

# SVMによるミリ波レーダデータからの悪視程判別 Detection of Bad Visibility from Milliwave Radar Data by SVM

白石 将<sup>†</sup>, 酒巻 洋<sup>†</sup>, 田中 久理<sup>†</sup>

Masashi Shiraishi, Hiroshi Sakamaki, Hisamichi Tanaka

植松 明久<sup>‡</sup>, 手柴 充博<sup>‡</sup>, 橋口 浩之<sup>‡</sup>, 深尾 昌一郎<sup>‡</sup>, 鈴木 修<sup>§</sup>

Akihisa Uematsu, Michihiro Teshiba, Hiroyuki Hashiguchi, Shoichiro Fukao, Osamu Suzuki

## 1. はじめに

我々は粒径の小さな霧を探知可能なミリ波レーダを開発し、霧観測を実施している [1]。ミリ波レーダを利用すればエコー強度の空間的な分布 (以下「エコー強度分布」と呼ぶ) が得られるが、空港や高速道路などの運用において実際に欲しいデータは、肉眼でどの程度の距離を見通せるかを表す視程である。しかし、エコー強度と視程との間には相関はあるものの、その関係式は水滴の粒径分布によって異なる。そのため、単一のエコー強度の情報のみから視程を精度良く求めることは困難である。

一方、エコー強度分布のパターンと、霧の粒径分布や視程との間に強い相関があることを示唆する観測結果がこれまでに得られている [2]。従って、ある地点の視程を知りたい場合にその地点のピンポイントのエコー強度のみに着目するのではなく、その周辺のエコー強度分布を考慮することによって、霧のタイプを考慮した視程推定が可能になるのではないかと期待される。この考え方に基づく方向としてまず考えられるのは、視程と強い相関を持つと考えられる特徴量をエコー強度分布から抽出して利用することである。例えば、文献 [3] ではエコー強度、エコー頂高度、エコー面積から視程状況を判定するアルゴリズムが提案されている。

一方、本稿では特定の特徴量を抽出せず、注目する地点近辺のエコー強度分布と視程との関係を実データから機械的に学習させることを考えた。但し、視程を数値として推定することは難しいと思われたため、悪視程か否かを判別することを目的とした。

本稿ではエコー強度分布からの悪視程判別の内容と、実データを用いた評価実験結果を述べる。

## 2. 判別方法

エコー強度分布と視程との関係の学習方法および、新たなエコー強度分布が与えられた際の悪視程判別方法について述べる。PPI(Plan Position Indicator) 走査時に得られるエコー強度データを表す模式図を図 1 に示す。図 1 のように、距離および方位角方向について、距離分解能および角度分解能によって定まる離散点におけるエコー強度が得られる。これらのエコー強度の値を並べて得られるベクトルを「特徴ベクトル」と呼ぶことにする。図 1 の場合、特徴ベクトルを  $x$  とすると、

$$x = (\dots, Z_i, Z_{i+1}, Z_{i+2}, \dots, Z_j, Z_{j+1}, Z_{j+2}, \dots)$$

と表される。CAPPI(Constant Altitude PPI) 走査や RHI(Range Height Indicator) 走査の場合も、同様にエ




図 1: PPI 走査時に得られるエコー強度データ

コー強度の値を並べることによって特徴ベクトルを生成する。また、特徴ベクトルによって張られる多次元空間を「特徴空間」と呼ぶ。

この時、特徴空間上で定義される (つまり特徴ベクトルを入力とする) 線形な判別関数  $f(\cdot)$  を考える。そして、特徴ベクトル  $x$  に対し、 $0 < f(x)$  ならば「悪視程」、それ以外の場合は「良視程」と判別することにする。 $f(\cdot)$  の具体的な形は、学習段階において、学習データをできるだけ正しく判別するように定められる。

以下、判別関数の学習について説明する。まず学習データとして、特徴ベクトルと、同じ観測時刻における注目地点での視程の対の集合を作成する。そして、予め視程閾値を定めておき、視程が視程閾値以下である場合は「悪視程」、それ以外の場合は「良視程」とする。学習データに基づいて判別関数を定める方法としてこれまでに多くのものが提案されているが、我々は SVM(Support Vector Machine)[4] を利用することにした。学習データが線形分離可能である場合、SVM は判別の境界となる超平面 ( $f(x) = 0$ ) と特徴ベクトルとの最小距離が最大となるように  $f(\cdot)$  を定める。線形分離可能でない場合は、正しく判別できないデータに対してペナルティを導入して判別関数を定める。

学習結果の評価は、新たなテストデータを利用して、判別関数による判別結果と実際に観測された視程とがどの程度一致していたかによって行う。

## 3. 実験

釧路における 2000 年取得のミリ波レーダデータおよび、釧路空港地上気象要素データに含まれる消散係数を視程に変換したものを利用して、評価実験を行った。実験に使用したデータは以下の通り。

<sup>†</sup>三菱電機株式会社

<sup>‡</sup>京都大学 宙空電波科学研究センター

<sup>§</sup>気象研究所




図 2: エコー強度画像の例

ミリ波レーダデータ レーダ設置地点は海岸線から約 1km, また海拔約 42m の地点で, 使用したデータは仰角 0.7, 1.3, 2.8, 4.9 度に関する CAPPI 走査によるエコー強度データ。データの分解能は, 距離方向に 125m, 方位角方向に約 0.35 度である。

消散係数 観測場所は釧路空港内にあり, 海拔は約 85m, またレーダ設置地点を起点として方位角約 15 度の方向に約 4.3km 離れた位置にある。従って, レーダの送信パルスが消散係数測定地点にて通過する位置は, 仰角 0.7 度では地上約 10m, 仰角 1.3 度では地上約 55m, 仰角 2.8 度では地上約 165m, 仰角 4.9 度では地上約 325m と見積もることができる。

エコー強度データを画像化したものの例を図 2 に示す。

以下, 悪視程判別実験の詳細について述べる。本実験では, 2000 年 7 月 31 日 1 時~2000 年 8 月 4 日 4 時のデータ (データ数:516) を用いて SVM によって悪視程判別関数を学習し, 8 月 7 日 8 時~8 月 10 日 9 時のデータ (データ数:307) を用いて学習結果を評価する。SVM の中心部分の処理については, SVM の C による実装であるフリーソフト SVM<sup>light</sup> [4] を利用した。

実験に利用するエコー強度分布の範囲は, 消散係数測定地点を囲むようにするため, レーダ設置地点を起点として方位角について 10~20 度, また距離について 1~5, 2~5, 3~5, 4~5km の領域とした。また, 良視程と悪視程との境界となる視程閾値として, 1000, 2000, 3000, 4000, 5000m の 5 通りについて実験した。

仰角 0.7, 1.3, 2.8, 4.9 度のエコー強度分布を利用して, 学習データを全て正しく判別するように判別関数を学習した場合の, テストデータに対する正解率をグラフ化したものを図 3 に示す。図 3 より, 悪視程の学習/判別に利用する空間的範囲が広い方が性能が良い, との傾向が伺える。

また, 比較的良好な性能を示していた場合 (距離: 1~5km, 視程閾値: 3000m, テストデータの正解率: 78.83%) の結果に関し, 評価段階における視程と悪視程判別関数値の時系列をグラフ化したものを図 4 に示す。




図 3: 悪視程判別の正解率




図 4: 視程と判別関数値の時系列 (評価段階)

ここで, 判別関数値が 0 以上の場合が悪視程 (視程が 3000m 以下), それ以外の場合が良視程 (視程が 3000m 以上) と判別されたことを意味する。

#### 4. おわりに

エコー強度分布と悪視程との関係を実データから機械的に学習させる方法を釧路の実データに適用し, 比較的良好な結果が得られること, また悪視程の学習/判別に利用する範囲が広い方が性能が良くなることを示した。

しかし, 本稿で述べたような学習に基づく方法では, 学習済みのタイプの霧に対してしか判別はうまくいかない。より正確な評価を行うためには, 今後, データを増やして実験を行うことが必要であると考えている。

#### 参考文献

- [1] 若山 他, “Ka バンド気象ドップラレーダによる霧観測”, 信学技報 SANE99-102, pp. 45-52, 2000.
- [2] 柳沢 他, “ミリ波レーダによる海霧の観測”, 天気, Vol. 33, No. 11, pp. 603-612, 1986.
- [3] 酒巻 他, “Ka バンド気象ドップラレーダを用いた霧の検出”, 信学技報 SANE2001-13, pp. 9-15, 2001.
- [4] T. Joachims, “Making large-Scale SVM Learning Practical”, Advances in Kernel Methods - Support Vector Learning, B. Schölkopf, et al. (ed.), MIT-Press, 1999.