

畳み込みニューラルネットワークを用いた 夜間全天画像からの雲領域検出

佐久間惇一[†] 井上中順[†] 篠田浩一[†]
 谷津陽一[†] 吉井健敏[†] 河合誠之[†] 下川辺隆史[†]
 東京工業大学[†]

1. 背景・目的

天文学は望遠鏡の大型化によって、より詳しく、より遠くまで観測することで発展してきた。この流れを変えたのが計算機と情報通信技術である。2000年以降、インターネットとロボット望遠鏡の連携による突発天体観測が世界中で行われるようになり、「時間領域天文学」という全く新しい学問領域が形成されつつあり、米国においては今後10年間の重点科学領域と認識されている。その最も象徴的なターゲットは昨年人類が初めて発見した重力波天体である。数百平方度にも及ぶ広い誤差領域から、重力波発生に伴う可視光放射を短時間に効率よく探し出すためには、人間の手を借りずに自律的に、かつシステムティックに探索を行う必要がある。

このような自動観測実現の障壁となるのが、観測所での天候である。日本のように天候の変化が早く快晴夜の少ないところで効率よく広い天域をカバーするためには、雲のない点域を選びながら望遠鏡を向ける必要がある。そこで、全天カメラで撮影された画像を用いて、雲が存在する領域を検出し、天体観測可能な領域と不可能な領域を分割する技術が必要となる。

日中の全天画像からの雲領域の検出は、赤と青の画素値の比を利用する方法[1]が効果的であるが、夜間の画像には適用できない。一方、画像認識の分野では、物体領域検出のための畳み込みニューラルネットワークを用いた手法が提案されている[2,3]。これらは深層学習の枠組みに基づいており、全天画像においても有効であると期待できる。

そこで、本研究では、夜間の全天画像における雲領域と晴天領域を検出する畳み込みニューラルネットワークを提案する。

Cloud Detection for Night All-Sky Images Using Convolutional Neural Networks

Junichi Sakuma[†] Nakamasa Inoue[†] Koichi Shinoda[†]
 Yoichi Yatsu[†] Taketoshi Yoshii[†] Nobuyuki Kawai[†] Takashi Shimokawabe[†]

Tokyo Institute of Technology[†]

ラルネットワークを提案する。

2. 関連研究

日中の全天画像から雲領域を検出するには、画像の画素値に基づく方法が広く用いられている。例えば、Longら[1]のシステムでは赤と青の画素値の比にしきい値を設けて雲の領域を検出している。しかし、この方法では日中の空や雲の色がはっきりと見える状態を前提としており、夜間の画像のように、空と雲の色の差が少ない画像には効果的ではない。

画像の物体領域の識別には主に畳み込みニューラルネットワークが用いられる。特に、Conditional Random Fields as Recurrent Neural Networks (CRF-RNN) [2]が、画像の物体領域分割に関するベンチマークである Pascal VOC 2012 Challengeにおいて高い成績を収めている。CRF-RNN は 16 層の畳み込みニューラルネットワークであるが、パラメータの数が多く、計算量も多い。そのため、GPU の使用メモリサイズ及びファイルサイズが大きくなってしまい、天文台や人工衛星で用いられる計算機には適していないという問題がある。

3. 提案手法

夜間全天画像中の雲や空は、一般的な物体認識で対象となる物体と比較してエッジやテクスチャといった特徴が少なく、また、識別すべきクラス数も 2 つと少ない。そのため、ネットワークもそれに用いられるものよりも単純なものであっても正確に領域分割できると考えられる。

そこで、[2]の CRF-RNN のネットワークから層数やパラメータ数を減らし、計算量を削減する。16 層の畳み込み層と 5 層のプーリング層を、それぞれ 3 層と 1 層に減らし、また、途中の結合する層や、条件付き確率場の処理を行う層も除外した。削減前後の構造を図 1 に示す。

4. 評価実験

実験に用いる画像は、山梨県の明野観測所に

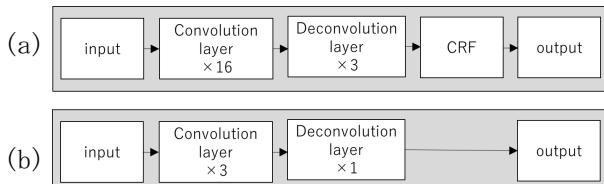


図 1 CRF-RNN(a)と提案ネットワーク(b)の構造

ある、望遠鏡から約5m離れた地点に設置している全天カメラで撮影されたものである。画像枚数は1,000枚で、異なる日時に撮影されたものである。図2に示すように、正解ラベル画像が付与されている。ネットワークの学習では、ランダムに選択した900枚の画像を用い、残りの画像はテスト用とする。元の画像サイズは2762×2762であるが、CRF-RNN[2]の構造に合わせて、トリミング及びリサイズを行い、500×500に縮小させる。

実験に用いるCRF-RNNは、事前にPascal VOC 2012 datasetで事前学習されたものを、前述の全天画像でファインチューニングしたものである。また、提案ネットワークはパラメータをガウス分布に基づいてランダムに初期化し、全天画像のみで学習している。

評価尺度は、出力ラベル画像と正解ラベル画像をピクセル単位で比較し、ラベルが一致したピクセルの割合である。これを正解精度(Accuracy)と呼ぶ。

結果は表1の通りである。提案ネットワークでは、メモリサイズ、ファイルサイズを大きく削減しながら正解精度を保つことに成功している。これは、前節で述べた通り、全天画像中の特徴量やクラス数が少ないため、層やパラメータ数が少ない提案ネットワークでも十分に画像特徴の表現ができるためであると考えられる。また、CRF-RNNと比較して提案ネットワークの方が精度が良いのは、パラメータ数が少ない分、過学習しにくいためと考えられる。

また、図3は提案ネットワークの出力において領域検出の精度が高い画像と低い画像の例である。図3(b)のように明け方で、厚い雲が一面青くなっている場合や、薄い雲で空が白んでいる場合は雲の検出が難しい。

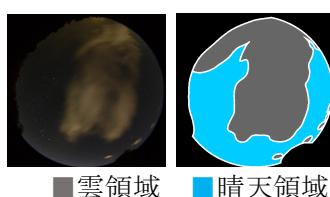


図 2 全天画像(左)とその正解画像(右)

	Accuracy	Memory size	File size
CRF-RNN[2]	0.91	4350MB	537MB
Ours	0.93	249MB	26MB

表 1 実験結果

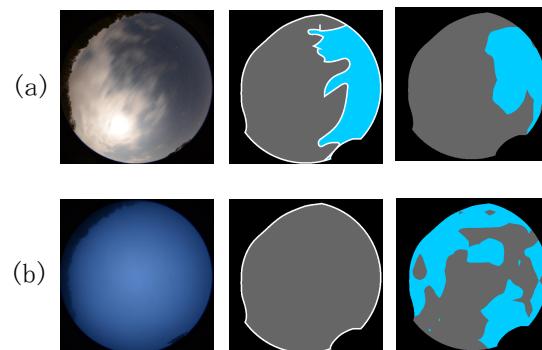


図 3 成功例(a)と失敗例(b)。左から、入力画像、正解画像、提案法の出力。

5. 結論・今後の課題

本研究では、全天画像から雲領域と晴天領域を分割する畠み込みニューラルネットワークを提案し、全天画像1,000枚を用いて実験を行った。その結果、提案ネットワークでは、既存の物体認識用のネットワークと比較して、同程度の精度を持ちながら、メモリサイズ及びファイルサイズを削減することができた。

今後の課題としては、障害物や水滴などの雲以外の物体の識別、また、雲の厚さに基づいた段階的な識別がある。

参考文献

- [1] C. N. Long, et. al, "Retrieving cloud characteristics from ground-based daytime color all-sky images." Journal of Atmospheric and Oceanic Technology, vol 23, no.5, pp. 633–652, 2006.
- [2] S. Zheng, et. al, "Conditional random fields as recurrent neural networks." Proceedings of the IEEE International Conference on Computer Vision, pp. 1529–1537, 2015.
- [3] J. Long, et. al, "Fully convolutional networks for semantic segmentation." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 3431–3440, 2015.