

加速度センサを用いたジェスチャ認識に 疲労および忘却が与える影響の評価

吉田 楽^{†1} 村尾 和哉^{†1}
寺田 努^{†1,†2} 塚本 昌彦^{†1}

携帯電話や携帯型ゲーム機に搭載されている加速度センサを用いたジェスチャ認識技術を利用することで、3D オブジェクトの描画など従来のインタフェースでは困難であった入力や日常生活での細かな動作の記録などが可能になる。ジェスチャ認識では、認識を行う前に数回分のジェスチャを行い、そのデータを学習データとして用いることが一般的である。しかし、ユーザが学習データ採取時に行った動きを忘れていたり、疲労によってジェスチャが変化することで、ジェスチャを正しく認識できない可能性がある。従来の研究ではユーザの状態が変化しないことを前提にしており、ジェスチャの変化を考慮していなかった。本研究では、ユーザの疲労および忘却がジェスチャ動作に与える影響を評価し、適切な学習データの位置をオンラインで探索する手法を提案する。評価より、提案手法を用いることではじめの数回を学習データとする手法よりもその後のデータに対して安定した学習データを選択できたことを確認した。

Evaluating Effect of Fatigue and Forgetfulness for Gesture Recognition using Accelerometers

GAKU YOSHIDA,^{†1} KAZUYA MURAO,^{†1}
TSUTOMU TERADA^{†1,†2} and MASAHIKO TSUKAMOTO^{†1}

Mobile phones and portable video games using gesture recognition technologies with an accelerometer enable drawing objects, which is difficult for conventional interfaces, and recording detailed activities in daily life. Generally, though several samples of gesture are used as training data, which may lead to misrecognition because the trajectory of gestures changes due to fatigue or forgetting gestures. However, researches considering changes of gestures have not been reported so far. We evaluate the effect of users' fatigue and forgetfulness for gesture recognition and propose a method finding appropriate position for training data in real time. We have confirmed that the proposed method finds more stable training data than that from conventional one.

1. はじめに

近年、マイクロエレクトロニクス技術の発展によるコンピュータの小型化、高性能化、軽量化に伴い、加速度センサを用いたジェスチャ認識に関する研究が数多く行われており、その応用が注目されている。特に、iPhone や Android 端末などの携帯電話や Wii や PS3 などの家庭用ゲーム機のコントローラにも加速度センサが内蔵され、そのセンサ値から端末の向きや動きなどを検出してユーザの直感的な操作や複雑な入力を実現している⁵⁾。そのほかにも、手に装着したセンサから日常生活における手の動きを詳細に記録することでリッチなライフログの構築も期待される。

ジェスチャ認識では、あらかじめ認識対象のジェスチャのデータを学習データとして取得しておき、認識したい未知のジェスチャのデータと学習データを比較することでユーザの行っているジェスチャを認識する。これまでに提案されているジェスチャ認識システムでは、事前に行った数回分のジェスチャ動作のデータを学習データとして使用しているが、ユーザの動作は周囲の環境やユーザの状態によって変化し、学習時の動作から異なる可能性があると考えられる。例えば、ユーザが学習時に行ったジェスチャの詳細な動作を忘れていたり、ユーザが1日の生活で疲労することで手の振りが小さくなって学習したジェスチャ動作と異なることで認識精度が低下する可能性がある。従来の研究の多くはジェスチャ動作の変化を考慮していない。このような変化に対応するためには、さまざまな状態でのジェスチャ動作をユーザに行わせて学習する方法が考えられるが、その種類が多く、また意図的に疲労や忘却を加えることは困難であり現実的ではない。

そこで本研究では、特定のジェスチャを1日200回繰り返し、7日間のデータ採取からユーザの疲労および忘却によるジェスチャ動作の変化を調査する。また、ジェスチャを複数回繰り返すことによって、疲労および忘却の影響を考慮した学習データをリアルタイムで取得する方法を提案する。提案手法を用いることで、少ない学習データの取得回数で疲労および忘却による影響を抑えたジェスチャ認識システムを構築できる。

^{†1} 神戸大学大学院工学研究科
Graduate School of Engineering, Kobe University

^{†2} 科学技術振興機構さきがけ
PRESTO, Japan Science and Technology Agency

2. 関連研究

加速度センサを用いたジェスチャ認識に関する研究はこれまでに数多く行われている。文献1)では、9個の加速度センサと9個の角速度センサを格子状に配置した盤面を用いて27種類のジェスチャの認識精度を求め、センサ数とセンサ位置、センサ種類による認識精度の違いを示している。Agrawalらは加速度センサを搭載した携帯電話をペンのように持って空中に書いたアルファベットを認識している²⁾。加速度のデータを幾何学的な動きに変換し、文字として認識する。いくつかの制約に準拠することにより、83%の認識率を達成している。空中に書いた文章や図をユーザ自身にメールで送信することができる。また、Chambersらからはビデオ映像の解析のみによるアノテーションは困難であるため、手首に装着した加速度センサを用いたジェスチャ認識によるビデオアノテーション手法を提案している³⁾。HMMを用いてジェスチャを認識しており「チョップ」「ひじ打ち」「パンチ」の3種類のカンフーの型を30回行い29回認識に成功している。さらに、Holgerらの研究では「ボタンを押す」や「飲み物を飲む」「受話器を上げる」などの日常の10種類の動作を80%の精度で認識している⁴⁾。このように、加速度センサを用いたジェスチャ認識に関する多くの研究が行われているが、いずれの研究においてもあらかじめ採取したデータのみを学習に用いており、ジェスチャ動作がユーザの状態によって変化することを考慮していない。

これに対して、Liuらは日々のジェスチャ動作が変化することに着目している⁵⁾。研究ではNokia研究所が提唱する直線や円などの8種類の図形を描くジェスチャを1個の3軸加速度センサで認識している。8名の被験者から4000以上のサンプルデータを収集し、認識アルゴリズムはDTW(Dynamic Time Warping)を採用している。学習したデータを日々更新することによって、高い認識精度を達成している。しかし、学習データの更新には正解情報の教示を行う必要がある。また、学習データの更新は1日1回で、日々のジェスチャ動作の変化には対応できるが、一日の中での変化に対応できるかは明らかでない。

3. 実験

本節では、ユーザの疲労および忘却によってジェスチャ動作がどの程度変化するかを調査するための実験およびその結果について述べる。本節の結果をもとに、次節で学習データとして適切なデータを得るためにジェスチャ動作を何回反復すればよいかを判断する手法を提案する。



図1 センサの装着位置
Fig. 1 Sensor position.

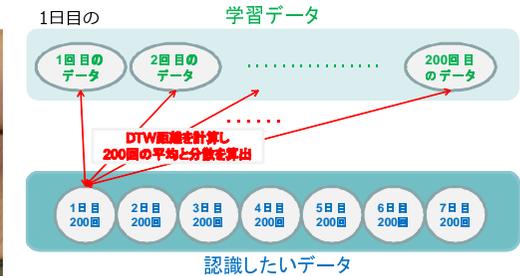


図2 データ間の距離の算出方法
Fig. 2 Calculation method.

3.1 実験方法

ユーザの疲労および忘却がジェスチャ動作に与える影響を調査するための実験の手順を以下に示す。図1に示すように手首に3軸加速度センサ⁷⁾を装着した22~23歳の男性5名の被験者に対して、「ボールを投げる」ジェスチャを3秒程度の間隔で200回行ったものを1セットとして、1日1セットを計7日行ってもらった。200回繰り返すことで疲労していくデータを、日を変えることで忘却していくデータを採取できると考えている。そのようにして採取したデータに対して、図2に示すように、採取した7日分のデータのうち、1日目の200回の試行の1回目のデータと7日分の各データとの距離(ジェスチャの類似度)をDTW(Dynamic Time Warping)⁶⁾を用いて被験者ごとに計算した。同様に、2回目から200回目までの各サンプルを学習データとして距離を計算し、この作業を学習データとする日を1日目から7日目まで変えて計算を行った。

類似度計算の最も簡単な手法はユークリッド距離であるが、時間的歪みの影響を受けやすく、比較するデータのサンプル数が同じでなければならないなどの欠点がある。DTWはユークリッド距離のもつ欠点を克服した時系列データの類似度計算手法である。DTWの特徴として、時間的非線形圧縮距離を計算することで時系列のスケールや部分的な速度に違いがあるデータ間やサンプル数の異なるデータ間の類似度が求められる。DTWと同様に時系列データの認識を行うアルゴリズムとしてHMMが挙げられる。両者の違いはDTWは学習モデルをテンプレートとして保持するのに対し、HMMでは遷移確率やシンボル出力確率として保持する点である。そのため、HMMは未知のジェスチャの入力に対して事前に学習したジェスチャである尤度を出力するが、DTWは事前に学習したジェスチャとの空間的な距離を出力する。本研究ではジェスチャ動作の変化を評価することが目的であるため、その指標

として尤度よりも距離の方が相応しいと考えたため、本研究では DTW を採用する。DTW の具体的なアルゴリズムを以下に示す。長さ m と n の 2 つの離散波形 $X = (x_1, \dots, x_m)$ と $Y = (y_1, \dots, y_n)$ を比較する際、 $m \times n$ 行列 $d(x_i, y_j) = (x_i - y_j)^2$ を定義する。次に、 X および Y のインデックスのペアから成るワーピングパス $W = (w_1, \dots, w_k)$ を探索する。ワーピングパスは以下の 3 つの条件を満足する。

- 境界条件

$$w_1 = (1, 1), w_k = (m, n)$$

- 連続性

$$w_k = (a, b), w_{k-1} = (a', b') \Rightarrow a - a' \leq 1 \wedge b - b' \leq 1$$

- 単調性

$$w_k = (a, b), w_{k-1} = (a', b') \Rightarrow a - a' \geq 0 \wedge b - b' \geq 0$$

距離最小のパスを探索するために、以下の手順を適用する。

(1) Initialization:

$$DTW(0, 0) = 0$$

$$DTW(i, 0) = \infty \text{ for } i = 1, \dots, m$$

$$DTW(0, j) = \infty \text{ for } j = 1, \dots, n$$

(2) Do for $i = 1, 2, \dots, m$:

Do for $j = 1, 2, \dots, n$:

$$DTW(i, j) = d(x_i, y_j) + \min \begin{cases} DTW(i-1, j-1) \\ DTW(i-1, j) \\ DTW(i, j-1) \end{cases}$$

(3) Output:

Return $DTW(m, n)$

上式によって得られたコスト $DTW(m, n)$ が X と Y の距離となる。コンテキストを認識する際は、波形と正解ジェスチャのラベルの組である複数のテンプレートを保持しておく。入力データとすべてのテンプレートとの距離を計算し、最短距離のテンプレートに付与されているジェスチャラベルを結果として出力する。

加速度センサからデータを受信するプログラムの実装は Microsoft Visual C# 2008 で行い、PC は SONY 社製 PCG-5T1N (CPU Core2Duo 2.53GHz×2, メモリ 4.00GB) を使用した。加速度センサはワイヤレステクノロジー社製 WAA-006 を使用し、サンプリング

周波数は 50Hz でデータを取得した。

3.2 実験結果と考察

試行日 X の 1 回目から 200 回目の 1 サンプルと各試行日の 200 回分のデータとの DTW 距離の平均を図 3, 図 4, 図 5, 図 6, 図 7, 図 8, 図 9 に、分散を図 10, 図 11, 図 12, 図 13, 図 14, 図 15, 図 16 に示す。図 3 から図 9 はそれぞれ試行日 X を 1 日目, 2 日目, 3 日目, 4 日目, 5 日目, 6 日目, 7 日目とした時の被験者のうち 1 名の各試行日の 200 回分のデータとの DTW 距離の平均, 図 10 から図 16 は同じ被験者の各試行日の 200 回分のデータとの DTW 距離の分散を示している。横軸は試行日 X の 200 回のデータのうち学習データにしたジェスチャの位置 (回目), 縦軸は DTW 距離の平均および分散を示している。図 3 を例に説明すると, day2 のグラフは 1 日目の n 回目のデータと 2 日目の 200 回分のジェスチャとの DTW 距離の平均を示しており, n を 1 から 200 まで変化させている。ただし, day1 のグラフについては, n 回目のデータを距離計算する対象のデータは n 回目以外の 199 サンプルとしている。ここで, 平均値が大きいほど選んだ 1 サンプルのデータ (学習データ) との距離が大きく, 学習データとはジェスチャが似ていないということを意味している。また, 分散値が大きいほど学習データとの距離が安定しておらず, ジェスチャ動作にばらつきがあることを意味している。

まず, 平均値についての考察を行う。図 3, 図 4, 図 5, 図 6, 図 7, 図 8, 図 9 から, 学習データとする位置を前半にした場合より後半にした場合の方が DTW 距離が小さくなっていることが分かる。これはジェスチャ動作が実験の始めと終わりで変化しており, 始めの数回を学習データとする従来の手法ではそれ以降に認識するデータとの距離が大きくなることを示している。その結果, 他のジェスチャとの差異が相対的に小さくなるため誤認識が起こりやすくなると考えられる。また図 3, 図 4, 図 5, 図 7, 図 8, 図 9 から学習データを得るためのジェスチャ試行回数が増える (グラフの右に行く) につれて DTW 距離が収束していることがわかる。これは被験者がジェスチャを繰り返すうちにジェスチャに慣れてフォームが安定した, もしくは疲労によりフォームが体が疲れにくいものに変化し安定したと考えられる。図 6 ではグラフは右下がり収束していないが, このままジェスチャを続ければ他の平均のグラフと同様に収束していくと考えられる。さらに図 3, 図 4, 図 5, 図 6, 図 9 より学習データとした試行日と距離計算を行ったデータの採取日が離れるにつれて, DTW 距離が大きくなる傾向がある。これは被験者がジェスチャのフォームを忘却していったためだと考えられる。

次に, 分散値についての考察を行う。図 10, 図 11, 図 12, 図 13, 図 14, 図 15, 図 16

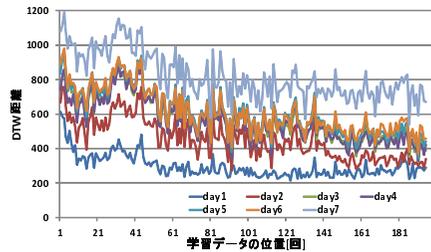


図 3 1 日目を学習データとした時の被験者 1 の平均の結果

Fig. 3 Average (user1, day1 as training data)

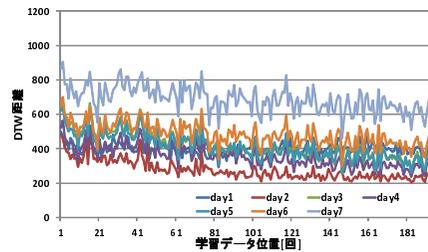


図 4 2 日目を学習データとした時の被験者 1 の平均の結果

Fig. 4 Average (user1, day2 as training data)

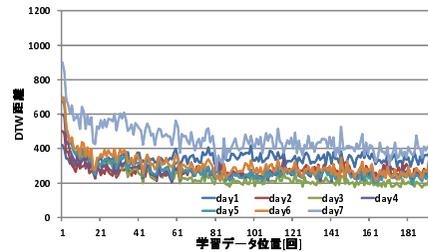


図 5 3 日目を学習データとした時の被験者 1 の平均の結果

Fig. 5 Average (user1, day3 as training data)

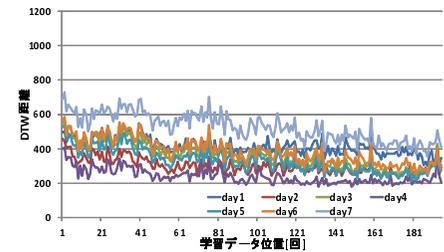


図 6 4 日目を学習データとした時の被験者 1 の平均の結果

Fig. 6 Average (user1, day4 as training data)

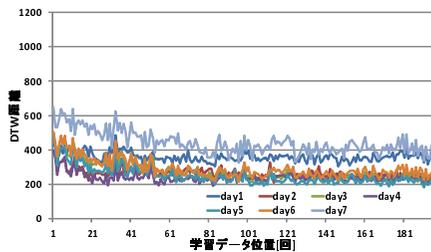


図 7 5 日目を学習データとした時の被験者 1 の平均の結果

Fig. 7 Average (user1, day5 as training data)

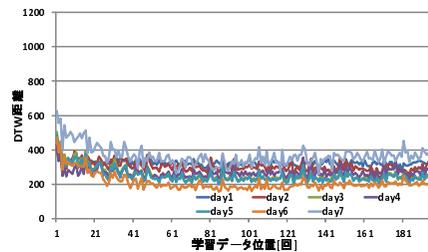


図 8 6 日目を学習データとした時の被験者 1 の平均の結果

Fig. 8 Average (user1, day6 as training data)

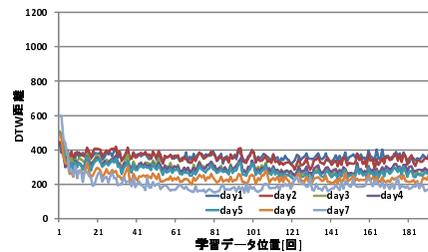


図 9 7 日目を学習データとした時の被験者 1 の平均の結果

Fig. 9 Average (user1, day7 as training data)

より、学習データの試行回数が増える（グラフの右に行く）につれて分散が小さくなる傾向がある。これは学習データが各試行日の 200 回分のデータの平均的なものに近付いていることを意味している。しかし、図 11, 図 12, 図 13, 図 14, 図 15 から 1 日目データの分散が大きくなっていることがわかる。平均のグラフは収束しているが分散が小さくない理由は、行われたジェスチャは学習データに近いが安定していないためであり、これは実験の初日は他の日に比べてジェスチャが安定しなかったことが原因であると考えられる。

得られた 5 人分の平均と分散のグラフを比較すると、平均と分散のパターンは「平均が大きく分散も大きい」、「平均が大きく分散が小さい」、「平均が小さく分散も小さい」、という 3 種類に分類されることがわかった。「平均が小さく分散が大きい」というパターンも考えられるが、DTW 距離は正の値のみを取るため、平均が小さいときに分散が大きくなるということは考えにくいので除外する。まず、平均が大きく分散も大きい場合は学習データと

認識されるデータとの距離が大きく、かつ安定していないため、その点のデータは学習データに適さない。次に、平均が大きく分散が小さい場合は認識されるデータと学習データとの距離が大きいところで安定しているため、その点を学習データとすると誤認識する可能性がある。最後に、平均が小さく分散も小さい場合は認識されるデータが学習データと近いところで安定しており、その点は学習データとして適切であると考えられる。

今回は「ボールを投げる」ジェスチャのみを行ったが、DTW 距離の平均値はジェスチャの種類に依存すると考える。例えば、動作が大きなジェスチャは誤差のスケールが大きくなり、動作時間の長いジェスチャは比較するデータ数が多くなり距離が大きくなる。逆に、動作が小さいジェスチャや動作時間の短いジェスチャは、誤差のスケールが小さく、また比較するデータ長が短いため距離は小さくなる。また、分散値は被験者のジェスチャの熟練度に依存すると考える。今回の実験結果から、ジェスチャの試行回数を重ねるにつれてフォー

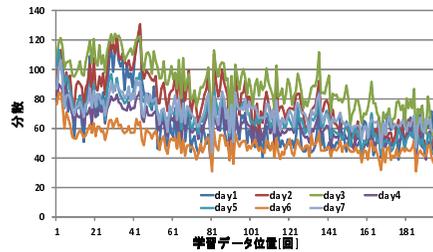


図 10 1 日目を学習データとした時の被験者 1 の分散の結果
Fig.10 Variance (user1, day1 as training data)

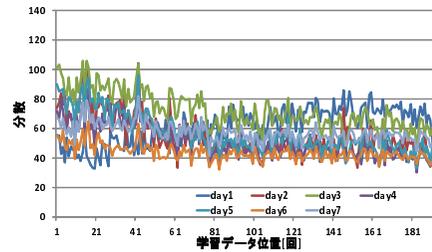


図 11 2 日目を学習データとした時の被験者 1 の分散の結果
Fig.11 Variance (user1, day2 as training data)

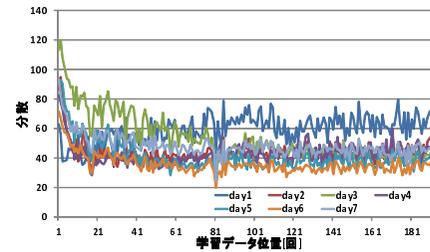


図 12 3 日目を学習データとした時の被験者 1 の分散の結果
Fig.12 Variance (user1, day3 as training data)

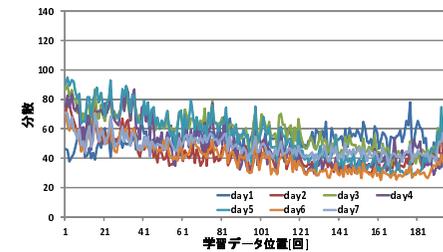


図 13 4 日目を学習データとした時の被験者 1 の分散の結果
Fig.13 Variance (user1, day4 as training data)

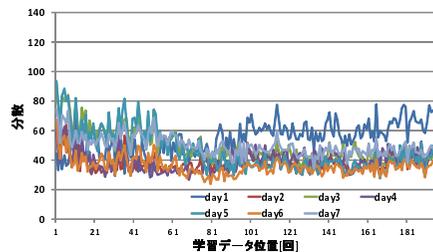


図 14 5 日目を学習データとした時の被験者 1 の分散の結果
Fig.14 Variance (user1, day5 as training data)

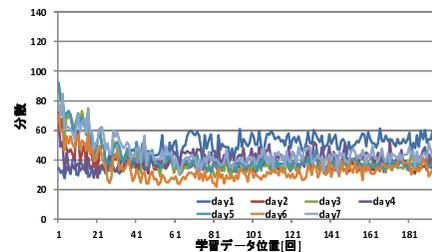


図 15 6 日目を学習データとした時の被験者 1 の分散の結果
Fig.15 Variance (user1, day6 as training data)

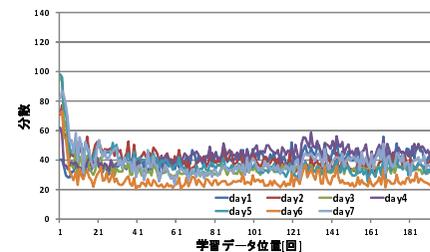


図 16 7 日目を学習データとした時の被験者 1 の分散の結果
Fig.16 Variance (user1, day7 as training data)

ムが安定していることから、対象とするジェスチャを日常的に行っているユーザとそうでないユーザではフォームの安定性が異なり、分散値に影響があると考えられる。また、同じジェスチャの呼び方でユーザによって動作の速さや大きさが異なったり、異なる動作を想像することによって DTW 距離やその分散に差が出ると考えられる。

これらの結果から、学習データは日々更新した方がよいが、それは最初の数回でなくジェスチャを複数回繰り返してフォームが安定した点が適しているといえる。また、当初、被験者がジェスチャを繰り返し行うことによって疲労すると仮定していたが、ジェスチャの慣れによる安定の影響が、あるいはジェスチャのフォームが疲労しにくいものに変化したために疲労によるジェスチャの変化が吸収されたと考えられる。この点に関して、実際に疲労の影響をどの程度受けたかは今回の実験では正確に評価することはできなかった。今後の課題として、ジェスチャの間に疲労を伴う作業を行い意図的に被験者を疲労させたり、心拍数など

から疲労を数値化しての評価を行う予定である。

4. 提案手法

前節に述べた実験の結果より、学習データとして採用するデータの適切な位置はそれ以降に現れるデータに対して DTW 距離の平均および分散が小さくなる位置であるということが明らかになった。しかし、実際に学習データを収集する際には実験のように将来得られるデータを見て適切な学習データの位置を求めることはできない。そこで、本研究では学習データの収集過程において、適切な学習データの位置をリアルタイムで判定する手法を提案する。提案手法は、被験者が認識対象のジェスチャを何回か繰り返している状態で、学習データとして適切なサンプルが現れた場合、そこで学習データの収集を終了させる。

提案手法の具体的なアルゴリズムについて述べる。流れとしては、3 節で述べた実験で収

集したデータから、提案手法によって発見したい理想的な学習データの位置を決定し、その点をオンライン処理で発見するための条件を決定する。まず、ある被験者の1日目の200回分のデータの1回目からn回目を学習データとしてnを1~200まで変化させ、2日目~7日目のそれぞれ200回分のデータとのDTW距離の平均を計算する。そして図17に示すように、得られたDTW距離の平均の最小値(終値)+10%以内で最大となった点を理想的な学習データの位置(収束点)とする。しかし、実際にはDTWの平均値の終値は不明であるため、逐次的処理で取得可能な指標を用いて収束点を検出する必要がある。

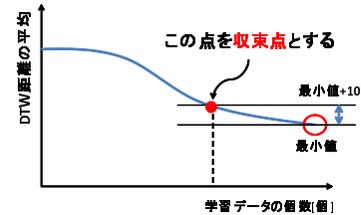


図 17 理想的な学習データの位置
Fig. 17 Ideal position for training data.

ここで、3節で述べた実験の結果より学習データとして適切な点は、他のデータとのDTW距離が小さく、分散も小さくなるのが分かっている。そこで、次のような手法を提案する。ジェスチャをx回行った時点で学習データをx-11回目のデータとして、x-10回目からx回目までのデータとのDTW距離の平均 μ_x および分散 σ_x を計算する。 μ_x と σ_x の値が以下のすべての条件を満たしたとき、その点を収束点と判断し、学習データの採取を終了する。

- $\mu_x < \mu_0$
- $\mu_x < \mu_0$
- $|\mu_x - \mu_{x-n}| < \mu_x \times 0.01, \text{ for } n = 1, \dots, 9$
- $|\sigma_x - \sigma_{x-n}| < \sigma_x \times 0.01, \text{ for } n = 1, \dots, 9$

平均および分散の計算に10回分のデータを必要とし、直近10個の平均および分散の値から収束の判定を行うため、提案手法では最低20回のジェスチャを行う必要がある。

5. 評価

提案手法の有効性を評価するために、提案手法から得られた学習データを用いて2日目から7日目までのデータのDTW距離の平均を求めた。比較手法として、1日目の終値+10%である理想的な収束点までを学習データとした場合(比較手法1)と、学習データを1日目の5回目までを学習データとした従来手法を用いた場合(比較手法2)、日ごとにその日の5回目までを学習データとした場合(比較手法3)を用いた。各手法で得られたDTW距離の平均を表1~表5に示す。

表より、提案手法を用いた結果は、比較手法1の理想的な収束点を用いた場合よりもDTW距離が大きくなっているが、比較手法2の1日目の5回を学習データとして用いる従来手法と比較してDTW距離は小さくなった。しかし、比較手法3の学習データを日ごとに変える手法と比較すると、DTW距離が大きくなっている場合もあり、提案手法が必ずしも有

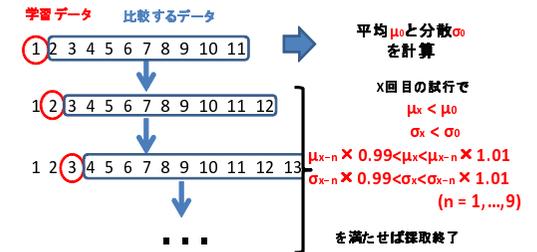


図 18 提案手法
Fig. 18 Proposed method.

表 1 被験者 1 の結果
Table 1 Result of subject1

	提案手法	理想的な収束点 (比較手法 1)	1 日目の最初の 5 回 (比較手法 2)	各試行日の最初の 5 回 (比較手法 3)
2 日目	395	255	560	372
3 日目	557	349	730	435
4 日目	525	329	662	331
5 日目	579	373	738	309
6 日目	608	404	747	287
7 日目	817	562	974	373

表 2 被験者 2 の結果
Table 2 Result of subject2

	提案手法	理想的な収束点 (比較手法 1)	1 日目の最初の 5 回 (比較手法 2)	各試行日の最初の 5 回 (比較手法 3)
2 日目	750	548	839	709
3 日目	903	724	997	592
4 日目	741	612	821	759
5 日目	754	604	834	606
6 日目	746	618	832	629
7 日目	760	631	893	624

効な手法とはならなかった。この原因としては、学習データを収集する過程においてジェスチャが理想的な収束点とは異なるフォームで安定し、それが一定期間続いてしまい、適切で

表 3 被験者 3 の結果
Table 3 Result of subject3

	提案手法	理想的な収束点 (比較手法 1)	1 日目の最初の 5 回 (比較手法 2)	各試行日の最初の 5 回 (比較手法 3)
2 日目	285	299	387	393
3 日目	331	356	444	355
4 日目	335	359	448	344
5 日目	362	393	431	352
6 日目	367	403	480	307
7 日目	400	425	482	376

表 4 被験者 4 の結果
Table 4 Result of subject4

	提案手法	理想的な収束点 (比較手法 1)	1 日目の最初の 5 回 (比較手法 2)	各試行日の最初の 5 回 (比較手法 3)
2 日目	427	427	658	560
3 日目	474	474	699	419
4 日目	439	440	628	442
5 日目	475	475	611	480
6 日目	452	452	676	400
7 日目	428	428	603	431

表 5 被験者 5 の結果
Table 5 Result of subject5

	提案手法	理想的な収束点 (比較手法 1)	1 日目の最初の 5 回 (比較手法 2)	各試行日の最初の 5 回 (比較手法 3)
2 日目	520	456	615	566
3 日目	496	432	618	506
4 日目	538	485	673	747
5 日目	524	465	695	586
6 日目	564	496	702	607
7 日目	569	484	736	601

ないデータが学習データとなったことが考えられる。また、表からもわかるように理想的な収束点を用いた場合でも、比較手法 3 と比較すると、DTW 距離が大きくなっている場合もあり、数日に一度は学習データを更新する必要があると考えられる。

次に、被験者ごとに結果を見ていく。被験者 1 と被験者 2 に関しては、比較手法 2 およ

び比較手法 3 と比べ DTW 距離が大きくなり、提案手法が有効ではない。被験者 3、被験者 4 に関しては、比較手法 1 と同程度の DTW 距離であり、比較手法 3 と比べて小さくなっている個所もあり、提案手法が有効であったと考える。被験者 5 に関しては、比較手法 1 と比べ DTW 距離が大きくなっているが、比較手法 3 と比べると小さくなっており、提案手法が有効であったと言える。このように被験者によって提案手法の有効性に差が出る結果となり、同じジェスチャであっても生じる被験者の個人差に対応するような提案手法を考えていく必要がある。

以上のような問題を解決するためには、平均および分散の閾値の見直しや、新たな特徴量を用いることなどが挙げられるが、今後の課題とする。

6. ま と め

本論文では、繰り返し行ったジェスチャのデータを 7 日分集めることにより、ユーザの疲労やジェスチャフォームの忘却がジェスチャ認識に与える影響について評価した。また、繰り返し行ったジェスチャのフォームが安定していくことから、リアルタイムで DTW 距離の平均と分散を求めることによって、ユーザの状態を考慮した適切な学習データ位置の探索方法を提案した。提案手法により、初めの数回を学習データとする従来手法と比較して、DTW 距離を小さくし、数日間学習データを更新する必要をなくすことができたが、理想的な収束点における学習データを用いる場合や学習データを日々更新する場合と比較して距離が大きく、改善の余地があることがわかった。

今後は疲労および忘却とジェスチャの関係を明確にし、評価するジェスチャ数の増加、疲労および忘却が実際の認識に及ぼす影響の大きさの評価、より高精度な学習データ位置検出のアルゴリズムを構築する。

謝辞 本研究の一部は、科学技術振興機構戦略的創造研究推進事業(さきがけ)および文部科学省科学研究費補助金基盤研究(A)(20240009)によるものである。ここに記して謝意を表す。

参 考 文 献

- 1) Murao, K., Terada, T., Yano, A., and Matsukura, R.: Evaluating Gesture Recognition by Multiple-Sensor-Containing Mobile Devices, *Proc. of International Symposium on Wearable Computers (ISWC 2011)*, pp. 55-58 (Oct. 2011).
- 2) Agrawal, S., Constandache, I., Gaonkar, S., Choudhury, R., Caves, K., and DeRuyter, F.: Using Mobile Phones to Write in Air, *Proc. of The International*

- Conference on Mobile Systems, Applications, and Services (Mobisys 2011)*, pp. 15–28 (June/July 2011).
- 3) Chambers, G.S., Venkatesh, S., West, G.A.W., and Bui, H.H.: Hierarchical Recognition of Intentional Human Gestures for Sports Video Annotation, *Proc. of International Conference on Pattern Recognition (ICPR 2002)*, pp. 1082–1085 (Aug. 2002).
 - 4) Junker, H., Amft, O., Lukowicz, P., and Tröster G.: Gesture Spotting with Body Worn Inertial Sensors to Detect User Activities, *Pattern Recognition*, pp. 2010–2024 (2008).
 - 5) Liu, j., Wang, Z., Zhong, L., Wiekramasuriya, J., and Vasudevan, V.: uwave: Accelerometer Based Personalized Gesture Recognition and Its Applications, *The IEEE Pervasive Computing and Communication (PerCom 2009)*, pp. 1–9 (June 2009).
 - 6) Myers, C. and Rabiner, L. R.: A Comparative Study of Several Dynamic Time-warping Algorithms for Connected Word Recognition, *The Bell System Technical Journal*, Vol. 60, pp. 1389–1409 (1981).
 - 7) Wireless Technologies, Inc.: <http://www.wireless-t.jp/>.