

## 記憶に基づく推論法における事例獲得と特徴重み付けの自己組織化

松居 辰則 岡本 敏雄

電気通信大学大学院 情報システム学研究所

記憶に基づく推論法 (Memory-Based Reasoning : MBR) はルールを用いず、事例をそのままの形式で保持することで知識ベースを構築する。そのため知識獲得のボトルネック解消の一手法として注目されている。MBR では、事例間の類似度の定義、具体的には特徴重み付け手法が大きな意味をもつため、扱う対象領域に依存してさまざまな特徴重み付け手法が提案されている。しかしながら、従来の MBR では事例獲得や特徴重みの更新は一切行われない。そこで、本研究では検索結果に対する評価に基づく事例獲得と特徴重みを自己組織的に最適化するメカニズムを実装した MBR を提案する。

### Knowledge-Acquisition and Self-Organization of Feature Importance of Memory-Based Reasoning

Tatsunori MATSUI & Toshio OKAMOTO

Graduate School of Information Systems, The University of Electro-Communications

Memory-Based Reasoning (MBR) is a reasoning method for classification problem, in MBR knowledge base is constructed without rules for reasoning, only by keeping many cases represented by original vector form of features. In MBR, the weighting methods for features and its metric definition for similarity degree are important to get high accuracy. However in original MBR, as a main feature of MBR, knowledge acquisition and update of feature importance are never launched. In this study, knowledge acquisition method based on evaluation for output results of MBR and self-organized optimization method of feature importance of MBR are proposed.

#### 1. はじめに

エキスパートシステムや知的教育システムを構築する場合、知識ベースの作成に多大なコストが必要であるという、知識獲得のボトルネック問題が存在する。専門家の知識をルール形式で抽出・記述ことは長時間の専門家との対話が必要であるなど方法論の観点からも困難な問題である。また、抽出されたルール群が無矛盾であることに対する保証もない。現在、この知識獲得のボトルネックの解消を目的としたさまざまな研究が活発に行われている。

記憶に基づく推論法 (Memory-Based Reasoning : MBR) [1][2]はルールを用いず、事例をそのままの形式で保持することで知識ベースを構築する。そのため知識獲得のボトルネックの解消方法の一つとして注目されている。

MBR では、後述するように、事例間の類似度の定義、具体的には特徴重み付け手法が大きな意味をもつ。そのため MBR で扱う対象領域に依存してさまざま

特徴重み付け手法が提案されている。しかしながら、従来の MBR の枠組みでは、所与の事例ベースから特徴重みを算出し、特徴重みを静的に用いることによって事例の検索を実行する。すなわち、検索結果に基づく特徴重みの更新・変更は一切行わない。また、検索結果に基づいて事例獲得も行わない。よって、事例ベース中にない回答を生成する能力はなく、回答カテゴリーが既知の分類問題のみを対象にしている。そこで、本研究では従来の MBR に事例獲得機能と自己組織的な特徴重みの更新機能を実装し、事例ベースにない回答および回答カテゴリーの生成能力、すなわち、知識獲得能力を実装することを考える。

以下、2章では MBR の概要を述べ、3章で MBR への事例獲得機能と自己組織的な特徴重みの更新機能を実装するための理論に関して述べる。

#### 2. 記憶に基づく推論法

ここでは、記憶に基づく推論法 (Memory-Based

Reasoning : MBR) の概要と, MBR における特徴重み付けと類似度算出の具体的手法とその特性に関して述べる.

## 2.1 MBR の概要

従来のエキスパートシステムでは, 通常 if-then 型のルールを蓄えた知識ベースを構築し, ルールを何段にも連鎖させて推論を行う. このようなルールに基づく推論 (Rule-Based Reasoning : RBR) と MBR は, 知識ベースの持ち方が本質的に異なる.

MBR とは, 「知的活動は, ルールではなく過去の経験的記憶を中心にして行われる」という仮説に基づく推論モデルであり, 幾つの特徴から構成される問題部と回答部 (回答カテゴリ) から成る. そして, 大量の訓練事例の中から質問事例 (テスト事例) に類似した事例を探索し, 「類似している問題であれば回答は同じになる」との仮定のもとに推論を実行する. つまり, MBR では事例 (問題と回答のペア) を大量に事例ベースに蓄えておき, 新たな質問には, 事例ベース内から最も類似した事例を検索し, その類似事例の回答をそのまま質問の回答とするのが基本的な考え方である. このメカニズムのイメージを図 1 に示す.

このように MBR では, データベースを直接利用して推論を行うために, エキスパートから知識を抽出する必要はない. そのため, 知識獲得が容易・知識の追加, 削除が容易・回答の説明が容易・システムの構築が短期間で行える, のような特徴をもつ.

MBR はこれまでに英単語の発音問題[1], 機械翻訳[3], 米国国勢調査の職業欄の分類[4], 天気予測[5]などに応用されている. MBR は RBR を大幅に簡略化した枠組みであると考えられる. RBR が述語論理の枠組みでのルールだとすれば, MBR の保持する事例は命題論理の範疇でのルールであると考えられる. すなわち, RBR ではルールに変数が存在するのに対して, MBR でのルールには変数が存在しない. また, ルールが多重連鎖的に連結されることはなく, 1 段しか適用されない.

MBR と類似した枠組みとして, 事例に基づく推論 (Case-Based Reasoning : CBR) [6]がある. MBR と CBR とは, 事例をもとに推論を行う点では同じであるが, CBR では得られた類似事例の回答を質問に適合するように修正を行い, 診断・修復のプロセスを通して知識獲得を行う. これに対して, MBR では修正・修復は一切行わない. CBR では事例修正のおかげで典型的な事例のみを事例ベースに保持すればよいが, その反面事例の修正のためのルールが必要となり, やはり知識獲得のボトルネック問題が存在する. MBR では, 事例の修正は一切行わず, 事例ベース中の類似事例の回答部分をそのまま質問に対する回答とする. 事例の修正の知識は不要であるが, その分事例を大量に準備する必要がある. また, 事例ベース中にない回答を生成する能力はなく, 回答カテゴリが既知の分類問題のみを対象にしている点が特徴である.

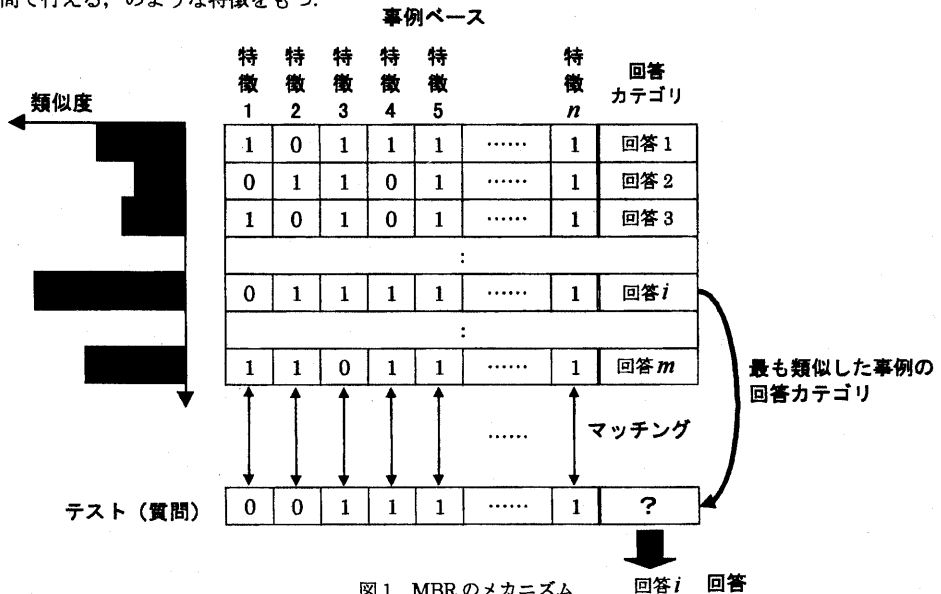


図 1 MBR のメカニズム

## 2.2 特徴の重み付け手法

MBR ではマッチングのみによって推論を行うため、類似度の決定方法が回答に大きな影響を与える。この特徴の重み付け手法としては、条件付き確率をもとにした手法など様々な手法が提案されており、その特性が多変量解析との比較結果として考察されている[7]。MBR での類似度の計算では、人間がその領域の専門知識を考慮して、類似度の計算式や計算に用いる特徴の重み値を決定する方法もよく用いられるが、条件付き確率をもとにした方法は、対象領域の専門知識を必要としない汎用な方法である。条件付き確率をもとにした特徴重み付け手法として次ようなものが提案されている。

- PCF (*Per-Category Feature Importance*)
- PFC (*Per-Feature Category Importance*)
- ACF (*Averaged Category Feature Importance*)
- CCF (*Cross-Category Feature Importance*)

$$w(a,c) = w(a) = \sum_{c=1}^N P(c|a)^2$$

ただし、 $c$  : 訓練事例の属する回答カテゴリ、 $a$  : 事例の特徴、 $N_c$  : 回答カテゴリの数、としている。特に、CCF の物理的意味を述べる。特徴が決定した際の回答カテゴリの存在確率を全回答カテゴリに対して 2 乗和をとり平均化したものであり、回答カテゴリによらず同じ値をとる。よって、「事例検索において出現頻度の小さい特徴のもつ情報は大きくある」との主張を強く反映した重み値であると考えられる。

## 2.3 事例間の類似度の算出方法

事例間の類似度の算出方法としては、以下の 3 種類が代表的である。

- SUM (Summation Metric)

$$\text{Similarity}(u,v) = \sum w(a_i, c_u) f(u_i, v_i)$$

- MAX (Maximize Metric)

$$\text{Similarity}(u,v) = \text{Max}(w(a_i, c_u) f(u_i, v_i))$$

- ERROR (Error Minimize Metric)

$$\text{Similarity}(u,v) = 1 - \prod (1 - w(a_i, c_u) f(u_i, v_i))$$

ただし、 $u$  : 訓練事例、 $v$  : テスト事例 (質問事例)、 $a_i$  :  $i$  番目の特徴、 $c_u$  : 訓練事例  $u$  の属するカテゴリ、 $u_i = \{0,1\}$  : 訓練事例  $u$  の特徴  $a_i$  に対する値、 $v_i = \{0,1\}$  : テスト事例  $v$  の特徴  $a_i$  に対する値、としている。なお、

$$f(x,y) = \begin{cases} 1 & (\text{if } x=y) \\ 0 & (\text{others}) \end{cases}$$

である。

## 3. 事例獲得と特徴重みの自己組織化

従来の MBR の枠組みでは、所与の事例ベースから特徴重みを算出し、特徴重みを静的に用いることによって事例の検索を実行する。すなわち、検索結果に基づく特徴重みの更新は一切行わない。また、検索結果に基づいて事例獲得も行わない。よって、事例ベース中にない回答を生成する能力はなく、回答カテゴリが既知の分類問題のみを対象にしている。そこで、本研究では従来の MBR に事例獲得機能と自己組織的な特徴重みの更新機能を実装し、事例ベースにない回答および回答カテゴリの生成能力、すなわち、MBR に知識獲得能力を実装する。

### 3.1 MBR の定式化

以下の議論のために MBR の処理系の定式化を行う。ここでは、一般に、事例ベース内には  $n$  個の事例が保持されており、各事例は  $m$  個の特徴 (問題部) と 1 個の回答部 (回答カテゴリ) のペアで表現されているものとする。そして、事例検索の局面では、検索条件として問題部に対応する  $m$  個の特徴を入力し、事例ベース内の最も類似した事例の回答部を出力として得るものとする。

#### (1) 事例ベースの表現

$i$  番目の事例  $c_i$  を  $(m+1)$  次元のベクトル  $c_i = (x_i, y_i)$  ( $1 \leq i \leq n$ )、事例ベースを  $C = \{c_1, c_2, \dots, c_n\}$  で表す。

ここで、 $x_i$  は問題部を表す  $m$  次元ベクトル  $x_i = (x'_1, x'_2, \dots, x'_m)$ 、 $y_i$  は回答部に存在する回答カテゴリに 1 対 1 対応した 1 次元の実変数である。ただし、 $x'_j \in \mathbf{B}$  ( $1 \leq j \leq m$ )、 $y_i \in \mathbf{R}^1$ 、 $c_i \in \mathbf{B}^{m+1}$  ( $\mathbf{B} = \{0,1\}$ )、 $\mathbf{R}$  は実数) である。

#### (2) 入力 (検索条件) の表現

$l$  番目の入力  $q_l$  を  $m$  次元ベクトル  $q_l = (q'_1, q'_2, \dots, q'_m)$ 、 $l \in \mathbf{N}$  ( $\mathbf{N}$  は自然数) で表す。

#### (3) 特徴重みと類似度の算出

特徴重みを  $m$  次元ベクトル  $w = (w_1, w_2, \dots, w_m)$  で表し、入力  $q_l$  と事例  $c_i$  との類似度を SUM を用いて、

$$s(\mathbf{q}_l, \mathbf{c}_l) = \sum_{j=1}^m w_j \cdot f(q'_j, x'_j)$$

で算出する。

#### (4) 出力 (回答) の表現

$s(\mathbf{q}_l, \mathbf{c}_l)$  の中で既定値以上を満足する事例の集合を  $S_l$  とする。このもとで、 $l$  番目の入力  $\mathbf{q}_l$  に対する出力  $\mathbf{a}_l$  を、

$$l = \arg \max_{\mathbf{c}_l \in S_l} s(\mathbf{q}_l, \mathbf{c}_l)$$

なる  $l$  を用いて 1 次元ベクトル  $\mathbf{a}_l = (y_l)$  で表す。ただし、 $\arg \max$  は最大値を与える添字を返す関数である。

以上、(1)~(4)により、MBR の処理系は、 $(m+1)$ 次元ベクトル空間  $\mathbf{C}$  の部分空間  $\mathbf{B}^m$ 、 $\mathbf{R}^1$  に関して、

$$\mathbf{a}_l = F(\mathbf{q}_l), \quad l = \arg \max_{1 \leq l \leq n} s(\mathbf{q}_l, \mathbf{c}_l)$$

なる関数  $F: \mathbf{B}^m \rightarrow \mathbf{R}^1$  で表すことができる。

### 3.2 事例獲得機能

次に本研究で実装する MBR における事例獲得に関して述べる。本研究における MBR では、出力結果 (類似事例の回答部) に対する評価結果に基づき、入力 (検索条件、すなわち問題部) と出力を結合し、新規事例として獲得することにより事例獲得を行う。事例獲得は「出力 (回答部) に対する評価が高く、かつ入力 (問題部) が事例ベース内の既存の事例の問題部との距離が大きい場合には新規事例としての価値が高い事例として獲得する」というスタンスで実行する。以下、事例獲得の手順に関して述べる。

- 1) 事例ベースの初期状態  $\mathbf{C}$  を構成し、特徴重みの初期値  $\mathbf{w}$  を CCF を用いて算出する。
- 2) 3) から 6) を繰り返して実行する。この過程を事例獲得の回数 1 と数える。
- 3)  $l$  番目の検索実行時の事例ベースを  $\mathbf{C}_l$ 、特徴重みを  $\mathbf{w}_l$  とする。検索条件として問題部  $\mathbf{q}_l$  の入力し、回答  $\mathbf{a}_l$  を出力する。
- 4) 回答  $\mathbf{a}_l$  に対する評価を行い、評価結果を  $E(\mathbf{a}_l)$  とする。評価関数  $E$  は、回答に対する満足度が高いほど高い値を返し、 $0 \leq E(\mathbf{a}_l) \leq 1, \forall l \in \mathbf{N}$  を満足するよう設定する。この下で、定数  $\varepsilon$  ( $0 < \varepsilon < 1$ ) に対して、 $E(\mathbf{a}_l) \geq \varepsilon$  を満足するとき、「回答  $\mathbf{a}_l$  に対する評価は高い」と判断する。
- (5)  $E(\mathbf{a}_l) \geq \varepsilon$  の場合、すなわち、回答  $\mathbf{a}_l$  に対する評価  $E(\mathbf{a}_l)$  が高い場合、入力  $\mathbf{q}_l$  と出力  $\mathbf{a}_l$  を結合し、新

規事例  $\mathbf{c}' = (\mathbf{q}_l, \mathbf{a}_l)$  を生成する。

- (6) 新規事例  $\mathbf{c}'$  の問題部  $\mathbf{q}_l$  と類似事例集合  $S_l$  に含まれる事例群の問題部  $x_i$  ( $1 \leq i \leq n'$ ) との平均的距離を次式で算出する。

$$D(\mathbf{c}', S_l) = \frac{1}{\#|S_l|} \sum_{\mathbf{c}_i \in S_l} \|\mathbf{c}' - \mathbf{c}_i\| \quad \left( = \frac{1}{\#|S_l|} \sum_{\mathbf{c}_i \in S_l} \|q'_j - c_{ij}\| \right)$$

ここで、 $\#|S_l|$  は集合  $S_l$  の要素数である。この値が既定値よりも大きい場合には、新規事例  $\mathbf{c}'$  を事例ベースに追加し、事例ベース  $\mathbf{C}_{l+1}$  を再構成する。ただし、 $\|\mathbf{c}' - \mathbf{c}_i\|$  は  $\mathbf{c}'$  と  $\mathbf{c}_i$  とのユークリッドの距離、すなわち、

$$\|\mathbf{c}' - \mathbf{c}_i\| = \sqrt{\sum_{j=1}^m (x'_j - x_{ij})^2} \quad \left( = \sqrt{\sum_{j=1}^m (q'_j - x_{ij})^2} \right)$$

である。

### 3.3 特徴重みの自己組織化機能

本研究における MBR では、事例獲得とともに、出力結果に対する評価に基づき特徴重みの更新を行い、検索回数に伴って自己組織的に特徴重みの最適化を行うことを実現する。ここで、事例検索における入力の問題部の中で、選択されている特徴群に対する最大の重みをもつ特徴を検索結果に対する要因特徴と命名する。すなわち、事例ベース  $\mathbf{C}_l$  において、 $\mathbf{q}_l$  を入力し、 $\mathbf{a}_l$  を出力として得た場合の要因特徴  $w'_k$  とは、

$$\mathbf{a}_l = F(\mathbf{q}_l), \quad l = \arg \max_{1 \leq l \leq n} s(\mathbf{q}_l, \mathbf{c}_l) \text{ における } w'_k, \quad k = \arg \max_{1 \leq j \leq m} w_j$$

である。このもとで、特徴重みの自己組織化は次のようなスタンスで実現する。

- ・出力の評価値が高い場合には、前述 (3.2) の手順で事例獲得を行い、さらに特徴重みの更新を行う。この場合の更新は、「要因特徴とその近傍特徴の重みを増加させる」。
  - ・出力に対する評価が低い場合には、事例獲得を行わず、特徴重みの更新のみを行う。この場合の更新は、「要因特徴とその近傍の特徴の重みを減少させる」。
- いずれの場合も、要因特徴の近傍特徴を要因特徴との相関関係で定義し (後述)、要因特徴に対する更新は相関関係の強弱によって近傍特徴群へ伝播する。以下、特徴重みの自己組織化の流れに関して述べる。

- 1) 事例ベースの初期状態  $\mathbf{C}$  を構成し、特徴重みの初期値  $\mathbf{w}$  を算出する。

2) 3)から6)を繰り返して実行する。この過程を特徴重みの更新回数1と数える。

3)  $l$  番目の検索実行時の事例ベースを  $C_l$ , 特徴重みを  $w_l = \{w'_1, w'_2, \dots, w'_m\}$  とする。検索条件としての問題部  $q_l$  の入力し, 回答  $a_l$  を出力する。

4) 回答  $a_l$  に対する評価結果を  $E(a_l)$  を得る。

$E(a_l) \geq \varepsilon$  を満足する場合には5)へ, 満足しない場合には6)へ。

(5)  $E(a_l) \geq \varepsilon$  の場合, 3.2の手順に従い, 事例獲得を実行する。

(5-1) 要因特徴  $w'_p$  ( $1 \leq p \leq m$ ) を検出する。すなわち,

$$a_l = F(q_l), \quad l = \arg \max_{1 \leq l \leq n} (q_l, c_l) \text{ における}$$

$$w'_p, \quad p = \arg \max_{1 \leq j \leq m} w'_j$$

となる特徴重み  $w'_p$  を求める。

(5-2) 要因特徴と近傍特徴の重みが増加するよう,

$$w_q^{l+1} = w'_q + \delta h_{pq} |kw'_p - w'_q|$$

により更新する。ただし,  $\delta$  は  $0 < \delta < 1$  を満足する正の定数,  $k$  は  $k \geq 1$  の定数である。また,  $h_{pq}$  は  $p$  番目の特徴と  $q$  番目の特徴との距離によって決定する近傍関数である。ここでは, 近傍関数  $h_{pq}$  として次のようなガウス関数を用いる。

$$h_{pq} = \exp\left(-\frac{1-r_{pq}}{\sigma^2}\right)$$

ここで,  $r_{pq}$  は  $p$  番目と  $q$  番目の特徴間の相関係数で,  $\sigma^2$  は調整用のパラメータである。この  $h_{pq}$  は  $r_{pq} = 1$ , すなわち, 要因特徴自身または要因特徴との相関が極めて強い特徴間で最大値1をとり, 要因特徴と特徴との相関が弱まるにつれて値が減少する。 $\delta$  と  $\sigma^2$  は自己組織化の途中で減少させ, 自己組織化の過程で特徴重みが振動的に振る舞うのを抑止する。また,  $k$  は特徴重みの更新の幅を調整するパラメータであり, 自己組織化の変動範囲を調整することができる。

(5-3) 事例獲得によって再構成された事例ベース  $C_{l+1}$  において, CCF によって算出された特徴重み  $w'_{l+1}$  と, (5-2) で更新された特徴重みを  $w_{l+1}$  を,

$$\lambda w_{l+1} + (1-\lambda)w'_{l+1} \quad (\lambda \text{ は, } 0 \leq \lambda \leq 1 \text{ の定数})$$

で合成して, 事例ベース  $C_{l+1}$  の特徴重みとする。

(6)  $E(a_l) < \varepsilon$  の場合, 事例獲得は行わない。記号の意味は(5)と同じである。

(6-1) 要因特徴  $w'_p$  ( $1 \leq p \leq m$ ) を検出する。

(6-2) 要因特徴と近傍特徴の重みが増加するよう,

$$w_q^{l+1} = w'_q - \delta h_{pq} |kw'_p - w'_q|$$

により更新し事例ベース  $C_{l+1}$  の特徴重みとする。

(7) 特徴重みを  $w_{l+1} = \{w'^{l+1}_1, w'^{l+1}_2, \dots, w'^{l+1}_m\}$  として, 事例ベース  $C_{l+1}$  を再構成する。

(5-3)では, (5-2)で更新された特徴重み  $w_{l+1}$  をそのまま事例ベース  $C_{l+1}$  の特徴重みとするのではなく, 事例獲得によって再構成された事例ベース  $C_{l+1}$  に対して CCF によって算出された特徴重み  $w'_{l+1}$  と合成することによって事例ベース  $C_{l+1}$  の特徴重みとしている。その理由は次の通りである。(5-2)による特徴重みの更新は, 更新前の特徴重みの構造に基づいて更新するものである。よって, 事例獲得によって追加された新規事例は要因特徴の検出に用いられるだけであり, 新規事例の構造が事例ベースの構造に反映されることはない。したがって, (5-2)による更新だけでは特徴重みの自己組織化の進行にかかわらず, 事例ベースの構造は初期状態の構造に強く依存することになる。そこで, 事例獲得によって追加された新規事例も含めて CCF によって算出された特徴重みを合成することによって, 新規事例の構造を事例ベースの構造に反映させることが可能となる。

### 3.4 実装結果

従来の MBR に事例獲得機能と特徴重みの自己組織的な更新機能を実装した結果, 検索回数の進行に伴い, 検索結果が向上するとの知見を得ている。

## 4. ニューラルネットワークからの考察

3章で述べた特徴重みの自己組織化をニューラルネットワークの競合学習の観点から考察を行う。

### 4.1 コホーネンネット

コホーネンネット[8]は出力教師データを必要とし

ない教師なし学習を行うが、入力データの空間での分布に従い、自律的にネットワークの重みを学習してゆくため自己組織化ネットワークとも呼ばれる。コホーネンネットワークの構成は基本的には2層の多層ニューラルネットワークであるが、出力ニューロン間に近傍関係が定義されていること、学習が教師なし学習を行うという相違点がある。学習は教師データの集合から入力データを1つずつ提示して行われる。ある入力提示されると、その入力に空間での距離が最も近い重みをもつ出力ニューロンが選択される。この出力ニューロンは発火ニューロンとよばれる。発火ニューロンの重みが入力に近づくように変更されるとともに、発火ニューロンの近傍のニューロンも重みが入力に近づくように変更される。このように、複数のニューロンの中から1個のニューロンを選択することにより学習する方法は競合学習とよばれている。このようにして学習されたネットワークでは入力データが集中しているところにニューロンが割り当てられるため、コホーネンネットワークにはデータ圧縮あるいは代表点の選択の機能があるといえる。また近傍関係が近いニューロンの重みは入力空間内でも近い関係を保っており、入力の近傍関係を保つ変換になっている。

#### 4.2 コホーネンネットワークとの比較

MBRにおける入力は検索対象の問題部、出力は類似事例の回答部である。そして、入力データと特徴重みとの合成演算から出力データを求めることから、MBRにおける特徴重みはニューラルネットワークにおけるネットワークの重みとみなすことができる。また、本研究におけるMBRの特徴重みの自己組織化も出力教師データを用いずに行っていることから、教師なし学習として捉えることができる。また、特徴重みの更新は物理的には、更新前の特徴重みを入力データと出力データとの関連をより明確にすることを目的として学習(更新)するため、学習における近傍関係を特徴間の相関性で定義している。よって、本研究でのMBRの自己組織化は、コホーネンネットワークの学習と対応させて議論することができる。このことは、MBRにおける計算量の問題をデータ圧縮の観点から対応可能であることを示唆するものであると考えられる。

#### 5. まとめ

本稿では、従来のMBRの枠組みに事例獲得および、

特徴重みの自己組織化に関する理論を述べた。本手法は、ニューラルネットワークにおける教師無し学習に対応しているため、「事例の修正は一切行わない」というMBRの枠組みを出るものではないと考えられる。

最後に、実装レベルでみた場合、MBRには計算量の大きさに関する問題点が存在し、従来の研究ではアルゴリズムを並列化することによってこの問題を解消している。具体的には、事例数だけの並列度が期待できることから、並列計算機上に実装した場合はプロセッサ台数に比例した並列度が期待でき、並列計算機の性能を十分に引き出すことが可能であるとの報告がある[4][5]。この点に関しては、コホーネンネットワークとデータ圧縮の関連から、計算回数軽減に関する手法が提案できるものとする。また、本稿における事例獲得は、事例の問題部だけの獲得になっており、回答部の獲得はおこなっていない。この点に関しては、回答部を多次元的に表現することによって実現できると考えている。これらに関しては今後の課題とする。

なお、本研究は文部省科学研究費補助金(奨励研究A 課題番号09780148)の援助を受けている。

#### 参考文献

- [1] 北野宏明; 超並列人工知能, 人工知能学会誌, Vol.7, No.2, pp.244-262, 1992.
- [2] Stanfil, C. and Waltz, D. L.; Towards Memory-Based Reasoning, Communications of the ACM, Vol.29, No.12, pp.1213-1228, 1986.
- [3] 佐藤理史; MBT1: 実例に基づく訳語選択, 人工知能学会誌, Vol.6, No.4, pp.592-600, 1991.
- [4] Creecy, R.H., Masand, B. M., Smith, S. J. and Waltz, D. L.; Trading MIPS And Memory for Knowledge Engineering, Communications of the ACM, Vol.35, No.8, pp.48-63, 1992.
- [5] 毛利隆夫, 田中英彦; 記憶に基づく推論による天気予測, 人工知能学会誌, Vol.10, No.5, pp.798-805, 1995.
- [6] 松原仁; 推論技術の観点からみた事例に基づく推論, 人工知能学会誌, Vol.7, No.4, 1992.
- [7] 毛利隆夫, 田中英彦; 記憶に基づく推論と多変量解析との比較, 人工知能学会研究会資料, SIG-KBS-9502-8, pp.56-63, 1995.
- [8] T.コホネン(中谷和夫監訳); 自己組織化と連想記憶, シュプリンガー・フェアラーク東京, 1995.

## 訂正記事

早稲田大学人間科学学術院 松居辰則  
京都情報大学院大学 岡本敏雄

本研究会報告「松居辰則, 岡本敏雄; 記憶に基づく推論法における事例獲得と特徴重み付けの自己組織化, 情報処理学会研究報告, MPS, 数理モデル化と問題解決研究報告, 98(27), pp.19-24, 1998-03-20.」の中に「毛利隆夫, 田中英彦; 記憶に基づく推論による天気予測, 人工知能学会誌, 10(5), pp.798-805, 1995-09-01.」(以下, 本研究会報告の参考文献番号に合わせて文献[5]と記します) からの引用方法が不適切な部分がありましたので, 以下のように訂正をさせていただきます.

本件により, 文献[5]の著者の皆様(毛利隆夫様, 田中英彦様), 本研究会報告を参照してくださった皆様, 情報処理学会関係の皆様にご迷惑をお掛け致しましたことを心よりお詫び申し上げます.

以下, 【修正前】において修正が必要と考えられる該当箇所を示し, 【修正点】において修正の方針を示した上で, 【修正後】に修正後の文面を記させていただきます. 具体的な修正箇所は【修正後】の中に下線で示させていただきます.

### (1) p.19, 左段, 2行目~17行目

#### 【修正前】

エキスパートシステムや知的教育システムを構築する場合, 知識ベースの作成に多大なコストが必要であるという, 知識獲得のボトルネック問題が存在する. 専門家の知識をルール形式で抽出・記述ことは長時間の専門家との対話が必要であるなど方法論の観点からも困難な問題である. また, 抽出されたルール群が無矛盾であることに対する保証もない. 現在, この知識獲得のボトルネックの解消を目的としたさまざまな研究が活発に行われている.

記憶に基づく推論法 (Memory-Based Reasoning : MBR) [1][2]はルールを用いず, 事例をそのままの形式で保持することで知識ベースを構築する. そのため知識獲得のボトルネックの解消方法の一つとして注目されている.

MBR では, 後述するように, 事例間の類似度の定義, 具体的には特徴重み付け手法が大きな意味をもつ.

#### 【修正点】

【修正前】におきましては文献[5]を引用している部分がありました. その部分を明確

にするとともに、文献[5]に限定せず一般論として記述可能な部分は、オリジナルの文面に改めさせていただきました。特に、「エキスパートシステムや知的教育システムを構築する場合、知識ベースの作成に多大なコストが必要であるという、知識獲得のボトルネック問題が存在する。専門家の知識をルール形式で抽出・記述ことは長時間の専門家との対話が必要であるなど方法論の観点からも困難な問題である。また、抽出されたルール群が無矛盾であることに対する保証もない。現在、この知識獲得のボトルネックの解消を目的としたさまざまな研究が活発に行われている。」、「MBR では、後述するように、事例間の類似度の定義、具体的には特徴重み付け手法が大きな意味をもつ。」の部分はオリジナルの文面に改めさせていただきました。

#### 【修正後】

知識獲得のボトルネック問題は、知的教育支援システムなどのエキスパートシステムを構築する上での重要な課題である。すなわち、システムに実環境に即した有意義な振る舞いを実現するためには、システムの扱う対象領域の専門家の有する知識を十分に反映させた知識ベースの構築が必要である。しかし、そのためには長時間にわたる専門家との対話など多くの困難な問題を解決しなければならない。さらに、抽出されたルール群が無矛盾であることに対する保証もない。現在、この知識獲得のボトルネックの解消を目的としたさまざまな研究が活発に行われており、記憶に基づく推論法（Memory-Based Reasoning：MBR）[1][2]はルールを用いず、事例をそのままの形式で保持することで知識ベースを構築する。そのため知識獲得のボトルネックの解消方法の一つとして注目されている[5]。

MBR では、後述するように事例間の類似度の定義や類似度の定義における特徴重み付け手法が重要な課題となる。

(2) p.20, 左段, 4行目～p.20, 右段, 最終行

#### 【修正前】

##### 2.1 MBR の概要

従来のエキスパートシステムでは、通常 if-then 型のルールを蓄えた知識ベースを構築し、ルールを何段にも連鎖させて推論を行う。このようなルールに基づく推論（Rule-Based Reasoning：RBR）と MBR は、知識ベースの持ち方が本質的に異なる。

MBR とは、「知的活動は、ルールではなく過去の経験的記憶を中心にして行われる」という仮説に基づく推論モデルであり、幾つかの特徴から構成される問題部と回答部（回答カテゴリ）から成る。そして、大量の訓練事例の中から質問事例（テスト事例）に類似した事例を探索し、「類似している問題であれば回答は同じになる」との仮定のもとに推論を実行する。つまり、MBR では事例（問題と回答のペア）を大量に事例ベースに蓄えておき、新たな質問には、事例ベース内から最も類似した事例を検索し、その類似事例の



回答をそのまま質問の回答とするのが基本的な考え方である。このメカニズムのイメージを図 1 に示す。

このように MBR では、データベースを直接利用して推論を行うために、エキスパートから知識を抽出する必要はない。そのため、知識獲得が容易・知識の追加、削除が容易・回答の説明が容易・システムの構築が短期間で行える、のような特徴をもつ。

MBR はこれまでに英単語の発音問題[1]，機械翻訳[3]，米国国勢調査の職業欄の分類[4]，天気予測[5]などに応用されている。MBR は RBR を大幅に簡略化した枠組みであると考えることができる。RBR が述語論理の枠組みでのルールだとすれば、MBR の保持する事例は命題論理の範疇でのルールであると考えることができる。すなわち、RBR ではルールに変数が存在するのに対して、MBR でのルールには変数が存在しない。また、ルールが多重連鎖的に連結されることはなく、1 段しか適用されない。

MBR と類似した枠組みとして、事例に基づく推論 (Case-Based Reasoning : CBR) [6]がある。MBR と CBR とは、事例をもとに推論を行う点では同じであるが、CBR では得られた類似事例の回答を質問に適合するように修正を行い、診断・修復のプロセスを通して知識獲得を行う。これに対して、MBR では修正・修復は一切行わない。CBR では事例修正のおかげで典型的な事例のみを事例ベースに保持すればよいが、その反面事例の修正のためのルールが必要となり、やはり知識獲得のボトルネック問題が存在する。MBR では、事例の修正を一切行わず、事例ベース中の類似事例の回答部分をそのまま質問に対する回答とする。事例の修正の知識は不要であるが、その分事例を大量に準備する必要がある。また、事例ベース中に入らない回答を生成する能力はなく、回答カテゴリーが既知の分類問題のみを対象にしている点が特徴である。

#### 【修正点】

【修正前】におきましては多くの部分を文献[5]を引用しておりました。よって、その部分を明確にするるとともに、特に文献[5]からそのまま引用している部分もございましたので、その部分に関しましては「文献[5]からそのまま引用した」ことを明記させていただき、該当の部分につきましては、「」でくくることで明確にさせていただきました。

#### 【修正後】

##### 2.1 MBR の概要

従来のエキスパートシステムでは、通常 if-then 型のルールを蓄えた知識ベースを構築し、ルールを何段にも連鎖させて推論を行う。このようなルールに基づく推論 (Rule-Based Reasoning : RBR) と MBR は、知識ベースの持ち方が本質的に異なる[5]。

MBR とは、「知的活動は、ルールではなく過去の経験的記憶を中心に行われる」という仮説に基づく推論モデルであり、幾つかの特徴から構成される問題部と回答部 (回答カテゴリー) から成る。そして、大量の訓練事例の中から質問事例 (テスト事例) に類似

した事例を探索し、「類似している問題であれば回答は同じになる」との仮定のもとに推論を実行する。つまり、MBR では事例（問題と回答のペア）を大量に事例ベースに蓄えておき、新たな質問には、事例ベース内から最も類似した事例を検索し、その類似事例の回答をそのまま質問の回答とするのが基本的な考え方である。このメカニズムのイメージを図 1 に示す。

文献[5]において MBR は次のように説明されている（一部著者により加筆修正致しました）。

「MBR では、データベースを直接利用して推論を行うために、エキスパートから知識を抽出する必要はない。そのため、知識獲得が容易・知識の追加、削除が容易・回答の説明が容易・システムの構築が短期間で行える、のような特徴をもつ。

MBR はこれまでに英単語の発音問題[1]、機械翻訳[3]、米国国勢調査の職業欄の分類[4]、天気予測[5]などに応用されている。MBR は RBR を大幅に簡略化した枠組みであると考えることができる。RBR が述語論理の枠組みでのルールだとすれば、MBR の保持する事例は命題論理の範疇でのルールであると考えることができる。すなわち、RBR ではルールに変数が存在するのに対して、MBR でのルールには変数が存在しない。また、ルールが多重連鎖的に連結されることはなく、1 段しか適用されない。

MBR と類似した枠組みとして、事例に基づく推論（Case-Based Reasoning : CBR）[6]がある。MBR と CBR とは、事例をもとに推論を行う点では同じであるが、CBR では得られた類似事例の回答を質問に適合するように修正を行い、診断・修復のプロセスを通して知識獲得を行う。これに対して、MBR では修正・修復は一切行わない。CBR では事例修正のおかげで典型的な事例のみを事例ベースに保持すればよいが、その反面事例の修正のためのルールが必要となり、やはり知識獲得のボトルネック問題が存在する。MBR では、事例の修正を一切行わず、事例ベース中の類似事例の回答部分をそのまま質問に対する回答とする。事例の修正の知識は不要であるが、その分事例を大量に準備する必要がある。また、事例ベース中になく回答を生成する能力はなく、回答カテゴリーが既知の分類問題のみを対象にしている点が特徴である。」

### (3) p.20, 図 1 のキャプション

【修正前】

図 1 MBR のメカニズム

【修正点】

図 1 は文献[7]「毛利隆夫, 田中英彦; 記憶に基づく推論と多変量解析との比較, 人工知能学会研究会資料, SIG-KBS-9502-8, pp.56-63, 1995.」の図 1 を参考にさせていただきながら作成致しましたので、その旨を明記させていただきました。

【修正後】

図 1 MBR のメカニズム (文献[7]の図 1 を参考に作成)

(4) p.21, 左段, 7 行目～11 行目

【修正前】

MBR での類似度の計算では、人間がその領域の専門知識を考慮して、類似度の計算式や計算に用いる特徴の重み値を決定する方法もよく用いられるが、条件付き確率をもとにした方法は、対象領域の専門知識を必要としない汎用な方法である。

【修正点】

この一文は文献[5]をそのまま引用させていただいておりましたので、そのことが明確になるようにさせていただきました。

【修正後】

文献[5]での説明によると、「MBR での類似度の計算では、人間がその領域の専門知識を考慮して、類似度の計算式や計算に用いる特徴の重み値を決定する方法もよく用いられるが、条件付き確率をもとにした方法は、対象領域の専門知識を必要としない汎用な方法である。」とされている。

(5) p.21, 左段, 11 行目～13 行目

【修正前】

条件付き確率をもとにした特徴重み付け手法として次のようなものが提案されている。

【修正点】

この一文の直後に示されている、特徴重み付け手法は文献[5]を参考させていただいておりましたので、その点を明記させていただきました。また、「次ような」は「次のような」の誤りでしたので修正をさせていただきました。

【修正後】

条件付き確率をもとにした特徴重み付け手法として次のようなものが提案されている [5]。

(6) p.21, 左段, 28 行目～29 行目

【修正前】

事例間の類似度の算出方法としては、以下の 3 種類が代表的である。

【修正点】

この一文の直後に示されている事例間の類似度の算出方法は文献[5]を参考にさせていただいておりましたので，その点を明記させていただきました。

【修正後】

事例間の類似度の算出方法としては，以下の3種類が代表的である[5].

(7) 全体を通して

「カテゴリ」と「カテゴリー」が混在しておりましたので，全てを「カテゴリ」に統一させていただきました。

以上