

TCP/IP Network 及び Echo State Network を用いた学習機モデル

Learning model using TCP/IP network combined with Echo State Network

丸山典宏 *1
Norihiko Maruyama岡瑞起 *2
Mizuki Oka阿部洋文 *2
Hirotake Abe池上高志 *1
Takashi Ikegami

*1 東京大学大学院総合文化研究科

Graduate School of Arts and Sciences, The University of Tokyo

*2 筑波大学システム情報系

Department of Computer Science, University of Tsukuba

The internet web can be considered as a complex large scale dynamical system, where its exchanging packets are controlled by the decentralized complex TCP/IP network. In this research, we propose a new learning model on top of the TCP/IP network by using the internet simulator called ns-2. This model is based on the Echo State Network (ESN) or so called reservoir computation, which is known as a supervised learning model of any recurrent neural network.

An advantage of the ESN model is that we should only adjust its output weight strengths for learning. Since the web shows a huge temporal variety in its packets flows, it is idealistic for implementing and processing reservoir computation. Some primitive results for learning temporal sequences will be presented here.

1. はじめに

記憶や学習あるいは計算といった能力は脳だけが持つ特徴ではなく、その能力の多くは(限定することによって)計算機によって代替可能なものであることが明らかにされている。しかし、自然システムと人工システムとの計算にはまだ大きな隔りがある。たとえば morphological computation (形による計算) というアイデアは、物理環境に自然に埋め込まれた「計算」の効率性を示唆しているし、原始的な生物や化学反応が記憶や学習とも考えられる振る舞いを見せる例もある。

このような視点に立ち、複雑で巨大な人工物であるインターネットを眺めた時、それが記憶や学習などの能力を持ちうるかどうか、持ちうるのならそれはどのような性質のものなのかは、大変興味深い対象である。と同時にそれを考えることは生命や脳の探求にも大きなフィードバックがあると考えられるが、未だ十分な研究が成されているとは言い難い。そこで本研究では、インターネットの基礎をなす IP ネットワーク及び TCP プロトコルを利用した学習機のモデルを提案することにより、以上の学習や記憶に関する議論を行うことを目的としている。

2. モデル

2.1 Echo State Network

本稿で紹介する学習機モデルは、Echo State Network (ESN)[Jaeger 01] をベースにしている。これは、任意の数の input と output を持つ Recurrent Neural Network (RNN) を内部に持つ教師あり学習機のひとつであり、RNN 自体は一種のブラックボックスとして触れずに、教師信号に基づき output に直結する重みのみ調整を行うという仕組みになっている。このことは、インターネットのような巨大な IP ネットワークの内部の packet flow を観察・制御することは難しいが、手元のノードコンピュータは自由に扱えるという状況と整合する。ESN では、RNN への入力に対する各ニューロンの反応の重み付き線形和をシステム全体の output とする。学習のフェーズでは学習信号を入れた際の出力と教師信号との二乗誤差を最小化するように、この重みを調整する。RNN は各ニューロンが input に対して非線形で多様な output を返すよう、比較的

連絡先: 丸山典宏 maruyama@sacral.c.u-tokyo.ac.jp

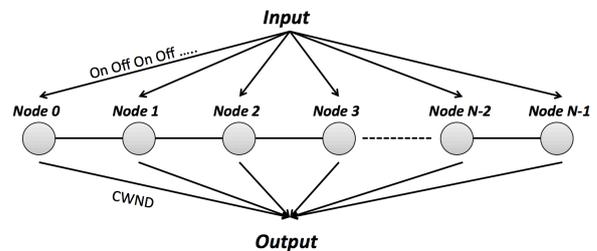


図 1: モデルの概要

大きくランダムな結合を持ったものを用いる場合が多いが、以下で述べるように IP ネットワークも input に対して複雑な振る舞いを示すことが示唆されている。

2.2 輻輳制御と cwnd

IP ネットワークは多数のルータの集合で成り立ち、packet のルーティングは基本的に各ルータで分散制御されている。ここで、packet の量がネットワークの許容量を超えるなどの原因で輻輳が発生するとネットワークのスループットは大幅に下がってしまう。インターネットのベースである IP ネットワークにはデータの到着を保証する仕組みは無いため、これを補い確実な通信を実現するための上位プロトコルとして TCP が存在するが、そこには安定で効率的な通信を行うために輻輳を防ぐ仕組みが必要とされる。そこで、ある時点で同時に送信できるパケットの量として congestion window size もしくは cwnd と呼ばれる値を設定し、それをネットワークの状態に合わせて動的に変更することによって輻輳の回避を目指している。

この cwnd 調整のためにはいくつかのアルゴリズムが開発されているが、本研究では現在一般的に用いられている NewReno アルゴリズムを用いた。NewReno アルゴリズムでは、cwnd を 1 から指数関数的に上昇させ、packet の損失が発生した時点で半分に減少させる。その後、cwnd を線形に上昇させ、再び packet の損失を検知したら半分に落とすことを繰り返す。これにより、出来る限り高いスループットを実現しつつ、packet の損失が起こるような混んだ状況に必要な以上に packet を送信し続けることを防いでいる。さらに、一定時間相手からの返答

がない場合は経路上で輻輳が起こっている可能性があるとして、一旦 $cwnd$ を 1 にリセットしてやり直す。実際にはこれにいくつかの工夫が加えられたものが NewReno アルゴリズムとして実際に使用されている。

IP ネットワークの内部は複雑な packet flow の dynamics を持つと考えられるが、このフィードバック制御のメカニズムのため、 $cwnd$ もネットワークの状態に応じて複雑な振る舞いを見せることが知られている [Oka 14]。また、このような packet flow はある程度の時間遅れを持つこと、特に輻輳の解消にはある程度の時間を要することから、ネットワークは履歴を持つと考えられ、これは IP ネットワークを用いた学習可能性を後押しする性質である。

以上のことから、ESN の内部の RNN を IP ネットワークに置き換え、システムの入力として送信パケット量を、output に各ノードの $cwnd$ の時系列を用い、ESN の学習を IP ネットワークにおいて実現することが本モデルの基本的なアイデアである。

2.3 システム

本研究では、図 1 にあるような N 個のノードが隣同士のみとリンクを持ったネットワークを想定した。各ノードは自分を除く全てのノードに対して TCP コネクションを作成し、データの送信を行う。ここで、システム全体への input として各ノードのデータ送信の on/off をコントロールする。図 1 では 1 次元の入力の場合を示しているが、入力データの次元に応じて各ノードはいずれかの input に接続される。このネットワークにおいては、多くの packet が中央付近を経由せざるを得ないため、必然的にそこを通る経路は輻輳が発生しやすくなり、逆に周辺部では比較的空いた状態が維持される。その結果、各ノードの $cwnd$ は様々なパターンを生成すると考えられる。

$cwnd$ は TCP コネクション毎に定義されるため、 $N^2 - N$ 個の $cwnd$ の時系列が得られ、これに重み付けした値

$$\sum_{i,j;i \neq j}^N c_{ij}(t)w_{ij}$$

をシステムの output として用いる。ここで $c_{ij}(t)$ は時刻 t でのノード i からノード j への packet flow に対応する $cwnd$ の値であり、 w_{ij} はそれに対応する重みである。

なお、本研究では実際のネットワークの代わりに ns-2 というネットワークシミュレータを利用した。これにより、実際のネットワークでは測定が難しい IP パケットの振る舞いなどのネットワークの内部状態を観察することも可能となっている。

3. 実験

ns-2 を用いて、2 つのランダムなバイナリ時系列を input としたシミュレーションを行い、output にその排他的論理和を出力するよう重みの学習を行った結果を図 2 に示す。2 つの緑線が入力であり、青が出力。赤は教師信号であり、トレーニング後は正解の判定のために表示している。ノード数 N は 10 である。

学習のフェーズでは、教師信号に対する fitting が成功していることから、システムには出力の表現能力は備わっていると考えられる。学習後では、学習時同様の正確さではないが、後半の長い 0 付近の output など、部分的には近い出力も見ることができる。

また、図 3 に、内部の $cwnd$ のダイナミクスの一部を示した。送信先 node によって異なった amplitude や frequency が現れている様子が見られる。

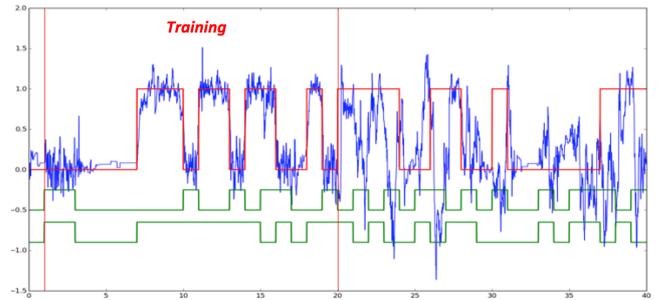


図 2: XOR の学習実験。システムへの 2 つの input (緑), output (青) の時系列。赤の縦線内は学習フェーズであり、赤のラインは教師信号及び正解の値を示している。

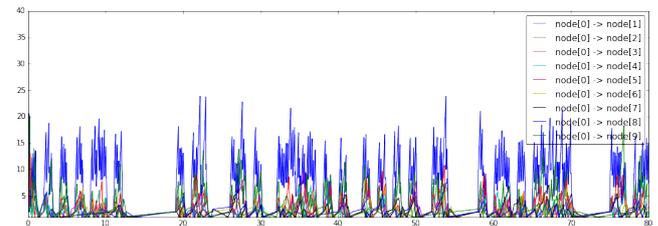


図 3: 内部の dynamics の例。ノード 0 から各ノードへの $cwnd$ の時系列。

4. 考察

本研究では、TCP/IP ネットワークにおいて、送信 packet 量とその内部のダイナミクスが複雑な関係にあることを利用した学習機のモデルを提案した。インターネットのような大規模な IP ネットワークの複雑なダイナミクスは直接観測することは容易ではないが、本モデルでは各ノードの $cwnd$ はネットワークの状況から feedback を受けて動的に変動することを利用し、これをシステムの出力とした。また、ESN の出力へのインターフェースのみ学習を行うという特性を利用している。

実験に関しては、RNN を用いたオリジナルの ESN においても学習データセットに応じたハイパーパラメタの調整は重要であり、本モデルでもその必要性は変わらないと考えられる。しかし本稿では、簡単なバイナリ入力の実験となり、その調整や、さらには詳細な学習能力の評価などには至らなかった。本発表時には、それらのより詳細に関しても紹介する。

参考文献

- [Jaeger 01] Jaeger, H.: The “echo state” approach to analysing and training recurrent neural networks-with an erratum note, *Bonn, Germany: German National Research Center for Information Technology GMD Technical Report*, Vol. 148, p. 34 (2001)
- [Oka 14] Oka, M., Abe, H., and Ikegami, T.: Dynamic homeostasis in packet switching networks, *Adaptive Behavior*, p. 1059712314556369 (2014)