

教師なし機械学習を用いた 金星の雲のクラスタリング: Mittendorf et al. (2024) の紹介

流体地球物理学教育研究分野

本間 友子


目次

1. はじめに
2. 使用するデータセット
3. 手法
4. 結果
5. まとめ

1 はじめに

1-0. 金星の雲

- 金星の高度約 45 ~ 70 km には, 全球を覆う雲が存在する
- 可視光で観測したときには特徴がないが, 紫外線で観測したときにはさまざまなスケールの特徴が現れる
 - 雲の厚さや紫外線反射物質の分布による, 紫外線の反射度を表す
- この特徴は雲層以下の大気の運動や, 大気と雲層表面との相互作用で変化する
- そのため, 特徴自身の形や, 時間発展を調べることで金星大気の気候システムや, 力学過程の理解を深めることにつながる



1-1. 論文の背景

- 金星の雲を研究するときには, それぞれのスケールごとに特徴の分類 (クラスタリング) を行う必要がある
- しかし, 手動でクラスタリングを行うと様々な問題が生じる
 - 対象となる領域が, 時間的, 空間的に限られる
 - 個々人の主観によって, 分類の不一致が生じる
- そこで自動的, かつ客観的にクラスタリングを行うアプローチが必要である
 - 機械学習, 特に教師なし機械学習に着目する

1-2. 機械学習の概要

- (本間が勉強中の内容のため不確実な部分を含む)
- 経験的に学習を行い, 入力データを処理する過程を自動で更新するアルゴリズムのこと
 - 学習データを用いてある学習結果を取得
 - 学習結果をもとにタスクを実行することが最終的な目標
 - クラスタリング (入力データ全体からいくつかの分類に分けるタスク)
 - 分類問題 (入力データを指定されたカテゴリーに分類するタスク)
 - etc...
- 主に教師あり学習, 教師なし学習, 強化学習(説明しない) がある

1.3 教師なし学習の概要

- (本間が勉強中の内容のため不確実な部分を含む)
- 教師あり学習
 - 学習データに『タスクに対する正解』となる指標 (ラベル) が付与されている
 - 学習モデルを通して, 正解に近づくように学習を重ねる
- 教師なし学習
 - 学習データにラベルがついていないもの
 - 学習モデルを通し, 入力データそのものの構造やパターンを取得するように学習を重ねる
 - 惑星科学分野では, ラベル付けされたデータの入手が困難であり, 他の惑星の特異性ゆえに既存の基準での分類が困難である (論文内の記述)
 - そのため教師なし学習の方が適している

1.4 論文の目的

- 本研究では, 教師なし機械学習を用いて金星の雲の特徴をクラスタリングする手法を開発することを目的とする
 - 画像データから雲パッチを生成
 - 畳み込みニューラルネットワーク (CNN) を用いて特徴ベクトルの抽出
 - 特徴ベクトルをベクトル空間へ投影
 - ベクトル空間上でクラスタリング


2. 使用するデータセット

2. 使用するデータセット

- 金星を撮影した 2 つのデータセット
- それぞれの紫外線画像を使用したクラスタリングを行う
 - Venus Express (VEX) の Venus Monitoring Camera (VMC) 画像データセット
 - あかつきの紫外イメージャ (UVI; Ultra Violet Imager) 画像データセット
- 地球の雲画像データセット
- クラスタリングの精度の指標として利用
 - Cloud-ImVN 1.0


2-1. VEX の VMC 画像データセット

- ESA (欧州宇宙機構) によって提供されている
- 特に紫外線 (波長 365 nm) 画像に着目する
- 以下の 2 つのファイルから構成される
 - 校正済みの画像データファイル
 - 画像の各ピクセルに対応する幾何学情報ファイル
 - 緯度
 - 経度
 - 入射角
 - 射出角
 - 位相角
 - (時刻)





(a) Venus Express VMC

2-1-1. 入射角, 射出角, 位相角の関係



2-2.あかつき UVI 画像データセット


- JAXA, ISASによって提供されている
- 以下の2つのファイルから構成される
 - 校正済み画像データファイル
 - 画像の各ピクセルに対応する幾何学情報ファイル
 - 緯度
 - 経度
 - 時刻
 - 入射角
 - 射出角
 - 位相角



(b) Akatsuki UVI

2-3. Cloud-ImVN 1.0

- [Hoang \(2020\)](#) によって提供される
- 地球の雲画像データセット
- 6つのクラスに分類されている
 - Clear sky
 - Patterned clouds
 - Thin white clouds
 - Thick white clouds
 - Thick dark clouds
 - Veil clouds
- 150×150 pxの画像が 2100枚 (各クラス 350 枚)
- クラスタリング精度の指標として利用




3. 手法

- クラスタリングまでの手順
 - 画像データから入力用データを生成
 - 着目するスケールの大きさに合わせた正方形の画像
 - 雲パッチ (もしくはパッチ) と呼ぶ
 - 畳み込みニューラルネットワーク (CNN) を用いた特徴ベクトルの抽出
 - ベクトル空間上でクラスタリング
- 入力用データ (パッチ) の生成手順の説明
- クラスタリングに使用するアルゴリズムの紹介


3-1 パッチ生成

- ① 事前処理
- データセット内の画像に対し, 適切なパッチを生成するための事前処理を行う
- 画像内の雲部分のみを使用するため, 画像から Invalid ピクセルを取り除く
 - Invalid ピクセル: 無効なピクセルのこと
 - 背景の空白部分や, 観測できてなかった部分が該当する

Original




1. Invalid pixel removal




3-1 パッチ生成

- ① 事前処理
- 次の段階での処理の精度を上げるために、入射角が 90° 以上, もしくは射出角が α 以上となるピクセルを取り除く
 - 画像データ上で陰になっているところと, 画像データの端に部分にあたる
 - α はパラメータ

1. Invalid pixel removal




2. Angle-based removal




3-1 パッチ生成

- ① 事前処理
- 惑星の形状によって明るくなっている部分を補正する
 - 画像から得られる輝度を,
惑星表面を真上から観測したとき（天底観測を行ったとき）の輝度にする
- Minnaert 補正 (Minnaert (1941)) を使用する

2. Angle-based removal



3. Normalization



3-1-1 Minnaert 補正

- Minnaert(1941) では, 観測される輝度は以下の式で表される

$$I(\mu, \mu_0) = I_0 \times \mu^{k-1} \mu_0^k$$

- $I(\mu, \mu_0)$: 観測されている輝度
- I_0 : 天底観測をした時の輝度
- μ : 射出角の余弦
- μ_0 : 入射角の余弦
- k : Minnaert 係数 (と呼ぶ)

3-1-1 Minnaert 補正

$$I(\mu, \mu_0) = I_0 \times \mu^{k-1} \mu_0^k$$

$$I\mu = I_0 \times (\mu\mu_0)^k$$

$$\log(I\mu) = \log(I_0) + k \log(\mu\mu_0)$$

- 3 式目より, $\log(I\mu)$ と $\log(\mu\mu_0)$ の線形回帰より k を求めることができる
 - どちらも, 画像のデータ, もしくは幾何学情報から得られる


3-1 パッチ生成

- ① 事前処理
- 補正式は以下の通り


$$I_{\text{norm}} = \frac{I(\mu, \mu_0)}{\mu^{k-1} \mu_0^k}$$

- I_{norm} : 惑星表面を真上から観測したときの輝度
- $I(\mu, \mu_0)$: 画像データ上での輝度
- μ : 射出角の余弦
- μ_0 : 入射角の余弦
- k : Minnaert 係数
 - $\log(I\mu)$ と $\log(\mu\mu_0)$ の線形回帰より求められる

2. Angle-based removal




3. Normalization




3-1 パッチ生成

- ① 事前処理
- 僅かに輝度が変わる特徴が見えなくなっているため、外れ値を持ったピクセルを取り除く
 - 3×3 の中央値フィルターをかける
 - 輝度が $t_0 \times \sigma_d$ 以上のピクセルを取り除く
 - t_0 : 任意のパラメータ
 - σ_d : 輝度の標準偏差


3. Normalization



Before outlier
removal




After outlier
removal



Pixel value

3-1 パッチ生成

- ② 球面へのマッピングとパッチの中心の選択
- 幾何データを用いて, 3次元球上に画像を投影する
- (以下の作業内容が分からなかった)
 - To improve the spacing between the patches and to ensure that even close-up images of the planet that only produce small sections of the sphere on the scale of the patches themselves always have at least one virtual camera viewpoint in their center, the 3D sphere is rotated along the z- and y-axis so that the median vector of all points lies directly on the x-axis.




3-1 パッチ生成

- ② 球面へのマッピングとパッチの中心の選択
- 天底観測を行う仮想のカメラを考える
- カメラの視点が格子点となる格子を考えるとき、格子間隔が以下の式になるように格子点を生成する


$$\Delta\phi_v = \Delta\theta_v = 2 \arcsin \left(\frac{s_p}{2R_{pl}} \right)$$

- $\Delta\phi_v, \Delta\theta_v$: 視点格子間隔
- s_p : パッチサイズ (=スケール)
- R_{pl} : 惑星半径
- 生成した視点のうち、データポイント領域上にあるものを、生成したいパッチの中心とする



3-1 パッチ生成

- ③ 平面への投影と数密度確認
- 視点が生成された後, 再度 3 次元球を回転させ, それぞれの視点を $(1, 0, 0)$ に合わせる
- 中心から y, z 方向に $1/2 s_p \times 1.5$ 以内の距離のデータポイントを選択し, y - z 平面の上の二次元画像を取得する




3-1 パッチ生成

- ③ 平面への投影と数密度確認
- 画像データポイント数が少ない二次元画像を取り除くための数密度確認を行う
- 各画像のデータポイント数 N_p に対し

$$N_{p,min} = \rho_{p,min} \times r_p^2 \times 1.5^2$$

より小さい場合, その画像を取り除く

- $\rho_{p,min}$: 任意の数密度パラメータ
- r_p : 解析を行うスケールのパッチの一辺が持つピクセル数 (≡ 解像度)
 - 現在の画像はパッチサイズの 1.5 倍である



3-1 パッチ生成


- ③ 平面への投影と数密度確認
- 大きな空白部分が存在する画像を取り除くための数密度確認を行う
- 各画像を $n_{\text{bin}} \times n_{\text{bin}}$ 個のビン (小さい領域) に分割し, その内部のデータポイント数を N_{bin} とする

- N_{bin} が

$$N_{\text{bin},\text{min}} = \rho_{\text{bin},\text{min}} \times \left(\frac{r_p}{n_{\text{bin}}} \right)^2$$


を下回るとき, その画像を使用しない

- $\rho_{\text{bin},\text{min}}$: 任意の数密度パラメータ



3-1 パッチ生成

- ④ データの補完
- 視点移動を行うときに拡大を伴うため、一部でデータが存在しない格子点が生じる (左図)
- これを埋めるために補完を行う (右図)




3-1 パッチ生成

- ⑤ flattening と standardization
- 理論上省略可能であるが, flatteningとstandardizationを加えた
- 画像細部の明瞭化するために flattening を行う
 - Gaussian blur(ぼやかす処理)を加えた画像を元の画像から引くことで得られる
- コントラストの増幅するために standardization を行う
 - 各ピクセルの輝度の値から, 平均値を引き, 標準偏差で割る




3-2 アルゴリズムの紹介

- 基礎となるモデル
- ResNet-18
 - 画像認識用畳み込みニューラルネットワーク (CNN) の一つ
 - 使用例
 - 画像分類 (教師あり学習)
 - 犬か猫か鳥か
 - ロゴが含まれているか
 - 特徴ベクトルの抽出 (教師なし学習)
 - A と B の画像は似ているか (類似度計算)
 - C と D の画像は同じグループに属するか (クラスタリング)



3-2 アルゴリズムの紹介


- 最適化のための学習アルゴリズム
 - SimCLR
 - 画像分類のための CNN 用学習アルゴリズムの一つ
 - 入力画像が
 - 同じ画像のとき, 抽出される
特徴ベクトルの一致度を最大化する
 - 違う画像のとき, 抽出される
特徴ベクトルの一致度を最小化する
- ように畳み込み層の重みを変えていく




[SimCLR \(A Simple Framework for Contrastive Learning of Visual Representations\) #Python - Qiita](https://qiita.com/DeepTama/items/c63f5087f4c1aabbccddf) より
(<https://qiita.com/DeepTama/items/c63f5087f4c1aabbccddf>)

手法（クラスタリング）


- クラスタリングのためのアルゴリズム
- HAC（階層型クラスタリング）
 - 最も似ているもののポイントを一つのクラス（固まり）としてまとめる
 - 上の作業を, 指定した数のクラスを作るまで, もしくは指定の回数まとめる作業を行うまで繰り返す
 - 最終的に生成されたクラスタ = クラスとする




(a)



(b)



(c)



(d) 32



4. 結果

4. 結果

- Cloud-ImVN 1.0
- 金星の雲画像データセットにおけるクラスタリング
 - 3 種類のスケールの雲の特徴に対し, それぞれ実施


4-1. Cloud-ImVN 1.0 のクラスタリング結果

- 特徴ベクトルをベクトル空間上に投影した図
 - フルカラーの場合



4-1. Cloud-ImVN 1.0 のクラスタリング結果

- Cloud-ImVN 1.0 におけるクラスタリング結果
 - フルカラーの場合



畳み込み = 特徴ベクトルの抽出がうまくいっていない

4-1. Cloud-ImVN 1.0 のクラスタリング結果




- Cloud-ImVN 1.0 におけるクラスタリング結果
 - フルカラーの場合

(a) Full color dataset

True classes	Predicted classes						Accuracy [%]
	Clear sky	Patterned	Veil	Thin white	Thick white	Thick dark	
Clear sky	339	0	4	3	4	0	96.9
Patterned	0	339	0	2	7	2	96.9
Veil	8	0	260	3	79	0	74.3
Thin white	0	4	0	229	108	9	65.4
Thick white	0	3	6	12	327	2	93.4
Thick dark	0	0	0	69	0	281	80.3
Total							84.5


4-1. Cloud-ImVN 1.0 のクラスタリング結果

- 特徴ベクトルをベクトル空間上に投影した図
 - グレースケールの場合



4-1. Cloud-ImVN 1.0 のクラスタリング結果

- Cloud-ImVN 1.0 におけるクラスタリング結果
 - グレースケールの場合



4-1. Cloud-ImVN 1.0 のクラスタリング結果

- Cloud-ImVN 1.0 におけるクラスタリング結果
 - グレースケールの場合

(b) Grayscale dataset

True classes	Predicted classes						Accuracy [%]
	Clear sky	Patterned	Veil	Thin white	Thick white	Thick dark	
Clear sky	157	0	41	44	94	14	44.9
Patterned	0	308	0	20	22	0	88.0
Veil	123	0	215	0	12	0	61.4
Thin white	2	2	1	154	191	0	44.0
Thick white	20	1	44	11	274	0	78.3
Thick dark	0	5	0	152	47	146	41.7
Total							59.7

> 1/6 の確度を持っている

4-2. 金星の雲画像データセットのクラスタリング

- 3 種類のスケールの金星パッチデータセットによるクラスタリング
 - 3000 km スケール (全球スケール)
 - 500 km スケール (中スケール)
 - あかつき UVI 365 nm 衛星画像から生成
 - 25 km スケール (小スケール)
 - VEX VMC UV 画像から生成
- クラス数は 4
- パッチ生成で使ったパラメータは表 4 の通り


Table 4

Parameter values (see Section 3.1) used for generating the Venus patch datasets in Section 4.2.

Parameter	Value
Angle-based removal threshold	$\alpha = 75^\circ$
Outlier removal sigma multiplier	$t_\sigma = 5$
Minimum patch density	$\rho_{p,\min} = 0.5$
Local density bins	$n_{\text{bin}} = 8$
Minimum bin density	$\rho_{\text{bin},\min} = 0.1$
Interpolation method	Nearest
Resolution	$r_p = 128$
Flattening blur sigma	$\sigma_f = 16$
Flattening blur kernel size	$k_f = 97$
Standardization contrast	$c_s = 0.33$

4-2-1. 3000 km スケールの特徴の場合



- クラスタリングの結果
 - 各クラスの特徴の例
 - Class 0 : 塊状になっている雲
 - 乱気流の跡
 - Class 1, 3 : 筋状の雲
 - Class 2 : 特徴なし
- 比較的明確な違いがある



(b) Random examples for each of the four classes of the 3000 km Venus cloud patches.

4-2-1. 3000 km スケールの特徴


- 特徴ベクトルをベクトル空間上に投影した図



4-2-1. 3000 km スケールの特徴


- クラスタリングによるクラスの緯度-経度分布と緯度-地方時分布

- Class 0 : 午後, 低中緯度
- Class 1 : 全日, 高緯度
- Class 2 : 特徴なし
- Class 3 : 午前,
低 ~ 高緯度



4-2-2. 500 km スケールの特徴の場合



- クラスタリングの結果
 - 各クラスの特徴の例
 - 3000 km ものより特有の特徴がない
 - Class 0 : わずかに筋状の構造が見える
 - Class 1, 3 : 塊状の雲
 - Class 2 : 特徴なし
- 各クラス間に明確な違いを持っていない



(b) Random examples for each of the four classes of the 500 km Venus cloud patches.

4-2-2. 500 km スケールの特徴


- 特徴ベクトルをベクトル空間上に投影した図



4-2-2. 500 km スケールの特徴


- クラスタリング結果のクラスの緯度-経度分布と緯度-地方時分布

- Class 0 : 特徴なし
- Class 1 : 午後,
低中緯度
- Class 2 : 特徴なし
- Class 3 : 午後,
低緯度



4-2-3. 25 km スケールの特徴の場合



- クラスタリングの結果
 - 各クラスの特徴の例
 - Class 0, 1, 2 : 特徴なし
 - Class 3 : はっきりとした特徴がある
 - 波の跡
- 2つのパターンにはっきり分類されている



(b) Random examples for each of the four classes of the 25 km Venus cloud patches.


4-2-3. 25 km スケールの特徴

- 特徴ベクトルをベクトル空間上に投影した図



4-2-3. 25 km スケールの特徴





- クラスタリング結果のクラスの緯度-経度分布と緯度-地方時分布
 - Class 3 の方が緯度が限定されている
 - 一部の緯度でのみ小規模な特徴が存在する



5. まとめ



5-1. 結果のまとめ

- 観測された画像データセットから一定スケールの雲パッチを生成し、クラスタリングを行うというフレームワークを導入した
- 地球の雲パッチデータセットに対して適用すると、高い正確性を得ることができた




5-1. 結果のまとめ

- 金星の雲パッチデータセットに対して適用すると
 - 全球スケールの雲パッチを, 特徴 (筋状, 塊状) に応じて分類することができた
 - 小スケールの雲パッチから, 波の跡が含まれるデータを区別することができた



5-1. 結果のまとめ

- 金星の雲パッチデータセットに対して適用すると
 - 一方, 中スケールの雲パッチデータセットを分類することができなかった
 - 目立った特徴が減り, 筋状の雲と塊の雲が混ざった特徴が現れるようになった



5-2. 今後の展望

- より発展的なクラスタリングアルゴリズム (SCAN / Density-based Spatial Clustering of Applications with Noise) (Van Gansbeke et al. (2020)) を使用しても改善できなかった
 - 機械学習ツールは常に莫大な学習データに依存する
 - しかし, 今回用意したデータセットは相対的に小さかったため, 学習できる量に制限があった
 - また ResNet の事前学習によって, 関係ない画像での学習があったことも影響していると予想される
- 教師あり学習と組み合わせたハイブリッドアプローチの利用が期待される
 - 特徴ベクトルの分割とクラスタリングの精度を上げるための追加情報を組み込むことができる

5-2. 今後の展望

- 本研究による手法は,拡張可能かつ客観的に大きなデータセットを解析する手法を提供でき,金星の雲の発展と大気の力学過程の研究を合理化できる可能性を持っている
 - 様々な時間の期間にわたるデータセットに適用することで,雲の形態的特徴の時間発展を追跡できる
 - 他の惑星にも適用できる
- 金星の大気現象の理解を深めるだけでなく,惑星科学のより広い分野に対し寄与することが期待される