

# 記憶ベース推論と経験的分類を利用した天気予測の検討 Consideration of Weather Forecasts Applying Memory-Based Reasoning and Empirical Classification

情報工学専攻 19N8100009I 瀧川綾乃

**要約:** 天気予報の作成時に利用するガイダンスとは、統計的手法をもちいて数値予報モデルの誤差を修正し、天気、最高/最低気温などの予報項目へ翻訳する作業を指す。本稿では、そのガイダンスを作成する新手法として記憶ベース推論をもちいた方法を検討した結果を述べる。既存研究に加え、経験的分類をもちいた事例の選択的記憶と気象項目値への予測対象の拡張をおこなった。記憶ベース推論をもちいた天気予測では、既存のガイダンス作成手法の課題であった訓練データに含まれない顕著現象に対して予測式が未対応である点や、不適切な係数変化による予測の不安定性などの課題を回避できることに加え、改良によって、継続的なシステムの稼働を想定した記憶容量の削減と処理の高速化を実現した。また、これまで研究されていた“晴れ”、“曇り”、“雨”などの天気の予測以外における、気象項目値の予測結果について述べる。

**キーワード:** 天気予測, ガイダンス, AR モデル, 経験的分類, 記憶ベース推論

## 1 はじめに

天気予報には数値予報モデルをもちいて予測した値を天気、最高気温、雨量などの予報要素に変換する作業が必要であり、これをガイダンスという。現行のガイダンス作成手法は事前学習型と逐次学習型の大きく二つに分類でき、2020年現在では予測する気象項目によって使い分けられている。事前学習型は過去数年分のデータを利用し一括して学習するガイダンス作成手法であり、主に発雷確率や降水量などの予測に利用されている。課題として、数値モデルの更新に際する再学習にかかる時間や訓練データに含まれない顕著現象に予測式が対応していないなどの点がある。逐次学習型は現在の天気状況を加味して予測式の係数を変更する学習方法であり、降雪量、風、気温などの予測に利用されている。課題として予報官が扱いにくい点や大雨などの顕著な天気の発生時に係数が不適切に変化する場合がある。

これらの課題を解決する新しいガイダンス作成手法として、毛利ら [1] の開発した天気予測システム WINDOM がある。WINDOM は記憶ベース推論をもちいたガイダンス作成手法である。事前に記憶した事例から検証事例にもっとも類似した事例を予測としてもちいる推論方式であり、関東甲信越以西のアメダス 960 点、有人観測所 120 点で観測された 1982 年から 1990 年の 9 年分のデータを利用し、現在の天気状況にもっとも近い 20 事例から 6 時間後の天気を予測として出力する。WINDOM では 15 区分の天気を予測したのち、その天気を 2 区分に再分類することによって降水の有無を予測する。記憶ベース推論をもち

いた天気予測手法には、前述したガイダンス作成方式に比べ二つの優位点がある。第一に、数値予報モデルの変更に対応可能な点である。記憶ベース推論では予測に数値予報モデルの値を使用しないため、モデル変更の度に予測式を変更する必要がない。

第二に、不適切な予測式の係数変化を回避できる点である。実測値を加味した逐次学習型の予測では夕立や台風などの顕著現象が発生したとき、それに対応した予測式を作成してしまい、そのあとの予測が大きく外れるという課題をもつ。記憶ベース推論では、実測値にもっとも類似した過去の顕著現象をもちいて予測をおこなうため、この課題を回避できる。WINDOM はこれらを並列型計算機 AP1000 に実装し、正答率は 1992 年現在で気象庁の公開する予測の正確度と同等の 86% を記録しており、新しい天気予測手法として有用であるといえる。

本研究は、毛利らの研究を二つの観点から増強する。まず、入力した気象データの一部を選択して記憶する。入力した全ての事例を記憶する WINDOM に対し、本研究では事例を選択して記憶し、記憶にない天気状況が発生したときにはその事例を新規に記憶する。事例の選択には記憶ベース推論をもちいて事例の属するクラスを予測するアルゴリズム (経験的分類) をもちいる。これによって、記憶容量の削減と処理の高速化が期待できる。

次に、気象項目値を予測する点について述べる。WINDOM では各事例の気象項目値を離散化しているのに対し、本研究では気温、降水量、風速などの値を連続値のまま記憶し予測に使用する。それによって、これまで記憶ベース推論をもちいて多く研究されていた“晴れ”、“曇り”、“雨”などの天気の分類の予測に対し、気象項目値の予測まで拡張する。気象項目値を保持したまま記憶・類似度を評価することで直感的な天気状況の把握や予報官の予測値の扱いやすさにつながる。また、降水の有無以外のガイダンス作成が期待できる。既存研究との違いのまとめを表 1 に示す。

表 1 既存研究との違い

比較項目	WINDOM	本研究
予測対象	降水の有無	各気象項目値
記憶事例	全て記憶	一部記憶
観測地点	関東甲信越以西の観測地点全て	東京気象台のみ

## 2 利用データ

### 2.1 データの扱いと欠損値の補完

本研究では、気象庁提供の東京において観測されたデータ<sup>\*1</sup>を利用する。データ内に資料不足として欠損した値や該当現象が整数に満たない値を含むとき、気象庁の表記方法<sup>\*2</sup>をもとに、表2の通りに数値に変換する。また、欠損値は気象の時系列連続性を考慮し前後の値から線形補完する。観測中に観測環境の変化はない。

表2 記号と数値の対応

変換前	変換後
///	欠損値として扱う
0+	0.5
10-	9.8
-	0

### 2.2 ラベリング

事例の属性値を利用し、事前に“晴れ”、“曇り”、“雨”のラベリングをおこなう。具体的な分類を表3に記す。

表3 ラベリング方法

気象用語	定義
晴れ	雲量が2以上8以下
雨	降水現象がある状態
曇り	全雲量が9以上かつ、降水現象がない状態。

### 2.3 予測の評価指標

予測値を  $y$ 、実測値を  $x$ 、事例数を  $n$  としたとき、平均絶対誤差 (mean absolute error [MAE]) と二乗平均平方根誤差 (root mean square error [RMSE]) をそれぞれ (2.1), (2.2) と定義する。また、予測値と実測値の差を残差とよぶ。

$$\text{MAE} = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (2.1)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}} \quad (2.2)$$

## 3 記憶ベース推論をもちいた予測

### 3.1 学習アルゴリズム

学習アルゴリズムは IB3(instance based learning algorithm 3) とユークリッド距離をもちいる。IB3 とは Aha[2] が提示した一連の事例ベース推論の学習ア

ルゴリズムの一つであり、以下に示す。記憶のために選択された事例を CD(Concept Description) といい、代表値集合とよぶ。事例の精度の下限がクラスの頻度の上限よりも (90 % の信頼水準で) 統計的に有意に高いとき、その事例は *acceptable* とされる。同様に精度の上限が統計的に高いときは事例は  $S$  から削除される。そのクラスの頻度の (70 % の信頼水準で) 下限よりも低いとき他の事例は学習中は  $S$  に保持され、許容できることが証明されないときは最後に削除する。信頼区間の上限と下限の式は (3.1) に示す。

$$\frac{p + \frac{z^2}{2n} \pm z\sqrt{\frac{p(1-p)}{n} + \frac{z^2}{4n^2}}}{1 + \frac{z^2}{n}} \quad (3.1)$$

分類後の事例集合  $S$  に対し事例の精度について、 $n$  は事例が  $S$  に導入されてからの分類試行の回数、 $p$  はその分類精度 (事例のクラスが  $t$  のクラスと一致した回数を  $n$  で除算した値)、 $z$  は信頼度 (受け入れるときは 0.9, 削除するときは 0.7) である。クラスの頻度において、 $p$  は、これまでにこのクラスに属する事例の割合、 $n$  は以前に処理された事例数、 $z$  は信頼度 (受け入

---

#### Algorithm 1 IB3 Algorithm (CD: Concept Description)

---

```
1:  $CD \leftarrow \phi$ 
2: for  $x$  in Training Set do
3:   for  $y \in CD$  do
4:      $\text{sim}[y] \leftarrow \text{similarity}(x, y)$ 
5:   end for
6:   if  $\exists \{y \in CD \mid \text{acceptable}(y)\}$  then
7:      $y_{\max} \leftarrow$  some acceptable  $y \in CD$  with maximal  $\text{sim}[y]$ 
8:   else
9:      $i \leftarrow$  a randomly selected value in  $[1, |CD|]$ 
10:     $y_{\max} \leftarrow$  some  $y \in CD$  that is the  $i$ -th most similar instance to  $x$ 
11:   end if
12:   if  $\text{class}(x) = \text{class}(y_{\max})$  then
13:     classification  $\leftarrow$  correct
14:   else
15:     classification  $\leftarrow$  incorrect
16:      $CD \cup \{x\}$ 
17:   end if
18:   for  $y$  in  $CD$  do
19:     if  $\text{sim}[y] \geq \text{sim}[y_{\max}]$  then
20:       update  $y$ 's classification record
21:       if  $y$ 's record is significantly poor then
22:          $CD \leftarrow CD - \{y\}$ 
23:       end if
24:     end if
25:   end for
26: end for
```

---

<sup>\*1</sup> 気象庁 | 過去のデータ/ダウンロード: <https://www.data.jma.go.jp/gmd/risk/obsdl/> (2019/11/1 ダウンロード)

<sup>\*2</sup> 気象庁 | 値欄の記号の説明: <https://www.data.jma.go.jp/obd/stats/data/mdrr/man/remark.html> (2020/12/18 アクセス)

れるときは 0.9, 削除するときは 0.7) である.

### 3.2 類似度

事例  $x, y$  の類似度  $s(x, y)$  は (3.2), (3.3) のとおりにもとめる. 予備実験の結果, 類似度の計算に利用する属性と重みを表 4 に示す.

$$s(x, y) = -D(x, y) \quad (3.2)$$

$$D(x, y) = \sqrt{\frac{1}{m} \sum_{i=1}^m w_i (x_i - y_i)^2} \quad (3.3)$$

表 4 各属性の重み

属性	降水	日照	雲量	蒸気圧	相対湿度
$w_i$	0.89	0.087	0.021	0.0014	0.0002

### 3.3 予測事例の扱い

既存研究では, 検証事例にもっとも近い事例の 6 時間後の実測値を予測として出力していた. しかし, 検証事例と記憶した事例が非常に類似していたときでも 6 時間後の天気はカオス状態にあり, 現行の類似度の計算方法では 6 時間後の天気についての類似性を評価出来ていない. 予測として出力する事例の扱いを図 1 に示すとおりに変更して予測する.

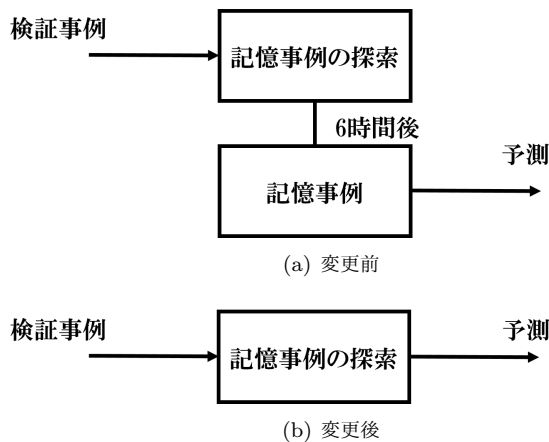


図 1 予測事例の扱い

## 4 結果

### 4.1 評価基準

本研究では記憶ベース推論の予測は以下の基準によって評価する.

1. 正答率  
正しくクラスを予測した事例数を検証事例数で除算した値を正答率として評価する.
2. 学習された表現の簡潔さ  
代表値集合 (CD) の数を代表値の数, 代表値の数を訓練事例数で除算した値を必要記憶容量 (%) として評価する.

表 5 予測結果 (評価値)

評価項目	NN 法	IB3
学習時間 (秒)	0	6809
代表値の数 (個)	-	2378
必要な記憶容量 (%)	100	27.0
正答率 (%)	70.3	69.9
回答時間 (秒)	0.65	0.16

表 6 予測結果 (残差)

属性	MAE	RMSE
降水 (mm)	0.33	1.5
日照 (時間)	0.30	0.50
雲量	1.8	3.0
風速 (m/sec)	1.5	2.0
気温 (°C)	3.6	4.9

### 3. 学習に要する時間

学習時間 (秒) として事例の選択と記憶にかかった時間を評価する.

### 4. 回答の生成に要する時間

一つの事例の予測に必要な回答時間 (秒) として評価する.

### 4.2 予測結果

データは 2014 年から 2018 年の 4 年間を使用する. 1 年分のデータを訓練用, その翌年を検証用とし, 結果は 4 年分の予測の平均値を示す. 予測の評価値の平均を表 5 に示す. NN 法での予測の正答率をほぼ維持したまま, 必要な記憶容量を 30% まで削減している. このことから, 経験的分類をもちいて予測に必要な事例を選択して記憶できているといえる. また, 属性ごとの残差を表 6 に示す. 降水と日照の RMSE はそれぞれ 1.5, 0.50 であるのに対し, 気温, 風速の RMSE は 4.9 と 2.0 と大きい. これは, 類似度の計算にもちいた属性の選択や属性の重みづけによるものと考えられ, 類似度の計算に含まれない属性や小さい重みの残差は大きくなる傾向がある.

### 4.3 データ量の増加に伴う回答の変動

本システムを天気予測システムとして継続的に利用する場合, 数年以上稼働したときにも正答率の低下や必要な記憶容量の爆発的増加が発生しないことが必要である. 最大 2 年分の訓練事例を与えたときの正答率と代表値集合の変化を調査した. 1 年間の総事例数は約 8700 事例である.

訓練データの事例数と正答率, 代表値集合の事例数の関係をそれぞれ図 2, 図 3 に示す. 図 2 から, 代表値集合の事例数の増加率が変化していることがわかる. 約 8700 事例以下を訓練データとして与えたとき, 代表値集合は比例して増加しており, 8700 事例以上の訓練データを与えたとき, それ以下の訓練データを与えたときよりも増加率は減少している. このことから, 記憶ベース推論における訓練データには最低 1 年分のデータ量が必要であり, 訓練データを増加させても予測に必要な事例を選択して記憶できていると考え

られる。

また、図3から約8700事例以下を訓練データとして与えたとき、正答率は指数関数的に増加している一方で、8700事例以上の訓練データを与えたとき正答率は70%程度で一定である。これらのことから、予測に必要な事例を選択して記憶できおり訓練データを増やさせても予測の正確度は低下しないといえる。

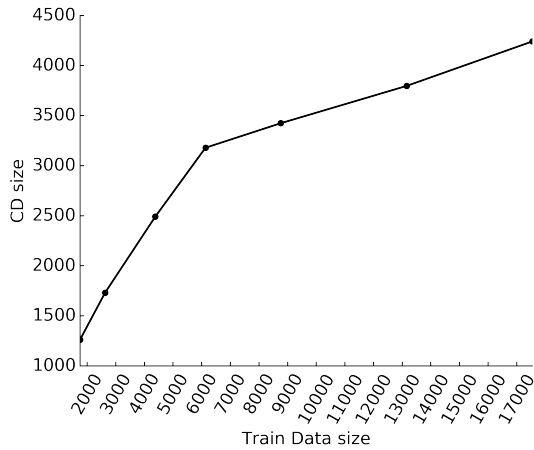


図2 データ量と代表値集合の関係




図3 データ量と正答率の関係

#### 4.4 降水の有無の予測比較

降水の有無を予測し既存研究と比較した結果について述べる。既存研究と同様に、予測した6時間後の天気を降水の発生の有無の2区分に再分類をおこない、予測する。“晴れ”、“曇り”は降水なし、“雨”は降水ありに分類した。既存研究の結果との比較を表7に示す。

既存研究の正答率に対し、記憶する事例を削減しても正答率は低下していない。予測に必要な事例のみを記憶し、その他の事例は削減できていると考えられる。また、記憶する事例を削減することによって予測の高速化も実現できている。

#### 5 おわりに

本研究では、記憶ベース推論をもちいた天気予測手法の検討結果を述べた。経験的分類をもちいた記憶事

表7 予測評価: 降水の有無の予測比較

評価項目	既存研究	本研究
学習時間 (秒)	0	6809
必要な記憶容量 (%)	100	27.0
正答率 (%)	86	90
回答時間 (秒)	3.8	0.16

例の選択と気象項目値の予測の二点について既存研究に改良を加え、次の三点を達成した。第一に、6時間後の天気(“晴れ”、“曇り”、“雨”)を予測したとき、70%の正答率と30%の記憶容量を実現できた。第二に、降水の有無の予測では既存研究と同等の正答率を維持したまま、記憶容量を30%に削減し、処理の高速化を実現できた。第三に、訓練データを増加させたときの正答率の維持を確認し、記憶ベース推論をもちいた手法の継続的な天気予測システムとしての有効性を示した。

今後の課題として風速や気温の予測正確度の向上、大規模な予測検証が挙げられる。これは、類似度の計算にもちいる属性の選択や重みづけによるものと考えられ、風速・風向・気温の要素を考慮したラベリングの開発や類似度の算出方法の改良[4],[5]によって改善が期待できる。また、気象予測システムとして利用するためには、様々な地域の天気を数年以上継続的予測することが想定される。東京以外の地域での予測や数年間稼働した際の正答率や記憶容量の変化の検証は今後の課題とする。

#### 参考文献

- [1] T.Mouri, M.Nakamura, H.Tanaka, “Weather-Forecasting Using Memory-Based Reasoning”, *Machine Intelligence and Pattern Recognition*, Vol. 15, pp. 185-197, 1994.
- [2] Aha W. David, “Tolerating noisy, irrelevant and novel attributes in instance-based learning algorithms”, *International Journal of Man-Machine Studies*, vol. 36, Issue 2, pp. 267-287, Feb. 1992.
- [3] K.Nakamura, S.Kobayashi, “An Interactive Case-Based Reasoning Model and Its Application to Supporting Machine Adjustment”, *Journal of the Japanese Society for Artificial Intelligence*, Vol.4, No.6, Nov. 1989, (in Japanese)
- [4] H. Lu, W. Wang and F. Zheng, “A case-based reasoning approach to local-scale and short-term weather forecast”, *2012 IEEE International Conference on Computer Science and Automation Engineering (CSAE)*, Zhangjiajie, 2012, pp. 228-231.
- [5] Bjarne K.H, Denis R., “Weather Prediction Using Case-Based Reasoning and Fuzzy Set Theory”, *Weather Prediction Using Case-Based Reasoning and Fuzzy Set Theory 2000*, 2001.