

Dynamical Recognizer モデルを用いた学習の非決定性 の問題と空間／時間認識の構造

池上高志

東京大学大学院総合文化研究科

1 Dynamical Recognizer の認識能力

Dynamical Recognizer (以後 DR と略す) は、2 次の再帰的なニューラルネットワークで、再帰的な汎関数システムである。外部と直接状態をやりとりする状態変数(ノード)と内部的に反復させる状態変数(ノード)をもっており、後者をコンテキストノードと呼ぶ。最初に Pollack [1] が示したように、DR は有限オートマトン ($+\alpha$) で受理できる言語を受理することが可能である。面白いことに、この時コンテキストノードの再帰写像の中のパターンと、オートマトンのノードを対応させられる。一方対応させ切れないような複雑なパターンを示すことも多い。これを見捨てずに認知というコンテキストのもとで意味づけようというのが研究の目的である。

今までの研究で、DR 同志を相互作用させて、相手の学習が破綻して複雑なパターンを生成しそれがもとで時間発展を与えるという様相を調べてきた [2, 3, 4, 5]。ここでは DR 単独の学習の問題を力学系の問題として考察する。

そもそも学習の定義は一様ではなく、どのような定義を持ち出してもそこにはクリプキの罠が待ち構えている [6]。力学系としての学習の問題は、外部から与えられた時間の系列をどのような因果律の形として自分のダイナミクスに取り込むか、ということである。つまり事象 (n) の次に事象 ($n+1$) が起きるということを写像の形として埋め込むということである。例えばパブロフの犬のような問題、鈴の音が聞こえる → ご飯が出てくる、という形の写像を内部的に構成してしまうことに対応する。これをプリミティブな学習の雛型と考えたくなるが、このパブロフの条件付け学習の場合でさえ、安定に系列が埋め込まれているとは限らない。例えばこの学習は、鈴の音のスペクトラムにはどのくらいよるのか、犬の内部状態にはよらないのか、鈴を持っている人の服装との間に写像を張ってしまった可能性はないのか。このように「学習できた」ということよりも、学習の外延の多様性にこそ注目すべきだろう。力学系的な描像では、この外延の多様性を例えばひとつの学習過程に付随するアトラクターの多様性と、アトラクター間の階層関係に見出していくことができる。

内部的にイベント間の写像を構成することで学習を特徴づけようとしたとき、一番単純なのは有限オートマトンとして(周期的なアトラクターを持つ写像として)学習する場合である。多くの場合には、そうした学習こそが成功と考えるであろう。しかし有限オー

トマトンは、時間の向きを持たない、という意味で特殊な学習と考えることができる。例えば、電卓でいつ $2 + 19$ を計算しても 21 という答が期待されるが、一方で夕方 7 時に家の前の巣穴から出てくる蟻の数がつねに 21 であるとしたら、奇妙に思うだろう。時間の向きを持つ認識が通常であるとき、時間の向きを持たない認識（コンテキストによらない認識）が生じることによって時間の向きを消しているのだろう。力学系的には、履歴が長く残るようなものを時間の向きを持った認識と考えることになる。以下にみるように DR の学習実験でも、同じ課題に関しても時間の方向を消す認知（空間認知）と時間の方向を保った認知（時間認知）に対応するアトラクターが出現することが示される。しかし同時に時間的認知か空間的な認知かを自分では決定できないという非決定性が出現する。

こうした学習の不安定性の問題は、例えば DR のサイズを大きくして解決する。それが脳の学習機構だ、という批判もあろう。しかし学習に付随するこの種の非決定性の問題は、量的な問題に換言されない質的な問題だと思える。物理現象のモデルでは、構造不安定なモデルを嫌うが、認知現象においては構造不安定なモデルが土台とされるとはいえないか。実際この認知現象に伴う不安定性は、逆にゲーム [2, 3, 4] や会話 [5] のモデルにおいて積極的に用いることが可能である。

2 動的認識システム

ここで扱うモデルは、コンテキストノードがインプットノードの状態との積の形でウエイトの強さを決める 2 次の再帰的ネットワークである。次の時間発展の形をしている。

$$z_i(n) = g\left(\sum_{j=0}^M w_{ij} y_j(n)\right), \quad (1)$$

$$w_{ij} = \sum_{k=1}^N u_{ijk} z_k(n-1). \quad (2)$$

ここで $z_j(n)$ は j 番目のノードの値で、 w_{ij} は i 番目と j 番目のノードをつなぐウエイトの大きさである。しかしこのウエイトはニューロンの状態の関数である。実質的なパラメータは u_{ijk} で与えられる。また関数 $g()$ は S 字関数である。ここで入力数 $M = 3$ （うちひとつは定数値）、リカレント数 $N = 3$ （うちひとつは定数値）、アウトプットはひとつとする。この結果パラメータ u_{ijk} の数は 27 個となる。これ以外に初期のリカレントニューロンの値もパラメータとなる。狭義の学習は、これらのパラメータを変更することにある。ここでは次の方式 (Williams-Zipser 方式) でウエイトとリカレントノードの初期値を変更する。

$$\Delta u_{ijk} = -\alpha \frac{\partial E}{\partial u_{ijk}} + \beta \Delta u_{ijk} \quad (3)$$

ここで E は 2 乗誤差で、以下で与えられる。 T は正解値なので、アウトプットの値がこの正解値に近づくように上の方程式を回してパラメータの値を変動させる。

$$E = \sum_{k=1}^L (z_0(k) - T(k))^2, \quad (4)$$

ここでの L の値は、学習させるために使う例題の数である。クリプキ問題における、最初の問題と解答のセットの数に相当する。考えるのは、入力系列のパリティーチェックの問題である。それを次のように2つのインプット列 I_1, I_2 に対し、答え O を一つ与えるという形にする。以下の例は $L = 20$ に相当する。

$$I_1 = 11010101011101010010$$

$$I_2 = 01001100110100110001$$

$$O = 10011001101001100011$$

解くべき問題は系列 I_1 の入力された時点までの偶奇（これが対応するアウトプット列のパターン）である。ここでさらにインプットとしてアウトプット系列 (O) を1個右にシフトした系列 (I_2) も与える。この場合 I_1 と I_2 の排他論理和から答を求めることも可能となる。もちろん系列1だけを使い、系列2は無視して答を出すことも可能である。前者が時間履歴をみない認知で、後者が時間履歴を使った認知になる。こうした2つの答の作り方を埋め込んでおいて、どういう形で学習するかをみてやろうというのである。詳細は原論文 [7] を参照してもらおうとして、主だった結果を箇条書きにすると次のようになる。

3 いくつかの結果

DR で先に説明したパリティー判定を学習させると、例えば図. 1 のような写像が得られる。パリティー判定に対し、アウトプットの値に対してある閾値を設け even(0.2 以下) と odd(0.8 以上) に離散化する。右側のパターンはこれを時間履歴を使わずに空間認知として（つまり排他論理和として）学習したものである。左側は時間の履歴を使って、与えた学習列は学習したが、パリティー判定にはならなかった例である。この左側の学習例が、例えば時間的認知に対応する可能な汎化の一例である。

最初の学習の非決定性として、そもそもサンプルパターンから何かしらの規則が学習できるか、という問題がある。この問題の特性として even/odd で答えないといけないから、答えられない場合には学習できないとする。図. 2 には、学習するかしないかが、学習の初期のウェイトの値に鋭敏によっていることが分かる。このとき空間認識学習を行なう領域はべたっと両端に見える。一方図の下側の領域は、学習できるところとできないところが細かく入り組んでいて、実際この領域ではリドル的なベイスン構造 [8] をなすことが分かる。つまりイプシロン近傍に他のアトラクターへのパスがある、ということになる。

ここで2番目の学習の非決定性が出現する。図.3 にみるように今度はアトラクターの近傍で図.2 と同じようなことを調べてみる。左の図の中央部分がランダムな初期状態から学習されたアトラクターのもつウェイトの値（のうちの2つ）である。そこからこの切断面上の2つのウェイトの値だけを少し変えて学習を再開するとはたして同じアトラクターに落ち込むかどうか、を調べたものである。これをみると分かるようにアトラクターの回りにはある程度そのアトラクターに引き込まれる領域が存在しているように見える。




Figure 1: どんな学習をしたかの表示。これは2軸をコンテキストノードの値、1軸をアウトプットノードにとり、ランダムな入力に対する値を順番にプロットしたもので、これをコンテキストプロットと呼ぶ。右側で○で囲んだ部分はオートマトンのノードに対応させられるクラスターを表示。

しかしさらにそのまわりでは、複雑な構造が広がっている。この様子を右図の説明にあるように学習されたアトラクターのウェイト全部にノイズをかけて再学習させることでどこに行きつくか、を調べることでさらに検証することができる。するとノイズの大きさに関し閾値が2種類あって、ある1種類の別のアトラクターに移り始める閾値(0.0006あたり)と、いろいろなアトラクターへのゲートが開く閾値(0.09)がある。もっともこのノイズへの依存の仕方はアトラクターの種類にもよるので、つねにこの傾向をもつということとはできない。実際アトラクターに行きつかなかったばあいや、行きついたアトラクターが有限オートマトンのかそうでないか、などによる。

ノイズを与えてアトラクターからの遷移をみたのは、力学系としての安定性の意味だけではなくて別の意味もある。それは学習したアトラクターに後からある形でアクセスする(例えばその学習の想起でもいい)様子を、このようにノイズ印加という形で近似しようということである。このときに、ある程度のノイズの大きさでアトラクターが変わってしまうとすると、それは想起のたびに壊れてしまうことになる。実際ここでのノイズの閾値0.1はウェイトの大きさの数パーセントのオーダーである。一般に考えられているように汎化が行なわれるとある形に学習の形が安定化するのではなく、それが移り変わってしまうという非決定性が内在しているということが、ここでの注目点である。

4 議論

ここでみたのは、単純な再帰的ネットワークの学習に付随する実質的な学習の非決定性のお話であった。この構造が出現するのは、ネットワークのサイズや与えるサンプルの隠れた構造などによるかもしれない。しかし、ここでみたような例が存在するという事は非決定性が学習には伴いうるという傍証にはなっている。




Figure 2: 10000 ステップで学習を打ち切ったときに、答えが even/odd という形で出せる学習ができた時に学習終了とみなす。初期のウェイト値の空間のある2次元切断面に対し、学習できたか／できないか、がどのように分布しているかを示したのがこの図。点の打ってあるところが学習できた領域で、このうち特に濃い色で点がうってあるところが、空間認識オートマトンに収斂したところである。




Figure 3: 右側はアトラクターのまわりのベイスン構造。左側はあるアトラクターに収斂したときに最大強度 σ でノイズをウェイトにかけて再学習させる。このときに同じアトラクターに戻ってくるか、別なものに収斂するかを判定した。判定には、サンプルに使ったものとは別のサンプル ($L=100$) を用意し、それに対するアウトプットの違いで判定した。それぞれのアトラクターへ 10000 回の試行でどのくらいが収斂したかを計算して表している。

ここでより重要なことは、決定できないにもかかわらずうまくいってしまうというわれわれが日常観察するところの学習の逆説的な安定性をとくところ、にあるのはいうまでもない。

References

- [1] J.B. Pollack, The induction of dynamical recognizers. *Machine Learning*, 7:227–252, 1991.
- [2] M.Taiji, and T.Ikegami, Dynamics of internal models in game players *Physica D*, 134, 253–266. 1999.
- [3] T.Ikegami and M.Taiji Structures of Possible Worlds in a Game of Players with Internal Models (ps.zip file) *Acta Polytechnica Scandinavica Ma.* 91(1998)pp.283-292.
- [4] T.Ikegami, and M. Taiji, Imitation and Cooperation in Coupled Dynamical Recognizers (ps.zip file) 545–554. *Advances in Artificial Life* eds. Floreano, D. et al., Springer-Verlag, 1999).
- [5] I.Igari and T.Ikegami, Coevolution of Mind and Language. (submitted to the int'l conf. on Evolution of Language. (Paris, April, 2000).
- [6] 足し算を子どもに教える時に $17 + 3 = 20$ で、 $2 + 7 = 9$ でと教えていき、子どもは足し算とは何かを「学習」したようにみえたとする。実際応用問題として、 $32 + 7 = 39$ もできたとしよう。ところが $11 + 4 = 22$ をやらせるとうまくできない。その理由をきくと、7がないときはあらたに7を足す演算と考えたんだ、と答えたとする。これは学習してなかったといえるか。もちろん、足し算を教えた人の立場からすると学習してくれなかったわけだが、ではどのくらい、「例」をみせれば、教師の思い通りの演算を獲得するのか。また思い通りの演算を獲得したことを確かめる術はあるのか。こうしたクリプキの「プラスとクワス」の問題は、言語におけるアーガイル問題と等価なものであり、特殊ではなくて日常のありとあらゆる場面に潜んでいることが分かる。そうでなければ、変わったパズルの問題としてほっておけばよい。例えばクリプキ問題がひっかかる日常的な問題は、同じコンテキストを保って会話ができるか、人に水泳を教えるにはどうすればよいか、なぜ新しい状況で文法的に正しい文がつかれるか、などなど。
- [7] T.Ikegami, Generalization and Memory Structures of Dynamical Recognizers (to be submitted)
- [8] J.C. Sommerer and E. Ott, "A physical system with qualitatively uncertain dynamics, *Nature*, Vol. 365 (1993), 138.