

データオーギュメンテーション技術による 行動変化点認識

赤嶺 賢作†

豊橋技術科学大学†

大村 廉‡

豊橋技術科学大学‡

1. はじめに

本研究では、加速度センサを用いた行動認識技術を扱う。行動認識技術では、一般に時系列データである加速度データから部分系列に分割するため、スライディングウィンドウが用いられる。また、通常、スライディングウィンドウでは、各窓関数はデータの変化とは独立に適用されるため、部分系列内に行動の変化点が含まれることがあり、その部分系列に対する認識では認識率の低下を招くことが多い。

この原因の一つとして、行動の変化が明示的にクラスとして扱われていないことがある。例えば、「歩く」から「走る」への行動変化が行なわれる場合、通常の行動認識では「歩く」もしくは「走る」のいずれかに分類されることになる。このため、変化点を含んだ部分系列のデータ（以下、変化点部分系列、と呼ぶ）に対し適切なラベル付けが行なわれることは非常に少ない。また、行動の変化がクラスとして扱われない要因として、行動の変化に関するデータを取得することが困難である、ということがある。通常の行動に比べ、変化は一瞬であり、部分系列として捉えられるデータは通常の行動よりも少なくなる。さらに、例えば8種類の行動を対象とした行動認識において、全ての可能性のある行動の変化を取得しようとした場合、 sP_2 種類の行動変化に関するデータを取得しなければならない。そのため十分な学習データを取得することが困難となる。

そこで本研究では、変化点をクラスとして定義するとともに、変化点部分系列を人工的に生成し、学習データとすることによってこれらの問題の解決を図る。

2. 行動変化点データ生成

変化点部分系列を人工的に作成するにあたり、それぞれ記録している行動が異なる二種類の部分系列を用いて、(1)式により合成した部分系列を作成する。

$$y(t) = w(t)x_a(t) + (1 - w(t))x_b(t) \quad (1)$$

y は合成された変化点部分系列データを表す。 x_a , x_b はそれぞれ異なる行動 a , 行動 b のセンサデータ部分系列を示す。また、 w は $0 \leq w \leq 1$ となる重みである。すなわち、式(1)によって、 $x_a(t)$ および $x_b(t)$ を $w(t)$ の比率で合成し、 $y(t)$ を生成する。概念図を図1に示す。




図1 変化点データ生成

3. 評価実験

本研究では、センサデータとして、HASC2014corpus データセットを使用した[1]。HASC2014corpus は、各行動における加速度データを主としたデータセットであり、「歩行」、「走行」、「静止」、「スキップ」、「階段を上る」、「階段を下りる」の6種類の各行動のデータと、それらを任意に組み合わせて一連の行動とした「シーケンスデータ」からなる。本研究では、HASC2014corpus 内の加速度データについて、装着位置を腰、サンプリング周波数を 100Hz とするデータを抜粋し、データセットの中から 40 人分のデータを使用することとした。

変化点部分系列を作成するにあたり、HASC2014corpus は 6 種類の行動を対象とするため、その種類数は総当たりで $sP_2=30$ 種類とした。各行動データについて、ウィンドウサイズが 2560ms、重なり 50%のスライディングウィンドウを用いて切り出しを行い、式(1)を用いて作成した変化点部分系列データを学習データとして用いた。学習に用いた変化点部分系列数は、各クラス（行動の組み合わせをラベルとするクラス）で 6510 個であり、合計 195300 個作成した。

なお、実験における $w(t)$ は、変化前の行動から変化後の行動に線形で遷移するパターン（パターン1）、 $w(t)$ を0.5で固定することで変化前と変化後を均等に合成するパターン（パターン2）、前半を変化前の行動、後半を変化後の行動として合成するパターン（パターン3）、最初3分の1を変化前の行動、中間3分の1を変化前と変化後それぞれ均等に合成したもの、最後3分の1を変化後の行動とするパターン（パターン4）の4種類のパターンを試した。図2各グラフの右上部にこれら $w(t)$ の変化を図示する。

また、このデータで学習した場合の認識率を評価するため、シーケンスデータに対して任意にスライディングウィンドウを適用し、この中から行動の変化が含まれる部分系列を取り出してテストデータとした。使用したテストデータ数は816個である。

行動認識では、各ウィンドウから平均・分散・最大値・最小値の4種類の特徴量を計算して用いた。認識器はWeka[2]の識別器(最近傍法(1-NN), SVM, ランダムフォレスト(RF))を用いた。各識別器のパラメータはWekaのデフォルトの設定を用いた。本実験では、評価基準としてF-measureで評価した。

4. 結果

それぞれのパターンにおける評価結果を図2に示す。それぞれ最もF-measureの高かったデータとして、パターン1では、SVMで0.0589、パターン2では、SVMで0.0556、パターン3では1-NNで0.0941、パターン4では1-NNの0.0957が最大となった。最も高精度の結果が得られたのはパターン4の1-NNの場合である。しかしながら、全体的に変化点に関するF-measureは0.10を下回る非常に低い結果となってしまった。

原因として、実際のデータ（テストに用いたデータ）と合成された変化点部分系列について

比較を行なった。まず、目立った特徴として、実際のデータにおける変化前/後の行動の不均一性がある。本研究では部分系列の中間に行動の変化があることを仮定し合成を行なったものの、実際のデータでは部分系列の中で、非常に早い時期、もしくは、非常に遅い時期に行動が変化しているものが多くあり、このことが実際のデータと合成データとの不一致を生じさせたと考えられる。また、実際のデータの変化点において、行動の変化は必ずしもスムーズに変化する訳ではなく、極端なピークやノイズと思われる変化点前、変化点後とも異なるデータが出現しているデータが少なからずあった。このことも、実際のデータと合成データとの不一致の原因となったと考えられる。

この他、今回用いた特徴量は平均・分散・最大値・最小値と非常に単純なものであり、変化点部分系列の特徴を十分に捕らえられなかったことが考えられる。

5. まとめ

本研究では、行動変化点を含む部分系列に対する認識精度を向上させるため、変化を考慮したクラスの割り当て、また、人工的にデータを作成する手法を試みた、6種類の対象行動としたHASC2014データセットを用いて実験を行い、3分の1ずつ変化前と変化後を合成したデータを学習データとし、最近傍法による識別器を用いた場合、F-measureは0.0957であることを確認した。

しかしながら十分な認識精度とはならなかった。原因として、変化点部分系列における変化前/後の行動の偏りや変化時の特異なデータの出現などから、今回の人工データでは実際の変化点部分系列を十分に再現できなかったことが考えられる。また、本研究ではセンサデータ同士を直接合成する方法を用いたが、特徴量をもとに合成することも考えられる。今後、これらの方法試して行きたいと考えている。

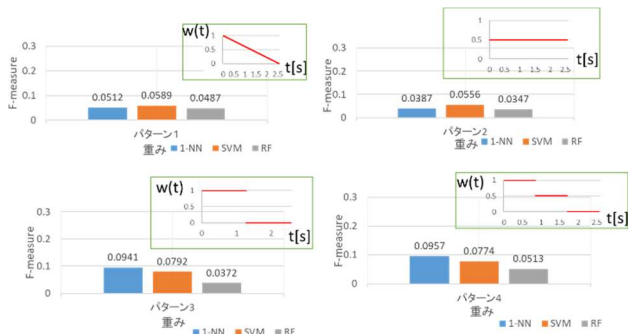


図2 評価結果

参考文献

[1] Human Activity Sensing Consortium: HASC Challenge2014, <http://hasc.jp/hc2014/index.html>, 2018-12-24
 [2] Eibe Frank, Mark A. Hall, and Ian H. Witten (2016). The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques", Morgan Kaufmann, Fourth Edition, 2016