

〈研究ノート〉

スマート酪農の実現に向けた ドローンによる家畜管理の可能性

長尾光悦 * 渋谷弘貴 †

Possibility of Livestock Management using Drone for Realization of Smart Dairy Farm

Mitsuyoshi NAGAO* Hirotaka SHIBUYA†

要旨

近年、酪農産業において高齢化や後継者不足による労働力不足が問題となっている。これにより、酪農における作業を効率化し、少ない酪農事業者により効率的な生産が可能となるような環境を整えることが急務とされている。本研究では、ドローンによる圃場の家畜管理の実現に向け、画像認識などの分野で注目されている畳み込みニューラルネットワーク（Convolutional Neural Network、以下 CNN）を利用した空撮画像に基づく圃場内の牛の計数法を提案する。また、CNN のハイパーパラメータ設定変更による識別率の変化を検証する。

Abstract

Dairy industry has problems about aging workforce and lack of labor. Therefore, it is necessary to realize the environment where more efficient production can be carried out by few dairy workers. In this research, we propose cattle counting method using Convolutional Neural Network (CNN) in order to implement livestock management in farm field by using drone. We realize to count cattle in airborne imagery taken by drone. Moreover, we confirm the variation against recognition performance in case of use of difference hyper parameters for CNN.

キーワード

酪農 (Dairy industry) ドローン (Drone) 牛 (Cattle) 計数 (Counting) CNN

* 北海道情報大学経営情報学部システム情報学科教授, Professor, Department of Systems and Informatics,
HIU

† 北海道情報大学経営情報学部システム情報学科 B4, B4, Department of Systems and Informatics, HIU

1. はじめに

北海道において、酪農産業は全国1位の産出額となっており、重要性の高い産業の一つである。しかしながら、近年、酪農業者の高齢化が進んでおり、2015年時点での酪農業従事者の平均年齢は57.2歳まで上昇している。更に、後継者不足による労働力不足が問題となっており、酪農産業は衰退の一途を辿っている。このような酪農就業人口の減少と高齢化問題は、現在、日本が抱えている少子高齢化、人口減少問題とリンクしているため早急に解決することは極めて困難である。このため、酪農における作業を効率化し、少ない酪農事業者により効率的な生産が可能となるような環境を整えることが急務とされている。現在、このような環境を実現するため、スマート酪農が提唱されている[4]。スマート酪農とは、ICTやロボット技術によって酪農事業者の負担を軽減することを目的としているものである。

北海道における酪農産業が他地域と異なる点として、土地利用型と呼ばれる恵まれた土地資源を生かした酪農を実施していることが挙げられる。北海道の圃場面積は平均28万2000平方メートルにもなり、圃場面積は非常に大きく、その管理は他地域と比較し、労力の高い業務となっている。このような広大な圃場を管理するための技術として、無人航空機（Unmanned Aerial Vehicle (UAV)、もしくは、ドローン）が注目されている。ドローンは、近年、小型軽量化、高解像度カメラ搭載、長時間安定飛行など性能が著しく向上しており、様々な分野での応用が行われ始めている技術である[5]。このようなドローンを利用した放牧地の管理についての検討も行われている[3]。また、土地利用型酪農においては、放牧地の管理だけではなく、放牧されている

家畜の管理も重要なタスクのひとつである。

本論文では、広大な圃場におけるドローンを用いた家畜放牧管理の実現に向け、畳み込みニューラルネットワークを利用した牛の計数法を提案する。本研究では、実際の家畜放牧管理を実現するためのトイ・プロブレムとして、圃場に見立てた疑似フィールドにバルーンによる模擬牛を配置し、これをドローンにより空撮することにより圃場内に存在する模擬牛の計数を実現する。開発する畳み込みニューラルネットワークは、空撮画像内に存在する牛の数に基づきクラス分けを行うものである。更に、識別精度に対するハイパーパラメータの影響を検証する。

2. 問題設定

2-1 疑似圃場

図1に本研究における疑似圃場を示す。疑似圃場としては、北海道情報大学の中庭を用いることとした。この場所には芝が育成されており、実際の圃場と類似していることから採用したものである。圃場のサイズは、縦35メートル、横25メートルを設定した。また、圃場の範囲がわかるよう白線を引いた。

2-2 模擬牛

疑似圃場内に牛に見立てたバルーンを配置した。図2に模擬牛の例を示す。これは、エスエージー・バルーンズ社が発売するトイ・バルーンであり、縦34cm×横70cmの大きさとなっている。ホルスタイン種の乳牛の大きさが肩から尾のつけね部分まで約170cm前後であるため、模擬牛は実際の乳牛の約3分の1程度のサイズとなる[7]。この模擬乳を疑似圃場内に縦向き、横向きのいずれかで配置する。



図 1 疑似圃場



出典: DJI Website

図 3 利用ドローン



出典: Amazon Japan Website

図 2 模擬牛

2-3 利用ドローン

本研究では、空撮のため DJI Japan 株式会社から販売されている Inspire 1 を用いることとした。図 3 に Inspire 1 を示す。Inspire 1 は、外形寸法が $438 \times 451 \times 301\text{mm}$ 、重量が 2935g、最大飛行時間 18 分、最大飛行速度が 22m/s という機体である。また、圃場の空撮を行うために、DJI 社が提供しているアプリ「DJI GO」を利用する。

ドローンによる飛行高度は地上から 5m とした。実際の圃場を想定した場合には約 15m 上空からの撮影となる。高度が低すぎる場合、牛を驚かせ、骨折などを引き起こす可能性がある。また、高度が高すぎる場合には、認識が難しくなる可能性があるため、ヒューリスティックにより 5m の設定を行った。図 4 に、疑似圃場に設置された模擬牛、及び、ドローン



図 4 模擬牛設置例

の例を示す。

3. 置込みニューラルネットによる牛の計数法

3-1 ドローンによる画像収集

本研究では、ドローンによって疑似圃場内を空撮し、空撮画像内にバルーンによる模擬牛が何頭存在するかの計数を実現する。ここでは、画像内に模擬牛が 0 から 6 頭存在する場合の 7 クラスへの分類を行う。

この識別を実現するための CNN を構築するため、トレーニング用空撮画像の収集を行った。トレーニング空撮画像の収集風景を図 5 に、各クラスにおけるトレーニング画像例を図 6 に示す。トレーニング用の空撮画像としては、疑似圃場の境界を示す白線が画像内に映り込んだものも採用した。また、各クラスにおいて、様々な模擬牛の配置パターンでト



図 5 トレーニング画像の収集風景

トレーニング用の画像収集を行った。

本撮影により、トレーニングデータとして 2352 枚の画像を収集した。各クラスとしては、0 頭クラス 238 枚、1 頭クラス 505 枚、2 頭クラス 400 枚、3 頭クラス 390 枚、4 頭クラス 143 枚、5 頭クラス 233 枚、6 頭クラス 353 枚である。更に、識別テスト用の空撮画像を各クラス 50 枚、計 350 枚を撮影した。

各クラスにおけるトレーニングデータ数にばらつきがあるため、識別性能への影響も考えられるが、これも含め精度検証を行う。

3-2 牛の計数 CNN

近年、機械学習の一手法である深層学習が注目されている。その中でも、画像認識分野において CNN が大きな成果を挙げている [1][2][6]。本研究では、CNN を利用することにより、空撮画像から疑似圃場内に存在する模擬牛数の分類を実現する。

ドローンにより空撮される画像は、 $4000 \times 2250\text{px}$ のサイズである。このサイズは CNN に与えるデータとしてはサイズが大きいため、 $28 \times 28\text{px}$ に画像サイズを縮小したものを利用し、分類を行う。また、この縮小に伴い、画像の不足部分を補うパディング処理を適用する。図 7 にサイズを縮小し、パディング処理を行った空撮画像例を示す。

畳み込みニューラルネットワークは、入力

層と出力層の間に畳み込み層とプーリング層の組み合わせが複数並べられ、これら組み合合わせの後、複数の全結合層が続く構成となる。出力では、ソフトマックス関数を使用して、クラス分類的回答を得るものである。本研究における CNN の構成を図 8 に示す。図に示されるように、本研究における CNN は 2 つの畳み込み層とプーリング層の組み合わせ、更に、2 つの結合層から構成される。

畳み込み層においては、畳み込み処理が行われ、画像の特徴を表す特徴マップの獲得が行われる。具体的には、入力画像においてフィルタを走査することによって特徴マップを獲得する。本 CNN においては、第 1 層の畳み込み層においては、 $5 \times 5\text{px}$ の 32 個のフィルタ、第 2 層の畳み込み層においては、 $7 \times 7\text{px}$ の 64 個のフィルタを利用することにより特徴マップの獲得を行う。また、畳み込み層からプーリング層に送られる出力を ReLU 関数により変換する。

プーリング層は、得られた特徴マップを圧縮し、新たな特徴マップ作成を行う。この操作により細かな変動に対するロバスト性を実現する。本 CNN では、最大値プーリングを使用し、 2×2 のフィルタ領域で表れた画像の特徴に最も関係するものを抽出する。

また、畳み込み層とプーリング層の両方でゼロパディングを適用した。ゼロパディングは、入力の特徴マップの周辺を 0 で埋めることで出力サイズが次第に小さくなるのを防止する役割を果たすものである。

2 つの畳み込み層とプーリング層の組み合わせの後、全結合層が配置される。全結合層は、各ノードの結合重みから、プーリング層で得られた特徴に基づき、画像の判別を行う。ここでは、ソフトマックス関数を用いることにより識別ラベルの確率に変換する。

更に、CNN は複雑な構造ゆえに、過学習に陥る場合が存在する。そのため、これを防ぐためのドロップアウト層を第 1 層目の全結合層の後に追加する。ドロップアウト率は 0.5 と

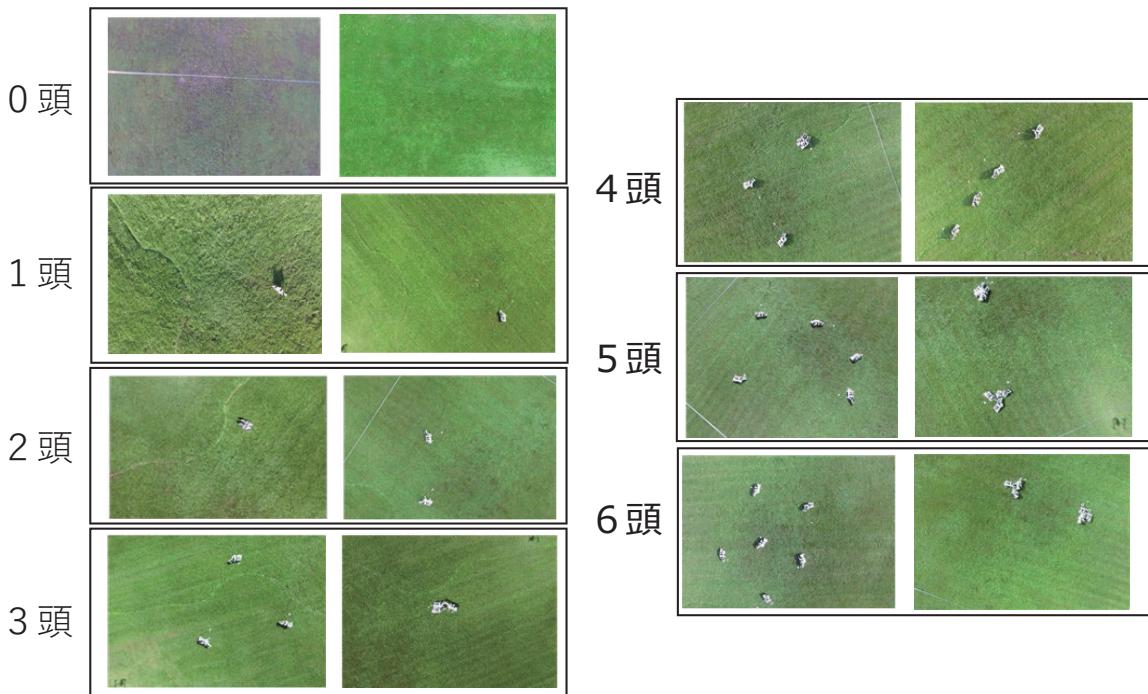


図 6 トレーニング空撮画像例

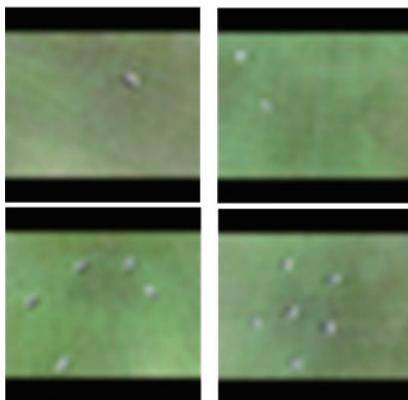


図 7 CNN 用空撮画像例

する。学習過程においては、誤差逆伝播法を用いて正解データとの交差エントロピー誤差が最小となるよう、重みの調整を行う。

4. 性能検証

4-1 CNN の実装

提案する牛の計数のための CNN の実装を行った。実装環境は、Windows10, Intel Core i5 のデスクトップ PC を利用し、Python, Anaconda3, TensorFlow, OpenCV を用いた。

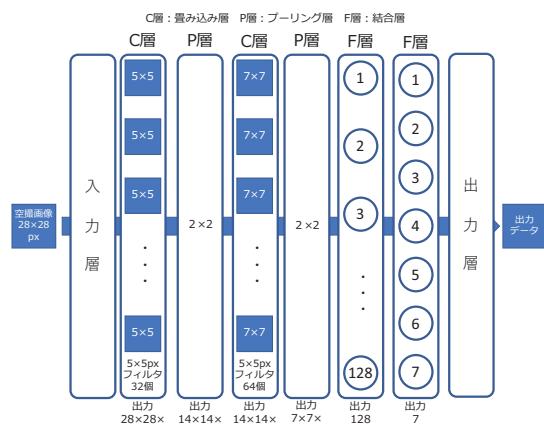


図 8 CNN の構成

これらを使い実装した。実装した CNN において、分類クラス数、学習回数、学習率、フィルタのサイズを変更することにより、識別精度がどのように変化するか性能検証を行った。

4-2 性能検証方法

実装した CNN を用いて性能検証実験を行った。実験においては、疑似圃場における 0 から 6 頭までの模擬牛を識別する 7 クラス分類問題を、学習率 $2.5e^{-5}$ 、フィルタサイズ 1 層目

5×5 , 2 層目 7×7 , 学習回数 400 ステップ, バッチサイズ 24, 最適化手法 Adam のハイパーパラメータを利用して識別精度の検証を行った。これを基本ハイパーパラメータとした。

更に、クラス数、学習率、学習回数、各畳み込み層のフィルタサイズを変更したときの識別性能を、基本ハイパーパラメータによる識別性能と比較した。表 1 に変更するハイパーパラメータを示す。また、表におけるフィルタサイズは、前者が一層目、後者が 2 層目のフィルタサイズを表す。

検証では、分類クラス数を 2 から 7 クラスまで変更した場合の性能の変化を検証した。7 クラス分類の場合には、疑似圃場における 0 頭から 6 頭までの模擬牛の分類、6 クラス分類の場合には、疑似圃場に 0 頭から 5 頭まで模擬牛が存在する場合の分類を行った。以降のクラス数が減少する場合には、最大頭数のクラスを削除する方法によりクラス数の減少を行う。また、2 クラス分類の場合には、疑似圃場に模擬牛が存在するか否か、すなわち、0 頭か 1 から 6 頭存在するかの分類を行う。

また、学習率を変化させた場合には性能の変化を検証する。学習率は機械学習のための重要なハイパーパラメータで、学習率が大きすぎた場合には、学習は発散し、小さくしすぎると学習の収束時間が大きくなる。ここでは 6 種類の学習率を利用する。

更に、フィルタサイズの変更を行い、サイズが識別結果に与える影響を検証する。フィルタサイズは、特徴マップを獲得するための重要なハイパーパラメータであり、特徴を捉えるための適切なサイズの設定が求められるものである。

4-3 性能検証結果

基本ハイパーパラメータを用いた 7 クラス分類における識別率は 85.4% であった。識別率が 85% 超えており、良好な識別結果が得られたといえる。

表 1 変更ハイパーパラメータ

| クラス数 | 2~7 クラス |
|---------|--|
| 学習率 | $1.0e^{-4}$, $3.0e^{-5}$, $2.5e^{-5}$, $2.0e^{-5}$, $1.0e^{-5}$, $1.0e^{-6}$ |
| 学習回数 | 400, 500, 600, 700 |
| フィルタサイズ | $3 \times 3 \& 3 \times 3$, $3 \times 3 \& 5 \times 5$, $5 \times 5 \& 3 \times 3$, $5 \times 5 \& 5 \times 5$, $5 \times 5 \& 7 \times 7$, $7 \times 7 \& 5 \times 5$, $7 \times 7 \& 7 \times 7$ |

図 9 にクラス数の変更による識別率の変化を示す。図に示されるように、分類クラスが 6 場合には 87.0%, 5 クラスの場合には 88.4%, 4 クラスの場合には 89.0%, 3 クラスの場合には 91.3, 2 クラスの場合には 96.6% とクラス数の減少と共に識別率が上昇することが示された。本研究では、空撮画像の中に最大 6 頭の模擬牛が存在することを想定した。この結果から 6 頭以上の場合には、識別率が低下することが懸念されるが、空撮の高度調整、または、近年、光学ズーム付きカメラを搭載したドローンも発売されていることから、これらを調整することにより画像内に含まれる最大頭数を減少させることができると考えられる。このため、一定以上の識別率は確保できる可能性は高いものと判断される。

図 10 に学習率を変化させた際の識別結果を示す。図に示されるように学習率 $2.5e^{-5}$ を利用した場合の識別率が最も高い値を示した。この学習率より大きい値である $1e^{-4}$, $3e^{-5}$ を利用した場合には、識別率は共に 14.2% となつた。これは学習が発散し識別率が極端に悪くなつたものである。また、この値よりも値が小さい $2e^{-5}$, $1e^{-5}$, $1e^{-6}$ を利用した場合、識別率はそれぞれ 81.7%, 73.7%, 51.4% となつた。いずれも、 $2.5e^{-5}$ の場合の識別率を下回り、学習率が小さくなるに従って、識別率も低下することが示された。これは、同じ学習回数の設定であるため、学習の収束に時間を要し識別性能が低下していったものである。

図 11 に学習回数の変化による識別性能の



図 9 クラス数による識別性能の変化

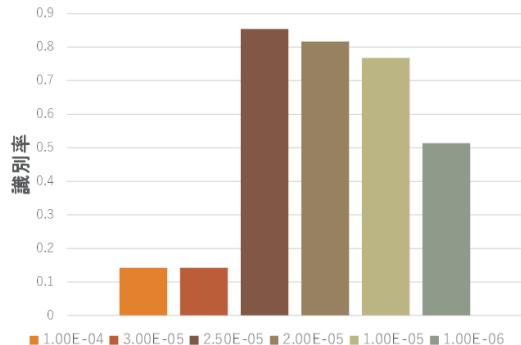


図 10 学習率の変更に伴う性能変化

変化の検証結果を示す。基本ハイパーパラメータである 400 回から学習回数を増加させた場合、500 回で 93.7% と識別率の上昇が見られた。しかしながら、600 回では 92.5%、700 回では 93.1% と、基本性能よりは高い識別率を示したが、識別率の軽微な低下が確認された。学習は 500 回で収束しており、これ以上回数を増加させても識別率の上昇にはつながらないことが確認された。

図 12 に畠み込み層において利用されるフィルタサイズの変更による識別率の変化の検証結果を示す。図 12 に示されるように、基本ハイパーパラメータである 1 層目 5×5 、2 層目 7×7 の場合と比較して、フィルタサイズの変更により多少の識別率の増減が確認された。最も高い識別率を示したのは、2 層とも 5×5 のフィルタサイズを用いた場合で、識別率は 87.7% であった。しかしながら、両層とも 7×7 のフィルタサイズを用いた場合、著しい識別率の低下が確認された。模擬牛一頭当たりのサイズは 2 ピクセル程度であった。このためフィルタが大きすぎ、模擬牛の特徴抽出ができていないためであると考えられる。

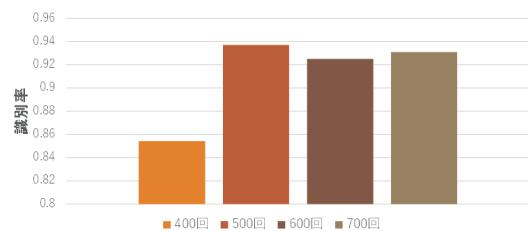


図 11 各学習回数における識別性能

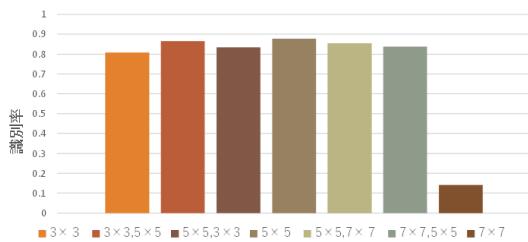


図 12 各フィルタサイズの識別性能

以上の検証結果から、適切なハイパーパラメータ設定を利用した場合、空撮画像からの CNN を用いた疑似圃場における模擬牛の識別結果は 90% を超えており、トイ・プロblem におけるドローンによる家畜管理が実現可能であることが示された。これにより、実際の圃場における家畜管理の実現可能性が示されたと考える。

5. おわりに

本論文では、スマート酪農の実現に向けたドローンによる家畜管理を実現するため、畠み込みニューラルネットによる牛の計数法を提案した。また、提案する CNN を実装し、疑似圃場と模擬牛を用いた識別実験を実施した。更に、CNN におけるハイパーパラメータを変更することにより識別性能にどのような変化が生じるかを検証した。

実験結果から CNN を用いることで疑似圃場の空撮画像からの模擬牛の計数が可能であることが確認された。また、性能検証の結果から、分類クラス数、学習率、学習回数、フィルタサイズのハイパーパラメータ変更により、識別精度が変化することが確認された。最も

適切なハイパーパラメータを利用した場合には、識別性能は 90%を超えることが示された。今後、画像サイズの変更や、CNN における層構成の変更などを行うことにより性能がどのように変化するか検証したい。更には、実際の圃場及び乳牛を利用した識別の実施を行いたい。これらは今後の課題である。

参考文献

- [1] 細川皓平, 川村秀憲 (2016) 「畳み込みニューラルネットワークを用いた人物画像の認識と評価」『情報処理学会第 78 回全国大会』 pp.97-98
- [2] 池田宥一郎, 飯塚博幸, 山本雅人 (2018) 「畳み込みニューラルネットワークによるチンパンジーの個体識別」『第 32 回人工知能学会全国大会論文集』 1B1-OS-11a-05. pp.1-3
- [3] 川村健介, 林志炫, 吉利怜奈, 渡辺也恭 (2018) 「無人航空機を利用した放牧地の管理とその応用に向けた課題」『沙漠研究』 28-1, pp.19-24
- [4] 永木正和 (2016) 「スマート酪農への期待と課題」『畜産の情報』 Vol.317, pp.2-4
- [5] 林野庁「平成 29 年度国有林材の販売に係る収穫調査等の効率化検討委託事業報告書」http://www.rinya.maff.go.jp/j/gyoumu/gijutsu/attach/pdf/syuukaku_ko_urituka-1.pdf (2019 年 11 月 20 日アクセス)
- [6] 利根川凜, 飯塚博幸, 山本雅人, 古川正志, 大内東 (2016) 「被災がれき量推定に向けた畳み込みニューラルネットワークを用いた倒壊建造物の自動抽出」『情報処理学会論文誌』 Vol.57, No.6, pp.1565-1575
- [7] 四つ葉お客様相談室「四つ葉 Q&A」<https://www.yotsuba.co.jp/faq/faqlist/1216.html> (2019 年 11 月 13 日アクセス)