

階層型ニューラルネットワークによる 観測変数間の関係抽出

4 Q-9

○(学) 都志武史,(正) 藤原健史,(正) 西谷紘一
奈良先端科学技術大学院大学・情報科学研究科

1. はじめに

異常診断においてシステムの正常を認知する1つの方法は、観測値が観測変数間の正常時の従属関係に従っているかどうかを調べることである。しかし、複数の観測変数をもつ非線形システムにおいて、観測変数間の従属関係を求めることは容易ではない。本研究では、[1,2]で考察されている自己連想型ネットワークを用いたときの、観測変数間の関係を抽出する効率の良いネットワーク設計方法を提案し、数値例によってその有効性を検証した。

2. 関係抽出のためのネットワーク

いま、独立変数の組を、すべての観測変数を表現するために必要な最小個数の変数の組と呼ぶことにすると、観測変数間の従属関係を求めることは観測変数を独立変数の関数として表すことに置き換えられる。このような独立変数を観測変数から構成するため、図1に示す5層の自己連想型ネットワークを用いる。このネットワークの特徴は次のとおりである。

- 5層の階層型ニューラルネットワークである
- 入出力層は対称、次元は観測変数の次元に等しい
- 第3層の次元は入力層の次元より小さい
- 第2,4層は対称、次元は入力層の次元より大きい
- 入力層の出力関数は線形、その他の層は sigmoid

ここで、ネットワークを5層としたのは、観測変数の次元から独立変数の次元への非線形写像およびその逆写像を精度よく実現するためである。




図1 5層の自己連想型ネットワーク

3. ネットワークの設計

本研究では、ボトルネック層を独立変数に対応させることから、まずこのボトルネック次元 (BN) の決定を行なう。独立変数の次元は、観測変数を復元できる最小の次元であるから、恒等写像を実現できる最小次元の探索により求める。次に、マッピング次元 (MP) の決定を行なう。この次元は、ネットワークの表現能力、つまりモデルの精度を決定するので、段階的に学習誤差によるモデル評価を行ない、最適な次元を探索する。ここで学習誤差は、学習データに対するネットワークの入出力の偏差の2乗平均で表す。

以上の設計の過程をアルゴリズムで示すと次のようになる。

1. ボトルネック次元 (BN) の決定
 - (a) $BN=1, MP=N+1$ とする (N は入力次元)。
 - (b) 学習データを用いて、恒等写像の学習を行なう。
 - (c) 学習誤差により判定 (一定回数で打ち切り)。
 - 判定基準より大きい: $BN \leftarrow BN+1$, (b) へ。
 - 判定基準より小さい: BN を返し、終了。
2. マッピング次元 (MP) の決定
 - (a) $MP=N+1, BN$ は上の操作で求めた値とする。
 - (b) 学習データを用いて、恒等写像の学習を行なう。
 - (c) 学習誤差によりモデルの評価を行なう。
 - 旧モデルより良い: $MP \leftarrow MP+1$, (b) へ。
 - 旧モデルより悪い: 最適な次数 MP を判断し、終了。

ここで、1(c) の判定基準は、評価するネットワークに乱数組を学習させた時の結果をもとに決定する。また、2(c) では、学習誤差の推移、パラメータ数などを考慮

Extraction of Relation among Observations Using Multi-layered Neural Networks.
Takeshi Tsushi, Takeshi Fujiwara, Hirokazu Nishitani.
Nara Institute of Science and Technology.
8916-5 Takayama, Ikoma, Nara 630-01, Japan.

して次数を決定する。

4. 例

(x, y) を独立変数とする 4 字組

$$(X_1, X_2, X_3, X_4) = \left(\frac{x+y}{2}, xy, \frac{x^2+y^2}{2}, x^2 \right)$$

を観測変数としてネットワークを設計する。

学習データは無作為に 1000 個のサンプル選んだ。

1. ボトルネック次元の決定

ボトルネック次元の探索結果を以下に示す。

表 1 ボトルネック次元の探索

BN	学習誤差	判定結果	判定基準
1	1.685e-03	×	1e-04
2	3.754e-07	○	1e-04
3	2.312e-07	○	1e-04

この結果、ボトルネック次元は 2 と決まる。

2. マッピング次元の決定

MP の変化に伴う学習誤差の推移を示す。




図 2 MP に対する学習誤差の推移

図 2 から、マッピング次元が 6 程度で十分な精度のモデルが表現できていると判断できる。

以上のアルゴリズムにより、この例の 4 字組の関係を表す 4-6-2-6-4 のネットワークが得られる。ここで得られたボトルネック次元 2 は、この例で与えた独立変数の次元と一致している。

5. モデルの評価

学習で獲得したモデルの良否は、起こりうる観測変数データの組に対して、モデル誤差 (入出力偏差の 2 乗平均) がいかに小さいかによって決まる。ここでは、学習データとは別に (x, y) を均等に分布させて作った

100000 個のサンプルに対してモデル誤差を評価する。上述の例におけるモデル誤差 (実線) と学習誤差 (点線) の推移の比較を図 3 に示す。




図 3 MP に対するモデル誤差の推移

図 3 から、本モデルが学習データに依存したものではなく、与えられた 4 字組の観測変数の関係を十分に表現していることが確認できる。また、モデル誤差を見ても、マッピング次元 6 が、モデルを精度よく表現するのに十分な数であることが確かめられる。

6. おわりに

観測変数の関係抽出のために、まず観測変数を表現するのに必要な独立変数の次元 (ボトルネック次元) をみつけ、次に適当なモデル精度が得られるようにマッピング次元を探索するというネットワーク設計手法を示した。そして、その有効性を例によって示した。この設計方法により、ネットワークのパラメータ数は小さく抑えられる。本文では述べていないが、観測変数にノイズを含む場合に、そのノイズが観測値に対して 10% 程度であれば、本手法が有効であることも確認している。今後は、実プロセスのデータを用いて検証を行ない、異常診断などの実問題へも適用したいと考えている。

7. 参考文献

- [1] 入江文平, 川人光男. 「多層パーセプトロンによる内部表現の獲得」. 電子情報通信学会論文誌 D-II Vol.J73-D-II No.8 pp.1173-1178, 1990.
- [2] Mark A. Kramer. "Nonlinear Principal Component Analysis Using Autoassociative Neural Networks." AIChE Journal, Vol.37, No.2, 1991.