

ニューラルネットワークによる情報表現と 非線形関数の同定

5F-3

生 天 目 章 木 俣 康 之

防衛大学校 応用物理学教室

1. はじめに

これまでのニューラルネットワークの研究は主に視覚情報処理等のいわば低次の知識処理に限定されていた。ところがバックプロパゲーション法の提案によってこれまでは困難であるとされていた隠れ素子を多く含む多層ネットワークの学習が可能となりこれまでにない高度な知識処理への適用に期待が高まっている。多くの知識処理問題や工学的諸問題は非線形システムの同定問題として定式化できる。しかしながらこのような非線形写像関係をもつシステムの入出力データは定量的なものばかりではなく定性的データをも含む場合がある。これまではこのような問題に対して統計学的手法によって近似的に求められてきた。もしこのような非線形の連続構造を持つ入出力関係をニューラルネットワークに学習させることができるならこれまでの統計学的手法にはない数々の利点が得られることが期待される。

このような非線形関係をニューラルネットワークに学習させるにはこの入出力情報をネットワーク上でどのように表現するかということが大きな問題となる。本研究では非線形な入出力関係についてニューラルネットワーク上に表現するための情報表現モデルについて考察し、そのような非線形構造をニューラルネットワークを用いて同定する方法を確立する。

2. 基本モデルと空間分割モデルによる情報表現

非線形関数は3層のニューラルネットワークを用いれば任意の精度で近似できることはわかっているが⁽¹⁾、その表現方法は一般には確立されていない。

Hinton⁽²⁾らはニューラルネットワークにおける情報表現を局所的及び分散的表現に分類している。しかしながら連続な非線形関係をニューラルネットワーク上に表現する問題ではこのような表現のみでは不十分であり、実際は表現対象領域をどのようにネットワークに対応させるかそして各素子は(0,1)の離散値を仮定するかまたは連続値を仮定するのかなどの問題が生ずる。従って本研究ではこの観点から情報表現モデルを 1. 基本的表現モデル 2. 空間分割表現モデルとに分類

する。基本的表現法とは図1のように入出力それぞれの領域を一つの情報表現単位とし、それぞれに1つの素子を配置したものである。




図1 基本表現モデル

また空間分割表現モデルは入出力の写像関係の双方またはそのいずれかの領域を細分化して、それぞれの部分空間を1つの情報表現単位として扱うものである。図2は入出力双方にこの表現を用いたものでそれぞれの表現領域を 73×45 に分割して表現したものである。




図2 空間分割表現モデル 図3 基本表現モデルによる非線形関数の同定

この場合これを局所的表現で素子配置すると素子数の爆発は明らかであり、分散的表現によって素子配置することが望ましい。この場合、領域の分割数 N に対して $\log_2 N$ 個の素子数が必要になる。

3. 非線形関数の同定と高次関数表現モデル

基本表現モデルと空間分割モデルを用いて実際に非線形関数を同定した場合空間分割法についてはほぼ満足のゆく結果が得られたが隠れ層を1層もつ基本表現モデルでは図3のように非線形関数を忠実に再現するのが難しいことがわかる。これは隠れ層を増やすことによってやや改善することは期待されるが素子数が増加し計算量が爆発的に増えるために望ましい方法とは言えない。そこで本研究では新たに基本表現モデルの発展型として高次関数表現モデルを導入する。これは図4のようにネットワークの入力としてもの入力の高次関数及び正弦余弦素子を導入する。Pao等⁽³⁾(1988)は隠れ素子を排除し計算の高

Neural Representation of Nonlinear System Structure

Akira NAMATAME, Yasuyuki KIMATA
NATIONAL DEFENCE ACADEMY

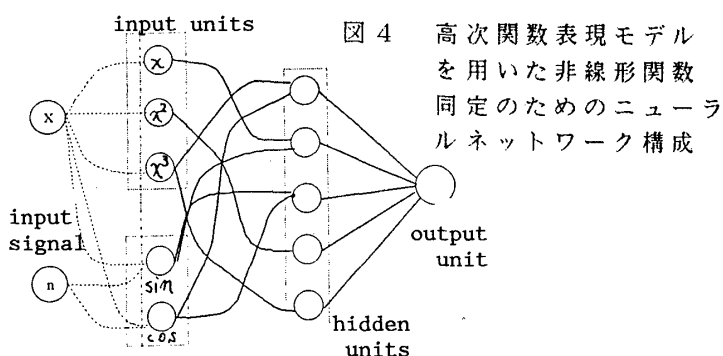


図4 高次関数表現モデルを用いた非線形関数同定のためのニューラルネットワーク構成

速化を図る目的で多変数間の交差項などを入力素子として追加することを提案している。しかしながら入力素子として高次関数項を増やすだけでは一般の非線形関数を高い精度で近似できないため本研究では図のように隠れ層を1層含んだモデルを考案した。高次関数表現モデルを用いて前出の非線形関数を同定したのが図5である。このように高次関数表現モデルを用いることによってこのような非線形関数をかなりの精度で同定できることがわかる。

4. 一般化/帰納性に関する検討

バックプロパゲーションによる学習時間は素子数によってばかりか学習信号の増大によっても増加する。また入出力関係を示すデータはすべての観測点で入手可能であるとは限らない。従ってできる限り少ないデータ(学習信号)で学習させ、このデータ以外のポイントでも満足のゆく結果がでることが望ましいこととなる。この一般化/帰納性問題に対してこれまでに考察した入力に空間分割表現を用いたモデルと高次関数表現モデルについて検証する。どちらの場合も入力領域を73に分割し、その中の任意の35点を学習信号としてこの入出力関係を学習させその後73のすべての点で再現性を検証した。図6及び図7はこの結果を示したものである。これから明らかかなように空間分割表現法を用いた場合には学習したポイント以外は全くもとの非線形関数を再現していないことがわかる。一方高次関数表現モデルを用いた場合には学習したポイント以外でももとの関数をうまく再現していることがわかる。

5. まとめ

本研究ではニューラルネットワークによる情報表現モデルを空間分割モデル及び高次関数表現モデルに分類して考察した。両モデルとも学習信号として提示した入出力関係については高い精度での近似表現が可能であることがわかった。しかし、波形識別問題⁽⁴⁾に適用されている空間分割法は学習信号以外のデータに対する一般化/帰納性能力が劣り、

高次関数モデルによる非線形構造の表現が空間分割法に比べ優れていることを示した。

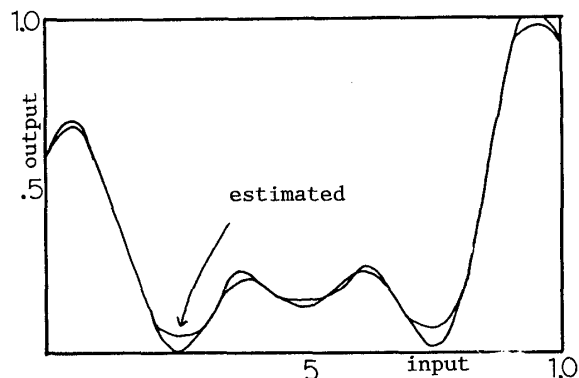


図5 高次関数モデルによる非線形関数の同定




図6 空間分割表現モデルの一般化/帰納性

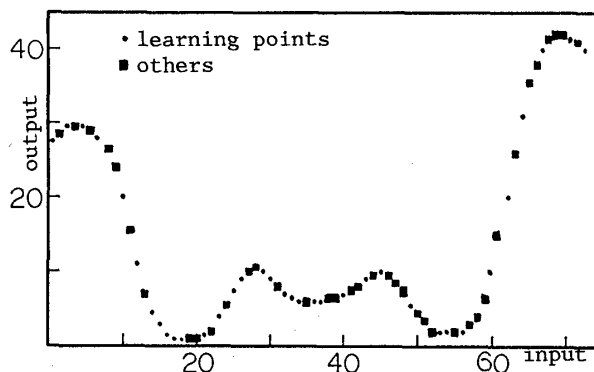


図7 高次関数表現モデルの一般化/帰納性

REFERENCES:

- (1) 船橋賢一: ニューラルネットワークのcapabilityについて, 電子情報通信学会技報MBE88-52, 127/134(1988).
- (2) Hinton, G. E., McClelland, J. L., and Rumelhart, D. E.: Distributed Representations. In Parallel Distributed Processing, Rumelhart, D. E., McClelland, J. L. (EDS.), Cambridge MA: MIT Press. (1986).
- (3) Klassen, M., Pao, Y., Chen, V.: Characteristics of The Functional Link Net. Proc. of IEEE ICNN 88 1-157(1988).
- (4) Gorman, R. P., Sejnowski, T. J.: Analysis of Hidden Units to Classify Sonar Targets. Neural Network Voll. No. 1(1988).