

ドローンの羽音を利用した個体識別

室崎 之典^{1,a)} 小野 龍一¹ 斉藤 佑祈¹ 大淵 康成¹ 羽田 久一¹

概要：エンターテインメント分野での、ステージ等における複数台のドローンの演出を行うには、各個体の識別は必要不可欠である。ドローンに何も施さずとも個体識別が可能となるシステムの提案をする。本稿ではその提案の実現のため、機械学習を用いてこれらを実現させる。羽音から抽出できる音響的特徴のみを用いて機械学習により識別を試み、全く同じ機種での識別を行なった。結果、最大 80 % の確率で同機種での個体識別に成功した。

キーワード：ドローン、個体識別、音、機械学習

Individual Drone Identification using Drones' Feather Sounds

MUROSAKI YUKINORI^{1,a)} ONO RYUICHI¹ SAITO YUKI¹ OBUCHI YASUNARI¹ HADA HISAKAZU¹

Abstract: Recognizing individual drone at the same time for entertainment contents is important. In this paper, we propose a method to identify drones without doing anything on a drone. We employ a machine-learning to identify drones by their noises. As a result, we identified each drone even if the same model with a probability of 80 percent.

1. はじめに

1.1 研究背景

近年ドローンを用いた演出表現が普及してきている。ドローンを使用した演出の例として、Elevenplay と RhizomatiksResearch の 24drones[1] では、24 台の小型ドローンが機械学習の手法を取り入れることで、お互いにぶつからない安全な距離を常に保ちつつ 3 人のダンサーとパフォーマンスを行っている。Sky Magic live at Mt.Fuji[2] では、富士山を舞台とし、20 台を超えるドローンの編隊飛行、三味線の生演奏、MIDI コントロールされた 1 万 6500 個の LED ライトでのライブ演出がある。500 機のドローンを使ったライトショーでギネス記録を更新した Intel の Intel' s 500 Drone Light Show[3] などがある。これらの複数制御の演出では、各ドローンの個体識別情報は必須であるが、識別するためにはドローンに何かしら加工を施さなければならない。そこで、ドローンのプロペラの音のみを用いて

識別が可能であれば、前回の研究で異なるメーカーでの異機種での識別実験は 100 % の確率で識別できたが [7]、実用性を考慮して同じメーカーの同機種での識別が可能かを検証する必要があったため、本稿では同機種での識別実験について述べる。

1.2 研究目的

本研究の目的はエンターテインメントの分野におけるドローンの個体識別を音情報のみで行うことにある。前述の通り、オープンスペースにおける演出としてドローンを複数台使用する事例が多くあり、その際個体識別をするために本体に加工を施すと、ドローンの動きやビジュアル面で制約をもたせてしまう。動きにおいては識別のためのマーカー装着等の加工をする分、重量も増すためスピードや飛行可能時間にも影響が生じる。またビジュアル面では LED 等の装飾を施す際や、見た目の点で制約がかかる。光学式の場合は外的な光に弱いという点も、演出としての制約になり得る。エンターテインメント分野でのライブ演出は照明によるライティング効果を多用するため少なからず影響

¹ 東京工科大学
Tokyo University of Technology
^{a)} m011443459@edu.teu.ac.jp

は及ぶ。そのためドローンに加工や追加の装備を施すことなく、それらの処理が可能であると考えられるドローンの発する羽音を用いて実現させる。

この手法で行うことによって、あらかじめドローンに加工を施さずとも、機体の重量が入手時の状態のまま変化せずに個体識別が可能になるため、よりドローン本来のポテンシャルを最大限発揮できるパフォーマンス形態を生み出す可能性があると考えられる。これは今後のエンターテインメント分野におけるドローン演出に大きな幅をもたせることにもなりうる。

2. 関連研究

本研究はドローンの音の識別に機械学習を使うため、機械学習によるパターン認識を行った研究を挙げる。音の特徴量を抽出し機械学習で分類した例として、機械学習による硬貨落下音の分析の研究 [4] がある。この研究ではピッチ抽出やパワーなどの特徴量を使用して硬貨の判別を試みている研究である。実験には特徴量の抽出に openSmile、機械学習に weka を使用しており、最終的な結果として三種類の硬貨の音を 80 % の正答率で識別している。この研究は人間の耳には似通っていて判別することができないような音を、機械学習により高確率で判別することができた例である。

機械学習を用いたジェスチャー認識の事例に佐藤らの「ユーザの触り方を検知するデバイス”Touche”」の研究 [5] がある。ユーザがデバイスに触れる際のタッチの状態によって、予め流入した電極のインピーダンスおよび静電容量の周波数特性の変化を周波数解析し、99 % のジェスチャー識別の結果をだしている。

これらの研究は教師ありの機械学習を用いている。教師ありの機械学習は予め学習用にデータを蓄積し、そのデータをもとに作成された学習モデルをもとに、未知のデータを予測して正しい方に分類するものである。こういった機械学習を用いることで、本研究のドローンの羽音で学習モデルを作成すれば、人間の耳ではわからない音でも判別できるのではないかと考えた。

3. 羽音による個体識別の提案

複数のドローンを制御する際、位置情報がわかっている個体の区別がなければ、演出等での制御に支障が出る。ドローンに制限をかけないようにするため、どのドローンにも一様に備わっている特徴としてプロペラの羽音に着目した。本研究では羽音による個体識別システムの検証を行った。

4. 同機種での個体識別

本研究ではドローンの羽音を個体ごとに分類し、個体別に識別させるため機械学習を用いる。複数同時に飛行して



図 1 実験に利用したドローン (MJX 社 - X400)

Fig. 1 Drone used for experiment (MJX Co. - X400)

いるドローンの羽音を識別させるには、予めドローンの個々の音を知っておく必要があり、その情報を元に新たに取得した音はどのドローンの音なのかを既知の情報と照らし合わせて分類させることで、識別が可能となると仮定する。前提として使用するドローンはあらかじめ決まっているので、教師ありの機械学習によって予め個々のドローンの羽音を学習させておき、それに基づいて分類予測させる。またその際、音質を考慮して高音質マイクを用いて行う。

前回行った異なるメーカーの異機種モデルのドローンを使用した個体識別検証 [7] では、メーカーや型が違っても羽やモーター、フレーム構造も違うため 100 % の確率で識別できるということがわかった。しかし、実際に演出に使われる実用的場面では、全く同じモデルのドローンを用いて行うことが多い。そこで本稿ではそのことを考慮し、図 1 の MJX 社の X400 [6] というドローンを 3 台用いて同機種での識別を行った。

4.1 手法概要

羽音の特徴量抽出に OpenSMILE、パターン認識および分類に Weka を使用して識別させる。大まかな流れは図 2 のように、マイクでドローンの音を録音し、その音声ファイルから指定した音響的特徴量を抽出し、そのデータをもとに学習モデルを作成する。その学習モデルに新しく録音したデータを適用し、どのドローンの音なのかを分類する。

同機種での識別は明確な違いが出にくく、異機種での識別で用いた特徴量とアルゴリズムでは精度が低かったため、羽音の分類に適した特徴量とアルゴリズムを選定する必要がある。

特徴量に関しては、抽出する特徴が多い場合、分類に関係のないものが含まれていると分類の妨げになる。また、少ない場合は必要な特徴が不足して入れば分類精度が低下する。そのため適切な特徴を選択し、抽出しなければいけ

表 1 特徴量の最終結果

Table 1 Final result of feature quantity

特徴量の名称	抽出内容
RMSenergy	音量の二乗平均平方根値
voiceProb	その時点での音が声である確率
spectralCentroid	スペクトルの重心
spectralEntropy	スペクトルのエントロピー
amean	平均
linregc1	線形回帰係数 (傾き)
linregc2	スペクトルの尖度 (オフセット)
linregerrQ	線形回帰二乗誤差




図 2 機械学習プロセス

Fig. 2 Machine learning process

ない。

アルゴリズムによって計算方法や分類の方法が異なるため、訓練データや抽出した特徴量が同じでも学習モデルの分類率や、予測の分類正解率もかなり異なる。アルゴリズムや特徴量の選択によって大きく結果が異なるので、ドローンの羽音を分類するための最も精度の高いアルゴリズムを選定することは、識別においてかなり重要な点である。

4.2 特徴量とアルゴリズムの選定

羽音に適した特徴量とアルゴリズムを調べるために、抽出する特徴量を増減させてアルゴリズムごとに分類正解率を比較した。図 3 は異機種での識別実験時に使用した特徴量 (1, 青) を基準に、特徴量を増やしたもの (2, 橙) と、そこから削減したもの (3, 灰) をアルゴリズム別に比較した図である。このグラフから特徴量を増やせば、分類に関係のない情報を含んだ特徴がでてくるため、分類の妨げとなり結果、分類精度が低くなると考えられる。また、減らすと分類に必要な情報が少なくなるため、それもまた精度が低くなる。初期の特徴量が最も高い分類正解率であったため、これを用いて個体識別検証を行った。

次に、テストデータを適用させて分類精度を見る。テストデータで最も高い正解率だったのは 73.3 % で “simpleLogistic” で、正解率が 7 割を超えているものはこれだけであった。モデル作成時の分類正解率と違って未知のテストデータでの適用した際の正解率がかなり異なっていたことから、モデルの分類精度が高くても、未知のデータに対する分類は苦手なものもあることがわかった。モデルとテストデータのそれぞれの分類正解率を比較すると図 4 のようになる。

今回の結果で最も高い結果が 73.3 % と出たが、さらに精度を向上させるために特徴量の見直しをした。

4.3 基本周波数を除いた識別

使用していた特徴量の中に基本周波数を抽出していた。基本周波数は音響解析に有用な特徴であるが、ドローンの

羽音のようなノイズ音から正しく抽出するのはほぼ不可能に近いということがわかったため除外した。除外して分類予測を行なった結果、図 5 のようになった。その結果、「SimpleLogistic」と「LMT」というアルゴリズムで最大で 80.0 % まで正解率が向上した。この 2 つのアルゴリズムは基本周波数の削除前の結果でも全体的に高い数値であったが、削除後は “LMT” では 16.7 %, “SimpleLogistic” では 6.7 % も精度が向上した。このことから基本周波数はやはり正確に抽出することができておらず、不安定かつ信頼度が低い抽出結果をモデルに渡していたため、予測の妨げになっていたと考えられる。ドローンの羽音のようなノイズ音の場合、基本周波数を音響特徴として抽出分析することは困難かつ、分析やその後の使用の妨げになることが確認された。

5. 結果と評価

同機種での個体識別の検証を行った上で、最終的に抽出した特徴量は表 1 の通りである。

そして、これらの特徴量を用いて識別した結果、最も高い分類正解率 80.0 % という結果が出た。テストデータの分類正解率が 7 割を超えていたものは表 2 のように 4 つであった。精度が高かった 2 つのアルゴリズムについて簡易的に説明をすると、“LMT” はロジスティックモデルツリーを構築する分類器で、葉においてロジスティクス回帰関数を割り当てた分類木である。アルゴリズムは 2 値と多値のクラスに使用でき、数値属性、名義属性と欠損値に対応している。“SimpleLogistic” は、線形ロジスティック回帰モデルを構築するためのアルゴリズムである。ロジスティックモデルのフィッティングには、基本学習者としての単純回帰関数を使用した LogitBoost が使用され、実行する LogitBoost 反復の最適な回数は相互検証され、自動属性選択が行われる。

1 度目の異なる機種での実験を受けて、さらにアルゴリズムと抽出する特徴の組み合わせを見つけることで、個体の特有の違いがないような同メーカーの同機種でも識別が可能となった。プロペラの羽音のようなノイズ音の分析に有用性のある特徴のみを抽出するだけでなく、そういった




図 3 特徴量のアルゴリズム別分類正解率

Fig. 3 Algorithm classification accuracy of feature quantity by algorithm




図 4 アルゴリズム別のモデル分類率とテストデータの予測結果

Fig. 4 Model classification rate by algorithm and prediction result of test data




図 5 基本周波数を除く前後の予測結果比較

Fig. 5 Comparison of forecast results before and after excluding basic frequency

表 2 アルゴリズムと予測正解率の最終結果

Table 2 Final result of algorithm and prediction accuracy rate

アルゴリズム	正解率
LMT	80.0 %
MultilayerPerceptron	70 %
RandomSubSpace	73.3 %
SimpleLogistic	80.0 %

音に優位な分類のためのアルゴリズムを見つけることも、精度向上に重要な点であったことがわかった。特徴に関しては、数多く抽出すると分類に有用なものと、そうでないものが混在する形になるため、分類の際に妨げとなっていた。そのため正確率の高い特徴のみを使って分類を行うために選定することが、全体の正解率の向上に起因したと考えられる。そこでノイズから抽出することが困難な、基本周波数の特徴量を取り除いて分類することで正解率が高くなったということから、基本周波数が妨げとなっていたことが示された。またこの実験は、サンプル量を増やせばさらに精度向上が見込める結果であることも分かった。

6. 今後の展望

今後の本研究の結果を踏まえた展望として、以下のようことが挙げられる。まず、精度をさらに高めるために、本稿では追求できていなかった特徴量の選定を1つ1つの正解率の検証を行って最適な特徴のみを使用することで精度の向上が期待される可能性がある。

雑音処理に関しては、先行事例でも多く使われていたフィルタリングを行うことが必要になる。フィルタリングは録音した音声データに対して周波数単位でフィルターをかけ、識別や位置推定に必要な帯域の音をカットすることにより雑音成分を取り除く方法である。

また、本研究では購入から未使用の状態で行ったが、ある程度使用された機体は未使用状態と音響的特徴は変化するか否かを調べる余地は、実用的なことを考慮すると大いにある。

実験では全ての機体は満充電の状態で行ったが、長時間飛行させると、プロペラの回転数等が変化することで識別に影響が出る恐れがある。その対処としてバッテリーの減りによる回転数の変化も学習させておくというやり方が考えられ、対処できる可能性はあると考えられる。

7. おわりに

本研究では、エンターテインメント分野でのステージ等の演出における複数台のドローンの各個体を知ることが目的とし、そのためのシステムの提案と実装、実験を行った。ドローンのプロペラから発生する羽音のみの情報を用いて識別するシステムを提案した。

前回の研究を踏まえ、本稿では演出などのシーンで使わ

れる場合の多くは同機種のドローンを複数台使用するため、実用的な面を考慮し、同じメーカーの全く同じ機種を3台用いての識別を行った。識別には教師ありの機械学習によって、あらかじめ使用するドローンを個体ごとに羽音を学習させて、羽音から個体を分類予測させた。同機種の場合はパーツや作りが同じなため、圧倒的な特徴の違いは出にくく、抽出する音響的特徴量と正確に分類するためのアルゴリズムの最適な組み合わせを見つけることで識別が可能になると考え、検証を重ねた。その結果、個々のドローンの羽音を正しく分類することに適したアルゴリズムと音響的特徴量の組み合わせを見つけることにより、最大80%の確率で個体を識別することに成功した。

参考文献

- [1] Elevenplay x Rhizomatiks Research *24 drones* 入手先 (<https://research.rhizomatiks.com/s/works/24drones/>) (2015).
- [2] マイクロアド *Sky Magic Live at Mt. Fuji : Drone Entertainment Show* 入手先 (<https://www.youtube.com/watch?v=5WWwvIgGbkq>) (2016).
- [3] intel *Intel's 500 Drone Light Show* 入手先 (<https://www.youtube.com/watch?v=aOd4-Tp5fA>) (2016).
- [4] 横田 渉・大淵康成：機械学習による硬貨落下音の分析，映情学技報，vol. 41, no. 12, AIT2017-119, pp. 261-264, 2017年3月.
- [5] Munehiko Sato, Ivan Poupyrev, Chris Harrison. "Touch: Enhancing Touch Interaction on Humans, Screens, Liquids, and Everyday Objects." In Proceedings of the 30th Annual SIGCHI Conference on Human Factors in Computing Systems (Austin, TX, May 5- 10, 2012). CHI '12. ACM, New York, NY.
- [6] mjsx *mjxrc* 入手先 (<http://www.mjxrc.net>) (2017).
- [7] 小野 龍一, 室崎 之典, 斉藤 佑祈, 中野 亜希人, 大淵 康成, 羽田 久一：ドローンの羽音を利用して個体識別及び位置情報を検出するシステムの提案，エンタテインメントコンピューティングシンポジウム 2017 論文集, pp. 145-150, 2017年9月.