

センサデータクラスタリングによる自律移動体の異常検知システムの開発

古濱尚樹[†] 山下大貴[†] 中島碩人[†] 鎌田典彦[‡] 喜田弘司[†]

香川大学[†] 日本電気通信システム株式会社[‡]

1. はじめに

近年の宅配・郵便業界は人手不足が問題となっている[1]. この対策として人が荷物を運ぶ代わりに自律移動体(以下ドローン)が荷物を運ぶ, ドローン配送の実現が期待されている.

ドローンは荷物を運ぶ際, 故障やバッテリー切れ, 天候の影響により, 異常が発生した場合, 墜落や交通事故などを誘発し, 人や社会に害を及ぼすことになる. そのためドローン配送において, 異常をいち早く検知する仕組みが必要となる.

2. 課題

2.1. 従来方式

センサを用いた異常検知の分野には, 例えば工場の装置の可動部分などにセンサを取り付け, 得られるセンサデータを閾値処理して定められた範囲を逸脱した場合に異常とみなす方式がある. このような方式は固定設置され, 環境条件が保たれ, データに周期性のある装置を対象としている. そのため平常時と違う挙動をしたセンサデータの異常を閾値から検知できる.

2.2. 従来方式の限界

ドローンは他のドローン, 鳥などの動物, 建物を始めとする障害物, 雨風などの運行環境に対し, 自律的に対処しながら飛行する. そのためセンサデータがとりうる範囲が広く, 周期性がなく, 前述したような閾値を決めることができない.

3. 解決のアイデア

そこで我々は, データに周期性がなくとも, ドローンのセンサデータはいくつかの似通ったパターンがあると仮説をおいた. このパターンはクラスタリングで検知することができ, センサデータがこれまでにないパターンの場合はどのクラスタにも所属せず, 異常検知できる. 本稿ではこの仮説を検証し, 結果を考察する.

図1に概要図を示す. まず学習データのみでクラスタリングを行う. 次に検証データを入れ, 各クラスタの重心との距離から所属するクラスタを決定する. 決定したクラスタの重心との距離が閾値より大きければ異常と判定する.




図1 クラスタリングによる異常検知

4. 研究方針

本研究の全体像について説明する. センサによるドローンの異常検知をするにあたって, ドローンのセンサデータが十分でないという問題がある. そこで本研究の第一ステップとして, ドローンの異常検知の代わりに自転車にセンサを取り付け, 自転車の異常検知を行う. まずデータ収集を簡単に行うためバッチ処理で異常検知を試みる. 第二ステップでは実運用の要件の一つと考えられるリアルタイム処理による異常検知を目指す. 以降はドローンのセンサデータの異常検知を検討する. 第三ステップでは現在開発中のドローンシミュレータで集めたデータを, 第四ステップでは実際のドローンのセンサデータを集め, それぞれを用いて異常検知を目指す.

本稿では, 第一ステップのバッテリー切れの異常検知について述べる. このステップの最終目標としてドローンに起こる様々な異常に対応した異常検知を目指す. まずバッテリー切れという一つの異常を検知することから始める.

5. 異常検知

5.1. 異常検知の分析

3章で述べた仮説を検証するためにドローンの異常を参考に自転車で検知する異常検知項目を策定した(表1). 本研究ではドローンで起こる異常には飛行物との衝突回避, バッテリー切れ, 経路外走行大, 経路外走行小を挙げる. 本稿はドローンの異常の内, バッテリー切れを典型例とし, それぞれ似たような状況を自転車で設定した. バッテリー切れの異常は, 自転車のギアを3から1に変更することで意図的に速度を落としたデータを用いて異常検知を目指す.

表1 検知する自転車の異常検知項目

ドローンの異常	自転車の異常
飛行物との衝突回避	急ブレーキ・急カーブ
バッテリー切れ	平常時ギア3, バッテリー切れ時ギア1
経路外走行大 (GPS誤差)	経路とは反対の車線の歩道を走行
経路外走行小 (風)	横風: 経路内の端を走行 追風: 自転車の速度を上げ, 途中でブレーキ 向風: ギアを最大まで上げ, ゆっくり走行

Development of anomaly detection system for autonomous mobile vehicle by clustering sensors

[†]Naoki Furuhashi, [†]Daiki Yamashita, [†]Sekito Nakashima, [‡]Norihiko Kamata, [†]Koji Kida
[†]Kagawa University, [‡]NEC Communication Systems, Ltd

5.2. システム構成

異常検知システム(以下,本システム)は学習フェーズと検知フェーズの2つから成る(図2).

学習フェーズ: 学習データを入力し,モデルを生成する.学習データはギア3走行データを用い,モデルはクラスタリングした結果となる.

検知フェーズ: 学習フェーズで生成したモデルから各クラスタの異常判定に用いる閾値を求める.その閾値と検証データを入力し,検証データが正常か異常かのラベルを出力する.検証データはギア3から1に変更した走行データを用いる.




図2 システム構成図

5.3. 特徴量の検計

特徴量には以下の2つを用いる.

- 1) 速度の平均値
- 2) 速度の平均値の蓄積標準偏差

蓄積標準偏差とは,開始から k 秒後まで標準偏差のことである.数式を以下に示す.

$$k \text{ 秒後の蓄積標準偏差} = \sqrt{\frac{1}{k} \sum_{i=s}^k (x_i - \bar{x})^2} \quad \begin{cases} \{x | s \leq x \leq k\} \\ \{k | s \leq k \leq g\} \end{cases}$$

s はデータの範囲の開始, g は終了を指す.例えば k が 30 の場合,開始から 30 秒までの範囲のデータで標準偏差を求める.継続的に速度に変化が現れた場合,標準偏差が大きくなる.

5.4. 異常検知方式

本システムでは,学習データのみでクラスタリングし(学習フェーズ),その後検証データを1つずつ入れ,学習データから作られたクラスタの重心との距離から異常を検知する(検知フェーズ).クラスタリングには k -means を用いる.重心との距離には閾値を設ける.今回はクラスタの重心と,そのクラスタに所属するデータの最大距離とする.この閾値より大きい場合に異常と判定する.

6. 実証実験

6.1. 実験方法

自転車のセンサデータは大学内の直線距離 170m の往復データを用いる.学習データは速度が安定区間に入る,開始 15 秒から 40 秒までとし,0.2 秒刻みでデータを取得した.

本実験では 25 秒から 27 秒の間にギアを変更している.そこで 15 秒から 25 秒までを正常,25 秒から 40 秒までを異常と正解ラベルをつけた.これら

の正解ラベルと本システムが出力したラベルの正誤から,適合率,再現率(真陽性率),真陰性率 3 つの評価軸を設定する.また,最適なクラスタ数についても検討した.今回は 5 から 30 までクラスタ数で実験を行った.

6.2. 実験結果

実験結果は有効数字 2 桁とした.まず最適なクラスタ数について検討した.図 3 に各クラスタの適合率,再現率,真陰性率を,表 2 にクラスタ数が 15 のときの混同行列を示す.クラスタ数が 15 のとき,適合率と真陰性率が 1.0 と高い結果が得られた.対して再現率は 0.13 と低く,クラスタ数を増やしても,最大 0.34(クラスタ数が 21 のとき)までという結果になった.




図3 最適なクラスタ数

表2 クラスタ数 15 のときの混同行列

		システムが出力したラベル	
		異常	正常
正解ラベル	異常	30	206
	正常	0	149

6.3. 実験結果の考察

適合率が高い結果から,本システムが異常と判定したデータは異常である可能性が高いといえる.また,真陰性率が高く,再現率が低い結果から,本システムは正常のデータを取りこぼし少なく正常と検知できてはいるが,異常のデータを正常と誤検知している数が多いといえる.

再現率が低い原因の一つとして,ギアを変えたタイミングからしばらく走行した後,速度に変化が現れるからだと考えられる.そのためギアを変えた直後から速度が落ちるまでの間は,異常であるものの正常と判定されてしまうため,誤検知が多くなっているといえる.このことから第一ステップのバッテリー切れの異常検知として,ギアを変更した直後の異常を検知できるように,新たな特徴量を見つける,閾値を再設定することで,精度を向上できると考える.

参考文献

- [1] 宅配・郵便業界における人手不足について,
https://www.mof.go.jp/public_relations/finance/201810/2018101.pdf (2020年1月9日)