

ディープラーニングを用いた風景画像中の人工物領域の特定

砂川皓 長名優子

東京工科大学 コンピュータサイエンス学部

1 はじめに

風景画像を対象とした類似画像検索において、人工物の有無を判定し、人工物領域を特定することができれば検索精度の向上が期待できると考えられる。文献[1]ではRBF (Radial Basis Function) ネットワーク[2]を用いて約95%の精度で人工物領域の特定を実現している。RBF ネットワークでは、初期値の設定や学習の仕方により最終的に求まる解が異なるため無数の局所解が存在する。このため、局所解への収束を避け、高い汎化能力を実現するのが難しい。また、文献[3]ではサポートベクトルマシン[4]を用いて、学習に用いていないデータに対する識別能力を高くすることで、約95%の精度で人工物領域の特定を実現している。サポートベクトルマシンでは、赤みの帯びた岩など通常の状況とは異なる色をしている領域に対して正しい判断をすることが難しい。

これに対し、多層構造のニューラルネットワークであるディープラーニング[5]では、画像認識などにおいて有効性が確認されている。画像に含まれるオブジェクトを認識するものであり、画像中の各領域に対する認識はほとんど行われていない。また、これらは画像1枚を分割せず行っている。そこで、画像を分割し、領域ごとに人工物領域の判定を行うことでより精度向上が期待できる。本研究では、ディープラーニングを用いた風景画像中の人工物領域の特定を提案する。

2 畳み込みニューラルネットワーク

畳み込みニューラルネットワークは、ディープラーニングにおける手法の一つであり、主に画像認識に利用されている。このモデルでは、自動的に特徴量を抽出することができ、事前に色やエッジなどの特徴量を抽出する必要がない。

図1は畳み込みニューラルネットワークの一般的な構造を表したものである。畳み込み層とプーリング層がペアになっており、この順に並んだペアが複数回繰り返される。ただし、図1のように畳み込み層のみが




図1: 畳み込みニューラルネットワークの構造

複数回繰り返され、プーリング層を1層重ねることもある。畳み込みニューラルネットワークを他クラス分類に用いる場合には、最後に全結合層を経て、ソフトマックス層から入力された画像に対する各カテゴリの尤度が出力される。

畳み込み層は、データとフィルタ間の積和の計算であり、データにフィルタと似た濃淡構造があるとき畳み込み層のニューロンが活性化する。フィルタはニューラルネットワークの重みに対応している。この計算によって、畳み込み層は特徴的な濃淡構造を抽出する働きがある。プーリング層は、通常畳み込み層の直後に設置される。プーリング層のニューロンは局所受容野を持っており、フィルタの表す特徴の位置感度をわずかに低下させる働きがある。

3 畳み込みニューラルネットワークを用いた風景画像中の人工物領域の特定

提案手法では、画像を K 平均法[6]を用いて領域分割し、分割された各領域に対して人工物が含まれているか否かの判定を行う。提案手法において、領域ごとの人工物の有無の判断は以下の手順で行う。

Step 1: K 平均法を用いて領域分割を行う。

Step 2: 各領域に対して畳み込みニューラルネットワークを用いて人工物領域があるかを判定する。

3.1 K 平均法による領域分割

K 平均法を用いて画像を分割する。手順を以下に示す。

Step 1-1: K 個のデータをランダムに選び、クラスタの中心とする。




図 2: 領域以外に塗りつぶしを行った画像

Step 1-2: すべてのデータに対し, 各クラスタの中心との距離を求め, 距離が最小となるクラスタを各データに割り当てる.

Step 1-3: 各クラスタに対し, そのクラスタに属するデータの平均値を求め, それをクラスタの中心とする.

Step 1-4: クラスタ中心が更新されるクラスタが存在しなくなるまで Step 1-2, 1-3 を繰り返す.

領域分割を行う際には, データとして画素ごとの色情報 (HSV 表色系) と座標を使用する. そのため, 画素, 位置情報を考慮した上で, 色情報に基づいて領域分割ができる. 領域分割を行う際にクラスタ数が少ないと 1 つの領域に人工物と自然物の両方が含まれてしまう可能性が高くなる. 提案手法では, クラスタ数を多めに設定することでそのような問題が発生しないようにしている.

3.2 畳み込みニューラルネットワークを用いた人工物領域の判定

図 1 のような構造の畳み込みニューラルネットワークに認識対象となる領域以外を塗りつぶした図 2 の右のような画像を入力し, 入力された領域のクラスを出力するように学習を行う. クラスは, 人工物または自然物, もしくは雲, 空, 道などの特定物のラベルである. 出力層では, ソフトマックス層を用いてクラス分類を行う. 出力層は, 分類したいクラス数 N と同数のニューロンから構成されており, ソフトマックス層の出力 y_n は

$$y_n = \frac{\exp(u_n)}{\sum_{i=1}^N \exp(u_i)} \quad (1)$$

のように求められる. ここで, u_n はニューロン n の内部状態を表している. ソフトマックス層では式 (1) のようなソフトマックス関数により出力を決定するため, N 個のニューロンの出力の和は 1 となる.

4 計算機実験

提案手法の有効性を示すために計算機実験を行った. 図 3, 4 に提案手法と従来手法 [4] において人工物領域の判定を行った結果を示す. 図 3, 4 において赤で示



(a) 原画像 (b) 従来手法 (c) 提案手法

図 3: 判定結果 (1)



(a) 原画像 (b) 従来手法 (c) 提案手法

図 4: 判定結果 (2)

した領域は人工物であると判定された領域である. 提案手法の方が適切に人工物を判定できていることが分かる.

参考文献

- [1] 藤崎豪人, 長名優子: “RBF ネットワークを用いた風景画像中の人工物領域の判定における SIFT, LBP の利用による判定精度の向上,” 情報処理学会第 77 回全国大会, 2015.
- [2] J. Moody and C. J. Darken: “Fast learning in networks of locally tuned processing units,” *Neural Computation*, Vol.1, pp.281–294, 1989.
- [3] 福田孝真, 長名優子: サポートベクトルマシンを用いた風景画像中の人工物領域の判定, 情報処理学会第 77 回全国大会, 2016.
- [4] 阿部重夫: パターン認識のためのサポートベクトルマシン入門, 森北出版, 2011.
- [5] 岡谷 貴之: 深層学習 (機械学習プロフェッショナルシリーズ), 講談社, 2015.
- [6] J. B. MacQueen: “Some methods for classification and analysis of multivariate observations,” *Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability*, Vol.1, pp.281–297, University of California Press, 1967.