうこと、歩調・歩幅を固定することで個人固有の歩き方が強制的に失われてしまうことが考えられる。

5.2 今後の課題

5.2.1 成りすまし耐性の調査

本検討では、歩幅・歩調を固定して歩行することで成りすまし歩行における歩行データを取得した。しかし、歩幅・歩調を固定して歩行することで、個人特有の歩き方が強制的に失われてしまうことが考えられる。そこで、本人とする被験者には通常通りに歩いて歩行データを取得し、本人とする被験者の歩き方を見て、他人とする被験者がそれを真似して歩くことにより成りすまし歩行に

おける歩行データを取得する必要があると考えられる。これにより、本人とする被験者固有の歩き方を失うことなく、歩行データを取得することができるため、より成りすまし耐性について正確な評価を行うことができる。

5.2.2 取得環境の影響の調査

本検討では、携帯端末 (iPhone4S) を右腰に専用のケースを用いて固定し、平地を歩行することで歩行データを取得した。しかし、環境要因 (天候、道の凹凸など) により歩行動作が変化し、保持状態 (端末を保持する場所) により歩行動作における加速度データが変化すると考えられる。そのため、取得環境によって歩行動作にどのように影響があるのかを調査し、その影響を考慮した上で歩行認証を行う手法を検討したい。

5.2.3 特徴量の検討

本検討で、音声処理で用いられている特徴量の LPC ケプストラムが歩行認証において従来の特徴量と比較して、有効であると示した。今後は、バイオメトリクス認証で用いられている特徴量や、音声処理で用いられている他の特徴量を歩行認証に適用した場合の有効性を評価したい。

参考文献

- [1] 杉浦一成, 榎原靖, 八木康史, “全方位カメラを用いた複数方向の観測による歩容認証,” 情報処理学会論文誌, Vol.1, No.2, pp.76-85, Jul.2008.
- [2] 白井隼人, 吉井英樹, 小松尚久, “携帯端末のセンサ情報を用いたユーザー行動状態識別に関する研究 - LPC ケプストラムを用いた歩行状態の識別 -,” 電子通信情報学会技術研究報告, vol.110, no.450, pp.119-124, Mar.2011.
- [3] Jennifer R.Kwapisz, Gary M.Weiss, and Samuel A.Moore, “Cell Phone-Based Biometric Identification,” IEEE Biometrics, pp.1-7, Sep.2010.
- [4] Davrondzhon Gafurov, Kirsi Helkala, and Torkjel Sondrol, “Gait Recognition Using Acceleration from MEMS,” IEEE Availability, Reliability and Security, Apr.2006.
- [5] 伊藤智則, 上原聡介, 笠原弘樹, 市野将嗣, 吉井英樹, 鶴丸和宏, 甲藤二郎, 小松尚久, “加速度センサを用いた歩行状態識別におけるケプストラム分析の有効性に関する一考察,” 信学技報 LOIS2011-63, Jan.2012.
- [6] 石井健太郎, 上田修功, 前田英作, 村瀬洋, “わかりやすいパターン認識,” オーム社, 1998.