

緊急/平時デュアルコンテキスト判定のためのセンサフュージョンによる 2 段階判定モデルの開発

A Two-Stage Sensor Fusion Model for Dual Context Recognition

佐藤 博正[†] 島川 博光[†] 原田 史子[†]
Hiromasa Sato Hiromitsu Shimakawa Fumiko Harada

1. はじめに

近年、ウェアラブルセンサを用いて人間の生体情報を収集し、そこから感情や状態を推定する技術の研究が進められている[1]。しかしながら、人間は常に移動や動作を行っており、そのときの感情や認知状態は時間、場所、行動に大きく依存する。このような背景から、単なる生体データだけでなく、その時点での行動や状況、すなわちコンテキストを反映した状態推定が必要であると考えられる。

本研究では、複数センサで取得されたマルチモーダルな時系列データを用いて、行動を検出し、その情報をもとにコンテキストを自動判定するモデルを構築する。このモデルは、産業現場での従業員状態の把握や、生活空間での快適性や緊急性の判定への応用が期待される。本研究は、センサデータと AI による行動理解と状態推定の融合により、現実世界の多様な課題にアプローチすることを目的とする。

2. 背景

ウェアラブルセンサを活用した行動認識 (Human Activity Recognition: HAR) は近年急速に発展しており、加速度やジャイロ、心拍、位置情報などのセンサを組み合わせることで、日常生活や産業現場での多様な活動推定が可能になってきている[1]。本研究でも、これらの先行技術を踏まえて、複数のセンサデータで得られる時系列のクラスタリング手法を利用する。

2.1 時系列クラスタリング

時系列クラスタリングは、センサなどで得られる連続データを分類・構造化する。3 つに大別される [2]。

全時系列クラスタリング：各時系列全体を一つの単位としてクラスタリングする。

部分時系列クラスタリング：時系列データ内の部分的なセグメントをクラスタリングする。

時間点クラスタリング：時系列の各時点でクラスタリングを行う。

本研究では、行動の発見に焦点を当てるため、部分時系列クラスタリングに着目する。

2.2 部分時系列クラスタリング手法

TS3C (Time-Series Clustering based on the Characterization of Segment Typologies) は、Aghabozorgi らによって提案された手法で、次の 2 段階から構成される[4]：

セグメント化と特徴抽出[3]：統計的基準に基づき時系列をセグメントに分割し、各セグメントに対して平均、標準偏差、傾きなどの特徴量を抽出する。

クラスタリングとマッピング：得られた特徴量をもとにセグメントをクラスタリングし、各時系列を高次元のクラスタ空間にマッピングする。

TS3C は部分的な行動パターンの抽出に有効であるが、高次元センサデータへの適用やセグメント定義の柔軟性に課題がある。

2.3 多次元での時系列クラスタリング手法

TICC (Toeplitz Inverse Covariance-based Clustering) は、多変量時系列データに対して、セグメンテーションとクラスタリングを同時に行うモデルベースの手法である[5]。各クラスタは、スパースな逆共分散行列 Θ_i によって表現され、これはマルコフ確率場 (MRF) として各時系列部分系列の構造的関係をモデル化する。

$$\min_{\{\Theta_i\}, \{P_i\}} \sum_{i=1}^K \left[\sum_{X_t \in P_i} l(X_t, \Theta_i) + \lambda |\Theta_i|_1 \right] + \beta \sum_{t=2}^T \mathbb{1}\{X_{t-1} \notin P_i\}$$

ここで

- K ：クラスタの数
- P_i ：クラスタ i に属する時系列データの集合
- $l(X_t, \Theta_i)$ ：データ点 X_t がクラスタ i に属する対数尤度
- $\lambda |\Theta_i|_1$ ：スパース性を促すための L1 正則化
- β ：時間的一貫性を保つためのペナルティ
- $\mathbb{1}\{X_{t-1} \notin P_i\}$ ：クラスタの切り替えが起きた場合に 1 となる指示関数

である。

この最適化は、交互最小化 (alternating minimization) により、クラスタ割り当てと構造推定を繰り返すことで解かれる。Toeplitz 構造の制約により、時間不変な依存構造を学習できる点が TICC の特徴である。

2.4 センサフュージョン技術

センサフュージョンとは、加速度、温度、位置など複数のセンサから得られる異種情報を統合し、単一センサでは困難な状況認識を実現する技術である。自動運転やロボティクスで広く活用されており、行動認識や状態推定への応用も進んでいる。近年では、センサフュージョンと AI を組み合わせることで、複雑な状況下におけるパターン認識や異常検知が可能となっており、人間の動作認識や行動理解への応用も期待されている。一般に、異常検知は正常なパターンからの逸脱を捉えることであり、医療、セキュリティ、機械監視などさまざまな分野で活用されている。しかし、時系列データにおいては時間依存性やノイズの影響も大きいため、正確な検出は依然として困難な課題であるとされており、Chandola らは異常検知を「通常からの逸脱を発見するプロセス」と定義し、時系列における構造理解やラベル欠如の難しさを指摘している[6]。

[†] 立命館大学情報理工学部データ工学研究室
Ritsumeikan University, Information Science and Engineering,
Data Engineering Lab

3. コンテキスト判定による行動支援

3.1 クラスタリングと行動検知の融合

本研究では、行動とコンテキストの判定を 2 段階で行うアーキテクチャを提案する。

1 つの行動は、複数の部分からなると考えられる。本研究では、部分時系列クラスタリングにより、行動の各部分の特徴を特定する。複数のセンサからの多変量のデータを用いるので、TICC を用いる。本研究では、異なるセンサからのデータを統合することで、ノイズの影響を低減しつつ、行動の微細な変化を捉える。さらに、AI 技術と組み合わせることで、リアルタイムかつ高精度な行動理解と異常検知を実現する。図 1 に時系列クラスタリングによる行動特徴の定義と 2 段階検知の融合を示す。

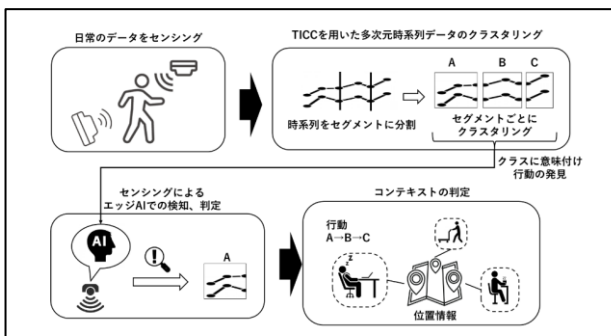


図 1 手法概要図

3.2 クラスタリングによる行動発見

取得した多次元時系列データを、TICC でクラスタリングし行動のセグメントを抽出する。行動は開始・継続・終了を持つ動的プロセスであるため、単一時点での状態推定ではなく、セグメント単位でのパターン分析が有効である。

得られたクラスターを時間軸上に並べることで、複数のクラスが連続して構成する行動単位を特定する。さらに、クラスターの平均的特徴や連続性に基づいて意味付けを行い、個々の行動の特徴を定義する。

3.3 エッジ AI による開始検知とコンテキスト判定

検知段階では、エッジ AI を搭載した加速度センサを用いて、行動の開始をデータ取得時に認識する。定義段階で得られた行動クラスを教師信号として用い、決定木を構築し、エッジ側での軽量かつ高速な判定を可能とする。

検知された開始点以降のデータはサーバに送信され、過去の行動クラスとの類似性に基づいて行動を認識する。その上で、同時刻の位置情報と組み合わせることで、コンテキストを推定する。

3.4 異常検知

本研究では、複数のセンサから取得されたデータを統合するセンサフュージョン技術と機械学習モデルを組み合わせることにより、対象行動に対する異常検知の高精度化を実現する。センサフュージョンを用いることで、単一センサでは捉えにくい微細な行動変化やセンサノイズの影響を低減し、対象の全体的な動作パターンをより正確に把握することが可能となる。

統合されたセンサデータに対して AI モデルを適用することで、通常の行動パターンからの逸脱を検出する。本研究では特に、以下の 2 種類の異常検知手法を実装する。

第 1 の手法では、行動の時間的構造 (開始・継続・終了) に基づき、行動クラスの遷移が適切でない場合を異常として検出する。具体的には、ある行動 A の開始クラスを検知した直後に、行動 B の継続クラスが観測されるような不自然なクラスの連続があった場合、それを異常とみなす。これにより、行動フェーズごとの特徴量変動を明示的に捉え、異常の早期検出を可能とする。

第 2 の手法では、同一行動クラス内においてセンサ値の異常を検出・補正する。例えば、行動 A 中に特定センサの出力が一時的に異常に高い値を示した場合、その値は当該クラスにおける他の正常データの平均値で補完される。これにより、外れ値の影響を抑制し、モデルのロバスト性を向上させる。

4. おわりに

本研究では、複数のセンサから取得した多次元時系列データに対して、センサフュージョン技術と AI モデルを組み合わせることで、行動の検出およびコンテキストの判定を実現する手法を提案した。クラスタリングベースの事前学習によって行動を抽出し、軽量のエッジ AI を用いて行動の開始をリアルタイムに検知する 2 段階構成の判定モデルを示した。また、行動構造に着目した異常検知、およびセンサ値の異常補正も導入し、システム全体の頑健性と柔軟性を高める。

本手法により、行動の時系列的な構造を把握しつつ、リアルタイムなコンテキスト理解が可能となるため、産業・生活両面での応用が期待される。たとえば、職場環境における従業員の状態把握や、生活空間における快適性の評価、さらには緊急事態の早期検知などへの展開が考えられる。

なお、これまでセンサフュージョン技術と AI の統合は、異常検出など一部の応用にとどまっていた。本研究は、センサフュージョン技術に AI 技術を本格的に組み込む取り組みの一例として位置づけられ、今後の先進的な行動理解や状態推定の基盤となることが期待される。

参考文献

- [1] Lara, O. D., & Labrador, M. A., "A survey on human activity recognition using wearable sensors," *IEEE Communications Surveys & Tutorials*, vol. 15, no. 3, pp. 1192–1209, 2013.
- [2] Aghabozorgi S., Seyed Shirghorshidi A., Wah T.Y., "Time-series clustering - A decade review", *Information Systems*, Vol.53, No.1 (2015).
- [3] Keogh E., Chu S., Hart D., Pazzani M., "Online segmentation of time series based on polynomial least-squares approximations", *Data Mining and Knowledge Discovery*, Vol.10, No.1 (2005).
- [4] Aghabozorgi S., T.Y. Wah, "Time-Series Clustering Based on the Characterization of Segment Typologies", *Knowledge-Based Systems*, Vol.76, No.1 (2015).
- [5] Hallac D., Leskovec J., Boyd S., "Toeplitz Inverse Covariance-Based Clustering of Multivariate Time Series Data", *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Vol.23, No.1 (2017).
- [6] Chandola, V., Banerjee, A., & Kumar, V., "Anomaly detection: A survey," *ACM Computing Surveys (CSUR)*, vol. 41, no. 3, pp. 1–58, 2009.