



MSMガイダンスの概要と特徴

気象庁予報部 数値予報課

2013年11月20日

- ガイダンスについてのおさらい
 - ガイダンスとは
 - 気象庁ガイダンスの作成に用いる予測手法
- MSMガイダンス
 - MSMガイダンスの概要
 - MSMガイダンスの予測精度

ガイダンスについてのおさらい

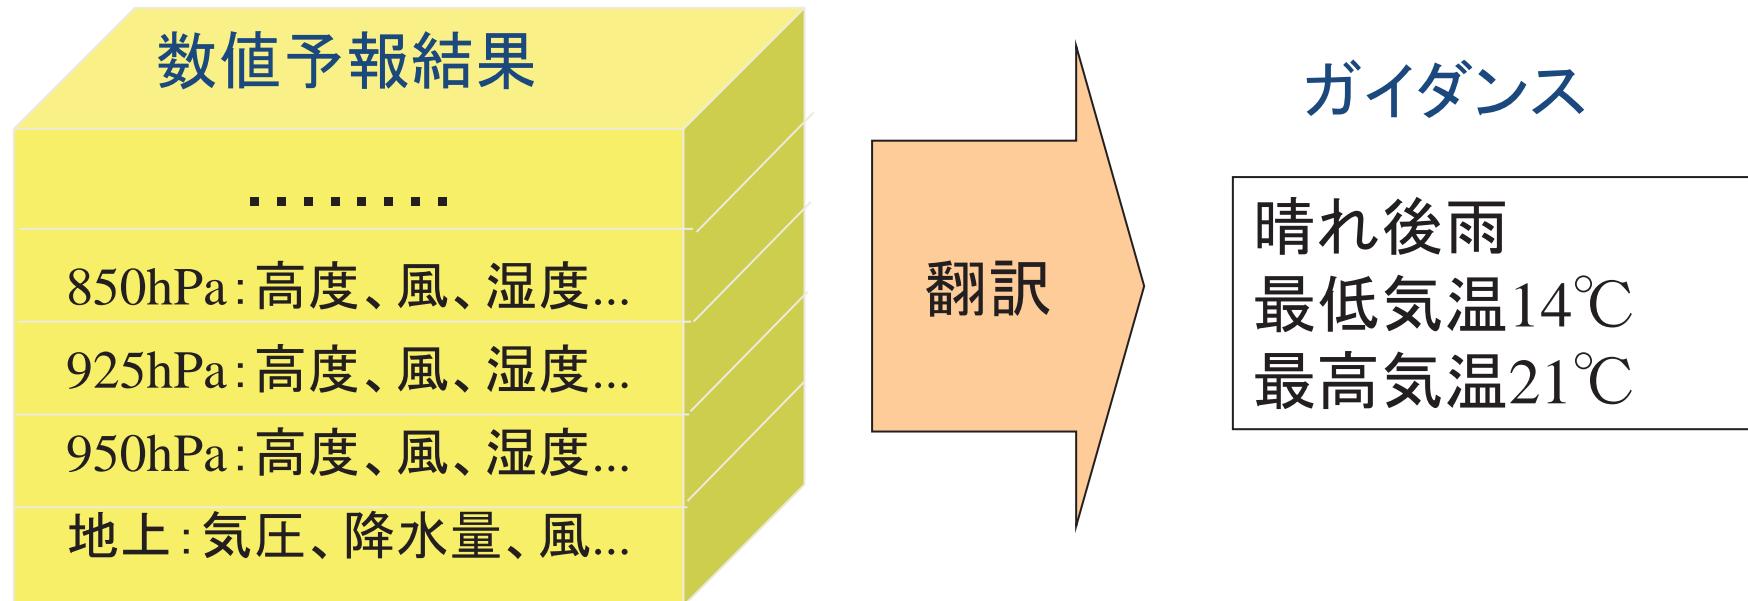
ガイダンスとは

数値予報モデルはスーパーコンピュータを利用して未来の気象状況の予測を行います。

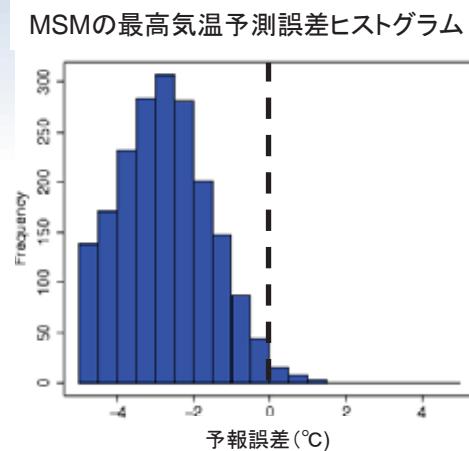
ガイダンスは数値予報モデルの出力を統計手法を利用して加工し、予報精度の改善や利用者が利用しやすい形に加工して提供し、予報作業を支援することを目的に作成しています。

ガイダンスとは

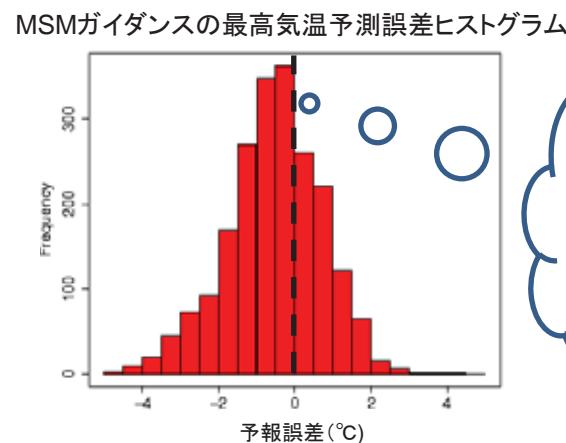
数値予報結果を予報に必要な要素へ客観的に翻訳したもの



予測精度の改善例(最高気温ガイダンス)

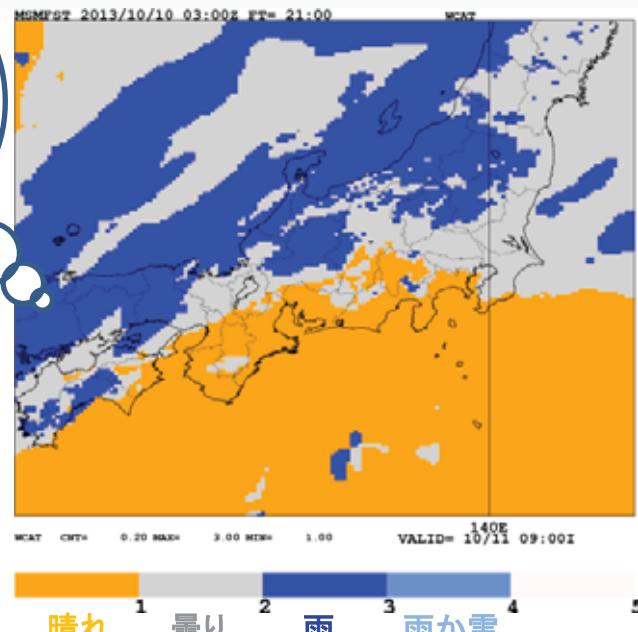


モデルの
予測しな
い量(天
気)に変
換



モデル
の系統
誤差を
軽減

要素変換の例(天気カテゴリの分布)

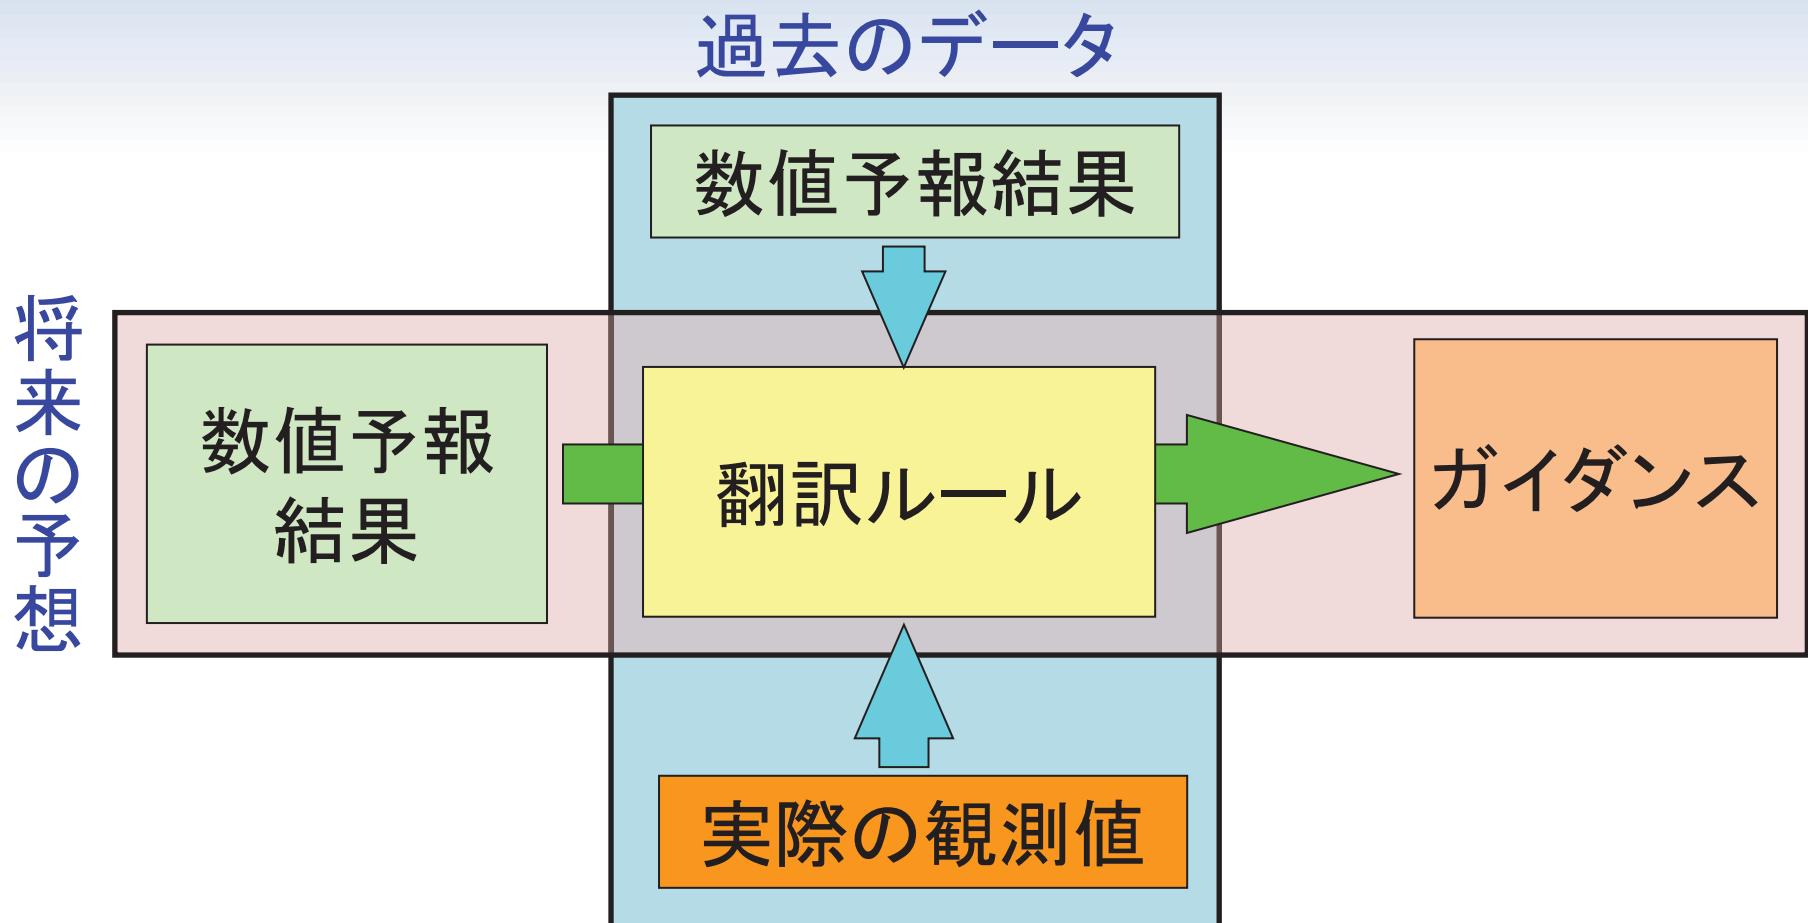


2013年8月の東京における実況が30°C以
上の日の予測誤差のヒストグラム
モデル(上)、ガイダンス(下)

予報担当者が一見してモデルの予測す
る天気を把握できるように加工



ガイダンスの作成手順

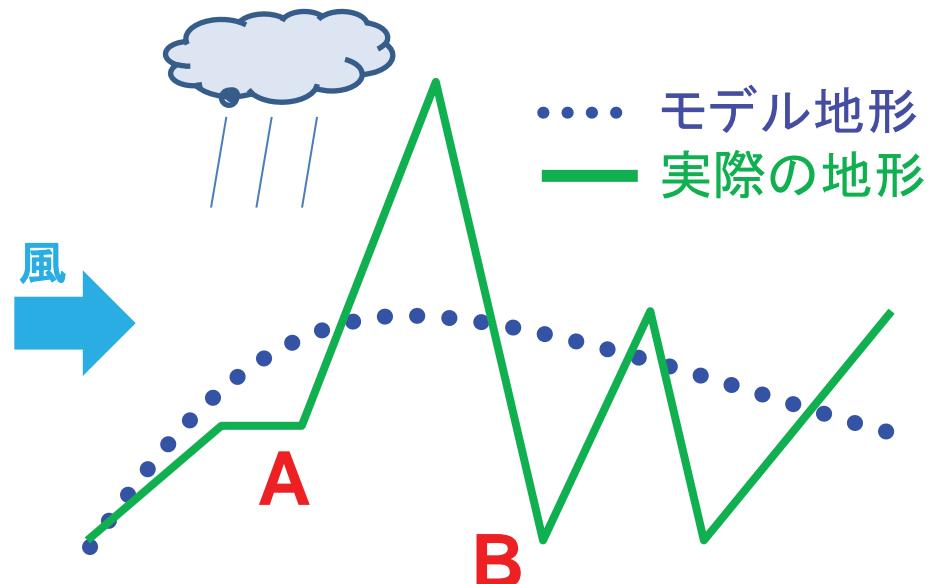


1. 過去データより翻訳ルールを作成(縦枠)
2. ルールを使って数値予報結果を翻訳(横枠)

ガイダンス作成のメリット(系統誤差修正)

系統的(一貫性がある)誤差は**修正可能**

モデル地形と実地形の違い



実際の地形では

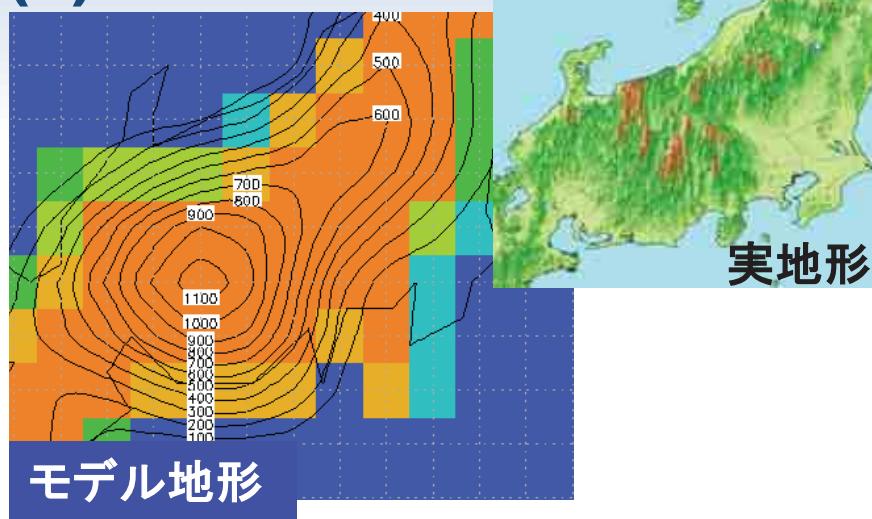
- A: 急斜面で地形性の降水多い
- B: 標高低く、気温高い

モデルの地形では

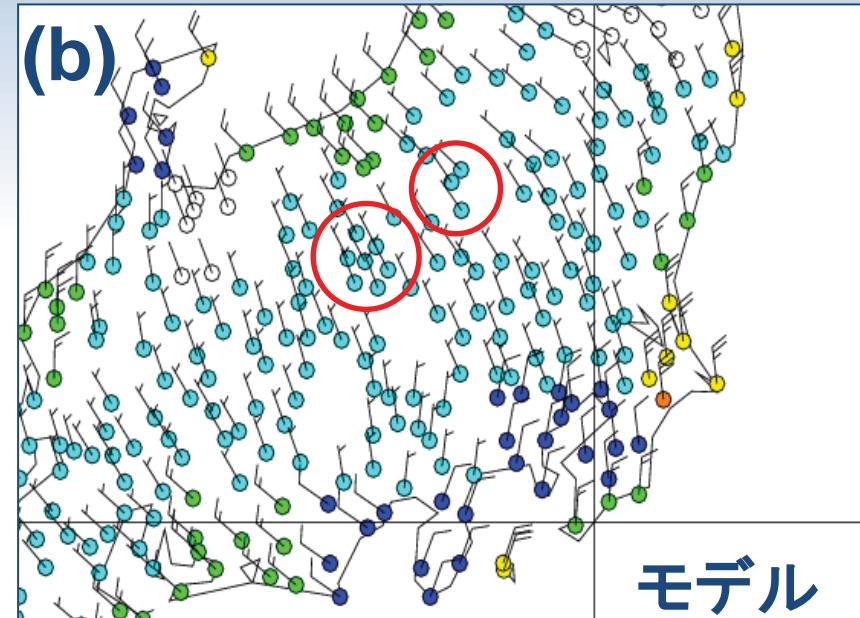
- A: 地形がなだらかで降水少ない
- B: 標高高く、気温低い

系統誤差の修正例

(a)

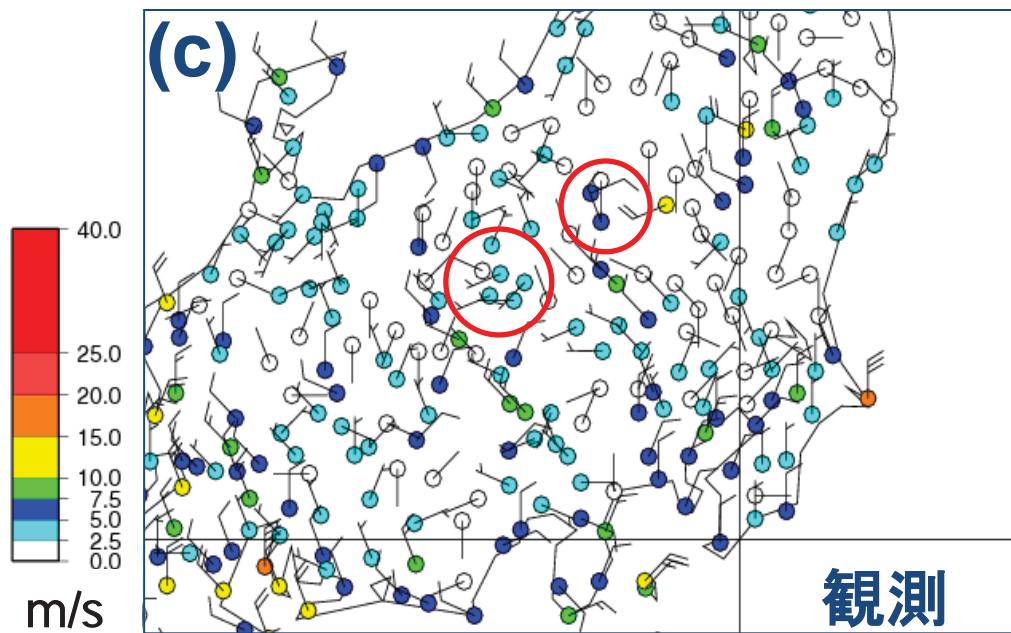


(b)



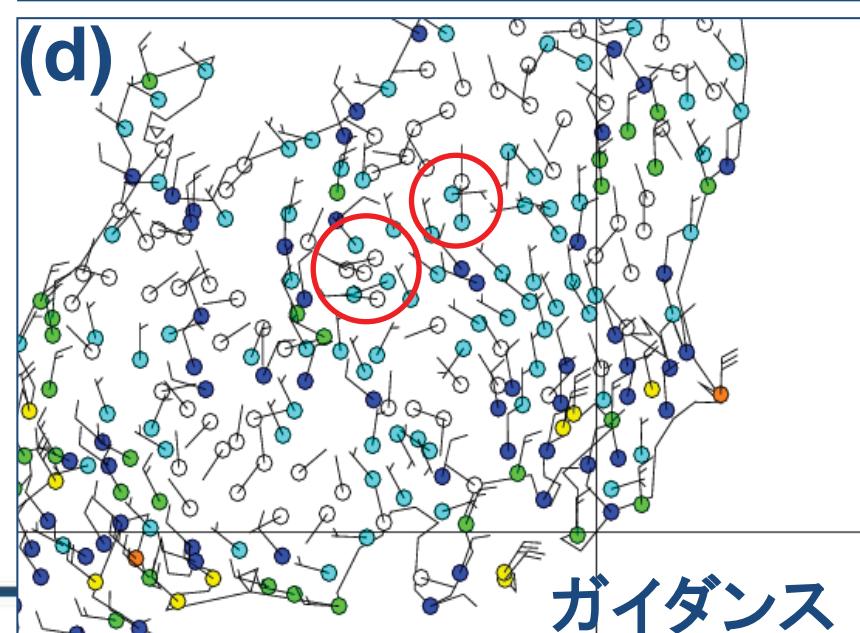
モデル

(c)



観測

(d)

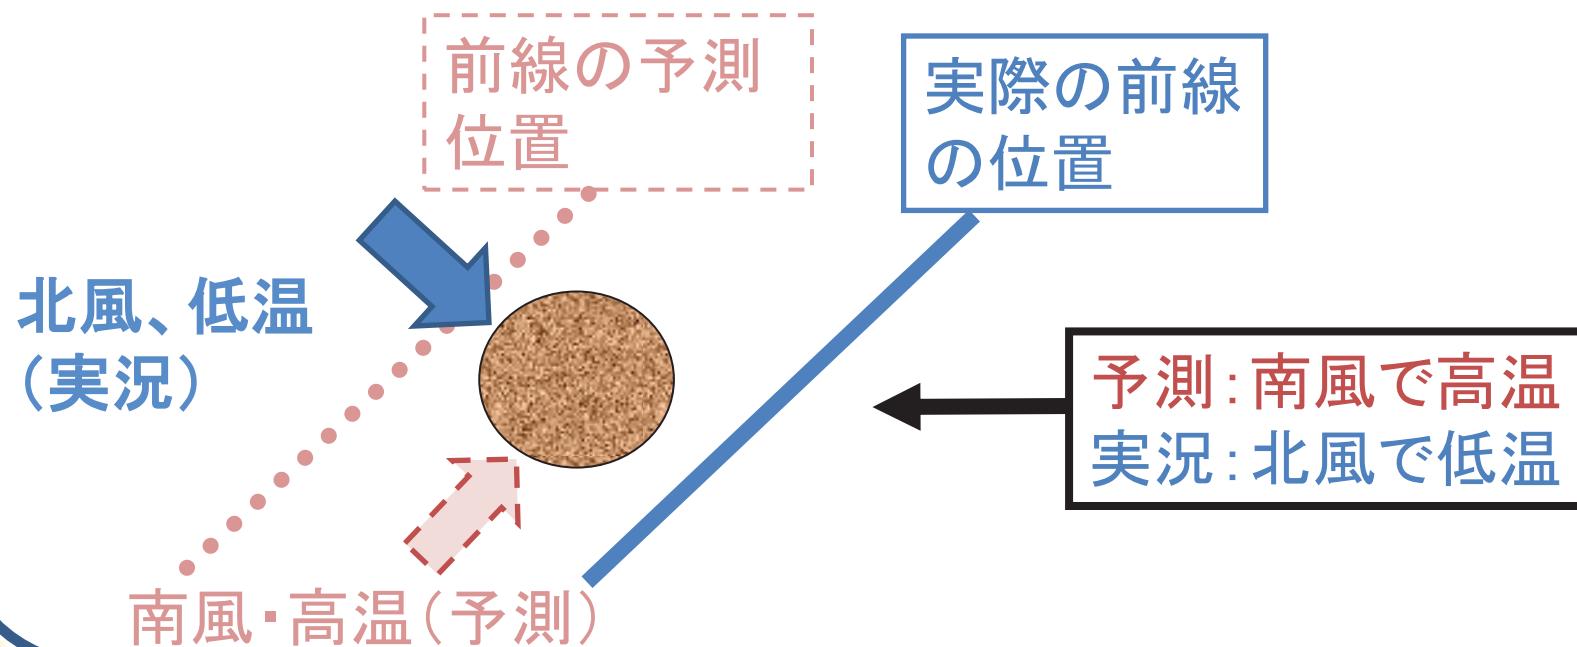


ガイダンス

非系統(ランダム)誤差の修正

非系統的(ランダム)誤差は**修正不可能**

寒冷前線の進行速度誤差など



ガイダンス作成に用いる予測手法

1. 線形重回帰
2. カルマンフィルタ
3. ニューラルネットワーク
4. ロジスティック回帰

- I. 頻度バイアス補正
- II. 層別化

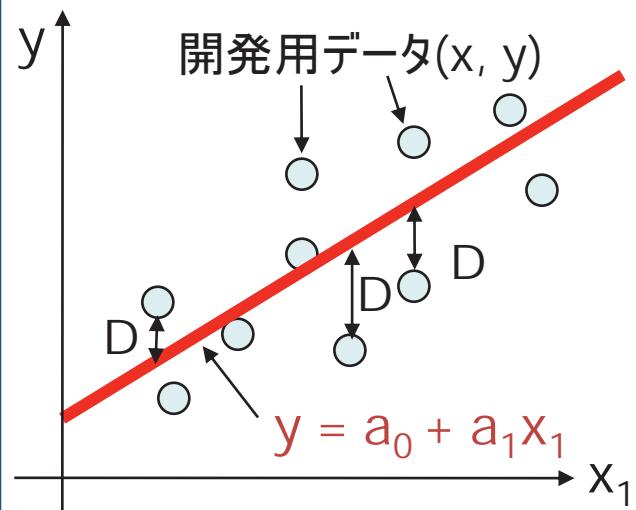
1. 線形重回帰

予測式: $y = a_0 + a_1x_1 + a_2x_2 + \dots$

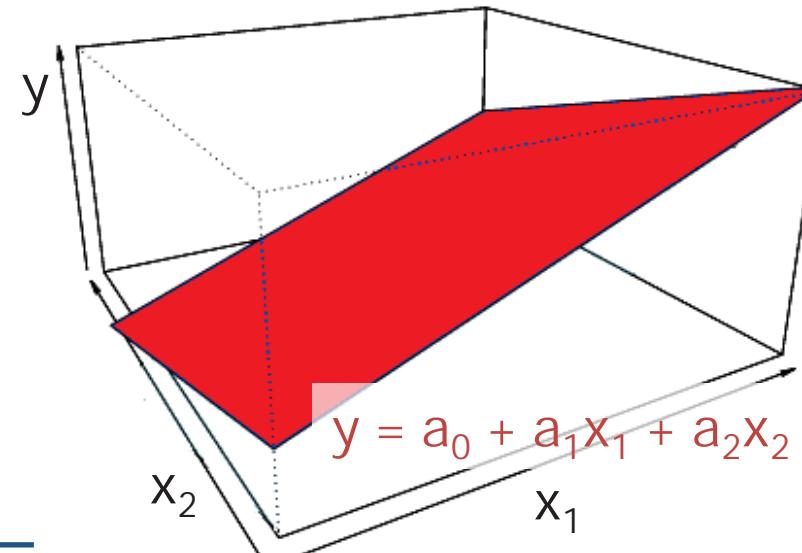
y : 目的変数 x_i : 説明変数 a_i : 係数

- 係数 a_i は開発用データで誤差分散 ΣD^2 を最小にするように決め、固定

説明変数1個の場合



説明変数2個の場合



1. 線形重回帰

特徴	<ul style="list-style-type: none">係数が固定→予測式が変化しないサンプルデータを適切に用意できれば、ほとんど自動的に精度の高い予測式を作成可能
メリット	<ul style="list-style-type: none">特性が把握しやすい説明変数の客観的選択が可能作成および維持管理が比較的容易
デメリット	<ul style="list-style-type: none">予測式が変化しないため、数値予報モデルの変更に伴い予測特性・精度の変化が起こる可能性作成に長期間のデータ必要(数年間のデータが必要なことも。モデル更新直後には予測式作成できない)年変動、季節変動への対応が困難
用途	気象庁では1996年までは主流。

2. カルマンフィルター

予測式: $y = a_0(t) + a_1(t)x_1 + a_2(t)x_2 + \dots$

線形重回帰と同じ形だが、時刻(t)が付く

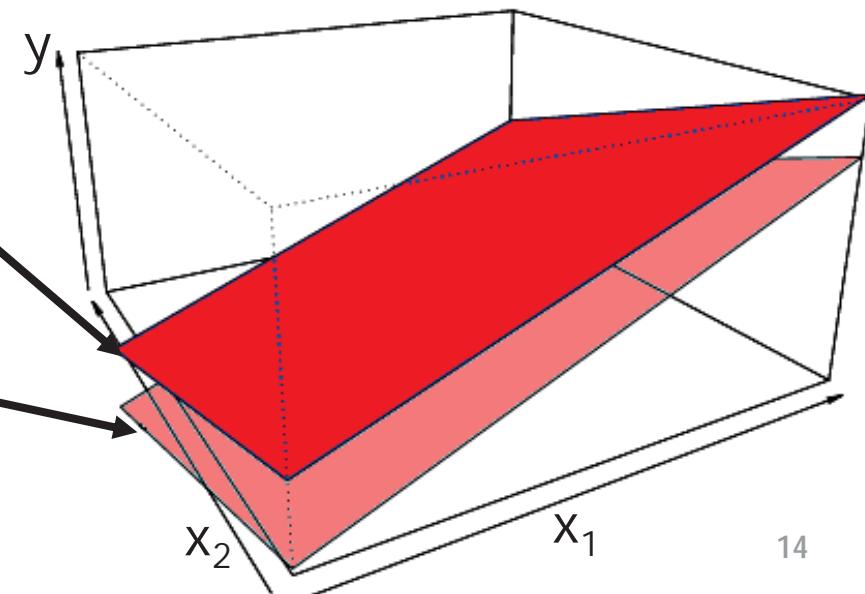
y : 目的変数 x_i : 説明変数 a_i : 係数

- 係数 a_i を各時刻で最適になるようにカルマンフィルタを使って逐次変化(学習)が可能
- 係数の変化は目的変数 y が観測値に近づくように行われる

$$y = a_0(t) + a_1(t)x_1 + a_2(t)x_2$$

$$y = a_0(t') + a_1(t')x_1 + a_2(t')x_2$$

説明変数が2個の場合

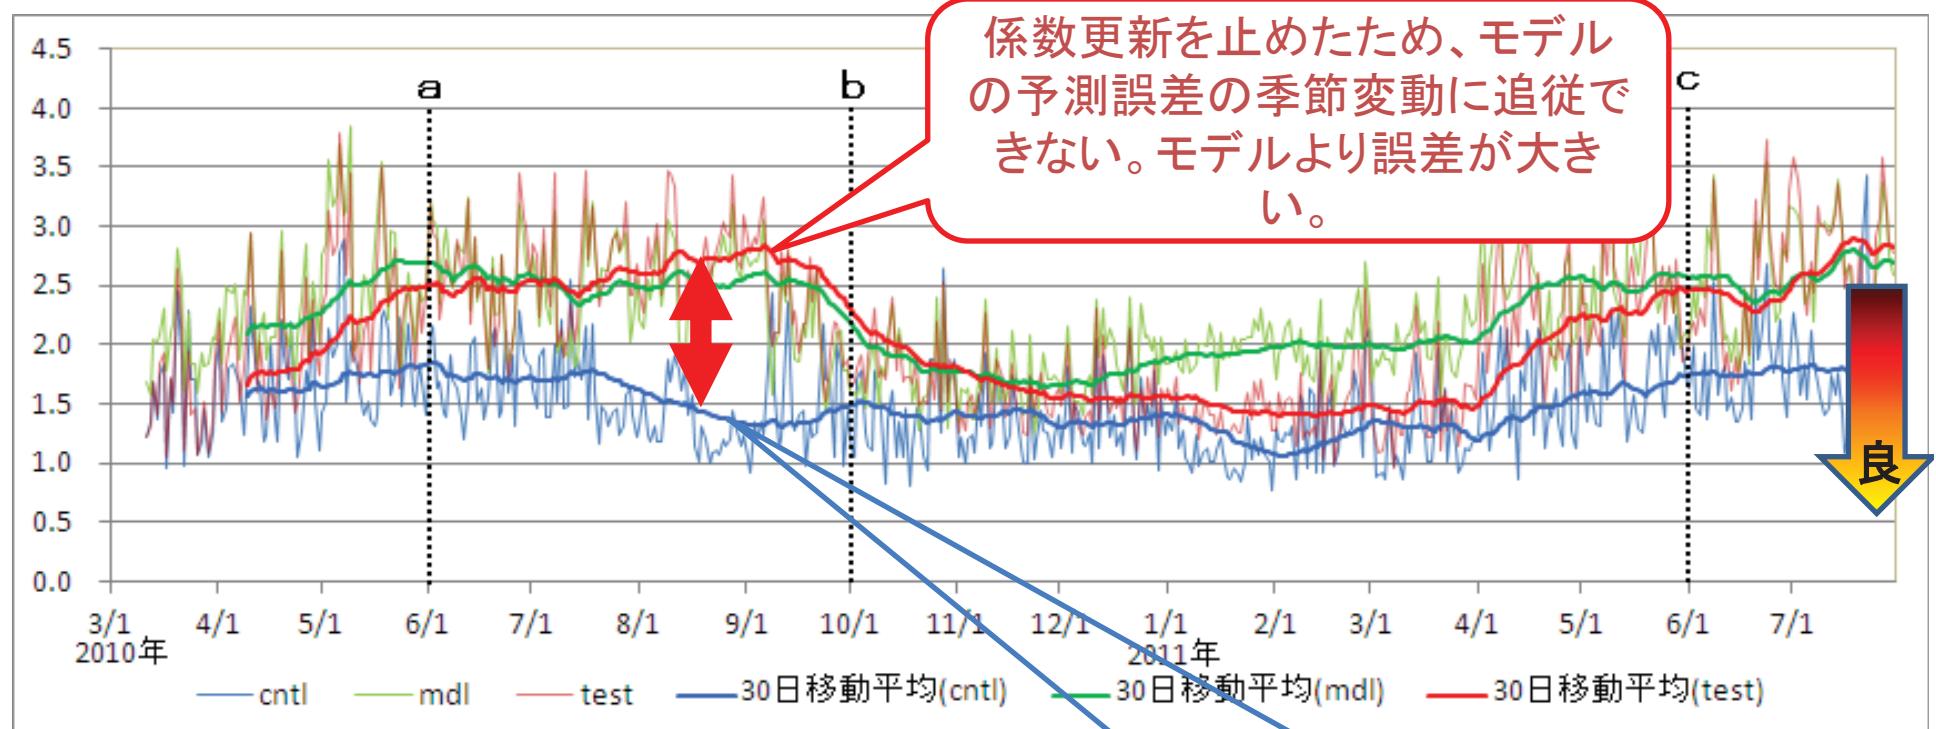


カルマンフィルターの学習の効果

最高気温のRMSE時系列グラフ 期間:2010年3月～2011年7月

緑:モデル 青:ガイダンス 赤:2010年3月で係数更新をストップ

細実線:日別値 太実線:30日移動平均 (日ごとのRMSE)



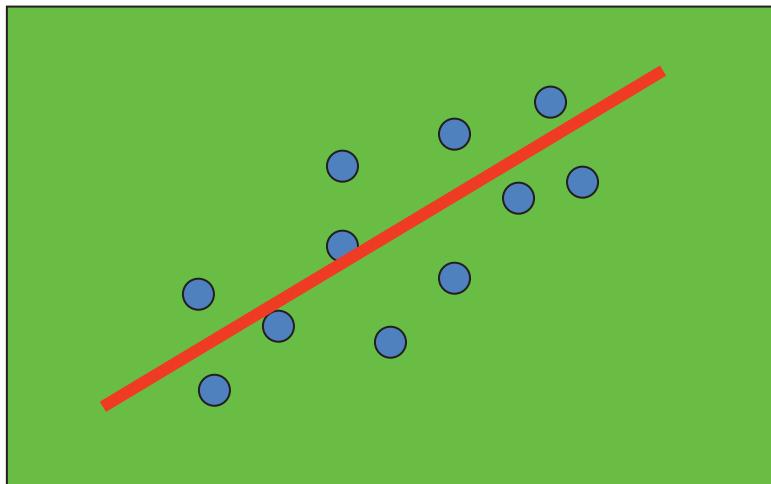
2. カルマンフィルター

特徴	<ul style="list-style-type: none">係数の逐次更新が可能
メリット	<ul style="list-style-type: none">数値予報モデルの変更に対応可能年変動、季節変動への対応が可能比較的少量のデータで作成可能(気温なら1週間程度の学習でもOK)
デメリット	<ul style="list-style-type: none">係数が毎回変わるため予測特性の把握が困難観測値の変動が激しい場合、不適切な係数の変化を起こす場合がある説明変数の選択が主観的
用途	降水量、降水確率、気温、風、視程など

3. ニューラルネットワーク

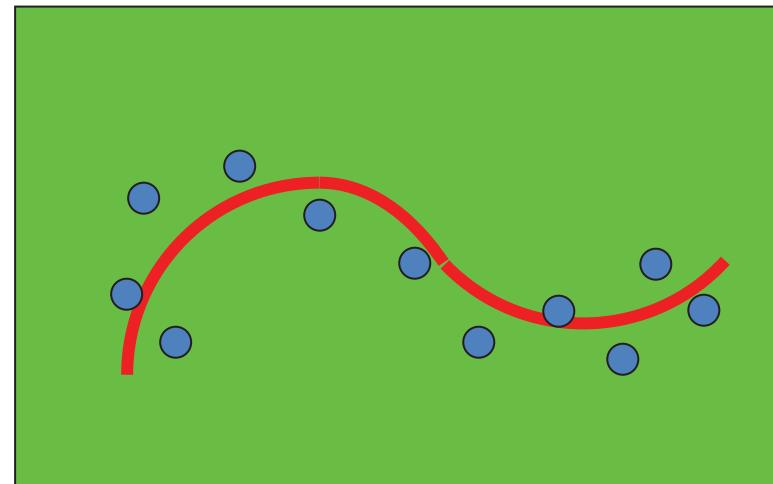
- 非線形の関係を予測
- 係数の逐次最適化

線形



入出力関係が直線で表現できる

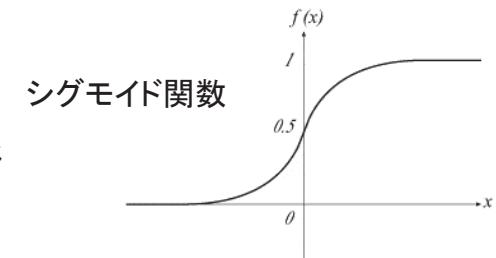
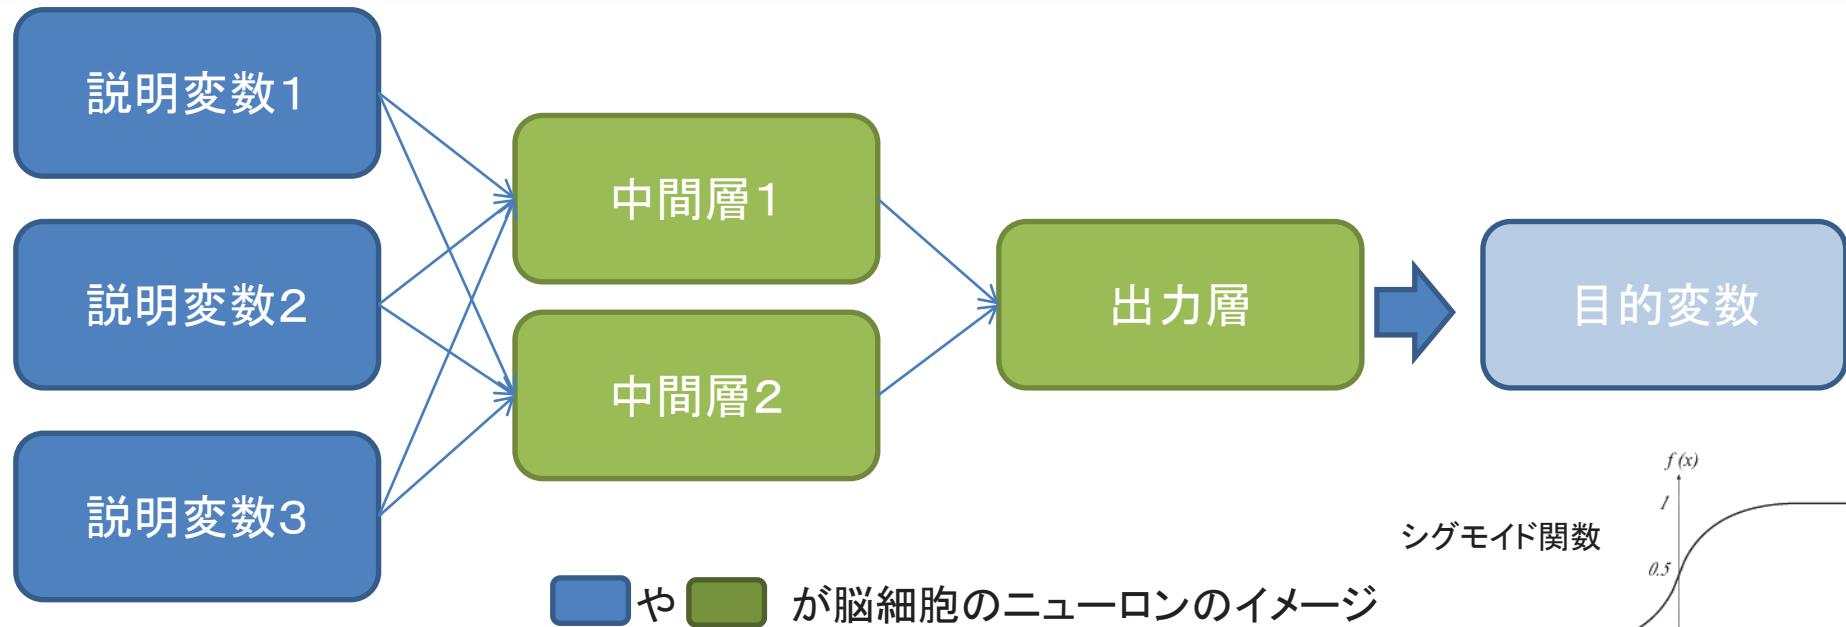
非線形



入出力関係が曲線でないと表現できない

3. ニューラルネットワーク

説明変数と目的変数の直接的な関係式はわからなくても使える。
ニューロンの連結によって変換する。



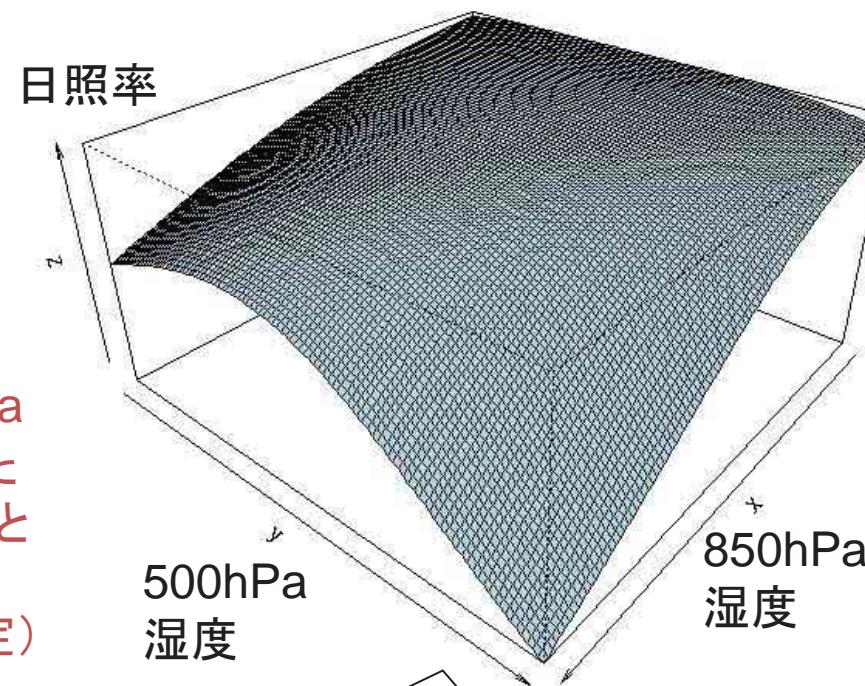
それぞれの層では、それぞれの入力に重みを掛けて合計する。
その結果を、シグモイド関数に代入したものを、その層の出力としている。
目的変数の結果と観測の差が小さくなるように、重みを更新していく(学習)
重みは、矢印毎に存在する。シグモイド関数とは、 $F(x)=1/(1+\exp(-x))$ である。
層や層毎のユニットの数は自由度がある。

3. ニューラルネットワーク

日照率ガイダンスの入出力関係(例)

東京 暖候期 2008年6月23日12UTC

500hPa湿度と850hPa
湿度の値を変動させた
時の予測値(日照率)
との関係
(他の説明変数は固定)



非線形の関係がある
程度表現している。

3. ニューラルネットワーク

特徴	<ul style="list-style-type: none">あらゆる非線形関係を予測
メリット	<ul style="list-style-type: none">あらゆる非線形関係を予測できる年変動、季節変動への対応が可能
デメリット	<ul style="list-style-type: none">予測結果の根拠把握が困難係数が毎回変わるために予測特性の把握が困難中間層の設定などシステムに任意性複雑さに見合った精度が得難い
用途	天気(日照率)、最小湿度など

4. ロジスティック回帰

0/1の2値データ* (発雷の有無など)の確率予測

以下の式で重回帰を行う手法

*2値でなくても可

$$\ln\left(\frac{p}{1-p}\right) = a_0 + a_1x_1 + a_2x_2 + \dots + a_nx_n$$

p: 目的変数 a : 係数 x : 説明変数

対数オッズ比

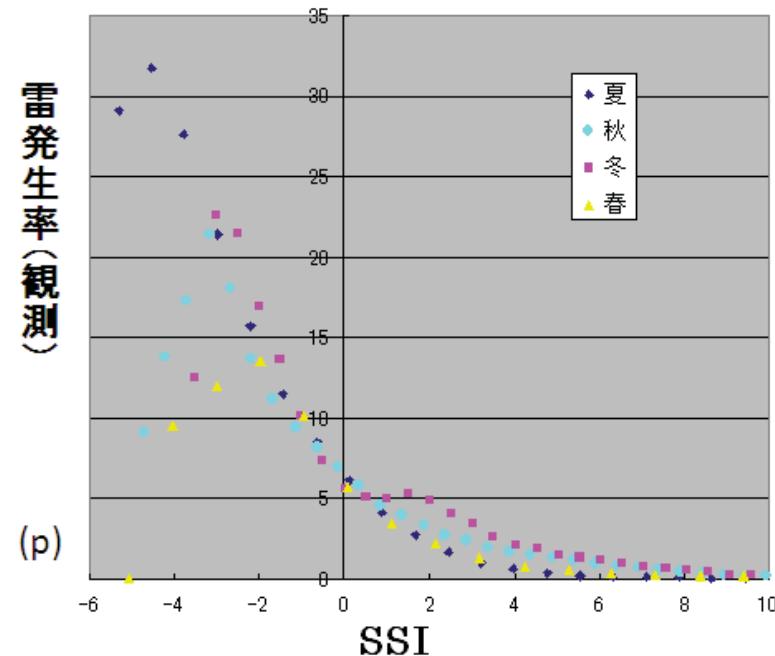
右辺は線形重回帰と同じ形

$$p = \frac{1}{1 + \exp\{-(a_0 + a_1x_1 + a_2x_2 + \dots + a_nx_n)\}}$$

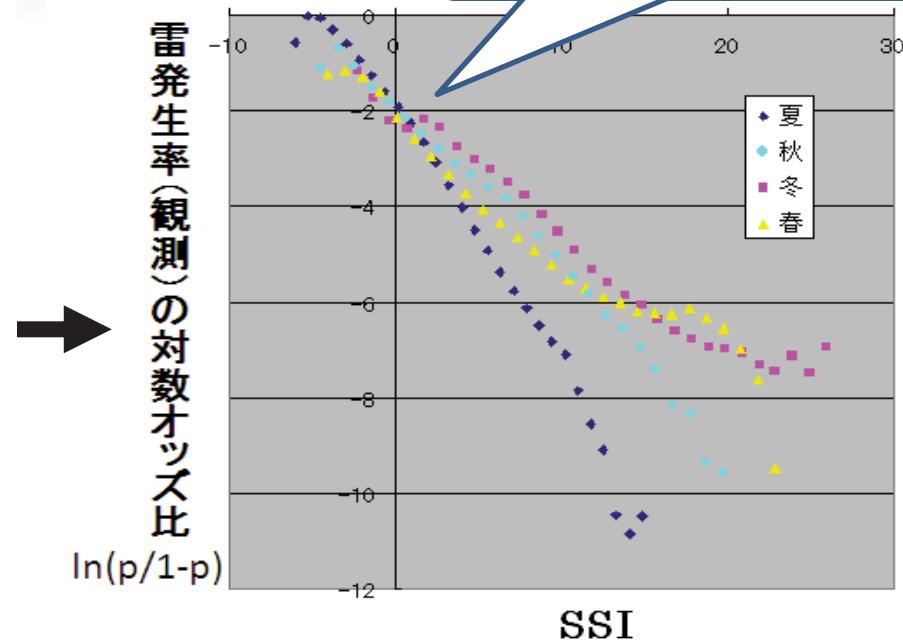
4. ロジスティック回帰

説明変数(SSI)と雷発生率との関係

大体直線で近似できる
(線形な関係)



$$p \Leftrightarrow SSI$$



$$\ln(p/(1-p)) \Leftrightarrow SSI$$

p : 雷発生率(あるSSIの時に発雷のあった回数の比率)

対数オッズ比を用いると線形関係になる

4. ロジスティック回帰

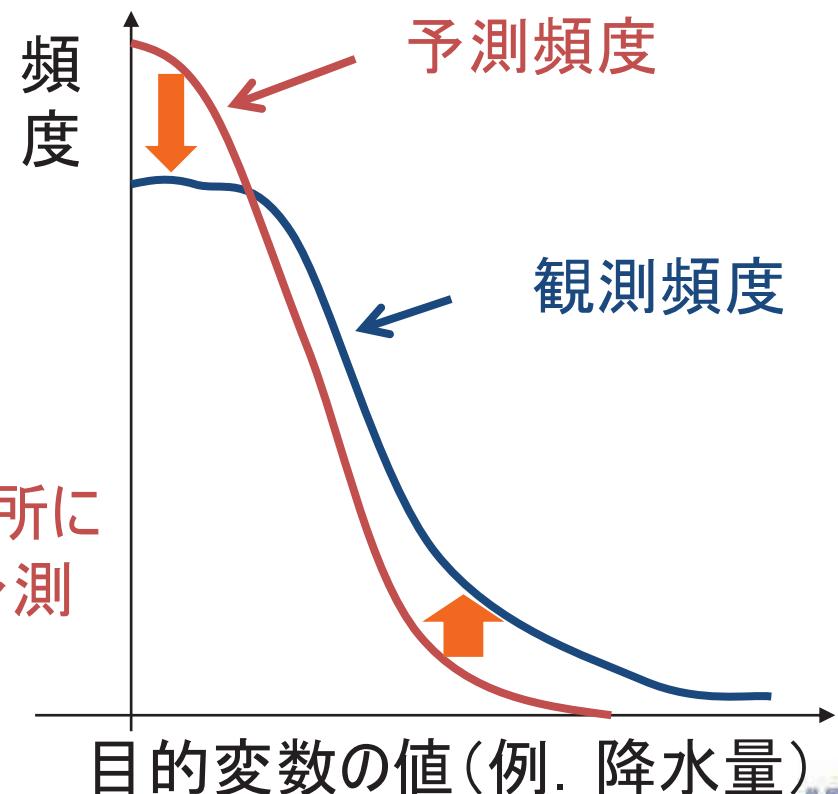
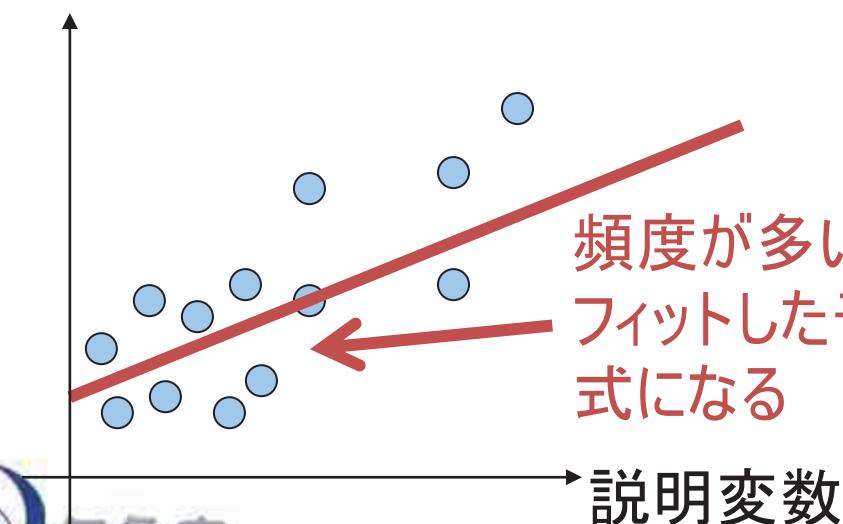
特徴	<ul style="list-style-type: none">・ 2値データ(0か1か)の確率予測について、対数オッズ比を用いた式で表現する手法
メリット	<ul style="list-style-type: none">・ 確率値を直接予測できる・ ある種の非線形関係を予測できる・ 説明変数の客観的選択が可能
デメリット	<ul style="list-style-type: none">・ 係数固定のため、モデル変更に対応できない・ 作成に長期間のデータ必要
用途	発雷確率など

I. 頻度バイアス補正

サンプル数が多い所にフィットした予測式となり、頻度が少ない大雨などの予測が出にくくなる。

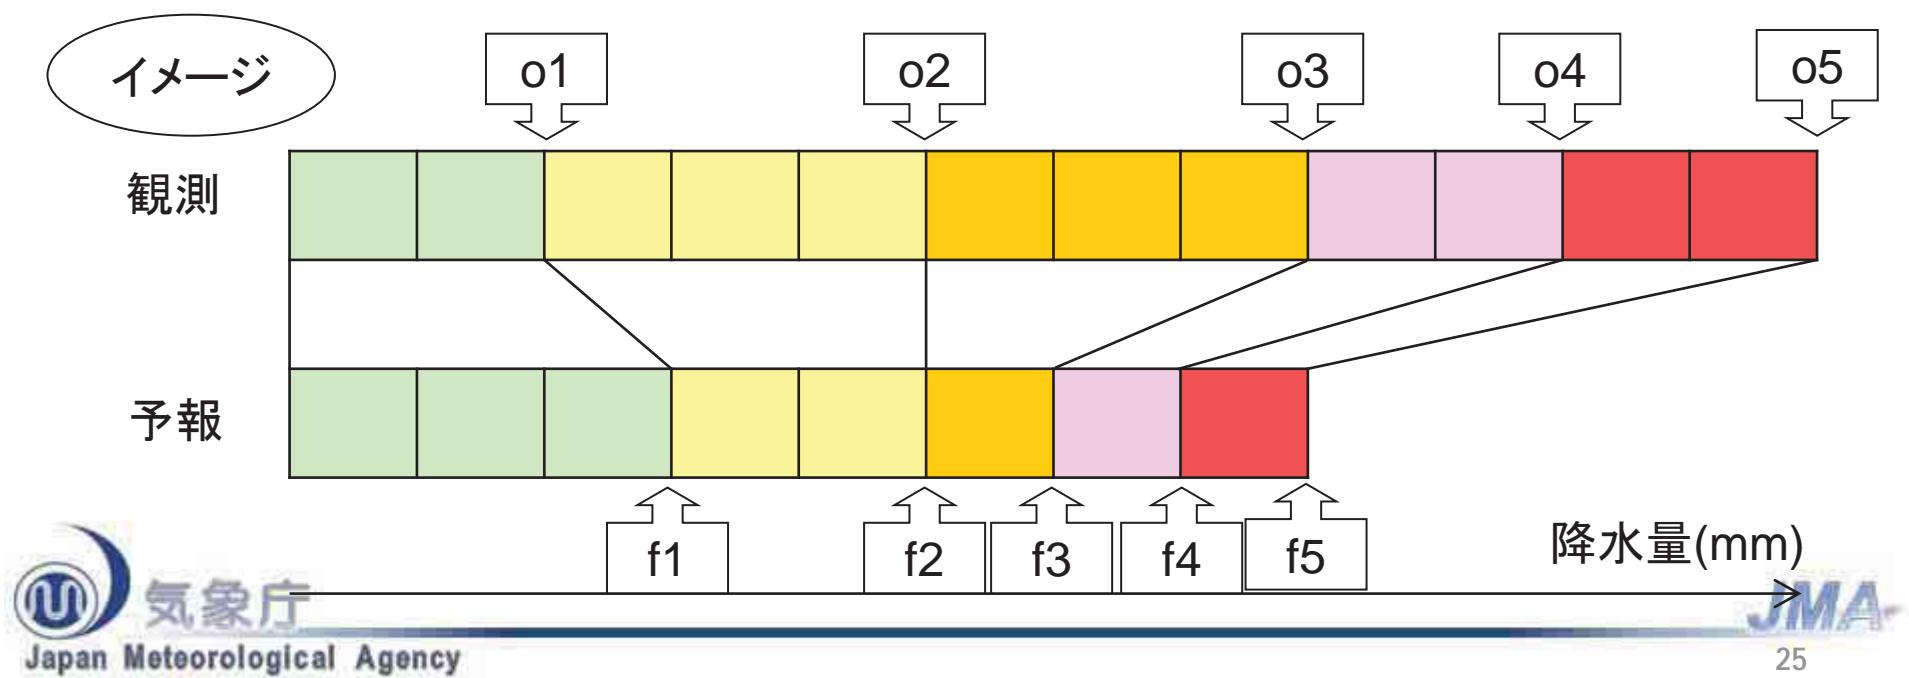
予測頻度を観測頻度に合わせる(頻度バイアス補正する)ことによって、大雨の予測数を増やし、捕捉率を上げる

頻度が少ない所(大雨等)
にはフィットしにくい
目的変数



I. 頻度バイアス補正

- 偏りを修正するため、観測の頻度分布と予報の頻度分布が同じになるように補正する。
- 観測と予報に閾値を設けていくつかのカテゴリーを作り、対応するカテゴリーの頻度が等しくなるようにする。
- 観測の閾値は固定し、予報の閾値は学習によって変化させる。

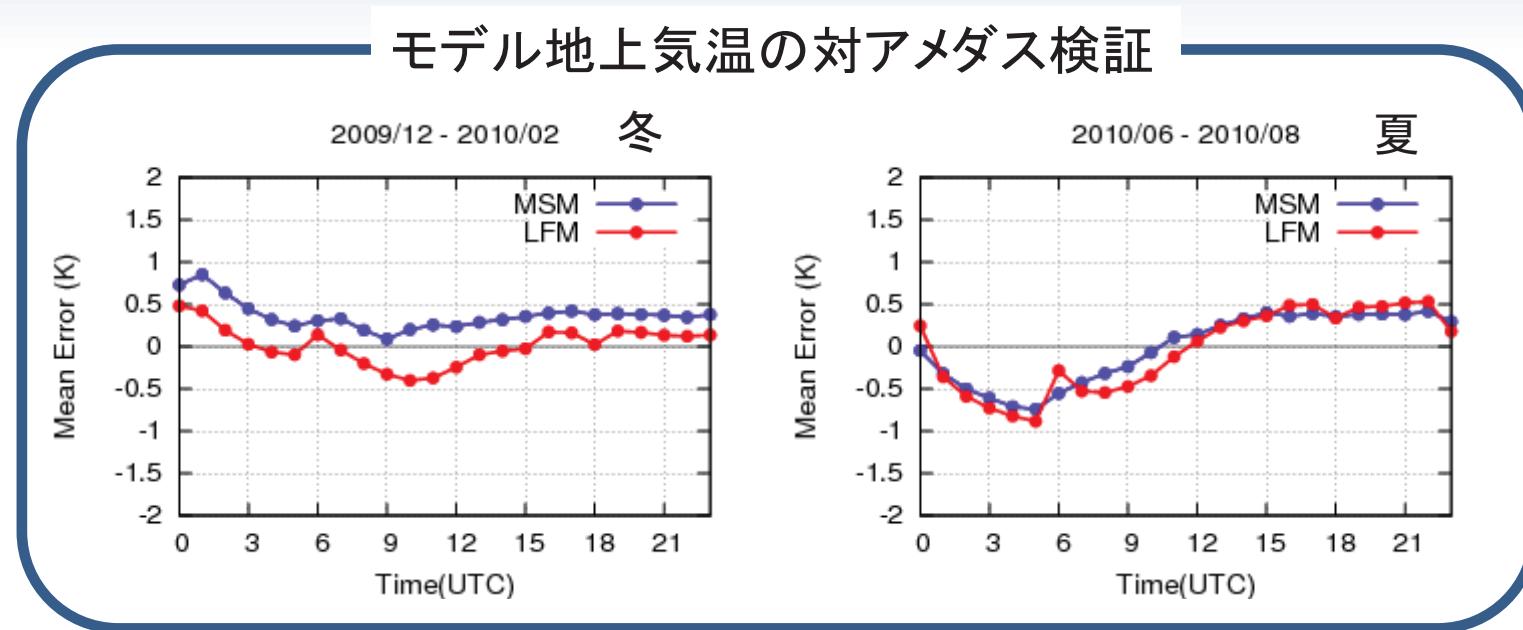


I. 頻度バイアス補正

特徴	観測と予測に閾値を設けていくつかのカテゴリーを作り、観測の頻度分布と予測の頻度分布が同じになるように偏りを補正
メリット	<ul style="list-style-type: none">顕著事例の捕捉率が上昇する
デメリット	<ul style="list-style-type: none">空振りが増加する全体の誤差が大きくなる可能性がある
用途	降水量、風など

II. 層別化

数値予報の系統誤差は、場所、対象時刻、予報時間、季節で変化



予測式を複数使い分けて予測精度の向上を図る

||

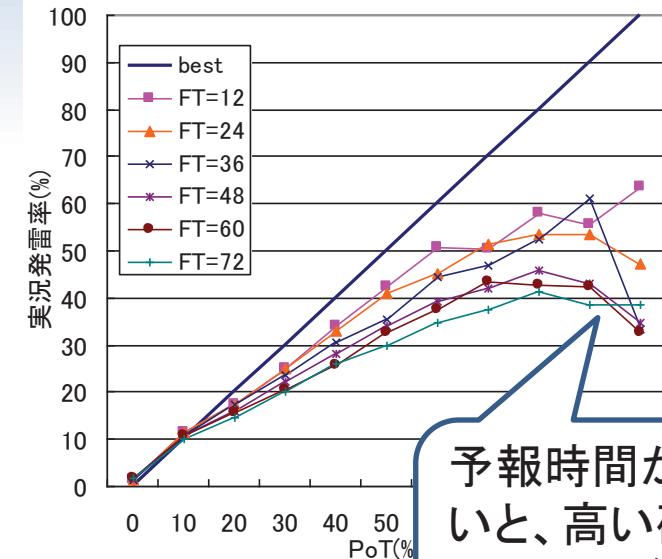
層別化

例) 気温ガイダンス: 予報対象時刻(1時間ごと)で係数が異なる

II. 層別化

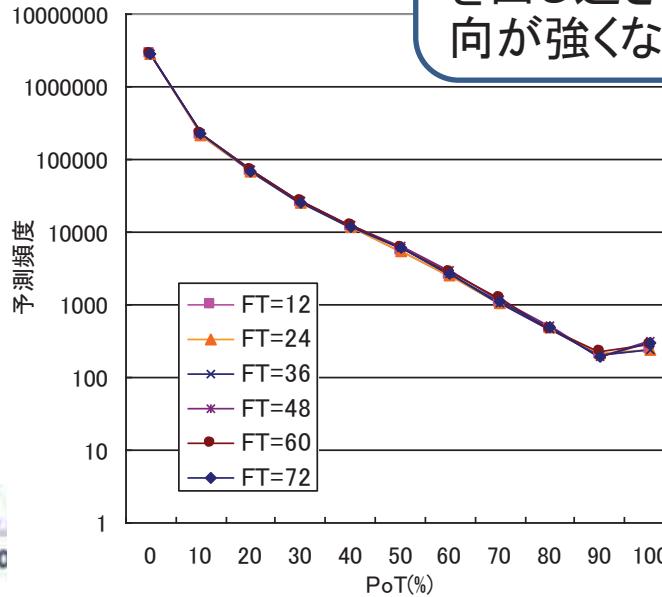
発雷確率(予報時間による層別化なし) 発雷確率(予報時間による層別化あり)

信頼度曲線



予報時間が長いと、高い確率を出し過ぎる傾向が強くなる

頻度



予報時間によらず、信頼度曲線が45度付近になっている
(予測頻度が適切)

予報時間が長くなるに従い(予測精度を反映して)高い確率が出にくくなっている

II. 層別化

特徴	<ul style="list-style-type: none">場合に応じた予測式を用意すること
メリット	<ul style="list-style-type: none">有効な層別化は精度を大きく上げる層の数を多くすると種々の変化に対応可能
デメリット	<ul style="list-style-type: none">層別化が多すぎるとサンプル数が減り精度の高い統計式が得られない
用途	気温、降水量、風など多数

MSMガイダンス

MSMガイダンスの概要

● 基本的な作成方法はGSMガイダンスと共通

- 数値予報モデルの出力をカルマンフィルター、ニューラルネットワーク、ロジスティック回帰などの統計手法を利用して利用しやすい形に加工して提供。
- 予測精度は一般にベースとなるモデルの予測を上回る。

● 季節的な予報精度の違い

- 夏期) MSMガイダンスの予測精度がGSMガイダンスを上回る場合が多い。
- 冬期) GSMガイダンスとMSMガイダンスの予測精度の差は大きくなく発雷確率など一部の要素ではGSMガイダンスがMSMガイダンスを上回る場合もある。

提供(予定)ガイダンス一覧

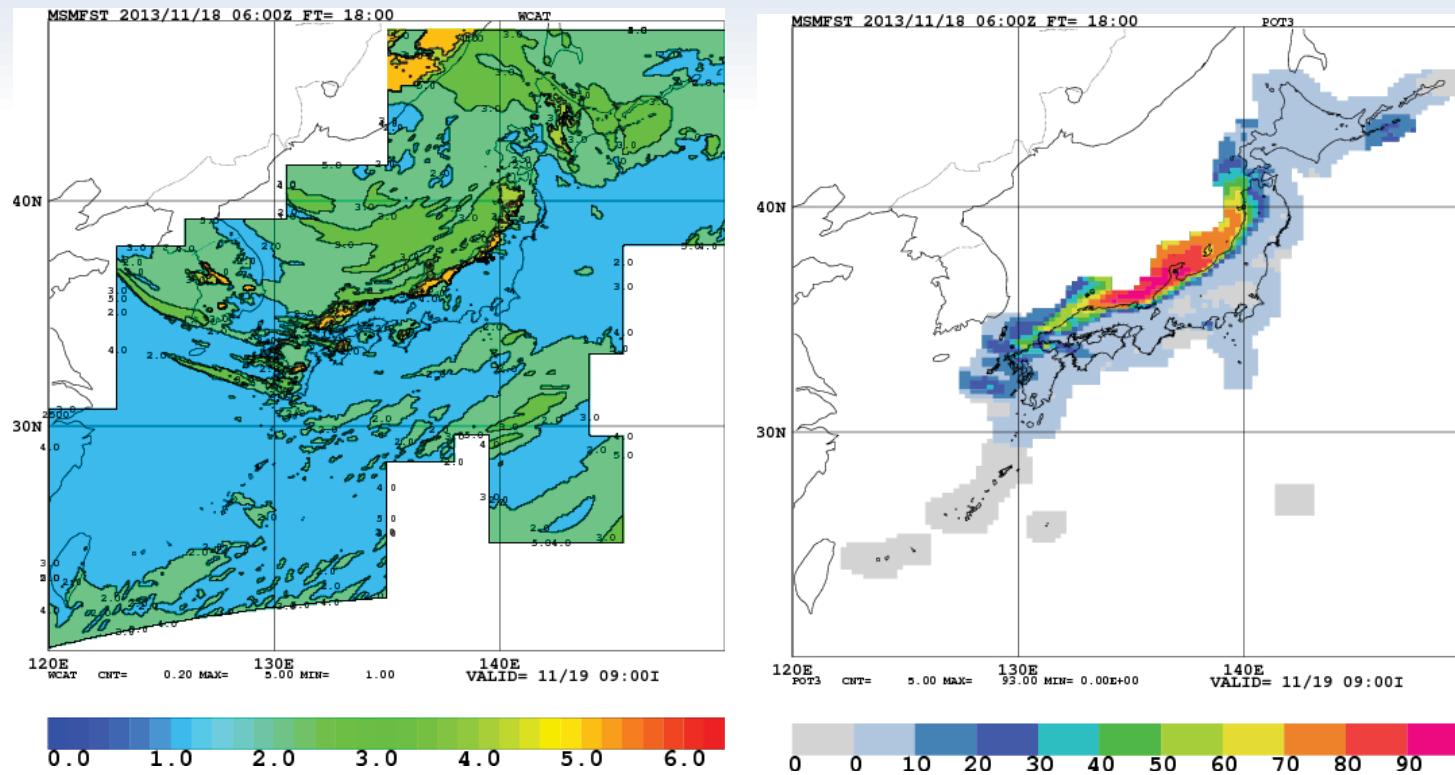
○ MSM/GSMガイダンス

		MSM				GSM			
		間隔	時間	格子	地点	間隔	時間	格子	地点
雨	3時間平均降水量	3h	39	5km	--	3h	84	20km	--
	降水確率	6h	39※1	5km	--	6h	84	20km	--
風	定時の風速・風向	1h	39	--	○	3h	84	--	○
気	気温	1h	39	--	○	1h	84	--	○
温	最高・最低気温	--	39	--	○	--	84	--	○
発雷確率		3h	39	20km	--	3h	84	20km	--
日最小湿度		--	39	--	○※2	--	84	--	○※2
天気		3h	39	5km	○	3h	84	20km	○

*1 00シリーズはFT=9~39、03シリーズはFT=6~36

*2 気象官署および特別地域気象観測所

MSMガイダンスの提供領域(イメージ)



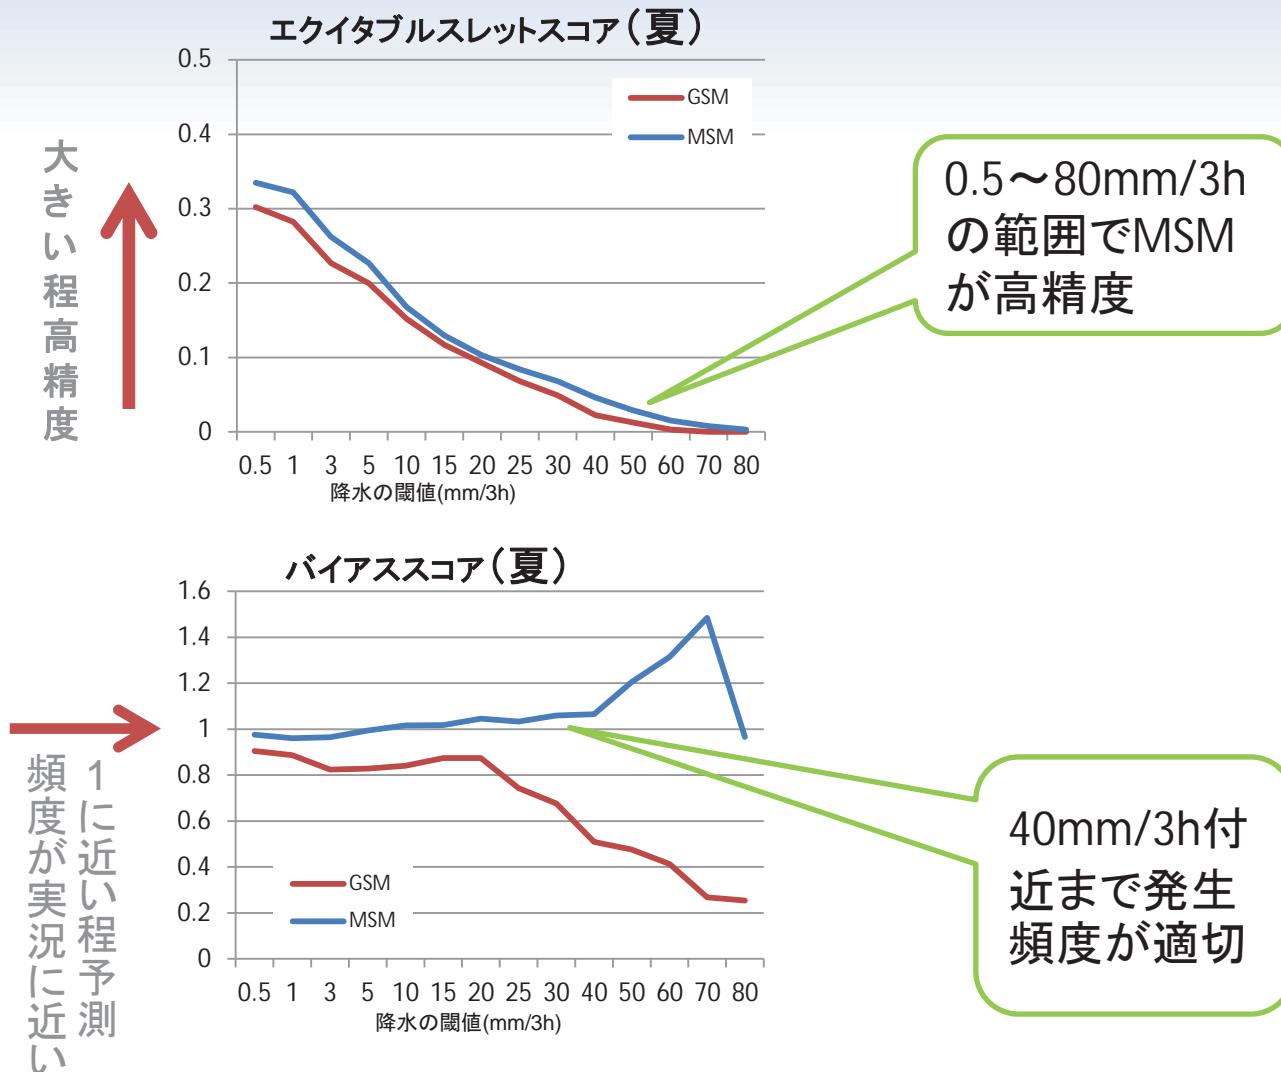
格子系ガイダンスのデータ提供領域とおおよその実データの領域(可変)
左)天気、降水量、降水確率
右)発雷確率

MSMガイダンスの予測精度

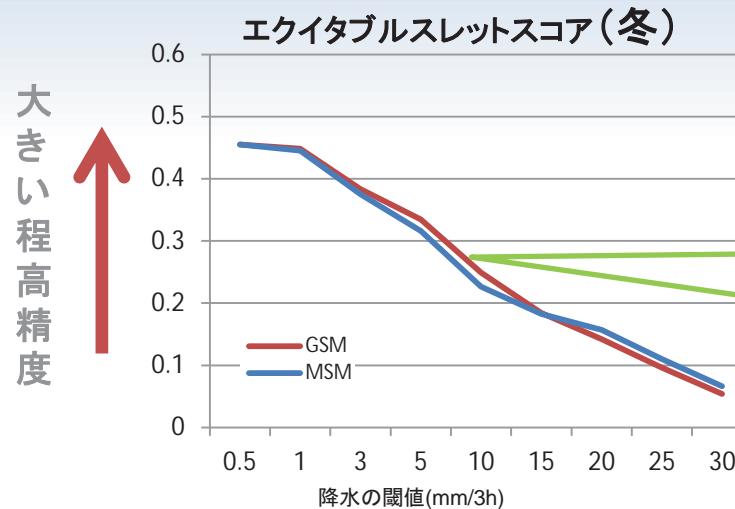
- MSMガイダンスの予測精度について、GSMガイダンスと比較して説明
 - 検証期間は2013年6～8月(夏)および2012年12月～2013年2月(冬)
 - 初期時刻は00UTC(GSMガイダンス)および03UTC(MSMガイダンス)、予報時間は33時間まで(MSMガイダンス)を対象

※検証に利用できるガイダンスとしては00UTC初期値のMSMガイダンスは予報時間が15時間と短い(現在は39時間)こと、また午後の予報に利用できる最新のガイダンスはGSMは00UTC初期値、MSMは03UTC初期値であることなどを考慮。

MSM降水ガイダンスの予測精度(夏)

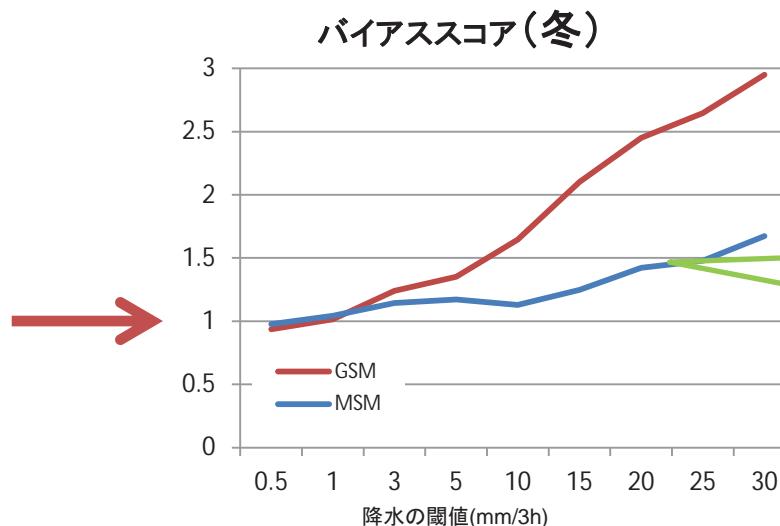


MSM降水ガイダンスの予測精度(冬)



精度に明確な
差はない

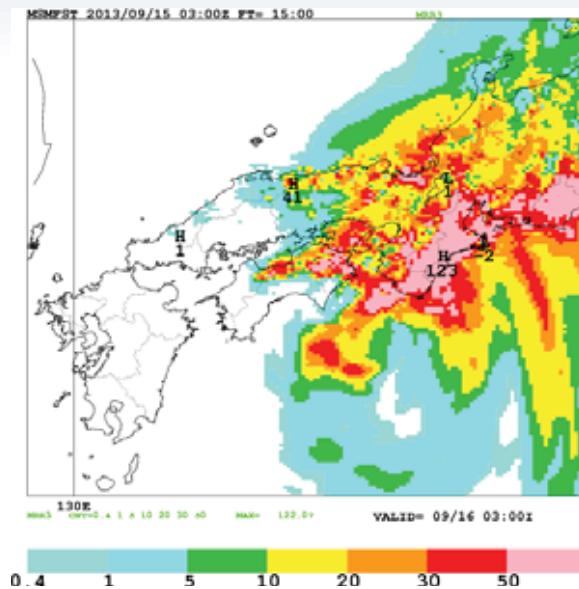
頻度が実況に近い
1に近い程予測



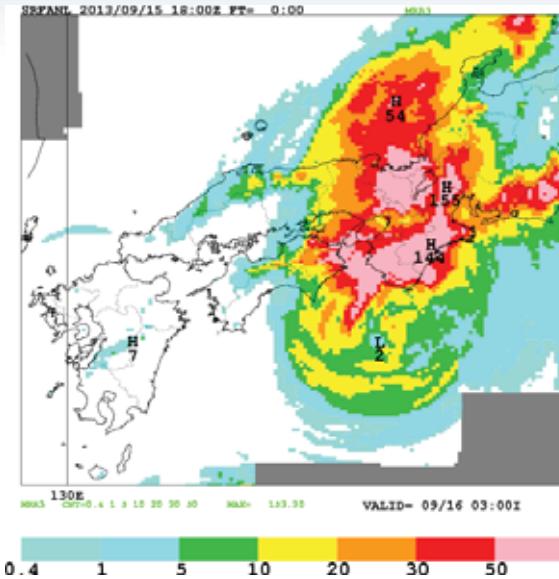
予測頻度は
MSMが適切
(より1に近い)

予測例

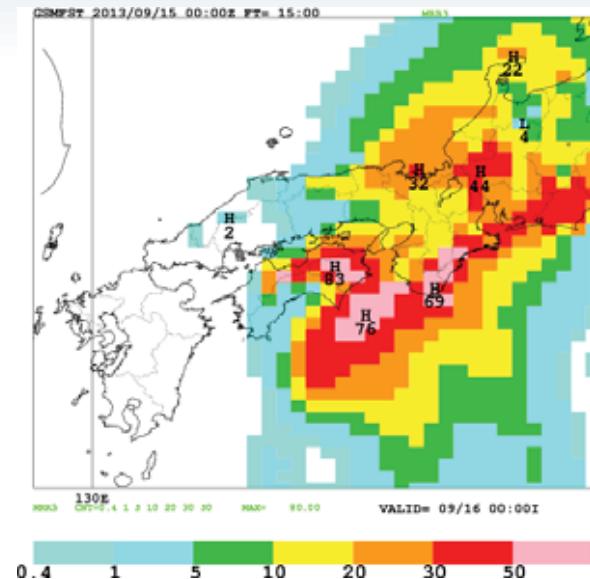
MSMガイダンス



解析雨量



GSMガイダンス



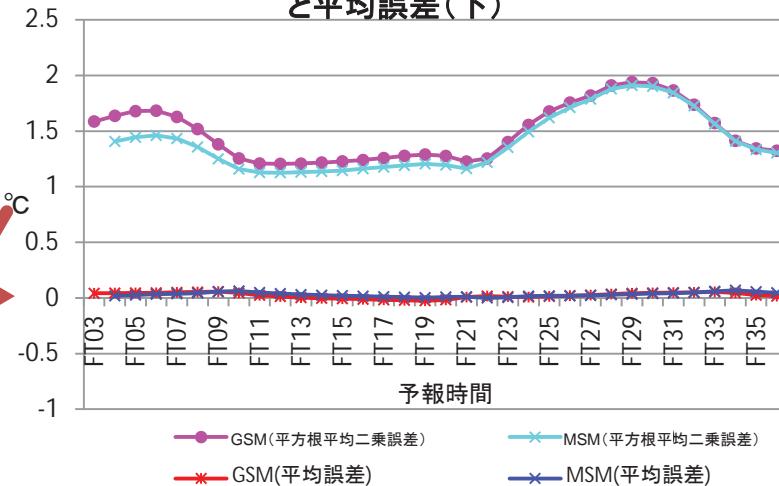
※2013年台風第18号:2013年9月16日03時までの3時間降水量

この事例では、両ガイダンスとも台風による降水を概ね良く予測できている。
MSMガイダンスは格子間隔が5kmとGSMガイダンス(20km)より細かい事などにより、**地形の影響を受ける降水など**はGSMガイダンスより**良く予測できている**。

MSM気温ガイダンスの予測精度(夏)

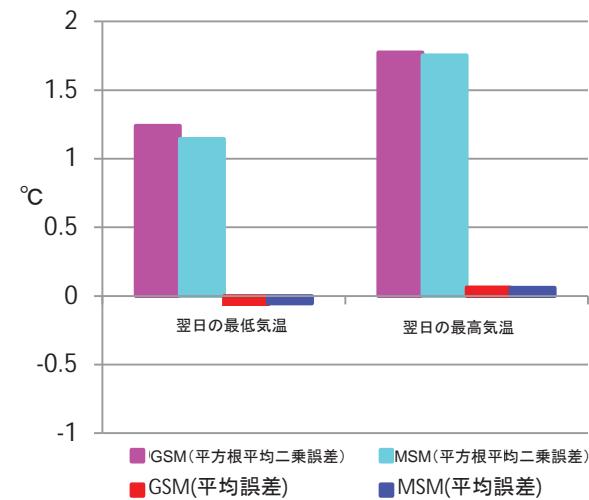
小さい程誤差が少ない
0に近い程予測に偏りが少ない

時系列気温ガイダンスの
平方根平均二乗誤差(上)
と平均誤差(下)



※平方根平均二乗誤差: 小さい程誤差が少ない
※平均誤差: 0に近い程、系統誤差が少ない

最高・最低気温ガイダンスの
平方根平均二乗誤差と平均誤差

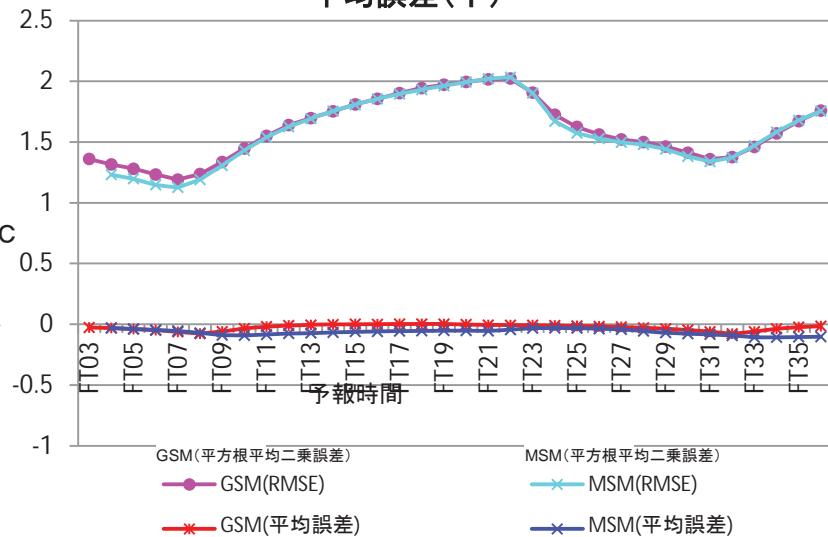


平均誤差はMSM,GSMともにおおよそ0
平方根平均二乗誤差はMSMが小さい(高精度)

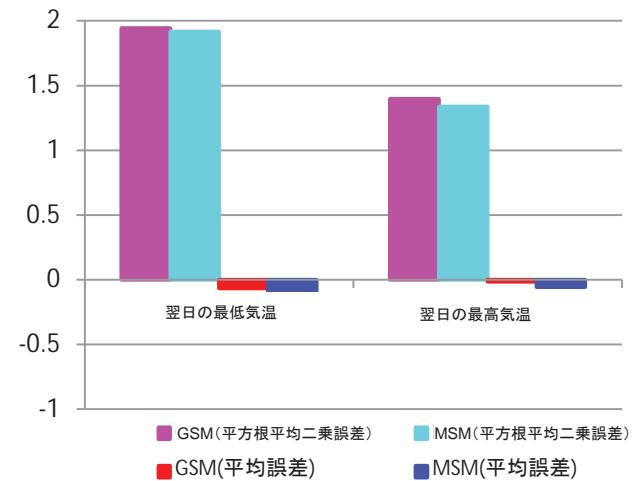
MSM気温ガイダンスの予測精度(冬)

小さい程誤差が少ない
に偏りが少ない
0に近い程予測

時系列気温ガイダンスの
平方根平均二乗誤差(上)と
平均誤差(下)



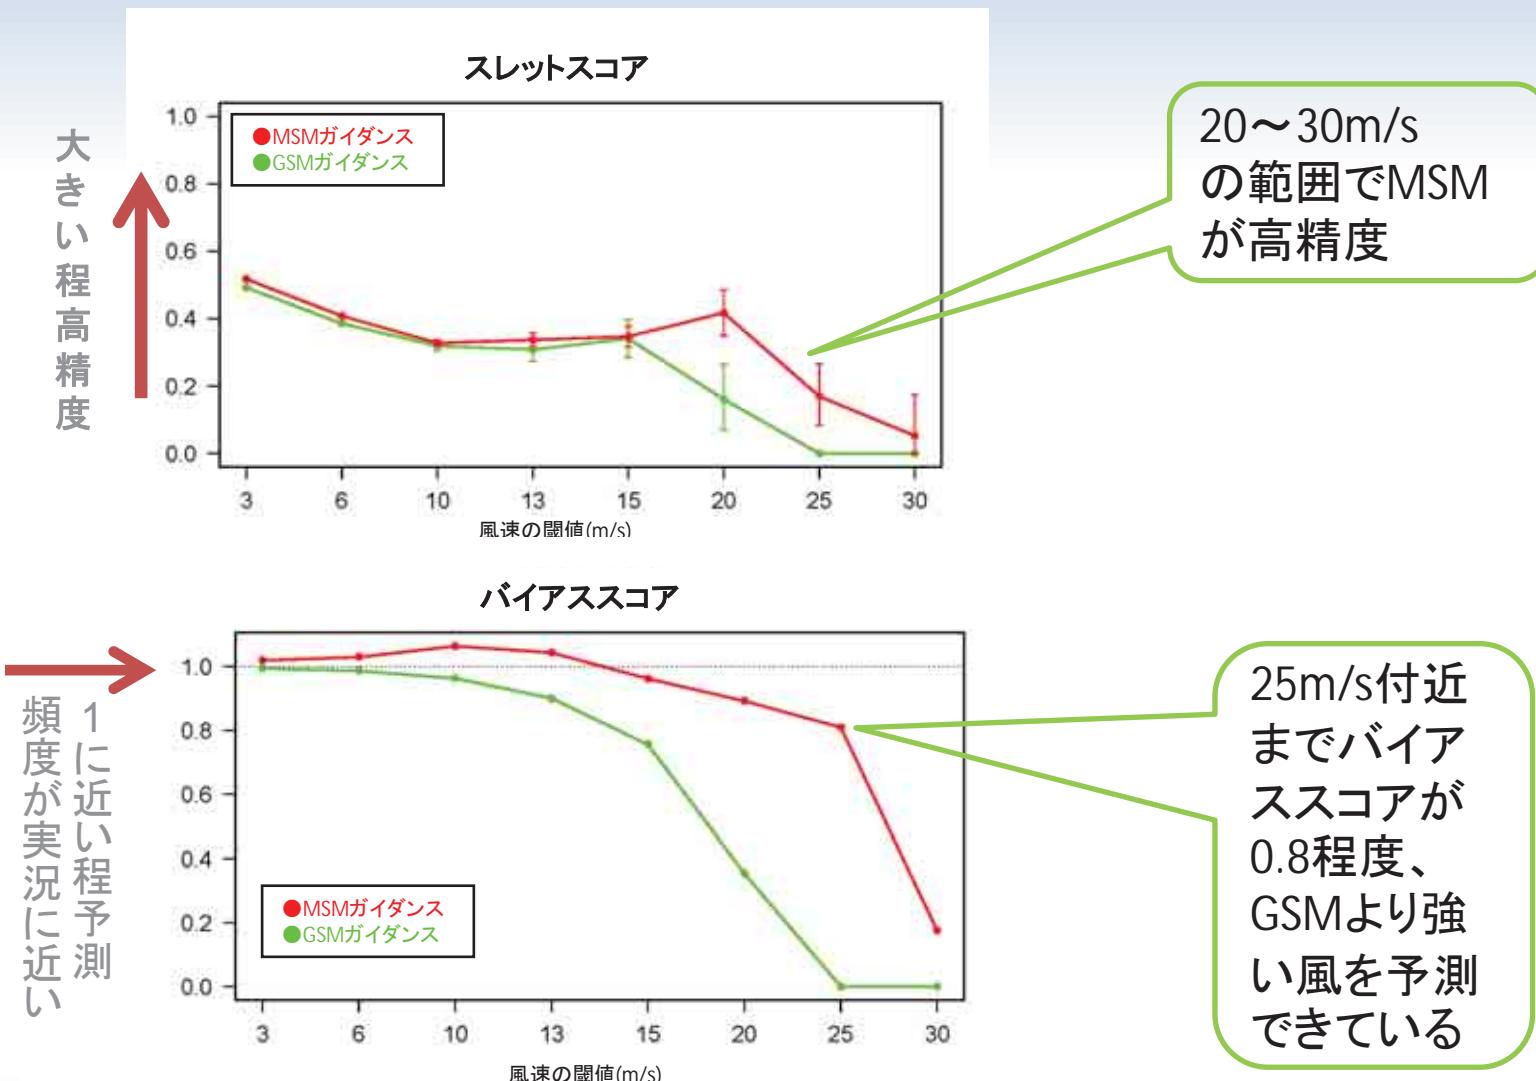
最高・最低気温ガイダンスの
平方根平均二乗誤差と平均誤差



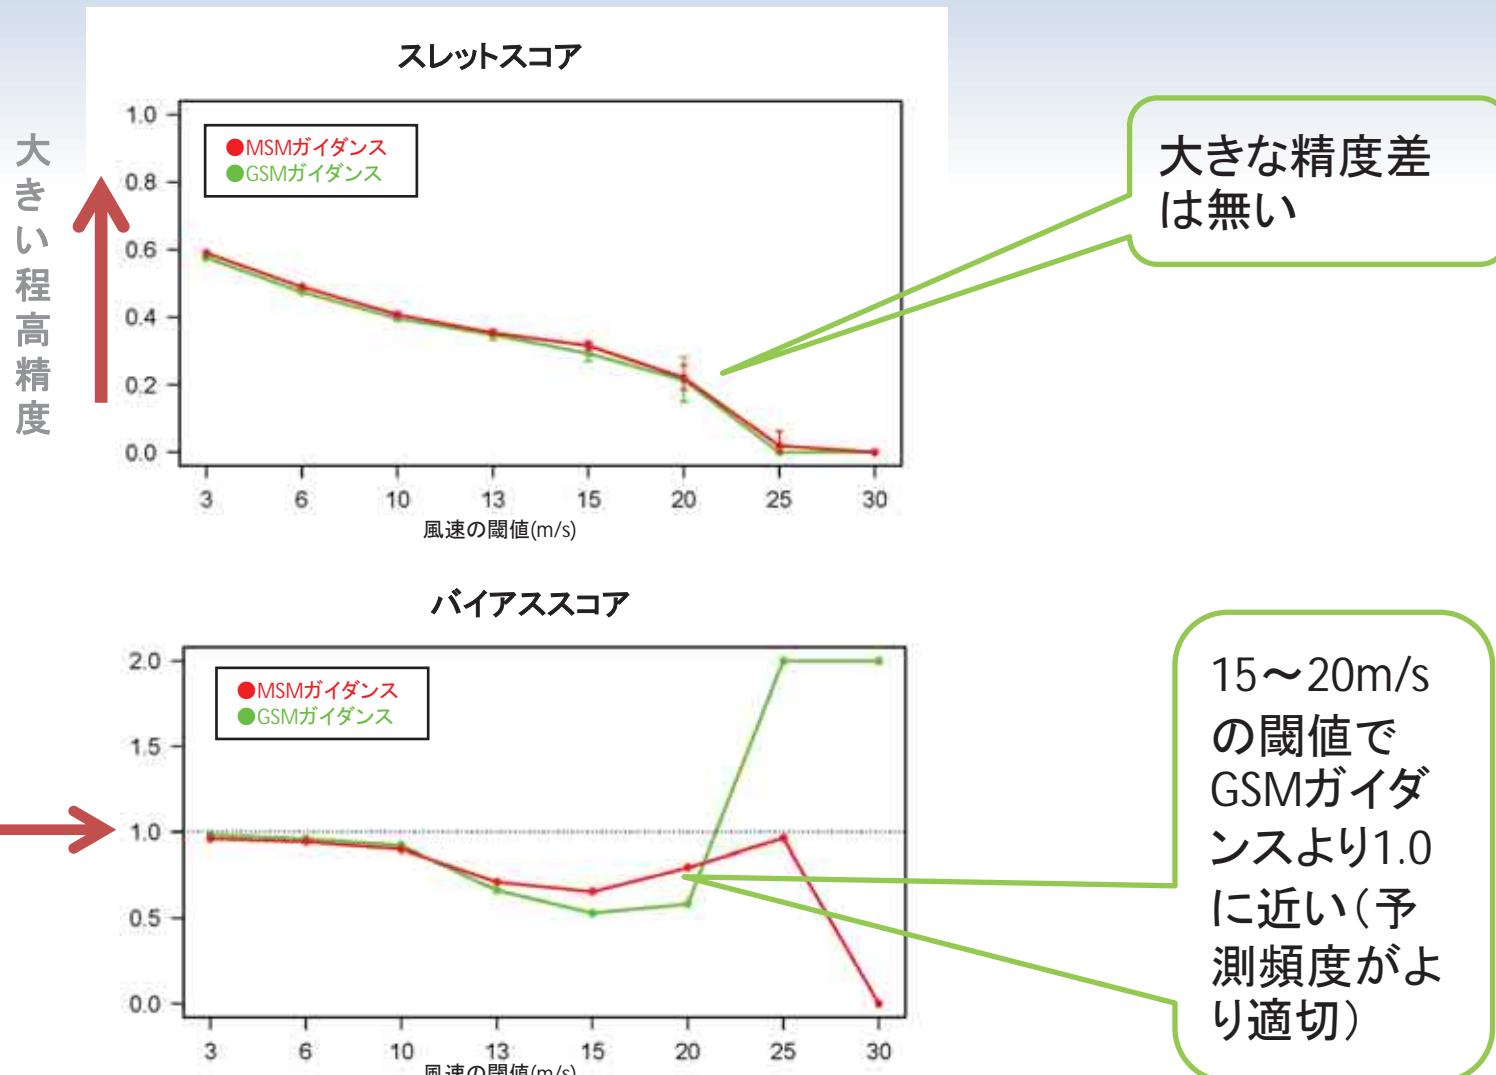
※平方根平均二乗誤差: 小さい程誤差が少ない
※平均誤差: 0に近い程、系統誤差が少ない

平均誤差はMSM,GSMともにおおよそ0
平方根平均二乗誤差についてもMSM、GSMで大きな差はない

MSM風ガイダンスの予測精度(夏)



MSM風ガイダンスの予測精度(冬)

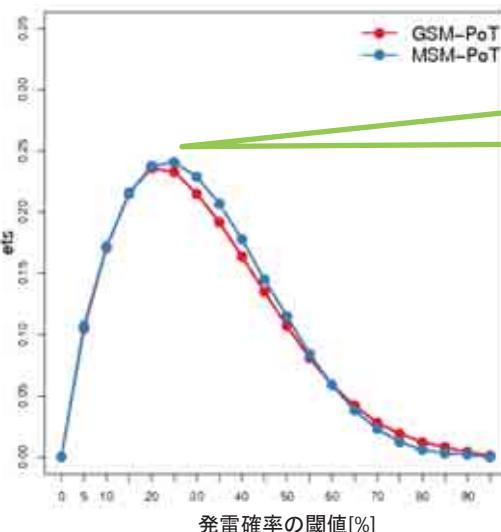


MSM発雷確率ガイダンスの予測精度(夏)

大きい程高精度



閾値別エクイタブルスレットスコア(ETS)

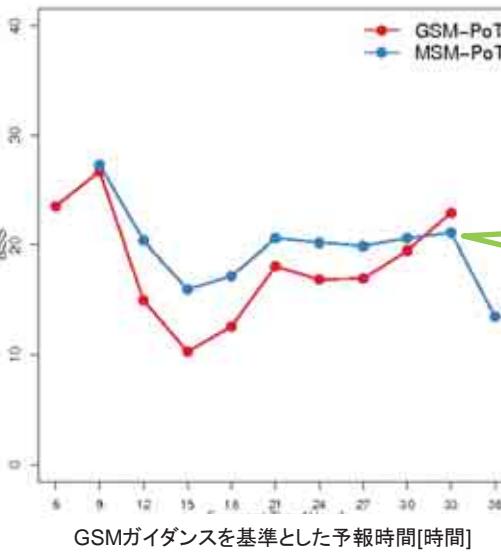


閾値別スコア
のピークが
MSMが高い
(高精度)

大きいほど確率予報の精度が良い



予報時間別プライアスキルスコア(BSS)



ほとんどの予報時間において、MSMのスコアが高い
(確率予報の精度が良い)



気象庁

Japan Meteorological Agency

JMA

※検証対象予報時間:6-33時間(MSM,GSM)

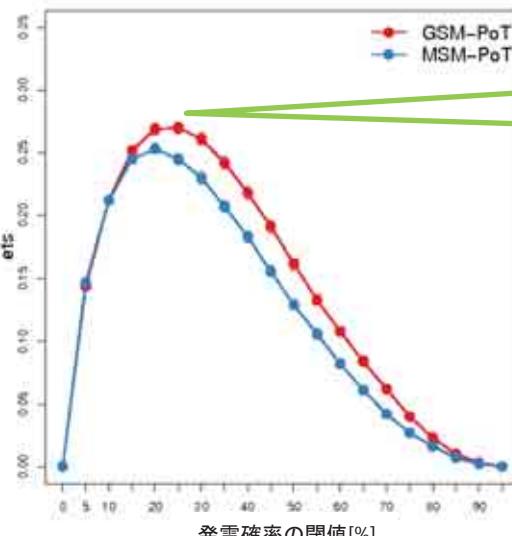
42

MSM発雷確率ガイダンスの予測精度(冬)

大きい程高精度



閾値別エクイタブルスレットスコア(ETS)

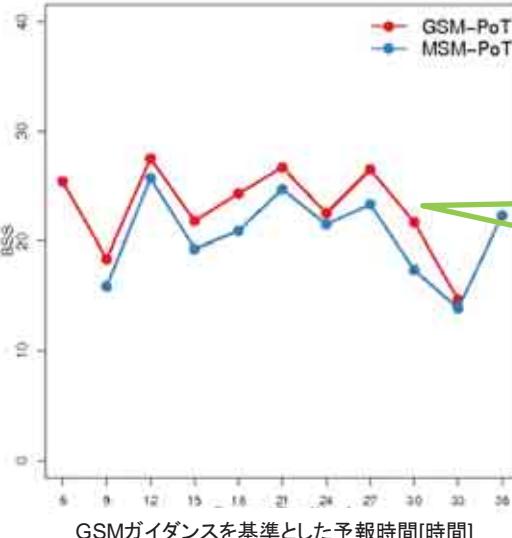


閾値別スコア
のピークが
GSMが高い
(高精度)

大きいほど確率予報の精度が良い



発雷確率のブライアスキルスコア(BSS)



ほとんどの予報時間において、GSMのスコアが高い
(確率予報の精度が良い)