

令和3年度
畜産関係学術研究委託調査研究報告書
(詳細版)

人工知能の画像解析を利用した
肉用鶏の成育・健康管理システム開発に関する研究

令和4年3月

山形大学 教授	堀 口 健 一
山形大学 教授	片 平 光 彦
山形大学 准教授	松 山 裕 城
山形大学 連携研究員	市 浦 茂
岩手大学 大学院生	孟 彤

要 約

養鶏（肉用鶏）の飼養管理において、人工知能を利用して画像情報から効率的な監視による肉用鶏の成育・健康状態を把握する管理システムの開発に必要な知見を得るため、多様な画像情報と人工知能の技術を組み合わせ、個体の検出と追跡、摂食行動と飲水行動の検出、体温（死鶏）の検出について検討した。その結果、調査対象週齢の肉用鶏では、一定の体重増加率や行動量の範囲で個体識別用の物体検出モデルを再作成することで、50%程度の精度で検出を継続することが可能であること、首の曲げ角度が異なる動作パタンの組み合わせで作成した物体検出モデルは摂食または飲水の発現行動を高い精度で検出できること、死鶏画像を用いて作成した物体検出モデルは死鶏の検出が可能であることが示唆された。

はじめに

畜産現場において、それぞれの規模に合わせた最適な管理を適正な飼養環境下で行うことが重要となる。特に、大規模化が進むなかで、生産面や衛生面を最適化しながら快適性に配慮した家畜飼養、作業の負担軽減といった点を意識した管理技術の高度化が求められ、モノのインターネットや人工知能を活用し、家畜の成育・健康状態を監視できる管理技術の導入による効率的な飼養管理へ展開していくことが望まれている。

家畜飼養での群れ管理下において、生産効率の向上や防疫態勢の強化につながる飼養管理が不可欠であり、アニマルウェルフェアの考え方を踏まえた飼養管理にも対応していくことが必要である。これらを体系的に構築していくためには、多様なセンサデバイスから得られた情報をモノのインターネットや人工知能といった技術を活用しながら家畜の飼養管理のなかで共有できるシステムが強く求められ、飼養管理で必要な情報に変換していくシステムを構築する技術開発が重要である。

そこで、本研究では飼養規模の拡大が著しい養鶏（肉用鶏）での人工知能の利用による適切な飼養管理に関する技術開発に必要な知見を得るため、多様な画像情報と人工知能による画像認識の技術を組み合わせ、それらから作成した物体検出モデルにおいて、個体の検出と追跡、行動（摂食行動、飲水行動）の検出、体温（死鶏）の検出について検討した。

画像情報と人工知能を利用した肉用鶏における個体の検出と追跡の検討

現在、人工知能の開発環境はオープン化され、農業分野や畜産分野へも活用できる土台が構築されつつある。畜産分野（肉用鶏の生産現場）においては、飼養規模の拡大に伴う最適な管理システムの強化とともに、生産現場での人手不足へ対応した管理システムへの移行が求められており、少ない労働力で最大限の生産を得られる効率的な家畜（肉用鶏）の飼養管理をアシストしていく技術の開発が強く望まれている。本調査では、肉用鶏の多羽飼養での群れ管理下において、一定個体（鶏舎内の飼養総羽数の数パーセント個体）の情報から総体的な成育状態を把握するための技術開発に不可欠な個体の検出と追跡について、可視光カメラを用いて得られた画像に対する個体識別用の物体検出モデルの検出精度や追跡能力を検証した。

材料と方法

供試動物と飼養条件

肉用鶏（チャンキーブロイラー、雌）の雛を導入し、群れでの一般的な飼養条件下で管理した10羽（5週齢）を供試した。本調査は山形大学動物実験委員会の承認を受けた動物実験飼養施設にて動物実験計画書にしたがって実施した。飼料は市販の配合飼料を、水は水道水を用いた。飼養管理については、仕切り板で囲いを設置して給餌器と給水器を配置した2つのエリアに分割し、不断給餌、自由飲水とし、敷料として糶殻を用いて行った。

データの収集と物体検出モデルの作成

画像データは、5～6週齢の肉用鶏を撮影した画像を用いた。また、無線で自動認識が可能な個体識別用の小型タグ（RFIDタグ）を肉用鶏に取り付け、2つのエリアの通路にRFIDタグ受信器内蔵の体重計を設置し、個体の確認と体重を記録した。

本調査では飼養管理した10羽のうち、1羽の肉用鶏（ID95鶏）を選定して個体識別用の物体検出モデルを作成した。市販の可視光カメラ（M25、Mobotix）で収集した画像から、ID95鶏を物体検出モデルへ学習させるため、アノテーション作業（ラベル付け）として、同個体の全身を指定した。アノテーションによる物体検出モデル学習用の教師デー

タは 2,617 枚とし、物体検出アルゴリズムはディープラーニングのフレームワーク Darknet を、物体検出アルゴリズムは YOLOv4 (YOLOv4.conv.137) を用いて転移学習にて物体検出モデルを作成した。ディープラーニングの学習の設定は、入力する画像サイズを 800×800 ピクセル、バッチサイズを 64、Train と Validation の分割割合を 8 : 2 とし、学習回数を 10,000 回で統一した。

肉用鶏の成長により、その容姿は変化するため、定期的に新たな画像を用いて物体検出モデルを作り変えることで、一定の調査期間での個体の検出と追跡を行った。肉用鶏の個体検出モデルは、撮影 1 日目の画像データ 2,617 枚で作成したパターン A の物体検出モデル、撮影 1 日目、撮影 4 日目、撮影 7 日目に、それぞれ 2,617 枚の画像で作成したパターン B の物体検出モデルを比較した。

物体検出モデルの精度評価

物体検出モデルの精度評価は、作成したパターン A とパターン B の 2 つの ID95 鶏を検出する物体検出モデルに対して、モデル作成用と異なるテスト用画像を撮影期間中の 12:00～13:00 の時間帯から 100 枚/日 (20 枚×5 セット) を無作為に抽出し、合計 900 枚で混同行列にしたがって行った。物体検出モデルの精度は、Darknet に実装されている mAP オプションを利用し、信頼度 (物体検出モデルが検出したものが対象物である確率) が 50% 以上のものを検出するように指定し、適合率 (ID95 鶏を予測した総数のうちで正しかったデータ数の割合)、再現率 (実際の ID95 鶏の個体数のうちで ID95 鶏を予測したデータ数の割合)、F 値 (適合率と再現率の調和平均) で判断した。

調査個体の体重増加率と行動量

ID95 鶏の体重は RFID 受信機内蔵体重計で記録した。体重増加率 (%) は基準値を調査初期が撮影 1 日目、調査中期が撮影 4 日目、調査後期が撮影 7 日目として体重増加分の差分を算出して容姿の変化を示す指標とした。また、ID95 鶏の行動量は、アノテーションの際に作成したバウンディングボックスの左上部点を原点とし、X と Y の座標データが得られるため、それを利用して累積値として算出し、体重を表示する LED 表示器の寸法 (15cm×5cm) と比較して距離に換算した。なお、調査期間については、1 日目～3 日目を調査初期、4 日目～6 日目を調査中期、7 日目～9 日目を調査後期とした。

結果と考察

選定個体の物体検出モデルによる検出と体重増加率

図 1-1 にはパタン A の物体検出モデルでの ID95 鶏の検出状況（信頼度 1.00 で ID95 鶏と推定した場合）を示した。作成した個体識別用の物体検出モデルは、調査開始日の時点で、ID95 鶏を再現率 0.4 で検出していた。ID95 鶏の体重増加率は、調査中期から調査後期の期間で 39.0%、調査後期の期間で 13.4%、それぞれ増加し、成育が進むにつれて期間内の体重増加率が低下する傾向にあった。ID95 鶏の体重は 6 週齢で 1,864g、8 週齢で 3,206g と、期間中に体重が 1,342g 増えており、体重増加率の変化と合わせて検出の特徴点となる体型や羽毛が成長して容姿が変化していたと思われる。これは、特徴に関する情報が成育に伴って変動することを示し、物体検出モデルの検出精度に影響を及ぼす。



図 1-1 パタン A の物体検出モデルによる ID95 鶏の検出状況

個体識別用の物体検出モデルの精度評価

作成した個体識別用の物体検出モデルの精度を判断するための適合率、再現率および F 値の結果を図 1-2 に示した。適合率において、パタン A は調査 4 日目まで良好であったが、その後、時間の経過とともに低下し、パタン B は調査 6 日目まで 0.8~1.0 と良好であり、それ以降で低下した。再現率をみると、両パタンとも調査 3 日目まで 0.4 程度であり、ID95 鶏の誤検出や未検出があったが、パタン B は調査 4 日目に検出能力が 0.8 まで改善され、パタン A と明らかに異なっていた。F 値に関して、両パタンとも調査 3 日目まで同様に推移し、パタン B は調査 4 日目で高まり、調査 4 日目以降でパタン A とパタン B の変化は大きく異なっていた。

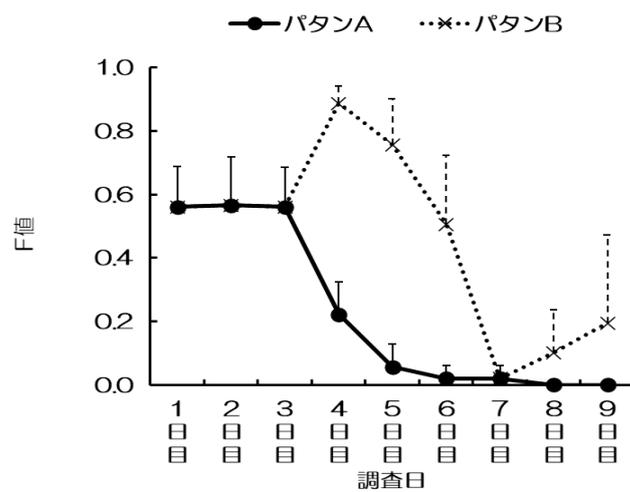
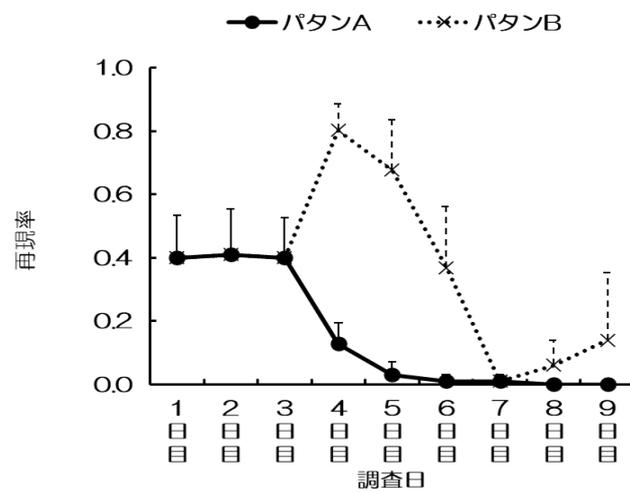
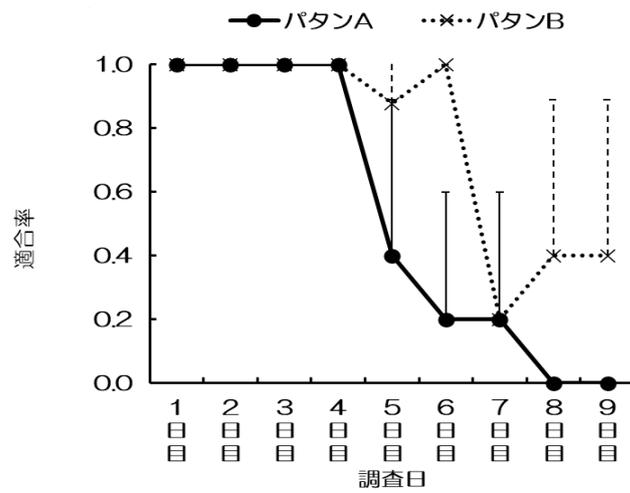


図 1-2 個体識別用の物体検出モデルによる適合率、再現率および F 値の日変化
 上段が適合率、中段が再現率、下段が F 値をそれぞれ示す。

図 1-3 には調査初期から調査後期までの体重増加率と行動量を示した。これらの結果と比較させながら物体検出モデルの検出精度を照らし合わせると、調査初中期は、ID95 鶏の行動量が多く、体重の増加に伴う体型や羽毛といった容姿の変化により、特徴点となり得る多様な画像を収集できていたことが考えられる。これらの画像を使って作成した新たな物体検出モデルを調査 4 日目に差し替えることで、新たな容姿に追従できる物体検出モデルとなり、ID95 鶏をある程度の精度で検出できたと考えられる。一方、調査 7 日目からの調査後期において、新たに作成したパターン B の物体検出モデルは、調査 4 日目に収集した画像で作成しており、調査 4 日目から調査 6 日目の期間での行動量とともに、体重の増加に伴う特徴点の変化が大きく、物体検出モデルが対応しきれていなかったと思われ、調査 7 日目時点の容姿の変化に追従できず、ID95 鶏の検出が難しかったのではないかと考えられる。

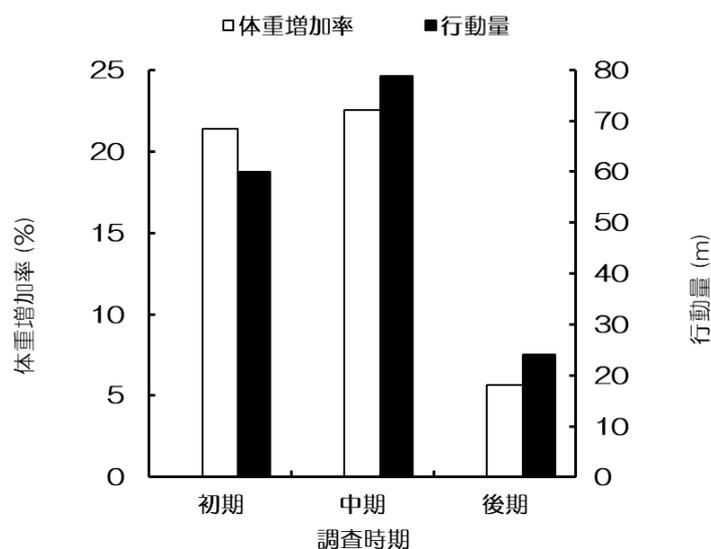


図 1-3 調査期間ごとの ID95 鶏の体重増加率と行動量

これらの結果から、調査対象とした 5、6 週齢の肉用鶏では、一定の体重増加率や行動量の範囲で個体識別用の物体検出モデルを再作成することで、50%程度の精度で検出を継続することが可能であることが示唆された。なお、5 週齢の後半では、適合率、再現率、F 値がともに低下していることから、体重増加率や行動量を加味して物体検出モデルを切り替える必要があると思われる。

画像情報と人工知能を利用した肉用鶏における行動検出の検討

家畜の飼養管理において、管理者による家畜の体調や成長の把握は重要であり、アニマルウェルフェアの観点から、家畜の快適性への配慮が重要視されている。肉用鶏においても、様々な飼養環境下での発現行動や発育性などを総合的に解析する技術開発が求められている。肉用鶏で観察される様々な行動を通じて、その健康状態や成育状態を把握することが可能である。通常の飼養管理のなかで発現する肉用鶏の行動のうち、生命維持や体温調整にかかわる摂食行動（摂食行動と飲水行動）は極めて重要かつ基本的な行動である。本調査では、肉用鶏の摂食行動と飲水行動を人工知能による画像認識から検出できるかを検証した。

材料と方法

供試動物と飼養条件

肉用鶏（チャンキーブロイラー）の雌 10羽（6週齢）を供試した。雛を導入後、山形大学動物実験委員会の承認を受けた動物実験飼養施設にて慣行的な飼養方法に基づいて管理した。飼料は市販の配合飼料（必要な栄養成分やミネラル成分を満たしている飼料）を、水は水道水を用い、飼料と水は自由に摂取できるようにした。肉用鶏の飼養スペースを 3 つに仕切り（各スペースには自由に移動できるよう一部を仕切り）、左右のスペースに給餌器または給水器を置き、糞殻を敷料とした（図 2-1）。



図 2-1 飼養管理中の肉用鶏と行動撮影用カメラの設置状況

動作パターンと学習用データセット

行動は監視カメラ（CS-W72FHD、プラネックスコミュニケーションズ）を設置して動画を撮影し、発現した行動の画像を収集した。その撮影動画から摂食行動と飲水行動の画像を得た。本調査では肉用鶏が摂食行動または飲水行動しているときの首の曲げ状態を画像での特徴点の1つとして想定し、肉用鶏の体に対して首の真っ直ぐな状態からの曲げ角度により、動作を5つのパターンに分けた。

それぞれの動作パターンは以下のとおりとし、学習用データセットは動作パターンの組み合わせとラベル部位の違いにより設定した（表2-1）。

- 動作パターン1 首の曲げ角度が右斜め45度以下の範囲で撮取している動作
- 動作パターン2 首の曲げ角度が右斜め45度までの範囲で撮取している動作
- 動作パターン3 首を真っ直ぐにして撮取している動作
- 動作パターン4 首の曲げ角度が左斜め45度までの範囲で撮取している動作
- 動作パターン5 首の曲げ角度が左斜め45度以下の範囲で撮取している動作

表2-1 学習用データセット

データセット	動作パターン	画像数	ラベル部位
A	1、2、3、4、5	500	全身
B	3、4、5	300	全身
C	1、3、5	300	全身
D	2、4	200	全身
E	3	100	全身
F	1、2、3、4、5	500	頭首
G	3、4、5	300	頭首
H	1、3、5	300	頭首
I	2、4	200	頭首
J	3	100	頭首

物体検出モデルの作成

各動作パターンの学習用画像は50枚を用いた。学習用画像はすべて1羽のみの肉用鶏の画像とした。ディープラーニングを行うためにフレームワークとアルゴリズムとしてDarknetとYOLOv4 (YOLOv4.conv.137)を使用した。ディープラーニングの学習の設定は、入力する画像サイズを608×608ピクセル、バッチサイズを16、TrainとValidation

の分割割合を 8 : 2 とし、学習回数は 5,000 回と 20,000 回の 2 種類を設定した。

物体検出モデルの精度評価

テスト用データセットについては、摂食行動、飲水行動ともすべての動作パタンの画像を、それぞれの動作パターンとも 4 枚として計 20 枚とした。行動判別用の物体検出モデルの精度評価については、それを用いて 5 回実施し、Darknet に実装されている mAP オプションを利用し、信頼度が 50% 以上のものを検出するように指定して適合率、再現率、F 値を算出して行った。なお、適合率は「摂食行動または飲水行動を予測した総羽数のうちで正しく検出した羽数 (割合)」であり、この数値が大きい場合、作成した物体検出モデルは物体 (摂食行動または飲水行動) をより正確に検出することを示し、再現率は「実際の摂食行動または飲水行動の羽数のうちで正しく検出した羽数 (割合)」であり、この数値が大きい場合、作成した物体検出モデルは物体 (摂食行動または飲水行動) をより検出する能力が高いことを示す。

結果と考察

行動判別用の物体検出モデルによる摂食行動と飲水行動の検出

作成した行動判別用の物体検出モデルによる肉用鶏の摂食行動と飲水行動の検出状況 (ラベル部位が頭首の場合) を図 2-2 に示した。摂食行動または飲水行動を検出するために作成した物体検出モデルは、摂食行動または飲水行動が発現していた肉用鶏を検出した。

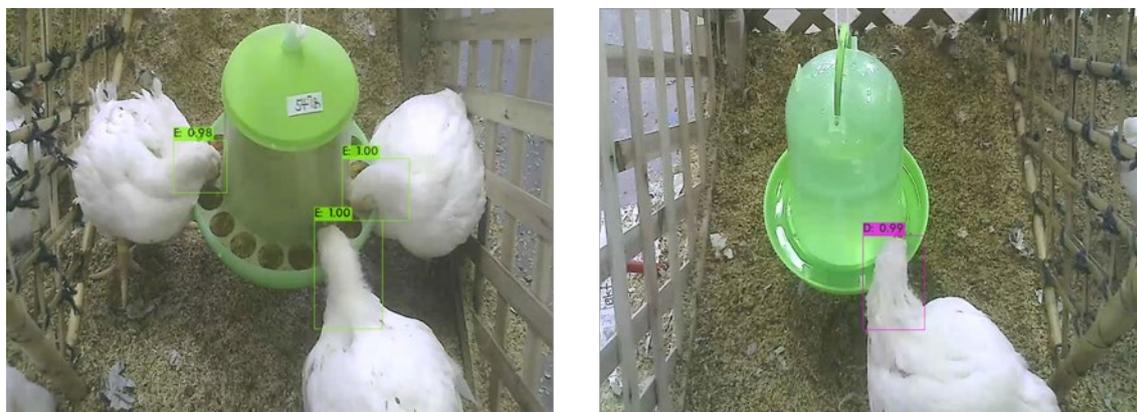


図 2-2 物体検出モデルによる肉用鶏の摂食行動 (左) と飲水行動 (右) の検出状況

行動判別用の物体検出モデルの精度評価

行動判別用の物体検出モデルによる適合率を表 2-2 に示した。すべてのデータセットにおいて、摂食行動、飲水行動とも 0.9 以上であり、作成した物体検出モデルは、摂食行動または飲水行動をより正確に検出していたことが確認できた。摂食行動では、単独の動作パターン（動作パターン 3）のみとしたデータセットが複数の動作パターンを組み合わせたデータセットより若干低かった。飲水行動においては、単独の動作パターンと複数の動作パターンの間に違いがなかった。ラベル部位（全身、頭首）や学習回数（5,000 回、20,000 回）の設定条件の違いでは一定の傾向が認められなかった。

表 2-2 行動判別用の物体検出モデルによる各データセットの適合率

データセット	学習回数	摂食行動	飲水行動
A	5,000	0.99 (0.02)	1.00 (0.00)
	20,000	1.00 (0.00)	1.00 (0.00)
B	5,000	0.99 (0.02)	0.99 (0.02)
	20,000	1.00 (0.00)	0.98 (0.03)
C	5,000	0.99 (0.02)	1.00 (0.00)
	20,000	1.00 (0.00)	1.00 (0.00)
D	5,000	1.00 (0.00)	0.99 (0.02)
	20,000	0.99 (0.02)	0.99 (0.03)
E	5,000	0.94 (0.05)	0.99 (0.03)
	20,000	0.95 (0.07)	1.00 (0.00)
F	5,000	0.99 (0.02)	0.99 (0.02)
	20,000	0.99 (0.02)	0.99 (0.02)
G	5,000	0.98 (0.02)	0.99 (0.02)
	20,000	0.98 (0.02)	1.00 (0.00)
H	5,000	0.97 (0.04)	1.00 (0.00)
	20,000	0.96 (0.04)	1.00 (0.00)
I	5,000	0.97 (0.03)	0.98 (0.04)
	20,000	1.00 (0.00)	0.97 (0.04)
J	5,000	0.92 (0.06)	0.98 (0.03)
	20,000	0.95 (0.03)	0.97 (0.05)

数値は5反復の平均値であり、カッコ内は不偏標準偏差を示す。

行動判別用の物体検出モデルによる再現率を表 2-3 に示した。すべての動作パターンを含むデータセットである A と F は、摂食行動、飲水行動とも 0.95 以上であり、摂食行動ま

たは飲水行動を検出する能力が高かったことが確認できた。1つの動作パターン（動作パターン3）のみとしたデータセットのEとJは、同じラベル部位内で比較すると最も低い結果であった。ラベル部位を全身としたデータセットEは、摂食行動、飲水行動ともすべてのデータセットのなかで最も低かった。ラベル部位による違いを組み合わせた動作パターンが同じデータセットで比較すると、摂食行動、飲水行動とも全身より頭首の方が高かった。学習回数については、20,000回より5,000回の方が高くなるデータセットが多かった。

表 2-3 行動判別用の物体検出モデルによる各データセットの再現率

データセット	学習回数	摂食行動	飲水行動
A	5,000	0.97 (0.03)	0.98 (0.03)
	20,000	0.96 (0.03)	0.95 (0.04)
B	5,000	0.97 (0.03)	0.90 (0.07)
	20,000	0.92 (0.03)	0.92 (0.07)
C	5,000	0.89 (0.07)	0.96 (0.02)
	20,000	0.90 (0.07)	0.89 (0.07)
D	5,000	0.88 (0.05)	0.90 (0.05)
	20,000	0.85 (0.07)	0.88 (0.13)
E	5,000	0.70 (0.07)	0.82 (0.12)
	20,000	0.60 (0.08)	0.74 (0.09)
F	5,000	0.98 (0.03)	0.98 (0.03)
	20,000	0.98 (0.03)	0.98 (0.03)
G	5,000	0.99 (0.02)	0.96 (0.02)
	20,000	0.97 (0.02)	0.97 (0.03)
H	5,000	0.97 (0.03)	0.97 (0.03)
	20,000	0.93 (0.03)	0.97 (0.03)
I	5,000	0.90 (0.08)	0.95 (0.06)
	20,000	0.92 (0.03)	0.92 (0.05)
J	5,000	0.86 (0.07)	0.92 (0.06)
	20,000	0.82 (0.06)	0.82 (0.08)

数値は5反復の平均値であり、カッコ内は不偏標準偏差を示す。

作成した物体検出モデルの検出精度の指標となるF値（適合率と再現率の調和平均）を表2-4に示した。動作パターンを2つ以上組み合わせたデータセットは、摂食行動、飲水行動とも0.9以上であり、検出精度が高かった。一方、1つの動作パターン（動作パターン3）のみとしたデータセットのEとJは、ほぼ0.9以下であった。ラベル部位による違いを組

み合わせた動作パターンが同じデータセットで比較すると、摂食行動、飲水行動とも全身より頭首の方が上回った。学習回数は、20,000 回に比較して 5,000 回が同等以上であった。

表 2-4 行動判別用の物体検出モデルによる各データセットの F 値

データ セット	学習回数	摂食行動	飲水行動
A	5,000	0.98 (0.02)	0.99 (0.01)
	20,000	0.98 (0.02)	0.98 (0.02)
B	5,000	0.98 (0.01)	0.94 (0.03)
	20,000	0.96 (0.02)	0.95 (0.04)
C	5,000	0.94 (0.05)	0.98 (0.01)
	20,000	0.94 (0.04)	0.94 (0.04)
D	5,000	0.94 (0.03)	0.94 (0.02)
	20,000	0.91 (0.04)	0.93 (0.08)
E	5,000	0.80 (0.06)	0.89 (0.08)
	20,000	0.74 (0.06)	0.85 (0.06)
F	5,000	0.99 (0.02)	0.99 (0.02)
	20,000	0.99 (0.02)	0.99 (0.02)
G	5,000	0.99 (0.02)	0.98 (0.02)
	20,000	0.98 (0.02)	0.99 (0.01)
H	5,000	0.97 (0.03)	0.99 (0.01)
	20,000	0.94 (0.04)	0.99 (0.01)
I	5,000	0.94 (0.04)	0.97 (0.05)
	20,000	0.96 (0.02)	0.95 (0.05)
J	5,000	0.89 (0.06)	0.95 (0.04)
	20,000	0.88 (0.04)	0.88 (0.05)

数値は5反復の平均値であり、カッコ内は不偏標準偏差を示す。

このことから、複数の動作パタンの画像を組み合わせ、ラベル部位を頭首とした画像を用い、学習回数を 5,000 回として作成した物体検出モデルは、摂食行動と飲水行動を検出する精度が高くなることが確認でき、肉用鶏における摂食または飲水の発現行動を高い精度で検出可能な物体検出モデルを作成できることが示唆された。肉用鶏の首の曲げ状態を画像の特徴点とした場合（首の曲げ角度が異なる動作パターンでの検討において）、単独の動作パターンより複数の動作パタンの組み合わせ（動作パタンの多様性）が重要であると考えられ、今後の検討としては、行動判別用の物体検出モデルを作成する際の学習用の画像数による影響も踏まえ、その精度を確認していくことが必要である。

画像情報と人工知能を利用した肉用鶏の体温判別（死鶏検出）の検討

畜産の生産現場では人手不足が深刻な状況になりつつあり、少ない人員での飼養管理を可能にするシステム開発が求められている。また、家畜の飼養管理において、ヒトを介さずして家畜の健康状態や成育状態といった特徴的な生体情報を取得・利用しながら作業負担の軽減となる管理システムの開発が望まれている。養鶏（肉用鶏）の大規模飼養では効率的な作業による管理技術が不可欠であり、ヒトの鶏舎への出入りを減らして衛生的な飼養環境の整備を強化することが防疫の観点からも必要である。本調査では、人工知能の画像認識を活用した体温（死鶏）の検出について、可視光カメラとサーマルカメラで得られた肉用鶏の死鶏画像を用いて死鶏判別用の物体検出モデルを作成して検証した。

材料と方法

供試動物

死鶏は死んだ成鶏（チャンキーブロイラー）を県内の養鶏農家から導入した。死鶏の導入や取り扱いにあたっては、県内の家畜保健衛生所の獣医師より、導入時や撮影時の詳細な留意点、具体的な対応方法を事前に確認して取り組んだ。

なお、獣医師からの指示内容を以下に示す。

- 床面をビニールシート等で養生するほか、撮影機材も操作の妨げにならない程度ビニール袋等で養生すること。
- 実施者は紙つなぎ、手袋、キャップ、マスク、専用の履物を着用すること。
- 使用した紙つなぎ等は密封廃棄し、繰り返し使用できるものは洗浄・消毒を行うこと。
- 実施・飼養場所から退出する際は履物の交換、手指の洗浄消毒、うがい等を行うこと。
- 鶏の飼養管理後に死鶏を扱う等の対応を行うこと。

画像データの収集と物体検出モデルの作成

学習用とテスト用の画像データは、導入した死鶏（33日齢）各1羽を用いて撮影して準備した。導入時の死鶏の体重は、学習用が1,288g、テスト用が1,108gであった。画像の撮影は、市販の可視光カメラ（M25, Mobotix）とサーマルカメラ（Thermal M16, Mobotix）を用い、木製の枠で囲いを設置して糞殻を敷いた上に死鶏を置いて行った。その際、死鶏

を置く位置は木製の枠内でランダムに4ヶ所とし、その向きは頭が上下左右の4つの方向となるようにした(図3-1)。

死鶏判別用の物体検出モデルへ学習させるためのアノテーション作業(ラベル付け)は死鶏の全身を指定して行った。学習用データとしての画像は100枚とし、すべて1羽のみの死鶏の画像を用いた。死鶏判別用の物体検出モデルの作成は、ディープラーニングのフレームワークとしてDarknet、物体検出アルゴリズムとしてYOLOv4(YOLOv4.conv.137)を使用して行った。ディープラーニングの学習の設定は、入力する画像サイズを608×608ピクセル、バッチサイズを16、TrainとValidationの分割割合を8:2、学習回数を10,000回とした。



図3-1 肉用鶏の死鶏画像の撮影状況

物体検出モデルの精度評価

テスト用画像20枚を用いて、作成した死鶏判別用の物体検出モデルの精度評価を実施した。Darknetに実装されているmAPオプションを利用し、信頼度が50%以上のものを検出するように指定して適合率、再現率、F値を算出した。なお、適合率は「死鶏を予測した総羽数のうちで正しく検出した羽数(割合)」、再現率は「実際の死鶏の羽数のうちで正しく検出した羽数(割合)」、F値は「適合率と再現率の調和平均」である。

結果と考察

死鶏判別用の物体検出モデルによる死鶏の検出

サーマルカメラで得られた肉用鶏の死鶏画像を用いて作成した物体検出モデルによる

死鶏の検出状況を図 3-2 に示した。死鶏を検出するために作成した物体検出モデルは死鶏を検出した。

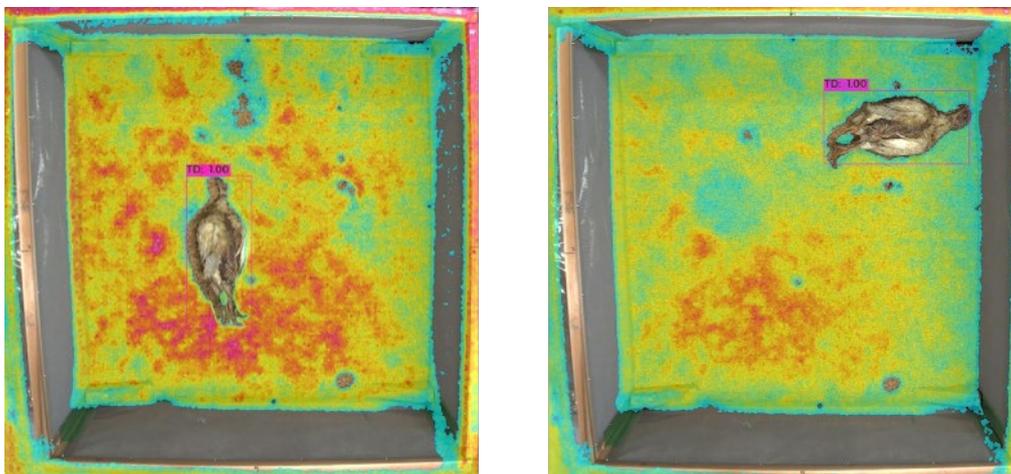


図 3-2 死鶏判別用の物体検出モデルによる肉用鶏の死鶏の検出状況

死鶏判別用の物体検出モデルの精度評価

物体検出モデルの精度判断に用いられる適合率、再現率および F 値は、それぞれ 1.00 であった。本調査で作成した死鶏判別用の物体検出モデルについては、その検出精度の評価を反復して実施しておらず、検出精度の再評価が必要であると考えているが、本結果を踏まえ、肉用鶏での死鶏画像を用いて作成した物体検出モデルは死鶏の検出が可能であると思われる。

おわりに

今後の畜産現場ではモノのインターネットや人工知能の技術を適用することにより、ヒトの介在を極力減らし、ソフトウェア技術やロボット技術を用いた家畜の飼養管理をアシストする技術開発が進み、ヒトを介さずして家畜の成育・健康状態や快適性を見極めることが可能になるとと思われる。

本研究は人工知能による画像認識の最新技術を畜産業（養鶏）へ実装していくための技術開発を目指しており、得られた成果は、国内外の養鶏における最適な飼養管理のシステム化に適用可能であり、アニマルウェルフェアに対応した飼養管理の開発にも寄与でき、

管理作業時の労働負担の軽減と作業効率の改善につながる技術開発に貢献できると考えている。

畜産現場へのモノのインターネットや人工知能の活用は、ヒトの目でしか判別できなかった家畜の成育状態や健康状態、飼養管理における最適な作業や作業負担の軽減につながる技術ポイントについて、コンピュータを目や脳として適切に判断できるようになると考えられ、本研究から得られた成果も踏まえながら畜産現場（養鶏の生産現場）が求める次世代の飼養管理システム開発へ展開していくことが必要である。