

# 自己連想記憶理論を用いた情報自動構造化アルゴリズムの構築

Building of an Automatic Information Structuring Algorithm with Memory Prediction Framework

086919 牧野晃典

指導教員 松尾豊 准教授

## 1. 研究背景

有史以来、人類による知識の生産効率は、文明や技術の発展に支えられて、時の流れとともに向上しつづけてきた。しかし、近年の急速なウェブの発展に伴う増加ほど爆発的な傾きを示したことはない。あらゆる情報の絶対量は今や線形ではなく、幾何級数的に増えつづけている。

このことは情報収集の便宜と同時に、情報把握の困難を生み出した。我々は必要とする情報を、関連した情報も含め好きなだけ集めることはできるが、その意味の離散した莫大な情報群を理解可能な形に編集する術を欠いており、それゆえに集めた情報を充分有効には利用できていない。そんな中、ウェブ上では二次情報、三次情報が再生産され、情報量の増加は加速度的に進行していく。なんらかの手段を講じない限り、情報は我々にとって目を追うごとに把握困難なものになっていく。

一方で、情報へのアクセスが容易になればなるほど、知識を持っていることそれ自体は差別化された力たり得なくなり、それをどのように用いるかという知識、すなわち「知を使う知」が重要視されるようになった。ことに技術や経営の領域ではその傾向が顕著である。

この両傾向を併せ考えて導かれる結論は、知を使う知が必要であり、その使うべき知が人間の手に余るほど巨大になった今、人が直接膨大な知の海に直面する以前に、それをパースする機械に知能が求められているということである。その機械こそ、あらゆる情報を自動的に構造化できる人工知能に他ならない。

こうした事情を踏まえて、東京大学俯瞰工学部門

では、ひとつの広大な学問領域における重要な論点や全体の方向性を容易に把握するための手段として、学術俯瞰マップの研究を行ってきた。

学術俯瞰マップは、関連論文を引用分析の手法により自動的にクラスター化することで生成されるネットワーク図である。マップ生成に用いた各論文は、引用関係のリンクとともにマップ上に図示される。この作業は計算機によって自動的に行われるものであり、いかなる学問領域のマップの作成にも人力や専門家を要しない。これによって、急速に膨張している学術研究をいつでも客観的に俯瞰することができるようになった。

大量の情報を構造化したいという需要は日増しに大きい。このような事情を背景として、本研究は次節に示す目的の達成を目指すものである。

## 2. 研究目的

本研究の最終的な目的は、上述の学術俯瞰マップをより汎用的で有用な形に進化させることである。そのため、学術俯瞰マップが人にとって有用なツールである理由を考察し、その有用性の原理を一般的なアルゴリズムとして抽出することが必要である。

我々が俯瞰マップによって得ることのできる一般的な知見として、領域間の関係性、下位領域の存在、ハブの存在などが挙げられる。

学術俯瞰マップがこれらの特性を持つのは、論文をノード、その引用・被引用関係をエッジとして、ネットワークという形式に情報を変換することで、論文というデータの抽象度を上げ、クラスターとして概念化しているからである。ネットワークには情報を概念化して示すという特性がある。情報の構造

化とは、扱う情報を正しくネットワーク化することに他ならない。

しかし、学術俯瞰マップで扱う論文というデータは、引用・被引用関係も含め、形式的に整理されたものであるが、我々が通常必要としている情報の多くは、論文のように形式的に整理されたものではない。ウェブ上の情報などはその典型である。現状を考慮すれば、論文の構造化のみならずあらゆる領域について、学術俯瞰マップに比する情報構造化ツールが必要である。すなわち、いかなる形式であれ何らかのデータが与えられれば、それを自動的に抽象化して概念をつくりだし、その概念間に関係を見出すようなシステムである。これは対象データの形式に依らない原理的なアルゴリズムを要するものであり、そのアルゴリズム発見のためには、情報の構造化という手法に関する基礎的な研究が必須であろう。

本研究は、知の構造化及びネットワークに関する従来研究を踏まえた上で、情報構造化のためのより深いアルゴリズムの方式を探る。その目的は俯瞰マップの汎化及びその手法の昇華である。

直接的に俯瞰マップの性能を向上するなどの貢献まで辿り着かなくとも、現在俯瞰マップが果たしている機能を分解し、その原理を解明して深めていくことは、求められている大量の情報の構造化と、それに基づく分析及び意思決定のための重要な基盤となる。

### 3. 関連研究

本研究の提案アルゴリズムは、ニューラルネットワークの手法に、以下の既存研究のアイデアを適用したものである。

#### 転移学習

転移学習は、未知のタスクに対する仮説を効率的に発見するために、他の領域で得た知識を移転・適用する手法に関する研究である。本研究の提案アルゴリズムは、データに対する学習を終えたニューラルネットワークの構造が、未知のデータに対する予測性を持つことを意図して設計するものであり、し

たがって一種の転移学習と見なすことができる。領域間で転移・共有されるものは、ネットワークの中間構造である。

#### 補助問題と構造探索

構造探索は、データに内在する構造を学習する手法であるが、そのためにはデータから自動的に補助問題を生成して、これを解く必要がある。この補助問題をどのように生成するかが、構造探索の鍵となる。本研究の提案アルゴリズムは、後述する自己連想記憶理論に基づいてデータから補助問題の生成を行い、それを解くことで、データの予測性に基づくパターンを抽出し、構造化するものである。

#### 自己連想記憶理論

Jeff Hawkins によって提唱された、脳の情報処理システムをアルゴリズムの形に書き下すために用いる理論[2]である。上述の補助問題の生成も、この理論に依って行われる。本研究の骨子となるアイデアである。

#### 神経ダーウィニズム

情報の構造化にあたって、データに人為的な措置を施したり、対象データの種類や性質に応じてその処理に特化したアルゴリズムを用いなければならないアルゴリズムでは汎用性がない。本研究の提案アルゴリズムが想定しているのは、種類や形式を問わずあらゆるデータを入力することで、自動的に構造化が行われるシステムである。そのため、人間の脳がそうした情報処理の柔軟性を持ち得た理由を説明する、神経ダーウィニズムの理論に着目する。

### 4. 定式化

本研究が解くべき問題を定式化する。前章で、データから補助問題を生成して、それを解くことでデータに内在する構造探索を行う手法があることを述べた。しかし、データにラベル付けを行い、その一部をマスクして他のデータからマスクしたデータを予測するという Ando ら[1]の補助問題の生成手法は、理論的には優れていても現実的には妥当ではない。現実世界では、そのような状況でデータを取り入れ

ることはほとんどないからである。

そこで本研究では、現実世界においても妥当な方法で、大量のデータの入力から自動的かつ連続的に補助問題を生成し、それを解きながら自己構造化を行う方法として、「現在までに観測されたデータを用いて将来観測されるであろうデータを予測する」という補助問題の生成方法を提案する。これは Hawkins の自己連想記憶理論によれば、人間の脳が自己を構造化するために日々行っているものであり、したがってそれを補助問題とすることは、脳の情報処理システムを模倣しようとする本研究のアルゴリズムにとって適切であると考えられる。

アルゴリズムは、階層記憶システムを内部に作り出すため、現在までに観測された過去の情報に基づき、次に起こる観測について予測を立てる。このことを考えるために、いま観測と時間の関係を模式的に図示すると次のようになる。




図 1 データを内包する時空間チューブ

図 1 は、データの散在している空間を時間軸方向に引き伸ばしたものである。これを以下、時空間チューブと呼ぶ。我々が外部に観測する情報は、この時空間チューブ内の任意の点として表すことができる。

時空間チューブ上においては、予測という機能は図 2 のように表わせる。




図 2 時空間チューブ上における予測の表現

予測のために使える情報は、現在 ( $t = T$ ) 以前の時空間内に存在するすべてのデータである。これを入力  $X$  とし、次の時刻におけるデータの観測予測を出力  $Y'$  とすると、予測という機能は、 $Y' = f(X)$  における  $f$  であると言い換えることができる。そうして、予測性を最大化することは、実際の観測を  $Y$  としたとき、次の式で表される誤差  $E$  を最小にすることである。ただし、 $g(a, b)$  は、何らかの形で  $a$  と  $b$  の乖離を表す関数である。

$$\text{minimize } E = \sum_y g(f(x), y) \quad (x \in X, y \in Y)$$

多くの分類問題は、 $f$  をデータの分離平面として、その平面の探索にアルゴリズムの力を尽している。しかし階層記憶システムでは、過去の観測データを自在に用いて未来を予測するということを端的に表すのであれば、 $f$  は図 3 のように、観測データ同士を自在に繋いで作る構造として表現することができる。




図 3 構造自体を  $f$  とする解釈・概略図

過去の観測データに基づいて未来を予測する、その予測精度を最適化する問題は、この構造の最適な形を探索するタスクであると言い換えることができる。

しかし、データの量と存在範囲が大きくなればなるほど  $f$  の解空間は広大になり、探索には時間がかかるようになる。本研究の目的は、この広大になった解空間から、いかにして迅速に、かつ良好な  $f$  を探索するか、その方法論に原理を見出し、統一的な説明を与えることである。

ネットワーク構造を変形・更新する方法はいくらでも考えられる。未知の予測を行うためにもっとも効率的で効果的な更新方法は何か。本研究ではそれ

を、自己連想記憶理論に基づき、過去の観測データ自身を予測するという補助問題を解くことによって構造化を行うことであると仮定する。そうしてこの手法が、未知の予測に対して優れた  $f$  を迅速に探索する手段となっていることを証明する。

以上が本研究の目的の定式化である。

## 5. アルゴリズムの設計と分析

これまでに述べてきた本研究の提案アルゴリズムの全貌を定義すると、「なんらかの入力データを大量に与えることで、そのデータ群に内在するパターンを発見し、ネットワークの内部に構造化された階層記憶を作り出すようなアルゴリズム」と記述することができる。

いま、これをデータの抽象化という言葉に集約する。具体的にどのような仕組みがデータの抽象化を実現しうるだろうか。

本研究では、その仕組みを選択淘汰、適応、多層化、時間方向の圧縮という四つの要素に分解して考え、個々の要素について、効果を確認するためのアルゴリズムを設計し、人工データを用いた実験と考察を行った。

個々の要素を検討する前に、まずアルゴリズム全体の基板となる補助問題についての検証を行った。すなわち、データ自身を予測するという補助問題を解くことによるネットワークの自己構造化が、データの抽象化に寄与することを確認する。そのために、多層パーセプトロンとバックプロパゲーションを用いて実験を行った。実験データには、結果を視覚的な形で容易に確認することのできるデジタル数字認識を用いた。こちらで用意した実験用のデータと、一般に機械学習のため公開されている手書き文字の認識実験用データを用意して、二通りの実験を行った。結果、多層パーセプトロンに対して数字をあらゆるベクトルデータを与え、データ自身を予測するという補助問題を解きながらバックプロパゲーションによって構造を更新することで、データの抽象化を行う中間ニューロンが自動的に生成されることが

確認された。

次に、選択淘汰の検討を行った。神経ダーウィニズムに基づき、データの予測に役立つニューロンのみを生き残らせ、予測に役立たないニューロンを淘汰するというプロセスを、三層のネットワークに対して繰り返し行った。結果、上述のプロセスを繰り返すことで、計算時間はかかるものの、最終的にはデータの予測に最適なネットワーク構造に辿りつけることが確認された。

次に、適応の検討を行った。前節で設計した神経ダーウィニズムによる選択淘汰のモデルに、ニューロンの適応力を評価するリワードの概念を導入することで、ネットワーク内の軸索の重み更新を可能にしたモデルを設計する。結果、適切な更新ロジックを与えることで、ネットワークの構造最適化が、前節の神経ダーウィニズムのみに基づくモデルよりも早くなることが確認された。

次に、多層化の検討を行った。上述のモデルはいずれも三層のネットワークであるが、構造が三層である限り原理的に解くことのできない問題が存在することを示し、その問題を多層化されたネットワークに解かせる実験を行う。多層化のプロセスは、いくつかの手法を比較検討する。結果、多層化されたネットワークは、前述の三層構造では解けない問題を解くことができることが確認された。また、多層化のプロセスの比較により、優れた多層化の方法も確認された。

最後に、時間方向の圧縮の検討を行った。多層化モデルは計算に膨大な時間がかかることを確認し、その解決方法として、入力データを全て等価なネットワークへの入力情報として扱うのではなく、観測の時間方向に圧縮し、実数値として入力層に与えるモデルを設計する。ネットワーク構造の経済化を試みた。結果、ここでは、入力データの時間方向の圧縮により、入力層及び中間層の構造が経済化されたネットワークは、もっとも優れた多層モデルにも劣らない精度と、遥かに速い構造最適化の速度を示すことが確認された。

## 7. 考察と適用可能性

本アルゴリズムを適用すべき、構造化したいデータをいくつか例に上げ、それらに対してどのような抽象化が行われ、その結果どのような知見が得られるかを考察する。

### 特許

特許のメタデータには、発明者、出願人・機関、国際特許分類（IPC：International Patent Classification）などがある。これらのメタデータを提案アルゴリズムの入力として与えることを考える（図 4）。




図 4 特許データへの適用例

アルゴリズムは、与えられたデータの一部から、与えられない部分を予測するように構造化されている。したがって構造内部に、たとえば「国際特許分類 G（物理学）」を予測するような中間ニューロンを持っている。この中間ニューロンが表しているのは、物理学という技術分類特許を予測するような発明者、機関のデータのおつまりである。これは、物理学周辺で活躍する研究者のグループや機関を表していると考えられる（図 5）。




図 5 特許におけるデータ抽象化の例

同様に「発明者 X」を予測している中間ニューロンは、発明者 X をキーパーソンとするような技術分野や、機関のおつまりを表していると考えられる。「機関 A」を予測している中間ニューロンは、ある一機関が手がけている技術分野の集合と考えれば、産業的に近い領域にある技術分野のおつまりである

と見ることができ、ある機関の周辺に所属する研究者のグループと考えれば、その機関に関連して何らかの共同研究を行っているグループを表していると見ることができる。いずれも、特許分析に際して我々が知りたいと思うような事柄ばかりである。

### ニュース

単語を入力とすれば、単純なニュースのカテゴリ分類問題と解くこともできるし、ニュース自体を入力とすれば、社会現象の俯瞰図を作ることも可能になる。抽象化の仕組みに関しては既に述べたので、ここでは繰り返さないが、たとえば世界各地のニュース群をその地図情報と同時に入力とすることで、ニュースやそれに関連する社会現象の地域性を知ることができ、問題のグローバル性やローカル性が明らかになる。

### 気象情報

世界各地にセンサーを点在させることで、人間の網膜のようなセンサー群として、そこからの入力パターンを学習すれば、局地的なパターン、広域的なパターン、何時間、何年、何十年にわたる緩急様々な変化のパターン、どのようなパターンでもアルゴリズムは発見することが可能である。それによって、特定地域の天気の前測から、広い帯域の気象現象前測まで、様々な気象情報の前測を立てることができるようになる。




図 6 気象情報におけるアルゴリズム適用例

このように非常に多岐にわたる領域で有用に利用できながら、それがすべて単一なアルゴリズムによって実現可能である、すなわちどの領域においても専門家や既存の知識をただのひとつも要しないところが、本アルゴリズムの最大の有用性であり、従来手法にはなかった画期的な点である。社会的なインパクトは極めて大きいと言える。

## 8. 結論

本研究は、大量の情報を構造化する必要が生じていることを背景に、現行の情報構造化ツールである学術俯瞰マップを考察した。その結果、情報構造化の有用性はノードをクラスタリングすることでデータを抽象化し、人に予測性を与えるという機能にあることを明らかにした。一方、学術俯瞰マップやそれに類するネットワーク図の従来手法は、この予測性を目的に据えたものではないことを踏まえ、これらを本質的に改良する手法として、予測性を目的関数としてデータの抽象化を行う情報の構造化アルゴリズムを提案した。

そのアルゴリズムを実現するための足がかりとして、ニューラルネットワークと脳の情報処理に着目した。特に、脳は観測されたデータから周辺世界に対する予測を行うことで自己構造化を行っているとする Hawkins の自己連想記憶理論や、脳は進化によって生じたものであり、計画的に設計されたものではないため、脳の機能はダーウィンの集団的思考原理に基づいて説明されるべきであるという Edelman の神経ダーウィニズムに立脚し、これを本研究のベースアイデアとした。

また、提案アルゴリズムの妥当性を検証するための実験を行った。バックプロパゲーション実験では、自己連想記憶理論による補助問題の生成と、それを解くことによるネットワークの自己構造化が中間ニューロンに観測の抽象化を行わせていることを明らかにした。また、データの抽象化を行う仕組みを選択淘汰、適応、多層化、時間方向の圧縮という四つの要素に分解し、それぞれの効果を確認するための実験を行った。選択淘汰の実験では、ニューロンの選択淘汰のアルゴリズムのみからネットワークの構造は最適化可能であることを確認した。適応の実験では、前述の選択淘汰モデルに適応のアルゴリズムを追加し、軸索の重み更新ロジックを導入することで、ネットワークはより早く進化できることを確認した。多層化の実験では、三層モデルでは原理的に解き得ない問題を多層モデルでは解けることを確認

し、様々な多層化のプロセスを比較検討した。その結果、前世代で生き残った中間ニューロンから軸索を張って多層化させるモデルが、もっとも優れた性能を示すことがわかった。時間方向の圧縮の実験では、観測データをすべて別々のセンサーに入力せず、ひとつのデータにつきひとつのセンサーニューロンを定め、データの観測を時間で減衰させながら加算した実数値を初期値として与えるモデルを考え、それが小規模なデータに対しては多層モデルと変わらない性能を示し、大規模なデータに対しては多層モデルよりも圧倒的に早く最適化されることを確認した。

さらに、これらの理論モデルを包含する、生体的な制約に基づいた統合的アルゴリズムの構築を試みた。構築したプログラムの動作確認を通じて、第5章で理論的に設計・構築したモデルが、神経科学的に可能な形で実装されうることを確認した。

最後に、本アルゴリズムを論文、特許、企業情報、産業情報などのデータに対して適用することで、どのようなデータの抽象化が可能になり、従来得られなかった、または得難かったどのような知見がそこから得られるかを議論した。

以上の実験及び考察から、本研究は、直接的に大量データの構造化には至らないものの、大量データを自動的に構造化するための基盤となるアルゴリズムを提案しており、潜在的な有用性は極めて高いと結論する。本研究の提案アルゴリズムを深めることは、数々の有益な仕事を実現する、知能を持つシステムの実現に近づいていくことにつながると確信している。

## 参考文献

- [1] Rie Kubota Ando, Tong Zhang, “A Framework for Learning Predictive Structures from Multiple Tasks and Unlabeled Data”, 2005
- [2] Jeff Hawkins, “On Intelligence: How a New Understanding of the Brain will Lead to the Creation of Truly Intelligent Machines”