

Title	有限オートマトンネットワークによる時系列情報処理
Sub Title	Time series information processing by networking finite state neural networks
Author	櫻井, 彰人(SAKURAI, AKITO)
Publisher	
Publication year	2009
Jtitle	科学研究費補助金研究成果報告書(2008.)
JaLC DOI	
Abstract	有限状態オートマトンネットワークの実装として、特殊な構造をもったニューラルネットワークを提案した。実験により、時系列データの構造認識の例として、言語の文法範疇が精度良く学習できることを確認した。関連して、従来のSRN (simple recurrent network) では時系列データの構造認識に必要なスタックが表現できないことを理論的に証明した。
Notes	研究種目：基盤研究(C) 研究期間：2006～2008 課題番号：18500118 研究分野：総合領域 科研費の分科・細目：情報学・知能情報学
Genre	Research Paper
URL	https://koara.lib.keio.ac.jp/xoonips/modules/xoonips/detail.php?koara_id=KAKEN_18500118seika

慶應義塾大学学術情報リポジトリ(KOARA)に掲載されているコンテンツの著作権は、それぞれの著作者、学会または出版社/発行者に帰属し、その権利は著作権法によって保護されています。引用にあたっては、著作権法を遵守してご利用ください。

The copyrights of content available on the Keio Associated Repository of Academic resources (KOARA) belong to the respective authors, academic societies, or publishers/issuers, and these rights are protected by the Japanese Copyright Act. When quoting the content, please follow the Japanese copyright act.

様式 C-19

科学研究費補助金研究成果報告書

平成 21 年 3 月 31 日現在

研究種目：基盤研究(C)

研究期間：2006～2008

課題番号：18500118

研究課題名（和文） 有限オートマトンネットワークによる時系列情報処理

研究課題名（英文） Time series information processing by networking finite state neural networks.

研究代表者

櫻井 彰人 (SAKURAI AKITO)

慶應義塾大学・理工学部・教授

研究者番号：00303339

研究成果の概要：

有限状態オートマトンネットワークの実装として、特殊な構造をもったニューラルネットワークを提案した。実験により、時系列データの構造認識の例として、言語の文法範疇が精度良く学習できることを確認した。関連して、従来の SRN (simple recurrent network) では時系列データの構造認識に必要なスタックが表現できないことを理論的に証明した。

交付額

(金額単位：円)

	直接経費	間接経費	合計
2006 年度	1,200,000	0	1,200,000
2007 年度	1,100,000	330,000	1,430,000
2008 年度	1,100,000	330,000	1,430,000
年度			
年度			
総 計	3,400,000	660,000	4,060,000

研究分野：総合領域

科研費の分科・細目：情報学・知能情報学

キーワード：人工知能アーキテクチャ

1. 研究開始当初の背景

脳の情報処理機構モデルとしては、神経素子をネットワーク上に配置した神経回路網モデル（ニューラルネットワーク）が代表的である。ネットワーク構造として DAG を考えれば、フィードフォワード型ネットワークという典型的な人工ニューラルネットワークが得られる。脳内の神経素子ネットワークは、フィードバック結合はあるものの、主とした情報の流れは抹消から中枢に、そして中枢から抹消へとなっている。フィードフォワード型はこの脳内の情報の流れを擬似しているとはいえ、遅延をいれようといれまいと、本質的に、入力から出力への関数であり、時系

列的な処理が表現できるわけではない。

2. 研究の目的

本研究では、このフィードフォワード型ニューラルネットワークにおいて、神経素子に代えて有限状態オートマトンを置いたものに相当するニューラルネットワークを提案し、時系列処理が自然に表現できるようにしたモデルを提案する。

人間の高次機能の代表は、言語機能であり、それは典型的な時系列処理である。本研究では、この事実に鑑み、言語処理機能のモデル化が可能なモデルとすることを目指す。

3. 研究の方法

各有限状態オートマトンのモデルとして、SRN (simple recurrent neural network) を用いるもの、ESN (echo state network) を用いるもの、SRN 中のシグモイド素子を閾値素子としたものを試みる。

一方、言語処理モデルとしてこれらを用いるために、言語実データを複数の有限状態オートマトンで説明するモデルとその学習方法を検討する。

4. 研究成果

まず、最初に行った基礎的な成果について記し、その後、個々の成果について記す。

SRN (simple recurrent neural network) を複数ネットワーク構造としたモデルを用い、データとして正規言語（有限状態オートマトンで生成する）のサンプルを用いた学習実験を行った。この実験では、学習の収束が非常に遅いのみならず、本来記号化して学習されるべき同一グループの終端記号、すなわち、同一の非終端記号に属する終端記号が、殆ど記号化されない、すなわち、何らかの意味での内部活動状況がクラスタリングされないことを発見した。

Elman の SRN を用いた実験では簡単な文脈自由言語を用い、次単語予測を学習させることにより、終端記号である単語の文法範疇に対応して、ネットワーク内活動状況がクラスタリングされると報告されている。

本研究で同様な結果が得られないのは、Elman の実験に比し、ネットワークの自由度が高い故と考えられる。なお、別途我々が行った、Elman 実験の追試では、ネットワークの複雑度を上げると急速に必要学習データ量が増加すること、Elman 主張の結果は不安定であること、すなわち、実験毎に良い結果が得られることも全く得られないことがあった。

そこで、本研究においては、不安定性の理由の探求、実質的にデータ量を増加させることでの学習結果の改善、不安定性の原因がそもそも SRN では記号学習が不可能な故であろうと考え、より安定的な学習方法（ネットワークに対する条件を変更すると ESN (echo state network) と等価であることが後に判明した独自の方法）の探求等を行った。

標準シグモイド素子（活性化関数が $1/(1+\exp(-x))$ で表される素子）を用いたネットワークでは文脈自由言語が学習できないことを理論的に示した。本結果は、本研究で扱う有限状態オートマトンについての制限ではなく、従って、我々のアプローチの原理的正しさを示している。

より正確に述べると、次の定理が成立する。

一般に RNN (recurrent neural network) が言語 $\{a^n b^n \mid n > 0\}$ が認識できる必要十分条件は、 P_ω の点がすべて Q_ω に属するかまたはある $q \in Q_\omega$ に対し $W^{u,-1}(q) = W^{u,f^{-1}}(q)$ が成立することである。ただし、

$$P_\omega \text{ は } \left\{ f_+^n(s_0) \mid n > 0 \right\} \text{ の集積点の集合}$$

$$Q_\omega \text{ は } \left\{ f_+^{-n}(s_0) \mid n > 0 \right\} \text{ の集積点の集合}$$

$$W_{loc}^{s,f}(q) = \left\{ y \in U_q \mid \lim_{m \rightarrow \infty} \text{dist}(f^m(y), q) = 0 \right\}$$

$$W_{loc}^{u,f}(q) = \left\{ y \in U_q \mid \lim_{m \rightarrow \infty} \text{dist}(f^{-m}(y), q) = 0 \right\}$$

$$W^{s,f}(q) = \bigcup_{i \geq 0} f^{-i}(W_{loc}^{s,f}(q))$$

$$W^{u,f}(q) = \bigcup_{i \geq 0} f^i(W_{loc}^{u,f}(q))$$

とする。

なお、上記で「不安定」と記しているのは、上記言語の部分言語は実現できるのだが、各部分言語を実装するパラメータの値が、近い言語に必ずしも近くなっていないからである。上記言語に実装可能な部分言語があること、それが「不安定」なことは下記の例からわかる。

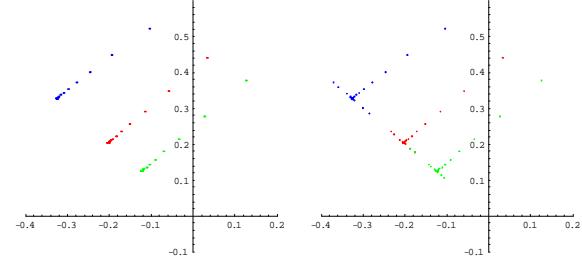


図 1. 左図では $\{f^{-n}f^{n+p} \mid 40 \geq n \geq 1\}$ (赤)、 $\{f^{-n+1}f^{n+p} \mid 40 \geq n \geq 1\}$ (青)、そして $\{f^{-n}f^{n+1} \mid 40 \geq n \geq 1\}$ (緑)、ただし $p = (0.5, 0.95)$ 。右図と左図との違いは、右図が $70 \geq n \geq 41$ と n がより大きい範囲の動きを図示したものである点である。

次に実質的に学習データ量を増加させる方法の検討とその結果について記す。

言語の文法学習では文法範疇の学習が重要である。しかし、文法範疇は文法を定義するために必要となる抽象的な存在であり、個々の学習サンプルには存在しない。大量の学習サンプルがあり、正しい文法範疇がわかつていれば、その文法範疇の妥当性が明確に確認できるという再帰的定義的なものである。

Elman らの SRN を用いた実験では、仮定する同一範疇の要素をできる限り入れ替えた多量の文例を学習サンプルとした。しかし、現実の言語サンプル数は（相対的に）遙かに少数であり、単純な計数によつたのでは推定できないのが範疇である。

この課題を多数の有限状態オートマトンを用いて解決するのであるが、そのためには、実質的に少数な学習サンプルを多数に見せる必要がある。その方法として、本研究では、

有限状態オートマトンの多数性を生かし、可能な文法範疇定義をランダムに多数生成し、その中の妥当なもののみが使われるよう学習する学習アルゴリズムを考えた。この「多数の有限状態オートマトン」を用いるアイデアは別途述べる。

多数の文法範疇定義を用いた場合に実際に SRN で文法学習がより確実に容易にできることを検証する実験を行った。図 2 に実験に用いたネットワーク構成を示す。

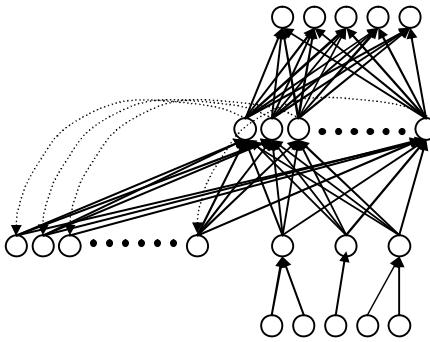


図 2. 文法範疇学習の基礎実験に用いたネットワーク。右下の回路が範疇を学習する部分である。

実験結果の一部を図 3 に示す。

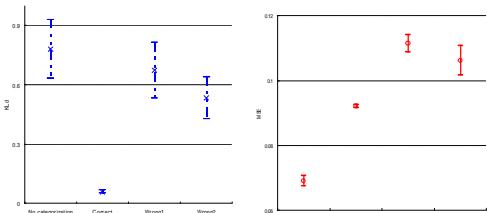


図 3. 左図は左から、範疇を与えたなかった場合、正しい範疇、誤った範疇 1、誤った範疇 2 をそれぞれ与えた場合の汎化誤差を表す。右図は、左図と対応する各場合の、学習誤差を表す。

図 3 からわかるように、正しい範疇を与えると誤った範疇を与えた場合より、次単語予測誤差(分布の Kullback-Leibler divergence で計る)に関して、学習誤差も汎化誤差も最少となることがわかった。この学習誤差最少と汎化誤差最少を達成する文法範疇(の定め方)が同一であるということは、実験上では、排他的な範疇に関して確認された。

すなわち、このような場合には学習誤差最少の文法範疇を選べば、汎化誤差も最少となっている可能性が高いということである。

次に「多数の有限状態オートマトン(をモデル化したニューラルネットワーク)からなるニューラルネットワーク」の提案・理論的検

討・実験結果について記す。

ネットワークの全体構造を図 4 に示す。このネットワークは簡易的な記述では SRN (simple recurrent network) と同一であるが、中間素子の個数・活性化関数、結合加重の設定方法、学習方法において SRN とは全く異なる。

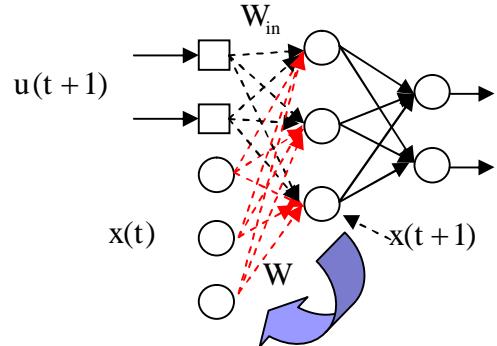


図 4. 提案する「多数の有限状態オートマトンからなるネットワーク」の構造。この図のみでは SRN と同一であるが実装は全く異なる。本文に記す。

提案ネットワークでは、中間素子の活性化関数は閾値関数(ステップ関数)であり、中間素子は多数(実験では 500 程度を用いた。SRN では 30 個程度)用意し、入力素子から中間素子への結合荷重は $[-1, 1]$ からランダムに設定し(学習によって変更することはない)、中間素子から出力素子への結合は、教師パターンとの二乗誤差を最小にするように設定する(繰り返し計算は必要ない)。

ところが、このネットワークと類似なアイデアに基づく ESN (echo state network) は既に提案され、chaotic な時系列を非常に高い精度で近似・予測することが発表されていた。

ESN は構造上は図 4 と同じであるが、中間素子の活性化関数として標準シグモイド関数を用い、入力素子から中間素子への結合荷重からなる行列 W_{in} の固有値の最大絶対値が 1 以下であるという条件を課している。

我々は ESN を用いて、(対応する括弧のリストという文字列である)言語 $\{ a^n b^n \}$ の学習実験を行ったが、全く近似できなかった。この言語は n を真に正整数の範囲にとるとその認識にスタックが必要となる、最も簡単な文脈自由言語である。実際には有限の範囲で学習しているが、ESN での学習は困難であった。一方、我々の提案するネットワークでは学習可能であった。

ESN が精度よく近似する対象は微分方程式系で記述される chaotic な時系列であり、我々の学習対象は記号的な時系列である。そこに違いの根源があると考え、それを埋める方法を考察した。

ESN において結合荷重行列の固有値絶対値

を1以下に抑えているのは、標準シグモイド関数によるラッチアップを回避するためである。一方、我々の目標とする記号計算では、逆に、シグモイド関数によるラッチアップがクラスタリングを促し、記号的学習が可能となると予想された。

そこで、結合荷重行列の固有値の絶対値の最大値が1を越え、実際に絶対値が1を越える固有値が多数になるよう、ランダムに設定した結合荷重をスケールした結合荷重行列を用いて、実際に文法範疇の学習が可能であることを示すべく実験を行った。

対象言語として $\{a^n b^m a^l\}$ の学習・予測実験を行った。Chomsky階層では正規言語である。特徴は、 a としては、 $\{a_1, a_2, a_3, a_4\}$ 、 b としては、 $\{b_1, b_2, b_3, b_4\}$ が許されるが、学習サンプルにはその一部しか現れないという点である。 a と b とは、第一グループ $\{a_1, a_2, b_1, b_2\}$ 、第二グループ $\{a_3, a_4, b_3, b_4\}$ とに分けられ、学習サンプルの一文には同一グループからしか出現しないが、テストサンプルにはすべての組み合わせが出現しうるという設定である。

結果を次の表1と表2に示す。

	提案手法	既存手法
解分布とのKLD	0.61	2.156

表1. 設定問題から考えられる解分布を考え、その分布との予測分布との距離をKLD (Kullback-Leibler divergence)で表した

	提案手法	既存手法
頻度分布とのKLD	1.21	0.61

表2. 実際に使用した学習サンプルから得られる頻度分布と予測分布との距離をKLDで表現した

表1と表2からわかるように提案手法では文法範疇を(おそらく)推定し、解分布により近い分布で出力予測をするのに対し、既存手法では、学習サンプルの分布をよりよく近似した出力予測をしていることがわかる。

以上より、提案している「多数の有限状態オートマトンからなるネットワーク」では、文法範疇という記号系の学習を従来手法よりよく行っていることが示された。

5. 主な発表論文等 (研究代表者、研究分担者及び連携研究者には下線)

〔雑誌論文〕(計4件)

1. A. Sakurai and Y. Shinozawa. Linguistic Productivity and Recurrent Neural Networks. In V. Kordic (ed.), Recurrent Neural Networks, 査読有, pp.43-60,

- I-Tech Education and Publishing (2008).
2. Y. Suhara, H. Toda and A. Sakurai. Extracting related named entities from blogosphere for event mining. Proc. 2nd International Conference on Ubiquitous Information Management and Communication (ICUIMC), 査読有, vol.1, pp.225-229 (2007).
3. Y. Suhara, H. Toda and A. Sakurai. Event mining from the Blogosphere using topic words. Proc. International AAAI Conference on Weblogs and Social Media (ICWSM), 査読有 (2007).
4. Y. Suhara and A. Sakurai. A Simple Computational Model for Classifying Small String Sets. Proc. Brain-inspired Information Technology 2006, 査読有 (2006).

6. 研究組織

(1)研究代表者

櫻井 彰人 (SAKURAI AKITO)

慶應義塾大学・理工学部・教授

研究者番号 : 00303339

(2)研究分担者

該当なし

(3)連携研究者

該当なし