

ディープラーニングによる CG と実写の画像判別 Image Recognition of CG and Photographed Image using Deep Learning

1W173094-7 仲 雄司 指導教員 坂井 滋和 教授
NAKA Yuji Prof. SAKAI Shigekazu

概要：近年,コンピュータグラフィックス(以下CG)技術の発達より,実写に限りなく近い画像や映像を制作することが可能となっている.それに伴い,実写とCG画像を直感的に判別することが困難になってきている.本研究は,CG画像と実写画像をディープラーニングの技術を用いて判別学習を行い,人間には分からないそれぞれの違いを判別可能であるか検証したものである.CGと実写の違いを判別できるかどうかを検証したいため,対象物を1種類に固定し,その物体のCG及び,実写画像を用意する.最後に,学習モデルの精度を分析し,出た数値からCGと実写の判別ができているかを考察する.また,CGと実写画像のどの部分から画像判別を行っているのかを知るため,それぞれの画像の特徴量を抽出し,それぞれの類似特徴を検出する.

キーワード：CG, 実写, ディープラーニング, 画像判別,

Keywords: CG, photographed image, deep learning, image recognition

1. はじめに

CG技術の発展によって,現在では様々な分野でCGを用いた映像や画像が用いられるようになり,CGか実写かどうか分からないような映像や画像が現在多く制作されている.

また,ディープラーニングによる画像判別技術も近年発達を続けており,画像処理の分野においてよく用いられている.その際,機械に学習させる時には大量のデータセットが必要となる.[2]しかし,大量の画像データを入手する際,対象物によっては現実で画像を入手する難易度が高いものも数多く存在するため,CG画像を用いることが可能であれば,負担を軽減出来ると考えた.

そこで本研究では,人間には判別できない画像もAIには判別可能なのではないかと考え,画像判別技術において有効であると認められている神経回路モデルのひとつである,畳み込みニューラルネットワーク(Convolutional Neural Network, 以下CNN)を用いたCGと実写画像の判別及び,判別に用いられている部分の可視化を行う.

2. CNNによる画像の識別

本研究で用いるCNNは画像認識のディープラーニングの手法の中でも高い精度を出している.CNNの構造は最初の層から順に,入力層,畳み込み層,プーリング層,全結合層,出力層と呼ばれる層で構成されている.入力層は入力するデータを読み込む層である.全結合層では,プーリング層からの出力をまとめるためのものである.最後の出力層は,全結合層からの出力を元に,活性化関数と呼ばれる関数を用いて確率に変換し,それぞれの領域に正しく分類される確立を最大化することによって分類を行う.[3]

また,類似特徴を抽出するため,AKAZEを用いた特徴量マッチングを行う.特徴点マッチングは,異なる画像間で,固有の点を対応付けることであり,AKAZEは特徴点検出と特徴量記述を行う手法である.他の特徴点検出手法と比べ精度が高く,画像認識の分野において多く使用されている.[4]

3. 実験とその方法

研究の手法は,CNNによる画像判別を用いた

ものである。事前にリンゴの CG 画像 2500 枚と、実写画像 2500 枚を準備し、三つの実験を行う。一つ目の実験では色のついた CG 画像と実写画像の判別学習を行う実験を行う。二つ目の実験では、色による特徴判別のない場合の判別精度を調べるため、実験 1 で用いる画像をグレースケール化し、同様に判別学習を行う。最後に、三つ目の実験では、CG と実写画像のどの部分が特徴として見られ、判別の要素となっているのかを調べるため、AKAZE を用いた実験を行う。

4. 結果

CG と実写画像の訓練用データ及び、検証用データをそれぞれ 2000 枚と 500 枚として学習させた。実験 1 と実験 2 の学習推移は、学習精度 (Validation Accuracy) と誤差 (Validation Loss) の値を示したグラフから判断する。

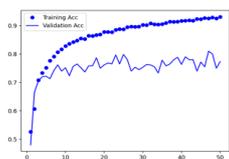


図 1 学習精度 (色付き)

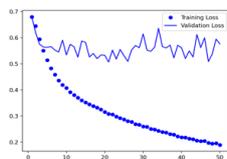


図 2 学習誤差 (色付き)

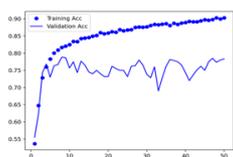


図 3 学習精度 (モノクロ)

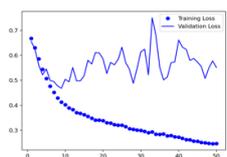


図 4 学習誤差 (モノクロ)

実験 3 では、色付きとグレースケール化した画像の特徴量マッチングの結果が検出できた。

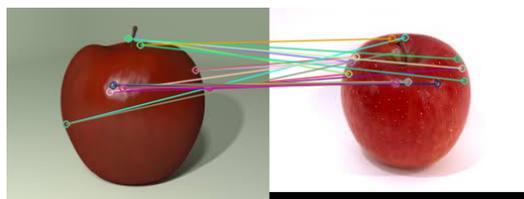


図 5 色付き画像の抽出された類似特徴

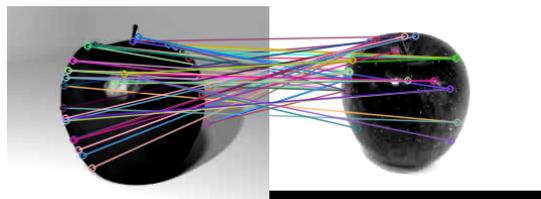


図 6 グレースケール化画像の抽出された類似特徴

図 5, 図 6 からわかるように、特徴量が分散していればしている程、二つの画像は全体的にマッチングしていることを示し、特徴点の一部に偏っていれば、その部分にマッチング状況が良好なものが集中していることを示している

5. 考察

以上のことから、グレースケール化した画像の学習推移は色付き画像の学習推移よりも安定性の低い結果となり、色付きの画像の判別学習の方が精度の高い学習を行っていることが分かった。これは類似特徴の特徴点の量がグレースケール化画像の方が多いためであり、その結果、色付きの CG と実写画像の判別の方がそれぞれの画像の色合いの違いを識別できていることを示した。これにより、CG と実写の判別は可能であるが、形状の類似度に影響することが推測される。

参考文献

- [1]伊藤 穰, CG 技術と映像表現 一二つの日常化一, 跡見学園女子大学機関リポジトリ, 2013, <https://ci.nii.ac.jp/naid/110009605167>
- [2]原田 達也, 機械学習と大規模データによる画像認識, 電気学会論文史 C, Vol.136 No.3 pp.245-248
- [3]村上研究室 コラム/ニューラルネットワーク, <http://ipr20.cs.ehime-u.ac.jp/column/index.html>
- [4]小野 美沙, 吉岡 理文, 柳本 豪一, 井上 勝文, 真相学習を用いた歩行状態推定における活性化関数の検討, 平成 27 年電気学会電子・情報・システム部門大会講演論文集, pp669-674, 2015