

ドローン配送におけるセンサを活用した 状態経過観察方式の開発

古瀨 尚樹¹ 中島 碩人¹ 黒部 誠規¹ 鎌田 典彦² 喜田 弘司¹

概要：近年、宅配・郵便局業界における人手不足を解消するために、ドローン配送が期待されている。ドローン配送ではドローンは自律飛行して配送するため、ドローン自らが異常を検知できる必要がある。しかし、ドローン配送において異常検知すればすぐにその場で着陸するという対処は、人と衝突してしまう危険や、水上に着陸することで荷物の回収が困難になるなどの問題がある。そのため、ただ着陸するのではなく、異常に対して適切な対処が不可欠である。そこで、ドローンに搭載されたセンサを用いて、ドローンの状態を推定し、その結果をもとに状態を経過観察することで異常判定する方式を提案する。異常判定結果から対策を打つことで、適切な対処をすることができる。本論文では、ドローンの動作コマンド (f, fcw, fccw) と、意図的に発生させた風 (wind) を教師ラベルとして、センサによる学習を行い、作成したモデルからドローンの状態を推定し、その状態を経過観察する方式を開発した。状態推定では精度 0.72、状態経過観察方式による異常判定では、学習データには見られなかった急上昇するという挙動を異常と判定した。

Development of a Sensor-Based State Monitoring Method for Drone Delivery

NAOKI FURUHAMA¹ SEKITO NAKASHIMA¹ MASAKI KUROBE¹ NORIHIKO KAMATA²
KOJI KIDA¹

1. はじめに

近年、宅配・郵便局業界における人手不足が問題となっている [1]。これを解決するために、新たな配送形態として、人の代わりに荷物を運ぶドローン配送の実現が期待されている。

ドローン配送には2つの利用シーンがある。1つ目は人が運ぶには効率が悪く収益性が低い、離島や山間部、過疎地域などにおける配送である。人が配送する場合、配送先が分散し、荷物量も少ないため効率が悪く、時間的コストが多大にかかってしまう。2つ目は都市部における各配送拠点から目的地 (企業、個人宅等) までのラストワンマイル配送である。都市部は人口が集中するため荷物量が多く、配達する人員が足りていない。本研究では、ドローンによるラストワンマイル配送実現を目指している。

国土交通省の定めるドローンの飛行の環境整備では、ドローンの飛行形態をレベル1からレベル4の4段階にわけられている (図1) [2]。1つ目の配送が無人地帯における補助者なしの目視外かつ自律飛行 (レベル3) である。日本でも実証実験の実施や [3]、サービス展開 [4] をしている。2つ目の配送が有人地帯における補助者なしの目視外かつ自律飛行 (レベル4) である。2022年度を目処に制度整備している段階であり、現在はレベル4に向けたドローン管制システムの開発・実証実験が行われている [5]。

制度整備に関しては、国土交通省が公表した、ドローンを活用した荷物等配送に関するガイドライン Ver.1.0 (法令編) [6][7] にあるとおり、道路交通法などの関係法令の適用関係や手続きが不明確なところが改善されてきている。このガイドラインにより、ドローンが上空に通過するために必要な飛行手続きや関係機関との調整が大幅に簡略化された。

以上を踏まえ、ラストワンマイル配送実現に関連するレベル4運行に関する制度整備が進んでおり、近い将来、ド

¹ 香川大学
Kagawa University

² 日本電気通信システム株式会社
NEC Communication Systems, Ltd.

- 無人航空機の飛行の安全を確保し、その利活用拡大を図るため、航空法では、無人航空機の飛行の許可・承認制度（平成27年改正）、登録制度（令和2年改正）など、段階的に環境整備を進めている。
- ドローンに関する技術の向上、物流等の利活用へのニーズが高まっている中、2022年度を目途に、現行では飛行を認めていない「有人地帯における補助者なし目視外飛行」(レベル4)を実現すべく、交通政策審議会等において検討を行ってきたこと。



図 1 ドローンの飛行の環境整備 [2]

ローンのレベル4運行によるラストワンマイル配送が実施されると考えられる。しかし、技術的課題はまだ残っており、その例としてドローンの異常判定とその異常に対する対処が挙げられる。

ドローンによるラストワンマイル配送では、特定の空域内を複数のドローンが飛び交い、荷物を運ぶことが想定される。その条件下で円滑な配送を実現するために、ドローンの飛行状況や飛行空域の情報を収集し、それらの情報を一括に管理して、適宜ドローンに指示を与える管制が必要である。

ドローン配送の初期段階では、安全のため人による管制が行われると考えられる。しかし、管制には専門スキルが必要なことに加え、人手不足解消のためのドローン配送に人を割いてしまっているという問題がある。さらに、ドローン配送が普及していくにつれ、数台のドローンによる配送ではなく、数百、数千の規模の配送になる可能性が高い。そのような将来を見据えれば、人がすべてのドローンを管制することは現実的ではない。

管制の役割の1つとして、ドローンに発生し得る異常(故障、攻撃、風にあおられる等)を把握し、適切に指示することが挙げられる。この異常を把握すること(判定)と、異常に応じた指示をすること(対処)の2つを、すべて管制がするには負担が大き過ぎると言える。

以上より、ドローンに起きる異常はドローン自身で判定・対処させることで、管制の負担を減らすことができる。これは管制の負担軽減だけでなく、判定からの対処を迅速にできるため、安全性と可用性を確保することにも繋がる。ここでの安全性とは、ドローンが人に害を及ぼす障害を防ぐことであり、可用性とは、ドローン配送の運行要件を満たすことである。

ドローンの異常とは、ドローンを通常の自律配送時とは異なる制御をさせる必要があることと定義する。ドローンの異常には、ドローン内部に起因する異常と外部環境に起因する異常の2種類がある。ドローン内部に起因する異常では、ドローンのモーターの故障、プロペラの破損、バッテリー不足などが挙げられる。外部環境に起因する異常で

は、雨風などの天候、ドローンの乗っ取りなどのサイバー攻撃 [8] などが挙げられる。

例えば、バッテリーの残量が少なくなっている、といった異常は、単純に閾値を設定することで、閾値を下回れば異常として検知することができる。しかし、先に挙げたように、ドローンの異常には内部に起因する場合と外部環境に起因する場合があります。これらを見分けるには、このような方式ですべての異常を判別できない。異常の判別ができなければ、安全面を考慮して着陸する対処しかすることができない。

そこで、我々はドローンに搭載された加速度やジャイロなどのセンサから学習した機械学習モデルに基づき、ドローン自身が2種類の異常を判定し、適切に対処することを目指す。本論文では、センサを活用した状態経過観察方式の提案および開発について述べる。

2. 関連研究

異常検知の研究分野は、異常のデータが非常に少ないことから、教師なし学習によるアプローチが主流である。

Chowdhury[9]らは、カメラ映像とIMUセンサを活用したドローンの異常検知に関する研究を行っている。カメラ映像からは、映像の角度を推定する深層学習モデルAngleNetを提案しており、推定された角度を異常度としている。IMUセンサからはオートエンコーダを用いてセンサを再構成し、実測値との誤差を異常度としている。これらの異常度をアンサンブル学習することで異常検知している。

他にも教師なし学習によるドローンの異常検知に関する研究は既に行われている [10][11] が、これらの研究は異常を検知することをスコープとしており、その対処法までは考慮されていない。教師なし学習による異常検知は正常か異常かの2値でしか判定しないため、ドローン配送の実運用を考えれば、異常と検知されたときは安全面を考慮して着陸する対処しかすることができない。これはドローン配送において重要な安全性と可用性の確保が不十分である。

本研究では、ドローンによるラストワンマイル配送実現を目指しており、ドローン配送の実運用を視野に入れた異常判定とその異常に対する対処に関して、これらの研究とは異なる。

3. 課題

現状、ドローン配送のサービスは離島や山間部、過疎地域などの一部の場所に限定されている [4]。そのため、ドローンに何らかの異常が発生した場合、安全面を考慮するために予防的な対処として着陸させることができた。しかし、レベル4運行による配送では有人エリア上空を飛行するため、着陸させる対処は必ずしも安全性と可用性を担保できない。

安全性の観点で言えば、着陸させることによって、地上の人や車両、送電線、重要施設などと接触してしまう危険

性がある。

可用性の観点で言えば、着陸させることによって、決まった時刻までに荷物が届かなくなる可能性がある。例えば、着陸位置が河川などの水上であれば回収困難になり、山奥であればGPSが辿れず行方不明になり、都市部であれば第三者に盗難されるなどが挙げられる。

いずれの観点からも、このような問題が想定される状況下でも、ドローンを着陸させなければならないほど危険な状態でない限り、前記のような問題が起きない場所で着陸させるべきである。そうしなければ、配送の要件を満たさないため、ドローン配送のサービスそのものに支障が出てくる。これはドローン配送の信用問題にも影響しかねない。

つまり、ドローン配送において、安全性と可用性を両立した運用をすることが課題である。

4. 解決のアイデア

この課題を解決するために、異常を見分けることと見極めることが必要である。見分けることでは、複数あるドローンの状態から異常を判別する。見極めることでは、判別した異常が配送をすぐに中止させなければならないほど危険な状態なのか、若干不安定な飛行は続くが配送自体は十分継続可能な状態なのか判断する。

そこで、単一の異常判別結果からすぐに対処するのではなく、ある時間幅をとった状態の変化から総合的に判定する方式を提案する。具体的には、ドローンに搭載されたセンサを用いて学習した機械学習モデルから状態を推定し（見分ける）、その状態を経過観察する（見極める）ことで解決する。これにより、異常の度合いから早急に対処しなければならない異常か判断でき、さらに異常に対して最良の対処法が着陸か、別の対処法なのか判断できる。

5. 提案方式

5.1 全体構成

提案方式の概要を説明する(図2)。

オフライン処理：ここでは事前に集めたドローンのセンサデータの特徴ベクトル(5.4節)として学習を行い、状態モデルを作成する。学習データには正常飛行と異常飛行の2種類あり、正常飛行は扇風機を当てずに飛行させ、異常飛行は扇風機を経路上に設置して飛行させた。それぞれで集めたデータを正常飛行センサデータ、異常飛行センサデータと呼ぶ。データの収集方法は5.2節で説明する。

異常ラベリング部では、異常飛行センサデータが飛行中どの時間帯で風にあおられたかをラベリングする。正常飛行センサデータには飛行の動作コマンドラベルが記述されているが、異常飛行センサデータにはどの時間帯で風にあおられたかのラベルはないため、この処理を行う。これは状態学習部での状態の教師ラベルとして用いる。ラベリング手法は5.2節で説明する。

状態学習部では、状態の教師ラベルを紐付けられたセン

サデータをもとに学習を行い、状態モデルを出力する。オンライン処理では、この状態モデルをもとに、飛行中のドローンのセンサデータと状態モデルをマッチングさせ、状態を推定する。

オンライン処理：状態推定部では、現在飛行中のドローンからリアルタイムにセンサデータを受け取り、ドローンの状態を推定する。この推定はオフライン処理で学習して作成した状態モデルをもとに行う。推定した状態は状態ラベルとして出力される。

状態履歴異常判定部では、状態ラベルを状態履歴として記録し、この記録と状態履歴異常ルールをもとにドローンの異常を判定する。状態履歴異常ルールは状態ラベルごとに用意し、各ルールはある状態が何回続いたかや、状態の発生順序などが条件として記述される(6.2節)。ある状態ラベルを観測したドローンが、いずれかの異常ルールの条件を満たしたとき異常と判定する。判定した異常は異常ラベルとして出力される。以上のように状態を履歴として記録し、履歴に基づいた異常ルールの条件を定義することで、状態1つから異常判定するのではなく、状態の経緯から異常を判定することができるようになる(経過観察)。

対策決定部では、異常ラベルを入力としてドローンがとる適切な対策を決定し、ドローン制御部に渡す。ここではあらかじめ、異常ラベルと紐付けられた対策ルールを用意しておく。ある異常ラベルを観測したドローンは、対策ルールをもとに対策を打つ。決定された対策はドローン制御部によってドローンの動作として反映される。

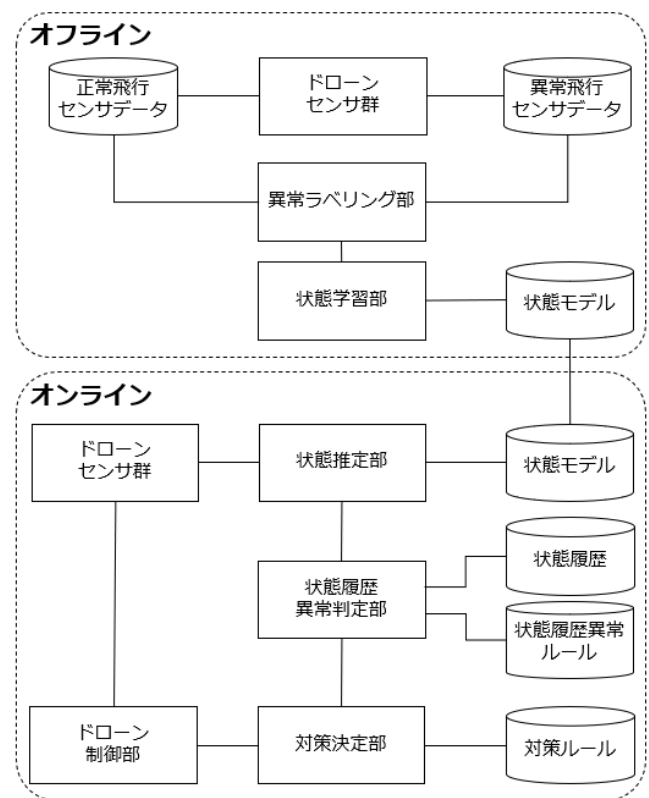


図2 システム構成図

5.2 データ収集方法

本実験では図3のような実験室環境で小型なドローンを飛行させ、データを収集した。緑色のテープはドローンが飛行する経路を意味し、ドローンはこのライン上を飛行するようプログラムされている。経路の途中にある扇風機は、意図的に発生させる風による外乱のために設置している。

ドローンはプログラミング学習用ドローンである Tello[12]を採用した。Tello はプログラムによる動作命令が容易にでき、姿勢制御に用いられているセンサ類や空撮用のカメラ映像を収集することができる。しかし、1つの動作命令をコマンドにより命令することが基本動作となっており、ドローン配送のような飛行経路から外れた場所を飛行したとき、もとの飛行経路上に戻るといった動作をすることができない。例えば「forward 200」というコマンドは「前に2メートル進め」、「cw 90」というコマンドは「90度時計周りに回転しろ」となる。

そこで本実験では、スマートフォンやコントローラから Tello を操作するためのコマンド (RC コマンド [13]) を用いて、床に貼られたテープをラインとしてトレースし、飛行させた。RC コマンドは左右、前後、上下、Z 軸回転を同時に命令することができる。ドローン配送では飛行経路上に戻る動作をウェイポイントと呼ばれる空域上に置かれた座標と GPS を用いて行うが、本実験環境では Tello に搭載されたカメラを用いて同様の処理をした。カメラで検出したテープの重心点とカメラの映像の中心点から、Tello がライントレースするために必要な回転角を計算した。RC コマンドにより必要回転角を更新しながら前進する動作を命令し続けることで、ライントレースを実現した。

以上の環境より、離陸、ライントレース、着陸の流れでドローンは飛行する。この1回の飛行を1フライト1単位として、センサデータを収集する。今回は収集したセンサデータの内、ライントレース中のデータのみ学習データとして用いる。センサデータは0.1秒ごとに収集しており、これは Tello が取得できる最小のサンプリング周期である。

5.3 ラベリング

本実験環境では、異常のケースとして外乱による風を意図的に発生させるために、飛行経路の途中に扇風機を設置した。これにより、ドローンが風にあおられたときのセンサデータを収集する。

収集したセンサデータの内、どの時間帯でドローンが風にあおられたかのラベルをつけるために、k-近傍法 ($k=1$) による教師なしアルゴリズムを用いた。正常飛行センサデータの特徴ベクトルとして (5.4 節) 学習し、正常飛行モデルを作成する。このモデルと異常飛行センサデータの1近傍の距離を計算することで、異常飛行センサデータの中から正常飛行センサデータにも見られた挙動は距離が近く、正常データでは観測されなかった挙動は距離が遠くなる。この距離を異常度と呼称する。



図3 データ収集環境

異常度が大きい値は、正常飛行センサデータでは観測されなかった挙動=扇風機の影響を受けた時間帯であると仮定した。異常度を0~1の範囲に収まるよう正規化し、ヒストグラムを可視化した (図4)。この異常度の分布から、信頼係数90%として信頼区間推定を行い、上側信頼区間0.592が求まった。これより、距離が0.592より大きい観測値が統計的に観測されにくい、つまり、扇風機の影響を受けた時間帯としてラベリングした。

例として、加速度X、各特徴ベクトルから算出した異常度、そのときの閾値を可視化した (図5)。左から各フライトが順に並んでおり、青色の折れ線グラフが加速度Xの値、赤色の折れ線グラフがそのときの異常度、黒色の線が閾値である。閾値より大きい異常度のみラベリングした。




図4 異常度のヒストグラム




図 5 加速度 X、異常度、閾値の可視化

5.4 特徴ベクトル

収集したセンサデータの内、加速度センサ、ジャイロセンサ、距離センサ（床からの高さ）を特徴ベクトルとして使用する。加速度センサとジャイロセンサは実測値から新たに特徴ベクトルを作成し、距離センサは特に変換等行わずそのまま用いた。

加速度センサの X、Y、Z 軸をそれぞれ a_x, a_y, a_z とする。これらの加速度から合成加速度 a は (1) で表される。

$$a = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (1)$$

これより、合成加速度を a が求まる。また、ジャイロセンサの各角速度を g_x, g_y, g_z とする。

これら $a_x, a_y, a_z, a, g_x, g_y, g_z$ を基本特徴ベクトルと呼ぶ。基本特徴ベクトルから、ウィンドウサイズ 10 として、ウィンドウサイズ内のデータに対する最小値、最大値、中央値、平均、標準偏差、歪度、尖度、二乗平均平方根、回帰係数を用いた時間領域における特徴ベクトルを作成した。

時間領域における特徴ベクトルについて簡単に説明する。取得したセンサデータを x_i で表し、N 個センサ時系列を $X = \{x_i | i = 1, 2, 3, \dots, N\}$ とする。

最小値は X の中で最も小さい値、最大値は X の中で最も大きい値、中央値は X をソートしたときに真ん中にくる値である。

平均はデータの中間的な指標である。(2) で表される。

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

標準偏差はデータのばらつき具合を表す指標である分散の平方根をとった値である。(3) で表される。

$$s = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (3)$$

歪度はデータの分布の非対称性を表す指標である。(4) で表される。

$$\beta_1 = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{s} \right)^3 \quad (4)$$

尖度はデータの分布の尖り度と裾の広がり度を表す指標である。(5) で表される。

$$\beta_2 = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{s} \right)^4 \quad (5)$$

二乗平均平方根はデータの二乗値の平均を算出して平方根をとった値である。(6) で表される。

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i)^2} \quad (6)$$

回帰係数はデータが右肩上がりか、右肩下がりかの傾きを表す指標である。時間 t として、線形回帰モデル $\hat{X} = at + b$ で表される。 \hat{X} は推定された予測値、 a は傾き、 b はバイアス（切片）を表すパラメータである。 a と b は予測値 \hat{X} と実測値 X の誤差が最小になる値となる。 a を回帰係数として用いる。

以上、9 種類の計算を基本特徴ベクトルに対して行った。したがって、基本特徴ベクトル 7 次元、時間領域における特徴ベクトル $7 \times 9 = 63$ 次元、距離センサ 1 次元を合計した $7 + 63 + 1 = 71$ 次元を特徴ベクトルとして用いる。

6. 実験

6.1 状態推定

本実験環境において Tello は飛行中、前進 (f:forward)、時計回りをしながら前進 (fcw:forward clockwise)、反時計回りをしながら前進 (fccw:forward counterclockwise) の 3 状態で飛行する。これらの状態は動作命令として収集したセンサデータ内に含まれている。この 3 状態以外の状態になったとき、Tello は何らかの問題が発生している可能性がある。

本論文では、3 状態以外の状態として、風にあおられたときのデータ (wind) を用いる。3 状態のラベルと 5.3 節でラベリングした風にあおられたときのラベルをもとに学習し、作成されたモデルから Tello の状態を推定する。機械学習モデルにはランダムフォレスト、LightGBM、ロジスティック回帰、k-近傍法で分類した。それらの結果から状態推定精度が高く、予測を高速で行えたランダムフォレストを採用した。

正常飛行センサデータ 35 フライト、異常飛行センサデータ 35 フライト、合計 70 フライトで学習し、異常飛行センサデータ 15 フライトで評価する。学習データは f は 3256 件、fcw は 4384 件、fccw は 6394 件、wind は 290 件、テストデータは forward は 179 件、cw は 578 件、ccw は 875 件、wind は 105 件であり、ラベルに偏りがある。そのため、ランダムフォレストのハイパーパラメータ `class_weight` を `balanced` として学習した。他のハイパーパラメータは交差検証より、`max_depth=10`、`max_features=10`、`n_estimators=100`、

min_samples_leaf=4、min_samples_split=2とした。状態推定の混同行列 (confusion matrix) を (図6) に示す。結果、精度 (accuracy) は 0.72 (表1) となった。

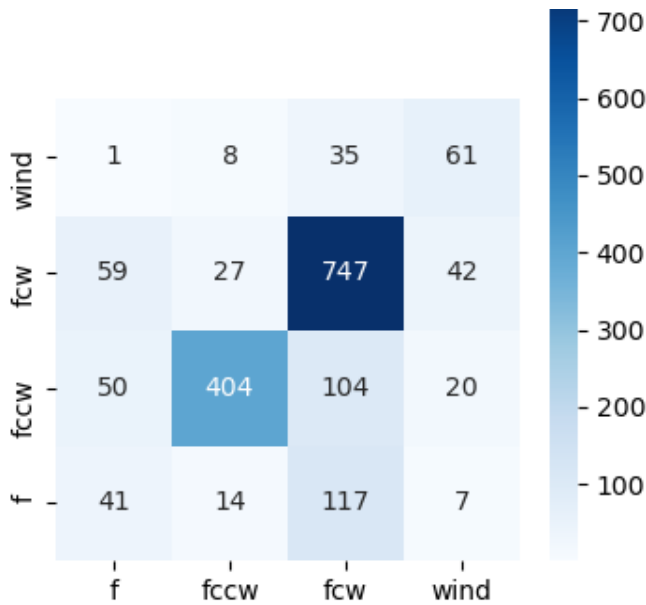


図6 状態推定混同行列

表1 状態推定評価結果

	precision (適合率)	recall (再現率)	f1-score (F 値)
f	0.27	0.23	0.25
fccw	0.89	0.70	0.78
fcw	0.74	0.85	0.80
wind	0.47	0.58	0.52
accuracy (精度)			0.72

6.2 状態経過観察方式による異常判定

状態推定部による推定結果 (状態ラベル) をもとに異常判定する。ドローンが異常かどうかの判定は状態履歴異常ルールに基づく。ドローン配送の実運用では、このルールを運用者が適宜作成することで、空域環境や運ぶ荷物などによって柔軟に変更することができる。本論文では、このルールは筆者が作成した。

状態履歴異常ルールには、各状態ごとに1フライトの間に推定される件数 (all_count) と、1フライト間に連続して推定される件数 (seq_count) を記述した。

fは前進飛行のため、本実験では何回推定されても異常と扱わず、all_countとseq_countともに300とした。なお、サンプリング周期は0.1秒であるため300は30秒を意味し、1フライトは30秒ほどであるため、事実上異常判定しないことになる。

fcwとfccwは時計回りもしくは反時計回りに回転しながら前進飛行するため、回転動作が何度も続くようなケー

スで異常と判定する。このようなケースには例えば、扇風機の横風の影響により、ライン上を飛行できないなどが挙げられる。今回はall_countを300、seq_countを100とした。ライントレース中は15秒ほどであるため、100はライントレース中の2/3ほど回転動作が続くと異常となる。

windは外乱として横から扇風機を当てたときの飛行であるため、f、fcw、fccwよりも厳しく設定した。今回はall_countを20 (合計で2秒)、seq_countを5 (連続して0.5秒)とした。

状態履歴異常判定部では、扇風機を当てて飛行した24フライトのデータを用いて異常判定した。これら24フライトはすべて扇風機を当てて飛行しているが、離陸、ライントレース、着陸まで問題なく飛行できたデータである。図7に実験結果を示す。図7の上側は24フライトの各フライトが順に並んでいる。それぞれ、青色が加速度Z、橙色がwindを推定している間、赤色が異常判定結果である。実験結果から、windのseq_countにより、16フライト目で異常判定していることがわかった。

Telloにはカメラも搭載されており、そのカメラにより集めた映像を見ることで、各フライトの飛行を確認できる。映像より16フライト目は扇風機の影響により、急激に上昇していることがわかった。このとき、図7の下側から、加速度Zも大きく変化していることもわかる。

6.3 考察

状態推定の精度は0.72であり、高い精度があるとは言えない。この原因は3つあると考える。

1つ目は状態ラベルに偏りがあることである。学習データ70フライトの内、最大fccwが6394件、最小windは290件である。このように教師あり学習をするにはあまりラベルの偏りが大きいと、精度が低いと考えられる。

2つ目はwindのデータ数が少ないことである。ラベルに偏りがあったとしても、十分なデータ数があれば精度向上が見込めると考える。

3つ目は各ラベルが2状態、もしくは3状態同時に起きていることである。fcwとfccwは前進と回転の2状態が同時に起きている。windに関しては、2状態としてwindとf、3状態としてwindとfcw、windとfccwのいずれかが起きている。このように状態ラベルが独立ではないため、精度が低いと考えられる。

評価に用いた24フライトの内1フライトのみ異常判定した。Telloのカメラ映像より、この1フライトでTelloが急激に上昇していることがわかった。このことから、学習データには観測されていなかった急上昇するといった動作を誤検知したのだと考えられる。

7. おわりに

本論文では、ドローン配送におけるセンサを活用した状態経過観察方式の提案および開発について述べた。ドロー




図 7 異常判定実験結果

ン配送において、安全性と可用性を両立した運用をすることが課題である。その例として、異常判定したドローンが着陸することによって、人との接触や荷物の行方不明などを挙げた。この課題を解決するために、異常を見分けることと見極めることを述べ、その方式を提案した。

提案方式である状態推定と状態経過観察方式による異常判定に関して実験を行った。状態推定は精度 0.72、状態経過観察方式による異常判定は急上昇を誤検知した。

状態推定と状態経過観察方式による異常判定について、それぞれ今後の課題を述べる。状態推定では、精度向上を目指すとともに、マルチラベルを予測するモデルを作成し評価する。これは本論文での状態ラベルが複数の状態が同時に起きているからである。状態経過観察方式による異常判定では、実際に墜落したなど、異常であると自明なデータを用いて評価する。これは異常の見逃しを評価できていないためである。

参考文献

- [1] 財務省, "宅配・郵便業界における人手不足について", 入手先 (https://www.ipsj.or.jp/journal/submit/ronbun_j-prms.html) (参照 2021-04-22).
- [2] 国土交通省, "無人航空機 (ドローン) の飛行の環境整備", 入手先 (https://www.kantei.go.jp/jp/singi/kogatamujinki/kanminkyougi_dai15/siryou1.pdf) (参照 2021-04-22).
- [3] 日本郵便, "小型無人航空機を用いた配送試行の実施", 入手先 (https://www.post.japanpost.jp/notification/pressrelease/2020/00_honsha/0317_01.html) (参照 2021-04-22).
- [4] 楽天, "Rakuten Drone Project", 入手先 (<https://drone.rakuten.co.jp/project/>) (参照 2021-04-22).
- [5] KDDI, "KDDI スマートドローンの管制システム", 入手先 (<https://news.kddi.com/kddi/corporate/newsrelease/2021/03/25/5026.html>) (参照 2021-04-22).
- [6] 国土交通省, "ドローンを活用した荷物等配送に関するガイドライン Ver.1.0(法令編)【本文】", 入手先 (<https://www.mlit.go.jp/common/001396667.pdf>) (参照 2021-04-22).
- [7] 国土交通省, "ドローンを活用した荷物等配送に関するガイドライン Ver.1.0(法令編)【概要】", 入手先 (<https://www.mlit.go.jp/common/001396693.pdf>) (参照 2021-04-22).
- [8] 野波健蔵編著, "続・ドローン産業応用のすべて", オーム社, 2020, pp.298-301.
- [9] Sayeed Shafayet Chowdhury, Kazi Mejbaul Islam, Rouhan Noor, "Unsupervised Abnormality Detection Using Heterogeneous Autonomous Systems", arXiv:2006.03733, 2020-07.
- [10] Nadarasar Bahavan, Navaratnarajah Suman, Sulhi Cader, Ruwinda Ranganayake, Damitha Seneviratne, Vinu Maddumage, Gershom Seneviratne, Yasinha Supun, Isuru Wijesiri, Suchitha Dehigaspitiya, Dumindu Tissera, Chamira Edussooriya, "Anomaly Detection using Deep Reconstruction and Forecasting for Autonomous Systems", arXiv:2006.14556, 2020-06.
- [11] Vikas Sindhwani, Hakim Sidahmed, Krzysztof Choromanski, Brandon Jones, "Unsupervised Anomaly Detection for Self-flying Delivery Drones", IEEE International Conference on Robotics and Automation (ICRA), 2020.
- [12] Ryze Technology, "Tello", 入手先 (<https://www.ryzerobotics.com/jp/tello>) (参照 2021-04-22).
- [13] Ryze Technology, "Tello SDK 2.0 User Guide", 入手先 (<https://dl-cdn.ryzerobotics.com/downloads/Tello/Tello%20SDK%202.0%20User%20Guide.pdf>) (参照 2021-04-22).