

知識を追加的に獲得可能なパターンベースの推論システム

Pattern Based Reasoning Machine Capable of Online Incremental Learning

須藤 明人*¹ 佐藤 彰洋*¹ 長谷川 修*²
Akihito Sudo Akihiro Sato Osamu Hasegawa

*¹東京工業大学 総合理工学研究科

Department of Computer Intelligence and System Science, Tokyo Institute of Technology

*²東京工業大学 像情報工学施設

Imaging Science and Engineering Lab., Tokyo Institute of Technology

We propose an architecture for reasoning with pattern based if-then rules, which we consider essential for systems solving varying tasks autonomously in non-stationary environments. Not only both storing if-then rules of which atomic proposition are patterns and reasoning using those if-then rules but also learning if-then rules on online-incremental manner are realized with the proposed architecture. Avoiding duplication of results of reasoning is required for the pattern based reasoning. If-then rules are classified into several different clusters to achieve that. Those properties, online-incremental learning and clustering if-then rules, are provided by adopting the algorithm inspired by SOINN and SOINN-AM.

1. はじめに

推論が人間の高度な知能にとって不可欠であることは疑いようもなく、人工知能の研究における推論・論理に関する研究に関する歴史は長い。しかし、計算機上で実現されている既存の推論システムと、柔軟で汎用的な人間の知能の間には依然として大きな開きがある。特に、非定常な環境下において汎用的なタスクを扱う必要のある知能ロボット等にとっては既存の推論システムの枠組みでは不十分である。既存の推論システムが不十分である理由はいくつかあるが、筆者らは既存のシステムがシンボルベースの推論しか行えないことが重要な理由のひとつであると考えている。

代表的なシンボルベースの推論機としてプロダクションシステムがあるが、これは事前に人間の専門家が if-then ルール の形でシステムにシンボルベースの知識を与えておく必要がある。システムの扱うタスクの範囲が限定されていて、それらのタスクを解くために必要な知識が事前にわかっているならば、その知識を事前にシステムに与えておけばシステムはその知識を利用して推論によってタスクを解決することが可能である。一方、非定常な環境下で自律的に活動することを要求される知能ロボットのようなシステムにとっての十分な知識を事前に全て列挙することは原理的に不可能であり、新たな環境に適応するために自律的に知識を追加学習していくことが必要となる。このようなシステムが実世界で獲得する情報は環境から得られるパターン情報であり、シンボル化はされていない。新たに得たパターン情報に対応するシンボルを毎回新しく生成するか、あらかじめ持っているいずれかのシンボルとして扱うことにすれば従来のシンボルベースの推論機で推論を行うこともできる。しかし、前者の方法ではシンボルの数が爆発してしまうため現実的ではない。また後者の方法は既存のシンボルとは性質の異なるパターン情報を新たに得たときに対応できない。

そこで本論文では、パターン情報をシンボル化しなくても推論を行うことのできるシステムを提案する。提案手法はパターン情報を原子命題とし、この原子命題に連言（かつ）、選言（または）、否定を付加した命題を含意（ならば）で結びこ

で作られる任意の if-then ルールを学習することができる。例えば、A から F をパターン情報としたとき、「 $A \rightarrow B$ 」や「 $((A \rightarrow B) \rightarrow C) \rightarrow (D \rightarrow E \rightarrow F)$ 」といった知識が学習の対象となる*¹。If-then ルールを学習したシステムに対しファクトにあたるパターン情報が入力されると、学習した if-then ルールを利用して演繹推論を行い、いくつかの結果を導き出すことができる。もし「 $(A \rightarrow B) \rightarrow (C \rightarrow D)$ 」と「 $C \rightarrow (E \rightarrow F)$ 」を学習したシステムに対し「 $A \rightarrow B$ 」を入力すると、 $C \rightarrow D$ 、 $(E \rightarrow F) \rightarrow D$ を推論結果として出力することができる。

パターン情報ベースの推論機を非定常な環境下で自律的に活動することが必要なシステムへ応用する場合、上段で述べた機能に加えて追加学習、汎化性能、推論結果の重複を防ぐ仕組み、ノイズ耐性の4点が必要になることが予想される。まず、システムが学習すべき if-then ルールを人間が事前に全て用意し与えることはできないため、システムは if-then ルールをバッチ学習することはできない。そのため、システムが知識を追加的に学習することが必要である。システムが追加学習可能であれば、頻繁に利用される推論結果を新たに if-then ルールとして追加することもできるので、計算時間の削減にもつながると考えられる。また、学習によって得た知識と異なるデータがファクトとして入力されても、入力データと似ている知識を用いて推論を行えることが望ましい。そもそも実世界で活動するシステムにとって学習データと完全に一致するデータが入力されることは考えづらく、この機能は実世界で活動するシステムには不可欠である。ただ、類似データを用いた推論がある程度行えるにしてもそれには限界がある。そのため、シンボルベースでは単一の if-then ルールで表せる知識もパターン情報ベースでは複数の if-then ルールとして学習することが必要になってくるだろう。しかしこれによって推論結果に重複が生じてしまう恐れがある。例えばシステムが環境から $\{a_i \rightarrow b_j | i, j = 1, 2, 3, \dots\}$ といった複数の if-then ルールを学習したとする。これらが別々の知識であるとシステムが認識すると、ファクトとして a_1 を入力すれば推論結果として b_1, b_2, \dots が得られる。学習データが本当に別の知識であればそれによいが、学習した複数の知識がシンボルベースでは A

連絡先: 〒 226-8503 横浜市緑区長津田町 4259

{sudo, snowmoon, hasegawa}@isl.titech.ac.jp

*¹ 本論文では連言、選言、否定、含意を \wedge , \vee , \neg , \rightarrow を用いて表す

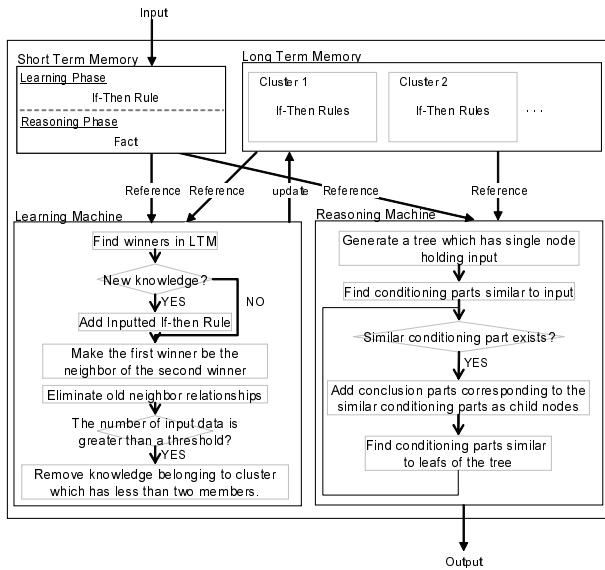


図 1: 提案手法のアーキテクチャ

B という単一のルールで表せる知識であった時は計算量の削減や推論結果の利用の観点から、状況に応じ推論結果の重複を避けて一つだけ推論結果を出力することもできたほうがよい。さらに、環境が理想的でない限り、システムへの入力にノイズが混じることは避けがたく、一定のノイズ耐性を持っていることが求められる。特に実環境下で活動する知能ロボット等への応用を行う際にはノイズ耐性は非常に重要になる。

提案手法はパターン情報で表される if-then ルールの単なる蓄積やそれを用いた推論にとどまらず、上記の要求も満たしている。これらの機能を実現するために、提案手法はクラスタリングやトポロジー学習を目的としたニューラルネットワークモデルである Self-Organizing Incremental Neural Network (SOINN)[Shen 05] や、SOINN を連想記憶モデルに拡張した Neural Associative Memory with Self-Organizing Incremental Neural Network (SOINN-AM)[Sudo 07] のアルゴリズムを拡張して利用している。これにより追加学習、類似データの取り扱い、推論結果の重複の回避、ノイズ耐性の機能を持たせている。

本論文に直接関係する先行研究は非常に少ない。最近では山根らがニューラルネットワークモデルを利用したパターンベース推論 [山根 07] を提案しているが、連言(かつ)、選言(または)、否定を扱うことができないという大きな問題のほか、2 値データしか扱えない、追加学習の性能が限定的であるといった問題をかかえている。そのため知能ロボットへの応用には不十分である。

2. 提案手法

図 1 に示したように、提案手法は長期記憶、短期記憶、学習機、推論機からなる。長期記憶には学習した if-then ルールが蓄積され、短期記憶には入力データが一時的に保存される。提案手法は if-then ルールを獲得する学習フェーズと獲得した if-then ルールと入力されたファクトをもとに推論を行う推論フェーズに分けることができる。学習フェーズではパターン情報を原子命題とする if-then ルールが入力され、所定のアルゴリズムに従ってそのデータを学習する。




図 2: 出力される OR 木の例

学習フェーズでは、学習データを長期記憶に追加すべきかどうかや既に長期記憶にあるデータで削除すべきものがあるかどうかをオンラインで判断している。また、長期記憶の if-then ルールはオンラインでクラスタリングされる。これらの機能により追加学習および推論結果の重複の回避を同時に行うことができる。入力された if-then ルールの全てをただ長期記憶に蓄積していくのではこれらを実現することはできない。

以下で学習フェーズと推論フェーズのアルゴリズムについてそれぞれ述べる。

2.1 学習フェーズ

学習フェーズでは、学習データとして入力された if-then ルールを学習し、推論フェーズで利用する知識として長期記憶に保存する。

まず、学習すべき if-then ルールの条件部と結論部をそれぞれ選言標準形に変形することで if-then ルールを次式で表されるような形にするという前処理が必要である。

$$\bigvee_i [(\bigwedge_j P_{ij}^L) \wedge (\bigwedge_j \neg Q_{ij}^L)] \rightarrow \bigvee_i [(\bigwedge_j P_{ij}^R) \wedge (\bigwedge_j \neg Q_{ij}^R)]$$

ただし、 $P_{ij}^L, Q_{ij}^L, P_{ij}^R, Q_{ij}^R$ は原子命題 (パターン情報) を表す。任意の命題論理式は選言標準形に変形できることに注意されたい。提案手法は上式の if-then ルールをさらに条件部と結論部を節ごとに分けて新たに次式のような $M \times N$ 個の if-then ルールを作る。

$$\left\{ (\bigwedge_j P_{ij}^L) \wedge (\bigwedge_j \neg Q_{ij}^L) \rightarrow (\bigwedge_j P_{kj}^R) \wedge (\bigwedge_j \neg Q_{kj}^R) \right\} \\ (i = 1, 2, 3, \dots, k = 1, 2, 3, \dots)$$

つまり、リテラルの連言を含意で結んだ形をした複数の if-then ルールを作るということである。提案手法はこのように分解された if-then ルールを長期記憶として保存する。

学習データとして与えられた if-then ルールを単純に全て蓄積しておくだけでは、追加学習および推論結果の重複の回避が行えない。これらを行うためには学習データや長期記憶のデータのうち不要なものをオンラインで削除する仕組みや長期記憶の if-then ルールをクラスタリングする仕組みが必要である。これらを目的とした手法は数多いが、多くの手法では追加学習に不向きである。そこで、提案手法はトポロジー学習および教師無しクラスタリングをオンラインで行うことのできる SOINN や SOINN を連想記憶モデルに拡張した SOINN-AM のアルゴリズムを拡張した学習アルゴリズムを採用している。

2.2 推論フェーズ

推論フェーズでは、パターン情報に連言、選言、否定を付与した情報がファクトとして入力される。ファクトが入力さ

れると、学習フェーズで獲得し長期記憶として保存されている if-then ルールと入力されたファクトを利用して推論を行い、入力したファクトを根とする OR 木が出力される。この木の各節はリテラルの連言を保持しており、これらを選言で結んで作られる複数の選言標準形を推論結果とみなすことができる。

ファクトが入力されると入力されたファクトを根としそれ以外の節はもたない木を生成する。次に、長期記憶に蓄えられている if-then ルールの条件部との距離を計算し、あらかじめ定めた閾値以下の距離になった if-then ルールの結論部のみを先の木に入力されたファクトの子ノードとして追加する。ただし、同一のクラスタから複数の if-then ルールを追加することを避けるため、閾値を下回る if-then ルールが同じクラスタに複数ある場合は距離の最も小さい if-then ルールのみが子ノードに追加される。もし、閾値以下の距離になるような if-then ルールが長期記憶に存在しない場合は処理は終了する。その後、追加された子ノードを入力されたファクトと同様に扱い、順次ノードを生成していく。この手順は、入力されたファクトと長期記憶の知識を組み合わせて多段の推論を行っていることに相当する。例として、長期記憶として $A \ B \ C \ (D \neg E), C' \ F \ G \ (H \ I), D' \ \neg E' \ \neg J$ を保持しているときに $A' \ B'$ がファクトとして入力されたときに出力される木を図 2 に示した。ここで、 $(A, A'), (B, B'), (C, C'), (D, D'), (E, E')$ は閾値に対して十分に距離が小さいパターン情報のペアである。

出力される木の各節にはデータとしてリテラルの連言が保持されているが、これらは単独では推論結果として正しくない。なぜならば、各節はもともとは選言で結ばれたものを分解して学習されたものだからである。図 2 で言えば $A \ B \ C \ (D \neg E)$ なのであって、 $A \ B \ C$ ではない。そこで、出力された木を OR 木として扱い、節を選言で結んだ選言標準形が推論結果として正しいものとみなす。例えば図 2 の木が出力された場合は、推論結果が $C \ (D \neg E), C \ \neg J, F \ G \ (H \ I) \ (D \neg E), F \ G \ (H \ I) \ \neg J$ であったとみなす。

このように、推論結果は選言標準形をしているが、これは提案手法が可能性についての推論を行っているという解釈が可能である。例えば現在地に関する情報をファクトとして入力した結果、出力として「スーパーまたはコンビニエンスストアまたは薬局」に相当する結果を得たとしよう。これは現在地からどのような場所に移動できるかという可能性を推論によって発見したと考えられる。

2.3 ニューラルネットワークモデルとしての解釈

知識工学の観点では本手法は図 1 のようなアーキテクチャであると見なせるが、図 3 に示したようなニューラルネットワークモデルとしての解釈も可能である。このニューラルネットワークモデルは、SOINN や SOINN-AM のように学習データの入力に応じて自律的にノードが増えていくモデルである。提案手法はこれらのモデルと学習データが異なるため、各ノードが保持する情報が異なり SOINN や SOINN-AM では用いられない種類のエッジを用いている。SOINN のノードは 1 個のパターン情報を表現するため実数値ベクトルを 1 個だけ保持する。SOINN-AM のノードは連想対を表現するため実数値ベクトルを 2 個だけ保持する。このように、SOINN や SOINN-AM が 1 個のノードで 1 個の知識を表現するのにに対し、提案手法のニューラルネットワークモデルはいくつかのノードの結合によってリテラルの連言を含意で結んだ 1 個の if-then ルールを表現する。表現すべき if-then ルールの条件部のリテラルの数を m 個、結論部のリテラルの数を n 個とすると、この if-then

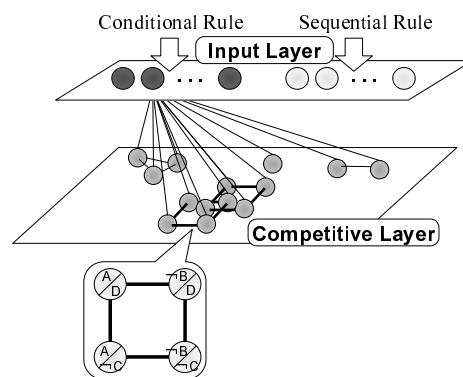


図 3: 提案手法のニューラルネットワークモデル

ルールを表現するために $m \times n$ 個のノードを用いる。各ノードは条件部と結論部のリテラルのペアを表現する。具体的には、原子命題を表す実数値ベクトルのペアとそれらが肯定なのか否定なのかという情報を保持する。これら $m \times n$ 個のノードで 1 個の知識であることを表現するため、これらのノードは SOINN や SOINN-AM のエッジとは異なる種類のエッジで結ばれる。参考までに図 3 には、 $A \ \neg B \ \neg C \ D$ を表現しているノード群が示されている。

3. 実験

実画像を用いて環境の因果関係や可能性について追加学習させ、学習した知識を用いて推論を行わせた。用いた画像は図 4 に示したような 56×46 ピクセルの 14 種類の画像についてそれぞれアングルを変えて撮影した画像各 20 枚ずつであった。学習させた if-then ルールは「 $A \ B, B \ D \ E, E \ (C \ N) \ F \ M, (C \ N) \ (G \ I) \ (H \ J), (G \ I) \ K, (H \ J) \ L$ 」である。これらをシンボルで書くならば「閉じたドア 開いたドア, 開いたドア 壁 廊下, 廊下 (部屋 表札) エレベーター 階段 (部屋 表札) (机 1 閉まった引出し 1) (机 2 閉まった引出し 1) (机 1 閉まった引出し 1) 開いた引出し 1 (机 2 閉まった引出し 2) 開いた引出し 2」である。学習データとして実際に入力されたデータは、各原子命題をあらゆる 20 枚の画像をそれぞれランダムに 1 枚ピックアップしてできる if-then ルールであり、そのようにランダムに選択してできる if-then ルールの入力を繰り返した。例えば $A \ B$ を学習させる際には、 A に対応する 20 枚の画像から 1 枚と B に対応する 20 枚の画像から 1 枚選び、それを if-then ルールとして学習させることを繰り返した。

学習によって 912 個の if-then ルールが長期記憶に蓄積されそれらは 10 個のクラスタに分類された。クラスタに属する if-then ルールはそれぞれ「 $A \ B, B \ D \ E, E \ (C \ N) \ F \ M, (C \ N) \ (G \ I), (C \ N) \ (H \ J), (G \ I) \ K, (H \ J) \ L$ 」に対応する知識だけであった。これはシンボルベースで表せば単一のルールとなるような if-then ルールをうまくクラスタリングできていることを意味する。学習データとして 4000 個の if-then ルールが与えられたが、そのうちの約 77% にあたる 3088 個の if-then ルールは長期記憶には蓄積されなかった。これは類似した知識を長期記憶に蓄積しないために導入したアルゴリズムがうまく働いていることを示唆している。ここで、上記の学習手順がバッチ学習ではなく

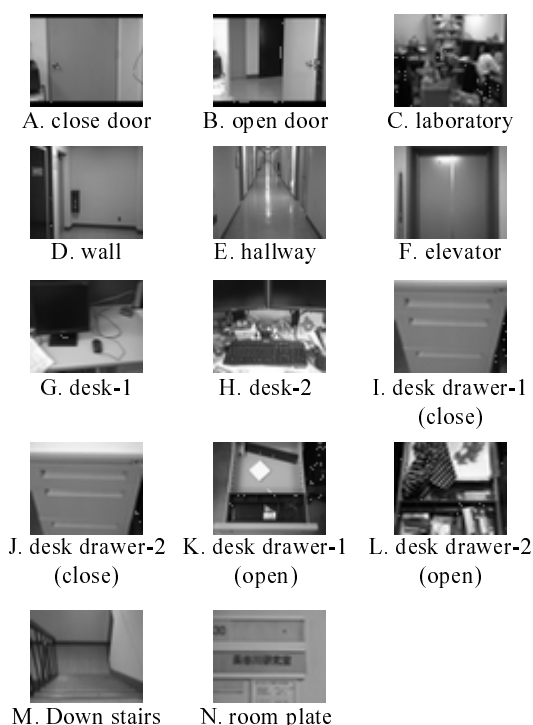


図 4: 実験に使用した画像の例

追加学習になっていることに注意されたい。上記の手順で正しく知識を学習できたことは、いったん学習が終了した後に新たな学習データが追加されたとしても以前に学習した知識を忘却することなく新たな知識を学習することや、同じか極めて類似したデータの長期記憶への追加によるメモリの浪費を避けることが可能であることを示している。

学習後、ファクトとして図 5 の根にあたる画像を入力して推論を行わせたところ、if-then ルールとして断片的に学習したデータを組み合わせて図 5 の OR 木が推論結果として出力された。これは入力したファクトと学習させた if-then ルールから得られる結果として不足も重複もない必要十分なものであるといえる。この結果は、閉じたドアから階段、エレベータ、引出し等に到達可能であることと、それらの場所に至るまでの経路をシステムが推論によって見出すことができたと解釈できる。引出しに関する推論の部分では提案手法が連言を扱うことができることが有効に働いている。もし連言を扱えないと、机の画像を知識として与えずに閉じた引出しの画像だけを学習することになり、異なる引き出しでも見た目は同じであるため正しく推論を行うことができない。推論結果に重複が無いのは if-then ルールをクラスタリングしながら学習できたためである。もしクラスタリング結果を無視して、閾値よりも小さい if-then ルールの結論部を全て節として追加するようにして推論を行わせたところ、根の子ノードだけで 112 個の節が生成された。これらの節の持つ画像は全て図 4 の B に対応する 20 枚の画像に一致し、シンボルベースで解釈するならば 1 つの節で表現すべき内容であった。この結果は if-then ルールをクラスタリングすることの有効性を示唆している。

なお、紙面の都合上提案手法の性能に関する定量的な評価は口頭で発表する。

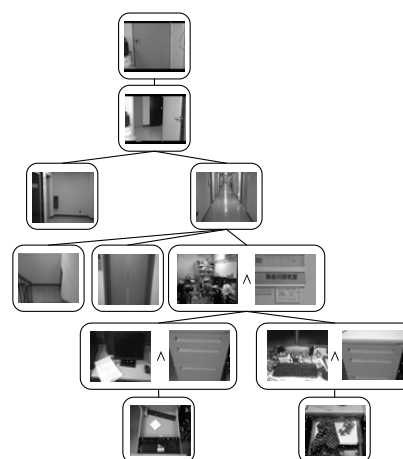


図 5: 出力された OR 木

4. むすび

非正常な実環境下で自律的に活動することが要求されるシステムにとって従来のシンボルベースの推論が不十分であることをふまえ、パターン情報ベースの推論機の提案を行った。提案手法はパターン情報を原子命題としそれらの原子命題に連言・選言・否定を付与した任意の形の if-then ルールを学習することができる。また学習した知識を利用して多段の推論を行うことができる。これら推論機としての基本的な機能以外にも if-then ルールの追加学習、推論結果の重複の回避、汎化性能、ノイズ耐性を実現している。提案手法は if-then ルールをオンラインでクラスタリングしながら学習していくが、将来的にシステムの内部的なシンボル獲得につながる可能性もあると考えている。

今後は提案手法を知能ロボットに応用する予定である。提案手法により環境から自律的にパターン情報ベースの if-then ルールを学習しその知識をもとにした推論によってタスクを解決する知能ロボットが開発できるものと考えている。

謝辞 本研究の実施にあたり NEDO 産業技術研究助成事業から支援を頂きました。記して感謝いたします。

参考文献

- [Shen 05] Shen, F. and Hasegawa, O.: An Incremental Network for On-line Unsupervised Classification and Topology Learning, *Neural Networks*, Vol.19, No.1, pp. 90-106, 2006.
- [Sudo 07] Sudo, A., Sato, A. and Hasegawa, O.: Associative Memory for Online Incremental Learning in Noisy Environments, *IJCNN'07*, 2007.(accepted)
- [山根 07] 山根健, 蓮尾高志, 末光厚夫, 森田昌彦: 軌道アトラクタを用いたパターンベース推論, *電子情報通信学会論文誌 (D)*, J90-D, 933-944, 2007.