

畳込みニューラルネットワークを利用した デジタルカメラ画像からの雲物理量推定手法の開発

増田 涼佑[†] 岩渕 弘信[†] K. Sebastian Schmidt[‡] 工藤 玲[§]

東北大学大学院理学研究科[†]/ コロラド大学ボウルダー校[‡]/ 気象研究所[§]

1. はじめに

近年、再生可能エネルギーの中でも特に太陽光エネルギーを利用した発電割合が日本では急増している。それに伴い、太陽光発電量予測技術への期待が高まっているが、これを正確に予測するためには正確な雲物理量を予め推定しておく必要がある。特に重要と言われている雲物理量に全天域の雲光学的厚さがある。雲光学的厚さとは太陽放射に対する雲層の不透明さの程度を示す尺度であり、気候変動を議論する際にも頻繁に使用される物理量である。一般に雲光学的厚さが大きいと、雲の不透明度が増す。全天域の雲光学的厚さを地上観測から推定する試みは現在のところ先行研究1つのみであり、その研究では、雲量が小さい時に推定誤差が大きくなることが示されている[1]。これは、3次元放射効果の影響を受けていると考えられる。3次元放射効果とは例えば、雲の側面で入射光が反射し、その反対側で暗くなる現象など、入射光が3次元的に散乱されることで生じる複雑な効果であり、雲量が小さい時に起こりやすい。この3次元放射効果をシミュレーションできる3次元放射伝達モデルが存在するものの、計算コストが非常に高く、即時推定を要する研究には不向きであることから、文献[1]も含めて従来の雲物理量推定手法では近似化された1次元放射伝達モデルを使用している。

このように、物理学に基づいた手法では3次元放射効果を取り扱うことが困難であるため、本稿では畳込みニューラルネットワーク(CNN)とデジタルカメラ画像を利用して、3次元放射効果を考慮した全天域の雲光学的厚さを推定する手法を提案する。

2. 学習データ作成

本研究の目的に適するデータセットが存在しないため、物理モデルを用いたシミュレーション

により事前に学習データの作成を行った。本研究では、RGBの3チャンネルを持つカメラ画像と画像上の太陽と各画素の位置関係を画像にした1チャンネルの計4チャンネルを入力とし、入力と同サイズの雲光学的厚さの分布画像を出力とした学習データを作成するために、3次元放射伝達モデル(MCARaTS)とSCALE-LES高解像度雲データを用いて放射伝達を3次元的にシミュレーションし、これら入出力画像を作成した。なお、モデルで計算されるのはRGBデジタル値ではなくRGB放射輝度値であるので、事前に観測カメラ画像もRGB放射輝度値に変換できるように積分球で校正をした。本研究では、様々な雲データを使用して、学習データを103680組、テストデータを11520組作成した。図1には学習データの一例を示す。




図1 学習データの一例。(a)RGB放射輝度合成画像、(b)太陽と各画素の位置関係画像、(c)雲光学的厚さ分布画像。

3. 学習モデルの構築と学習

本研究では、セマンティックセグメンテーション用に開発された深層学習モデルである、PSPNet(Pyramid Scene Parsing Network)[2]を参考にして学習モデルを構築した。入力を4チャンネル、出力を1チャンネルとした。本研究で扱う問題は回帰問題であるため、出力層の活性化関数は恒等写像とした。PSPNetは中間層に4種類の平均プーリングを使用しており、これによって様々なスケールの雲を高精度に推定することが可能であると考えられる。最適化手法はAdamを、誤差関数には平均二乗誤差を使用し、計1000エポックの学習を行った。

4. テストデータによる性能評価

学習済みモデルを実観測データに適応する前

Development of a method for cloud physical property retrieval from digital-camera image using deep convolutional neural network
[†]Ryosuke Masuda, [†]Hironobu Iwabuchi, [‡]Konrad Sebastian Schmidt, [§]Rei Kudo
[†]Graduate School of Science, University of Tohoku/ [‡]University of Colorado, Boulder/ [§]Meteorological Research Institute

に、テストデータを用いて性能評価を行なった。図2には、テストデータと学習済みモデルからの出力画像の一例を示す。雲光学的厚さの値や雲の位置が正確に推定されていることが確認出来る。




図2 テストデータと出力画像の一例。(a)テストデータのRGB放射輝度合成画像, (b)テストデータの雲光学的厚さ分布画像, (c)学習済みモデルから出力された雲光学的厚さ分布画像。

次に、定量的な評価をするために、各雲光学的厚さに対しての相対誤差を計算した。その結果を図3に示す。図3からは、光学的厚さが小さい雲に対しては誤差のばらつきが大きくなるが、バイアス誤差は小さいことが確認された。本稿には示さないが、雲量が小さい時の方が誤差のばらつきが大きいことが確認されている。以上のことから、学習済みモデルは、考慮しきれていない3次元放射効果があるものの、従来の研究[1]よりも精度良く推定が出来る「可能性」を示した。




図3 雲光学的厚さ(Truth COT)と相対誤差(Relative Error)の関係図。

5. 実観測データへの応用

テストデータによる性能評価を受けて、実際にデジタルカメラで撮影した画像を学習済みモデルに入力して、その結果を確認した。図4にその結果の3例を示す。




図4 実観測データへの適応例。(a,b,c)RGB放射輝度合成画像, (d,e,f)推定雲光学的厚さ分布図。

図4(d)は定性的には良い結果を示している。これは図4(a)のような雲場が学習データに含まれているために表現できているものと考えられる。図4(e)は太陽周辺でフレアが起り、太陽周辺が図4(b)のように白っぽくなってしまふことにより、晴天域を雲域と判断している。このフレアに関しては学習データで考慮していないために対応出来ていないと考えられる。図4(f)は雲光学的厚さを過大評価している。これは図4(c)のような薄い雲(巻雲または巻層雲)が学習データに含まれていないために対応出来ていないと考えられる。以上のように、学習済みモデルは、学習データに含まれている雲に関しては定性的には良い結果を得ることが出来た。今後は、他手法との比較と、学習データの補充を行なって、実観測データへの適応可能性を定量的に判断していく。

謝辞

本研究では東京大学情報基盤センターが所有するスーパーコンピュータ Reedbush を利用して学習データ作成並びにモデル学習を行いました。学習データ作成の際に用いた SCALE-LES 高解像度雲データは、理化学研究所 SCALE チームから提供を受けました。本研究は科研費(課題番号 17H02963)による支援を受けて行いました。

参考文献

- [1] Mejia, F. A., Kurtz, B., Murray, K., Hinkelman, L. M., Sengupta, M., Xie, Y., & Kleissl, J. (2016). Coupling sky images with radiative transfer models: a new method to estimate cloud optical depth. *Atmospheric Measurement Techniques*, 9(8), 4151-4165.
- [2] Zhao, H., Shi, J., Qi, X., Wang, X., & Jia, J. (2017, July). Pyramid scene parsing network. In *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)* (pp. 2881-2890).