

## 第5章 ガイダンス\*

### 5.1 応用処理の概要

前章までで述べられたとおり、数値予報は観測データの収集、デコード処理、品質管理、データ同化、数値予報モデルの実行、応用処理といった過程を経て未来の気象状況の予測を行っている（図 5.1.1）。数値予報モデルの実行結果は未来の気象状況を予測した、気温、風、湿度、気圧などの数値データの集まりである。

この数値データは、そのままでは予報官や一般のユーザーが扱いにくいいため、ユーザーが使いやすい形式に加工する必要がある。この過程を数値予報の応用処理と呼んでいる。さらに、この応用処理によって作成される製品を応用プロダクトと呼んでいる。




図 5.1.1 数値予報におけるデータ処理の流れ

#### 5.1.1 応用処理の目的

応用処理の主な目的は、数値予報の結果である数値データをユーザーが利用しやすい形式に加工することである。加工された製品は直接、図形式で提供される資料と、ユーザー側で可視化等の処理を行う目的で提供される格子点値 (GPV) や XML 形式などの数値データに分かれる。

図形式の資料としては FAX 図や Web 等で表示が容易な画像ファイルによるもので、ユーザーが気象状況を視覚的に捉えやすく、また特別な処理をすること無く利用できるという利点があり、従来から広く用いられてきた。

図形式以外の応用処理プロダクトは次の 3 つの目的をもって作成している。

- ① 数値データの切り出し。数値予報モデルが出力する膨大なデータからユーザーの利用目的に適した領域・要素等を選択し、形式を整えてユーザーに提供する。
- ② 予報要素へ変換（翻訳）。数値予報モデルが直接予測しない晴れ、曇りなどの天気カテゴリーや発雷確率などの要素を求める。
- ③ 統計的な修正。数値予報モデルの予測には必ず予測誤差が含まれている。応用処理により数値予報データに統計的な修正を行うことで、より精度の

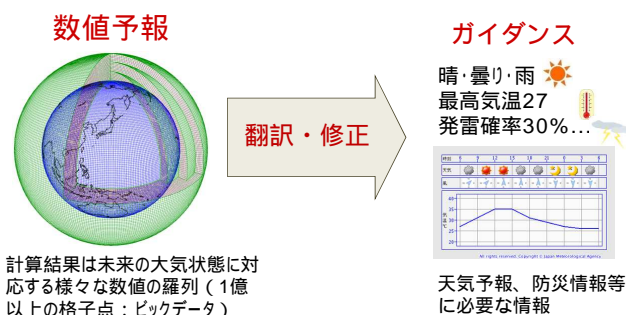


図 5.1.2 ガイダンスのイメージ

良い予測値をユーザーに提供する。

数値データ資料のうち、上記②または③の目的で作成した応用プロダクトをガイダンスと呼び、予報作業や注意報・警報の発表作業、飛行場予報の基礎資料として利用している（図 5.1.2）。なお、ガイダンスについての詳細な参考文献として、数値予報課報告・別冊第 64 号（気象庁予報部 2018）があるので、適宜、参照願いたい。

#### 5.1.2 応用プロダクトの種類

数値予報課で作成している応用プロダクトは以下の 3 種類に大別される。

##### (1) 天気予報・防災気象情報支援資料

天気予報作業や注意報・警報作業等の支援を目的として作成しており、予報作業の基礎資料として利用される（天気予報ガイダンス、防災情報ガイダンス、一般予報用 FAX 図、一般予報用 GPV）。

##### (2) 飛行場予報用支援資料

運航用飛行場予報 (TAF) の発表や飛行場における解説業務の支援を目的として作成しており、飛行場予報やカテゴリー予想の基礎資料として利用される（TAF ガイダンス）。

##### (3) 空域予報等支援資料

航空機が飛行する空域と呼ばれる領域を対象とした予測資料である。航空会社や航空局に提供され、航空機の運航支援に利用されるとともに、気象庁における空域予報作業の基礎資料として利用される（航空用 FAX 図、航空悪天 GPV、ATM 用悪天インデックスなど）。

### 5.2 ガイダンス

#### 5.2.1 ガイダンスの作成手順

気象庁でのガイダンスの典型的な作成手順を図 5.2.1 に示す。まず、過去の数値予報結果とその予報期間に対応する観測データを集める。次に統計手法を選択し、これらの予測値と観測値を統計処理することにより、予測値を観測値に翻訳するルール（これ以降、予測式

\* 石川 宜広

と呼ぶ。)を作成する(図 5.2.1 の縦枠に該当)。予測手法にはカルマンフィルタやニューラルネットワークなどがあるが、これらの予測手法については第 5.2.5 項で述べる。予測式ができれば、この式を最新の数値予報結果に適用することで未来の観測値に相当するガイダンスができる(図 5.2.1 の横枠に該当)。

ガイダンスは、天気予報や防災情報で使われる天気、最高・最低気温、降水確率、降水量、最大風速などを直接予測する資料である。これまでに数値予報の発展と共に、予測精度の向上及び気象庁の予報業務の発展に寄与してきた。

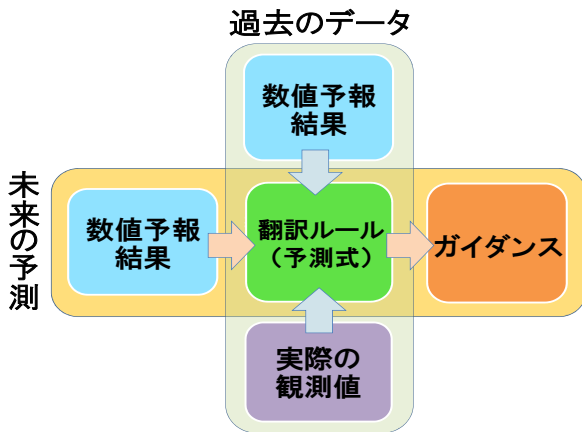


図 5.2.1 翻訳ルール作成の概念図

### 5.2.2 ガイダンスの種類

現在運用中のガイダンスは、警報・注意報や天気予報等の発表を支援することを目的に GSM, MSM, LFM から作成される天気予報ガイダンス・防災情報ガイダンス、飛行場予報・警報等の発表を支援する目的で MSM から作成される TAFM ガイダンス、空域予報の発表を支援する目的で GSM, MSM, LFM から作成される航空悪天 GPV の 3 つに大別される。表 5.2.1、表 5.2.2 及び表 5.2.3 にこれらのガイダンスの一覧を示す。MLR (線形重回帰)、KF (カルマンフィルタ)、NN (ニューラルネットワーク)、LR (ロジスティック回帰)、DM (診断手法)、FBC (頻度バイアス補正)、FC (フローチャート)<sup>1</sup>を略語とする。

### 5.2.3 一括学習型と逐次学習型

気象庁では 1977 年から数値予報と機械学習を用いて、ガイダンスの運用を開始した。当時のガイダンスは、数年分の数値予報のデータと観測データを用いて

<sup>1</sup> 閾値を設定し事象を複数のカテゴリに分類する手法。決定木と異なり、閾値は調査や経験則に基づく。

<sup>2</sup> 天気予報ガイダンスで作成される格子形式のガイダンスを入力とし、空港の周囲 4 格子の内挿値を予測値とする。最大降雪量では周囲 16 格子の最大値とその座標も提供する。

<sup>3</sup> 積乱雲量は MSM, LFM で作成している。

<sup>4</sup> 北太平洋を予測対象とする際は 0.5 度格子、全球を予測対象とする際は 1.25 度格子で作成する。

表 5.2.1 天気予報ガイダンスの一覧

| 要素   | ガイダンス名         | 統計手法    | 対象                              |
|------|----------------|---------|---------------------------------|
| 降水   | 平均降水量          | KF, FBC | 20 km 格子 (GSM)                  |
|      | 降水確率           | KF      | 5 km 格子 (MSM)                   |
|      | 最大降水量          | NN, MLR | 5 km 格子 (LFM)                   |
| 降雪   | 雪水比・降水種別・最大降雪量 | DM      | 5 km 格子                         |
|      | 降雪量地点          | NN, FBC | アメダス (323 地点)                   |
| 気温   | 時系列・最高・最低気温    | KF      | アメダス (927 地点)                   |
|      | 格子形式気温         |         | 5 km 格子                         |
| 風    | 定時・最大・最大瞬間風速   | KF, FBC | アメダス (927 地点)                   |
| 天気   | 日照率            | NN      | 20 km 格子 (GSM)                  |
|      | 天気             | FC      | 5 km 格子 (MSM)                   |
| 発雷確率 | 発雷確率           | LR      | 20 km 格子                        |
| 湿度   | 時系列湿度          | KF      | 気象官署 (153 地点、特別地域気象観測所含む)       |
|      | 日最小湿度          | NN      |                                 |
| 視程   | 視程分布予想         | DM      | 20 km 格子 (GSM)<br>5 km 格子 (MSM) |

表 5.2.2 航空気象予報ガイダンスの一覧

| 要素   | ガイダンス名      | 統計手法                       | 対象         |
|------|-------------|----------------------------|------------|
| 気温   | 時系列・最高・最低気温 | KF                         | 国内空港 95 地点 |
| 風    | 定時・最大・ガスト風速 | KF, FBC                    |            |
|      | ガスト発生確率     | LR                         |            |
| 天気   | 天気          | FC                         |            |
| 視程   | 視程、視程確率     | KF, FBC                    |            |
|      | 雲量、雲底高度     | NN, FBC                    |            |
| 雲    | 雲底確率        | LR                         |            |
| 発雷確率 | 発雷確率        | 天気予報ガイダンスから作成 <sup>2</sup> |            |
| 降雪   | 最大降雪量       |                            |            |

表 5.2.3 航空悪天 GPV の要素一覧

| 要素                      | 統計手法         | 対象                          |
|-------------------------|--------------|-----------------------------|
| 乱気流指数                   | LR           | 0.5 度格子 (GSM) <sup>4</sup>  |
| 着水指数                    | DM           | 1.25 度格子 (GSM) <sup>4</sup> |
| 積乱雲量 <sup>3</sup> ・雲頂高度 | DM           | 40 km 格子 (MSM)              |
| 視程分布予想 (LFM のみ)         | DM           | 10 km 格子 (LFM)              |
| 風、気温、湿度などの一般要素          | 入力とするモデルから内挿 |                             |

線形重回帰で予測式を作成し、その予測式でガイダンスを作成する、一括学習型(図 5.2.2)と呼ぶガイダンスのみであった。この方法は係数が変化しないためにガイダンスの予測特性を把握しやすい点で有効であるが、その反面、利用する数値予報が改良などによって特性が大きく変化した場合、最適な予測が出来なくなり、これらのデータが数年間かけて蓄積されるのを待ってから予測式を再作成しなければならなかった。このため、数年の間はガイダンスの予測精度に劣化を招く恐れがあった。

そこで数値予報が変更になった場合にもなるべく早く変化に適合できるような手法として、1996 年からカルマンフィルタ及びニューラルネットワークを使用するようになり、予測式を日々更新できるようになった。これらの手法を用いて逐次的に学習し、予測の度に係数が変化する型のガイダンスを、逐次学習型(図 5.2.3)と呼んで、一括学習型(図 5.2.2)と区別している。

当時は、この逐次学習型の手法は画期的なものとして受け入れられ、多くのガイダンスが一括学習型から

### ガイダンスの概念図（一括学習型）発雷確率の例

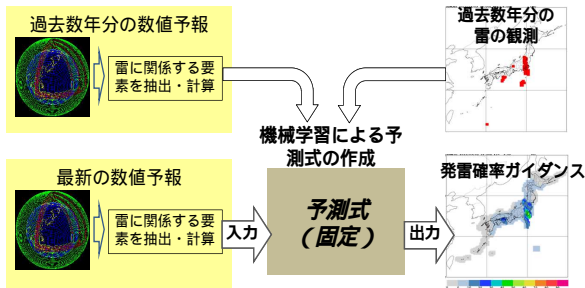
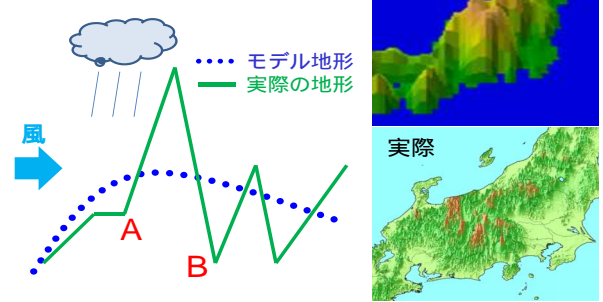


図 5.2.2 一括学習型ガイダンスの作成方法の概念図。発雷確率ガイダンスの例で、予測式はロジスティック回帰で作成される。

### 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

図 5.2.4 地形に起因する系統誤差の概念図

### ガイダンスの概念図（逐次学習型）気温の例

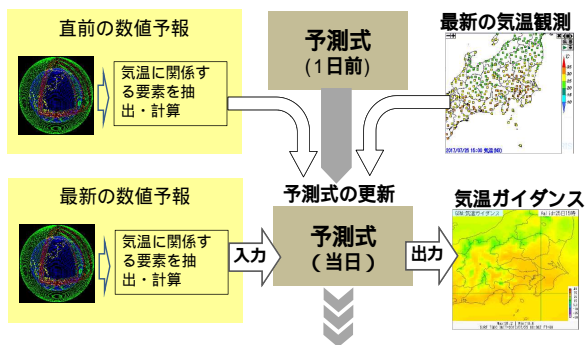


図 5.2.3 逐次学習型ガイダンスの作成方法の概念図。気温ガイダンスの例で、予測式の係数がカルマンフィルタで更新される。

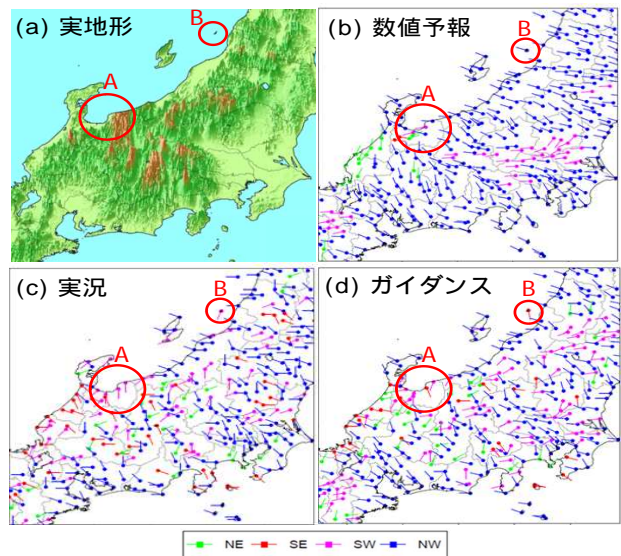


図 5.2.5 ガイダンスの系統誤差修正が有効な例。(a) 実地形、(b) モデル予測、(c) アメダスによる観測。(d) ガイダンスによる予測。矢羽の色は凡例で示した大まかな風向を表す。

逐次学習型に移行した。これにより、数値予報の特性の変化のみでなく、季節や年変化にも日々の学習で追従できるようになった。ただし、逐次学習型は発生頻度が稀な現象の予測に対して有効性が低く、一括学習型の方が良い場合もあるので、現在は両方の学習型が利用されている。

#### 5.2.4 ガイダンスによる系統誤差の修正

数値予報モデルの予測誤差は、ある偏りを持った系統誤差と、それ以外のランダム誤差に分けて考えることができる。系統誤差は、統計的な修正をすることにより軽減できる。一方、ランダム誤差は特定の傾向を持たないため、統計的な処理を行っても軽減することができない。系統誤差が生じる原因はさまざまであるが、ここでは数値予報モデルの地形と実際の地形の差に起因する系統誤差について説明する。

図 5.2.4 は実際の地形（緑線）と数値予報モデルの地形（青破線）の概念図及び GSM 地形と実地形の鳥瞰図である。気象条件として風が西から東（図の左から右）に向かって吹いており、降水がある場合を考える。地点 A において観測される降水は、地形斜面の効果によって強化されるが、数値予報モデルの地形は実地形よりもなだらかなため、数値予報モデルで予測される降水

量は、観測よりも過少になりやすい。一方、地点 B では実地形が谷底に位置しており、数値予報モデルで表現される地表面より標高が低い。このため、仮に数値予報モデルの予測が正しいとしても、標高が高い分、数値予報モデルの地表面の気温は実況よりも低く予測されてしまう。さらに地点 B での数値予報モデルで予測される風についても、実際には谷筋に沿った（紙面に垂直な方向に）風が吹くと期待されるが、数値予報モデルは実地形より滑らかなため、地形による風向への影響が少なく、実際と異なる風が予測されることになる。

数値予報モデルの地形では、図 5.2.4 の地形の鳥瞰図から判るように、中部山岳地帯が一つのなだらかな山岳として表現されており、標高も実地形よりも低くなっている。このように、数値予報モデルの地形が実際と異なることによって、系統誤差が発生することになる。この誤差はガイダンスで軽減することが可能である。

ガイダンスの修正効果をより分かりやすく見るため、図 5.2.5 にガイダンスにより修正された風の例を示す。(b) は数値予報モデルの予測した地上風で、数値予報モデルの地形に沿うような形で水平方向に比較的一様な流れとなっている。(c) は同じ時刻のアメダスによる観測で、(a) の実地形の影響により地点毎に細かく変化しており、数値予報モデルの予測とは大きく異なる。(d) はガイダンスによる予測で、丸 A の部分に注目すると、地形の違いによる系統誤差が軽減し、実況により近い風向を予測していることがわかる。また、丸 B の部分 (栗島) は、(a) の実地形からもわかるように本来、島として陸地であるべきところであるが、数値予報モデルの地形では海となっており、アメダスと風向が異なっている。ガイダンスでは実況に近い風向に修正されている。

### 5.2.5 ガイダンスの作成手法

ガイダンスでは、数値予報モデルの予測値を観測値で翻訳または修正するための予測式を作成する。予測式は目的変数、説明変数、係数で構成されている。目的変数はガイダンスで予測する物理量、指数及び確率などの要素である。説明変数はガイダンスで予測する要素と相関のある物理量や指数などの要素で、例えば降水量ガイダンスであれば数値予報モデルの降水量の予測値や安定度の指数など数値予報モデルの予測結果から直接計算できるものが用いられる。係数は過去の数値予報モデルの予測結果と観測データを統計処理することによって得られる。この係数を決めることにより予測式が完成する。予測式を作成するための統計手法について、気象庁のガイダンスに用いられている手法を説明する。各手法の詳細については気象庁予報部 (2018) を参照願いたい。

#### (1) 線形重回帰

1996 年以前までは、気象庁の多くのガイダンスで線形重回帰 (工藤 2018a) が用いられていたが、現在では 24 時間最大降水量ガイダンスで使用されている。アメリカ、カナダ、ドイツの現業数値予報センターでは今でも主流な予測手法である。予測式は係数と説明変数の積を足し合わせる形の線形多項式 (5.2.1) で表される。

$$y = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n \quad (5.2.1)$$

ここで、目的変数  $y$ 、説明変数  $x$ 、係数  $w$  で、 $n$  は説明変数の個数である。

過去数年分の数値予報結果と観測値を一括して統計処理し、係数の作成を行う。図 5.2.6 は説明変数が 2 個の場合の線形重回帰の予測式の概念図である。この図のように予測式を決める事は、3 次元空間上で一つの平面を決めることに相当する。ガイダンスに線形重回帰を用いるメリットは、係数が変化しないためにガイ




図 5.2.6 説明変数が 2 つの線形重回帰の予測式のイメージ。係数を決定することは 3 次元上の平面を決めることと同じ。

ダンスの予測特性をユーザーが経験的に把握しやすい点と、説明変数を客観的に選択する手法が準備されていることである。デメリットとしては、係数決定の為に過去の数値予報結果と観測データを多量に準備する必要があることと、数値予報モデルの変更に柔軟に対応できないことなどがあげられる。こうした理由により、現在では (3)、(4) で述べるニューラルネットワークやカルマンフィルタが気象庁におけるガイダンス作成手法の主流になっている<sup>5</sup>。

#### (2) ロジスティック回帰

ロジスティック回帰 (工藤 2018b) は、実況が現象の有無の 1 (現象有り)、0 (現象無し) の 2 値で表現できる現象の確率を予測する場合に使われ、気象庁では発雷確率、雲底確率ガイダンスなどの作成に用いられている。ロジスティック回帰では、現象の発生確率  $p$  がロジスティック関数 (5.2.2) で表せるものと仮定する。

$$p = 1/[1 + \exp(-(w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n))] \quad (5.2.2)$$

ここで、確率を表す目的変数  $p$ 、説明変数  $x$ 、係数  $w$  で、 $n$  は説明変数の個数である。

予測式 (5.2.2) を確率  $p$  のロジット  $\ln(p/(1-p))$  で表すと、(5.2.3) 式のようにロジットと説明変数に線形関係があると仮定していることがわかる。

$$\ln(p/(1-p)) = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n \quad (5.2.3)$$

発雷確率ガイダンスのロジスティック回帰式の有効性について、発雷確率で用いられている説明変数の一つであるショワルターの安定指数 (SSI; Showalter 1953) と実況の発雷確率の関係で説明する。図 5.2.7 は、季節別に SSI の値と実況の発雷確率及びそのロジットを

<sup>5</sup> 季節予報用ガイダンスなどでは線形重回帰が使われている。

グラフにしたもので、左図の SSI と実況の発雷確率では両者が非線形な関係になっているのに対し、右図の SSI と実況の発雷確率のロジットでは、両者はほぼ線形な関係となっている。このことから、発雷確率の予測にロジスティック回帰を使うと良い予測特性を得ることが期待できる。




図 5.2.7 発雷確率と SSI(左) 及び発雷確率のロジットと SSI(右) の関係

ロジスティック回帰は目的変数が 2 値データである場合に発生確率を予測することができ、シンプルな手法でありながら従来用いていた手法と比べて高い予報精度を持つことから、気象庁のガイダンスにおいても確率予測に広く利用されている。

### (3) ニューラルネットワーク

ニューラルネットワーク (工藤 2018c) は最大降水量、天気、最小湿度、日照率などのガイダンスに用いられている。ニューラルネットワークは、神経細胞の動作を模した働きをするように作られた情報処理の手法である (図 5.2.8)。この手法は、説明変数と目的変数の関係が線形でない場合でも取り扱う事ができる点に特徴がある。たとえば、ある説明変数が閾値を境に現象の振る舞いが大きく変化する場合は、カルマンフィルタなどの線形な予測式では一般的に取り扱う事が難しい。

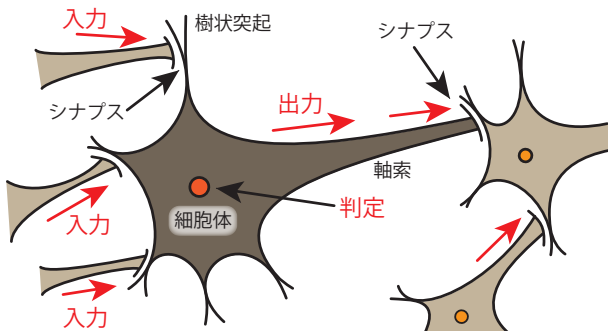


図 5.2.8 ニューラルネットワークのモデル (神経細胞の動作)。細胞体への入力の総和がある閾値を超した時に出力が次の細胞体に伝達されるという動作がニューラルネットワークのモデルとなっている。

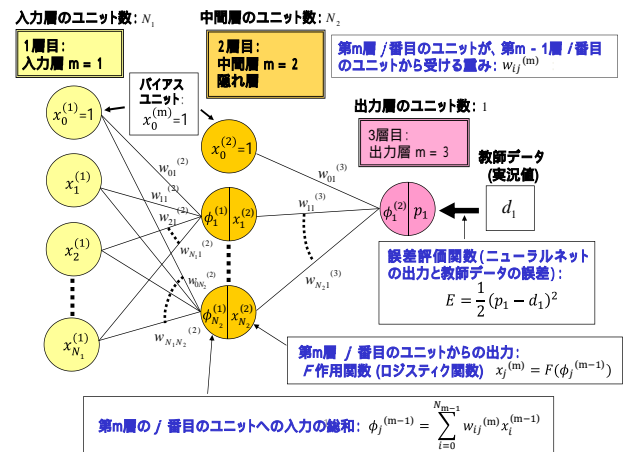


図 5.2.9 ニューラルネットワークの説明

図 5.2.9 は、順伝播型ニューラルネットワークというガイダンスで採用されている手法を一般化して表現したものである。ニューラルネットワークでは、左の入力つまり説明変数から、右端の出力すなわち目的変数としてガイダンス値に至るまで、ユニットという単位の処理を経る。各ユニットは、一つ下の層のすべてのユニットの判断結果を受け取り、自分の判断を下す。その際、以下の処理が成される。

- ① 中間層ではどのユニットの判断をどれくらい重視するか、という重み付けをして値を受け取っており、具体的には、入力層のそれぞれの出力に重み係数をかけてその総和が入力となる。
- ② 次に、入力の総和  $\phi_j$  に活性化関数を作用させた値を中間層からの出力  $x_j^{(2)}$  とする。このとき活性化関数にロジスティック関数などの非線形関数を用いることで、目的変数と説明変数の間に非線形関係がある場合でも取り扱うことができる。
- ③ 最終的に得られた出力  $p_1$  (下のユニットの重み付き総和の関数値) を観測値 (教師データ)  $d_1$  と比較し、その誤差を小さくするようにユニットの重みを変える。
- ④ バイアスユニットでは常に 1 が出力され、閾値の設定に利用される。

図 5.2.10 は天気ガイダンスで晴曇判別をするための日照率ガイダンスのニューラルネットワークの構成を示したものである。このガイダンスでは 3 層の「順伝播型ネットワーク」と呼ばれる手法が使われている。入力層は、数値予報モデルの結果である各層の相対湿度、気温及び降水量である。中間層が一層あり、出力は日照率で、この値の大きさにより晴れと曇りが判別される。日照の観測値を教師データとし、各層の重み係数を学習している。

ニューラルネットワークはブラックボックスであるが、ある程度その構造を抜き出してみることができる。図 5.2.11 は寒候期と暖候期の特定した日における説明

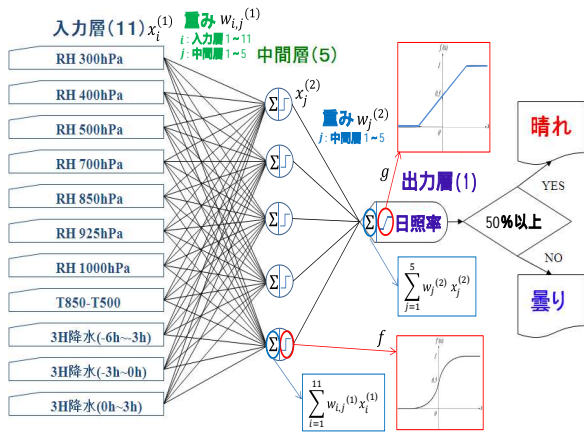


図 5.2.10 日照率ガイダンスのニューラルネットワーク

変数と目的変数の入出力関係を示したもので、500 hPa の湿度と 850 hPa の湿度の値を変化させた場合の出力 (日照率) の変化を示している。ニューラルネットワークでは説明変数は 0 ~ 1 に正規化されている。冬の新潟では下層雲が支配的であり、500 hPa の湿度より 850 hPa の湿度が良く効いている。この例ではそれほど強い非線形関係にはなっていない。東京の暖候期の事例では強い非線形関係が出ている。500 hPa 湿度が 0.5 を超えると急に日照率が減ってゆく。また 850 hPa が乾いている時には 500 hPa の湿度はあまり影響しない構造となっている。季節によって逐次学習が行われ最適化されていることがわかる。

(新潟) 寒候期2007年12月31日12UTC (東京) 暖候期2008年6月23日12UTC

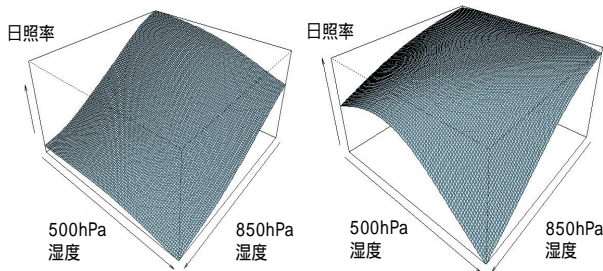


図 5.2.11 日照率ガイダンスの入出力関係

ニューラルネットワークを用いたガイダンスのメリットは、非線形の関係を取り扱うことができることである。この手法は予測式が非線形であるため、ユーザーが説明変数と予測結果との関係を把握することが困難なこと、予測式が変化するためにユーザーが経験的に予測特性を把握することが困難なこと、また、説明変数や中間層の数などのパラメータを客観的に選択する方法がないため、これらを試行錯誤により決める必要があり開発コストが高いことなどのデメリットもある。

#### (4) カルマンフィルタ

カルマンフィルタ (工藤 2018d) は気温、平均降水量、

降水確率、時系列湿度、視程の各ガイダンスに用いられている。カルマンフィルタを用いたガイダンスの予測式は、線形多項式 (5.2.4) で表され、観測モデルと呼ばれる。前回の予測と実況の差に応じて、初期時刻毎に最適な係数に更新する。

$$y^{(t)} = w_0^{(t)} + w_1^{(t)} x_1^{(t)} + w_2^{(t)} x_2^{(t)} + \dots + w_n^{(t)} x_n^{(t)} \quad (5.2.4)$$

ここで、目的変数  $y$ 、説明変数  $x$ 、係数  $w$  で、 $t$  は対象時刻を表し、 $n$  は説明変数の個数である。

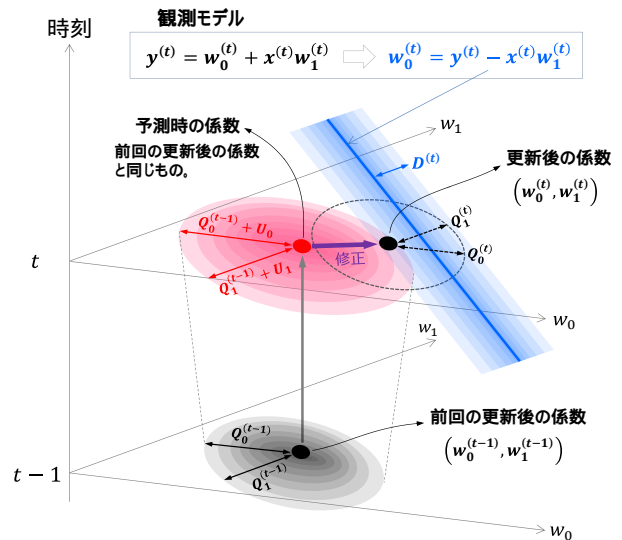


図 5.2.12 カルマンフィルタでの係数更新のイメージ。係数が 2 個の場合。時刻の添字は ( ) を付けて上付きで示している。

図 5.2.12 に係数が 2 個 ( $w_0, w_1$ ) の場合のカルマンフィルタでの係数更新のイメージを示す。時刻は ( ) を付けて上付きで示している。図では係数を確率密度関数 (以降は PDF (Probability Density Function) と呼ぶ) として正規分布を仮定し、その  $w_0, w_1$  方向の分散を  $Q_0, Q_1$  で表す。また、予測式の不完全性により時間発展する誤差をシステムノイズと呼び、 $U_0, U_1$  で表す。今、時刻  $t$  での予測時の係数は、前の時刻  $t-1$  で更新された係数をそのまま利用しているが、時刻  $t$  での PDF の分散は、時刻  $t-1$  と比べてシステムノイズの  $U_0, U_1$  分だけ大きくなる。このことは図では赤の楕円に対応しており、時刻  $t-1$  の PDF の分散 (灰色の楕円) と比べて中心位置は変わらないが広がりは大きくなっている。

(5.2.4) 式の観測モデルの係数 2 個の場合について、 $w_0^{(t)}, w_1^{(t)}$  の関数に変形すると、 $w_0^{(t)} = y^{(t)} - x_1^{(t)} w_1^{(t)}$  となる。ここで、時刻  $t$  の観測  $y^{(t)}$  が得られると、既に与えられている説明変数  $x_1^{(t)}$  と観測モデルにより、未知の変数である時刻  $t$  の係数の真値  $w_0^{(t)}, w_1^{(t)}$  が  $w_0^{(t)} = y^{(t)} - x_1^{(t)} w_1^{(t)}$  を中心として、観測誤差に起因する PDF を仮定した観測ノイズの分散  $D^{(t)}$  領域 (図中の青の直線および長方形) に分布することがわかる。そこで、時

時刻  $t$  の係数を更新するには、観測モデルの PDF と時刻  $t-1$  の係数の PDF について、この 2 つの確率密度の積が最も大きくなる係数が時刻  $t$  の期待値  $(w_0^{(t)}, w_1^{(t)})$  となり、その係数の PDF の分散は  $Q^{(t)}$  となる。

このとき  $D^{(t)}$  を大きな値に設定すると図中の青の長方形で示した領域が広がり、更新後の係数は予測時の係数に近い値になる。逆にシステムノイズ  $U^{(t)}$  を大きな値に設定すると図中の赤の楕円で示した領域が広がり、更新後の係数は観測値に近い値になる。相対的に  $D^{(t)}$  が小さい場合には、新たな観測が得られる度に観測に寄せるように係数が決まるため、係数の変動幅が大きくなる。逆に  $D^{(t)}$  が大きい場合には係数の変動幅は小さくなり、予測と実況の差が大きかったとしても係数はあまり変化しなくなる。

予測時の係数を更新後の係数に修正させるベクトル (図中の紫矢印) は、観測値と予測値との差 (イノベーションと呼ぶ) に、カルマンゲインというベクトルを掛けたものなる。カルマンゲインはガイダンスでは観測モデルや係数の PDF の分散などから計算される。カルマンゲインの算出方法については、工藤 (2018d) を参照していただきたい。図で破線の楕円で示したように、観測値の情報を得ることで、更新後の係数の PDF の分散は予測時の分散よりも小さくなる。観測ごとに以上のことを繰り返すことで、カルマンフィルタでは最新の観測値の情報を取り込みながら係数を逐次更新する。

カルマンフィルタを用いたガイダンスは、予測式が線形多項式であるため説明変数の変動がどの程度、予測結果に影響を与えているかを把握しやすく、係数が自動的に最適化されることからガイダンス利用開始前の事前学習が比較的少量のデータで済む。さらに季節変化による数値予報モデルの予測誤差特性の変化や数値予報モデルの変更にも柔軟に対応できるなどメリットがある。一方、係数が最適化により変動し、予測特性が常に変化するため、ガイダンスのユーザーが経験的に予測特性を把握することが難しいことや、頻度が少ない大雨や強風などの現象に対しては逐次学習により必ずしも予測精度が向上しないこと、また、維持管理コストが掛かることなど、線形重回帰を用いたガイダンスと比較してデメリットもある。

### (5) 頻度バイアス補正

カルマンフィルタなどの統計手法を用いて気象要素を予測すると、発生頻度の高い現象を予測するのに適した予測式となり、発生頻度の低い強風や大雨などは実況に対して予測頻度が低くなる (図 5.2.13)。しかし気象予測ではこれらの現象を予測することが防災などの観点からは重要であるため、平均的な予測誤差が多少悪くなくても発生頻度の低い現象の予測精度を上げたい。こうした時に頻度バイアス補正を用いている。

具体的には、観測の頻度分布と予報の頻度分布が同




図 5.2.13 統計手法による予測のデメリット。目的変数と説明変数の関係 (風、降水など)。

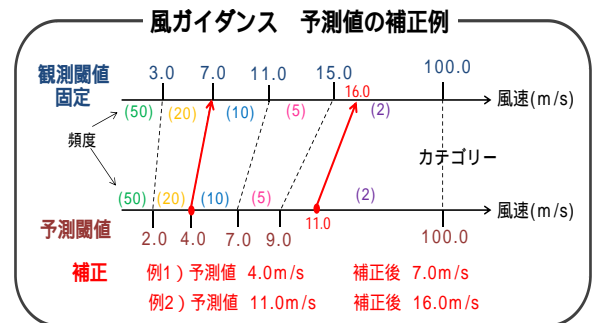


図 5.2.14 頻度バイアス補正の仕組み。観測と予報で同じ区間の事例数が等しくなるように予報の閾値を調整する。

じになるように補正を行う。図 5.2.14 に風ガイダンスの予測値の補正例を示す。観測と予報に閾値を設定していくつかの 카테고리を作り、対応する同一カテゴリの現象の発生頻度が等しくなるように (バイアスコアが 1 となるように) 予測の閾値を調整する。

例 1 ではカテゴリ II と III の境界での予測閾値 4.0 m/s が、観測閾値 7.0 m/s に対応しているため、予測値の 4.0 m/s を 7.0 m/s に補正している。また、例 2 ではカテゴリ V の予測値 11.0 m/s を、カテゴリ内にある観測値の大きさを考慮して、16.0 m/s に補正している。頻度バイアス補正は平均降水量、風、視程などのガイダンスに用いられている。頻度バイアス補正を用いることのメリットは強風や大雨などの捕捉率を向上させることができる点であるが、一方空振り率が増加してしまうデメリットもある。

### (6) 係数の層別化

係数の層別化は気温、降水、風、発雷確率など多くのガイダンスで行われている。数値予報の系統誤差は、場所、対象時刻、予報時間、季節などで変化する。また、説明変数と目的変数の関係も変化する。このため一つの予測式で全ての場合に対応する事は困難なため、特定の条件により予測式の係数を複数使い分けて予測精度の向上を図ることが多い。このことを係数の層別化と呼ぶ。しかし、予測式を多くすれば、予測式を作成するためのサンプル数が少なくなり精度の高い予測式を作成できなくなるというトレードオフの問題が発




図 5.2.15 発雷確率ガイダンスの区域による層別化。青線で区切られた 1~9、a~z の格子では同じ予測式を使う。

生ずる。このため、どの程度層別化を行うかはガイダンス開発の重要なポイントとなる。例えば、気温、風については予報対象時刻、初期時刻、地点などにより数値予報モデルの誤差特性が大きく変動するため、これらのガイダンスではそれぞれについて層別化を行っている。また、発雷確率ガイダンスでは格子毎に予測式を作成すると必要なサンプル数を確保できないため、発雷特性の似た格子同士をまとめて日本を 35 区域に分けて予測式を作成している (図 5.2.15)。

#### (7) 診断的な手法

近年では数値予報モデルの予測精度が向上してきたため、厳密な系統誤差の補正を行わず、数値予報モデルの出力をそのまま予測値に変換するタイプのガイダンスを作成しやすくなった。このようなガイダンスの予測式は論理的な関係や簡便な調査結果などを基に作成し、格子毎に予測式を変えるなどの細かい調整は行わない。このため、観測資料が十分得られない場合でも作成することができる。このようなガイダンスの例として、視程分布予想、航空悪天 GPV の積乱雲頂高度、着氷指数などがある。これらは面的または立体的な予測値として提供することが可能である。また、ほかにも、予測式の作成に長期間のデータの蓄積が不要なこと、数値予報モデルの結果が直接的に予想に反映されるため、シャープな予測がされることもメリットとしてあげられる。一方で、厳密な系統誤差補正を行わないため数値予報モデルの予測特性がそのまま反映され、数値予報モデルの変更に伴い予測特性が変化することが予報作業に利用する上ではデメリット<sup>6</sup>となりうる。

<sup>6</sup> モデルの予測特性の変化が直接表れることは数値予報モデルの予測特性を確認したい開発者にとってはメリットと言える。

### 5.2.6 ガイダンスの提供形式

ガイダンスの提供形式としては、地点形式と格子形式がある。地点形式のガイダンスは、気温や風などのガイダンスのようにアメダス地点や空港などの現地観測を利用して、数値予報モデルの予測値に統計的な補正を行うものである。一方、格子形式のガイダンスには、最大降水量や最大降雪量ガイダンスのように日本の陸域及び海岸線から離れた約 100 km までの海域を予測領域として、統計的な補正を重視したものと、視程分布予想や航空悪天 GPV などのように面的、立体的な日本及びその周辺や北太平洋の広領域の情報提供を重視するものがある。

### 5.3 ガイダンスの例

気象庁で作成しているガイダンスのうち、カルマンフィルタやニューラルネットワークによる統計的な補正を重視したガイダンスの例として、気温ガイダンスと降水量ガイダンスを、複数のガイダンスを入力にした例として、最大降雪量ガイダンスを紹介する。

また、診断的な手法やロジスティック回帰を用いた、平面や立体的な気象情報を作成するガイダンスの例として、視程分布予想、航空悪天 GPV の乱気流指数、着氷指数、積乱雲量・雲頂高度を紹介する。

最後にガイダンスとは異なるが、直接、観測と予測を特定の用途に適した形に加工して提供する応用プロダクトの例として、ATM 用悪天インデックスを紹介する。

#### 5.3.1 気温ガイダンス

気象庁では一般予報および飛行場予報を支援する目的で地点ごとの気温ガイダンスの作成を行っている (三戸 2018)。統計手法にはカルマンフィルタを用いており、アメダス観測地点での数値予報モデルの地上気温の誤差 (修正量) を目的変数として予測を行う。説明変数には地上気温+40 度、地上風速、東西南北成分の地上風、中下層雲量、前 3 時間降水量、気温減率、前日とのモデル地上気温差を使用している。地上気温 (摂氏) に 40 度を足しているのは、0 度を境に説明変数の地上気温の符号が反転することを防ぐためである。天気予報ガイダンスではアメダス地点の時系列気温および最高、最低気温を予測し、TAF ガイダンスは航空官署の時系列気温および最高、最低気温を予測している。

格子形式気温ガイダンスは、地点形式の時系列気温ガイダンスをもとに格子形式での毎正時の気温の予測を行う。GSM, MSM を入力として作成し、いずれも 5 km 格子を予測対象としている。本ガイダンスは、各アメダス地点における時系列気温ガイダンスのモデル気温修正量を標高などを考慮して水平内挿し、それを各格子のモデル地上気温に加えることで作成される (図 5.3.1)。



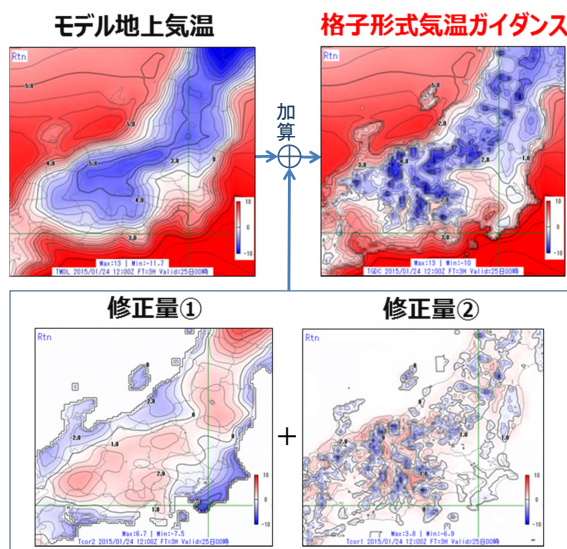
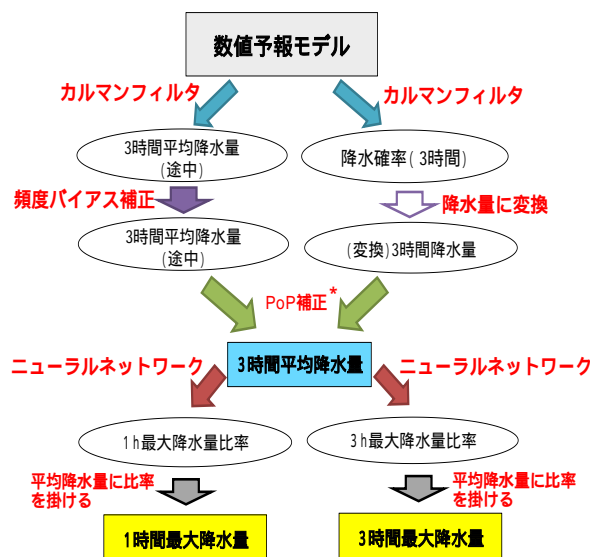


図 5.3.1 格子形式気温ガイダンスの作成の流れの概念図。モデル地上気温に、修正量 1 (格子毎に周囲のアメダス地点の重み付け平均推定) と修正量 2 (格子毎にモデル標高から 5 km 平均標高への標高補正で修正で推定) を加えることで、格子形式気温ガイダンスは作成される。図中の赤系統の色は正、青系統の色は負値を示す。



\* PoP補正とは、3mm以下の弱い雨について、(変換)3時間降水量と3時間平均降水量とを重み付き平均により降水量を計算する手法である。

図 5.3.2 降水ガイダンスの予測要素間の関係

### 5.3.2 降水量ガイダンス

気象庁では天気予報および注意報・警報発表作業等の基礎資料として最大降水量ガイダンスの作成を行っている(白山 2018)。最大降水量ガイダンスは格子 (GSM ガイダンス 20 km、MSM ガイダンス 5 km) 内の降水量の最大値を予測する。作成方法は、まずカルマンフィルタと頻度バイアス補正により平均降水量の予測値を作成し、続いてニューラルネットワークにより解析雨量から算出した平均降水量と最大降水量の比を予測して、最後に両者を掛け合わせるにより最大降水量を作成する(図 5.3.2)。

### 5.3.3 最大降雪量ガイダンス

最大降雪量ガイダンスは 5 km 格子内の降雪量を予測するガイダンスである(土田 2018)。天気予報作業および注意報・警報発表作業等の基礎資料として利用されている。最大降雪量ガイダンスは格子形式気温ガイダンスと数値予報モデルの予測する相対湿度から計算した雪水比(降雪量と降水量の比)を平均降水量ガイダンスに掛けることにより作成する(図 5.3.3)。雪水比の計算には過去の気温の観測値と雪水比の実況から作成した統計式を使用する(図 5.3.4)。このような比較的簡便な手法で作成された気温と雪水比のガイダンスを用いることにより、以前は雪の観測値データのある地点でしか作成できなかった降雪量も格子形式で作成することができるようになった。

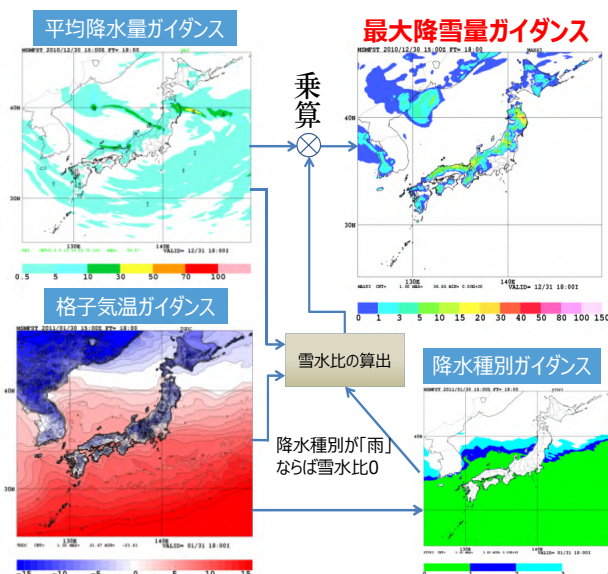


図 5.3.3 最大降雪量ガイダンス

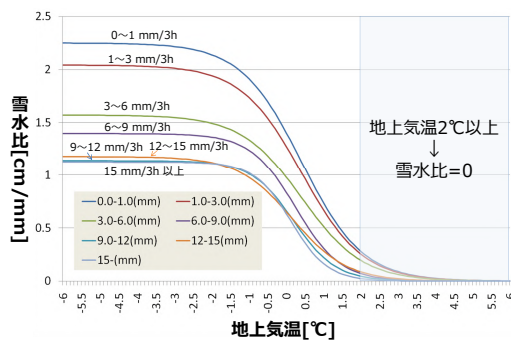


図 5.3.4 降水量によって層別化された雪水比

### 5.3.4 視程分布予想

視程分布予想は数値予報モデルの予測値から雲、エロゾル、雨、雪それぞれに起因する消散係数<sup>7</sup> ( $\sigma$ ) を

<sup>7</sup> 照度 E の距離 x に対する減衰率を消散係数とする。dE/dx =  $-\sigma E$  の関係がある。

視程 VIS=3 / ; 消散係数 = p+ c+ r+ s

浮遊塵の消散係数 :  $p = 0.12(1-RH)^{-0.5}$   
 雲の消散係数 :  $c = 12.0 \times Qc^{0.9}$   
 雨の消散係数 :  $r = 0.45 \times Rain^{0.55}$   
 雪の消散係数 :  $s = 7.5 \times Snow^{0.7} + 0.07 \times FF$

Qc : モデル面第2~5層の雲水量の和 [g/kg]  
 Rain : モデル内の降雨量の予想 [mm/h]  
 Snow : モデル内の降雪量の予想 [mm/h]  
 RH : モデル面第2層の湿度 [%], 85%を上限  
 FF : モデル面第2層の風速 [m/s]

図 5.3.5 MSM 視程分布予想の消散係数の算出方法

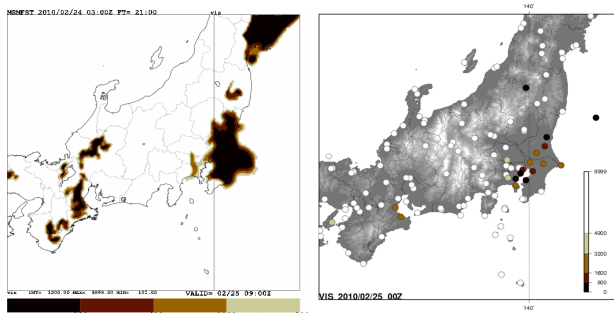


図 5.3.6 MSM 視程分布予想と実況。2010年2月24日03UTC 初期時刻の25日00UTCの視程分布予想(左)と現地観測(右)(単位 m)

診断的に計算し、消散係数と視程の近似式(変換式)を用いて各格子における視程を予測する(後藤 2018)。消散係数は数値予報モデルの予測する雲水量、相対湿度、降水量、降雪量、風速と消散係数の関係をもとに経験的に決めている(図 5.3.5)。このような手法を用いることにより、視程観測データの無い地点の予測や視程分布の予測を作成することができるようになった(図 5.3.6)。視程分布予想が実用的な予測精度を持つことができたのは、数値予報モデルの地上付近の雲水量や水蒸気量の予測精度が向上したことによる。

### 5.3.5 航空悪天 GPV

空域予報業務を支援する目的で、航空悪天 GPV を作成している。航空悪天 GPV は乱気流指数(工藤 2018e)、着氷指数(井藤 2018a)、積乱雲量・雲頂高度(井藤 2018b)などの分布を3次元で予測している。乱気流指数(図 5.3.7)は、乱気流の要因別に作成した複数の指数をロジスティック回帰で組み合わせた指数である。ロジスティック回帰で得られた確率値を調整することで、高度によらず同じ閾値を目安として乱気流の予測をすることが可能となっている。

着氷指数(図 5.3.8)は過去の気温および湿数と、着氷の発生頻度から求めた統計式により着氷の発生しやすさを0~100の数値で表した指数である。積乱雲量(予測格子内における積乱雲のしめる割合)および積乱雲頂高度の予測は、数値予報モデルの予測した成層状態からパーセル法に基づく診断手法により積乱雲の発生の有無を判定し、それに基づいて積乱雲量と積乱雲

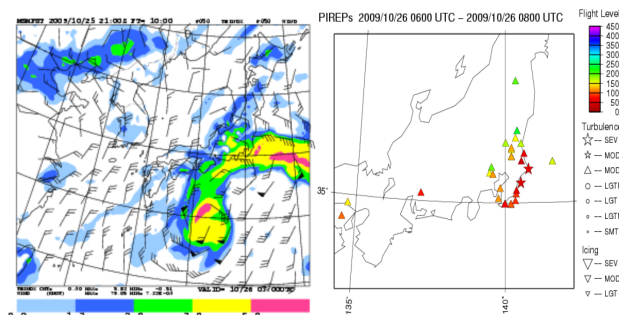


図 5.3.7 乱気流指数の例。2009年10月25日21UTC 初期時刻の26日06UTCの乱気流指数(左)と乱気流の観測。☆△は乱気流の通報された位置と強さ、色は高度を表す。

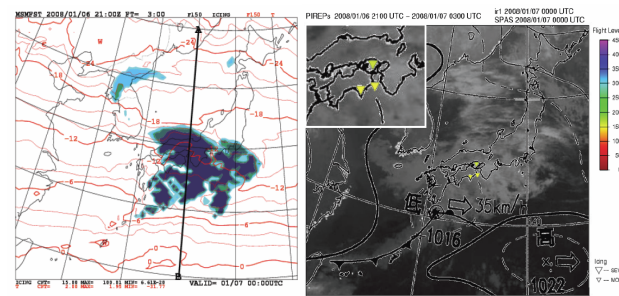


図 5.3.8 着氷指数の例。2008年1月6日21UTC 初期時刻の7日00UTCの着氷指数(左)と着氷の観測(右)。▽は着氷の通報された位置と強さ、色は高度を表す。

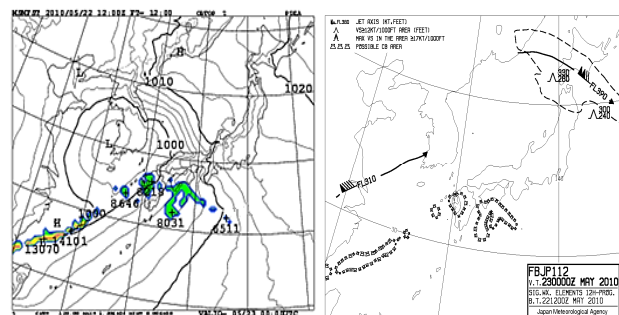


図 5.3.9 積乱雲の雲頂高度の予測例。2010年5月22日12UTC 初期時刻の23日00UTCの雲頂高度の予測(左)と積乱雲量の予測(右)。雲頂高度の数値はピーク値[m]を表し、積乱雲量については雲量3/8以上の領域をキャラクターで囲んで表示。

頂高度を算出している(図 5.3.9)。

### 5.3.6 ATM用悪天インデックス

航空交通気象センター(ATMetC)では航空局の航空交通管理を支援するためにATMet時系列情報を提供している(図 5.3.10; 宮内誠二ほか 2008)。このATMet時系列情報の作成を支援するために、ATM用悪天インデックスを作成している。

ATMet時系列を作成するための基礎資料として、降水短時間予報や LFM 航空悪天 GPV で作成された強

<sup>8</sup> 航空交通管理センター(ATMC: Air Traffic Management Center)には、福岡管制部があり日本飛行情報区(FIR)の航空交通管理の責任を負っている。ATMetCはこのATMCを支援するための情報提供を行っている。

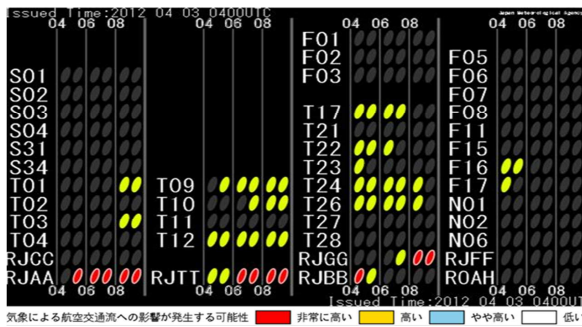


図 5.3.10 ATMet 時系列の例。縦方向に並んだ 3~4 個の英数字は管制空域及び空港を表す。英数字の右に並ぶ 6 個の楕円形の色が向こう 4~9 時間の航空交通流に影響が発生する可能性を表す。

雨や積乱雲などの悪天域を管制空域別に編集して指数化し、ATM 用悪天インデックスとして提供を行っている。

## 5.4 まとめ

最初に数値予報の応用処理について説明し、その代表的な応用プロダクトとしてガイダンスについて機能や作成方法、いくつかのガイダンスの例を紹介した。数値予報を開始した当時は、特に地上付近の予測精度が十分では無かったため、数値予報モデルの予測値を元に、観測値との統計関係を求めて、数値予報モデルの予測値を大幅に修正した資料を作成し、予報作業に利用する必要があった。

近年、数値予報モデルの予測精度の向上のおかげで、観測データが比較的少ない海上や上空でも面的または立体的な予測情報を実用的な精度で提供する新しいプロダクトを作成できるようになりつつある。今後さらに数値予報モデルの高解像度化が進み、高解像度のアドバンテージを生かした物理過程の開発が進むことにより、数値予報モデルのさらなる予測精度の向上とこれを生かしたガイダンスの充実が期待される。

## 参考文献

- 井藤智史, 2018a: 着氷指数. 数値予報課報告・別冊第 64 号, 気象庁予報部, 219-225.
- 井藤智史, 2018b: 積乱雲量・雲頂高度. 数値予報課報告・別冊第 64 号, 気象庁予報部, 226-232.
- 気象庁予報部, 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, 248pp.
- 工藤淳, 2018a: 線形重回帰. 数値予報課報告・別冊第 64 号, 気象庁予報部, 35-42.
- 工藤淳, 2018b: ロジスティック回帰. 数値予報課報告・別冊第 64 号, 気象庁予報部, 43-47.
- 工藤淳, 2018c: ニューラルネットワーク. 数値予報課報告・別冊第 64 号, 気象庁予報部, 48-61.
- 工藤淳, 2018d: カルマンフィルタ. 数値予報課報告・別

冊第 64 号, 気象庁予報部, 62-74.

工藤淳, 2018e: 乱気流指数. 数値予報課報告・別冊第 64 号, 気象庁予報部, 204-218.

後藤尚親, 2018: 雲ガイダンス. 数値予報課報告・別冊第 64 号, 気象庁予報部, 197-203.

三戸洋介, 2018: 気温ガイダンス. 数値予報課報告・別冊第 64 号, 気象庁予報部, 132-143.

白山洋平, 2018: 降水ガイダンス. 数値予報課報告・別冊第 64 号, 気象庁予報部, 95-118.

土田尚侑, 2018: 降雪ガイダンス. 数値予報課報告・別冊第 64 号, 気象庁予報部, 119-131.

宮内誠二, 白崎初未, 前鹿川勇明, 佐野浩, 2008: 航空交通気象時系列予想の活用に向けて. 航空気象ノート第 67・68 号, 気象庁航空気象管理官, 12-47.

Showalter, A. K., 1953: A Stability Index for Thunderstorm Forecasting. *Bull. Amer. Meteor. Soc.*, **34**, 250-252.