

## 2 降雪量に関する早期天候情報ガイダンス<sup>1</sup>

### 2.1 はじめに

気象庁では、2019年11月から、「大雪または雪に関する早期天候情報(以下、大雪早天)」の運用を開始した。この情報は原則月・木曜日に、2週目(8から12日先の各日を中心とする5日間)の冬季日本海側<sup>2</sup>の降雪量平年比(以下、降雪量)が、「かなり多い」となる確率が30%以上と見込んだときに発表される。これまで同様の早期に注意喚起する情報として、7日間降雪量を対象に「大雪に関する異常天候早期警戒情報(以下、大雪早警)」を運用してきた。これに代えて大雪早天は、2019年6月より運用を開始した2週間気温予報及び高温や低温に関する早期天候情報と平均(合計)期間をあわせ、5日間降雪量を対象として発表する。大雪早天の目的は大雪早警と同様に、早期に準備や対策を行うことで大雪による交通障害や農作物への被害などを事前に防ぐことである。本章では、このような防災情報としての目的を持った大雪早天の発表に資するためのガイダンスについて説明する。なお、大雪早警については大久保と中三川(2015)を、早期天候情報については平井と伊藤(2019)を参照されたい。

### 2.2 ガイダンスの作成手法

大雪早警と大雪早天では、対象とする降雪量の合計期間が7日間と5日間で異なる。一般に平均(合計)期間が短い方が、長期予報ではノイズとして扱われる短周期の現象(日々の高・低気圧など)の影響を受けやすく、予測は困難になる。そのため、7日間降雪量を対象とした従来手法で、5日間降雪量を対象としたガイダンスを作成すると、予測精度が低下することが分かっている(平井と伊藤, 2019)。そこで大雪早天の運用開始に向けて、ガイダンスの精度改善を目的に調査・開発を行い、従来の7日間降雪量を対象にしたガイダンスと同程度または上回る精度の大雪早天ガイダンスを開発した。

<sup>1</sup> 住友 雅司、伊藤 晋悟、伊藤 明

<sup>2</sup> 発表期間は11月から3月まで、発表地域は北海道日本海側、東北日本海側、長野県北部・群馬県北部、北陸地方、岐阜県山間部、近畿日本海側、山陰である。

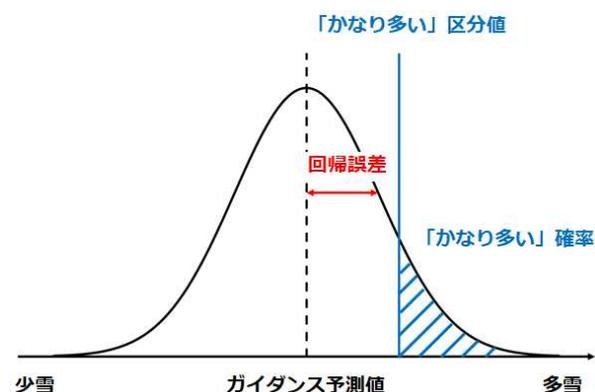
本節では、従来大雪早警ガイダンスの手法について簡単に説明した後、大雪早天ガイダンスで採用した新たな手法や説明変数の変更を説明し、精度を示す。なお、1か月予報など他の季節予報ガイダンスと共通する部分については、田中ほか(2017)を参照されたい。

#### 2.2.1 大雪早警ガイダンスについて

従来大雪早警ガイダンスでは、ガイダンスの確率分布に正規分布を仮定していた(田中ほか, 2017)。正規分布の平均値は、モデル予測値を説明変数、降雪量を目的変数とする線形重回帰式から計算され、標準偏差は平均的な予測誤差として回帰誤差を用いた(第2.2-1図)。そして予測時には、この正規分布と階級区分値から「かなり多い」となる確率を求めた。

#### 2.2.2 大雪早天ガイダンスについて

従来大雪早警と同様に、大雪早天は「プッシュ型の注意喚起情報」であり、情報を発表するか否かの判断が必要になる(平井と伊藤, 2019)。そこでガイダンスを開発するにあたって、降雪量そのものより情報発表の有無と現象発生の有無に注目した。情報発表の有無については、発表基準が「かなり多い」となる確率が30%以上であり、この確率をガイダンスで予測する必要がある。そのため予測対象は降雪量が「かなり多い」であるか否かとし、予測値は「かなり多い」となる確率であるガイダンスを開発すれば、予報作業に利



第2.2-1図 正規分布仮定法のイメージ図

正規分布の平均値をガイダンス予測値、標準偏差を回帰誤差とした正規分布を作成する。この手法は2週間気温予報ガイダンスなどで採用されている。田中ほか(2017)の第3.2-3図に加筆。

用できると考えた。また、大雪早天は防災情報としての役割もあるため、捕捉率(降雪量が「かなり多い」となった際に予測できていた割合)の改善が見込まれる手法を検討した。

ロジスティック回帰は、データを2つ以上のクラス(カテゴリー)に分類する問題(以下、分類問題)で広く利用されており、前述の条件を満たす手法であることから、大雪早天ガイダンスに導入した。ロジスティック回帰は、気象庁のガイダンスでは発雷確率ガイダンスなどで採用されている(後藤, 2018)。ロジスティック回帰の一般的な説明は工藤(2018)及び Bishop(2012)を参照いただき、本項では大雪早天ガイダンスへの適用について説明する。なお、以後では各種図表の説明などでリードタイム表記をする場合、5日間降雪量の合計期間の中日で表す。例えば早期天候情報の対象期間の最初の5日間(以下、早天初日)の場合は、発表日基準で6から10日後までの5日間降雪量を対象にしているため、リードタイム8日となる。

#### (1) ロジスティック回帰について

大雪早警ガイダンスでは連続値である降雪量を目的変数としたが、大雪早天ガイダンスでは降雪量が「かなり多い」となるか否かを目的変数とする。ここでは、降雪量が「かなり多い」となった場合を1、「その他(多い、平年並、少ない、かなり少ない)<sup>3</sup>」となった場合を0として目的変数を定義する。

ロジスティック回帰では、目的変数がベルヌーイ分布に従うことを仮定する。ベルヌーイ分布とは確率 $p$ で1、確率 $1-p$ で0をとるような2値データが従う分布である。第2.2-2図にベルヌーイ分布の例を示す。第2.2-2図(a)に地上気温<sup>4</sup>と降雪量が「かなり多い」と「その他」の散布図を示す。また、第2.2-2図(b)に地上気温が-2.5から-1.5℃の区間(以下、区間A)で集計した、「かなり多い」と「その他」の出現確率を示す。

<sup>3</sup> 本章では「多い(少ない)」を、「多い(少ない)」の区分値より多い(以下である)が、「かなり多い(少ない)」の区分値以下である(より多い)事例と定義する。

<sup>4</sup> 本章では、説明変数に用いるモデル予測値は全て平年からの偏差である。以後では、「地上気温」のように変数名のみ記述する場合、その変数の平年からの偏差を表すものとする。

第2.2-2図(b)から、区間Aでは33%の確率で「かなり多い」が、67%の確率で「その他」が出現していることが分かる。ロジスティック回帰では、この出現確率を推定する。

ここからは第2.2-1表で定義した変数を用いて説明する。ロジスティック回帰では、説明変数 $x$ とパラメータ $w, b$ が与えられると、「かなり多い」となる確率は

$$p(t=1|x) = \sigma(w \cdot x + b) = \frac{1}{1 + \exp(-w \cdot x - b)}$$

で求められる。ここで、 $\sigma(\cdot)$  はシグモイド関数と呼ばれる。第2.2-3図に $x$ を1次元とした場合のシグモイド曲線について示す。この図から、バイアス $b$ によらずシグモイド曲線は0から1の範囲で変化することが分かる。第2.2-3図(a)からは、係数 $w$ のみを変化させると( $b$ は0で固定) $x=0$ で $p=0.5$ になることが分かる。また、 $w$ が正(負)だと単調増加(減少)し、絶対値が大きい(小さい)と傾きが急(緩やか)になることが分かる。第2.2-3図(b)からは、 $b$ のみを変化させると( $w$ は1で固定)曲線の形は変化せず、曲線が平行移動していることが分かる。

第2.2-1表 ロジスティック回帰で用いる変数の定義  
太字はベクトルを表す。

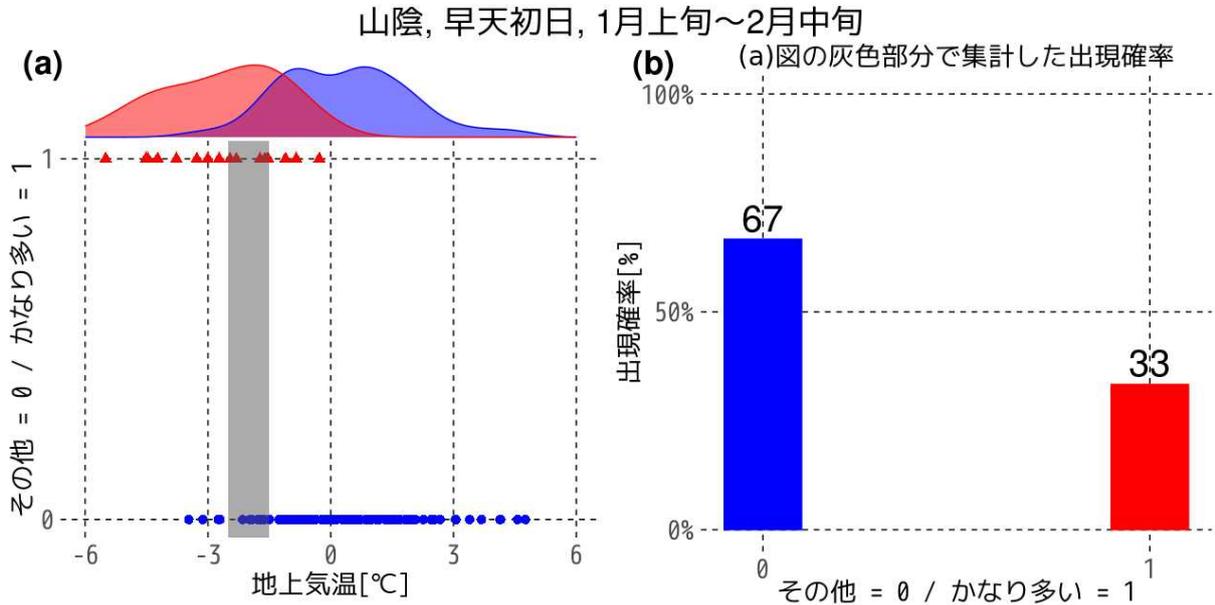
変数	意味
$x$	説明変数(モデル予測値)
$w, b$	推定するパラメータ(回帰係数) $w$ : 各説明変数の係数、 $b$ : バイアス
$p$	予測確率
$t$	目的変数(2値) 1: 「かなり多い」、0: 「その他」

ロジスティック回帰は、シグモイド関数の引数に線形モデル $w \cdot x + b$ を使っている。このことから、シグモイド関数の逆関数は説明変数に対して線形である。この逆関数はロジット関数と呼ばれ、以下のように表される。

$$\text{logit}(p) = \ln \frac{p}{1-p} = w \cdot x + b$$

左側の $\text{logit}(p)$ は確率 $p$ のロジットと呼ばれる。このことは、学習データにおいて説明変数がロジットと線形関係でない場合、ロジスティック回帰を適用できないこと

を示している(工藤, 2018)。第 2.2-4 図に、北陸地方における説明変数とロジットの関係を示す。北陸地方では説明変数の 1 つに地上気温を採用しているの



第 2.2-2 図 地上気温と降雪量が「かなり多い」と「その他」の散布図と、(a)図の灰色部分で集計した「かなり多い」と「その他」の出現確率

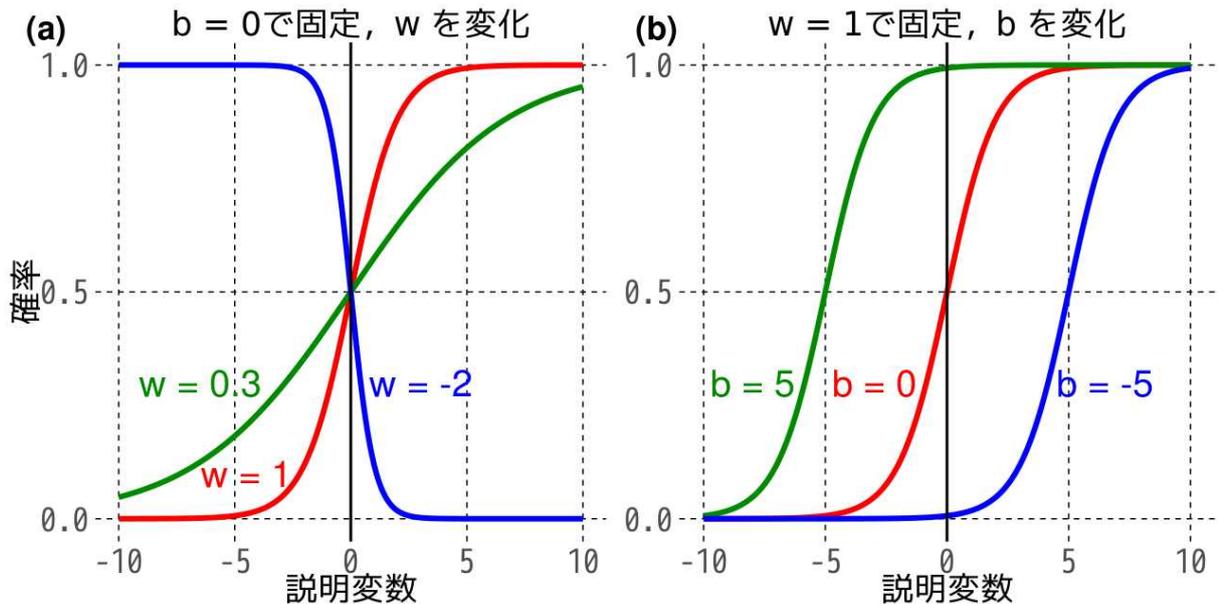
地域: 山陰、リードタイム: 早天初日、期間: 1 月上旬~2 月中旬

赤い点と長方形: 「かなり多い (=1)」、青い点と長方形: 「その他 (=0)」

(a) 図の灰色部分は、地上気温が $-2.5$  から $-1.5^{\circ}\text{C}$ の区間を表す。

(a) 図の上の曲線は、サンプルから推定した各クラスの密度分布を表す。

(b) 図のように、ある確率 $p$ (ここでは $p = 0.33$ )で一方の事象が、確率 $1 - p$ で他方の事象が生じるデータはベルヌーイ分布に従う。



第 2.2-3 図 様々なパラメータを与えたときのシグモイド曲線

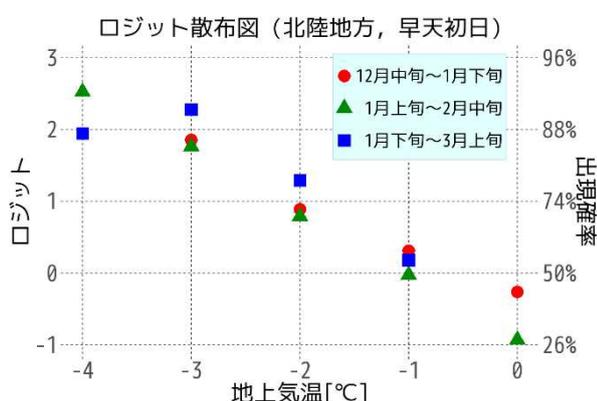
(a) 図は $b = 0$ で固定し、 $w$ のみを可変にした。(b) 図は $w = 1$ で固定し、 $b$ のみを可変にした。

地上気温とロジットの散布図を描画した(使用する説明変数については第 2.2-2 表参照)。その結果、両者の関係は概ね線形であることが確認できる。

## (2) 不均衡データについて

大雪早天が対象とする降雪量が「かなり多い」となる事例は、区分値の定義より、その時期としては概ね 10 年に一度しか起こらない。このことから、「かなり多い」となる事例は「その他」となる事例に比べ非常に少ない。このようにクラス(カテゴリー)間でサンプル数が大きく異なるデータは「不均衡データ」と呼ばれる。分類問題において少数事例を予測したい場合、不均衡データであることは大きな問題となる。ここでは、不均衡データが及ぼす悪影響について説明する。

学習データから統計モデルのパラメータを推定するとき、誤差関数を最小化して値を求める。不均衡データを用いてパラメータを推定する場合、誤差関数への寄与が大きい多数事例を中心にフィッティングされ、相対的に寄与が小さい少数事例は誤分類が増える



第 2.2-4 図 地上気温とロジットの散布図

地域: 北陸地方、リードタイム: 早天初日

右縦軸はロジットに対応する「かなり多い」の出現確率を表す。

学習データと同様に、対象旬の前後 2 旬×30 年を使って描画した<sup>5</sup>。

地上気温を-4.5, -3.5, ..., 0.5と1°C間隔で区切り、各区間の実況値から「かなり多い」が出現するロジット(確率)を求めた。

また大雪事例は少ないため、後述する SMOTE でサンプル数を調整してから計算・描画した。

<sup>5</sup> 学習は地域・リードタイム・初期日ごとに行っている。学習に使用するデータは、ハインドキャスト期間(1981~2010年の30年間)の前後2初期値の計150サンプルである。詳細は田中ほか(2017)を参照されたい。

おそれがある。これでは多数事例のみを予測し、少数事例を予測しない分類モデルができてしまうので、本来の目的を達成できない(第 2.2-5 図)。

大雪早天の場合、「かなり多い」と「その他」の比が 1 対 9 の不均衡データを扱うことになる。この場合、全て「その他」と予測すれば 1 割は誤分類となるが、9 割は適切に分類できたことになり、誤差としては小さいことになる。しかし、我々の予測対象である「かなり多い」に関しては捕捉率が 0%となり、全事例で見逃しとなる。上記の例は極端な場合だが、学習時に「その他」にフィッティングし、「かなり多い」を予測できないガイダンスを導入すると、見逃しが多くなる。第 2.2-6 図に大雪早警ガイダンス(旧ガイダンス、7 日間)、大雪早警ガイダンスの手法を 5 日間降雪量に適用したガイダンス(旧ガイダンス、5 日間)及びロジスティック回帰ガイダンス(不均衡データの対策なし、5 日間)の捕捉率を示す。この図から、ほぼ全てのリードタイムでロジスティック回帰ガイダンスの捕捉率が最低であることが分かる。捕捉率が高く、見逃しが少ないガイダンスの方が、情報の発表や事前の対策に利用でき、防災情報としての目的に資すると考えられる。そこで次に示すような、不均衡データがモデル推定に及ぼす悪影響を緩和する手法を採用した。

## (3) サンプリング手法の検討

不均衡データにおいて、少数事例を予測したい場合、前述の問題は深刻である。しかし、大雪予測に限らず、病気の検出や不良品の判定など、不均衡データは社会の至る所に存在し、その対策手法は既にいくつかが考案されている。Hayat et al. (2019)によると、この問題を解決する手法は以下の 2 つに大別される。

### • データレベルの対策

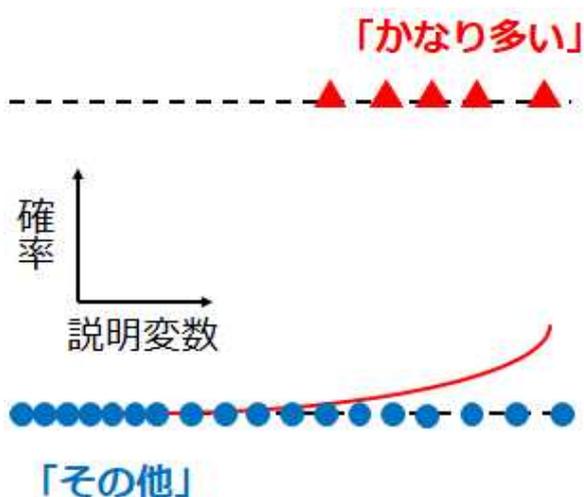
クラス間のサンプル数が均衡になるように学習データを調整する。少数事例を増やす手法(以下、over-sampling)と多数事例を減らす手法(以下、under-sampling)の 2 つに分けられる。

### • アルゴリズムレベルの対策

誤分類のコストを考慮した誤差関数を定義する。

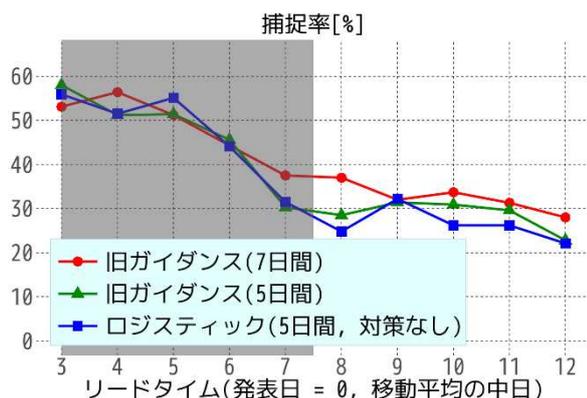
大雪早天ガイダンスでは、データレベルの対策を行う over-sampling を採用した。その理由として、以下が挙げられる。

- データレベルの対策は分類モデルの種類に依らずに適用できる(亀井ほか, 2007)。
- 元々少ない 150 サンプルの学習データで under-sampling すると、サンプル数がさらに減ってしまう。



第 2.2-5 図 不均衡データ対策を行わずにロジスティック回帰を適用した模式図

赤の三角:「かなり多い」サンプル  
 青の丸:「その他」のサンプル  
 赤の実線:ロジスティック回帰の回帰曲線  
 多数事例の「その他」にフィッティングし、少数事例の「かなり多い」を予測できていない。



第 2.2-6 図 各手法での捕捉率の比較

地域:全地域、期間:全期間  
 赤線:旧ガイダンス(7日間)  
 緑線:旧ガイダンス(5日間)  
 青線:ロジスティック回帰ガイダンス(5日間、対策なし)  
 シェード部分は早天対象期間外を表す。  
 不均衡データの対策なしでロジスティック回帰を用いると、捕捉率が低いことが分かる。

over-sampling の中にもいくつか手法があり、大雪早天ガイダンスでは SMOTE (Synthetic Minority Over-sampling Technique) (Chawla et al., 2002) を採用した<sup>6</sup>。SMOTE の手順は以下のとおりである。

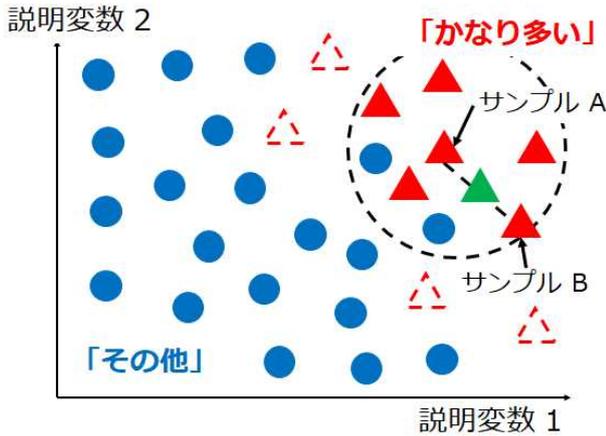
1. 少数事例をランダムに 1 つ選択する(サンプル A とする。)
2. A から距離が近い順に  $k$  個の少数事例を求める(ここでは  $k = 5$  とした。)
3. 2 で求めたサンプルからランダムに 1 つ選ぶ(サンプル B とする。)
4. サンプル A と B を結ぶ直線上にランダムに点を取り、新たなサンプルとする。
5. 1 から 4 の手順を少数事例が指定した数になるまで繰り返す。

この手順を模式的に表したものが第 2.2-7 図である。簡単のため、サンプルの分布が 2 次元平面上で表される場合(説明変数の数が 2 つの場合)を考えているが、多次元でも同様である。大雪早天ガイダンスでは、「かなり多い」と「その他」のサンプル数が同じになるまで上記手順を繰り返した。第 2.2-8 図に、SMOTE によりサンプル数を調整したデータにロジスティック回帰を適用した模式図を示す。両クラスの不均衡が緩和し、少数事例も加味して回帰をとることができるため、「かなり多い」も十分予測されると期待できる。そして、「かなり多い」が予測されることで、不均衡データの対策がない場合に比べ捕捉率が改善されると考えられる。

#### (4) 予測確率の補正

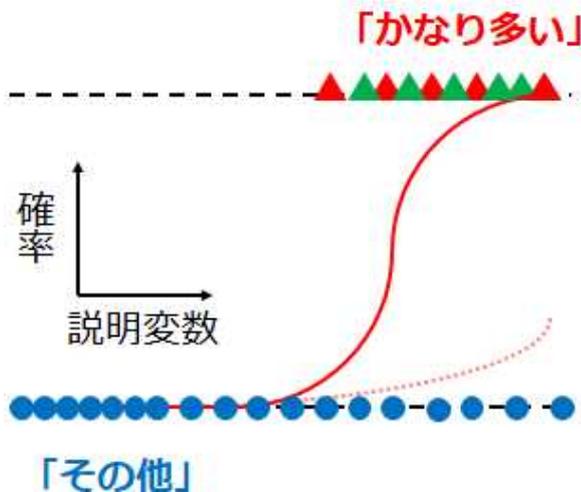
ここまで SMOTE を導入することで、少数事例も予測できる分類モデルを作成できることを述べてきた。しかし、SMOTE を含むデータレベルの対策を行うと、学習データと現実データでクラス間のサンプル比が変わるため、予測される確率を利用する際は補正が必要

<sup>6</sup> SMOTE 以外の over-sampling 手法として、少数事例を復元抽出する ROS (Random Over-Sampling) などが挙げられる。しかし、ROS は元データに含まれる少数事例に依存しやすく、過学習をするおそれがある (Chawla et al., 2002)。一方 SMOTE は復元抽出をせず、サンプル間の内分点を新たなサンプルとするので、過学習のリスクが抑えられやすいと考えられる。



第 2.2-7 図 SMOTE の模式図

緑の三角: SMOTE で生成された「かなり多い」サンプル  
 黒の破線: サンプル A から距離が  $k$  番目に近いサンプルの範囲(本文手順の 2 に該当)  
 赤破線の三角: 黒の破線外にあり、サンプル B となる候補から外れたサンプル  
 ランダムに選ばれたサンプル A とその近傍で選ばれたサンプル B の間に、新たなサンプルが生成される。  
 この操作を少数事例が指定した数になるまで繰り返す。



第 2.2-8 図 SMOTE によりサンプル数を調整したデータにロジスティック回帰を適用した模式図  
 ピンクの点線: 「SMOTE なし」の回帰曲線  
 赤の実線: 「SMOTE あり」の回帰曲線  
 SMOTE により、少数事例の「かなり多い」も加味した回帰曲線となっている。

である。SMOTE などによりクラス間の不均衡を緩和した学習データから分類モデルを作ると、実際のデータに比べて「かなり多い」サンプルが増えているため、その予測値は「かなり多い」確率を現実より大きく表現してしまい、空振りが多発してしまう。

この空振りが多発する傾向を補正する方法として、Bishop (2012) は事前確率を補正する旨を述べている。大雪早天ガイダンスでは、Bishop (2012) の方法に則り、予測確率を補正した。なお以後では、不均衡データ対策済みの学習データの確率には下添字に  $s$  を付け、現実データの確率(添字なし)と区別する。また、事象 B が起きる下で事象 A が起きる確率(条件付き確率)は  $p(A|B)$  と表す。

データレベルの対策を取ると、事前確率が学習データと現実データで異なる。例えば大雪早天の場合、「かなり多い」はその時期としては概ね 10 年に一度のため、元のデータでは  $p(t=1) \approx 1/10$  である。しかし、SMOTE でクラス間のサンプル数が等しくなるように調整すると、 $p_s(t=1) \approx 1/2$  となる。ベイズの定理より事後確率は事前確率に比例する<sup>7</sup>ので、補正前の事後確率  $p_s(t|\mathbf{x})$  は  $p_s(t)/p(t)$  のバイアスを持っている。そのため、以下の補正を行う必要がある。

1. 事前確率の違いを補正

$$p'(t|\mathbf{x}) = p_s(t|\mathbf{x}) \cdot \frac{p(t)}{p_s(t)}$$

2. 全事象の確率の総和が 1 になるように規格化

$$p(t|\mathbf{x}) = \frac{p'(t|\mathbf{x})}{p'(t=1|\mathbf{x}) + p'(t=0|\mathbf{x})}$$

ここでは 2 段階に処理を記述したが、より一般的に  $t=1$  のクラスを  $\alpha$  倍、 $t=0$  のクラスを  $\beta$  倍でサンプリングしたとすると、補正式は以下のように表される (Pozzolo et al., 2015)。

$$p(t=1|\mathbf{x}) = \frac{\beta \cdot p_s(t=1|\mathbf{x})}{\beta \cdot p_s(t=1|\mathbf{x}) + \alpha \cdot p_s(t=0|\mathbf{x})}$$

ロジスティック回帰で推定される係数は補正前の予測値に対するものなので、補正式を適用すると

<sup>7</sup> ガイダンス予測における事前確率と事後確率の関係をベイズの定理を使って考える。ここでは、学習データと新たな入力データを区別するため、前者の目的変数と説明変数を  $\{\mathbf{T}, \mathbf{X}\}$ 、後者のそれらを  $\{t, \mathbf{x}\}$  と表す。ガイダンスによる予測とは、学習データと説明変数(ともに既知)から事後確率  $p(t|\mathbf{T}, \mathbf{X}, \mathbf{x})$  を求めることであり、ベイズの定理から以下のように表される。

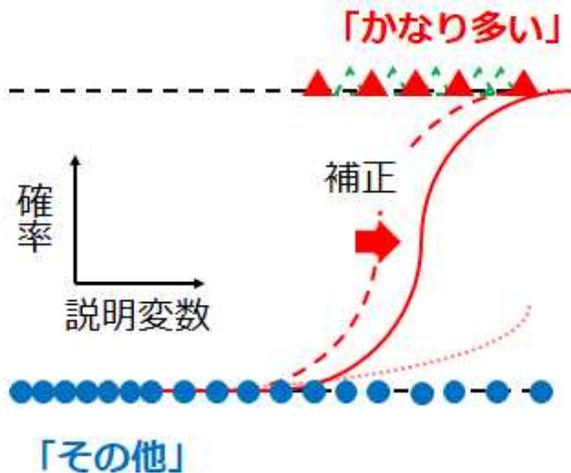
$$p(t|\mathbf{T}, \mathbf{X}, \mathbf{x}) = p(\mathbf{T}, \mathbf{X}|t, \mathbf{x}) \cdot p(t)/p(\mathbf{T}, \mathbf{X})$$

上式から事後確率は事前確率  $p(t)$  (データが与えられる前の確率) に比例することが分かる。なお、本文中では表記を簡単に保つため  $\{\mathbf{T}, \mathbf{X}\}$  を省略する。

$$p(t = 1|x) = \frac{1}{1 + \exp(-w \cdot x - b - \ln \beta/\alpha)}$$

$$= \sigma\left(w \cdot x + b + \ln \frac{\beta}{\alpha}\right)$$

と表される。

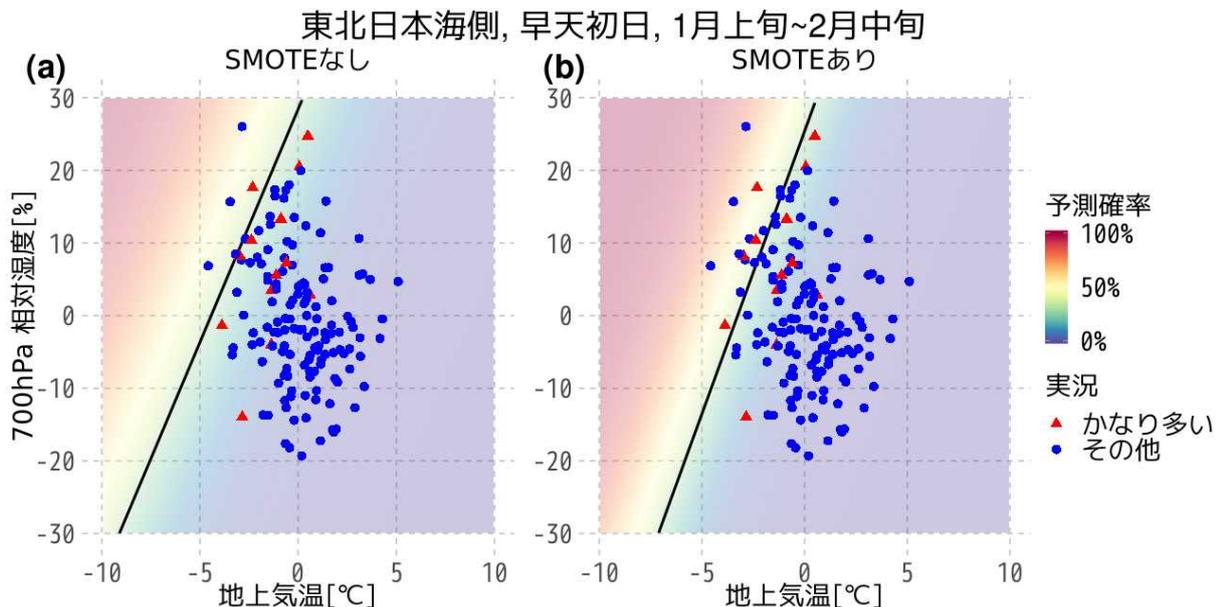


第 2.2-9 図 SMOTE で調整したデータにロジスティック回帰を適用し、確率を補正した模式図  
 ピンクの点線:「SMOTEなし」の回帰曲線  
 赤の破線:「SMOTEあり」で補正前の回帰曲線  
 赤の実線:「SMOTEあり」で補正後の回帰曲線  
 補正により、回帰曲線は傾きを変えず平行移動する。

第 2.2-9 図に SMOTE で調整したデータにロジスティック回帰を適用し、さらに事後確率を補正した模式図を示す。前述のシグモイド関数の特徴のとおり、補正により回帰曲線は傾きを変えず平行移動する。大雪早天ガイダンスでは説明変数に気温を用いているが(第 2.2-2 表)、補正により回帰曲線は低温方向(第 2.2-9 図では右方向)に平行移動し、空振りが多発するのを抑える。また、第 2.2-10 図に「SMOTEなし」の場合((a)図)と「SMOTEあり」の場合((b)図)における予測確率と実況の散布図を示す。なお、「SMOTEあり」の予測確率は前述の補正をしたものである。「SMOTEあり」は「SMOTEなし」に比べ、「かなり多い」を予測できていることが分かる。補正では回帰曲線の傾きは変化しないため、SMOTE の効果は補正後も残っている。また、両図の違いは第 2.2-9 図の模式図とも整合している。

### 2.2.3 説明変数の変更

第 2.2-2 表に、大雪早天ガイダンスで使用する説明変数の組み合わせを示す。長野県北部・群馬県北部及び岐阜県山間部で北陸地方の地域平均値を使う



第 2.2-10 図 予測確率と実況の散布図  
 地域: 東北日本海側、リードタイム: 早天初日、期間: 1月上旬~2月中旬  
 (a) 図: 不均衡データの対策をせずにロジスティック回帰を適用した場合  
 (b) 図: SMOTE で調整したデータでロジスティック回帰を適用し、確率の補正をした場合  
 カラー: ロジスティック回帰による予測確率(黒実線は発表基準の 30%)、赤点:「かなり多い」、青点:「その他」  
 東北日本海側では説明変数に地上気温(横軸)と 700hPa 相対湿度(縦軸)を使っている(第 2.2-2 表)。

第 2.2-2 表 大雪早天ガイダンスで使用する説明変数の組み合わせ

TS: 地上気温、T700: 700hPa 気温、 $\omega$ 700: 700hPa 鉛直 p 速度、RH700: 700hPa 相対湿度、T5-T9: 500hPa 気温と 925hPa 気温の差、T7-T9: 700hPa 気温と 925hPa 気温の差  
使用する説明変数を「○」で示している。

長野県北部・群馬県北部及び岐阜県山間部で北陸地方の地域平均値を使う以外、旧ガイダンスと変更はない。

地域	TS	T700	$\omega$ 700	RH700	T5-T9	T7-T9
北海道日本海側						
東北日本海側	○			○		
長野県北部・群馬県北部 岐阜県山間部		○ (北陸地方の 地域平均値)	○ (北陸地方の 地域平均値)			
北陸地方	○		○		○	
近畿日本海側 山陰	○		○			○

以外、従来の大雪早警ガイダンスと変更はない。大雪早警ガイダンスでは、長野県北部・群馬県北部及び岐阜県山間部の説明変数に関東甲信地方及び東海地方で地域平均したモデル予測値を使用していた。しかし、大雪早天ガイダンスでは両地域ともに北陸地方で地域平均したモデル予測値を使用することにした。

変更前後の違いを確認するために、第 2.2-11 図に岐阜県山間部における 5 日間降雪量の実況値と説明変数の散布図を示す。第 2.2-11 図 (b)、(e) から、説明変数の変更により降雪量と鉛直 p 速度の関係が逆転していることが分かる。変更前は「下降流が予測されれば多雪」だったが、変更後は「上昇流が予測されれば多雪」となっている。この理由は、東海地方で地域平均すると太平洋側の地点が多く含まれるので、冬型の気圧配置が強まると山越え後の下降流が表現されるためだと考えられる。一方、北陸地方で地域平均すると、冬型の気圧配置が強まれば山越え時の上昇流や雪雲による上昇流が表現されると考えられる。また第 2.2-11 図 (c)、(f) より、説明変数間の相関は変更後の方が弱く、多重共線性<sup>8</sup>による悪影響が軽減さ

<sup>8</sup> 説明変数間に複数の完全または近似的な線形関係が成立していること。多重共線性がある場合、用いる説明変数の加除により回帰式の係数が大きく変化したり、通常考えられる符号と異なる結果が得られたりすることなど、回帰式の信頼性が低下する。

れることが期待される。なお、長野県北部・群馬県北部でも同様の変化が確認された(図略)。

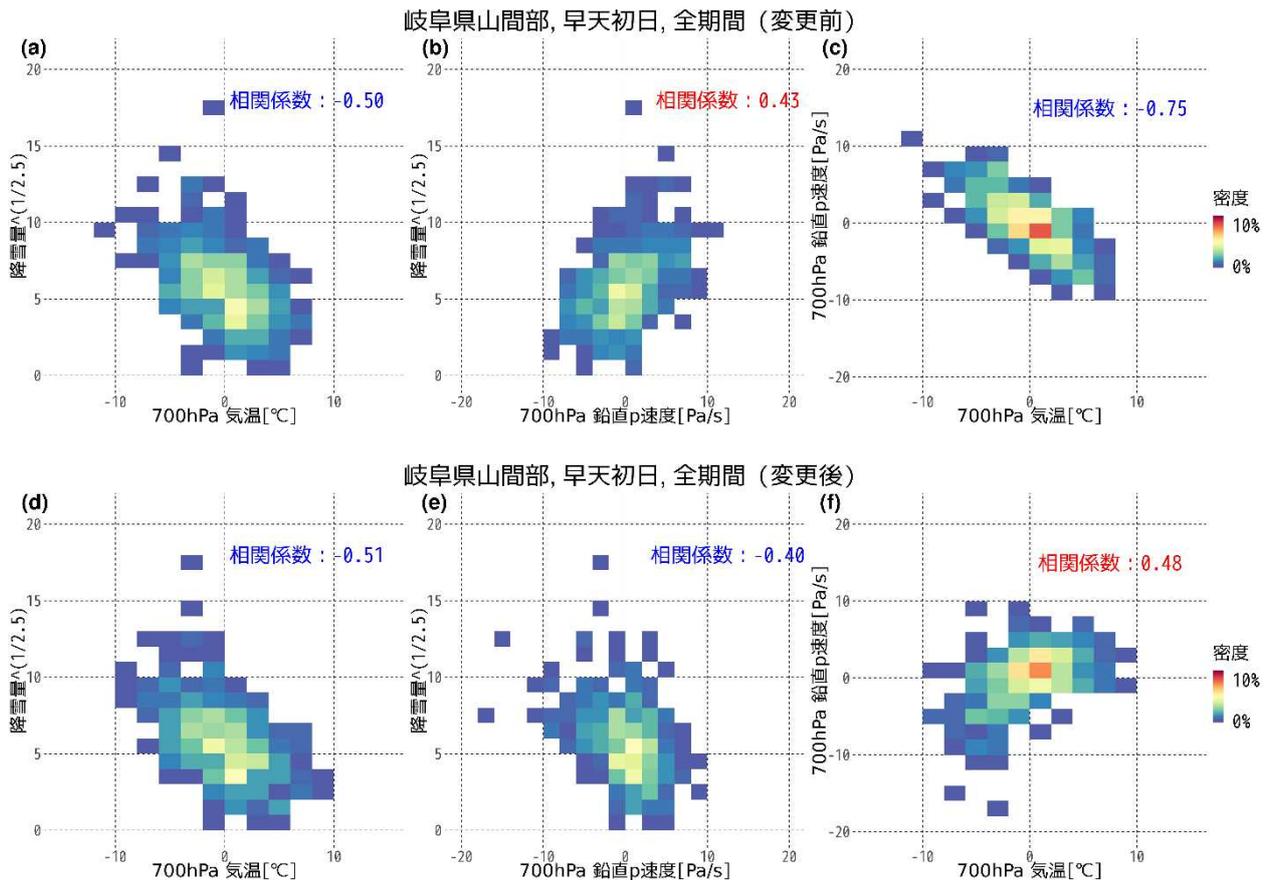
この変更により、ほぼ全てのリードタイムで捕捉率・適中率ともに改善していることが確認された(図略)。また、精度改善に加え、予報作業時にも降雪量ガイダンスと説明変数の関係が解釈しやすくなった。

2.3 ガイダンスの精度評価

本節では、大雪早天ガイダンスの精度を示す。以下では、従来の大雪早警ガイダンスを旧ガイダンス(7日間)、旧ガイダンスの手法で 5 日間降雪量を対象に作成したガイダンスを旧ガイダンス(5日間)、第 2.2 節で述べた手法を全て導入したものを新ガイダンスと呼ぶ(第 2.3-1 表)。検証は検討対象年のみを除く交差検証(クロスバリデーション)に基づいて行った。なお、ここに示す予測精度は、2017 年 3 月に運用を開始した全球 EPS(気象庁地球環境・海洋部, 2017)の再予

第 2.3-1 表 ガイダンス名称の一覧

名称	予測対象	手法
旧ガイダンス (7日間)	7日間降雪量	線形回帰
旧ガイダンス (5日間)		
新ガイダンス	5日間降雪量	ロジスティック回帰 SMOTE 説明変数の変更



第 2.2-11 図 説明変数の変更前(上図)と変更後(下図)の散布図

地域:岐阜県山間部、リードタイム:早天初日、期間:全期間

(a)~(c)図:東海地方で地域平均したモデル予測値を用いた場合(変更前)

(d)~(f)図:北陸地方で地域平均したモデル予測値を用いた場合(変更後)

(a)、(d)図:700hPa 気温と 5 日間降雪量の実況値の散布図

(b)、(e)図:700hPa 鉛直 p 速度と 5 日間降雪量の実況値の散布図

(c)、(f)図:700hPa 気温と 700hPa 鉛直 p 速度の散布図

各図の上には相関係数を示している(正の場合は赤字、負の場合は青字)。

なお、相関係数を計算するために、降雪量は 0 を除去し 2.5 乗根した。

変更後は 700hPa 鉛直 p 速度と降雪量の相関が負になり、「上昇流が予測されれば多雪」という関係性が表現されている。

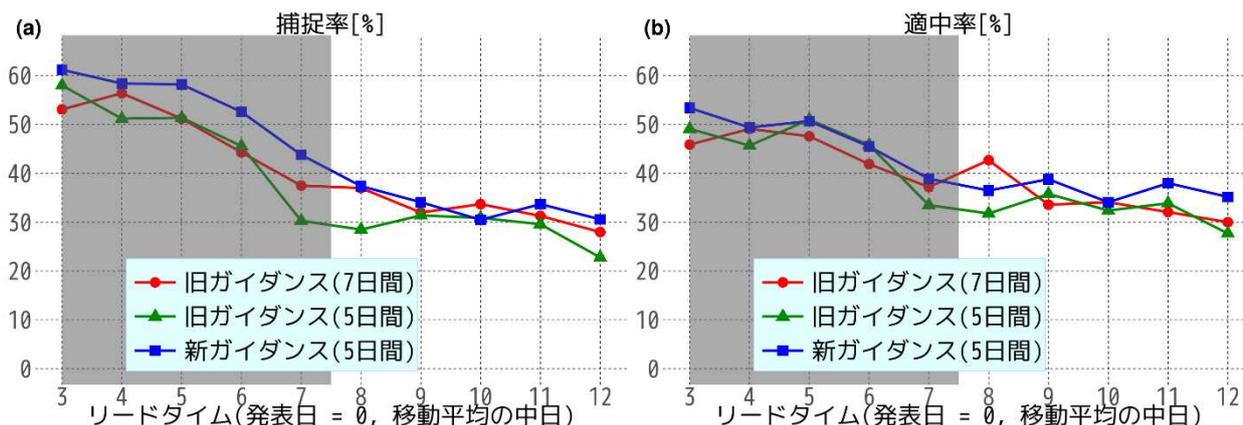
報(初期日は 1981~2010 年、各旬末日で大雪早天対象期間は計 450 事例、アンサンブルメンバー数は 5 で現業の仕様の 26 に比べて少ない)によるものである。

第 2.3-1 図に、全地域・全期間<sup>9</sup>で集計した「かなり多い」の捕捉率と適中率を示す。この図から以下のことが分かる。

- 線形ガイダンス同士を比べると、7 日間から 5 日間の変更で捕捉率・適中率の悪化が明瞭である。
- 新ガイダンスの捕捉率・適中率は、ほぼ全てのリードタイムで旧ガイダンス(5 日間)を上回った。
- 新ガイダンスの捕捉率・適中率は、ほぼ全てのリードタイムで旧ガイダンス(7 日間)と同程度または上回った。

まず、線形ガイダンス同士の比較について説明する。7 日間から 5 日間の変更で捕捉率・適中率が悪化

<sup>9</sup> 検証対象は 11 月から 3 月(大雪の早期天候情報の発表期間に相当)の全球 EPS の再予報。ただし、近畿日本海側と山陰は 11 月下旬から 3 月。



第 2.3-1 図 旧ガイダンス(7 日間:赤線、5 日間:緑線)と新ガイダンス(青線)の精度比較

地域:全地域、期間:全期間、(a)図:捕捉率、(b)図:適中率

赤線:旧ガイダンス(7 日間降雪量、線形回帰)

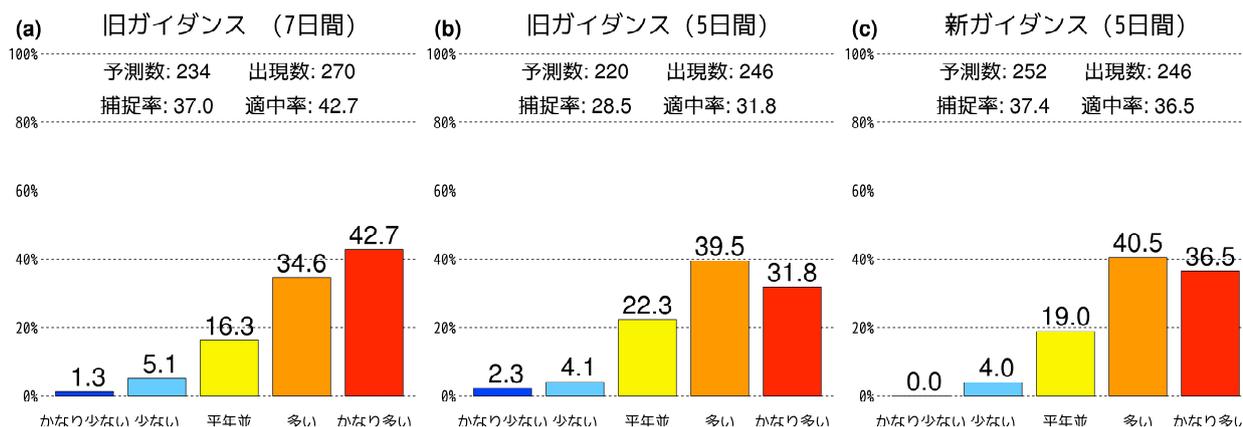
緑線:旧ガイダンス(5 日間降雪量、線形回帰)

青線:新ガイダンス(5 日間降雪量、ロジスティック回帰+SMOTE+説明変数の変更)

シェード部分は早天対象期間外を表す。

新ガイダンスの精度は、ほぼ全てのリードタイムで旧ガイダンス(5 日間)を上回っている。

また、旧ガイダンス(7 日間)と比較しても同程度または上回っている。



第 2.3-2 図 「かなり多い」確率が 30%以上のときにおける、実況値の階級別出現率<sup>10</sup>

地域:全地域、リードタイム:早天初日、期間:全期間

(a)図:旧ガイダンス(7 日間)、(b)図:旧ガイダンス(5 日間)、(c)図:新ガイダンス

横軸は降雪量の各階級を表し、左から「かなり少ない」、「少ない」、「平年並」、「多い」、「かなり多い」である。

縦軸は各階級の出現率を表す。

予測数は「かなり多い」確率が 30%以上になった回数、出現数は「かなり多い」が出現した回数である。

した主な要因は、合計期間が短くなったためだと考えられる。第 2.2 節で述べた通り、合計期間が短くなるとシグナル(予測可能)に比べノイズ(予測不可能)の割合が大きくなるため、予測精度は一般に低下する。

次に、新ガイダンスの精度について説明する。新ガイダンスでは、ほぼ全てのリードタイムで旧ガイダンス

(5 日間)の捕捉率・適中率を上回った。また、捕捉率については旧ガイダンス(7 日間)を概ね上回り、適中率は旧ガイダンス(7 日間)と同程度となった。精度改善の理由として、分類問題としてアプローチしたため大雪早天の情報形態に即したガイダンスを作成できたこと、SMOTE を導入して不均衡データの対策をしたことが挙げられる。その結果、大雪早天の情報形態では特に重要な指標である、捕捉率・適中率を概ね改善することができた。

<sup>10</sup> 第 2.3-2 図は出現率の総和が 100%になるように、「平年並」の出現率は 100%から「平年並」以外の出現率を引いて求めた。

第 2.3-2 図に、リードタイムが早天初日の降雪量の階級別出現率を示す。この図は、それぞれのガイドンが大雪早天の発表基準(「かなり多い」確率が 30%以上)を予測したとき、実況で降雪量がどの階級に属していたかを示したものである。新ガイドンでは、発表基準に達したときに「多い」と「かなり多い」が出現する確率は 77.0%と多雪傾向を予測できている。この数値は、旧ガイドンの両階級の出現率の和 77.3%とほぼ同じである。また、新ガイドンでは、発表基準に達したときに「少ない」と「かなり少ない」が出現する確率は 4.0%であり、小さいことが分かる。新ガイドンでは捕捉率・適中率の改善に加え、傾向も予測できているので、空振り感が小さいガイドンと考えられる。

## 2.4 事例検証

ここではハインドキャスト期間内で事例検証を行った結果を示す。第 2.4-1 図は、岐阜県山間部における 5 日間降雪量((a)図)と 2001 年 2 月 28 日初期値のガイドン予測確率((b)図)の時系列である。

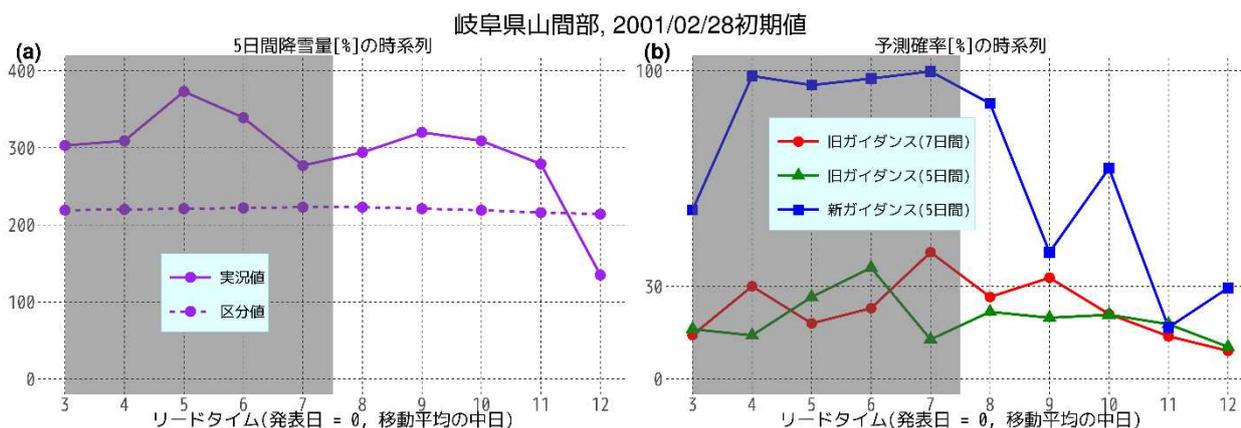
第 2.4-1 図(a)から分かるように、この事例では早天対象期間に含まれるリードタイム 8 から 11 日目において、5 日間降雪量が「かなり多い」となった。

ここで、ガイドンによる予測確率(第 2.4-1 図(b))を確認すると、リードタイム 8 から 10 日目にかけて、旧ガイドン(7 日間)は発表基準近傍の 30%前後を予

測しているが、旧ガイドン(5 日間)は 20%台で発表基準に達していない。一方、新ガイドンはリードタイム 10 日目まで 30%を超えており、本事例において新ガイドンを用いた場合、大雪早天の発表が可能となる。第 2.3 節で述べた通り、新ガイドンでは捕捉率・適中率が概ね改善したが、本事例はその改善に寄与した事例の 1 つと考えられる。

## 2.5 大雪早天ガイドンの利用上の注意事項

大雪早天ガイドンは、予測確率を解釈する上で注意すべき点がある。第 2.4-1 図(b)を確認すると、新ガイドンはリードタイム 8 日目以降で確率の変化が激しいことが分かる。前述のように捕捉率・適中率は概ね改善されたが、確率の信頼度は旧ガイドン(7 日間)及び旧ガイドン(5 日間)に比べ悪化していることが分かっている(図略)。信頼度とは、予測確率と現象の出現率がどの程度一致しているかを測る指標であり、詳細は中三川(2013)を参照いただきたい。新ガイドンでは高確率予測時に信頼度が悪化しており、このことが第 2.4-1 図(b)で確率が激しく変化している一因と考えられる。しかし、信頼度の悪化は高確率予測時が主で、発表基準である 30%付近では大きな悪化は確認されていない。そのため、情報発表の判断には直接影響しないと考えられる。



第 2.4-1 図 岐阜県山間部における 5 日間降雪量と 2001 年 2 月 28 日初期値のガイドン予測確率の時系列

(a) 図: 5 日間降雪量(実線)と「かなり多い」の区分値(破線)、(b) 図: 各手法のガイドン予測結果  
シェード部分は早天対象期間外を表す。

(a) 図縦軸は 5 日間降雪量、(b) 図縦軸は「かなり多い」となる予測確率を表す。

この事例の早天対象期間内では、リードタイム 8 から 11 日目までが「かなり多い」となっている。

一方、ガイドン予測確率が発表基準の 30%以上になったのは、旧ガイドン(7 日間)で 9 日目、旧ガイドン(5 日間)はなし、新ガイドンは 8 から 10 日目となっている。

## 2.6 まとめ

ここまで大雪早天で新たに導入したガイダンスについて述べてきた。新ガイダンスでは、大雪早天の情報形態にあった手法としてロジスティック回帰を導入し、さらに大雪事例の出現頻度が少ないことを考慮し、サンプリング手法を工夫した。その結果、対象とする降雪量の合計期間が7日間から5日間に短くなっても、捕捉率・適中率が従来の大雪早警ガイダンスと同程度または上回るものを開発することができた。一方、第2.4節で述べたように、新ガイダンスで高確率を予測した場合、その信頼度が低いことが分かっている。情報発表の判断は予測確率が30%以上か否かで行うため、高確率域の信頼度悪化は発表判断に直接影響を及ぼさないと考えられるが、今後は原因調査も含めて改善する必要がある。また、北海道日本海側の精度が他の地域と比べ低いことが分かっているが、この点も原因調査して改善を目指したい。

## 参考文献

- 大久保忠之, 中三川浩, 2015: 大雪に関する異常天候早期警戒情報の開始. 平成 25 年度季節予報研修テキスト, 気象庁地球環境・海洋部, 1-16.
- 亀井靖高, 松本真佑, 柿元健, 門田暁人, 松本健一, 2007: オーバーおよびアンダーサンプリング法を用いた Fault-prone モジュール判別モデルの精度評価. 情報処理学会論文誌, Vol. 48, No. 8, 2651-2662.
- 気象庁地球環境・海洋部, 2017: 1か月予報システムの更新～全球アンサンブル予報システムの運用開始～. 平成 28 年度季節予報研修テキスト, 81pp.
- 工藤淳, 2018: ガイダンスの解説. 数値予報課報告・別冊第 64 号, 気象庁予報部, 35-47.
- 後藤尚親, 2018: ガイダンスの解説. 数値予報課報告・別冊第 64 号, 気象庁予報部, 94.
- 田中基裕, 伊藤晋悟, 平井雅之, 2017: 1 か月予報及び異常天候早期警戒情報のためのガイダンスの改善. 平成 28 年度季節予報研修テキスト, 気象庁地球環境・海洋部, 48-64.
- 中三川浩, 2013: 季節予報の評価手法. 平成 24 年度季節予報研修テキスト, 気象庁地球環境・海洋部, 271-281.
- 平井雅之, 伊藤晋悟, 2019: 2 週間気温予報と早期天候情報. 平成 30 年度季節予報研修テキスト, 気象庁地球環境・海洋部, 10-42.
- Bishop, C. M., 2012: パターン認識と機械学習 上. 丸善出版, 第 9 版, 349pp.
- Chawla, N. V., K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, 2002: SMOTE Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, **16**, 321-357.
- Hayat, M., S. Khan, W. Zamir, J. Shen, and L. Shao, 2019: Max-margin Class Imbalanced Learning with Gaussian Affinity. *2019 IEEE International Conference on Computer Vision*, 6469-6479.
- Pozzolo, A. D., O. Caelen, R. A. Johnson, and G. Bontempi, 2015: Calibrating Probability with Undersampling for Unbalanced Classification. *2015 IEEE Symposium Series on Computational Intelligence*, 159-166.