

函館高専 ○浜 克己, 敦賀健一 北大工 嘉数信昇

1 はじめに

入力画像中の対象となる物体の3次元運動パラメータを推定する問題は、ロボットビジョンを含む広い分野で重要であり、オプティカルフローを用いる解析的手法をはじめとする種々の方法が提案されている。また、物体への追従性を考えると、画像処理にともなう時間遅れなどを補償するために、その運動を予測する必要がある。このような運動の時系列は、一般に自己回帰モデルに従うものと仮定し、予め決めておいたモデルに含まれる未知パラメータを推定する問題として定式化できる[1]。しかし、1つのモデルですべての異なる運動パターンに対応することは困難であるため、各運動パターンに適合するモデルの選択が要求される。その1方式として、両方向動的連想ニューラルネットワークを用いた拡張型の自己回帰モデルが提案されている[2]。そこで本稿では、このモデルをベースにして、運動パターンの予測に適するネットワーク構造の自動選択のための一手法を提案する。

2 目標運動予測のための自己回帰モデル

目標運動の追跡や予測処理では、近い将来における目標の運動状態は、現在および以前の運動状態の測定から計算されるべきである。いま、目標運動状態のある時刻までの観測列が既知で、それが $X(k) = [x(k), x(k-1), \dots, x(k-n)]$ のように表現されるとすれば、予測のタスクとは、それに続く系列 $x(k+1), x(k+2), \dots, x(k+m)$ を最もよく描写する系列 $Y(k+1) = [y(k+1), y(k+2), \dots, y(k+m)]$ を計算することであり、ここに n と m は定数である。

$X(k)$ の系列の関数形式が既知であれば、 $Y(k+1)$ は同次方程式群を解くことによって計算できる。しかし、通常は未知であるため、その場合は一般に以前の運動状態の線形結合が目標の運動状態を外挿するのに使用される。この計算には、通常自己回帰 (AR) モデルが使用され、運動状態の測定系列は差分方程式で記述した n 次の AR モデル

$$y(k+1) = \sum_{i=0}^n \alpha_i x(k-i) + e(k+1) \quad (1)$$

に適合される[1]。ここで、 α_i は予測係数、 $e(k+1)$ は予測誤差であり、係数 α_i は、誤差系列に最小2乗推定法を適用することによって得られる。

目標運動の予測における主問題は、信号雑音の影響と測定誤差を減らすこと、つまり予測の不確かさを減少することである。従って、将来の運動状態をより正確に計算するためには、測定データと以前の予測データの両方を使用する、再帰的な自己回帰モデルが必要である。このモデルは

$$y(k+1) = \sum_{i=0}^n \alpha_i x(k-i) + \sum_{i=0}^m \beta_i y(k-i) + e(k+1) \quad (2)$$

のように表現される。また、

$$V(k) = [x(k), \dots, x(k-n) | y(k), \dots, y(k-m)]^T \quad (3)$$

$$\theta(k) = [\alpha_1(k), \dots, \alpha_n(k) | \beta_1(k), \dots, \beta_m(k)]^T \quad (4)$$

とすると、式(2)は

$$y(k+1) = V^T(k)\theta(k) + e(k+1) \quad (5)$$

と書き換えられ、 $y(k+1)$ は自己回帰移動平均 (ARMA) モデルと知られる。このモデルのネットワークを図1に示す。

式(5)の係数ベクトル $\theta(k)$ に対する最小2乗解は

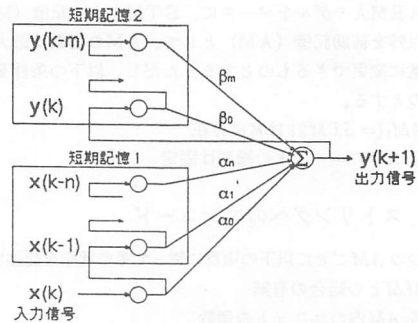


図1: ARMAモデルのネットワーク

$$\theta(k) = \theta(k-1) + \frac{P(k)V(k)}{1 + V^T(k)P(k)V(k)} \times [y(k) - V^T(k)\theta(k-1)] \quad (6)$$

で表現できる。ここで、 $P(k)$ は次のように示される。

$$P(k) = P(k-1) - \frac{P(k-1)V(k-1)V^T(k-1)P(k-1)}{1 + V^T(k-1)P(k-1)V(k-1)} \quad (7)$$

3 両方向動的連想ネットワーク

近年、両方向連想ニューラルネットワークを用いたいくつかの研究が示され、その1つに目標運動予測がある[2]。このネットワークモデルは、前述のARMAモデルに回想部分を追加した構成であり、目標運動状態の予測は、以下の回想自己回帰移動平均(RARMA)と呼ばれるモデルに従って行う。

$$y(k+1) = \sum_{i=0}^n \alpha_i(k)x(k-i) + \sum_{i=0}^l \beta_i(k)y(k-i) + \sum_{i=l+1}^m \gamma_i(k)z(k-i) + e(k+1) \quad (8)$$

このネットワークは、ベクトル $x(k), y(k), z(k)$ にそれぞれ対応している3つの短期記憶STM1, STM2, STM3から構成され、目標運動に対して予測処理と実行処理を実行する2つのデータフローを有する。このモデルのネットワークを図2に示す。

4 ネットワーク構造の自動選択

RARMAモデルでも、STM2とSTM3の各構成ユニット数の l と m を変えるだけで異なる計算スキーマが実現されるが、種々の運動パターンに対応させるためには、さらにSTMの個数についても考慮すべきである。そこで、ここではGA(Genetic Algorithms)[3]を導入して、各運動パターンを予測する際のネットワークの構造の自動選択を目指す。

4.1 ネットワークのトポロジー

RARMAモデルをベースに、STM1を主記憶(MM)、それ以外を補助記憶(AM)として、AMの個数は最大Mまで任意に変更できるものとする。ただし、以下の条件を満たすものとする。

- 1) $AM_1 (= STM2)$ は常に存在
- 2) 全AMのユニットの総和は固定

4.2 ストリングへのエンコード

1つのAMごとに以下の項目に従ってその状態を記述する。

- 1) MMとの結合の有無
 - 2) 各AM内のユニットの個数
- これをAM全体について(M個)並べたものが1個体であり、個体群規模はNとする。

4.3 ジェネティックオペレータ

ジェネティックオペレータとして、以下の3つを用いる。

- 1) 再生

再生は高性能のストリングを適合性値に従って評価し、存続ストリングを決定する手続きである。ここでは適合性値を以下のような予測誤差の2乗和で与える。

$$SJ_i = \sum_{k=t_1}^{t_2} \{e_i(k)\}^2 \quad (9)$$

つまり、同じ運動パターンをエンコードしたすべての個体に適用し、ある時間に渡る誤差の総和を求める。また、当該ストリングの生存確率を用いた最終的な存続ストリング数は

$$R_i = N \times \frac{SJ_i}{\sum_{j=1}^N SJ_j} \quad (10)$$

で与えられる。全体の平均以上の性能を持つストリング群は高い確率で存続し続け、世代が代わるたびに以下の2つのオペレーションが適用される。

2) 乗り換えと突然変異

乗り換えは、2つの存続ストリングをランダムに選択し、乗り換え発生率に従って両者の中で部分ストリングを交換するが、突然変異は、突然変異発生率に従って、ランダムに選択したストリングの一部を確率的に変更する。

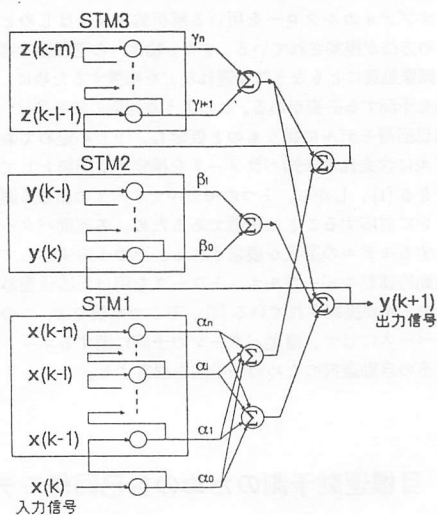


図2: RARMAモデルのネットワーク

5 まとめ

3次元運動パラメータを推定する際に重要となる目標運動の予測に着目し、自己回帰モデルをベースとして、種々の運動パターンへの予測に対応できるネットワーク構造の自動選択に関する一手法を示した。

参考文献

- [1] 中溝: 信号解析とシステム同定, コロナ社, 1988
- [2] Q.Zhu: Target Motion Prediction and Tracking by Bi-directional Dynamic Associative Neural Network, *IEEE ICSE*, pp.351-354, 1990
- [3] L.Davis: *HANDBOOK OF GENETIC ALGORITHMS*, Van Nostrand Reinhold, pp.1-22, 1991