Development and evaluation of analysis methods for science data based on statistical learning theory

メタデータ	言語: jpn
	出版者:
	公開日: 2017-10-05
	キーワード (Ja):
	キーワード (En):
	作成者:
	メールアドレス:
	所属:
URL	http://hdl.handle.net/2297/48062

This work is licensed under a Creative Commons Attribution-NonCommercial-ShareAlike 3.0 International License.



学位論文要旨

統計的学習理論に基づく 自然科学データ解析手法の開発および評価

Development and evaluation of analysis methods for science data based on statistical learning theory

自然科学研究科 電子情報科学専攻

太田 守

Abstract

Natural disasters make us recognize their awfulness and they are also important to predict for our daily lives. Understanding of natural phenomena is therefore imperative in observations of natural disasters. We developed new analysis methods for scientific data based on statistical learning theory. We addressed the following two issues.

- 1. The remote sensing technology which used weather radar for the analysis of global precipitation phenomena is exploited widely. In space observation, the precipitation particles are usually assumed as raindrops. This assumption is not satisfied for snowflakes or graupel because the scattering characteristics of electromagnetic wave can change variously. It is therefore convenient for understanding of the scattering characteristics to classify the particle type. We proposed an approximation method for Bayesian inference of the Gamma distribution. Applying the proposed method, we estimated the parameters of diameter-velocity distribution of precipitation particles.
- 2. Investigating characteristics of plasma waves observed by scientific satellites in the Earth's plasmasphere/magnetosphere is the effective key to understand not only generation mechanisms of the waves but also a plasma environment which influences its generation and propagation conditions. The wave distribution function (WDF) method can estimate a WDF as directional distribution of wave energy density. However, in order to determine the solution uniquely, we must assume an adequate model for WDF. We developed new estimation methods for the WDF method, and evaluated the performance by using computer-generated test data.

1 序論

1.1 研究の背景

自然現象は我々の生活と不可分に関わり合い、その 神秘性は現象に対する興味関心を惹きつけている. 古 来より人々を魅了し続けるオーロラは, 幻想的で荘厳 な美しさから興味の対象であるのと同時に畏怖の対 象でもあった. また, 2011 年 3 月 11 日に発生した東 北地方太平洋沖地震とそれに伴う津波、2016年10月 8日に発生した阿蘇山の爆発的噴火,近年増加してい る集中豪雨による水害や土砂災害を含む大規模災害 からは自然の脅威を感じずにはいられない. その一 方で、人間を含むあらゆる生物の生命存続にとって必 要不可欠な水資源は、自然がもたらす恩恵の一つでも ある. 自然現象が様々な恩恵や脅威をもたらす存在 であることを深く認識し、同時に自然とうまく関わっ ていくために、現象の定量的な解明および理解を目 指す自然科学の手法が発展してきた. 一例として近 年注目されている電磁波によるリモートセンシング は、遠方の環境を広範囲かつ瞬時に観測可能であり、 自然防災利用のために特に有効な観測技術として注 目されている.加えて2014年2月28日には、初の地 球全域の降水の詳細観測を行う全球降水観測計画主 2衛星が打ち上げられ、また 2016 年 12 月 20 日に放射 線帯でのプラズマ総合観測を目的とした ERG 衛星 が打ち上げられるなど、これまで実現困難であった高 分解能・高精度な観測を行うミッションが数多く計 画されている. 自然現象の解明において、今後得られ る観測データはより価値の高い情報を含み、同時にそ のデータ量は膨大になることが予想される. 自然現 象の理解および予測の観点において、計測技術の発達 により取得可能となった大規模かつ高精度なデータ には非常に多くの有益な情報が含まれていると考え られるが、それにともないデータ解釈の困難性は増し ているという問題に直面している.近年において、膨 大なデータを解析するために統計的学習を応用した 特徴抽出手法の研究が盛んに行われているが、その多 くは画像・音声といったメディアへの適用に留まり、 自然科学データに対して適用した事例は少ない. 自 然現象の解明・予測の重要性を鑑みて, 自然科学デー タへの統計的学習手法の適用は急務であるといえる.

1.2 研究の目的

本研究の目的は、自然科学データ解析における統計 的学習手法の開発及びその評価を行うことである.具 体的には、自然現象の理解・災害予測の観点において 特に重要と考えられる以下の二つの課題に取り組む.

1. 降水粒子の粒径-落下速度分布のパラメータ推定 技術の開発 厳密解を得ることが困難なガンマ分布 のベイズ推定の近似手法を確立し,その近似手法によ り効率的な学習が可能となる降水粒子の粒径-落下速 度分布のパラメータ推定を実データ解析に応用する.

2. プラズマ波動の到来方向推定手法の開発 伝搬特 性の重要な要素として波動の到来方向に着目し,衛星 による電磁場観測データから到来方向推定を行う手 法の開発を目指す. VLF 波動の伝搬方向推定手法の 入力データとしてはスペクトルマトリクスが一般的 に用いられている.本研究では,スペクトルマトリク スを入力データとする推定手法の開発と推定の信頼 性評価を行う.

2 気象レーダーによる降水強度予 測の基礎研究

降水現象は、水資源として我々の生活に多くの恵み を与えてくれるが、同時に集中豪雨や、局所的な豪雪 などの自然災害をもたらす.近年の雪害の増加に伴っ て、局所的な降水現象の詳細な解析が求められてい る. 全球的な降水現象の解析のために、気象レーダー を用いたリモートセンシング技術が広く使用されて いるが、これまでの解析では対象となる空間中の降水 粒子を雨滴と仮定している. 一般に, 雪片やあられな どの降水粒子の種類によって電波の散乱特性は大き く変化するため、この仮定は成立せず、降雪現象の解 析には従来の手法は適切でない場合がある. このた め、降水粒子を分類し、各降水粒子ごとの電波散乱特 性を把握することは有益である.特に、気象レーダー の観測量であるドップラースペクトルと推定対象の 降水強度との関係は、降水粒子の粒径-落下速度分布 のモーメントとして与えられるため、粒径-落下速度 分布のパラメータ推定が高精度な降水強度予測の基 礎技術として重要となる.

ガンマ分布に対するベイズ推定の近似 2.1.3 提案近似手法の相対誤差の評価 $\mathbf{2.1}$ 手法の提案

降水粒子の粒径分布のモデルとしては、 ガンマ分布 が用いられることが多い[1,2]. ガンマ分布は指数分 布族であるため事後分布のパラメータの更新は容易 に行えるが、事後分布の期待値の厳密計算は困難であ る.このため、ガンマ分布に対する効率的なベイズ推 定のための近似手法を提案した.

2.1.1 ガンマ分布の諸性質

確率変数 x が以下の確率密度関数

$$Gamma(x|\alpha,\beta) = \frac{\beta^{\alpha}}{\Gamma(\alpha)} x^{\alpha-1} \exp(-\beta x) \quad (1)$$

に従うとき, x は母数 α , β のガンマ分布に従うとい う. ここで, $\Gamma(\cdot)$ はガンマ関数である. ガンマ分布 の共役事前分布の分布族は、ハイパーパラメータを $\gamma, \varepsilon, \nu \ge b \subset$

$$p(\alpha, \beta; \gamma, \varepsilon, \nu) \propto \left[\frac{\beta^{\alpha} \gamma^{\alpha-1}}{\Gamma(\alpha)} \exp(-\beta \varepsilon)\right]^{\nu}$$
 (2)

と表現できる. ガンマ分布の共役事前分布のハイパー パラメータが $\{\gamma_0, \varepsilon_0, \nu_0\}$ であるとき,事後分布のパ ラメータ $\{\gamma^*, \varepsilon^*, \nu^*\}$ は次式から計算できる.

$$\gamma^* = (\gamma_0^{\nu_0} \mathbb{G}[x]^N)^{\frac{1}{\nu_0 + N}} \tag{3}$$

$$\varepsilon^* = \frac{\nu_0 \varepsilon_0 + N \bar{x}}{\nu_0 + N} \tag{4}$$

$$\nu^* = \nu_0 + N \tag{5}$$

ここで, \bar{x} と $\mathbb{G}[x]$ はそれぞれサンプル数 N からなる データ群の標本平均と幾何平均を表す.

2.1.2 提案する近似手法

 $p(\alpha, \beta; \gamma, \varepsilon, \nu)$ を β で周辺化して得られる分布 $p(\alpha)$ は、Stirlingの近似により一般化逆ガウス分布で近似 できる. この近似を Stirling-GIG 近似と呼び, Stirling の近似において α^{-1} の項を無視することで得られる ガンマ分布による近似を Stirling-Gamma 近似と呼 ぶことにする. また, $p(\alpha)$ の最頻値 $\hat{\alpha}$ における対数 尤度関数の高階微分係数を用いた近似で、一般化逆ガ ウス分布としたものを LS-GIG 近似, ガンマ分布と したものを LS-Gamma 近似と呼ぶことにする. 以上 の4つの提案手法と、Laplace 近似 [3]、Lindley の近 似[4]について誤差評価を行った.

図 1 に各近似手法により計算した期待値 $\mathbb{E}[\alpha]$ と数 値積分による結果との相対誤差を示す. どの α̂の場合



図 1: E[*α*]の相対誤差

にも共通する性質があり、Stirling-Gamma, Stirling-GIG は標本数が多くなるとともに相対誤差が一定値 に収束している. これは最頻値が厳密解からずれて いることが原因である. その他の Laplace 近似, LS-Gamma, LS-GIG, Lindley の近似は最頻値を厳密に 求めているため、標本数が多くなるにつれて誤差が 小さくなる傾向がみられる.図1より, LS-GIG 近 似が最も $\mathbb{E}[\alpha]$ の相対誤差が小さいことが分かる. ま た, $var[\alpha]$ や Hellinger 距離による誤差評価を行うこ とで、本提案の LS-GIG 近似によるものが比較した 近似手法の中で最適であることを示した. ガンマ分 布のパラメータの期待値計算に LS-GIG 近似を用い ることで、数値積分を行うことなく良好な近似値を効 率的に計算可能となった.

降水粒子の粒径-落下速度分布の解析 2.2

2.2.1降雪粒子観測装置と粒径-落下速度分布

富山高等専門学校本郷キャンパスの屋上に図2に 示す降雪粒子観測装置が設置してある.この観測装 置は、観測領域 (16.4 cm ×12.3 cm ×20.0 cm) の降 雪粒子をカメラで撮影する.得られた画像から降雪粒 子の粒径 D と落下速度 v が計算されている.本研究 で使用したカメラは Manta G-033 であり,解像度を 656×492 pixel, フレームレートを 60 fps とし,シャッ タースピードは 16000 μ s と設定したものを用いた. 図 3 に実際に観測装置で観測された粒径-落下速度分 布 N(D,v) の例を示す.粒径-落下速度分布 N(D,v)を落下速度で周辺化した N(D) を粒径分布という.降 水粒子の粒径分布 N(D) は,ガンマ分布でモデル化 されることが多く,

$$N(D; \alpha, \beta) = N_0 \cdot \text{Gamma}(D|\alpha, \beta)$$
(6)

と表現される [1, 2]. ここで, N_0 は降水粒子の空間数 密度を表す. また, 粒径と落下速度の関係式として,

$$v(D; \boldsymbol{w}) = w_0 D^{w_1} \tag{7}$$

が実データに対して当てはまりがよいと報告されて いる [5, 6]. ここで, $w = [w_0, w_1]^T$ は粒径と落下速 度の関係を決定する降水粒子の種類に依存するパラ メータである.降水粒子観測装置により取得された 粒径,落下速度データから,各パラメータ α , β , w を 推定した.



図 2: 降雪粒子観測装置

2.2.2 粒径-落下速度分布の確率モデル

粒径-落下速度分布のパラメータ推定に用いた確率 モデルを図4に示す.この図は、モデルで扱われる確 率変数の依存関係を矢印で表している. $D \ge v$ はそ れぞれ粒径と落下速度の観測データを表す.Kはモデ ルに便宜的に設けられる最大クラスタ数であり、Nは 全粒子数を表す.また、クラスタ番号kの粒子種の粒 径Dと落下速度vの関係式として $v = w_{0k}D^{w_{1k}}$ を採 用する.加えて、粒径分布をガンマ分布でモデル化す ることとし、k番目のクラスタのパラメータを α_k, β_k



図 3: 粒径-落下速度分布の例

とする. 以上をまとめて, $\alpha = \{\alpha_k\}, \beta = \{\beta_k\}, w = \{[w_{0k}, w_{1k}]^T\}$ と図中に表記している. また, 各粒子 (D_n, v_n) の所属クラスタは多項分布に従う確 率変数 z_n によって, クラスタの混合比は確率変数 π によって与えられる. 降水粒子を特徴づけるモデル パラメータ $\{\alpha_k, \beta_k, [w_{0k}, w_{1k}]^T\}$,実効的なクラス タ数を与える混合比 π , また n 番目の降水粒子デー $g(D_n, v_n)$ の所属クラスタ z_n を推定する. なお,本 モデルの同時確率は次式で定めた.

$$p(\boldsymbol{D}, \boldsymbol{v}, \boldsymbol{Z}, \boldsymbol{w}, \boldsymbol{a}, \boldsymbol{b}, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\pi}; \boldsymbol{\varphi}_0, \boldsymbol{s}_0, \boldsymbol{c}_0, \boldsymbol{d}_0, \boldsymbol{e}_0, \boldsymbol{f}_0)$$

= $p(\boldsymbol{v} | \boldsymbol{D}, \boldsymbol{Z}, \boldsymbol{w}, \boldsymbol{b}) p(\boldsymbol{D} | \boldsymbol{Z}, \boldsymbol{\alpha}, \boldsymbol{\beta}) p(\boldsymbol{Z} | \boldsymbol{\pi}) p(\boldsymbol{w} | \boldsymbol{a})$
 $\cdot p(\boldsymbol{a}; \boldsymbol{c}_0, \boldsymbol{d}_0) p(\boldsymbol{b}; \boldsymbol{e}_0, \boldsymbol{f}_0) p(\boldsymbol{\alpha}, \boldsymbol{\beta}; \boldsymbol{\varphi}_0) p(\boldsymbol{\pi}; \boldsymbol{s}_0)$ (8)

ここで、 $Z = \{z_n\}$ とした. $\varphi_0 = \{\gamma_0, \varepsilon_0, \nu_0\}, s_0, c_0, d_0, e_0, f_0$ は各確率変数のハイパーパラメータを表し、条件付き確率はそれぞれ

$$p(\boldsymbol{v}|\boldsymbol{D}, \boldsymbol{Z}, \boldsymbol{w}, \boldsymbol{b}) = \prod_{n=1}^{N} \prod_{k=1}^{K} \mathcal{LN}(v_n | \boldsymbol{w}_k^T \boldsymbol{\phi}(D_n), b_k^{-1})^{z_{nk}}$$
(9)

$$p(\boldsymbol{D}|Z,\boldsymbol{\alpha},\boldsymbol{\beta}) = \prod_{n=1}^{N} \prod_{k=1}^{K} \operatorname{Gamma}(D_{n}|\alpha_{k},\beta_{k})^{z_{nk}}$$
(10)

$$p(Z|\boldsymbol{\pi}) = \prod_{n=1}^{N} \prod_{k=1}^{K} \pi_k^{z_{nk}}$$
(11)

$$p(\boldsymbol{w}|\boldsymbol{a}) = \prod_{k=1}^{K} \mathcal{N}(\boldsymbol{w}_k|\boldsymbol{0}, a_k^{-1}\boldsymbol{I})$$
(12)

$$p(\boldsymbol{a};\boldsymbol{c}_0,\boldsymbol{d}_0) = \prod_{k=1}^{K} \operatorname{Gamma}(a_k|c_0,d_0)$$
(13)

$$p(\boldsymbol{b}; \boldsymbol{e}_0, \boldsymbol{f}_0) = \prod_{k=1}^{K} \operatorname{Gamma}(b_k | \boldsymbol{e}_0, \boldsymbol{f}_0)$$
(14)

$$p(\boldsymbol{\alpha}, \boldsymbol{\beta}; \boldsymbol{\varphi}_0) \propto \prod_{k=1}^{K} \left[\frac{\beta_k^{\alpha_k}}{\Gamma(\alpha_k)} \gamma_0^{\alpha_k - 1} \exp(-\beta_k \varepsilon_0) \right]^{\nu_0}$$
(15)

$$p(\boldsymbol{\pi}; \boldsymbol{s}_0) \propto \prod_{k=1}^{K} \pi_k^{s_0 - 1} \tag{16}$$

と定義した. ここで, $\phi(D_n) = [1 \ln(D_n)]^T$ である.



図 4: 粒径-落下速度分布のグラフィカルモデル

また、各確率変数の事前分布には共役事前分布を与えた、 $\mathcal{N}(x|\mu,\sigma^2)$ と $\mathcal{LN}(x|\mu,\sigma^2)$ はそれぞれ正規分布 と対数正規分布の確率密度関数を表す.本研究では、 以上で述べたモデルパラメータを次式で定義される 変分事後分布を用いて変分ベイズ法により推定した.

$$q(Z, \boldsymbol{w}, \boldsymbol{a}, \boldsymbol{b}, \boldsymbol{\alpha}, \boldsymbol{\beta}, \boldsymbol{\pi})$$

= $q(Z)q(\boldsymbol{w})q(\boldsymbol{a})q(\boldsymbol{b})q(\boldsymbol{\alpha}, \boldsymbol{\beta})q(\boldsymbol{\pi})$ (17)

このモデルは K を十分大きくとることで, 関連度自動決定 [7] により最適なクラスタ数が自動的に決定される.また,変分事後分布の落下速度に関わるパラメータについて無情報事前分布を仮定し更新則を適用しないことで粒径分布に対する混合ガンマ分布のクラスタリング手法として本モデルを用いることができる.また,変分ベイズ法の更新則に現れるガンマ分布のパラメータの期待値計算に本提案の LS-GIG 近似を用いて推定の効率化を図ることで大規模データの解析に適用が可能となった.

擬似データによる検討の結果,良好に関連度自動決 定が機能したK = 10として,周辺尤度の下限の最大 化によるハイパーパラメータの最適化を行い,粒径-落下速度分布のパラメータ推定を行った.

2.2.3 粒径データを用いたパラメータ推定結果

図5に雪片とあられが同時に降っている期間の粒 径分布と,前項で述べた推定手法によるクラスタリン グ結果を示す.用意された10個のクラスタの内,関 連度自動決定により8個のクラスタの混合比は零へ と縮退し,自動的に2つのクラスタが存在しているこ

とを学習しており、目視で確認した降雪種と合致する 推定結果となった.



図 5: 粒径分布のパラメータ推定結果

2.2.4 粒径,落下速度データを用いた推定結果

図6に粒径-落下速度分布のパラメータ推定により 得られた各クラスタの平均粒径と平均落下速度の時 系列変化を示す.平均粒径の大きいクラスタについ



図 6: 平均粒径, 落下速度の時系列変化

て,時間とともに次第に平均粒径が大きくなっている ことから,この時間帯において小さい雪片から次第に 大きな雪片へと遷移していく過程が確認できる.平 均粒径の時系列変化からは,平均粒径の大きな雪片と 平均粒径が小さい降雪粒子の2種しか判別できない が,同時刻の平均粒径の小さいクラスタの平均落下速 度をみると,あられの時間帯では速度が大きく,それ 以降の時間帯での速度が小さくなっていることが分 かる.つまり,粒径-落下速度速度分布のクラスタリ ングにより小さい降水粒子,雪片,あられの3種類に 分類できる可能性が示された.

ドップラーレーダーの観測量であるドップラースペクトル $Z_{\text{doppler}}(v)$ は、粒径-落下速度分布のパラメータにより

$$Z_{\text{doppler}}(v) = \sigma(D, v) \cdot N_0 \cdot \text{Gamma}(D|\alpha, \beta) \cdot \frac{\partial D}{\partial v}$$
(18)

として与えられる. ここで, $\sigma(D, v)$ は粒径 D, 落下 速度 v の降水粒子の後方散乱断面積である. 3 種の 降水粒子に分類されたという前項の結果を用いて計 算した, 各降水粒子ごとのドップラースペクトルの事 後予測分布を図 7 に示す. 各降雪種でドップラース



図 7: ドップラースペクトルの事後予測分布

ペクトルが大きく異なる形状をとることから,実際に ドップラーレーダーの観測量から観測領域の降雪粒 子種の比率を推定可能であることが示唆された.各 降水種ごとのドップラースペクトルと降水強度の関 係を計算しておくことで,降水強度の高精度推定が可 能になると考えられる.

3 スペクトルマトリクスを用いた 到来方向推定手法の開発

宇宙空間の本格的な利活用に伴い,地球磁気圏内の 物理現象を解明することの重要性が増している.地 球磁気圏を飛翔する科学衛星の電磁場観測データは, 地球周辺環境の把握のために必要な情報を豊富に含 んでいると考えられる.情報の活用のためには,デー タから波動の伝搬特性を推定するための手法の開発 が欠かせない.

3.1 到来方向推定手法の概要

3.1.1 スペクトルマトリクスの定義

科学衛星に搭載されるプラズマ波動観測器は,衛星 の位置における電場と磁場の波形観測を行う.到来 方向推定を行う際,観測信号はバンドパスフィルタに より解析対象の周波数帯域の解析信号 z(t) へと変換 される.観測時刻 { t_1, t_2, \ldots, t_N } における観測デー タ { $z(t_n)$ } の相互相関行列

$$\boldsymbol{S} = \frac{1}{N} \sum_{n=1}^{N} \boldsymbol{z}(t_n) \boldsymbol{z}(t_n)^{\dagger}$$
(19)

はスペクトルマトリクスと呼ばれ、伝搬ベクトル推定 において広く用いられている.以降では、Nをスペク トルマトリクスの平均回数と呼ぶことにする.また、 定義よりスペクトルマトリクスSは観測信号の成分 数を D として D 次の正定値エルミート行列である.

3.1.2 波動分布関数法

Storey ら [8] によって提案された波動分布関数法 では、観測点に到来する波を異なる周波数、伝搬方向 をもつ無限個の平面波と考え、エルゴード的な定常不 規則過程とみなせると仮定する.また、観測点に到来 する複数の波動のエネルギー密度分布を、波動分布関 数 $F(\theta, \phi)$ として表現する.ここで、伝搬方向を表す ベクトル \hat{k} に対して、 \hat{k} と地球磁場とのなす角を天 頂角 θ, \hat{k} を x-y 面に投影したベクトルが x 軸となす 角を方位角 ϕ と定義した.スペクトルマトリクスは 波動分布関数と以下の積分方程式で関連づけられる.

$$\mathbb{E}[\boldsymbol{S}] = \frac{\pi}{2} \int_0^{2\pi} \int_0^{\pi} \boldsymbol{a}(\theta, \phi) F(\theta, \phi) \sin \theta \mathrm{d}\theta \mathrm{d}\phi \quad (20)$$

スペクトルマトリクス S の平均回数が十分に多けれ ば確率的な揺らぎは小さくなり、上式の右辺の期待値 を観測値に置き換えた近似式が適用できる. 式中に 表れる $a(\theta,\phi)$ は (θ,ϕ) 方向の伝搬ベクトルを持つ波 動の単位エネルギー当たりのスペクトルマトリクス であり、積分核と呼ぶ [9]. 積分核は波動の周波数と 伝搬モード、サイクロトロン周波数とプラズマ周波数 をもとに理論的に計算可能である. 式 (20)に基づき 観測によって得られるスペクトルマトリクスと理論 から計算される積分核を既知として、 $F(\theta,\phi)$ を推定 する手法を波動分布関数法という [8]. この方程式の 解は一般的には一意に定まらないため、波動分布関数 に何らかのモデルを与える必要がある.

3.2 マルコフ確率場モデルに基づく波動分 布関数法

3.2.1 提案手法の概要

マルコフ確率場 (MRF) モデルに基づく波動分布 関数法 (以下,本手法と表記する)では,到来方向を 離散化して推定問題を取り扱う.本手法では,離散化 数を K として波動分布関数を表すベクトル $f \in \mathbb{R}^{K}$ と,観測されたスペクトルマトリクスの独立成分 L個からなる実ベクトル $\hat{s} \in \mathbb{R}^{L}$ との関係を,積分核行 列 $A \in \mathbb{R}^{L \times K}$ を用いて

$$\hat{\boldsymbol{s}} = \boldsymbol{A}\boldsymbol{f} + \varepsilon \boldsymbol{a}_{\varepsilon} + \boldsymbol{e}$$
 (21)

と表現する. この式は,式 (20) を離散化して得られ るものである. ここで, a_{ε} は白色ノイズに対応する 積分核であり,その強度は確率変数 ε で与えられる. また, $e \in \mathbb{R}^{L}$ は誤差ベクトルを表す. 図 8 に提案す る確率モデルのパラメータ依存関係を示す. ここで, 図中の α,β はそれぞれ \hat{s}, f の事前分布のパラメータ であり本手法では確率変数として取り扱われる. ま た,図 8 に示した依存関係から, MRF モデルの同時 確率は

$$p(\hat{\boldsymbol{s}}, \boldsymbol{f}, \varepsilon, \alpha, \beta) = p(\hat{\boldsymbol{s}} | \boldsymbol{f}, \varepsilon, \alpha) p(\boldsymbol{f} | \beta) p(\varepsilon) p(\alpha) p(\beta) \quad (22)$$

と表現できる.以下に,各モデルパラメータに与えた 確率分布を示す.

$$p(\hat{\boldsymbol{s}}|\boldsymbol{f},\varepsilon,\alpha) = \mathcal{N}_{L}(\hat{\boldsymbol{s}}|\boldsymbol{A}\boldsymbol{f} + \varepsilon\boldsymbol{a}_{\varepsilon},\alpha^{-1}\boldsymbol{I})$$
(23)

$$p(\boldsymbol{f}|\beta) = \frac{\beta^{\frac{K}{2}} |\boldsymbol{C}^{\mathrm{T}} \boldsymbol{C}|^{\frac{1}{2}}}{(2\pi)^{\frac{K}{2}}} \exp\left(-\frac{\beta}{2} \|\boldsymbol{C}\boldsymbol{f}\|_{2}^{2}\right) \quad (24)$$

ここで $\mathcal{N}_L(x|\mu, \Sigma)$ は確率変数xが平均 μ ,分散共分散行列 Σ のL変量正規分布に従うことを表す.また, β^{-1} は事前分布の分散に関するスケール変数であり, $C^{\mathrm{T}}C \in \mathbb{R}^{K \times K}$ は MRF の相関行列を表す.本手法では, ϵ , α , β の事前分布には共役事前分布を与えた. また,変分事後分布を

$$q(\boldsymbol{f},\varepsilon,\alpha,\beta) = q(\boldsymbol{f})q(\varepsilon)q(\alpha)q(\beta) \qquad (25)$$

として、変分ベイズ法を用いて近似的にモデルパラ メータの事後分布を推定する.このとき、変数の定義 により $f \ge \varepsilon$ が非負の値をとることから $\mathbb{E}[f] \ge 0$ 、 $\mathbb{E}[\varepsilon] \ge 0$ の制約条件のもと推定を行う.また、本手法 の推定結果を学習された近似事後分布の最頻値とし て定義する.

マルコフ確率場モデルに基づく波動分 3.2.2 疑似データを用いた提案手法の評価

本提案手法 (MRF) の波動分布関数の推定像を, 波 動の到来方向が既知の疑似データを用いて評価し た. 比較対象として, 最大エントロピー法 (MEM), Phillips-Tikhonov 正則化法 (PTM) を用いた. プラ ズマ周波数を 300 kHz, サイクロトロン周波数を 50 kHz, 波動の周波数を 3 kHz としてホイスラーモード を仮定した擬似データを作成した.



図 8: 提案する確率モデルのパラメータ依存関係



図 9: 三つの点波源の場合の各モデルの推定結果

1. ノイズを含まない擬似データを用いた評価 強度、広がりがともに等しい三つの到来波を仮定し、 各波の到来方向が $(\theta_1, \phi_1) = (60^\circ, 30^\circ), (\theta_2, \phi_2) = (60^\circ, 150^\circ), (\theta_3, \phi_3) = (40^\circ, 210^\circ)$ である疑似データ に対する各手法の推定結果を図 9 に示す. PTM で は、全ての波源を覆うような広がった推定像が得られ、MEM では二つ目の波源と三つ目の波源が一つの 広がった波源として推定されていることが分かる. そ

て、やや大きくなるものの三つの波源の到来方向が良 Nのスペクトルマトリクス Wの生起確率を表す尤 好に推定されていることが分かる.

2. ノイズを含む疑似データを用いた評価 到来方向 比を変えて擬似データを作成し,疑似データの波動 分布関数と各手法の推定像の平均二乗誤差 (MSE) を 計算した結果を図 10 に示す. 各 S/N 比ごとに異な るノイズを100パターン作成し、図には100回の試 行での MSE の平均値を点で, エラーバーでその試 行での MSE の最小値, 最大値を示した. S/N 比が 45,50[dB] の場合にはほぼノイズの影響はないと考 えられるため、点波源を良好に推定できていた MEM、 MRFのMSEは小さい値をとり、推定像が広がって しまう PTM では MSE が大きくでていることが分か る. また, S/N 比が低くなるにつれ提案手法 (MRF) は従来手法に比べ MSE が小さくなり、 ノイズに頑健 であることが明らかとなった.



図 10: S/N 比に対する各推定手法の推定像の MSE

3.3恣意的なモデルを排除した波動分布関 数法

p次元の観測信号が、平均0で積分核から理論的に 計算されるスペクトルマトリクス S を分散共分散行 列としてもつ定常ガウス過程に従うことを仮定する. このとき、Sは積分核と波動分布関数と以下の関係を もつ.

$$\boldsymbol{S} = \frac{\pi}{2} \int_0^{2\pi} \int_0^{\pi} \boldsymbol{a}(\theta, \phi) F(\theta, \phi) \sin \theta \mathrm{d}\theta \mathrm{d}\phi \qquad (26)$$

このガウス過程の母数としてのスペクトルマトリク スと観測値を区別するために、科学衛星の観測データ を用いて平均回数 N で作成されるスペクトルマトリ

れに対して、MRF は波源の広がりは元データに比べ クスの観測値を W と表現する. このとき、平均回数 度分布は.

$$p(\boldsymbol{W}|\boldsymbol{S}) = \frac{N^{Np} \cdot |\boldsymbol{W}|^{N-p} e^{-N \cdot \operatorname{tr}(\boldsymbol{S}^{-1}\boldsymbol{W})}}{\pi^{\frac{p(p-1)}{2}} |\boldsymbol{S}|^N \prod_{k=1}^p \Gamma(N-k+1)}$$
(27)

で与えられる.この尤度分布と無情報事前分布から 得られる波動分布関数の事後分布から、その実現値 をギブスサンプリング[7]を用いて複数個計算するこ とで、その期待値と信用区間を求めることができる. 図 11 に二つの波源からなる擬似データを、平均回数 を 200 回として推定した結果を示す.期待値と信用 区間の両方において二つの峰をもつ分布構造が現れ ており、二つの波源を特定できていることが分かる. このように信用区間と期待値を合わせて確認するこ とで、平均回数に対して推定像にどの程度の揺らぎが 存在するのかを恣意的なモデルを用いずに評価でき る.この方法は、波動分布関数法の推定像の性質の解 明や、より高速で信頼性の高い推定手法を開発してい くための理論基盤として有効に利用できると考えら れる.



(c) 95%下側信用区間 (d) 95%上側信用区間

図 11: 二つの広がった波源の場合の推定結果 (平均) 回数 N = 200)

4 結論

統計的学習理論に基づく自然科学データの解析技 術の開発およびその評価として二つの課題に取り組 んだ.

まず、レーダー気象学にとって重要な基礎研究の一 つである降水粒子の粒径-落下速度分布のパラメータ 推定問題を扱った. 粒径分布のモデルとしてよく用い られているガンマ分布のベイズ推定は、事後分布の期 待値が解析的に計算できない. この問題点を解決す るためにガンマ分布のベイズ推定のための近似期待 値計算手法の提案を行った.提案手法を用いること で大規模な降水粒子観測データに対して推定手法を 適用できるようになった. この粒径-落下速度分布の パラメータ推定手法を,降水粒子観測装置の観測デー タに適用し、良好に降水粒子のクラスタリングを行え ていることを確認した.また、粒径-落下速度分布の クラスタリングにより得られたモデルパラメータか ら、各降雪種のドップラースペクトルの事後予測分布 を計算した. ドップラーレーダによって取得される ドップラースペクトルとの比較によりレーダの観測 値のみから降水粒子種の比率を推定できる可能性と, その結果を用いた高精度な降水強度推定の可能性が 示唆された.

次に,科学衛星によって得られる観測波形データから作成されるスペクトルマトリクスを用いた伝搬ベクトル推定手法を開発した.また,マルコフ確率場モデルに基づく波動分布関数法の提案し,擬似データを用いて従来手法の推定像との比較,評価を行った.その結果,ノイズを含む擬似データに対しても本提案手法が平均二乗誤差の観点で従来手法に比べて安定に推定可能であることが分かった.

最後に、スペクトルマトリクスの平均回数を考慮し た尤度分布を用いることで、解を一意に定める必要 を無くし恣意的なモデルを排除した波動分布関数法 による推定を可能とした.この手法を用いることで、 平均回数による推定像の揺らぎを把握でき客観的に 解の良さが評価可能になる.また、効率的な到来方向 推定アルゴリズムの開発に当たっての推定像評価の 判断基準として本手法が有効に応用できると考えら れる.

本研究で用いた手法は、統計的学習理論に基づく データの性質によらない汎用的なものであり、その 応用範囲は広いといえる.本研究で扱った、工学的な 応用として重要なクラスタリングと逆問題解法の開 発・評価により、自然現象の機構解明の一助となるだ けではなく、実観測データを用いた学習手法の定量評 価を通じて機械学習分野の発展に貢献できれば幸い である.

参考文献

- [1] 深尾昌一郎, 浜津享助. 気象と大気のレーダーリ モートセンシング. 京都大学学術出版会, 2009.
- [2] Guifu Zhang, Juanzhen Sun, and Edward A. Brandes. Improving parameterization of rain microphysics with disdrometer and radar observation. *Journal of the Atmospheric Sciences*, Vol. 63, No. 4, pp. 1273–1290, 2006.
- [3] 元田浩, 栗田多喜夫, 樋口知之, 松本裕治, 村田昇
 (編). パターン認識と機械学習(上): ベイズ理
 論による統計的予測. 丸善出版, 東京, 2007.
- [4] D. V. Lindley. Approximate bayesian methods. Trabajos de Estadistica Y de Investigacion Operativa, Vol. 31, No. 1, pp. 223–245, 1980.
- [5] 椎名徹,村本健一郎.降雪粒子の落下速度と落下 中の粒径および融解直径の関係.電子情報通信 学会論文誌. D-II,情報・システム,II-情報処理, Vol. 81, No. 6, pp. 1108–1114, jun 1998.
- [6] 村本健一郎, 椎名徹. 画像処理による降雪粒子の 大きさと落下速度の自動測定. 電子情報通信学会 論文誌 D-2 情報・システム, Vol. 72, No. 9, pp. p1382–1387, sep 1989.
- [7] 元田浩, 栗田多喜夫, 樋口知之, 松本裕治, 村田昇
 (編). パターン認識と機械学習(下): ベイズ理
 論による統計的予測. 丸善出版, 東京, 2008.
- [8] L. R. O. Storey and F. Lefeuvre. The analysis of 6-component measurements of a random electromagnetic wave field in a magnetoplasma I. The direct problem. *Geophysical Journal International*, Vol. 56, No. 2, pp. 255–269, 1979.
- [9] L. R. O. Storey and F. Lefeuvre. The analysis of 6-component measurements of a random electromagnetic wave field in a magnetoplasma
 II. The integration kernels. *Geophysical Journal International*, Vol. 62, No. 1, pp. 173–194, 1980.

学位論文審査報告書(甲)

1. 学位論文題目(外国語の場合は和訳を付けること。) 統計的学習理論に基づく自然科学データ解析手法の開発および評価

2. 論文提出者 (1)所 属 <u>電子情報科学 専攻</u> (2) 芪 茗 太田 共

3. 審査結果の要旨(600~650字)

平成29年2月1日に第1回学位論文審査委員会を開催した後、口頭発表を行った。その 直後に、第2回審査委員会を開いて慎重審議を行った結果、以下の通り判定した。なお、口頭 発表における質疑を最終試験に代えるものとした。

本論文は、統計的学習理論に基づく自然科学データの解析技術およびその評価法の開 発を目的として、二つの課題に取り組んでいる。まず、レーダー気象学にとって重要な 降水粒子の粒径・落下速度分布のパラメータ推定問題に対し、近似解法を用いてパラメー タを効率的に求める方法を提案した。さらに同手法を降水粒子種毎の粒径・落下速度分布 のパラメータ推定に応用し、レーダー観測データから降水粒子の混合率が推定できるこ とを示した。次に、科学衛星で計測した電磁波の伝搬方向推定法の改良に取り組んだ。 まず、マルコフ確率場モデルに基づく波動分布関数の求解法を新たに提案し、データに 雑音が含まれる場合でも頑健かつ信頼性の高い推定解が得られることを示した。さらに、 測定データの平均回数に基づく尤度分布を利用することで、恣意的な仮定なしに推定結 果を得る方法を開発した。このように本研究は、多種多様なパラメータに依存する自然 科学観測データから、客観的かつ信頼度の高い解析結果を得る手法を提案したもので、 大変重要な成果といえる。以上より、本論文は博士(工学)に値すると判定した。 4. 審査結果 (1) 判 定(いずれかに〇印) 金 格 不合格

(2)授与学位 博士(工学)