

H_001

線形連想写像を用いた相互想起セルラニューラルネットワーク

Cellular Neural Networks for Hetero Associative Memory Using a Linear Associative Mapping

難波 道弘[†]

Michihiro NAMBA

渡辺 智美[†]

Tomomi WATANABE

1. まえがき

ニューラルネットワークにおける連想記憶機能はその性能の高さから、さまざまな実システムへの適用が試みられている。しかしながら、BAMなどの相互想起型連想記憶モデルは記憶パターンの制約条件の影響による記憶容量の低さから、実用的システムの適用は容易ではないといわれている。その中で、擬似緩和法をBAMに導入したPRLABは、記憶容量を大幅に改善したモデルとして知られている。

一方、セルラニューラルネットワーク(CNN)は、相互結合型の局所接続ニューラルネットワークである。これまでに画像処理、時系列処理など多くの応用例が報告されている。またCNNは自己想起型連想記憶に有効であることも示され、パターン認識や肝臓病診断、自動車の異常音診断などへの応用例が報告されている[1]。

本研究では線形連想写像と自己想起型連想記憶CNNを併用したモデルを提案し、シミュレーション結果をもとにその有用性について検討する。

2. 連想記憶CNN

CNNはセルと呼ばれる単純なアナログ回路をマトリクス状に配置したものであり、では各セルが近傍セルの影響を受けながら微分方程式のダイナミクスで変化する。各セルでの微分方程式を一括してベクトル記法で表現すると次式が得られる。

$$\dot{x} = -x + Ty + I \quad (1)$$

$$y = \frac{1}{2}(|x+1| - |x-1|) \quad (2)$$

ここで x は状態ベクトル、 T は近傍のセルからの影響を表すテンプレート行列、 y は出力ベクトル、 I はしきい値ベクトルである。また出力 y は入力 x の線形区分関数で表される。CNNでは記憶させたいパターンを結合係数行列へ写像することにより、システムを構

成している。また、記憶パターンとシステムの漸近安定平衡点とが対応していることになる。

次に連想記憶CNNの設計法について述べる。成分が ± 1 である q 個のパターン $\alpha_i (i = 1, \dots, q)$ を記憶ベクトルにもつCNNを設計する場合、各記憶パターン α_i を定数 $K (K > 1)$ 倍して得られるベクトル β_i を平衡点であると仮定すると、次式を得る。

$$\beta_i = K\alpha_i \quad (3)$$

したがって、 $\alpha_i (i = 1, \dots, q)$ を記憶ベクトルにもつCNNを設計するためには、次式を同時に満たすテンプレート行列 T およびしきい値ベクトル I を定めればよいことになる。これらを適切なものにするにより、CNNは安定状態に収束する。

$$\left. \begin{aligned} -\beta_1 + T\alpha_1 + I &= 0 \\ -\beta_2 + T\alpha_2 + I &= 0 \\ \dots \\ -\beta_q + T\alpha_q + I &= 0 \end{aligned} \right\} \quad (4)$$

ここで行列 A, B を次のようにおく。

$$\left. \begin{aligned} A &= (\alpha_1 - \alpha_q, \alpha_2 - \alpha_q, \dots, \alpha_{q-1} - \alpha_q) \\ B &= (\beta_1 - \beta_q, \beta_2 - \beta_q, \dots, \beta_{q-1} - \beta_q) \end{aligned} \right\}$$

式(4)において各式と α_q に関する最後の式との差をとり、式(5)の行列表示を用いると、次式を得る。

$$\left. \begin{aligned} B &= TA \\ I &= \beta_q - T\alpha_q \end{aligned} \right\} \quad (5)$$

一般的に(5)の第1式を満たすテンプレート行列 T を求めるには、大規模かつ複雑な行列演算を要するが、CNNでは疎な結合性から、計算量を削減することができる。その際に特異値分解を用いるのが一般的である。

3. 相互想起セルラニューラルネットワーク

図1に本稿で提案する相互想起CNNの概要を示す。なお、行列 W_{AB} は次の擬似逆行列を用いて求められる。

$$W_{AB} = B(A^T A)^{-1} A^T \quad (6)$$

[†]山梨英和大学人間文化学部
Faculty of Humanities, Yamanashi Eiwa College




図 1: 相互想起 CNN

動作アルゴリズムは以下のとおりである。

1. 記憶パターンから各自己想起 CNN のテンプレート T としきい値ベクトル I を求める。
2. 相互想起の相関行列を式 (6) を用いて求める。
3. 初期パターンの組を与える。
4. 一方の自己想起 CNN(CNN(A)) に数ステップ自己想起させる。
5. 相関行列 W_{AB} をかけ、相互想起を行う。
6. 他方の自己想起 CNN(CNN(B)) に数ステップ自己想起させる。
7. 相関行列 W_{BA} をかけ、相互想起を行う。
8. 4. に戻り、自己想起と相互想起を数回繰り返す。

このように、自己想起と相互想起を交互に繰り返し、所望のパターン対を想起するというものである。

4. シミュレーションおよび結果

有用性を検証するため、所望のパターン対を想起できるかというシミュレーションを提案モデルおよび PRLAB について行った。記憶パターンは2値のランダムパターンとし、初期パターンは一方の自己想起 CNN の記憶パターンに一樣雑音を重畳したパターンとした(簡単のため、他方の自己想起 CNN には初期パターンを与えない)。使用した CNN, PRLAB のサイズは $6 \times 6, 7 \times 7, 8 \times 8, 9 \times 9, 12 \times 12$ の5種類とし、相互想起のペアには同じサイズのものを組み合わせて用いた。記憶パターンの組数はそれぞれ 10, 16, 24, 30, 50, ノイズの強さは $0.01 \leq \sigma \leq 0.2$ の20種類とした。また、CNN の近傍は $r = 2$ とした。




図 2: PRLAB の完全想起率 (CNN の完全想起率はすべて 100%)

図 2 に PRLAB の完全想起率を示す。PRLAB の完全想起率は 6×6 ではほぼ 100% となっているが、それ以外ではノイズの強さおよびサイズによって低下していることがわかる。なお、PRLAB の完全想起率が全体的に低いのは、サイズに比べて記憶パターン数が多かったためと考えられる。一方、相互結合型 CNN はノイズの強さ・サイズに関わらず、100% の完全想起率が得られた。連想記憶 CNN が本来有する高い自己想起能力に相互想起機能を付加することで、高い相互想起機能を実現しているといえる。

5. むすび

本研究では、線形連想写像と自己想起型連想記憶 CNN を併用した相互想起型連想記憶 CNN をモデルを提案した。PRLAB との比較シミュレーションを行い、その有用性を確認した。今後はさらに強いノイズを用いるなどにより提案モデルの想起能力の詳細を調べ、実問題へ適用していきたい。

参考文献

- [1] Z.Zhang, M.Namba et al., "Cellular Neural Networks and Its Application to Abnormal Detection", J. of Information Processing, pp. 587-604, 2005.