

生成型学習による害獣検出の検討

Study of Destructive Animal Detection using Generative Learning

中坪 希水[†]松村 遼[†]

Nozomi Nakatsubo

Ryo Matsumura

1. はじめに

近年、害獣による農作物への被害が増加している。特にシカやイノシシによる被害は増加傾向にあり、生産者の営農意欲の減少など被害額以上の影響をもたらしている[6]。

これらの害獣による被害への対策として電気柵の設置が行われているが、感電事故なども報告されており、安全管理上の問題も発生している。また、このような侵入防止策は単一獣種のみに対応しているものが多く、多獣種に対応させるためにはさらなる整備が必要となり、運用コストが増大するという問題も存在する。上記のように害獣対策には安全性の確保、運用コストの削減が望まれており、これらの問題を解決することが急務となっている。そこで我々はカメラや音響機器、照明を用いた害獣検出及び撃退システムを構築し、これを害獣対策に活用することを目指す。

カメラによる害獣検出を行うためには、害獣の学習サンプルを大量に収集する必要がある。収集した学習サンプルを用いて高精度な検出器を構築するためには、学習サンプルに多様な見え方の変動を含む必要があり、このようなサンプルの収集は非常に困難となる。そこで、本研究では生成型学習[5]を用いて、この問題の解決を図ることとした。

2. 提案システムの概要

図 1 に提案システムの概要を示す。システムの構成機器は図に示すとおり、コンピュータ、カメラ、スピーカー等の音響機器、照明機器である。カメラより入力される画像から害獣を検出する。害獣が検出されたら、スピーカーなどの音響機器で音を発する、または照明の明滅を繰り返すことによって害獣を撃退する。

本システムにおいて、多獣種に対応させるにはコンピュータに害獣それぞれに対応する検出器を登録するだけで済むため、侵入防止策のように設備更新などの整備が不要で運用コストを削減することができる。

問題となるのは導入コストだが、検出処理・音響再生・照明の明滅制御を行うコンピュータは 1 台で充分であり、カメラも広範囲を監視できるため、設置台数を削減できる。音響機器や照明も適切な場所に設置することによって台数の削減が可能である。

本稿では提案システムの開発にあたり、害獣検出に生成型学習[5]によって構築された検出器を用いる。実際の害獣画像に対して実験を行い、生成型学習による害獣検出が有効であることを示す。

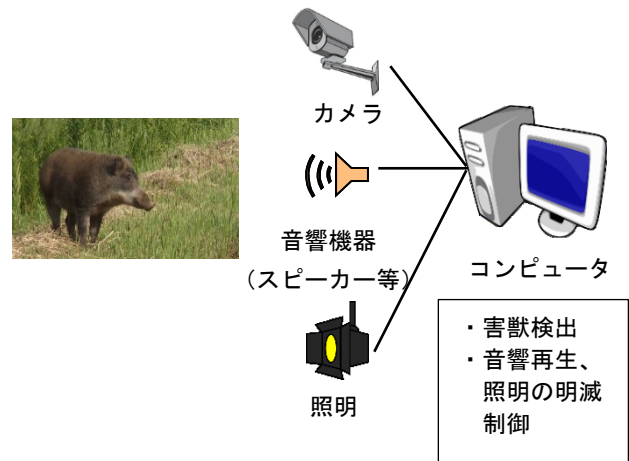


図 1 提案システムの概要

3. 生成型学習

生成型学習[5]とは、少数の学習サンプルから入力データに含まれるような変動を付加した学習サンプルを作成し、これを用いて機械学習により検出器を構築する手法である。

道満らは生成型学習を用い、道路標識の劣化などによる色変動をシミュレーションして、この変動を付加した学習サンプルを生成し道路標識検出器を構築している[4]。土屋らは人物の 3D モデルを作成し、回転などを施した上で画像上に重畳し、人物の学習サンプルを作成している[3]。

本研究では[3]を参考に、害獣の 3D モデルを作成し、これを画像上に重畳して学習サンプルを作成する。

4. 学習サンプルの作成

本稿では、害獣の一種であるイノシシを対象とした学習サンプルを作成する。3D モデルの作成には、Smoothie-3D という Web サービスを利用する。このサービスは画像から容易に 3D モデルを作成することができる。3DCG に習熟していない者でも違和感のない 3D モデルを作成することが可能で、モデル作成にかかる時間を短縮することができる。図 2 に本 Web サービスでイノシシの 3D モデルを作成した例を示す。

作成した 3D モデルに任意の回転を加え、画像上に重畳する。検出を行う際の実環境を考慮し、畑などが撮影された画像上に 3D モデルを重畳することとした。実際に作成した学習サンプルの例を図 3 に示す。図 3(a)がポジティブサンプル、(b)がネガティブサンプルである。

[†] 大島商船高等専門学校 情報工学科




図2 Smoothie-3Dでの3Dモデル作成例



(a) ポジティブサンプル



(b) ネガティブサンプル

図3 作成した学習サンプルの例

5. 実験

作成した学習サンプルを用いて RealAdaboost[2]で学習を行い、検出器を構築した。特徴量には Histograms of Oriented Gradients (HOG)特徴量[1]を使用している。学習サンプルの総数は4,012枚で、内訳はポジティブサンプルが990枚、ネガティブサンプルが3,022枚である。

実験では、評価用のテストサンプルも学習サンプルと同様の切り出した画像を対象とする。内訳はポジティブサンプルが50枚、ネガティブサンプルが408枚である。

検出器の評価にはDETカーブを用いる。DETカーブは横軸に誤検出率 (False Positive Rate)、縦軸に未検出率 (Miss Rate) をプロットした両対数グラフで、カーブが原点に近いほど性能が良いことを表す。本実験では、未検出率と1検出ウインドウあたりの誤検出率を比較した Miss Rate VS False Positive Per Window (FPPW) で評価を行う。

1枚の画像をラスタスキャンして検出を行った場合、検出ウインドウの統合処理によって性能が変化する。生成型学習によって構築された検出器が有効であるかを確認するため、上記の方法を用いた。

図4に実験結果を示す。結果より、誤検出率1.4%のときに未検出率が26%、検出率が95.8%となることがわかった。

6. 考察

検出率が95.8%となり、生成型学習による害獣検出は有効であるといえる。しかし本システムにおいては、誤検出よりも害獣が検出されない未検出のほうが問題となる。未検出率が0%のときに注目してみると、誤検出率15.7%、検出率86%となっており、さらに性能を向上させる必要があるといえる。これは、学習サンプル数をさらに増やすことで対応できると考える。

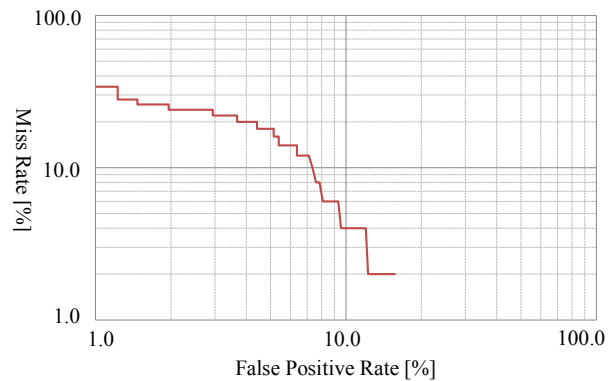


図4 実験結果

また、図3(a)からわかるように、学習サンプルには視点に大きなばらつきがあり、右向き、左向き、正面向きのイノシシのサンプルが混在している。このような視点の違うサンプルがハードサンプルとなり、学習がうまくいかず性能向上の妨げとなっていると考えられる。このことより、学習サンプルの視点を統一し、視点別の検出器を構築することで、さらに性能が向上する可能性があるといえる。

7. おわりに

本稿では害獣検出・撃退システム開発に向け、生成型学習による害獣検出について検討を行った。学習サンプルは、害獣の一種であるイノシシの3Dモデルに任意の回転を加え、画像上に重畳して作成した。作成した学習サンプルを用いて RealAdaboost で学習を行い、検出器を構築した。実際のイノシシ画像を用いた実験により、害獣検出における生成型学習の有効性を確認することができた。

今後の課題として、さらに精度を向上させるため、考察でも述べたように学習サンプル数をさらに増やすこと、視点別の学習サンプルを作成し、それぞれの視点に対応する検出器を構築することが挙げられる。また、イノシシ以外の他の獣種の検出器を構築していく必要もある。

参考文献

- [1] N. Dalal & B. Triggs, "Histograms of Oriented Gradients for Human Detection," *Computer Vision and Pattern Recognition*, pp.886-893, 2005.
- [2] R. E. Schapire & Y. Singer, "Improved boosting algorithms using confidence-rated prediction," *Machine Learning*, vol.37, no.3, pp.297-336, 1999.
- [3] 土屋成光, 山内悠嗣, 藤吉弘, "人検出のための生成型学習と Negative-Bag MILBoost による学習の効率化," *電学論 C* 134.3, pp.450-458, 2014.
- [4] 道満恵介, 出口大輔, 高橋友和, 目加田慶人, 井手一郎, 村瀬洋, "色変動を考慮した生成型学習法による道路標識検出器の構築," *信学論(D)*, 93(8), pp.1375-1385, 2010.
- [5] 村瀬洋, "画像認識のための生成型学習," *情処学論*, 2005.
- [6] 農林水産省, "鳥獣被害対策の現状と課題," http://www.maff.go.jp/j/seisan/tyozyu/higai/pdf/2502_meguji.pdf