

記憶容量制限下で時系列を逐次学習するニューラルネットワーク

郷 古 学[†] 菅 谷 至 寛[†] 阿 曾 弘 具[†]

本論文では、記憶容量制限下で時系列を逐次学習可能な、適応的逐次学習ネットワークモデル (Adaptive and Sequential Learning Network model : ASLN model) を提案する。提案モデルは入力として与えられる時系列情報の逐次学習が可能であり、記憶の忘却を行うことで記憶容量の有効利用を図りながら、周囲の環境の変化に適応的に知識を獲得する。モデルは入力時系列に含まれる要素と、その遷移に関する情報を記憶する。モデルは時系列の要素のなかでも入力頻度の高いものを重要と判断し、優先的に記憶する。また入力される要素の遷移に関する情報を状態ベクトルという形で表現し、階層型ニューラルネットワークにより記憶する。状態ベクトルは過去の入力系列の情報を保持しているため、提案モデルは文脈を表現することも可能である。本論文では計算機実験を行い、提案モデルが記憶容量の有効利用を図りながら、周囲の環境の変化に適応的に知識の獲得が可能であることを示す。

Neural Network for Sequential Learning of Temporal Sequences under Restriction of Memory Capacity.

MANABU GOUKO,[†] YOSHIHIRO SUGAYA[†] and HIROTOMO ASO[†]

In this paper, we proposed an adaptive and sequential learning network model (ASLN model). ASLN model is a neural network model for sequential learning of temporal sequences under restriction of memory capacity. The proposed model can successively learn elements and its transitions from input data given to the model under restriction of memory capacity. The model memorizes elements inputted high-frequency preferentially. Information on transition is represented as a state vector and stored in hierarchical neural network. The model can represent a temporal sequence which contains a context. We carried out computer simulations and confirmed that the proposed model is capable of learning the knowledge of temporal sequences with adapting to change in the environment with using a given memory capacity effectively.

1. ま え が き

本論文では時系列情報を扱う知的システムの構築を目的としている。時系列情報を扱うためにはその時系列に含まれる要素 (element) とそれら要素の遷移 (transition) の二つの情報を記憶し、利用する必要がある。更に時系列を扱う上で文脈を如何に表現し、利用するかという問題がある。文脈とは、本論文では同一の入力情報からでも、それより過去の入力系列に依存して異なる目的出力を得るような場合の過去の入力系列を意味する。

汎化性の高さやシステムの柔軟性という観点からニューラルネットワークを用いた時系列情報を扱う知的システムの構築に関する研究が盛んに行われている^{1)~4)}。しかし、ニューラルネットワークをシステムとして応用する場合、学習した知識を逸脱する環境においてはシステムが機能しないという適応性の問題があった。適応性の問題に対する一つの解決法に逐次学習 (入力情報そのものを学習すると同時に、その入力に対する出力を行う学習方法) がある。ネットワークへ入力される情報が周囲の環境を反映しているものとすれば、逐次学習ネットワークは常に環境の変化に適応的に学習していく。しかし、全ての入力情報を次々と学習・記憶し続けることは記憶容量の制限により不可能であるため、記憶容量制限下における逐次学習においては、記憶すべき情報を選別する機能が必要となる。この選別の基準として、時系列に含まれる要素の出現頻度が考えられる。すなわち、高頻度で出現する

要素 (以下パターンと呼ぶ) を重要なパターンとして優先的に記憶し、過去に重要なパターンだったが、環境の変化により重要ではなくなったパターンに関しては、そのパターンを記憶している領域に新たに重要となったパターンを記憶することで、記憶容量の有効利用が実現できる。以上の考察をもとに、記憶容量制限下において時系列情報を逐次学習するニューラルネットワークモデルの構築を目指した。

時系列情報を扱う従来のニューラルネットワークモデルのうち代表的なものとして Elman の提案したネットワーク (以下、Elman ネットと呼ぶ) がある⁵⁾。Elman ネットは学習により文脈依存的な入出力関係を実現することが可能である。しかし、事前に学習すべき知識を準備し、教師有り学習により学習するため、環境の変化への適応性に問題がある。また、Elman ネットは記憶容量制限下においては比較的少ない入力パターンでしか文脈依存的な入出力関係を実現することができないことが森田らにより指摘されている⁶⁾。

Barreto らにより提案されたモデル²⁾ は、入力された時系列情報の教師無し学習が可能であり、適応性の問題を解決するモデルであると考えられるが、ニューロンの数 (記憶容量) を上回るパターンが入力された場合は学習がうまくいかない。また、このモデルでは状態パターンと文脈パターンの2つのパターンから構成される入力パターンを時系列の要素と考えており、同じ状態パターンに対して異なる文脈パターンを付加することで異なる入力パターンを構成し、文脈に応じた入出力を実現している。そのため同じ状態パターンに対し複数の入力パターンを記憶する必要性が生じる場合があり、記憶容量という観点から効率的とはいえない。

[†] 東北大学大学院工学研究科電気・通信工学専攻
Department of Electrical and Communication Engineering, Graduate School of Engineering, Tohoku University




図 1 提案モデルの構造

本論文ではニューラルネットワークを応用する上でネックとなる適応性及び記憶容量制限の問題を同時に解決するモデルとして、適応的逐次学習ネットワークモデル (Adaptive and Sequential Learning Network model, 以下 ASLN model) を提案する。提案モデルを用いることにより、使用環境に適応する知的システムの構築が可能になる。

2. 適応的逐次学習ネットワークモデル

提案モデルは、フィードバック結合を持つネットワークで構成し、入力時系列に含まれるパターンを記憶する記憶層と、それらパターンの遷移情報を記憶する文脈ネットワークを持つ。パターンの記憶には芳澤ら⁷⁾の提案した自己連想記憶モデルを用いており、入力時系列情報に含まれるパターンのうち、入力頻度の高いパターンを優先的に記憶することができる。文脈ネットワークでは記憶層で記憶されたパターンの時系列上での順序 (遷移情報) を記憶する。

2.1 構造

提案モデルの構造を図 1 に示す。モデルは m_0 個のニューロンからなる入力層、 m_1 個のニューロンからなる記憶層、階層型のニューラルネットワークである文脈ネットワーク及び m_0 個のニューロンからなる出力層からなる。入力層の各ニューロンは記憶層の全てのニューロンと全結合している。時刻 t における入力層の i 番目のニューロンと、記憶層の j 番目のニューロンとの結合重みを $W_{ji}^{pa}(t)$ と表す。記憶層の j 番目のニューロンが持つ入力層との結合重みベクトルを、 $W_j^{pa}(t) = (W_{j1}^{pa}(t), W_{j2}^{pa}(t), \dots, W_{jm_0}^{pa}(t))$ と表す。また重みベクトルの大きさ $\|W_j^{pa}(t)\|$ をニューロン j の記憶パターンの信頼度 $R_j(t)$ と呼ぶ。

入力される時系列に含まれるパターンは入力層-記憶層間の結合重み $W_{ji}^{pa}(t)$ に蓄えられ、記憶層の 1 つのニューロンが 1 つのパターンを記憶する。記憶層の各ニューロンは、記憶パターンの信頼度 $R_j(t)$ と、角度閾値 $\theta_{max,j}(t)$ の情報を持つ。文脈ネットワークは状態層、中間層、想起層からなる 3 層の階層型ニューラルネットワークであり、状態層、想起層のニューロン数は m_1 個、中間層のニューロンの数は m_h 個である。モデルは記憶層から文脈ネットワークの状態層へとフィードバック結合を有しており、記憶層の j 番目のニューロンと状態層の j 番目のニューロン間で 1 対 1 で結合している。これらの結合重みは全て 1 で固定である。状態層のニューロン j の状態を $s_j(t)$ と表す。時刻 t における状態ベクトル $s(t)$ を $s(t) = (s_1(t), s_2(t), \dots, s_{m_1}(t))$ と表す。文脈ネットワークは各層間の結合重みを学習により更新する。想起層のニューロン j から出力層の

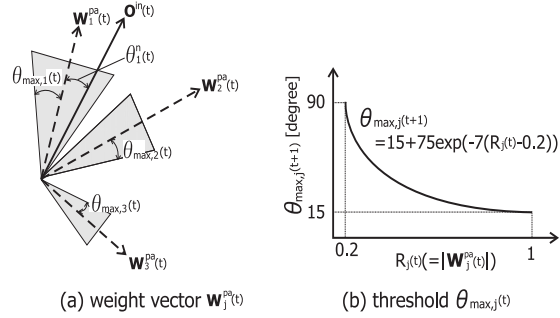


図 2 重みベクトルと角度閾値

ニューロン i への結合重みは、入力層のニューロン i から記憶層のニューロン j への結合重みに一致させる。

提案モデルは入力される時系列を学習する記憶処理と、学習した時系列を出力する想起処理の 2 つの処理を同時に行う。

2.2 記憶処理

記憶処理では入力時系列に含まれるパターンを記憶するパターン記憶処理と、遷移情報を記憶する遷移記憶処理の 2 つの処理が同時に行われる。更に、記憶容量の効率的な利用を目的とした忘却処理及び、角度閾値の更新が行われる。

2.2.1 パターン記憶処理

入力時系列に含まれるパターンの記憶は、芳澤らの提案した自己連想記憶モデル⁷⁾を用いて行う。

時刻 t において、あるパターンが入力層に入力されると、記憶層のニューロンの中で入力パターンベクトルと結合重みベクトルとのなす角が角度閾値以下で、かつ最小となるニューロン j_{me} が選択される (図 2(a) の例では、 $j_{me} = 1$ となる)。選択ニューロンが決定されない場合は $j_{me} = 0$ とする。

選択ニューロン j_{me} の重みベクトルを入力パターンベクトルとのなす角が減少するように Oja 則⁸⁾を用い更新する。つまり入力パターンは重みベクトルの向きとして記憶される。重みベクトルの大きさは更新されるごとに増加し 1 に近づく⁸⁾。すなわち、信頼度 $R_j(t)$ は入力パターンの提示回数に対応して増加する。

パターン記憶処理の後に、全ての重みベクトル $W_j^{pa}(t)$ の大きさを一定量だけ減ずる忘却処理を行う ($j_{me} = 0$ でも行う)。忘却処理により、あるパターンが信頼度の高い頑健な記憶として形成された後、そのパターンの提示回数が減少した場合、記憶パターンの信頼度は徐々に低下し、新たに重要な入力パターンを記憶することが可能となる。これにより記憶容量の有効利用を実現する。

次に、角度閾値を図 2(b) に示すような信頼度の関数に従って更新する。これにより、信頼度が高い記憶パターンは信頼度が低い記憶パターンと比較して小さな角度閾値を持つため、新しい入力パターンに対して影響を受けにくく頑健になる。また初期状態 ($t = 0$) において、全ての角度閾値は 90 度とする。

2.2.2 遷移記憶処理

文脈ネットワークでは遷移記憶処理を行う。時刻 $t-1$ における状態層の状態ベクトル $s(t-1)$ は時刻 $t-1$ までの入力時系列に対応する状態を表している。

時刻 t では、まず各層間の重みを記憶層の選択ニューロンの発火を教師信号としたバックプロパゲーション法により学習更新する。教師信号を活性ベクトル $\mathbf{a}(t) = (a_1(t), a_2(t), \dots, a_{m_1}(t))$ として次のように定義する。

$$a_j(t) = \begin{cases} 1 & \text{if } j = j_{me} \\ 0 & \text{otherwise} \end{cases} \quad (j = 1, 2, \dots, m_1) \quad (1)$$

この学習は、 $t-1$ までの状態ベクトル $\mathbf{s}(t-1)$ の入力に対し、時刻 t での入力に対応する活性ベクトル $\mathbf{a}(t)$ を出力するようになされている。

続いて、状態 $s_j(t-1)$ を更新する。

$j_{me} \neq 0$ のとき

$$s_j(t) = \begin{cases} 1 & \text{if } j = j_{me} \\ \alpha s_j(t-1) & \text{otherwise} \end{cases}$$

$j_{me} = 0$ のとき

$$s_j(t) = s_j(t-1) \quad (j = 1, 2, \dots, m_1) \quad (2)$$

ただし α は $0 \leq \alpha < 1$ であり減衰定数と呼ぶ。初期状態において全ての状態は 0 とする。遷移記憶処理では教師信号を用いた学習がなされるが、教師信号はネットワークの内部で生成され、特別な教師データは不要であることから、ASLN model は全体として教師無し学習を行うニューラルネットワークモデルである。

2.3 想起処理

時刻 t において、あるパターンを入力として与えると、モデルは記憶処理を行い、状態ベクトル $\mathbf{s}(t)$ が式 (2) により定まる。この状態ベクトルから文脈ネットワークの想起層の出力が最大となる l を求め、出力パターン $y_i(t) = W_{li}^{pa}(t)$ ($i = 1, 2, \dots, m_0$) を出力する。 $W_{li}^{pa}(t)$ は想起層の l 番目のニューロンと出力層との間の重みで、記憶層の l 番目のニューロンの記憶パターンと同じである。提案モデルはあるパターンが入力されると、自らの記憶に基づき、そのパターンの後に入力されるはずのパターンを出力(想起)する。このような処理を想起処理と呼ぶ。想起処理は記憶処理に続いてすぐに行われる。

ここで提案モデルの動作についてまとめる。時刻 t にモデルに対してパターンが入力されると、入力層から記憶層へ情報が送られる。記憶層においては入力層からの情報を元に選択ニューロン j_{me} を決定し、結合重みベクトル $W_{j_{me}}^{pa}(t)$ の更新、忘却処理及び角度閾値の更新を行う(パターン記憶処理)。同時に活性ベクトル $\mathbf{a}(t)$ を求め、文脈ネットワークの結合重みの更新を行う(遷移記憶処理)。続いて状態ベクトルを $\mathbf{s}(t)$ に更新し、それを元に出力層からパターンを出力する(想起処理)。この出力は次に入力されるはずのパターンになっていることが期待されている。以上が時刻 t においてパターンが入力されたときのモデルが行う処理である。

選択ニューロンが決定されない場合には、文脈ネットワークの重みの更新は行われず、状態ベクトルも変化しない。この性質により、記憶容量が制限された場合には、入力頻度の高いパターンがパターン記憶処理され、それをを用いた時系列の学習がなされる。




図 3 時系列データ

状態ベクトル $\mathbf{s}(t)$ は、記憶層のどのニューロンがどれだけ前に活性化したかという履歴情報を表している。式 (2) により決まる $s_j(t)$ の値は、一般的に、 $s_j(t) = \alpha^k$ ($k \geq 0$) と表され、これは記憶層のニューロン j に対応する入力が k 時刻前、すなわち、 $t-k$ 時刻に生じたことを表している。これは、文脈ネットワークが持つパターン識別能力が十分ならば、提案モデルは N 重マルコフモデルを表現できることを意味する (N は計算精度に依存する)。

3. 実験結果及び考察

計算機実験を行い、提案モデルが記憶容量制限下において時系列の逐次学習が可能であることを示す。また、環境の変化に伴い記憶がどのように変化するかを確認した。

実験では提案モデルに図 3 に示す異なる 2 種類の時系列 ((a):時系列 1, (b):時系列 2) を入力する。図 3(a) の場合はモデルに対して $A \rightarrow B \rightarrow (C \text{ or } D) \rightarrow E \rightarrow B \rightarrow F \rightarrow E \rightarrow (G \text{ or } H) \rightarrow F \rightarrow A \rightarrow \dots$ という順番でパターンを入力する、(C or D) と (G or H) に関しては、どちらか一方のパターンを等確率でランダムに選択し入力する。記憶処理、想起処理は各パターンの入力毎になされる。全てのパターンの入力完了した(パターンが順番に 9 個入力された)時を 1 ステップとする。実験で用いたパラメータは $m_0 = 49(7 \times 7)$ の文字画像, $m_1 = 4$, $m_h = 4$, $\alpha = 0.7$ とした。

実験は 1200 ステップまで行う。前半の 600 ステップまでを環境 1(env1) とし時系列 1 をモデルに繰り返し入力し、後半の 601 から 1200 ステップまでを環境 2(env2) とし時系列 2 をモデルに繰り返し入力する。入力時系列の変化は環境の変化を表現している。モデルは環境の変化に伴い、自らが記憶している時系列を変化させることが期待される。

実験では A から H の 8 つのパターンが入力されるのに対し、モデルの記憶容量を 4 とした(記憶層に 4 つのニューロンしか持たない)。モデルは入力頻度の高いパターンを優先的に記憶し時系列を表現することが期待される。

時系列の入力によりモデルが記憶した知識を確認するために、モデルにパターン A を入力(初期パターン)し、出力(想起)されたパターンをモデルに対し入力としてフィードバックし、新たな出力パターンを得るという作業を繰り返して順番に出力されるパターンを確認した(図 4)。図中のパターンは想起パターンとして得られた出力層ニューロンの重みベクトルの各成分の大きさを、正規化して得られたものである。初期パターン A 以外のパターンは、モデル自身の想起によ




図 4 想起結果

り得られたものである

図 4(a) は 600 ステップにおける想起結果である。これを見ると時系列 1 に含まれるパターン中、入力頻度の高い A, B, E, F により時系列 1 が表現されていることが確認できる。同様に 1200 ステップの想起結果 (図 4(b)) を見ると時系列 2 に含まれるパターン中、入力頻度の高い A, D, E, H により時系列 2 が表現されていることが確認できる。この結果から、提案モデルは周囲の環境から入力として与えられる時系列情報を逐次学習することが可能であり、記憶容量を超える数のパターンから構成される時系列を記憶する場合、入力頻度の高いパターンを優先的に記憶し時系列を表現することが示された。

次に環境の変化に伴いモデルが記憶する時系列の変化について着目する。1000 ステップにおける想起結果を確認したところ、パターン A の入力をきっかけに $A \rightarrow E \rightarrow E \rightarrow A \rightarrow E \rightarrow E \rightarrow \dots$ という時系列を繰り返し出力することを確認した。モデルは環境 1 においてはパターン A, B, E, F を記憶しているが、環境の変化に伴い入力頻度の下がったパターン B, F は徐々に忘却され、新たに環境 2 における高頻度入力パターン D, H の記憶の形成が始まる。忘却は徐々に進むため、環境が変化した直後は D, H が入力されても選択ニューロンは決定せず、文脈ネットワークの重みの更新は行われない。結果的に環境 1, 2 の両方で高頻度で入力されるパターン A, E のみで時系列が表現されたものと考えられる。

また、1100 ステップにおける想起結果を確認したところ、 $\dots \rightarrow D \rightarrow E \rightarrow H \rightarrow \dots$ という時系列を繰り返し出力することを確認した。この段階では環境 1 の記憶が忘却されて、新たにパターン D, H を記憶している。出力された時系列は時系列 2 の一部分である。これは環境の変化に伴い文脈ネットワークの結合重みが再更新され、一時的にパターン A が想起されなくなったものと考えられる。更に学習を続けると図 4(b) のように環境 2(env2) で記憶することが期待される時系列の記憶を形成する。

以上の結果から、提案モデルは環境が変化した場合、まず二つの環境で共通して入力頻度が高いパターンを用いて時系列を表現する。そして新たな環境で入力頻度の高いパターンの記憶が形成されると、文脈ネットワークの結合重みの更新がなされ、新たな時系列の記憶が形成されることを確認した。

4. まとめ

本論文では記憶容量制限下において時系列情報を逐次学習するニューラルネットワークモデルとして、適応的逐次学習ネットワークモデル (ASLN model) を提案した。提案モデルが入力として与えられる時系列情報を逐次的に学習可能であり、記憶容量の有効利用を図りながら、周囲の環境の変化に適応的に知識の獲得が可能であることを示した。

提案モデルは、ニューラルネットワークを応用する上でネックとなる適応性及び記憶容量制限という 2 つの問題を同時に解決している。また、逐次学習が可能であることから、実際に利用しながら、より詳細な知識を獲得する知的システムの構築が可能になる。

今回提案したモデルは入力として時系列情報を繰り返し与える必要がある。そのため環境の変化に対する即応性という点では問題が残る。即応性の向上を実現するために、より少ない回数で学習が可能となるようにする必要があり、そのためには文脈ネットワークにおける学習法の検討等が考えられる。この問題に関しては今後の課題とする。また今後、実際のロボットの行動データ等を用いるなど、提案モデルの応用に関する実験についても進めていく予定である。

参考文献

- 1) Bugmann, G., Koay, K. L., Barlow, N., Phillips, M. and Rodney, D.: Stable encoding of robot trajectories using normalised radial basis functions: Application to an autonomous wheelchair, *Proc. Int. Sym. Robotics (ISR '98)*, pp. 232-235.
- 2) Barreto, G. A. and Araújo, A. F. R.: Unsupervised learning and recall of temporal sequences: an application to robotics, *Int. J. Neural Systems*, Vol. 9, No. 3, pp. 235-242 (1999).
- 3) 下崎守朗, 國吉康夫: 記憶に基づいた時系列パターン予測を行うニューラルネットワークモデル, 日本ロボット学会学術講演会概要集 3H15, pp. 192-195. 大阪, 2002.
- 4) Araújo, A. F. R. and Barreto, G. A.: Context in temporal sequence processing: A self-organizing approach and its application to robotics, *IEEE Trans. Neural Networks*, Vol. 13, No. 1, pp. 1-13 (2002).
- 5) Elman, J.: Finding structure in time, *Cognitive Science*, Vol. 14, pp. 179-211 (1994).
- 6) 森田昌彦, 松沢浩平, 諸上茂光: 非単調神経素子の選択的不感化を用いた文脈依存的連想モデル, 電子情報通信学会論文誌 (D-II), Vol. 85, No. 10, pp. 1602-1612 (2002).
- 7) 芳澤伸一, 道木慎二, 大熊繁: 記憶容量の制約下での追加学習を目的とする新しい連想記憶システムの提案, 電子情報通信学会論文誌 (D-II), Vol. 82, No. 6, pp. 1072-1081 (1999).
- 8) Hertz, J., Krogh, A. and Palmer, R. G.: ニューラルコンピュータ: 統計物理学からのアプローチ, トッパン (1994). (笹川辰弥, 呉勇 訳).