

令和7年度 修士論文

慣性センサーを用いた機械学習による生物個体の運動解析

大阪公立大学大学院理学研究科物理学専攻  
非線形物理研究室  
学籍番号 BHB24097

福田大祐

## 概要

本研究では、慣性センサーより得られた加速度および角速度の時系列データを用い、機械学習によるハトの帰巢飛行と自由飛行の分類、および運動構造の解析を行った。時系列データから抽出した物理量を学習データとしてランダムフォレスト (Random Forest) を構築し、Shapley Additive Global Importance を用いて各特徴量の重要度を算出した。その結果、帰巢飛行と自由飛行には明確な運動学的差異があることが判明した。具体的には、帰巢飛行がダウンストロークを主体とした推進を行うのに対し、自由飛行ではダウンストロークに加えアップストロークによる推進および姿勢制御を行っていることなどが示唆された。また、学習データと検証データをさまざまな個体間で選択し、様々な条件下での運動特徴を比較した結果、群れでの飛行と単独での飛行では運動が異なること、一方で群れの先頭を飛行する個体と単独で飛行する個体の運動には高い類似性があることが明らかとなった。

## 目次

1	序論	3
2	解析データおよび解析手法	7
2.1	解析データについて	7
2.2	解析フレームワークの概要	8
2.3	ウィンドウ分割	9
2.4	行動クラスの定義	10
2.5	特徴量抽出	12
2.5.1	時間領域特徴量	12
2.5.2	周波数領域特徴量	14
2.6	機械学習モデルと評価	15
2.6.1	アルゴリズム	15
2.6.2	モデルの構築と最適化	18
2.6.3	モデルの評価指標	18
2.7	SAGEによる特徴量の重要度評価	19
2.7.1	SAGEの理論的枠組み	19
2.7.2	SAGEの近似アルゴリズム	20
3	モデルの学習と性能評価	22
3.1	解析対象データの構成とグループ定義	22
3.2	個体内検証	23
3.3	個体間検証（グループ内検証）	26
3.4	グループ間検証	28
3.5	総当たり検証	30
4	SAGEによる特徴量重要度解析	36
4.1	SAGE値の収束と信頼性の検証	36
4.2	全個体統合モデルによる普遍的特徴の抽出	38

4.3	飛行状況による重要特徴量の変化.....	39
5	運動メカニズムの詳細解析と物理的解釈.....	42
5.1	運動のリズム関連の特徴量 .....	42
5.1.1	前後加速度の二倍周波数と基本周波数のパワー比 (Ratio_fixed) .....	42
5.1.2	左右軸方向の角速度の周期と周期性 (period_Gy, periodic_Gy) .....	45
5.2	姿勢制御関連の特徴量 .....	49
5.2.1	左右軸回りの角速度の分布の歪度 (skew_Gy) .....	49
5.3	運動の対称性関連の特徴量 .....	52
5.3.1	前後方向の加速度の分布の歪度 (skew_Ax) .....	52
5.3.2	上下方向の加速度の分布の歪度 (skew_Az) .....	55
5.4	運動の強度関連の特徴量.....	58
5.4.1	前後方向の加速度の最大値と上下方向の加速度の最小値 (Max_Ax, Min_Az) ..	58
5.5	加速度平面を用いた総括的比較 .....	63
6	結論.....	68
6.1	本研究の総括 .....	68
6.2	群れの飛行と単独飛行における運動学的特性 .....	69
6.3	今後の展望.....	70
	参考文献.....	71

# 1 序論

近年、データロガーやセンサーデバイスの小型化、高性能化、軽量化に伴い、バイオロギング技術が発展している。これにより、自然環境下におけるヒトや動物の運動データを取得することが可能になった。特に、加速度センサーやジャイロ스코プを搭載した慣性センサーは、対象の身体に取り付けることで運動学的な情報を直接的に計測できるため、動物行動学やバイオメカニクスなど多岐にわたる分野でその有用性が示されている。本研究では、この慣性センサーから得られる時系列データに基づき、物体の運動パターンの差異を機械学習モデルによって推定する手法を提案する。

慣性センサーを用いた運動解析のアプローチとして、機械学習を用いた行動分類が広く行われている。例えば、Gerencsérらは、図1に示すように、犬の背中に三軸加速度センサーと三軸ジャイロ스코プを装着し、得られたデータから「伏せ、お座り、歩行、トロット、ギャロップ」など7種類の行動を識別する研究を行った [1]。彼らは、SVM (Support Vector Machine) を用いた教師あり学習により、同一個体内での学習・検証において90%を超える高い識別率を達成し、複数個体間でも80%以上の精度が得られることを報告している。また、Usherwoodらは、図2に示すように、ハトに高精度のGPSと慣性センサーを装着し、旋回時の求心加速度や羽ばたき周波数の解析を行うことで、群れの飛行における空気力学的コストやバンク角の制御に関する詳細な知見を得ている [2]。他にも、ヒトの歩行と走行の質的な違いの解明 [3] [4]、高齢者、脳卒中患者、ハンチントン病患者の歩行の識別 [5]、日常生活におけるヒトの行動識別 [6] [7]、群れを形成するドローンの異常検知 [8]など、慣性センサーを用いた研究は多分野で進んでいる。

しかしながら、機械学習を用いた行動分類は高い精度を誇る一方で、その判断根拠が不明瞭になりやすいという課題を抱えている。単に行動ラベルを予測するだけでは、主体が具体的にどのような運動をしているのか、その力学的メカニズムまでは明らかにできない。また、大量の慣性センサーデータから、運動の違いを決定づける本質的な特徴量を人力で探索することは容易ではない。

本研究の目的は、機械学習を用いて運動の特徴を網羅的に解析し、モデルの判断根拠を可視化することで、運動の物理的解釈に迫ることである。具体的には、広域的な特徴量重要度を算出する手法であるShapley Additive Global Importance(SAGE) [9]を導入し、構築した機械学習モデルの中身を解釈する。これにより、分類の際に「どのセンサーの、どの特徴量」が重要視されているかを定量的に特定し、抽出された特徴量をヒントに詳細な個別解析を行う。以上のプロセスを通じて、単なるブラックボックス的な分類にとどまらず、主体が物理的にどのような運動を行っているのかを推定

し、その運動特性の詳細を明らかにすることを旨とする。本研究では単一個体の解析にとどまらず、複数個体間での検証を行う。Gerencsérらは[1]において、複数個体のデータを用いてモデルの汎用性を検証しているが、本研究ではこの視点をさらに発展させ、SAGEを用いて各個体のモデルにおいて重要視される特徴量を比較・分析する。これにより、「群れ内での位置による差」および「単独飛行か群れ飛行か」などの複数の条件下における個体間の違いと、全個体に共通して重要となる特徴量（種に固有な特徴量）を分離・抽出することを試みた。

本論文の構成は以下の通りである。第2章では、解析するデータおよび計測デバイスについて、特徴量抽出、ランダムフォレストとSAGEを組み合わせた解析フレームワークについて詳述する。第3章では、個体内、個体間およびグループ間に及ぶ多角的な検証を行い、構築した学習モデルの識別精度と飛行環境による汎化性能の差異を評価する。第4章では、SAGEを用いて分類に寄与する重要特徴量を特定し、群れの先頭個体や単独飛行個体など、飛行状況の違いが運動学的特徴の寄与率に与える影響を分析する。第5章では、抽出された重要特徴量に基づき、周波数特性や波形の歪度、加速度平面の可視化を通じて、各飛行モードにおける翼の運動メカニズムを物理的に解釈する。第6章では、本研究の知見を総括し、生物の飛行戦略と社会的相互作用に関する結論を述べるとともに、今後の展望を記す。

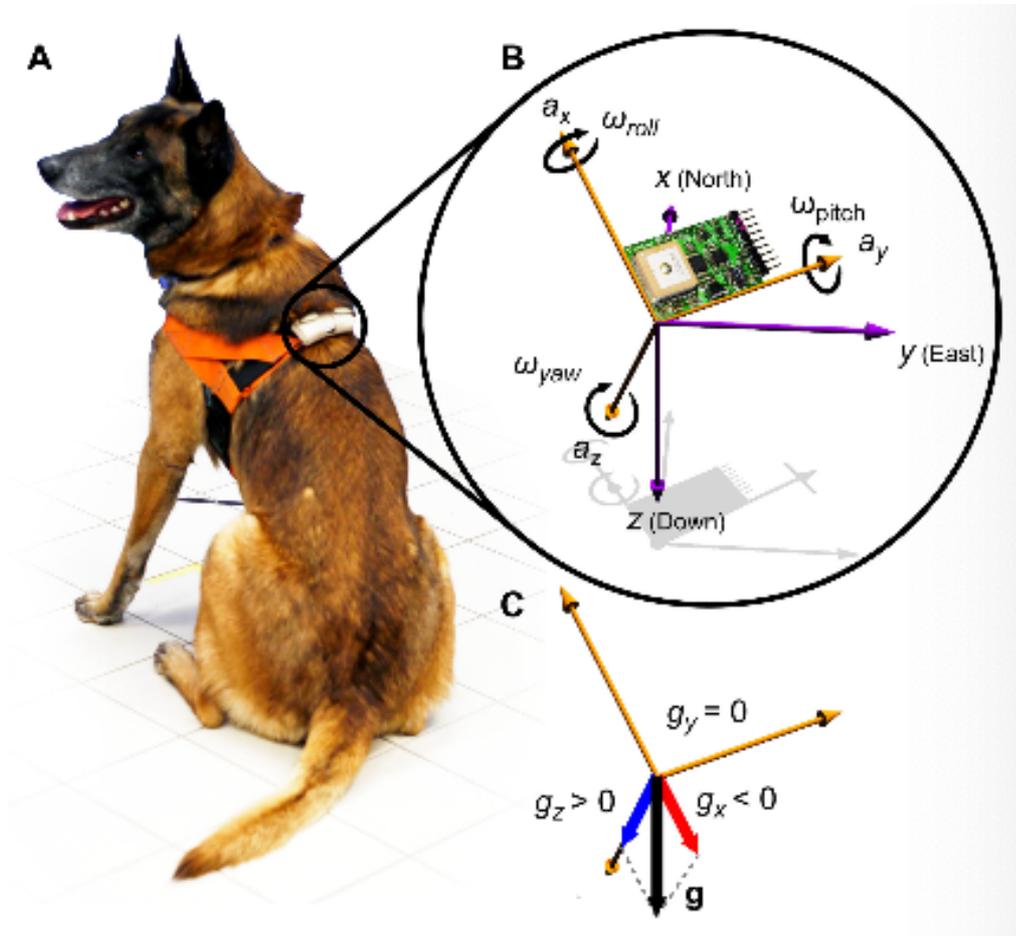


図 1：犬を対象とした慣性センサーの装着図と座標系。 [1] より転載。

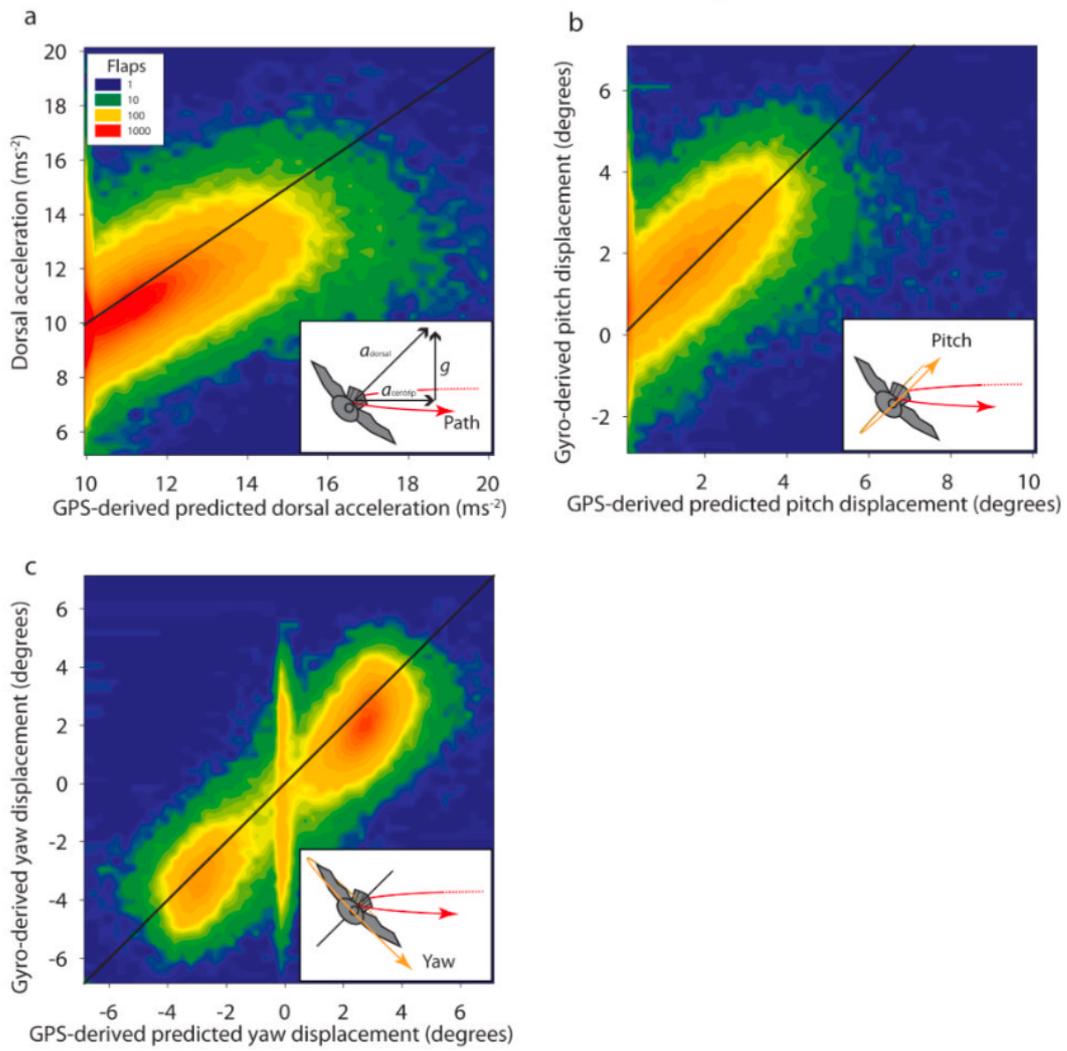


図 2：飛行中のハトを用いた実験での GPS データに基づく各軸の物理量の予測値と慣性センサー計測値の相関。(a)背腹軸方向の加速度、(b)ピッチ角変位、(c)ヨー角変位。横軸は GPS データからの予測値、縦軸は慣性センサーの計測値。ヒートマップの色はデータの密度を示し、黒実線は完全な一致を表す。各パネルの挿絵はそれぞれの運動成分の定義を示している。 [2]より転載。

## 2 解析データおよび解析手法

### 2.1 解析データについて

本研究では、英国オックスフォード近郊において計測されたハトの飛行データを使用した。本データはマックスプランク研究所の M. Nagy 博士より提供を受けたものである。

測定には飛行するおよそ 50 個体のハトが用いられた。その中で、後述する帰巢飛行と自由飛行の両方の飛行状態が測定されたという条件を満たす 13 個体分のデータに着目した。各個体の背中には、GPS および加速度 ( $A_x, A_y, A_z$ ) を測定する三軸加速度センサー、角速度 ( $G_x, G_y, G_z$ ) を測定する三軸ジャイロスコープを搭載した小型ロガーを専用のハーネスを用いて装着された。サンプリング周波数はそれぞれ、三軸加速度センサーおよび三軸ジャイロスコープが 100Hz、GPS が 10Hz である。本研究における身体固定座標系の定義および各軸の正の方向は図 3 に示すように、X 軸正方向が頭部方向、Y 軸正方向が左翼方向、Z 軸正方向が腹側方向である。



図 3：慣性センサーの搭載位置およびセンサー座標系の定義。

## 2.2 解析フレームワークの概要

本研究におけるデータ処理および解析の全体フローを図 4 に示す。本フレームワークは、単にクラスを分類するのではなく、その分類根拠を通じて運動の物理的特性を理解することを目的として設計されている。解析プロセスは以下の 5 つのフェーズからなる。

1. まず、取得したデータの前処理を行う。ここでは、慣性センサーから得られた時系列データに対して、2.3 節で定義する GPS の速度および角速度の閾値に基づくラベリングを行う。これにより、教師あり学習のための正解ラベル（帰巢飛行または自由飛行）を付与する。詳細は 2.4 節にて詳述する。
2. 次に、特徴量抽出である。ラベリングされた時系列データを一定の窓幅で分割し、各区間から時間領域および周波数領域の統計的特徴量（平均、分散、FFT 解析によるパワースペクトル等）を算出する。これにより、生データを機械学習モデルに解釈可能な形式へと変換する。詳細は 2.5 節にて詳述する。
3. 次に、機械学習モデルの学習および検証である。抽出された特徴量を入力とし、ランダムフォレスト（Random Forest）を用いた分類モデルを構築する。モデルの構築にあたり、交差検証（Cross-Validation）を用いて最適なハイパーパラメータの決定を行った。また、モデルの性能評価には正解率（Accuracy）およびマシューズ相関係数（Matthews Correlation Coefficient : MCC）を採用した。詳細は 2.6 節にて詳述する。
4. 次に重要特徴量の特定である。学習済みモデルに対して SAGE を適用することで、分類に大きく寄与した重要な特徴量を定量的に特定する。詳細は 2.7 節にて詳述する。
5. 最後に物理的解釈である。抽出された特徴量を運動学的観点から考察し、各飛行モードにおける運動学的メカニズムの差異を物理的に解釈する。



図 4：解析のフローチャート

## 2.3 ウィンドウ分割

慣性センサーから得られるデータは長時間に及ぶ時系列信号であり、そのまま機械学習モデルへ入力することはできない。そのため本研究では、特徴量抽出の前処理として、得られた時系列データを一定の時間長を持つ区間（ウィンドウ）に分割する。

ウィンドウサイズはハトの羽ばたき運動の周期性を十分に捉えられる長さに設定する必要がある。ハトの羽ばたき周波数は一般に 5~9 Hz 程度であると報告されている [2]。したがって、1つのウィンドウ内に複数回の羽ばたきサイクルを含むように、ウィンドウ幅を 1[sec]（サンプル点数  $N=100$  点）に設定した。図 5 に、実際の加速度データに対するウィンドウ分割の例を示す。同図より、1秒間のウィンドウ内に約 7 回前後の羽ばたき周期が含まれており、設定したウィンドウ長が妥当であることが確認できる。

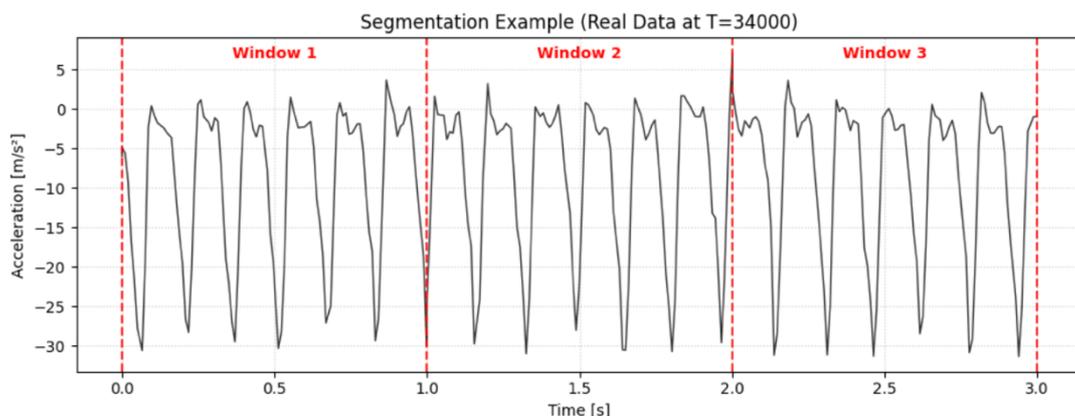


図 5：時系列データにおけるウィンドウ分割の例。横軸は時間[s]、縦軸は加速度の z 軸（背腹軸）方向成分 $[m/s^2]$ 。

## 2.4 行動クラスの定義

データ収集は屋外環境下で行われ、以下の2種類の異なる飛行モードが記録された。本研究では、これらを機械学習における分類対象（クラス）として定義する。

- ・帰巢飛行 (homing flight) : 放鳥地点から巣へと戻る際の飛行である。目的地に向かって直線的かつ高速で移動する傾向がある。

- ・自由飛行 (free flight) : 巣の周辺における自発的な飛行である。帰巢飛行と比較して、より低い速度で飛行し、多くの旋回を行うため不規則な飛行軌跡を描く。

図 6 に本実験で取得された GPS の対地速度データおよび対地角速度データの時系列を示す。緑色でマーキングしている部分が帰巢飛行、オレンジ色でマーキングしている部分が自由飛行である。また、これに対応する空間的な飛行軌跡を図 7 に示す。図 6 に示すように、帰巢飛行（緑色）では対地速度が比較的高く維持され、対地角速度が 0 付近で推移している。これは図 7 の左側のグラフとも整合しており、目的地に向かって高速かつ直線的に飛行していることが分かる。一方で、自由飛行（オレンジ色部）では、帰巢飛行に比べて、対地速度が小さく、対地角速度が大きな振幅で揺らいでいる。図 7 の右側のグラフからも明らかなように、一定の場所で旋回を多数繰り返すような不規則な軌道を描いていることを示している。このように、GPS データから両飛行パターンの違いが明確に確認できる。本研究では、機械学習の教師データを作成するために、これらの GPS データを基に、各ウィンドウに対して「帰巢飛行」か「自由飛行」のラベルを付与した。

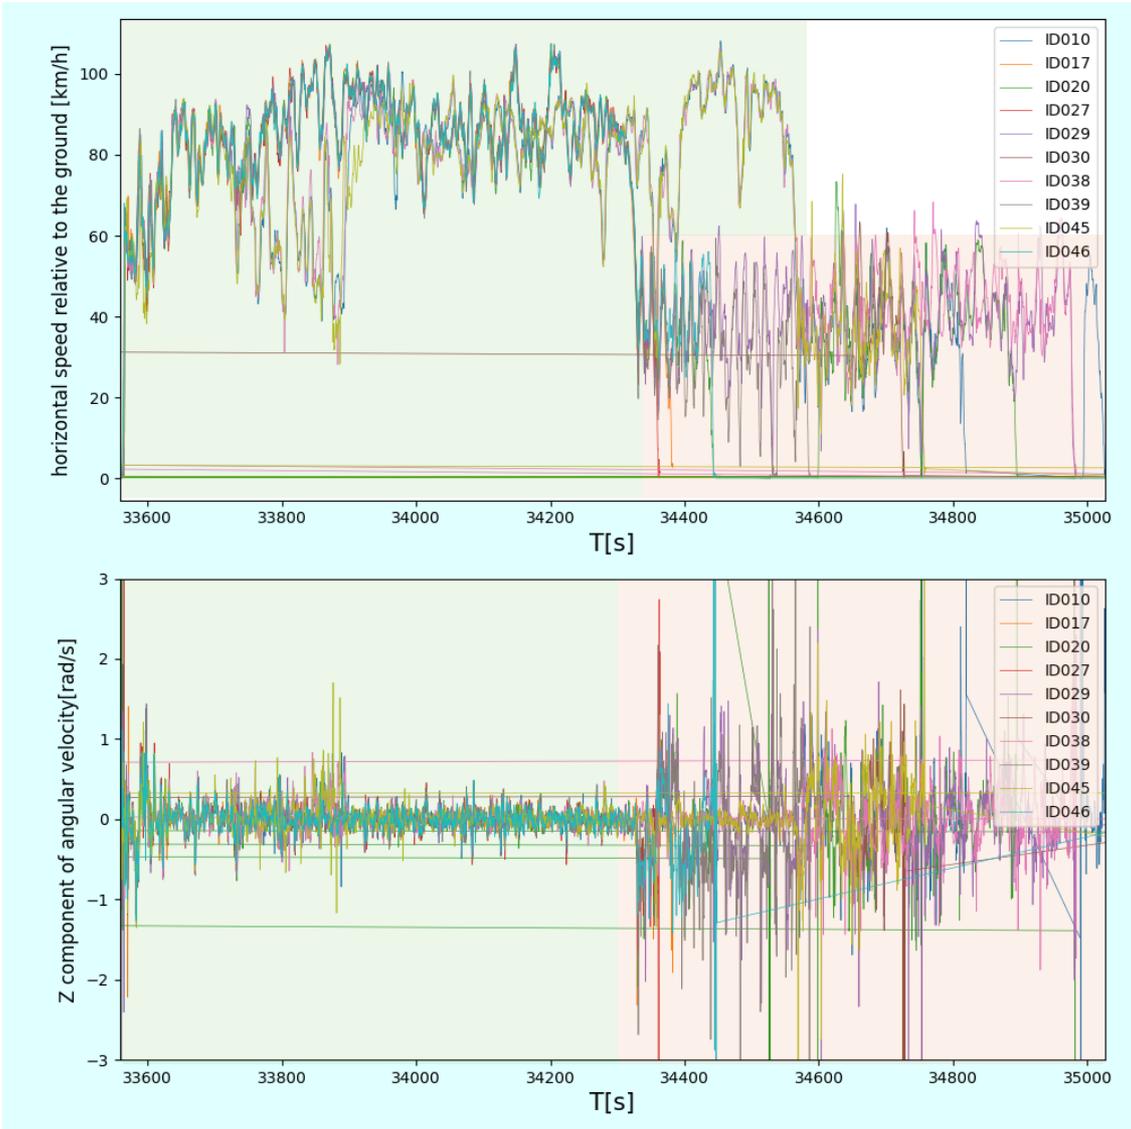


図 6：10 個体分の GPS の対地速度[km/h]および対地角速度[rad/s]の時系列。

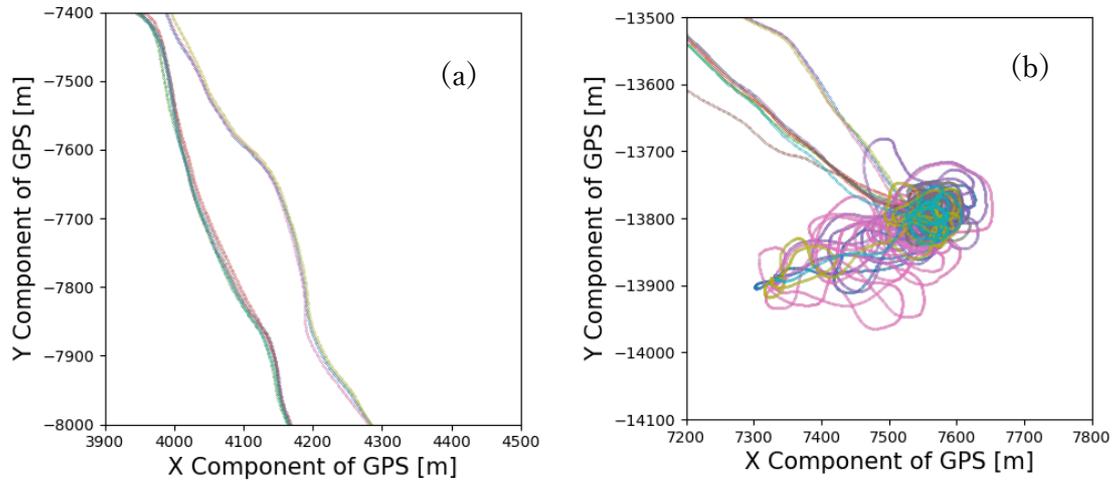


図 7：(a)帰巢飛行と(b)自由飛行の飛行軌跡の一部。横軸は GPS の東西成分[m]、縦軸は GPS 南北成分[m]。

## 2.5 特徴量抽出

前処理によって得られた時系列データは、そのままでは機械学習モデルの入力として扱うことが困難であるため、データの局所的な特性を定量化する特徴量抽出を行った。本節では、算出する時間領域・周波数領域の特徴量について述べる。

各ウィンドウ内の時系列データを  $s[n](n = 0, 1, \dots, N - 1)$  とする。ここで  $N$  はウィンドウ内のサンプル数、 $s$  は慣性センサーが記録する加速度データ  $A_x, A_y, A_z$  と角速度データ  $G_x, G_y, G_z$  である。

### 2.5.1 時間領域特徴量

- ・ 平均値( $\mu$ )および分散( $\sigma^2$ )：ウィンドウ内における運動の平均的な強度と、その変動の大きさを表す。

$$\mu_s = \frac{1}{N} \sum_{n=0}^{N-1} s[n] \quad (1)$$

$$\sigma_s^2 = \frac{1}{N} \sum_{n=0}^{N-1} (s[n] - \mu_s)^2 \quad (2)$$

例えば、 $\mu_{A_x}$  は加速度の頭尾軸方向成分の平均値、 $\sigma_{G_y}^2$  は角速度の左右軸方向成分の分

散を表す。

- ・二乗平均平方根 (RMS) : 信号の物理的なエネルギーの大きさを表す。

$$rms_s = \sqrt{\frac{1}{N} \sum_{n=0}^{N-1} (s[n])^2} \quad (3)$$

- ・歪度 (Skewness) : 波形の分布の非対称性を表す。羽ばたきにおけるアップストロークとダウンストロークの非対称性などを捉えるために有効である。

$$Skew_s = \frac{\frac{1}{N} \sum_{n=0}^{N-1} (s[n] - \mu_s)^3}{(\sigma_s^2)^{3/2}} \quad (4)$$

- ・最大値 (Max)、最小値 (Min)、範囲 (Range) : ウィンドウ内の最大振幅およびその振れ幅を表す。

$$Max_s = \max(s) \quad (5)$$

$$Min_s = \min(s) \quad (6)$$

$$Range_s = Max_s - Min_s \quad (7)$$

- ・躍度および角躍度の平均 (Mean Jerk) [10] : 加速度および角速度の変化率の平均であり、運動の滑らかさや急激な変化を評価する。

$$J_s[n] = \frac{s[n+1] - s[n-1]}{2\Delta t} \quad (8)$$

$$Mean\_Jerk_s = \frac{1}{N} \sum_{n=0}^{N-1} j[n] \quad (9)$$

## 2.5.2 周波数領域特徴量

- ・ 周期 ( $\tau$ ) および周期性の強さ  $R_{\text{peak}}$  : 運動の周期とその周期性の強さを表す。

自己相関関数 (Autocorrelation Function: ACF)

$$R_{ss}(k) = \frac{\sum_{n=0}^{N-k-1} (s[n] - \mu_s)(s[n+k] - \mu_s)}{\sqrt{\sum_{n=0}^{N-k-1} (s[n] - \mu_s)^2} \sqrt{\sum_{n=0}^{N-k-1} (s[n+k] - \mu_s)^2}} \quad (10)$$

この  $R_{ss}(k)$  に対して、ピーク検出を行い、自己相関関数が閾値 (0.5) を超えた最初のピークを与える時間から周期  $\text{period}_s$ 、そのピークの高さから  $\text{periodic}_s$  を特徴量として用いる。

- ・ 特定周波数帯域のパワー強度  $P_1, P_2$  およびその比率  $\text{Ratio\_fixed}$  : アップストロークとダウンストロークの強度およびそのバランスを評価する。

離散フーリエ変換  $s[k]$

$$s[k] = \sum_{n=0}^{N-1} s[n] \exp(-i \frac{2\pi}{N} kn) \quad (11)$$

各周波数成分のパワー強度  $P[k]$

$$P[k] = \frac{1}{N} |s[k]|^2 \quad (12)$$

求めた周波数成分とそのパワー強度から、ハトの典型的な羽ばたき周波数に対応する 5.0Hz から 9.0Hz の範囲において、最も高いパワー値を示す基本周波数のパワーを  $P_1$ 、基本周波数の 2 倍の帯域である 10.0Hz から 18.0Hz の範囲において、最も高いパワー値を示す周波数のパワーを  $P_2$  とした。また、 $P_1$  と  $P_2$  の比率を次式より算出した。

$$\text{Ratio\_fixed} = \frac{P_2}{P_1} \quad (13)$$

## 2.6 機械学習モデルと評価

### 2.6.1 アルゴリズム

本研究では、飛行パターン（帰巢飛行および自由飛行）を分類するモデルとして、決定木（Decision Tree）およびランダムフォレスト（Random Forest）の採用を検討した。最終的には、モデルの解釈性と特徴量評価の網羅性を考慮し、ランダムフォレストをモデルとして採用した。以下にその選定理由とアルゴリズムの概要を述べる。

まず、モデルの判断根拠を直観的に把握するために、単一の決定木による学習を行った。決定木は特徴量空間を軸に垂直な超平面で再起的に分割することで分類を行う手法であり、その最大の利点は構造の可視化が可能なことである。図 8 に、本研究のデータを用いて学習させたランダムフォレスト内の決定木の一例を示す。同図の各ノードにて、*range\_Ax* などの物理量がどのような閾値で分類に寄与しているのかを可視化して理解することが可能である。

単一の決定木は前述のように、解釈性に優れている反面、最も識別能力の高い特徴量が各ノードで使用されるため、その他の潜在的に有用な特徴量が無視されやすいという課題がある。本解析手法の目的は、SAGE を用いて多角的な視点から重要な特徴量を評価することであるため、特定の特徴量に依存しすぎるモデルは望ましくない。そこで本研究では、アンサンブル学習手法であるランダムフォレストを最終的なモデルとして採用した。図 9 に本研究におけるランダムフォレストの学習プロセスの概念図を示す。同図に示すように、ランダムフォレストではブートストラップサンプリングにより生成された多数のサブセットに対して、それぞれ独立して決定木を構築する。この際、各ノードの分割に使用できる特徴量をランダムに制限することで、各決定木で着目する特徴量が異なるため、モデル内の特徴量の多様性が保たれる。最終的な予測は全決定木の多数決によって行われる。このプロセスにより、単一の決定木では埋もれてしまうような微細な特徴量も網羅的に学習に組み込むことができる。これは後述する SAGE による重要度解析において、すべての特徴量を公平かつ大域的に評価する上で不可欠な性質である。

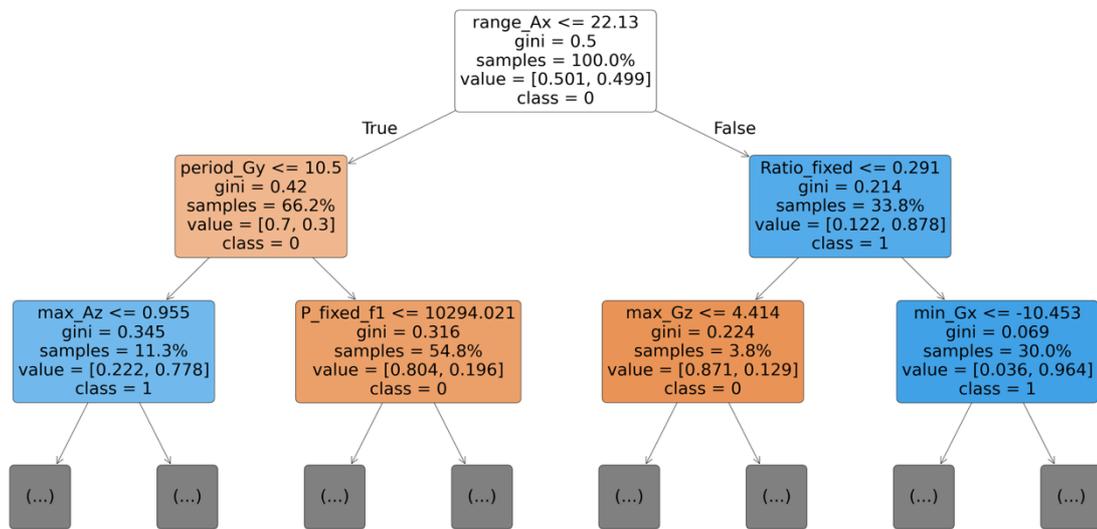


図 8：ランダムフォレスト内の決定木の一例。最初の分岐は Ax の範囲が 22.13 以下か否かで分けられる。22.13 以下を満たす窓群は（右下に進み）全体の 33.8%であり、帰巣：自由=0.122：0.878 となる。それぞれの窓群に対して、同様の分類を行い、設定された条件が満たされるまで分岐を続ける。



図 9：ランダムフォレストの学習プロセスの例。subset には重複しているデータや削除されているデータも含まれる。得られた複数の決定木の結果の多数決で分類を行う。

## 2.6.2 モデルの構築と最適化

モデルの識別能力を公平に評価し過学習を防ぐため、前処理において「帰巢飛行」と「自由飛行」のサンプル（窓数）が同一となるよう抽出範囲を調整し、クラス間の均衡を図った。これにより、正解率の期待値を 0.5、MCC（マシューズ相関係数）の期待値を 0 とする評価基準を明確化した。

その上で、ランダムフォレストによる解析精度の最大化を目指し、グリッドサーチおよび交差検証（Cross-Validation）を導入した。具体的には、決定木の数、木の最大深さ、および各ノードの分割に使用する特徴量数などのハイパーパラメータを段階的に変化させ、最も高い平均精度を示す最適な組み合わせを最終的なモデルとして選定した。

## 2.6.3 モデルの評価指標

本研究では、構築した機械学習モデル（ランダムフォレスト）の識別性能を定量的に評価するために、一般的な指標である正解率に加えて、統計的に厳密な評価指標であるマシューズ相関係数（Matthews Correlation Coefficient: MCC） [11]の 2 つを用いた。

評価にあたり、以下の混同行列の定義を用いる。

- ・ TP (True Positive) : 帰巢飛行を正しく帰巢飛行と予測した数
- ・ TN (True Negative) : 自由飛行を正しく自由飛行と予測した数
- ・ FP (False Positive) : 自由飛行を誤って帰巢飛行と予測した数
- ・ FN (False Negative) : 帰巢飛行を誤って自由飛行と予測した数

### (1) 正解率 (Accuracy)

正解率は、全データに対する予測が正解した割合を示す指標であり、次式で定義される。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (14)$$

本研究では、学習および検証のデータのクラス比率を均等に調整しているため、モデルがランダムな予測を行った場合の正解率の期待値は 0.5 となる。正解率はモデルの基礎的な性能を把握する上で有用であるが、0.5（偶然レベル）と優位な予測精度の差を視覚的・定量的に評価する際、後述の MCC の方が解釈性に優れる場合がある。

### (2) マシューズ相関係数 (MCC)

MCC は、予測値と実測値の間の相関係数を表す指標である。-1 から +1 の値を取り、+1 は完全な一致、0 はランダムな予測（無相関）、-1 は完全な不一致を表す。

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (15)$$

本研究では、後述する個体間検証など、モデルにとって未知のデータを扱う検証を含んでいる。その際、モデルの予測能力が偶然と同等か、それとも優位な相関があるかを明確に区別するため、0を基準として性能を厳密に評価できるMCCを主要な評価指標として採用した。実際に、本研究の結果（ヒートマップ等）においても、正解率では0.5付近の値のとなり評価が曖昧になるケースであっても、MCCでは0近傍の値を示すことでモデルの予測能力の欠如を明確に検出できている。

## 2.7 SAGEによる特徴量の重要度評価

本研究では、機械学習モデルの判断根拠を定量化し、物理的解釈へと接続するための手法としてSAGE [9]を採用した。他にも特徴量の重要度を算出する手法としてPermutation Importance (PIMP) [12]があるが、SAGEは協力ゲーム理論に基づき全変数の組合せを網羅するため、変数間の相互作用を含めた予測精度への実質的な貢献度を数学的な公平性を持って定量評価できる点において、統計的優位性の判定に留まるPIMPより本解析に適している。SAGEは、その特徴量が存在することでモデルの予測における損失関数がどれだけ減少したか、すなわち予測精度をどれだけ改善したかを定量的に表している。従って、SAGE値が高い特徴量は、帰巢飛行と自由飛行を区別する上でより重要な特徴量であると解釈することができる。

### 2.7.1 SAGEの理論的枠組み

まず、全特徴量の集合を $D$ とし、全特徴量を用いて学習済みのモデルを $f$ とする。SAGEでは、特徴量の重要度を評価する際にモデルの再学習は行わず、学習済みモデル $f$ に対して、特定の特徴量集合 $S \subseteq D$ のみが入力可能な状況をシミュレートする。具体的には、集合 $S$ に含まれない特徴量 ( $\bar{S} = D \setminus S$ ) をその周辺分布からランダムにサンプリングしてモデルに入力し、その出力の期待値をとることで、特徴量 $S$ のみがモデルに与えられた場合の予測を近似する。このとき、本研究のような二値分類課題における損失関数 $\mathcal{L}$ として、以下の交差エントロピー誤差を用いる。ここで、 $y$ は真のラベル(0または1)、 $\hat{y}$ はモデルの予測確率である。

$$\mathcal{L}(y, \hat{y}) = -[y \log \hat{y} + (1 - y) \log(1 - \hat{y})] \quad (16)$$

特徴量集合 $S$ が持つ予測力を表す関数 $v_f(S)$ は、特徴量の情報がない状態からの損失関数の減少量の期待値として次式で定義される。

$$v_f(S) = \mathbb{E}[\mathcal{L}(f, \emptyset)] - \mathbb{E}[\mathcal{L}(f, S)] \quad (17)$$

ここで $\mathbb{E}[\mathcal{L}(f, S)]$ は、特徴量 $S$ を固定し、それ以外をサンプリングしたときの損失の期待値である。特徴量の相関が強い物理データにおいては、ある特徴量 $x_i$ の貢献度は、同時にどこ特徴量が使われているかによって変化する。従って、特定の特徴量の組み合わせだけで評価するのではなく、あり得るすべての組み合わせパターンについてその貢献度を評価し、平均化する必要がある。SAGE は協力ゲーム理論におけるシャープレイ値 (Shapley Value) の概念を導入し、特徴量 $x_i$ を様々な部分集合 $S$ に追加した際の限界寄与分の加重平均として SAGE 値 $\phi_i$ を算出する。

$$\phi_i(v_f) = \sum_{S \subseteq D \setminus \{i\}} \frac{|S|!(|D| - |S| - 1)!}{|D|!} [v_f(S \cup \{i\}) - v_f(S)] \quad (18)$$

この定義により、特徴量間の複雑な相互作用を考慮した上で、モデルの大域的な予測精度に対する各特徴量の公平な重要度を算出することが可能となる。

## 2.7.2 SAGE の近似アルゴリズム

前節で定義した SAGE 値 $\phi_i(v_f)$ を厳密に算出するためには、特徴量のあらゆる部分集合 $(2^{|D|})$ について損失関数を計算する必要があり、特徴量数が増加すると計算量が指数関数的に増大するため現実的ではない。そこで本研究では、モンテカルロ法に基づく順列サンプリングを用いて、SAGE 値の近似計算を行った。具体的な計算手順は以下の通りである。まず、全特徴量のランダムな順列 $\pi$ を生成する。この順列にしたがって、特徴量の一つずつモデルに追加していく過程を考える。この順列において、ある特徴量 $x_i$ を含まない特徴量集合 $S_{\pi, < i}$ 、 $S_{\pi}$ に特徴量 $x_i$ を追加した集合を $S_{\pi, \leq i} = S_{\pi, < i} \cup \{x_i\}$ とする。このとき、順列 $\pi$ における特徴量 $x_i$ の限界寄与分 $\delta_i(\pi)$ は損失関数の減少量として次式で表される。

$$\delta_i(\pi) = v_f(S_{\pi, \leq i}) - v_f(S_{\pi, < i}) = \mathbb{E}[\mathcal{L}(f, S_{\pi, < i})] - \mathbb{E}[\mathcal{L}(f, S_{\pi, \leq i})] \quad (19)$$

ここで、特徴量集合に含まれない変数の値は、検証データセットからのランダムサンプリングによって補完される。本解析では、この順列 $\pi$ を多数回( $M=1000$ 回)サンプリングし、それぞれの限界寄与分の平均をとることで、SAGE 値の不偏推定量 $\hat{\phi}_i$ を求

めた。このアルゴリズムにより、特徴量間の相関を考慮しつつ、計算コストを抑制して大域的な重要度を安定的に推定することが可能となる。

### 3 モデルの学習と性能評価

本章では、第2章で述べた解析フレームワークに基づき、ランダムフォレストによる帰巢飛行と自由飛行の分類結果について述べる。

#### 3.1 解析対象データの構成とグループ定義

本章での解析にあたり、群れの構成が異なる2つのデータセットを対象とした。各データセットには元来10個体分の計測データが含まれていたが、一部の個体においてデータの欠損や記録不備が確認されたため、解析に利用可能な個体のデータを選定して使用した。また、解析にあたって、各個体が所属していた群れの違いに基づき、以下のグループ構成で評価した。このように群れごとにグループを明示的に分けることで「群れが異なること」や「群れの規模」が個体の運動パターンにどのような影響を与えるかを検証することを目的としている。内訳は以下のようなものである。

1. データセット1 (5個体) : 取得された10個体のデータのうち、解析可能な5個体を対象とした。本実験では、測定の早い段階で群れが7個体と3個体の2つのグループに分裂し、帰巢した。そのため、分裂後に形成された2つの独立したグループに基づいて以下の通りに分類した。
  - ・グループA (3個体/7) : ID020, ID029, ID039
  - ・グループB (2個体/3) : ID010, ID038
2. データセット2 (8個体) : 本データセットは1個体を除き、群れを維持して帰巢した。
  - ・グループC (7個体/9) : ID011, ID012, ID0014, ID024, ID028, ID035, ID037
  - ・グループD (1個体/1) : ID042

図10にデータセット2の各個体における横軸が対地速度、縦軸が対地角速度の散布図を示す。本図を見ると、対地速度が $70[\text{km/h}]$ 以上かつ対地角速度が $-0.5\sim 0.5[\text{rad/s}]$ の領域と、対地速度が $20\sim 65[\text{km/h}]$ 付近かつ対地角速度が $-1.5\sim 1.5[\text{rad/s}]$ の領域に明確に分かれており、前者が帰巢飛行、後者が自由飛行に対応する。

3.2節以降では、これらのデータセットを利用し、4種類の学習・検証プロセスを行う。まず、個体内検証(3.2節)において、一個体のデータを用いてモデルを学習・検証

し、個体固有の運動パターンの分類精度を評価する。次に、グループ内検証（3.3 節）として、特定のグループ内で Leave-One-Subject-Out (LOSO) 交差検証を行い、グループ内のモデルの類似性を評価する。さらに、特定のグループの個体で学習させたモデルを別のグループの個体データで検証するグループ間検証（3.4 節）を通じて、異なる群れ間のモデルの違いを評価する。最後に、グループの垣根を越え、特定の 1 個体のデータで学習させたモデルをその他の全個体のデータで検証する総当たり検証を用いることで、個体間の共通性と特殊性を網羅的に解析する。

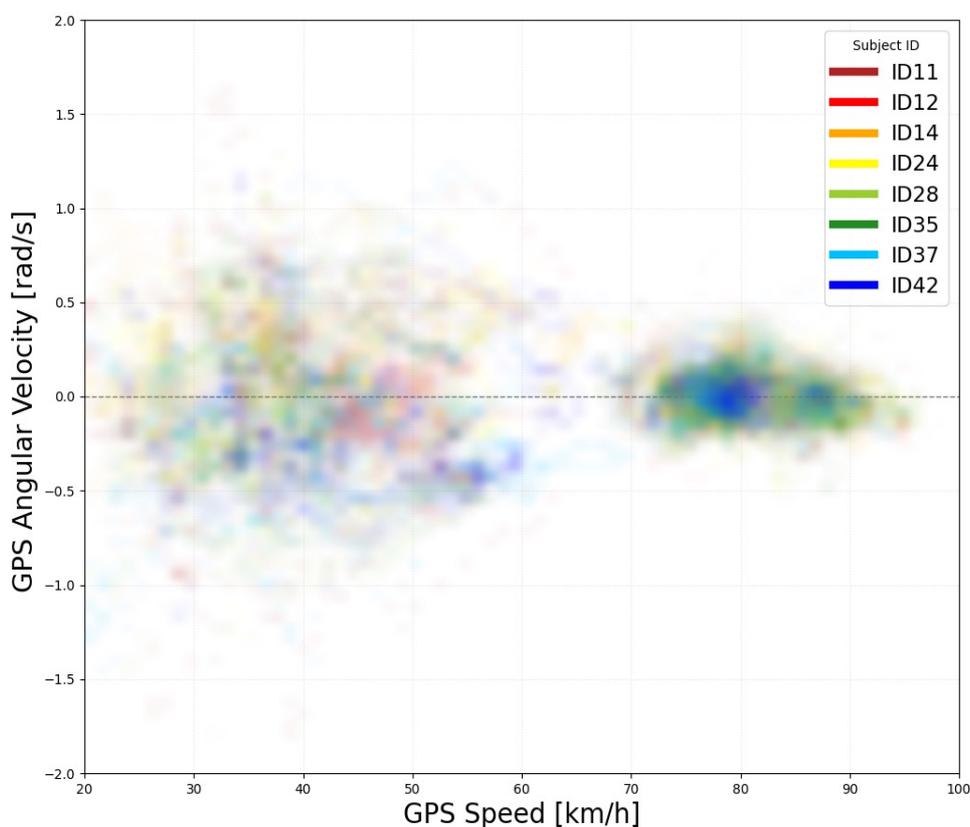


図 10：各個体における横軸が対地速度、縦軸が対地角速度の散布図。

## 3.2 個体内検証

前節で定義した各グループ（A～D）のデータセットを用いて、個体ごとに学習・検証を行った結果について述べる。各個体における正解率および MCC スコアの結果を図 11 に示す。

全体の結果として、すべてのグループにおいて高い分類精度が確認された。具体的

には、全体の平均で正解率は 0.96、不均衡データの評価指標である MCC スコアにおいても平均 0.93 という高いスコアが得られた。詳細を見ても、ID012 を除いて、極めて高い分類精度が得られている。

これらの結果のように、群れの違い、単独での飛行に関わらず一貫して高精度に分類ができたという事実は、「帰巢飛行」と「自由飛行」の間には環境要因や群れの状況に左右されない、明確な運動様式の違いが存在することを示唆している。また、この高い分類精度は、本研究で定義し、抽出した慣性センサー特徴量が、その飛行パターンの物理的な運動の違いを概ね捉えることができている裏付けと言える。次節以降の個体間検証において、「帰巢飛行」と「自由飛行」における明確な差異が群れ内で共有されるものなのか、あるいはハトという種に一般的なものなのかを検証する。

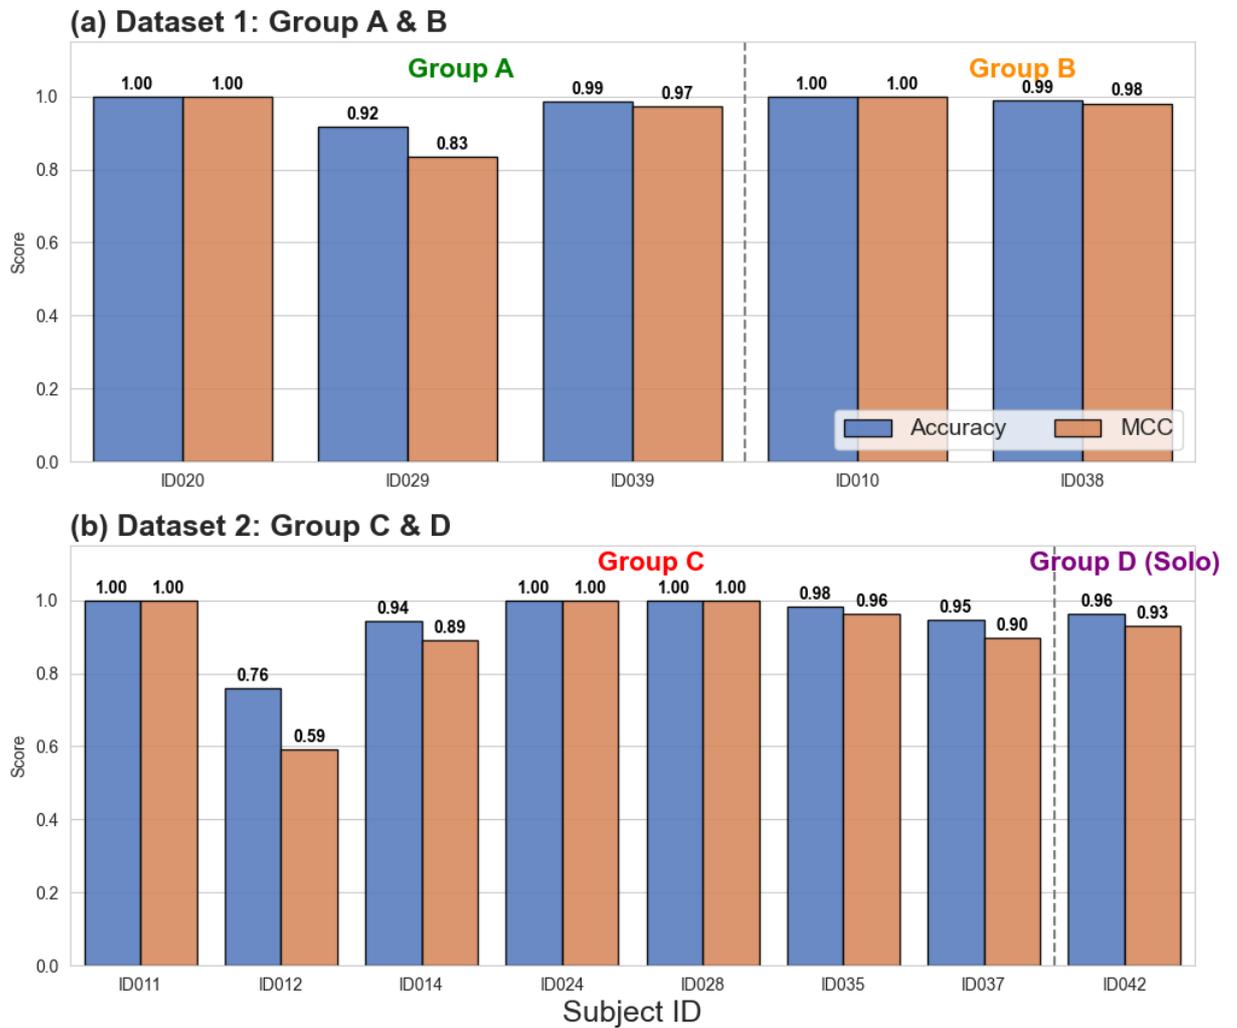


図 11： 各グループにおける個体内検証結果。(a)がデータセット 1 のグループ A,B、(b)がデータセット 2 のグループ C,D の結果である。青色は正解率 (Accuracy)、橙色は MCC スコアを示す。

### 3.3 個体間検証（グループ内検証）

本節では、同一の群れに属する個体間でのモデルの汎用性を検証するため、Leave-One-Subject-Out (LOSO) 交差検証を行った結果を述べる。Leave-One-Subject-Out (LOSO) 交差検証とは、解析対象のうち特定の 1 個体のデータのみを検証用、残りの全個体のデータを学習用として全個体分順次入れ替えて検証を繰り返す手法である。さらに、個体別のばらつきを超える「群れ全体の共通性」を評価するために、各グループの全個体のデータを統合して学習・検証を行ったモデルの精度を合わせて評価した。この検証により、前節における「帰巢飛行と自由飛行の運動パターンの違い」が群れ内で共通のものなのかを評価する。図 12 に各グループにおける正解率および MCC スコアの結果を示す。

全体の結果として、他個体のデータで学習したモデルであっても、高い分類精度が得られた。具体的にはデータセット 1 において、グループ B では正解率 0.99、MCC スコア 0.98 とほぼ完璧な予測精度を記録した。グループ A においても、正解率 0.94、MCC スコア 0.89 と高い水準を維持している。さらに、7 個体という多個体で構成されたデータセット 2 のグループ C (図 12 (b)) においても、平均正解率 0.90、平均 MCC スコア 0.82 という結果が得られた。個別の結果を見ると、ID011 や ID028 など半数以上の個体で MCC 0.90 を超えるスコアを記録しており、他個体のデータのみで自身の運動を正確に予測できている。一方で、ID035 については MCC 0.32 と例外的に低い値を示した。これは、当該個体が群れの平均的な運動パターンとは異なる特異的な動きをしていたか、あるいはセンサー位置のズレなどの外部要因による影響が考えられる。しかし、ID035 を除く大多数の個体で高い精度が維持されていることから、モデルは特定の個体の癖ではなく、群れに共通する一般的な運動特徴を学習できていると考えられる。ID035 の特異性については 3.5 節の総当たり検証で述べる。

また、各グループの全個体の学習データを用いてモデルを構築し、全個体の検証データに対して評価を行った結果 (図 12 中の斜線付きグラフ)、いずれのグループにおいても極めて高い分類精度が確認された。グループ A では正解率 0.98、MCC スコア 0.96、グループ B では MCC スコア 1.00 とほぼ完璧な分類精度を記録した。また、グループ C においても正解率 0.96、MCC スコア 0.92 という高いスコアを記録した。グループ C では ID035 のように精度が著しく低い個体が含まれていたが、グループ全個体のデータを統合して学習・検証を行うと、グループ全体としての識別精度は非常に高く安定している。この結果は、一部の個体に特異的な挙動が見られたとしても、群れ全体としては帰巢飛行と自由飛行を明確に区別する共通の運動法則が存在すること

を統計的に裏付けている。

以上の結果は、帰巢飛行において個体特有ではなく群れを構成する個体間で一般的な運動の特徴が存在することを示唆している。次節では、グループの異なる個体間で学習と検証を行うことで、本結果が群れ内に留まるものなのか、あるいはハトにおける一般的なものなのかを評価する。

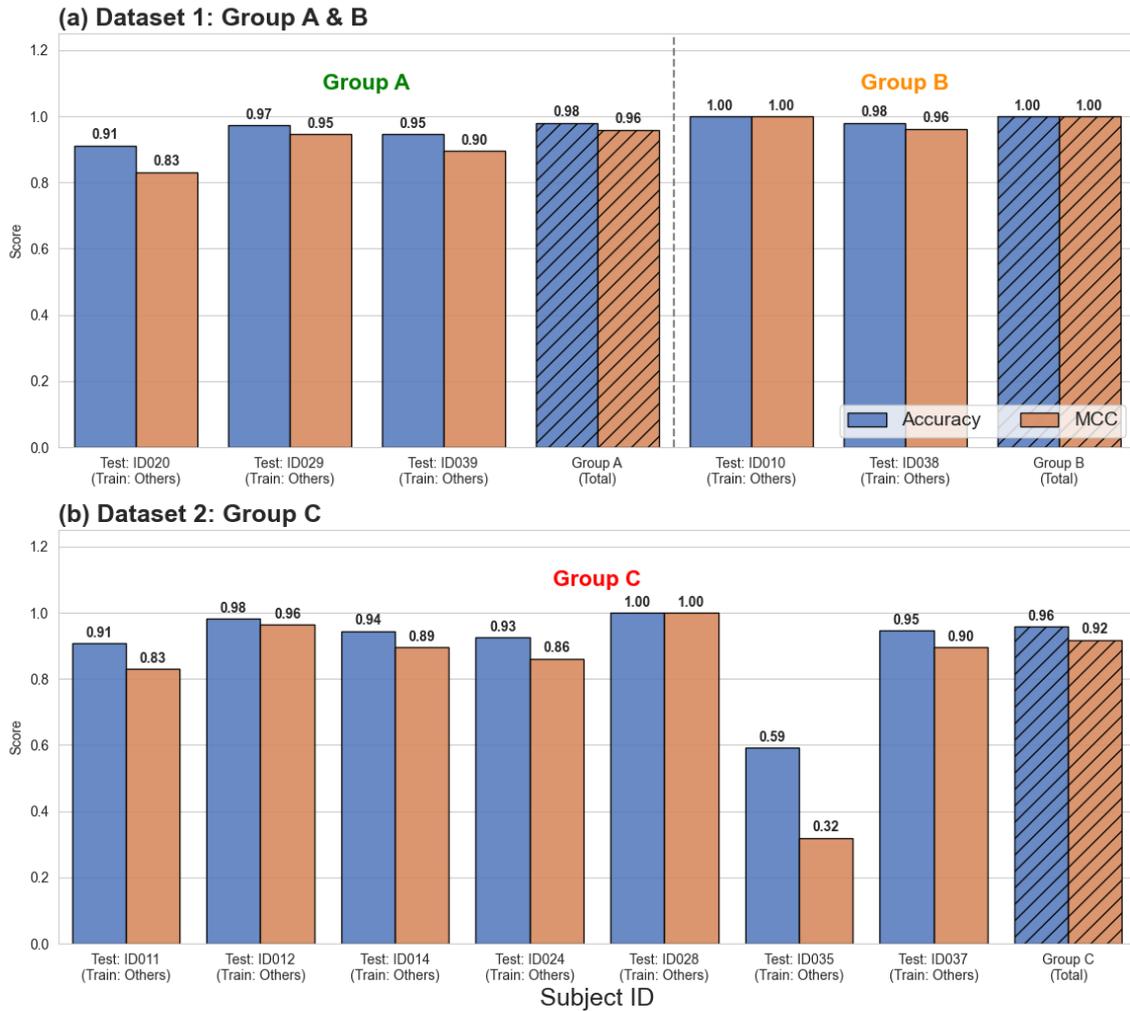


図 12: 各グループ内における個体間相互検証結果 (Leave-One\_Subject\_Out 交差検証)。(a)がデータセット 1 のグループ A,B、(b)がデータセット 2 のグループ C の結果である。青色は正解率 (Accuracy)、橙色は MCC スコアを示す。

### 3.4 グループ間検証

本節では、異なる群れや実験条件（データセット）を超えてモデルが通用するか、すなわち環境要因や個体差および群れの違いに依存しないハトの帰巢飛行における一般的な運動の特徴が捉えられているかを検証した。検証は、学習グループと検証グループを入れ替える形式で行い、その目的と対象に応じて以下の3つのフェーズで評価した。結果を図 13 に示す。

まず、同一環境において、分裂したグループ A とグループ B の間で検証を行った。グループ A で学習し、グループ B で検証を行ったケースでは MCC 0.99、逆のケースでも MCC スコア 0.90 という極めて高い精度が確認された。これは、同一の環境であれば、その運動パターンは類似していることを示唆している。

また、群れの構成が異なるデータセット間で検証を行った結果、汎化性能に非対称性が確認された。グループ C（データセット 2）で学習させたモデルは、グループ A、B（データセット 1）に対しても正解率 0.98、MCC スコア 0.95 という高い分類精度を示した。一方、データセット 1（グループ A、B）で学習させ、グループ C（データセット 2）で検証したケースでは、正解率 0.83、MCC スコア 0.70 に留まった。これは、グループ C の運動データが、グループ A、B の運動パターンをも包含する普遍的な特徴量で構成されていることを示している。また、この精度の低下はモデルの性能不足によるものではなく、グループ A、B から抽出される特徴だけでは、グループ C の運動を完全には説明できないという客観的事実を表している。この結果から、環境要因が運動パターンに与える可能性が示唆されている。同一データセット内にあるグループ A、B の間では正解率 0.99、MCC スコア 0.98 という完全に近い互換性が確認された（図 13）。この結果は、両グループが同じ環境要因に対して共通の適応を行っていた可能性があり、逆の検証ケースで正解率 0.83、MCC スコア 0.70 に留まったことは、環境への適応動作が強く反映されたことを示唆している。逆に、グループ C で学習したモデルが高い汎用性を示したことは、グループ C のデータが環境特異的なバイアスをあまり含まず、よりハトに一般的な帰巢飛行の運動を行っていた可能性を示唆している。

最後に、全ての群れデータ（A～C）を統合して学習させ、単独飛行個体（グループ D：ID042）を検証した（図 13 の最も右のグラフ）。結果は MCC スコア 0 以下と著しく低く、モデルは単独個体の運動を「帰巢飛行」として正しく識別することができなかった。この結果から、群れで飛ぶ場合の帰巢運動と、単独で飛ぶ場合の帰巢運動はモデルが同一視できないほど特徴量空間上で明確に乖離している（物理的に異なる運動モードである）ことが分かった。ハトが群れで飛行する際、群れで運動が同

期しているなどの理由が考えられるが、現時点では判然としない。

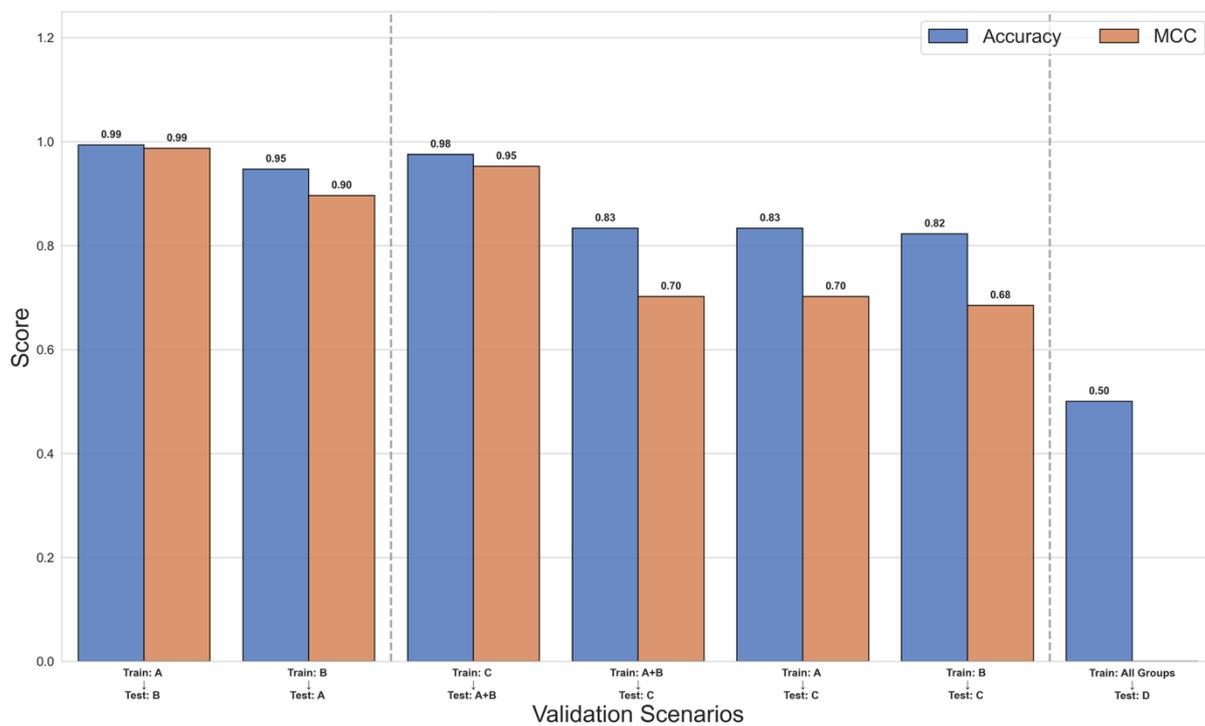


図 13：異なるグループ間におけるモデルの検証結果。縦軸は分類精度の指標を示す。青色は正解率（Accuracy）、橙色は MCC スコアを示す。

### 3.5 総当たり検証

前節で確認された結果を個体レベルの相互関係から明らかにするため、全 13 個体による総当たりの学習と検証を行った。図 14 および図 15 に各個体で学習したモデル（行）を用いて、各個体（列）で検証した際の正解率および MCC スコアの結果を示す。

ここでは MCC（図 15）を用いて説明する。データセット 1（グループ A、B）とデータセット 2（グループ C）の間において、予測精度の非対称性が確認された。具体的には、グループ C の個体（ID035, ID037 を除く）で学習させたモデルは、別のデータセットであるグループ A, B の個体に対しても比較的高い予測精度を示した（図 15 のグループ C の行で、グループ A もしくは B の列の MCC が 0.64~1.00）。一方で、逆にグループ A, B の個体で学習させたモデルがグループ C の個体を予測する際の精度は相対的に低くなった（図 15 のグループ A もしくはグループ B の行でグループ C の列の MCC が 0.00~0.93）。この結果は、グループ C から抽出された特徴量はグループ A, B の運動パターンも説明できる包含的な性質を持つ一方で、グループ A, B から抽出された特徴量はグループ C の運動パターンを完全にはカバーできないという事実を示しており、グループ間検証における結果と一致している。

また、同一のグループ C 内において、個体によって他個体への予測能力に大きな差が見られた。ID011 や ID014、ID028 は行として見た際にほぼ全ての群れ個体に対して高い正解率と MCC スコアを記録しており、1 個体のデータであっても一般的なモデルとして機能している。対照的に、ID037 は行全体が低いスコアとなっており。しかし、グループ内検証において ID037 のデータを高精度に分類できたという結果から、群れ内での共通の特徴を持ちつつも、独自の運動の特徴も持ち合わせていたということを示唆している。

また、ID042（ヒートマップの右端列）は ID035 を除く何の群れ個体モデルを用いても MCC スコアが 0 近傍、正解率が 0.5~0.6 程度に留まった。これは、モデルによる予測がランダムに近いことを意味し、群れ飛行と単独飛行の運動パターンの不一致を示している。つまり、単独での帰巢と群れでの帰巢が物理的に区別される異なる運動モードであることを示唆している。一方、特筆すべき例外として、単独飛行をした ID042 は群れ内の ID035 に対してのみ正解率 0.93、MCC スコア 0.85 と高い分類精度を示した。ID035 は他個体のモデルからの予測精度が低かった個体である。この相互相関の結果は、ID035 が群れの中に位置しながらも、運動の物理的特性としては単独飛行と極めて高い類似性を有していた事実を表している。先行研究 [2] によれば、ハトが群れで飛行する際、前方に他個体がいる場合、羽ばたき周波数が影響を受けるこ

とが確認されている。さらに、先行研究 [13, 11]では、ユリカモメの群れにおいて、各個体が進行方向に他の個体がいることを避けて飛行することが分かっている。ID035 が特異である理由として、群れの先頭を飛行しており、他の個体からの影響を受けていない可能性が考えられる。このことを検証するため、グループ C の 10 秒間の飛行軌跡を図 16 に示す。さらに、帰巣飛行時における、各個体の群れの重心からの相対位置を図 17 に示す。これらのグラフを見るとグループ C では、ID012 を除く個体が ID035 を追従して飛行していることが分かる。つまり、ID035 が単独飛行をする ID042 と類似した物理特性を持っていた要因が、「群れの先頭を飛行していたことで他個体の影響を受けなかったということ」ではないかと思われる。

以上の総当たりの検証結果は、単なる分類精度の高低を超え、帰巣飛行における一般的な運動の特徴の存在を示唆している。環境が異なるグループ C のモデルがグループ A,B の個体に対しても高い予測精度を示した事実は、帰巣飛行がその場や環境や個体の気まぐれで決まるランダムな運動ではなく、ハトにおける一般的な運動のルールが存在することを示唆している。

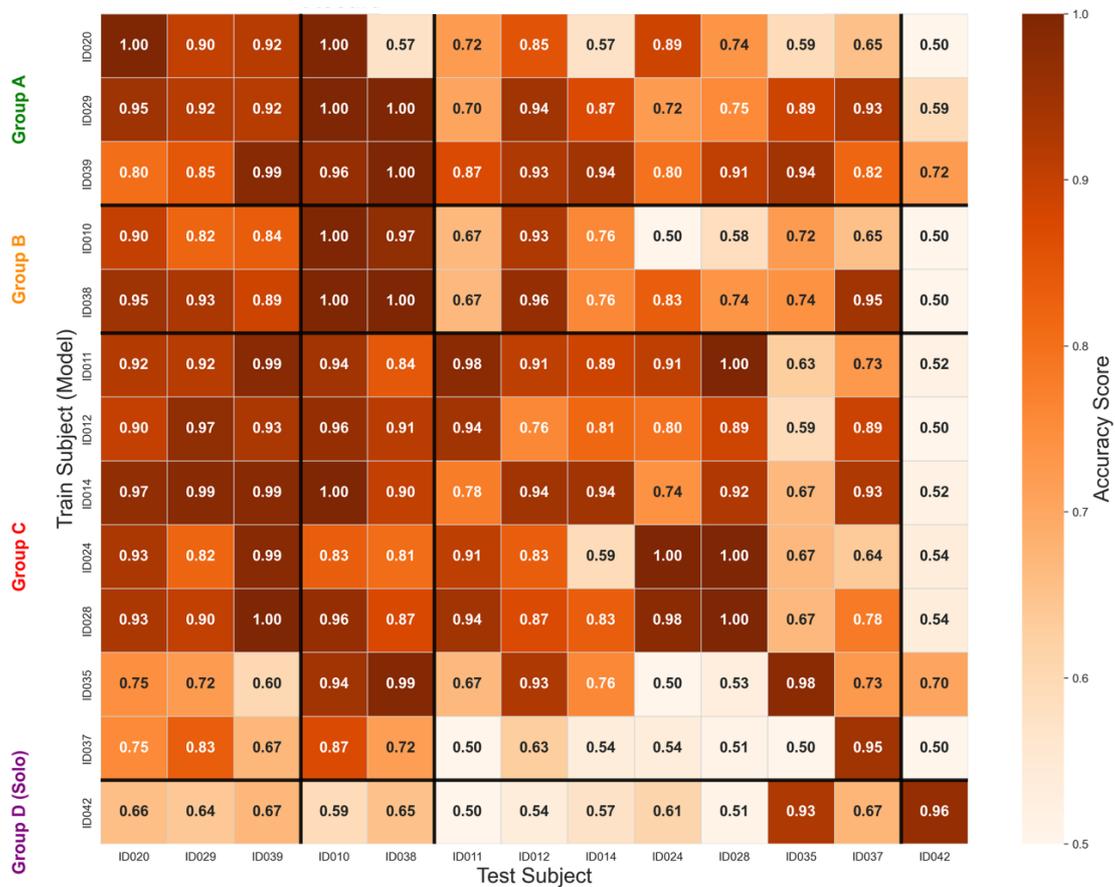


図 14：総当たり検証の結果のヒートマップ（正解率）。横軸はモデルの検証に使用された個体の ID、縦軸はモデルの学習に使用された個体の ID。

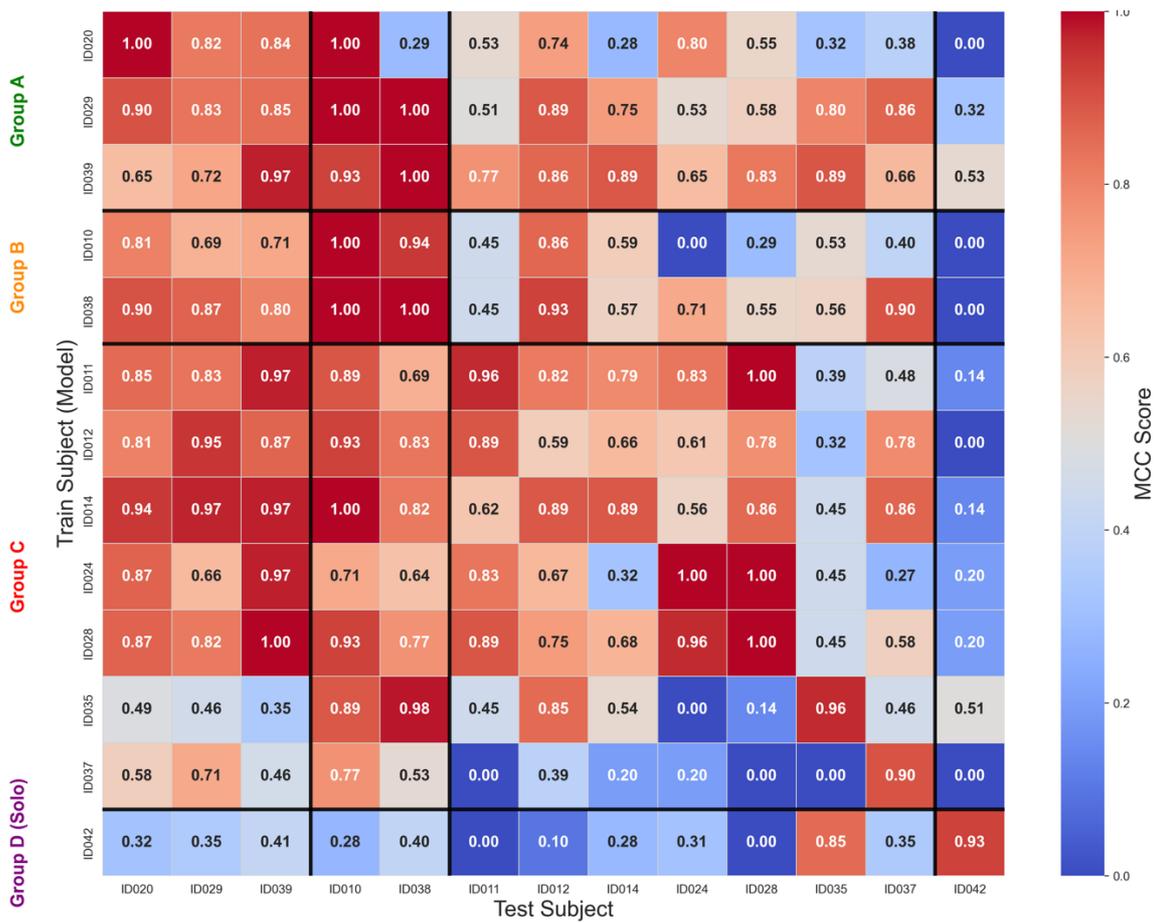


図 15：総当たり検証の結果のヒートマップ (MCC)。横軸はモデルの検証に使用された個体の ID、縦軸はモデルの学習に使用された個体の ID。

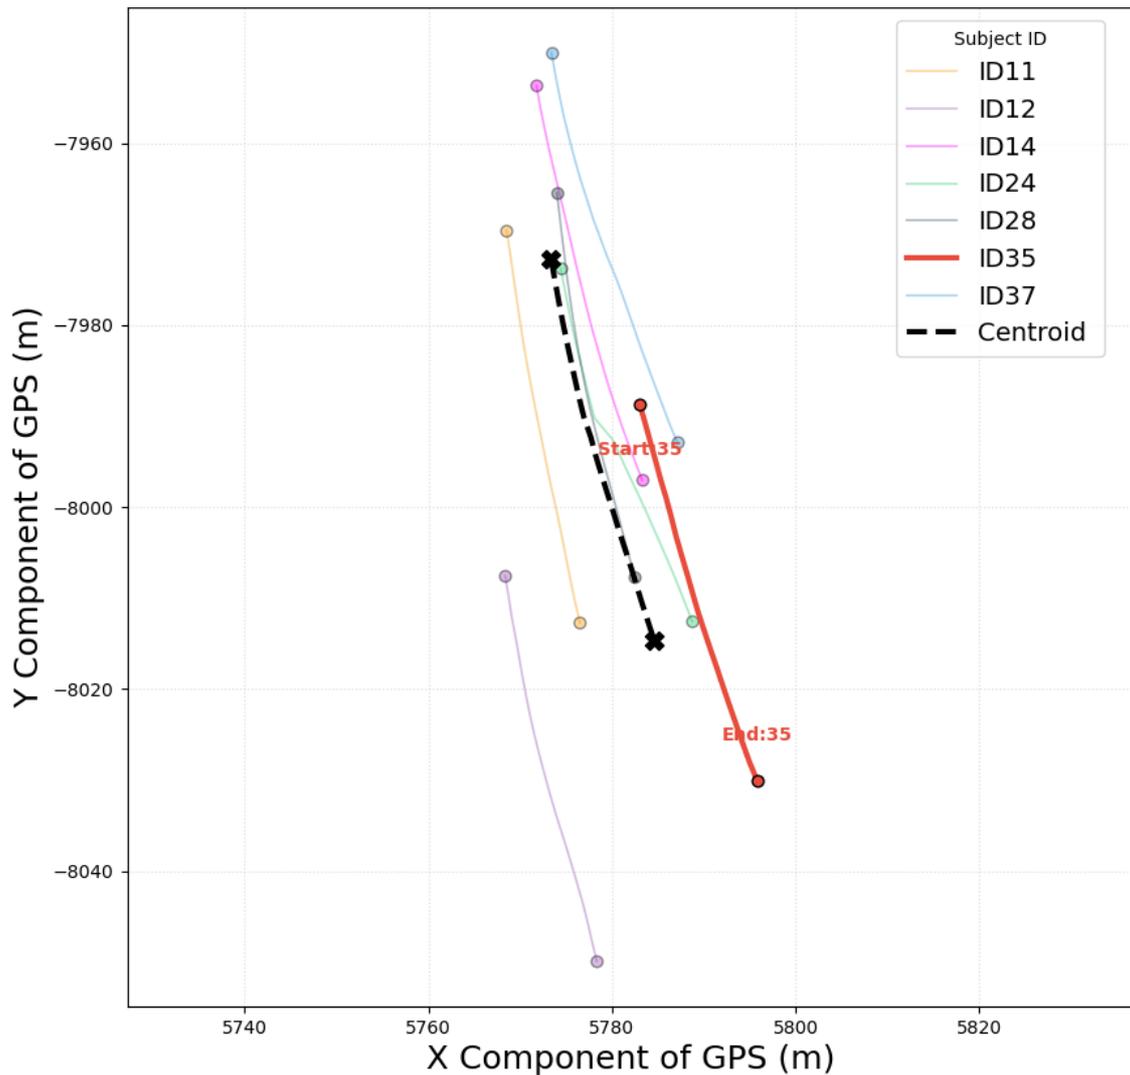


図 16：帰巢飛行における、グループ C の各個体および群れの重心の飛行軌跡（10 秒間）。横軸が GPS の X 成分、縦軸が GPS の Y 成分。移動方向は Y が減少する方向で、太い実線（赤色）は群れの先頭を飛行する個体 ID035 の軌跡、薄い実線は他の個体の軌跡、黒い破線は群れを構成する各個体の GPS データを平均した座標、すなわち群れの重心の軌跡である。

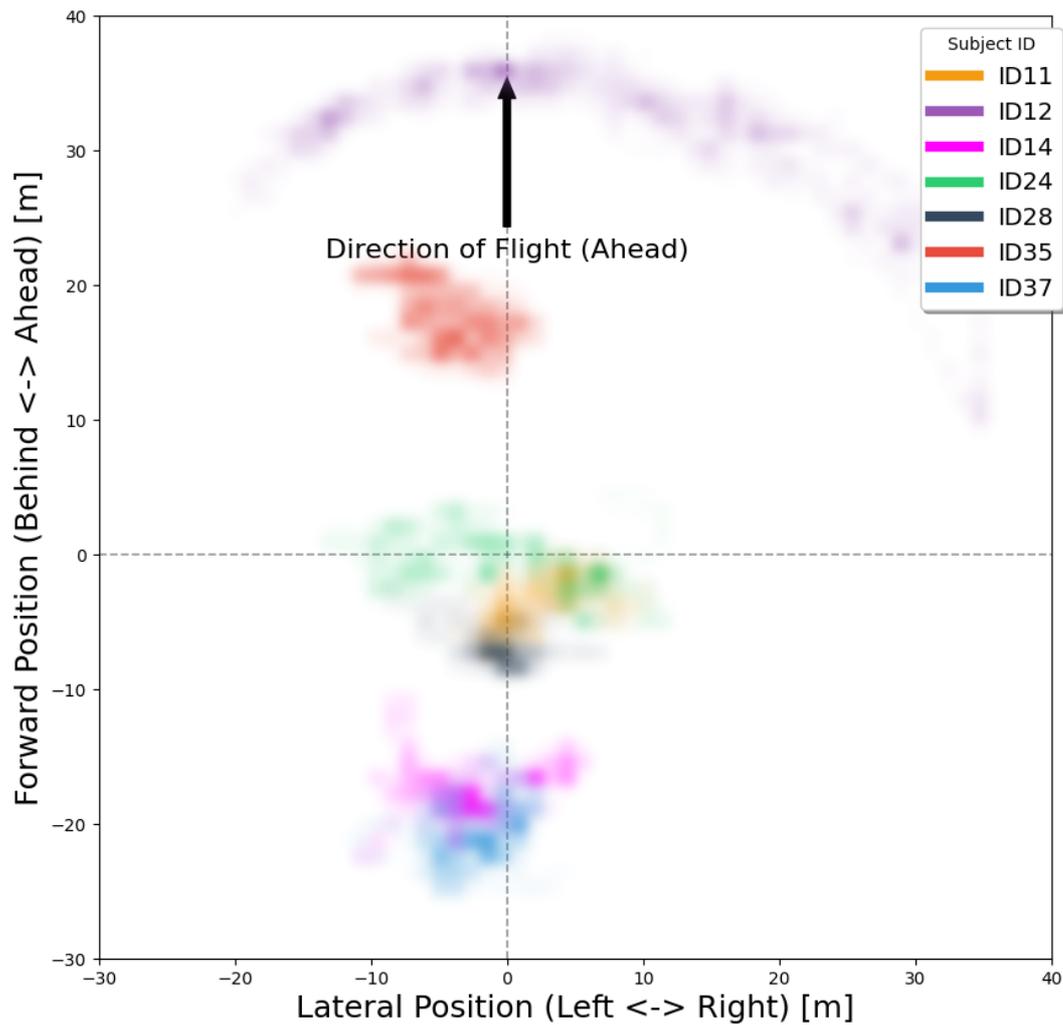


図 17：グループ C における、群れの重心を原点とした各個体の相対位置。横軸、縦軸はそれぞれ群れの重心からの左右方向の変位[m]、前後方向の変位[m]。ID012 が群れの前線を飛行しながらも、他個体が追隨しておらず、ID035 が実質的に群れの先頭を飛行していることが分かる。

## 4 SAGE による特徴量重要度解析

前章において、慣性センサーから得た特徴量を学習させたランダムフォレストモデルが高い分類精度を持つ一方で、「群れの違い」や「単独飛行か群れ飛行か」による運動パターンの違いが存在することが明らかになった。本章では、モデルの内部構造を解釈可能な状態にするため、SAGE を用いた特徴量重要度の定量化を行う。これにより、ブラックボックス化しやすい機械学習モデルが、どの特徴量に基づいて予測を行うのかを解明し、ハトの帰巢飛行と自由飛行における運動の違いを物理的に解釈するヒントを得ることができる。

### 4.1 SAGE 値の収束と信頼性の検証

SAGE 値は特徴量集合からのサンプリング（モンテカルロ法）に基づき、その特徴量が予測精度の改善にどれだけ寄与したかを近似計算する手法である。そのため、特徴量集合のサンプリング回数  $N$  が不足している場合、計算結果にばらつきが生じ、SAGE 値の信頼性が損なわれる可能性がある。本解析に先立ち、十分な信頼性を確保するために必要なサンプリング回数の検証を行った。サンプリング回数  $N$  を 10 から 3000 まで段階的に増加させた際の、主要特徴量における SAGE 値の変動を図 18 に示す。検証の結果、 $N < 100$  では値の振動が見られたものの、 $N > 500$  においてはすべての主要特徴量の SAGE 値が収束することを確認した。この結果に基づき、本研究における以下の解析では、計算コストと精度のバランスを考慮し、十分な収束が保証される  $N = 1000$  を採用した。

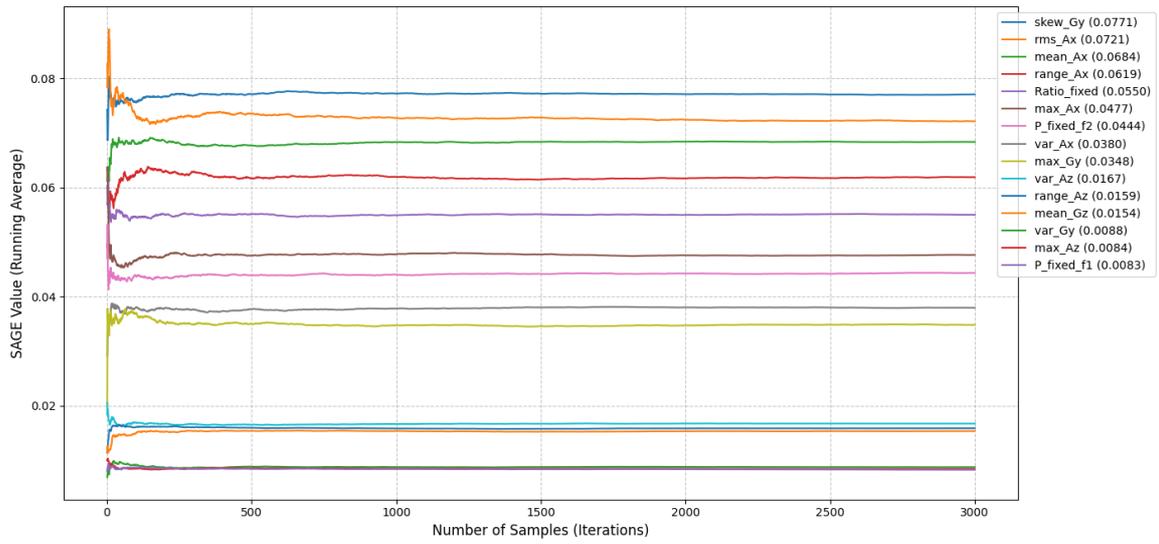


図 18：サンプリング回数による SAGE 値の収束 (ID029 の例)。上位 15 個の特徴量の値が安定するプロセスを示している。横軸はサンプリング回数、縦軸は SAGE 値。

## 4.2 全個体統合モデルによる普遍的特徴の抽出

一般に共通する帰巢飛行と自由飛行の物理的な差異を特定するため、全 13 個体のデータを統合して学習させたモデルの各特徴量の SAGE 値を算出した。図 19 にその結果を示す。本モデルは MCC スコア 0.92 という極めて高い精度を有しており、上位にランクインした特徴量は、環境や個体差に左右されない普遍的に重要な特徴量と言える。また、分析の結果、上位 15 項目でモデルの判断根拠の 83.2% が説明可能であることが判明したため、本研究ではこれらを以下の 4 つの主要カテゴリーに集約した。次章で各カテゴリーの詳細な解析結果を述べる。

### ・運動のリズム：*Ratio\_fixed* , *P\_fixed\_2* , *period\_Gy* , *periodic\_Gy*

SAGE 値が最も高かった *Ratio\_fixed* は、本解析における最重要指標である。これは前後加速度 ( $A_x$ ) における通常の羽ばたき周期とその倍周期のパワー比を抽出したものである。一般に、鳥類の飛行はダウンストローク (打ち下ろし) 時に最大の推進力を得るが、自由飛行時の激しい機動においては、アップストローク (引き上げ) 時にも加速する可能性が考えられる。もしアップストロークで加速が生じれば、 $A_x$  の波形には一周内に 2 つのピークが現れ、結果として倍周期のエネルギーが増加する。モデルがこの周波数比を重視しているという事実は、帰巢飛行と自由飛行では「アップストロークによる加速の大きさの違い」という推進力を生成するメカニズムが根本的に異なっている可能性を示唆している。

### ・姿勢制御：*skew\_Gy* , *range\_Gy* , *rms\_Gy* , *max\_Gy*

上位 15 特徴量中に  $G_y$  (ピッチ角速度) 関連の特徴量が複数含まれているという結果は、帰巢飛行と自由飛行の間で姿勢動態に違いがあることを示している。

### ・運動の対称性、ばらつき：*skew\_Ax* , *skew\_Az* , *var\_Ax* , *var\_Az*

ランキング 10 位以内に 3 軸全ての歪度がランクインしている点は本解析において重要な発見である。歪度は波形の非対称性を反映する統計量である。三次元的な加速・回転運動の偏りが分類の強い根拠となっている事実は、帰巢飛行と自由飛行で体や翼の動かし方が異なっているということを物理的に裏付けている。

### ・運動の強度、激しさ：*max\_Ax* , *min\_Az* , *rms\_Ax* , *mean\_Ax*

*max\_Ax* や *min\_Az* は 1 窓内の最大および最小を示すが、これらと併せて rms や mean を解析することで、羽ばたき運動全体の違いを評価する。

**Integrated Pareto Analysis of Flight Kinematics (Top 15)**  
**Total Contribution: 83.2% | MCC: 0.922**

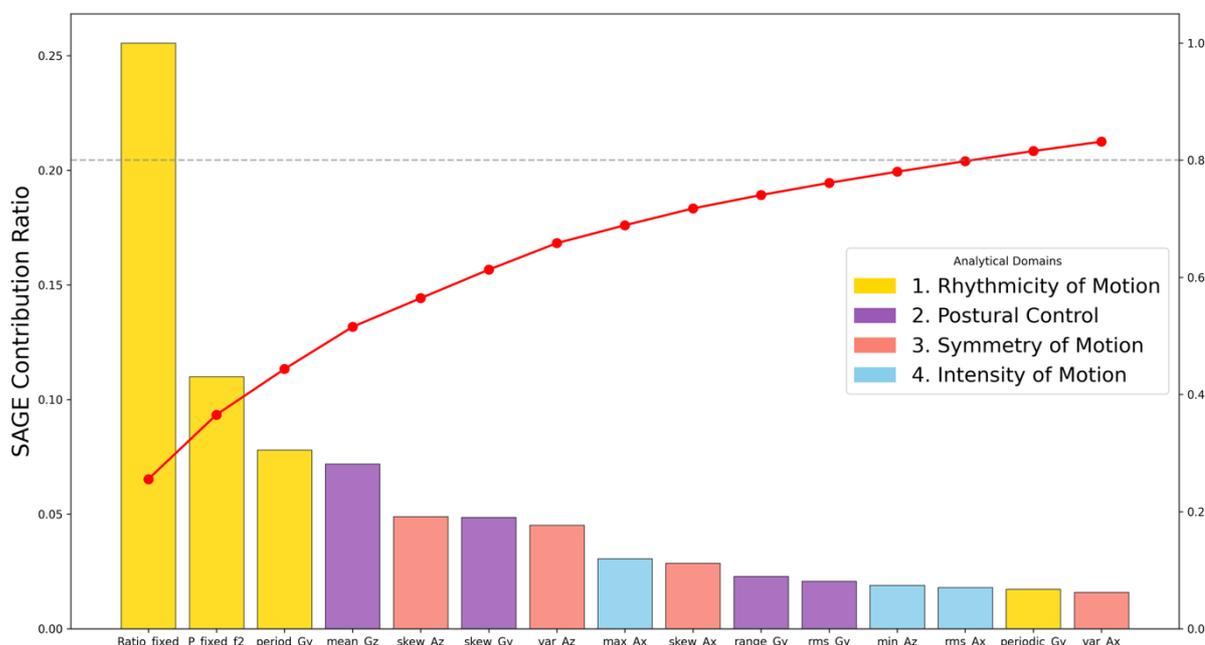


図 19：全個体統合モデルの各特徴量の SAGE 値（上位 15 個）および累積寄与度（赤線）。縦軸（左）は SAGE 値、縦軸（右）はそれらの累積寄与度、横軸は特徴量。各特徴量はその物理的特性に基づき、黄色（運動のリズム）、紫色（姿勢制御）、赤色（運動の対称性）、青色（運動の強度）の 4 カテゴリーに分割し、色分けした。

### 4.3 飛行状況による重要特徴量の変化

本節では、前章で確認された各飛行状況において、運動の特徴が異なる可能性を SAGE によって評価する。評価にあたり、全 13 個体のデータを統合して学習させたモデルを固定することで共通の尺度とし、各飛行状況のデータを用いて SAGE 値を計算した。

まず、解析の妥当性を評価するため、「標準的な群れ (ID035 を除くグループ A,B,C 全個体)」、「単独飛行の代表 (ID042)」、および「群れの先頭個体 (ID035)」の 3 パターンの検証データに対して、全個体統合モデルの予測精度を算出した。その結果を図 20 に示す。MCC スコアを見ると、全てのデータ群において MCC が 0.7 以上を記録しており、本モデルが各飛行状況における物理的特徴を抽出できていることが確認された。また、3つのデータ群に対して SAGE 値を計算した。前節で述べた特徴量のカテゴリーに基づき、各飛行状況における各カテゴリーの重要度 (SAGE 値) を比較した

結果、以下の客観的な差異が認められた（図 21）。

- ・標準的な群れの傾向：周波数領域の特徴量の寄与率が約半数を占めるが、他のデータ群と比較して姿勢制御関連の特徴量（23.4%）の寄与が最も高い数値を示した。一方、運動の非対称性およびばらつきに関連する特徴量の寄与は 15.3%と 4つのカテゴリの中で相対的に低い水準に留まった。

- ・単独飛行個体（ID042）の傾向：各カテゴリの寄与が最も分散している。他のデータ群と比較して、運動の強度および激しさに関連する特徴量と運動の非対称性およびばらつきに関連する特徴量の重要度が高い結果となった。

- ・先頭飛行個体（ID035）の傾向：周波数領域の特徴量の寄与率が 63.5%に達し、全データ群の中で最も高い値を示した。一方、姿勢制御に関連する特徴量および運動の非対称性に関連する特徴量の寄与が低い値を示した。

以上の各データ群におけるカテゴリ別寄与率の差異から、飛行状況および個体ごとに重要なる運動学的特徴として、以下の内容が推測される。まず、標準的な群れにおいて、周波数領域の特徴量が 48.7%と高い寄与率を示した事実は、群れでの飛行において個体差を超えて共有される協働的なリズムが存在することを示唆している。全個体統合モデルが本データ群に対して MCC スコア 0.951 という極めて高い分類精度を記録していることから、帰巢飛行と自由飛行の切り替え時に群れ内の個体が共通のリズム変化を起こしていると考えられる。対照的に、単独飛行において周波数領域の特徴量の寄与率が 36.7%と相対的に低下し、他の 3 カテゴリに寄与率が分散した結果は、周囲に他個体が存在しない環境下では、羽ばたきのリズムに個体ごとの独自性やばらつきが生じやすい可能性を示唆している。そのため、モデルが他カテゴリの特徴量も含めて多角的に分類を行っていると推測される。さらに、群れの先頭を飛行していた ID035 においては、周波数領域の特徴量の寄与率が 63.5%と全データ群の中で突出した値を示した。一方で、標準的な群れで重要視された姿勢制御に関する特徴量の寄与率は 13.5%という低い値を示している。これらの事実は、群れの先頭を飛行する ID035 のリズムに他の個体が合わせている可能性を示唆している。

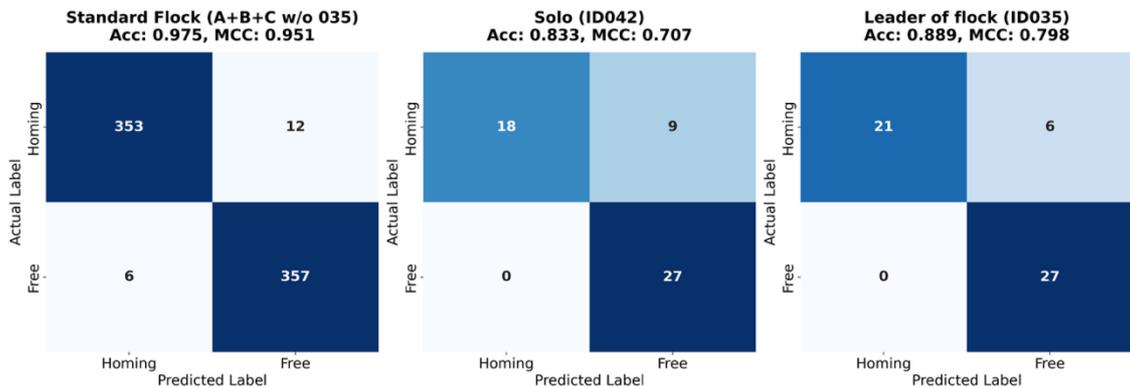


図 20：「標準的な群れ（ID035 を除くグループ A,B,C 全個体）」、「単独飛行の代表（ID042）」、および「群れ先頭個体（ID035）」の 3 パターンの検証データに対する、全個体統合モデルの混同行列および正解率、MCC スコア。

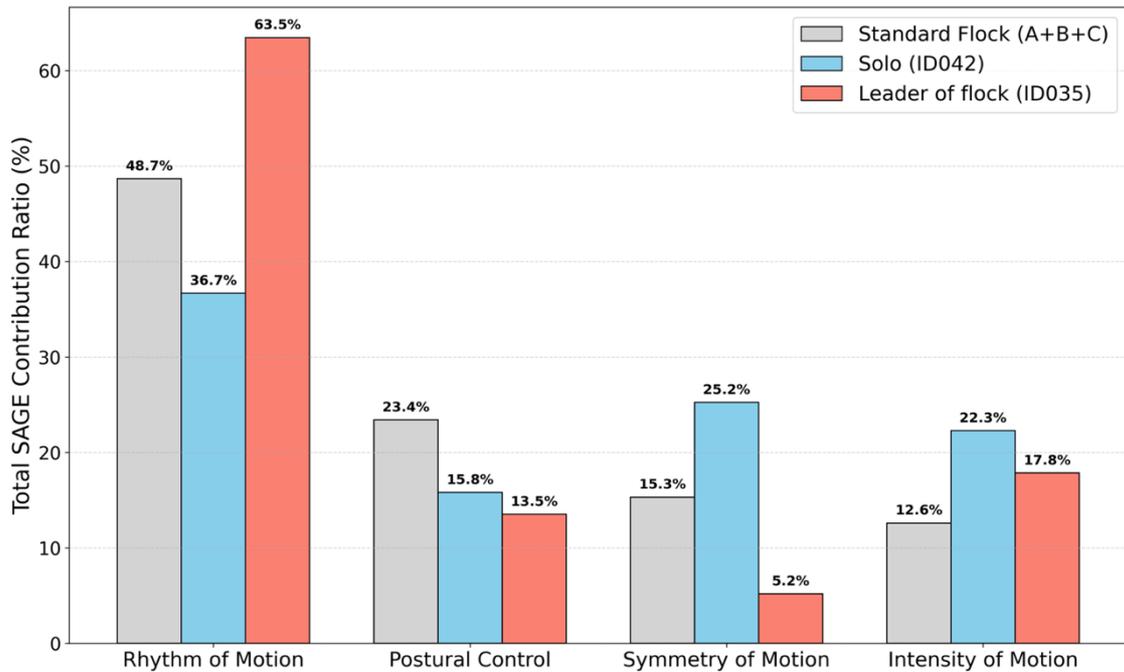


図 21：全個体統合モデルにおいて、特徴量の各 4 カテゴリー（運動のリズム、姿勢制御、運動の対称性、運動の強度）の合計寄与率を比較したグラフ。縦軸が合計寄与率である。灰色が「標準的な群れ（ID035 を除くグループ A,B,C 全個体）」、水色が「単独飛行の代表（ID042）」、赤色が「群れ先頭個体（ID035）」のデータによって計算された合計寄与率を表す。

## 5 運動メカニズムの詳細解析と物理的解釈

本章では、前章の SAGE による特徴量重要度解析から得られた全個体統合モデルにおける上位 15 個の特徴量 (図 19) から選定した重要特徴量 5 個について、個別の解析を行った結果を述べる。具体的には、帰巢飛行と自由飛行における各特徴量の全個体の分布を重ね合わせた積層密度分布から、種に共通した違いについて述べる。さらに、個体ごとの分布も併せることで、飛行状況別の差異についても考察を行う。

### 5.1 運動のリズム関連の特徴量

#### 5.1.1 前後加速度の二倍周波数と基本周波数のパワー比 (*Ratio\_fixed*)

まず、全 13 個体における *Ratio\_fixed* の分布を重ね合わせた密度分布を図 22 に示す。帰巢飛行時において、ID042 を除く全個体の分布のピークが *Ratio\_fixed* < 0.5 の極めて狭い帯域に集中していることが確認された。このことは、羽ばたきの加速度波形が純粋な正弦波に近く、第 2 高調波の要因となるアップストロークによる加速の寄与が小さいことを示している。これは、定常的な帰巢飛行において、ダウンストロークによる推進を行っていることを裏付けている。一方、自由飛行における分布を見ると、著しく広がっていることが分かる。このことは自由飛行時において、アップストロークによる加速が動的に変動していることを示している。自由飛行では、旋回や障害物回避などに際して、アップストロークによる加速度の調整を行っている可能性を示唆している。

また、各個体の分布を図 23 に示す。帰巢飛行において、同一グループに属する個体では、分布の形状が類似していることが確認できる。このことは、群れを形成して帰巢する際、個体間で加速のリズムが共有されている可能性を示唆している。対照的に、自由飛行では多様な分布が確認できる。理由として、自由飛行時には群れでの飛行から解放され、「個体の癖が現れやすくなっている」、「旋回や障害物回避などの特定のイベントに各々が適応している」などが推測される。また、単独飛行個体である ID042 の分布を見ると、他個体と比較して、帰巢飛行時でも値が大きくなっている窓が多数確認されるが、この事実は ID042 が帰巢飛行においても一部アップストロークによる推進を行っていたことを示唆している。

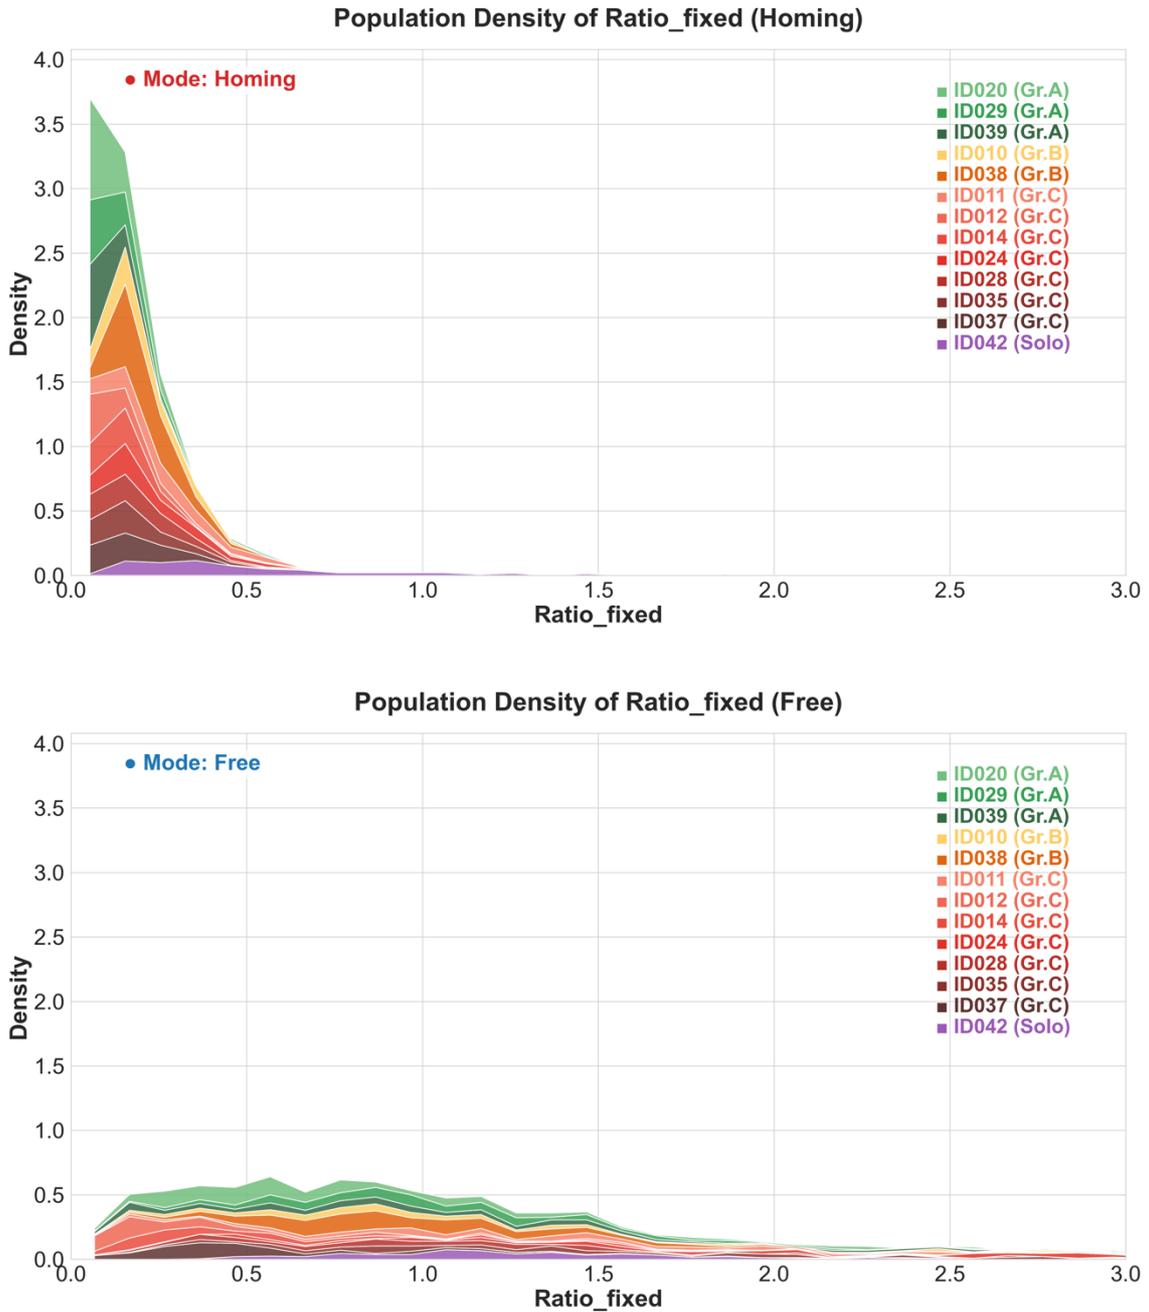


図 22：全個体における *Ratio\_fixed* の積層密度分布。上のグラフが帰巢飛行、下のグラフが自由飛行に対応する。横軸の *Ratio\_fixed* は羽ばたき基本周波数帯域（5.0-9.0[Hz]）の最大パワーとその2倍の帯域（10.0-18.0[Hz]）における最大パワーの比を表す。縦軸の *Density* は、各ウィンドウにおける *Ratio\_fixed* の出現頻度を正規化した確率密度を表す。

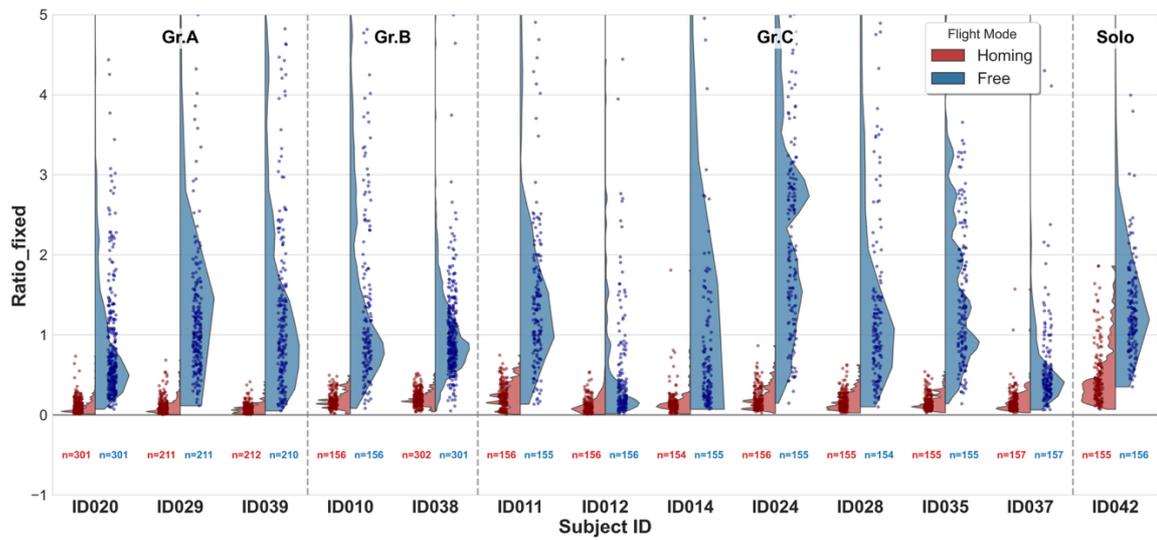


図 23：各個体における *Ratio\_fixed* の分布（バイオリンプロット）。横軸は解析対象の 13 個体の ID、縦軸の *Ratio\_fixed* は羽ばたき基本周波数帯域（5.0-9.0[Hz]）の最大パワーとその 2 倍の帯域（10.0-18.0[Hz]）における最大パワーの比を表す。赤色は帰巢飛行（Homing）、青色は（Free）の各データ分布を表す。グラフ下部に記載された数値（*n*）は各個体の各クラスにおける解析可能なウィンドウ数を示している。バイオリンの形状は各値の確率密度を可視化している。

### 5.1.2 左右軸方向の角速度の周期と周期性 (*period\_Gy, periodic\_Gy*)

本節では、角速度 $G_y$ の自己相関関数から得られた周期 $period\_Gy$ および周期性の強さ $periodic\_Gy$ について述べる。 $G_y$ の信号は、羽ばたきに伴う胴体のピッチング運動の挙動を直接的に反映しているため、 $G_y$ の周期と周期性は、それぞれ羽ばたきのテンポおよび羽ばたきの安定性を定量化する指標である。まず、全13個体における $period\_Gy$ ,  $periodic\_Gy$ の分布を重ね合わせた密度分布を図24, 図25に示す。

まず、全体的な傾向として、帰巢飛行は自由飛行と比較して高い周期性を示しており、また、羽ばたき周波数の分布が狭い範囲に収まっている。このことから、帰巢飛行では正確なリズムで羽ばたいていることがわかる。一方で、自由飛行においては、全体的に周期性が低下しており、また、一部の窓において羽ばたきの基本周波数の約2倍に相当する帯域に小さなピークが認められる。これは、自由飛行の特定の窓において、アップストロークによるピッチング運動が大きくなったことが $G_y$ に反映され、一回の羽ばたきサイクルに2つのピークを持つようになったことが理由として考えられる。この結果と前節における $Ratio\_fixed$ の分布から、自由飛行ではアップストロークにおいて、より大きく羽ばたいている場面があることを示唆している。

また、各個体の分布を図26に示す。周期性において、帰巢飛行時の分布にグループ内の類似性が見られる。このことは、同じ群れで飛行する個体はその時のイベントや環境に同じ適応を行っていたことを示唆している。また、羽ばたき周波数において、多くの個体において、本来の羽ばたき帯域の2倍付近に、小さなピークや広がりが見られる。全体の分布でも見られた倍周期の発生が個体レベルにおいても明確に裏付けられた結果である。また、周波数のピーク位置や分布の形状を個体間で比較してみると、同グループ内（特にグループC）で羽ばたきのテンポが異なっていることが確認される。先行研究[2]によれば、ハトの群れの中で前方に他個体がいる場合、羽ばたき周波数が増加するということが示されている。同一グループ内において、個体ごとに羽ばたき周波数が異なるのは、群れの中での相対的な飛行位置が関係している可能性がある。

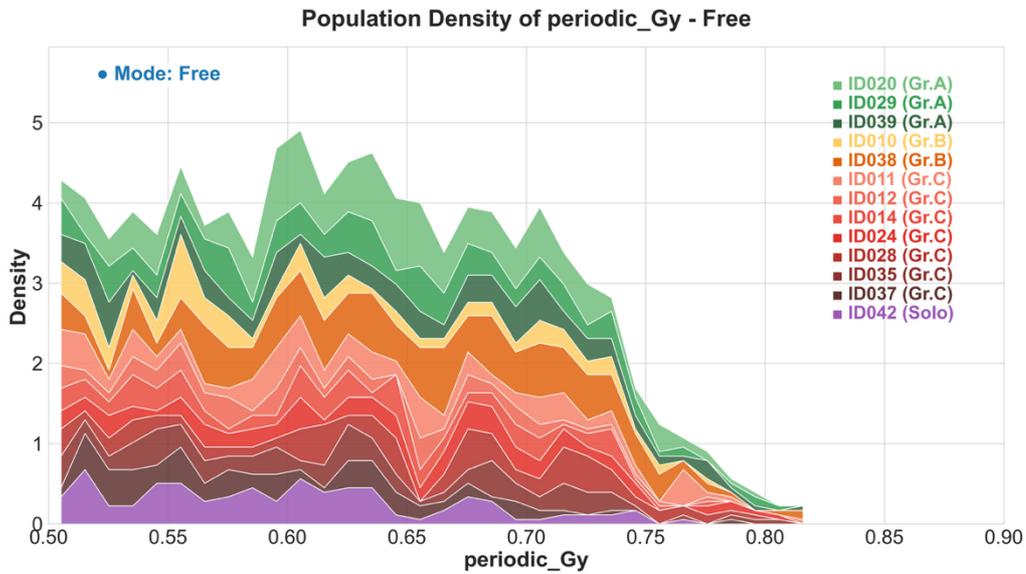
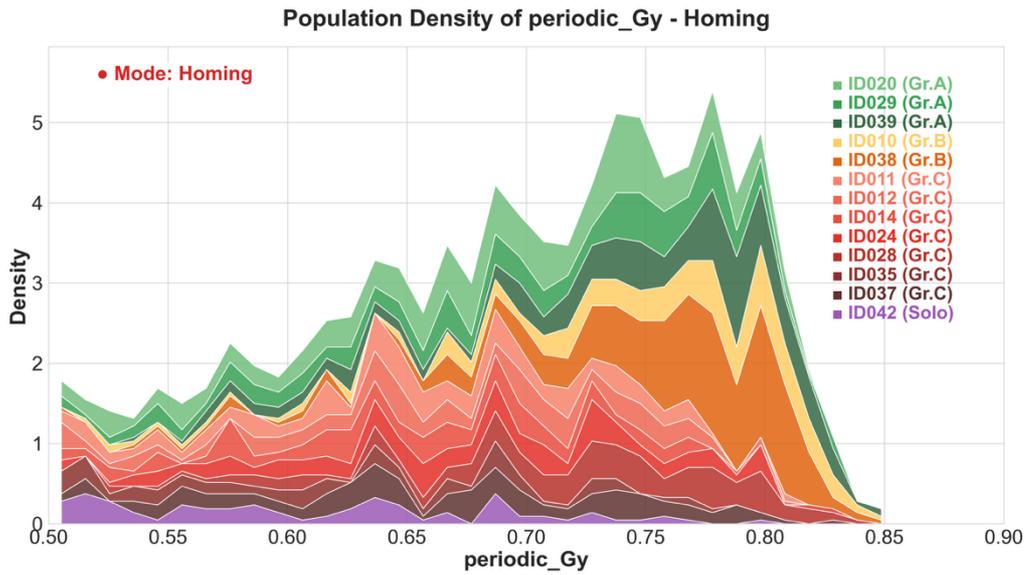


図 24：全個体における *periodic\_Gy* の積層密度分布。上のグラフが帰巢飛行、下のグラフが自由飛行に対応する。横軸の *periodic\_Gy* は Gy の周期性、縦軸の *Density* は、各ウィンドウにおける *periodic\_Gy* の出現頻度を正規化した確率密度を表す。

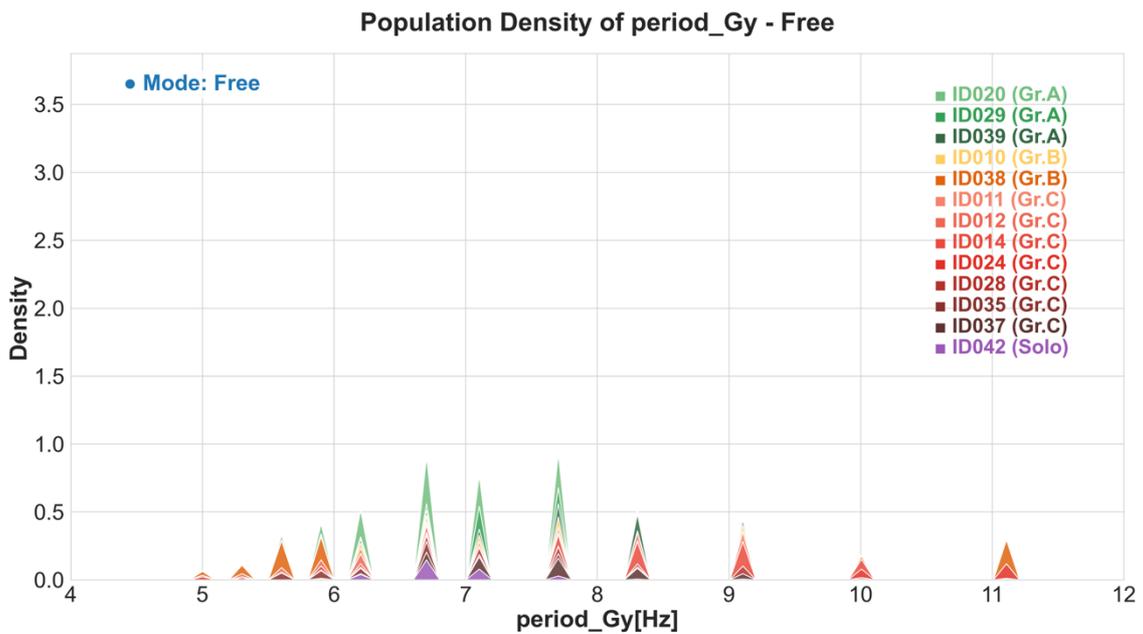
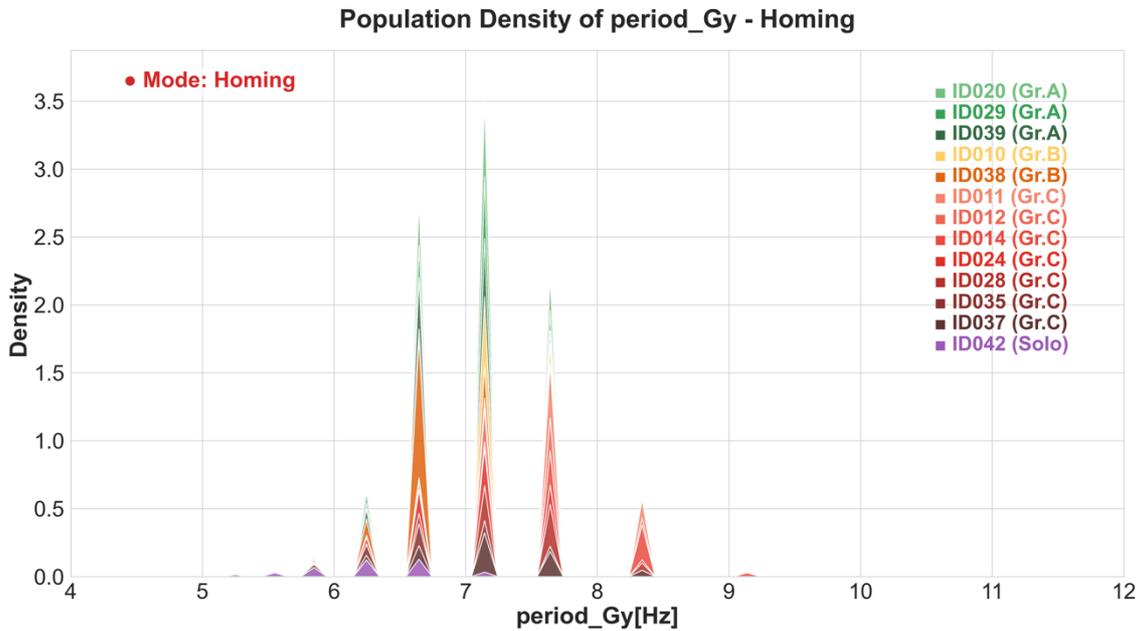


図 25：全個体における  $period\_Gy$  の積層密度分布。上のグラフが帰巢飛行、下のグラフが自由飛行に対応する。。横軸の  $period\_Gy$  は Gy の周期、縦軸の  $Density$  は、各ウィンドウにおける  $period\_Gy$  の出現頻度を正規化した確率密度を表す。

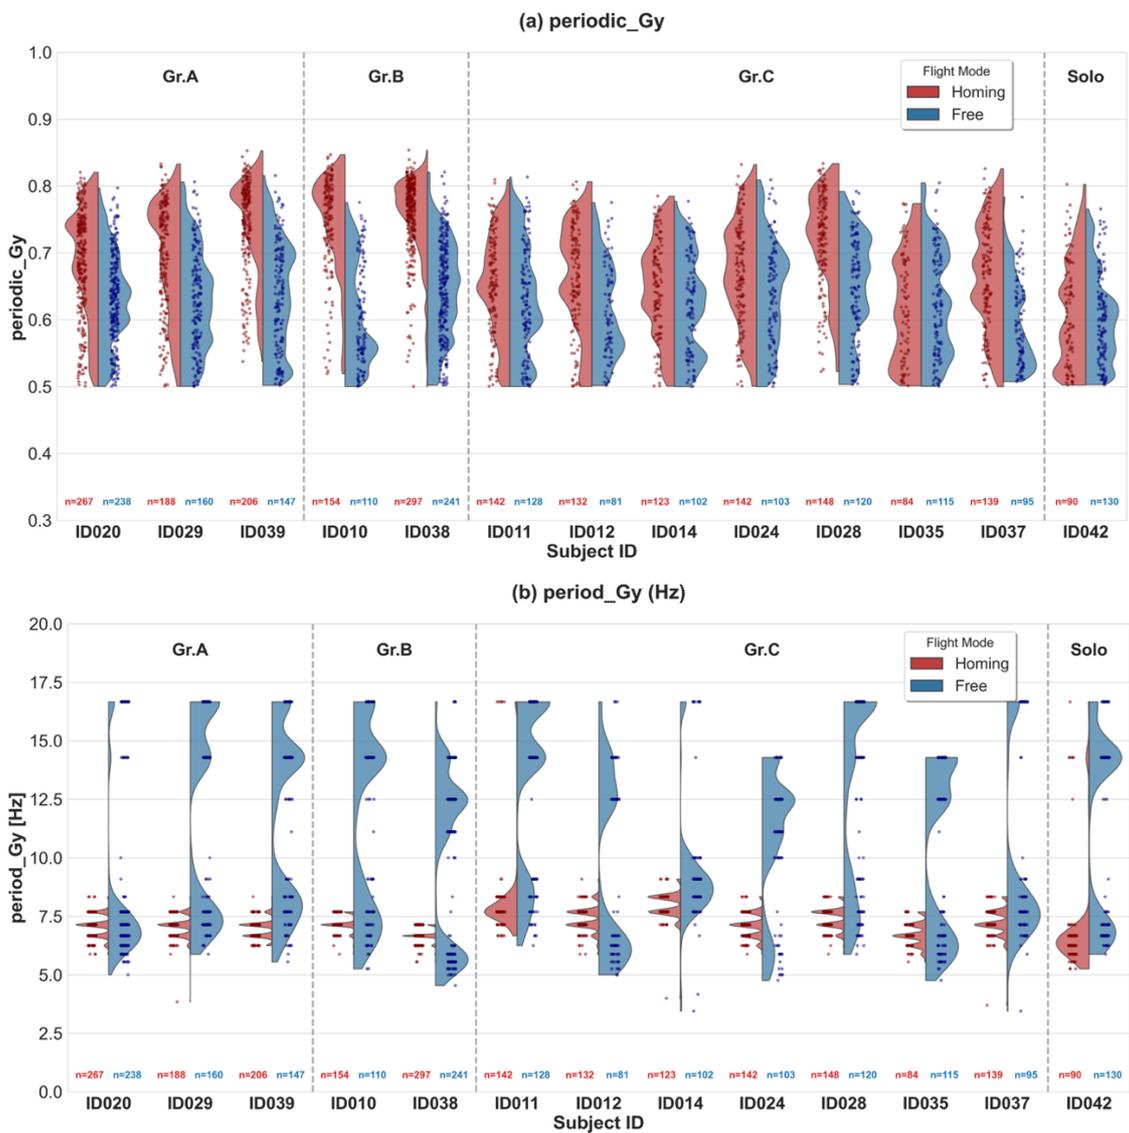


図 26：各個体における (a) *periodic\_Gy* , (b) *period\_Gy* の分布 (バイオリンプロット)。横軸は解析対象の 13 個体の ID、縦軸は (a)*periodic\_Gy* , (b)*period\_Gy* を表す。赤色は帰巢飛行 (Homing)、青色は (Free) の各データ分布を表す。グラフ下部に記載された数値 (*n*) は各個体の各クラスにおける解析可能なウィンドウ数を示している。バイオリンの形状は各値の確率密度を可視化している。

## 5.2 姿勢制御関連の特徴量

### 5.2.1 左右軸回りの角速度の分布の歪度 (*skew\_Gy*)

本節では、 $G_y$  の歪度について述べる。 $G_y$  の歪度は羽ばたきにおけるピッチ角の運動の対称性を表すため、ダウンストロークとアップストロークの運動の大きさのバランスを評価することができる。まず、全個体における  $G_y$  の分布を重ね合わせた密度分布を図 27 に示す。全体的な傾向として、帰巢飛行の分布は-0.5~0.0 付近にピークを示しており、歪度がわずかに負の方向に寄っている。この事実は、 $G_y$  の分布が負の方向に長い裾野があることを意味しており、運動の動的な非対称性を端的に示している。具体的には、負の側で  $G_y$  に急激な変化があり、このことは、帰巢飛行における羽ばたきの一周期中で、ダウンストロークの反動によるピッチ角の負の方向への変化が、アップストロークの反動によるピッチ角の正の方向への変化より急峻である、つまりダウンストロークにかかる時間がアップストロークにかかる時間より短いという可能性を示唆している。一方、自由飛行では帰巢飛行と比較して、分布が正の方向に位置している。このことは、帰巢飛行と比較して、アップストロークの反動による角速度の正の方向への変化がより急峻であることを示唆している。以上の結果は、帰巢飛行ではダウンストローク主体の羽ばたき運動であるのに対し、自由飛行はアップストロークも活用した羽ばたき運動であることを示唆しており、*Ratio\_fixed* の解析結果とも一致している。

また、各個体の分布を図 28 に示す。この結果を見ると、全個体の統計傾向とは異なる、個体間の差異が明らかとなった。まず、基本的に多くの個体において自由飛行の方が歪度の分布が広く、その絶対値も大きくなる傾向にある。これは機動に伴いピッチ角の動きによってアップストロークを能動的に調整している結果であると考えられる。しかし、*Ratio\_fixed* の結果と照らし合わせると、興味深い乖離が確認された。例えば、ID024 や ID035 は *Ratio\_fixed* の分布において自由飛行時のアップストロークによる加速の寄与が大きいことが確認できるが、それにもかかわらず、これらの個体は自由飛行時であっても  $G_y$  の歪度が比較的低い値に留まっている窓が多くある。このことはこれらの個体がアップストロークとダウンストロークの切り替えにおいて比較的対称性の高い機首（ピッチ角）の回転を行っていることを示している。また、帰巢飛行時において、歪度が比較的 0 に近い、あるいは正の値を記録している個体が複数確認できる (ID035, ID037, ID042)。ID035 は群れの先頭を飛行した個体、ID042 は単独で飛行した個体である。この結果から、前方に他の個体がない場合、ダウンストロークがより緩やかになる可能性が考えられる。先行研究 [2] によれば、

加速に必要な力が大きくなれば羽ばたきの大きさも増大することが確認されている。単独での飛行および群れの先頭を飛行する場合、他の個体が生み出した気流などによる加速の要求が比較的小さいことなどが関係している可能性が考えられる。

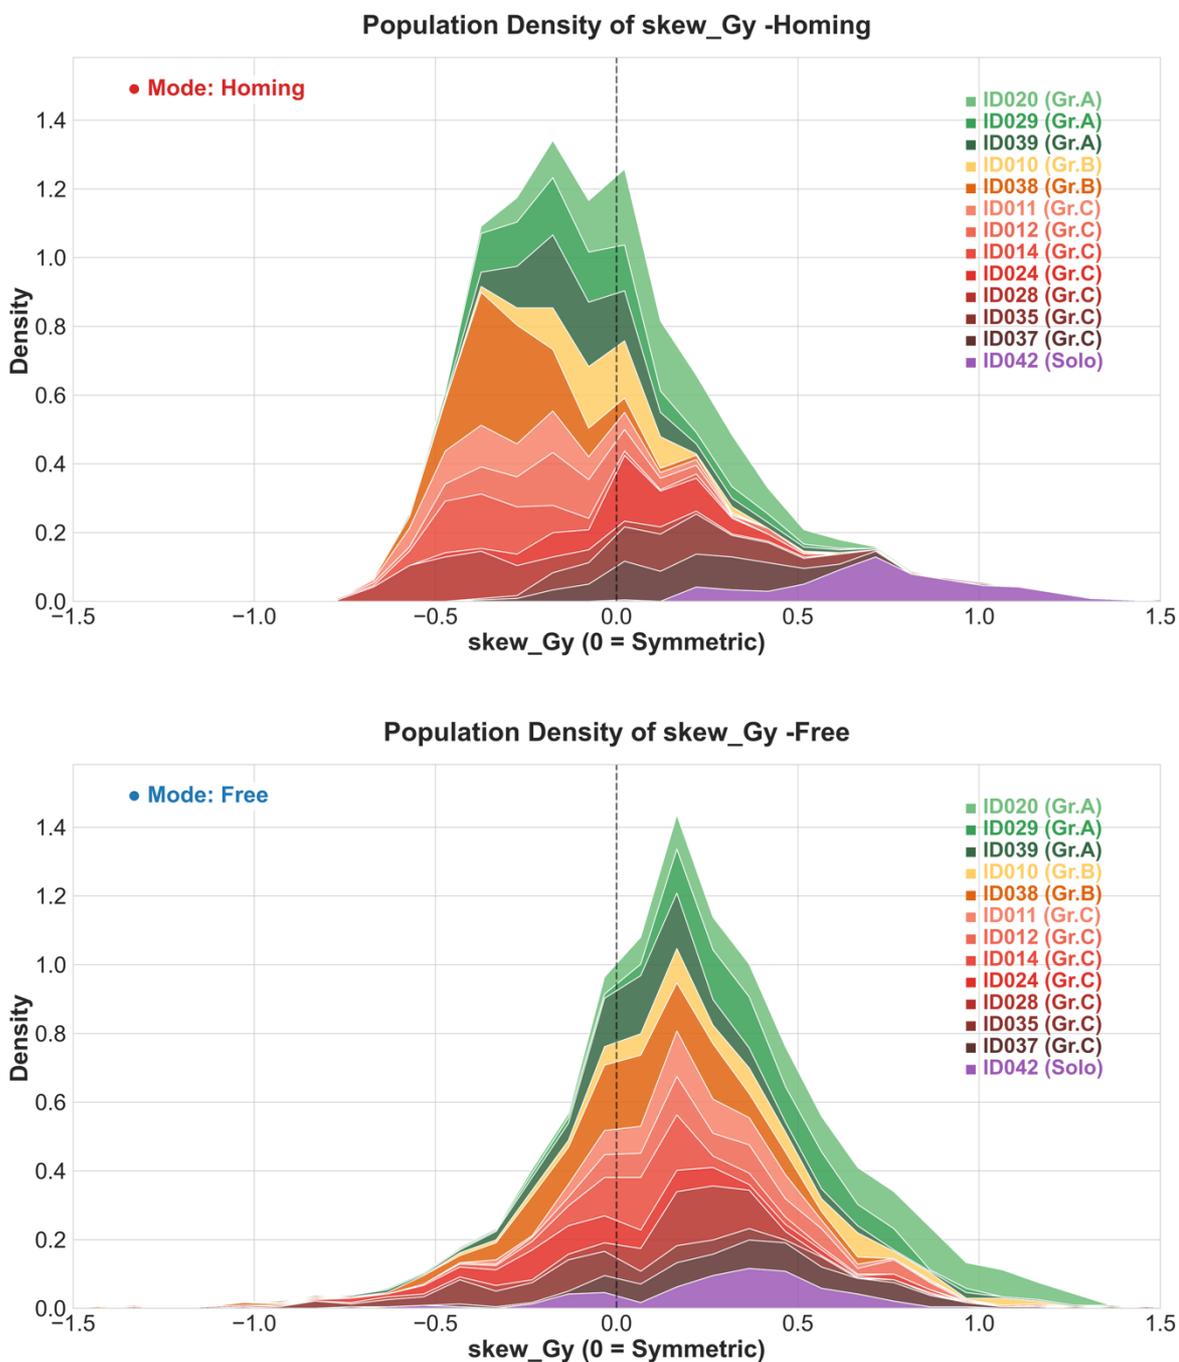


図 27：全個体における  $skew\_Gy$  の積層密度分布。上のグラフが帰巢飛行、下のグラフが自由飛行に対応する。横軸は  $skew\_Gy$ 、縦軸の  $Density$  は、各ウィンドウにおける  $skew\_Gy$  の出現頻度を正規化した確率密度を表す。

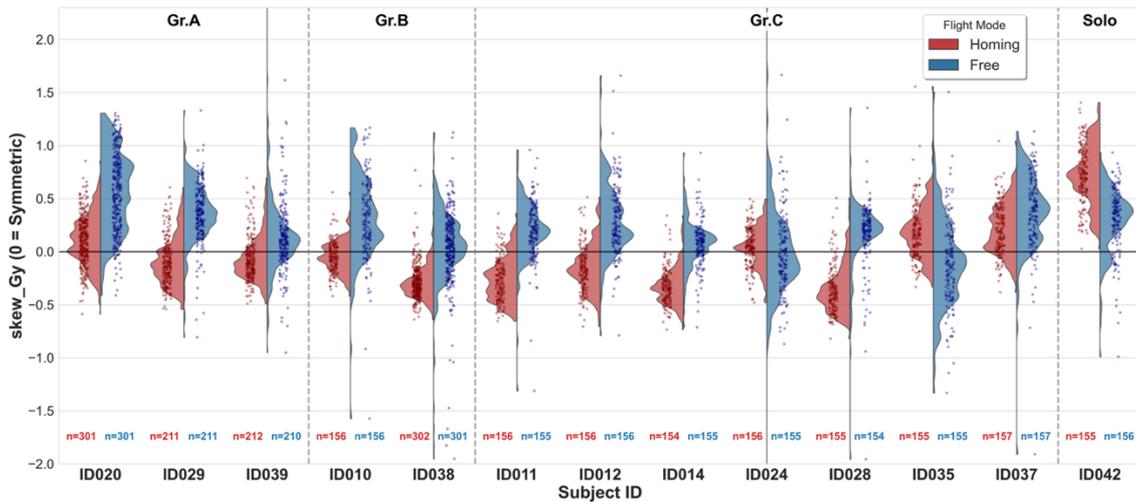


図 28：各個体における  $skew\_Gy$  の分布（バイオリンプロット）。横軸は解析対象の 13 個体の ID、縦軸は  $skew\_Gy$  を表す。赤色は帰巢飛行（Homing）、青色は（Free）の各データ分布を表す。グラフ下部に記載された数値（ $n$ ）は各個体の各クラスにおける解析可能なウィンドウ数を示している。バイオリンの形状は各値の確率密度を可視化している。

## 5.3 運動の対称性関連の特徴量

### 5.3.1 前後方向の加速度の分布の歪度 ( $skew_{Ax}$ )

本節では  $skew_{Ax}$  について述べる。 $A_x$  の歪度はハトが羽ばたきによって生成する推進力の形状を表している。まず、全個体における  $A_x$  の歪度の分布を重ね合わせた密度分布を図 29 に示す。全体的な傾向として、帰巢飛行の分布は-0.6~-0.3 付近にピークを示している。歪度が負の方向に寄っている事実は、 $A_x$  の分布の負の方向に長い裾野があることを意味しており、前後方向の加速の非対称性を端的に示している。具体的には、負の側（アップストロークへの移行時）で  $A_x$  に急激な変化があり、このことは、帰巢飛行時における羽ばたき一周期の中で、ダウンストロークによる正の方向への加速が一定時間持続し安定的であるのに対し、その後の切り替えに伴う負の方向への変化がより急峻であることを示唆している。一方、自由飛行の分布はピークが 0 付近に位置している。このことは、 $A_x$  の加速の分布が左右対称であることを示しており、ダウンストロークによる加速に加えて、アップストロークによる加速が発生している可能性を示唆している。

また、各個体の分布を図 30 に示す。この結果を見ると、帰巢飛行時における  $skew_{Ax}$  はほとんどの個体で全体の分布に近い形状を示しているが、ID035（群れの先頭）、ID037、ID042（単独）の 3 個体については、帰巢飛行時であっても値が 0 付近、あるいは明確に正の領域に分布しており、他個体の分布形状と異なっている。これらの個体は、 $G_y$  の歪度の分布において、他の個体とは異なる形状を示した個体である。単独飛行を行った ID042 に関しては、これが前章で述べた機械学習モデルの分類精度低下を招いた物理的要因である可能性が考えられる。前節の周波数領域の特徴量の解析において、全個体が帰巢飛行時にダウンストロークでの加速を主体としていることが確認されていたため、アップストロークで加速をしたことによる分布形状の変化が発生したのではないと考えられる。さらに、 $G_y$  の歪度の解析において、先頭飛行および単独飛行ではダウンストロークが緩やかであることが示唆された。つまり、先頭を飛行する ID035 や単独飛行の ID042 においては、ダウンストロークによる加速自体の性質が、群れの中で飛行する他の個体と物理的に異なっているということである。

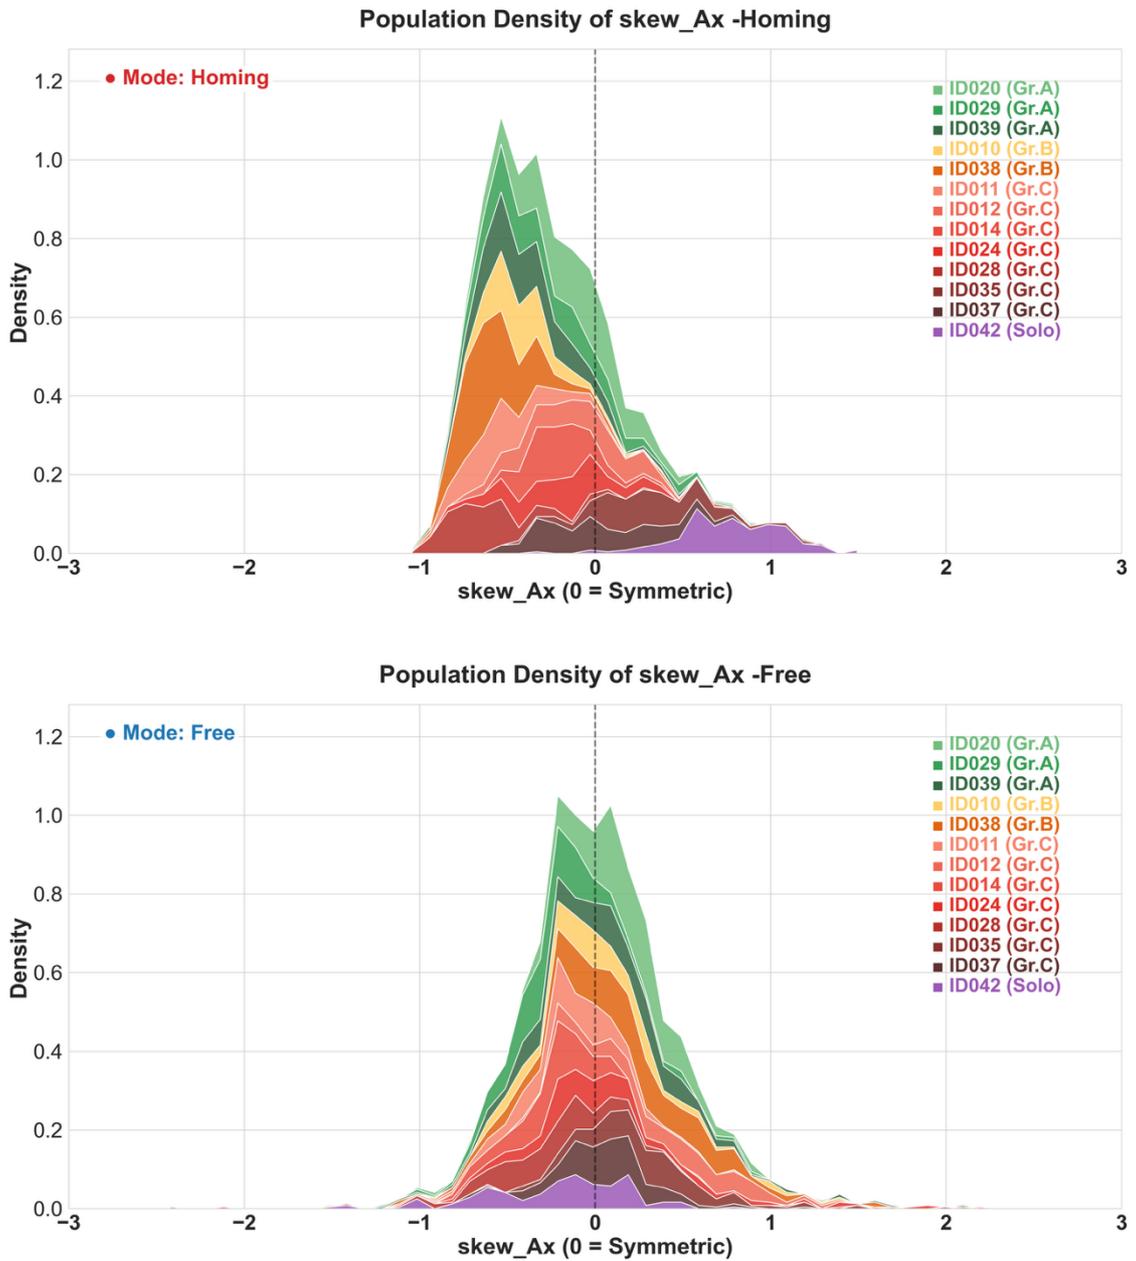


図 29: 全個体における  $skew\_Ax$  の積層密度分布。上が帰巢飛行のグラフ、下が自由飛行のグラフに対応する。横軸は  $skew\_Ax$ 、縦軸の  $Density$  は、各ウィンドウにおける  $skew\_Ax$  の出現頻度を正規化した確率密度を表す。

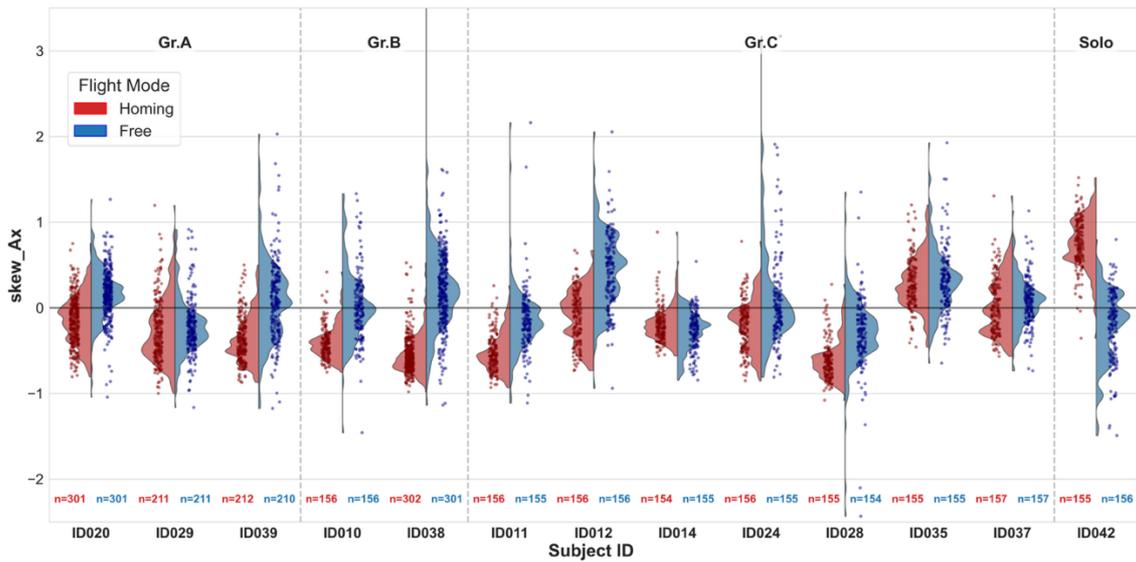


図 30：各個体における  $skew\_Ax$  の分布（バイオリンプロット）。横軸は解析対象の 13 個体の ID、縦軸は  $skew\_Ax$  を表す。赤色は帰巣飛行（Homing）、青色は（Free）の各データ分布を表す。グラフ下部に記載された数値（ $n$ ）は各個体の各クラスにおける解析可能なウィンドウ数を示している。バイオリンの形状は各値の確率密度を可視化している。

### 5.3.2 上下方向の加速度の分布の歪度 (*skew\_Az*)

本節では *skew\_Az* について述べる。 $A_z$  の歪度は羽ばたきによる揚力の形状を表している。まず、全個体における  $A_z$  の歪度の分布を重ね合わせた密度分布を図 31 に示す。全体的な傾向として、帰巢飛行の分布は-0.8 付近に非常に鋭いピークを示しており、歪度が大きく負の方向に寄っている。この事実は、 $A_z$  の分布が負の方向に長い裾野があることを意味しており、上下方向の運動の非対称性を端的に示している。具体的には、負の側（ダウンストロークによる身体の上昇時）で  $A_z$  に急峻な変化があり、このことは、帰巢飛行時における羽ばたき一周期の中で、強いダウンストロークによって身体が急峻に押し上げられる一方、それ以外のフェーズにおける上下方向の変化が相対的に緩やかであることを示唆している。一方、自由飛行の分布において、帰巢飛行と比較すると分布がやや正の方向へシフトしている。このことから、自由飛行ではダウンストロークによる急峻な身体の上昇に加えて、アップストロークによる身体の変位が減少し、上下方向の運動の対称性が高まっている可能性を示唆している。以上の結果から、帰巢飛行においては、ダウンストロークの羽ばたきがアップストロークの羽ばたきよりも大きく、自由飛行においては、帰巢飛行に比べてアップストロークが大きくなっている可能性が示唆されており、これは、*Ratio\_fixed* の解析結果と一致している。

また、各個体の分布を図 32 に示す。この結果を見ると、すべての個体において、帰巢飛行時の分布が負の値で鋭いピークを示している。このことから、羽ばたきによる身体の上方向の加速度変化の個体差が比較的小さく、ハトの帰巢飛行における一般的な特徴と言える。

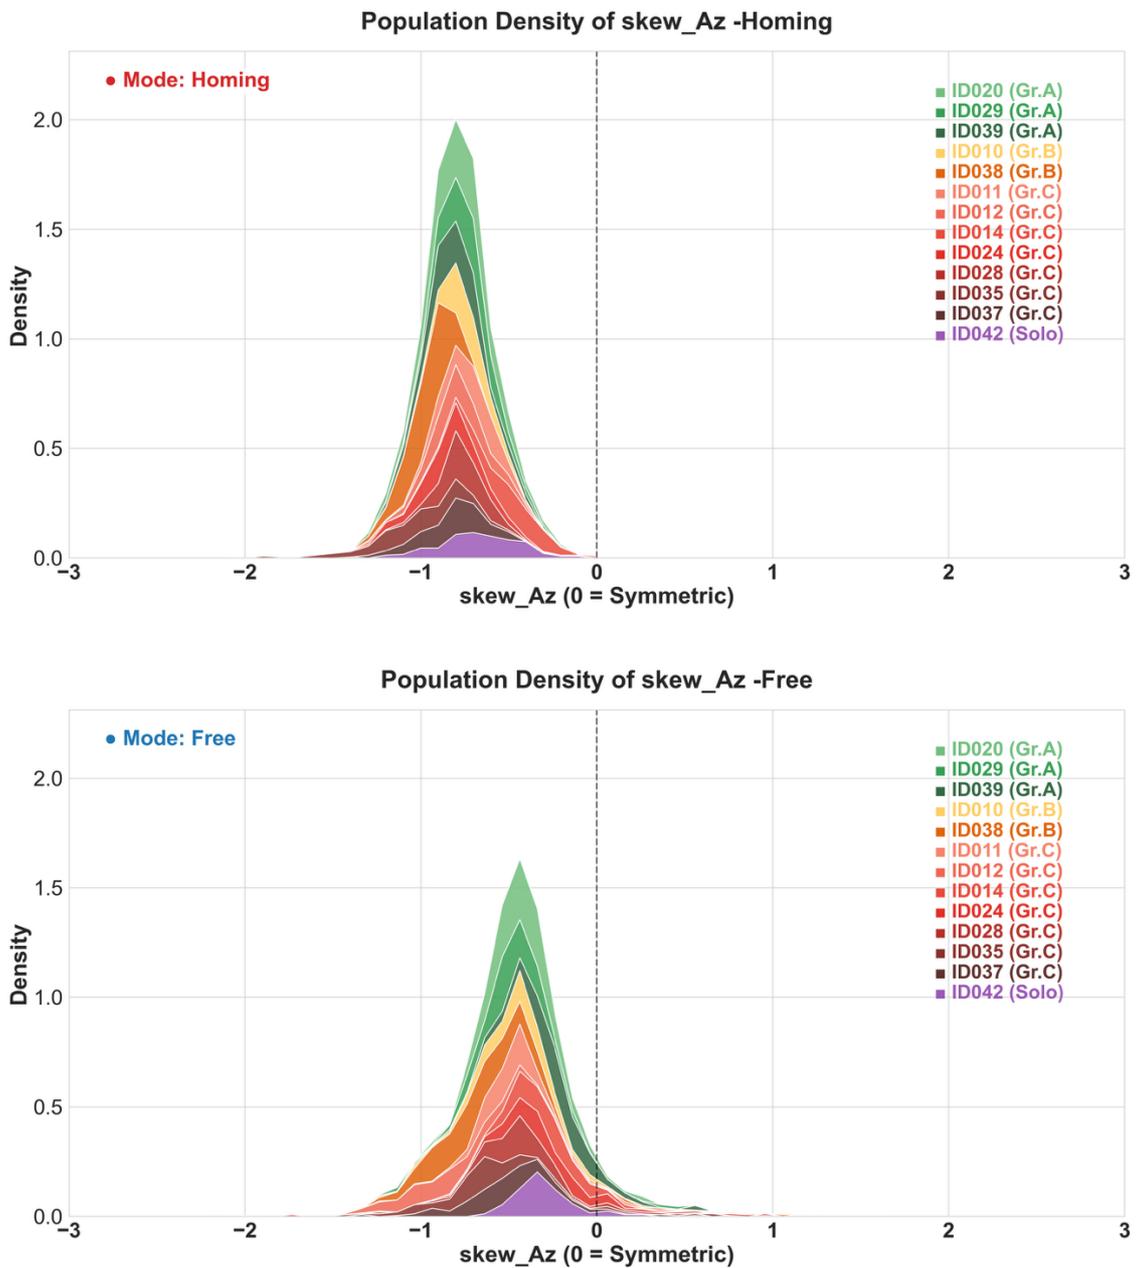


図 31：全個体における  $skew\_Az$  の積層密度分布。上が帰巢飛行のグラフ、下が自由飛行のグラフに対応する。横軸は $skew\_Az$ 、縦軸の  $Density$  は、各ウィンドウにおける  $skew\_Az$  の出現頻度を正規化した確率密度を表す。

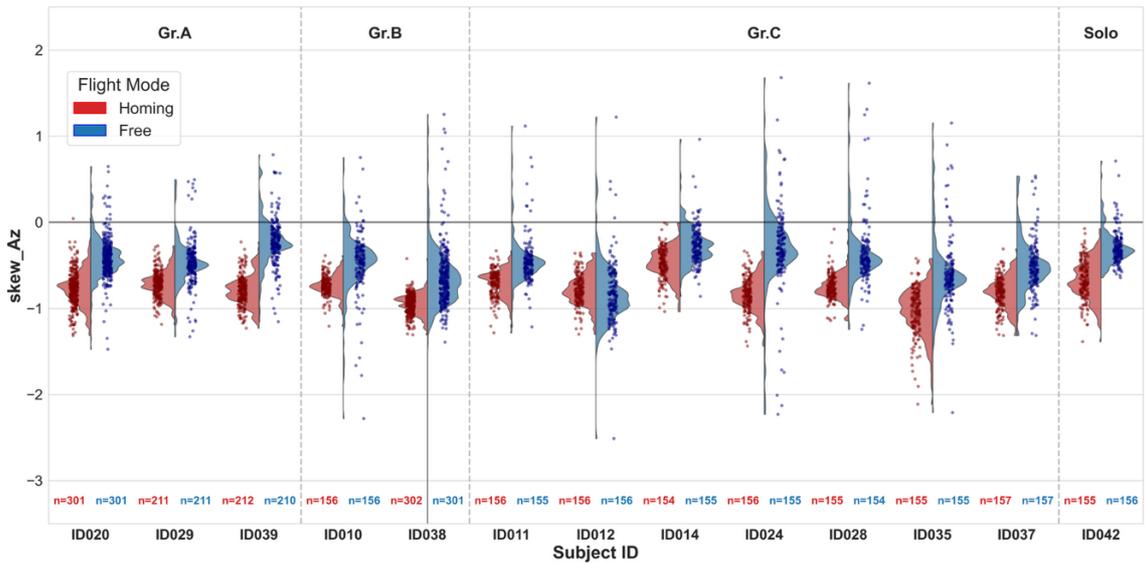


図 32：各個体における  $skew_{Az}$  の分布（バイオリンプロット）。横軸は解析対象の 13 個体の ID、縦軸は  $skew_{Az}$  を表す。赤色は帰巢飛行（Homing）、青色は（Free）の各データ分布を表す。グラフ下部に記載された数値（ $n$ ）は各個体の各クラスにおける解析可能なウィンドウ数を示している。バイオリンの形状は各値の確率密度を可視化している。

## 5.4 運動の強度関連の特徴量

### 5.4.1 前後方向の加速度の最大値と上下方向の加速度の最小値 ( $Max\_Ax$ , $Min\_Az$ )

図 33 と図 34 にそれぞれ  $Max\_Ax$  の積層密度分布と各個体の分布を示す。積層密度分布を見ると、帰巢飛行時における  $Max\_Ax$  は概ね  $5\sim 15[m/s^2]$  の範囲に鋭くピークを持ち、個体内のばらつきが小さい。これは、長距離の移動において一定の出力でダウンストロークを繰り返す飛行状態を反映していると考えられる。一方、各個体の分布を見ると、自由飛行時では、最大値が  $30[m/s^2]$  を超える窓があり、分布の裾野が広がっている。これは、自由飛行において急加速や旋回などの高出力な運動が発生していることを示唆している。5.3.1 節で述べた  $skew\_Ax$  の負の裾野は、この  $Max\_Ax$  の分布からも裏付けられる。帰巢飛行において、 $Max\_Ax$  が低値で安定していることは、ダウンストロークによる加速が突出することなく持続的であることを意味しており、それが分布の正の側の密集、つまり負の歪度を形成する要因となっている。

また、図 35 と図 36 に  $Min\_Az$  の積層密度分布と各個体の分布を示す。積層密度分布を見ると、 $-30[m/s^2]$  付近に集中的な分布を持っている。これは、一周ごとくに身体を一定高度まで押し上げるための安定した力をダウンストロークで生成し続けていることを示唆している。一方、自由飛行では、分布が広がっているのが確認できる。このことは、自由飛行時の様々なイベント（急加速、旋回）において、羽ばたき強度の調整が行われている可能性を示唆している。

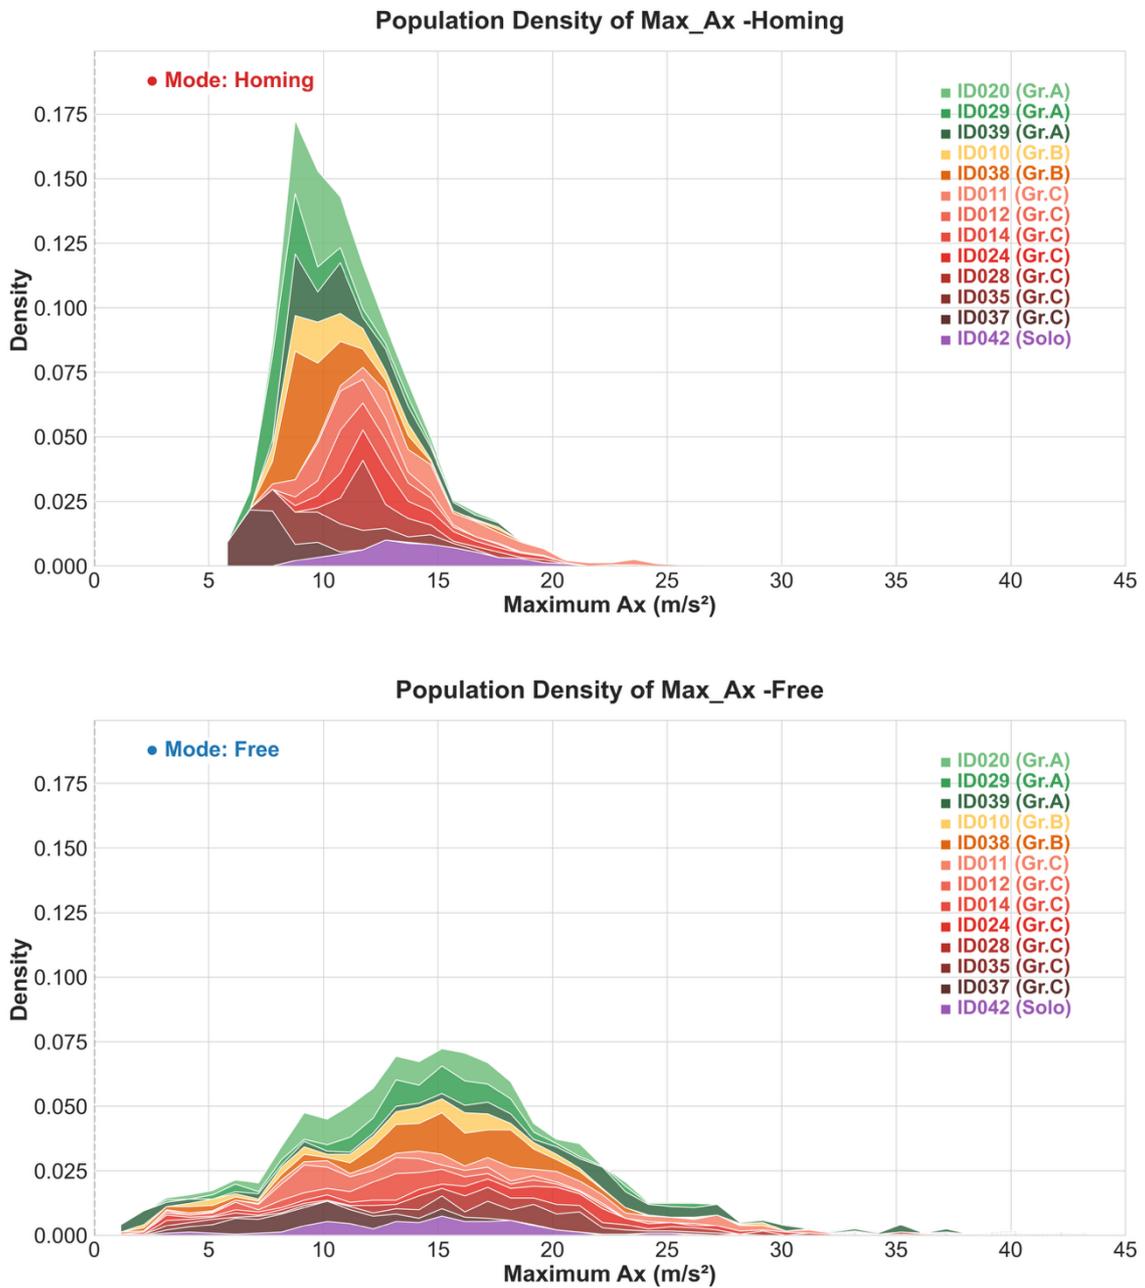


図 33：全個体における  $Max\_Ax$  の積層密度分布。上が帰巢飛行のグラフ、下が自由飛行のグラフに対応する。横軸は $Max\_Ax$ 、縦軸の  $Density$  は、各ウィンドウにおける  $Max\_Ax$  の出現頻度を正規化した確率密度を表す。

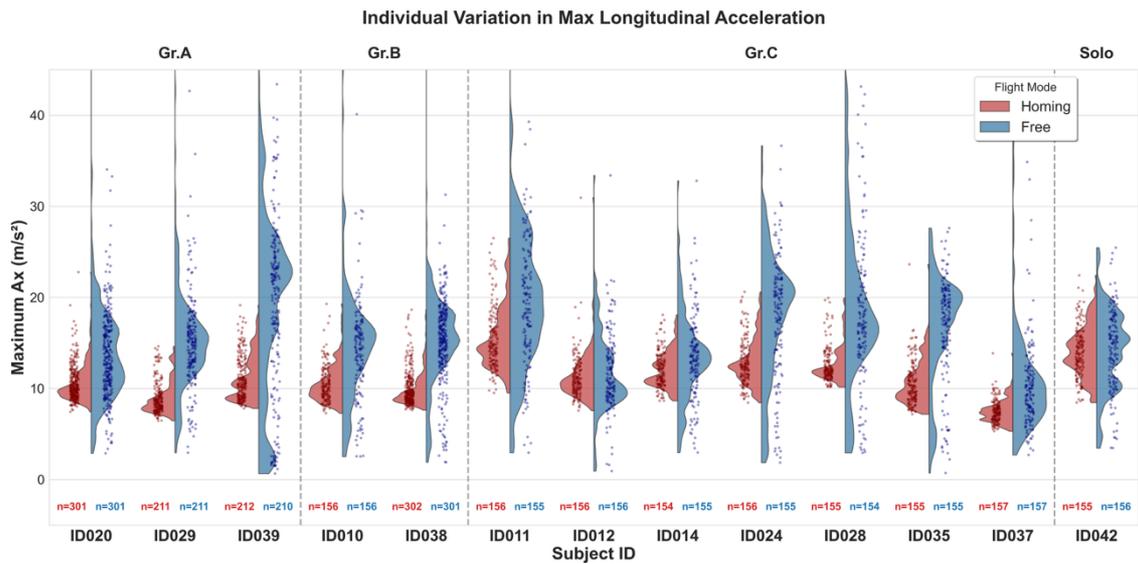


図 34：各個体における  $Max_{Ax}$  の分布（バイオリンプロット）。横軸は解析対象の 13 個体の ID、縦軸は  $Max_{Ax}$  を表す。赤色は帰巢飛行（Homing）、青色は（Free）の各データ分布を表す。グラフ下部に記載された数値（ $n$ ）は各個体の各クラスにおける解析可能なウィンドウ数を示している。バイオリンの形状は各値の確率密度を可視化している。

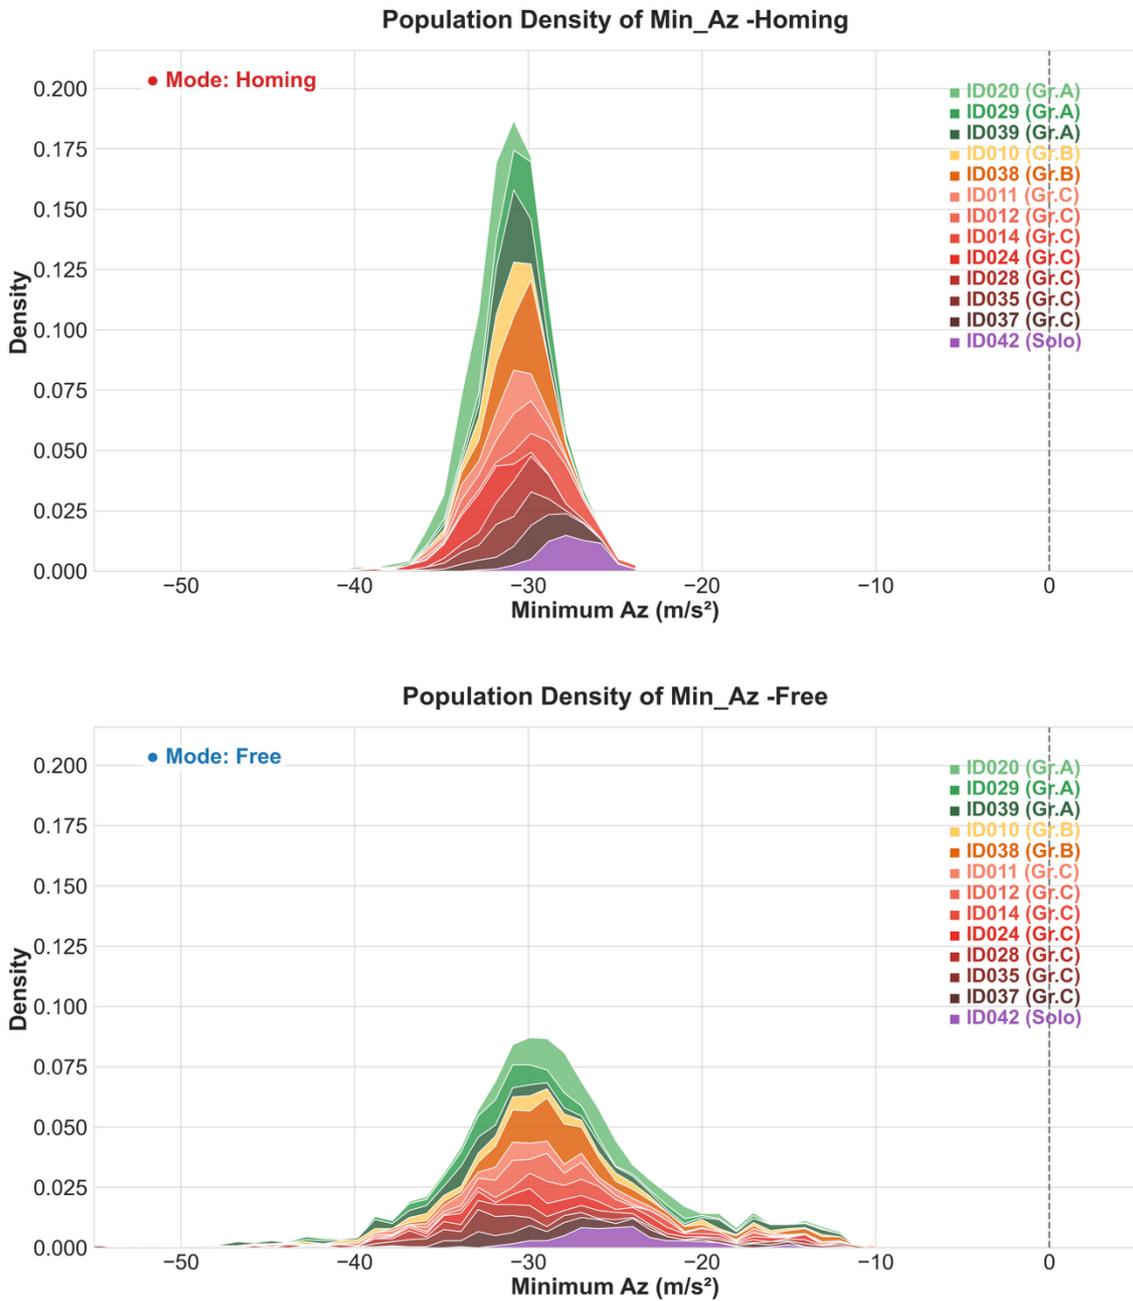


図 35：全個体における  $Min\_Az$  の積層密度分布。上が帰巢飛行のグラフ、下が自由飛行のグラフに対応する。横軸は  $Min\_Az$ 、縦軸の  $Density$  は、各ウィンドウにおける  $Min\_Az$  の出現頻度を正規化した確率密度を表す。

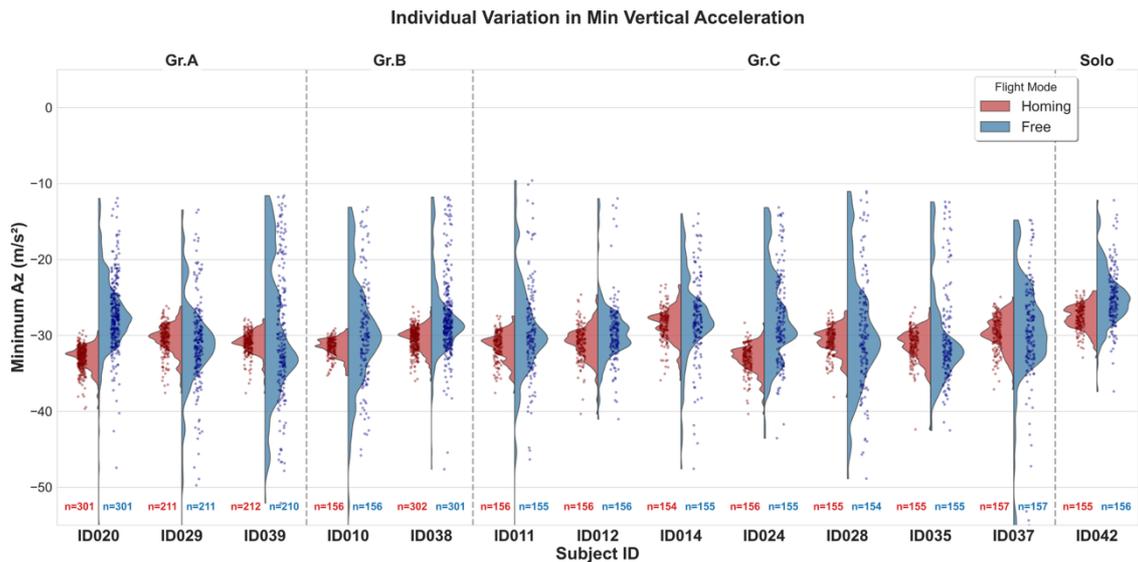


図 36：各個体における  $Min\_Az$  の分布（バイオリンプロット）。横軸は解析対象の 13 個体の ID、縦軸は  $Min\_Az$  を表す。赤色は帰巢飛行（Homing）、青色は（Free）の各データ分布を表す。グラフ下部に記載された数値（ $n$ ）は各個体の各クラスにおける解析可能なウィンドウ数を示している。バイオリンの形状は各値の確率密度を可視化している。

## 5.5 加速度平面を用いた総括的比較

本節では、慣性センサーから得られた加速度データに基づき、個体ごとの羽ばたき運動の物理的特性を加速度 ( $A_x - A_z$ ) 平面上で評価する。本解析に用いる加速度データはセンサーに内蔵された座標系から実験室系の固定座標系 GCS (Global Coordinate System) へと座標変換を行っている。この変換には、先行研究 [14] の手法を採用した。これにより、個体の装着状況に左右されない、絶対的な空間における前後方向 (AX) および鉛直方向 (AZ) の運動評価が可能となった。

各個体の加速度平面を図 37~図 39 に、図 40 に羽ばたき周期における翼の動きと加速度平面の関係の典型例を示す。これらの図から、帰巢飛行と自由飛行の間で顕著な差異が見られた。まず、帰巢飛行において、多くの個体の加速度平面で鉛直方向に鋭いピークを持ち、特に  $AZ < -10[m/s^2]$  のダウンストローク領域に集中している。このことは、帰巢飛行が重力に抗う揚力の生成を目的とした羽ばたきであることを示唆している。一方、自由飛行において、分布が前後方向 (AX) へ比較的大きく広がっている。また、 $AZ > -10[m/s^2]$  のアップストローク領域においても加速度の分散が大きくなっている。これは自由飛行において、アップストローク時にも翼の運動軌跡を調整し、前方向への加速を行っていることを示唆している。これらの結果は、前節で述べた *Ratio\_fixed* の解析結果と極めて高い整合性を示している。

*Ratio\_fixed* の値が低い帰巢飛行では、加速度平面上の軌跡が単純な縦長の構造をとるのに対して、*Ratio\_fixed* の値が高い自由飛行では、アップストロークの関与によって 1 周期の中に 2 つの加速が発生している。

また、前節の *Ratio\_fixed* の解析において、帰巢飛行時であっても高い値を示していた個体 ID042 (Solo) 加速度平面では、他の個体と異なり、帰巢飛行時においても、アップストローク領域で明確な加速度分布の張り出しが確認できる。これは ID042 が帰巢飛行時であっても、アップストロークによる加速を行っているという *Ratio\_fixed* の解析結果からの示唆を物理的に裏付けるものである。なお、モデルの互換性が確認された ID035 (群れの先頭個体) と比較すると、ID042 の帰巢飛行時の加速度分布はそれとは明らかに異なっている。この比較から、ID042 に見られた「帰巢飛行時におけるアップストロークの活用」という特徴が、単独飛行という条件に起因するものなのか、あるいは当該個体の固有性によるものなのかについては、現時点で判然としない。本研究においては、単独飛行を行う個体のデータが不足しており、飛行環境の差異が羽ばたき運動の制御に与える影響を検証することは難しい。したがってこの特異的な運動特性が単独飛行個体に共通の性質であるか否かを結論づけるには、今後更なるサンプルサイズの拡充と個体差を考慮した詳細な検証が必要である。

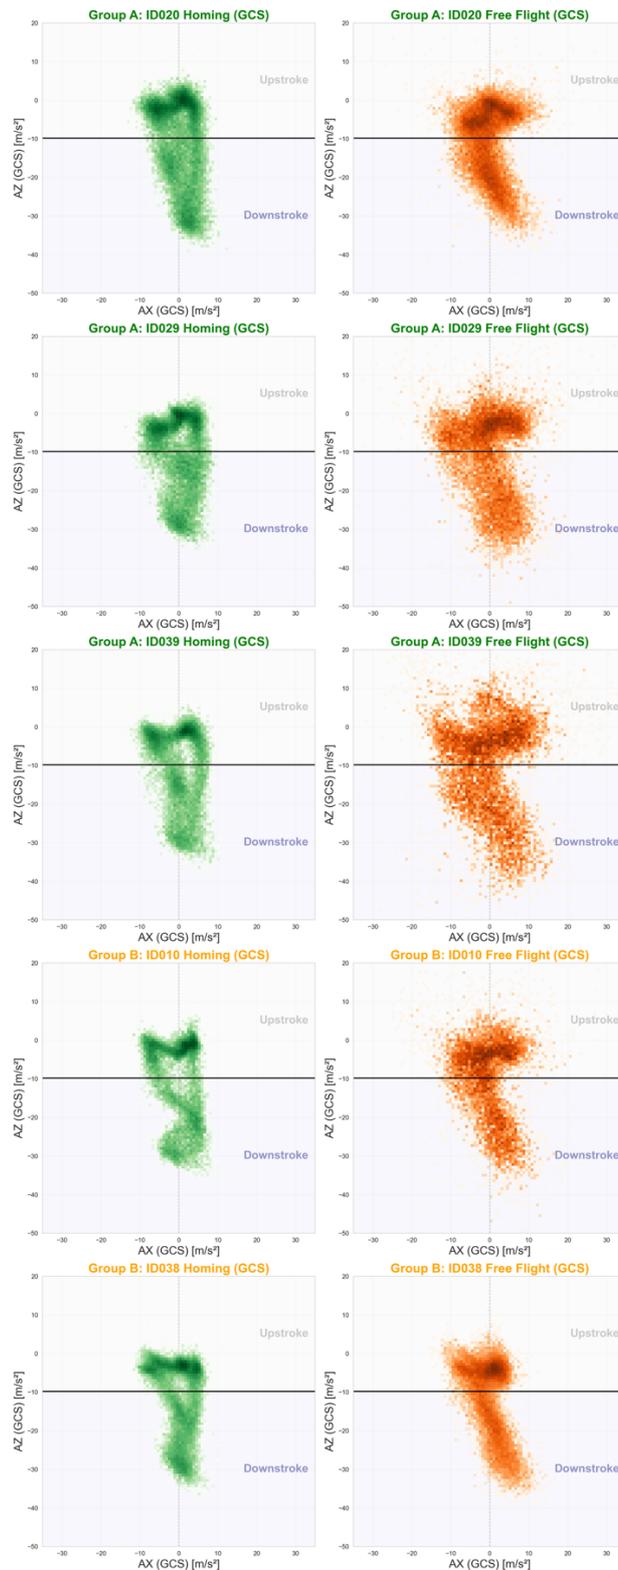


図 37：グループ A,B における各個体の加速度 (AX-AZ) 平面。横軸は AX (GCS)、縦軸は AZ (GCS)。緑色が帰巢飛行、橙色が自由飛行に対応する。黒線は重力加速度を示し、この線を境にアップストロークとダウンストロークが切り替わる。

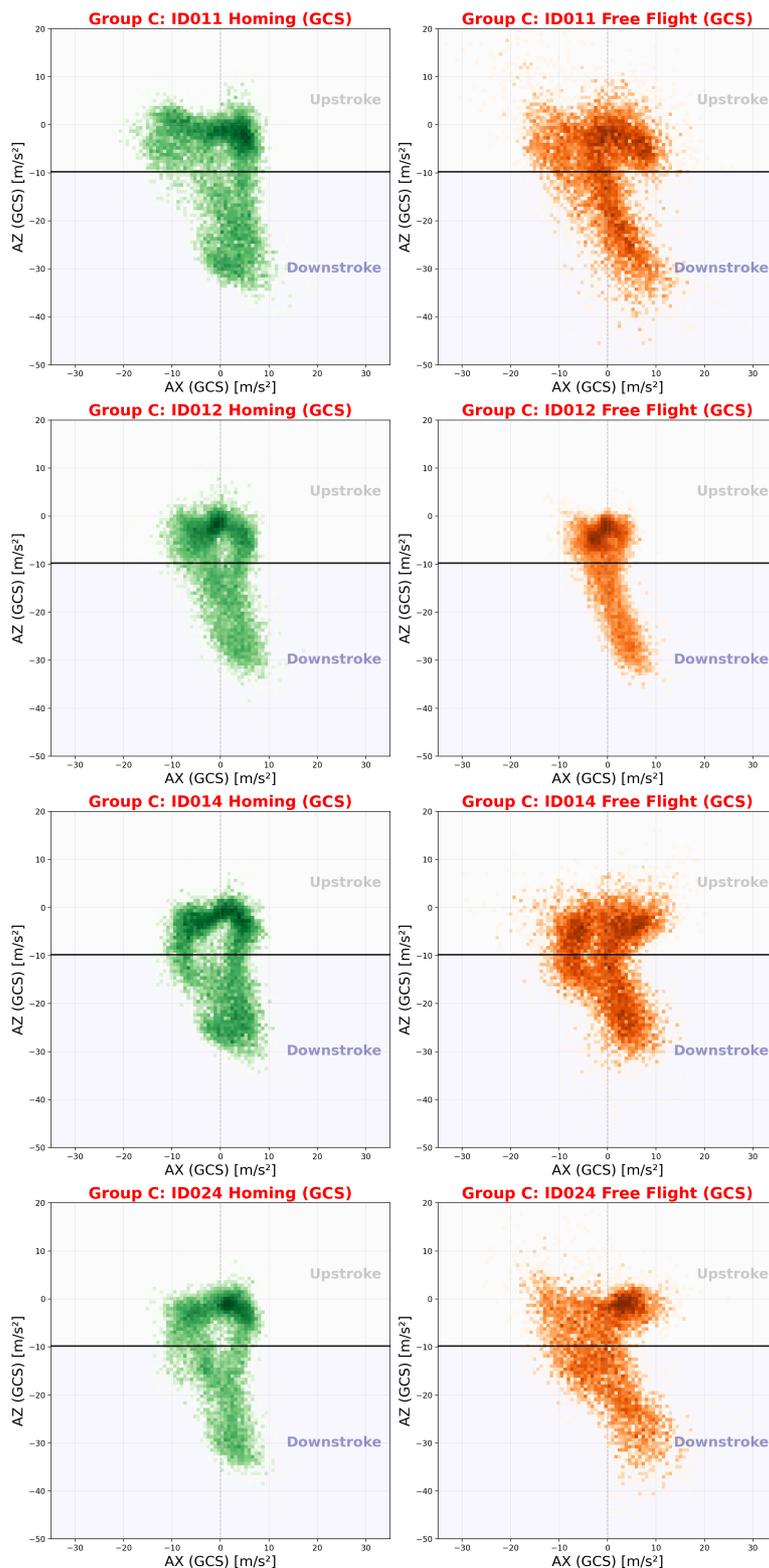


図 38：グループ C における各個体の加速度（AX—AZ）平面（5 個体分）。横軸は AX（GCS）、縦軸は AZ（GCS）。緑色が帰巢飛行、橙色が自由飛行に対応する。黒線は重力加速度を示し、この線を境にアップストロークとダウンストロークが切り替わる。

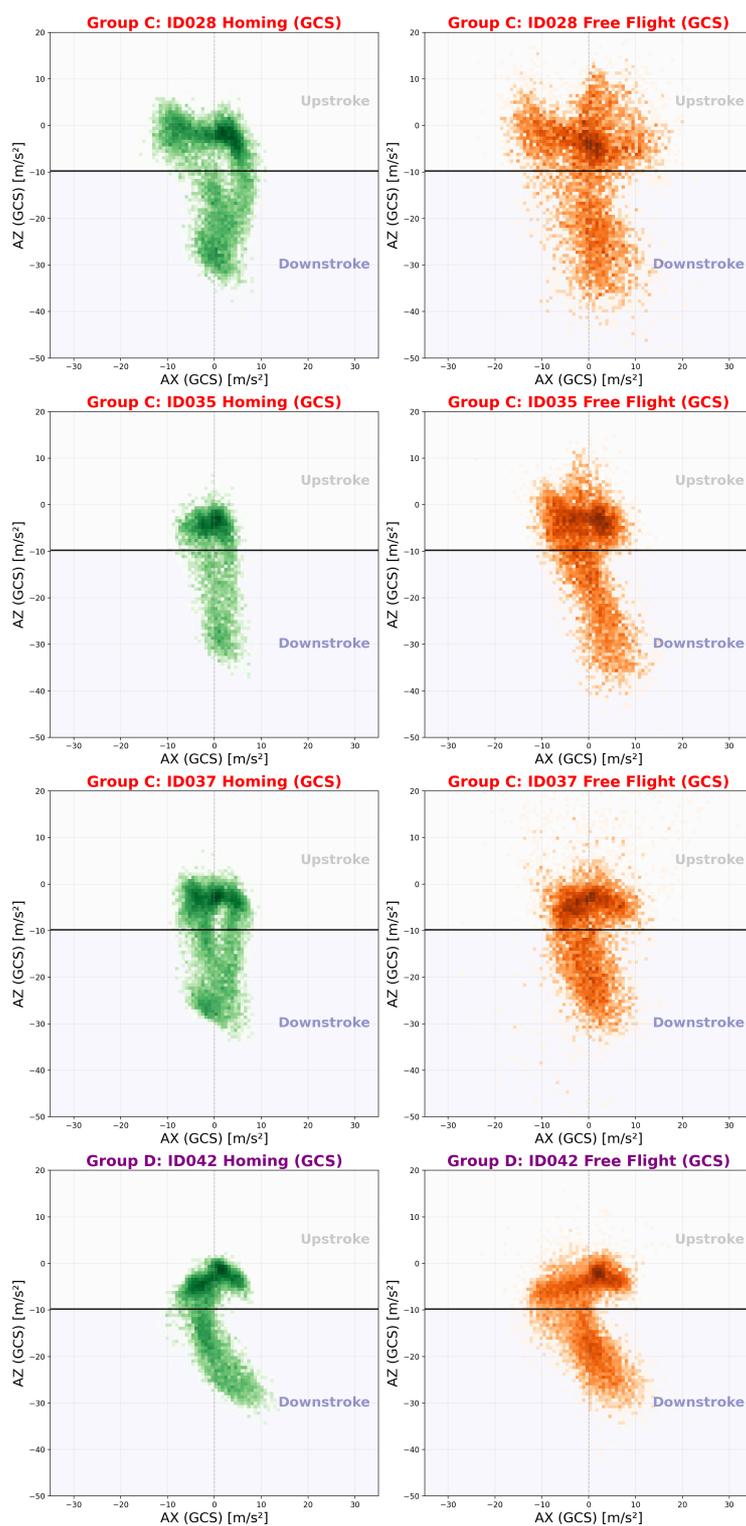


図 39：グループ C の 3 個体とグループ D（単独飛行個体）における加速度（AX—AZ）平面。横軸は AX（GCS）、縦軸は AZ（GCS）。緑色が帰巢飛行、橙色が自由飛行に対応する。黒線は重力加速度を示し、この線を境にアップストロークとダウンストロークが切り替わる。

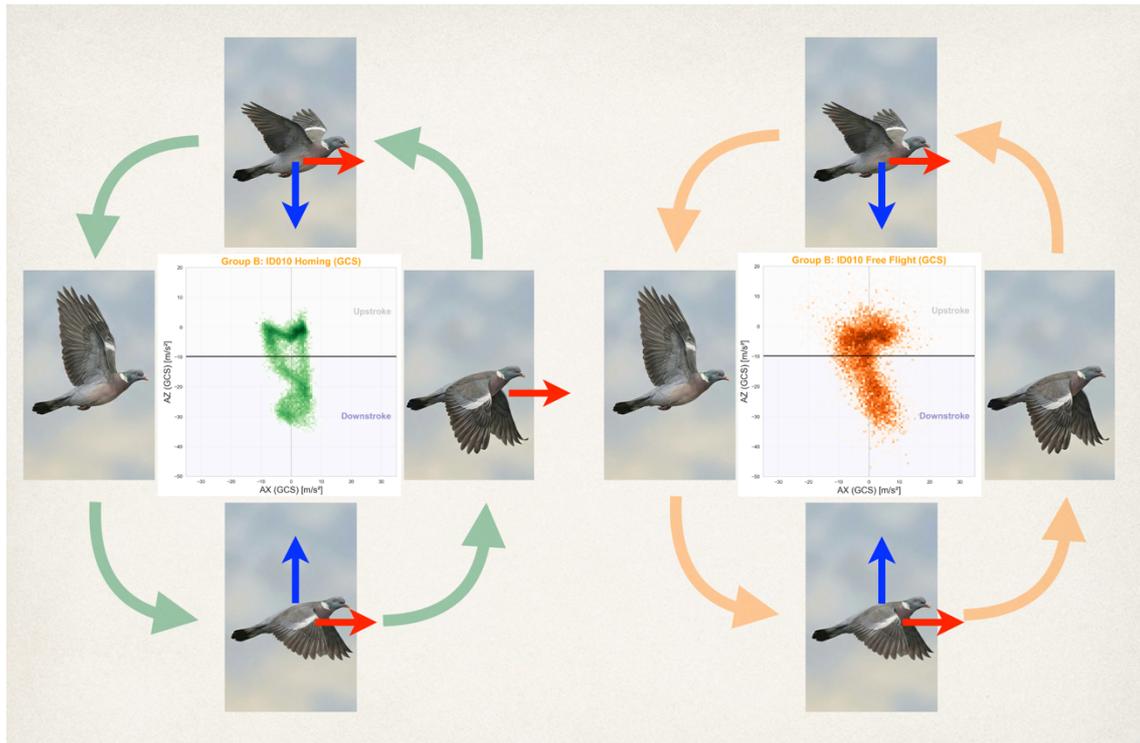


図 40：羽ばたき周期における翼の動きとそれによって生じる前後加速度および上下加速度の関係の典型例（ID010）。緑色が帰巢飛行、橙色が自由飛行に対応する。周囲のイラストは各加速度領域に対応する羽ばたきフェーズを模式的に表しており、赤矢印は進行方向、青矢印は垂直方向の加速度を表している。

## 6 結論

### 6.1 本研究の総括

本研究では、バイオリギング技術によって得られたハトの慣性センサーデータを用い、機械学習（ランダムフォレスト）と物理的解析を統合することで、ハトの帰巢飛行および自由飛行における運動学的な違いの解釈を試みた。従来の行動分類手法が欠けていたモデルの判断根拠の不透明さという課題に対して、大域的な特徴量重要度算出手法である SAGE を導入し、構築されたランダムフォレストの物理的解釈可能性を確保する解析フレームワークを設計した。

解析の結果、個体内検証において、ランダムフォレストは帰巢飛行と自由飛行を平均正解率 0.96、平均 MCC スコア 0.93 という極めて高い精度で識別することに成功した。この事実は、環境要因や個体差を超えて、ハトの飛行運動には目的に応じた明確な物理的差異が存在することを統計的に裏付けている。

さらに、SAGE によって抽出された重要特徴量をヒントに、周波数領域および時間領域での詳細な運動解析を行った結果、以下の知見が得られた。

- ・帰巢飛行の普遍的構造：帰巢飛行は、基本周波数のパワーが支配的であり、第二高調波の寄与が極めて低い、ダウンストローク主体の安定した推進運動であることが明らかとなった。加速度平面（AX-AZ）においても、分布は鉛直方向に鋭いピークを持ち、揚力生成を目的とした効率的な飛行運動であることが判明した。

- ・自由飛行における能動的制御：対照的に、自由飛行では、アップストローク時にも翼の運動軌跡を調整し、前後方向への加速や姿勢制御を能動的に行っていることを示唆する結果が得られた。*Ratio\_fixed* の増大や加速度平面における横方向への広がり、旋回などのイベント下において、ハトが羽ばたきの一周毎に進行方向の加速度を二度発生させることで高度な機動性を確保していることを示唆している。

## 6.2 群れの飛行と単独飛行における運動学的特性

本研究の特筆すべき成果は、複数個体間の検証を通じて、飛行状況が個体の運動に与える影響を評価した点である。まず、帰巢飛行時における *Ratio\_fixed* の分布を確認すると、同一グループ内で分布の形状が類似している事が確認された。この事実は、群れを形成して帰巢する際、個体間で加速のリズムが共有・同期されている可能性を示唆している。また、全個体統合モデルにおける ID035（群れの先頭個体）の SAGE 値計算結果、周波数領域の特徴量の重要度が極めて高かった。このことは、先頭を飛行する個体に合わせて、追従個体がリズムを共有している可能性を示唆している。一方で、羽ばたき周波数 (*period\_Gy*) の詳細な比較では、同一グループ内であっても個体ごとにテンポが異なることが確認された。具体的には、ID035 の羽ばたき周波数の分布が比較的低い位置にあり、その他の個体の分布は全体が少し高い領域に位置していた。この結果は、先行研究 [2] の「前方に他個体が飛行している場合、羽ばたき周波数が増加する」という知見と一致しており、群れの中での相対的な飛行位置が個体の運動制御に直接的な影響を与えていることを示している。

また、角速度  $G_y$  の歪度 (*skew\_Gy*) の解析において、群れの先頭個体である ID035 および単独飛行個体である ID042 は、他の個体と比較して歪度が 0 に近い、あるいは正の値を記録する傾向があった。先行研究 [2] によれば、加速に必要な力が大きくなれば羽ばたきの大きさも増大することが示されている。本研究の結果は、前方に他個体が存在しない状況下では、他個体が生成する気流などによる加速の要求が比較的小さいため、ダウンストロークが緩やかになり運動の対称性が高まっている可能性を示唆している。この傾向は、前後方向の加速度の歪度 (*skew\_Ax*) の解析結果とも一致しており、物理的な整合性が確認された。

さらに、単独飛行個体である ID042 は、*Ratio\_fixed* および加速度平面の解析結果から、帰巢飛行時においても、アップストロークによる推進を行っているという特異な運動構造を示した。しかし、単独飛行個体のデータ不足から、この特異性が単独飛行に共通のものなのかは現時点で判然としない。

### 6.3 今後の展望

本研究で得られた知見をさらに発展させ、ハトの運動制御における普遍的な原理を解明するためには、以下の課題に取り組む必要がある。まず、データサンプルの拡充である。本研究では、単独飛行個体や群れの先頭個体において、追従個体とは異なる特異的な運動特性が確認された。しかし、これらの特徴が「単独」や「先頭」という飛行状況に起因するものなのか、あるいは個体固有の性質によるものなのかを厳密に結論付けるには、現時点ではデータが不足している。したがって、今後さらなるデータサンプルを蓄積し、統計的な信頼性を高めることで、本研究で見出された運動学的差異をより確固たるものにする必要がある。

また、本研究で構築した「機械学習による分類・SAGEによる重要特徴量の特定・物理的解釈」という一連の解析フレームワークは、ハトの飛行運動飲みに限定されるものではない。本手法は、慣性センサーデータから得られるあらゆる運動対象に対しても適用可能である。今後は、対象とする生物種を拡大し、異なる運動様式間での比較を行うことで、生物が環境や状況に応じて運動を最適化するメカニズムの解明につなげたい。

## 参考文献

- [1] L. Gerencser, et al., Identification of Behaviour of Freely Moving Dogs(Canis familiaris) Using Inertial Sensors, *PLOS ONE*, **8**, e77814, 2013.
- [2] J. Usherwood, et al., Flying in a flock comes at a cost in pigeons, *Nature*, **474**, pp.494-497, 2011.
- [3] 池本祥太郎, 大阪府立大学大学院工学研究科平成 30 年度修士論文, 2019.
- [4] S. Ikemoto, D. Izutsu and T. Mizuguchi, Gait dependence of the lumber motion in human locomotion, submitted.
- [5] A. Mannini, et al., A Machine Learning Framework for Gait Classification Using Inertial Sensors: Application to Elderly, Post-Stroke and Huntington's Disease Patients, *Sensors*, **16**, 134, 2015.
- [6] F. Attal, et al., Physical Human Activity Recognition Using Wearable Sensors, *Sensors*, **15**, pp.31314-31338, 2015.
- [7] W. S. Lima, et al., Human Activity Recognition Using Inertial Sensors in Smartphone: An Overview, *Sensors*, **19**, 3213, 2019.
- [8] H. Ahn and S. Chung, Deep learning-based anomaly detection for individual drone vehicles performing swarm missions, *Expert Systems With Applications*, **244**, 122869, 2024.
- [9] I. C. Covert, S. Lundberg and S. Lee, Understanding Global Feature Contributions With Additive Importance Measures, *Advances in neural information processing systems*, **33**, pp.17212-17223, 2020.
- [10] K. Schneider and R. F. Zernicke, Jerk-Cost Modulations During the Practice of Rapid Arm Movements, *Biological Cybernetics*, **60**, pp.221-230, 1989.
- [11] D. Chicco and G. Jurman, The advantage of Matthews correlation coefficient(MCC) over F1 score and accuracy in binary classification evaluation,

*BMC Genomics*, **21**:6, 2020.

- [12] A. Altmann, et al., Permutation importance : a corrected feature importance measure, *Bioinformatics*, **26**, pp.1340-1347, 2010.
- [13] 右衛門佐誠, 大阪府立大学大学院工学研究科平成 23 年度修士論文, 2012.
- [14] 井筒大輔, 大阪府立大学大学院理学研究科平成 31 年度修士論文, 2020.

## 謝辞

本研究の遂行にあたり、指導教員である水口毅先生には多くの助言を頂きました。心から感謝いたします。また、データを提供していただいた Máté Nagy 博士に感謝します。最後になりましたが、生活面を支えていただいた家族にも感謝します。