

図形パターンの予測と認識に関する研究

1J-10

— 平行移動不変 —

岩手大学工学部情報工学科
西山 清, ○ 齊藤 崇

1 はじめに

図形パターンの認識やその一部分からパターン全体を復元する問題は物体認識などにおいて重要なテーマとなっている。本研究では、図形パターンを時系列化した後学習し、予測、認識する新たな人工ニューラルネットワークを提案し、その能力について考察する。

2 図形パターンを学習するネットワーク

2.1 図形パターンの時系列化とネットワークの構造

図形パターンの学習、想起を行うため、図1のように図形パターン(円)を2次元時系列へと変換する。




図1: 図形パターンから2次元時系列への変換

このとき、反時計方向に仮想的時間が導入され、図形パターンの座標は2次元時系列 $\{x[k], y[k]\}$ として表される。よって、図2のように入力層のそれぞれのニューロンに図形パターンの絶対座標 $\{x[k], y[k]\}$ を入力値として与えて出力層の誤差 $\{e_x[k+1], e_y[k+1]\}$ を用いてネットワークを学習させれば、ネットワークに図形パターンを記憶することができる。複数の図形パターンを記憶するためには、順次図形パターンを呈示し学習すればよい。




図2: ネットワークの構造例

2.2 学習アルゴリズム

教師信号を $\{x[p][k], y[p][k]\}$ としたとき、教師信号と出力ユニットの出力値 $\{\hat{x}[p][k], \hat{y}[p][k]\}$ の2乗誤差の総和 E

は次のように表される。

$$E = \frac{1}{2} \sum_{p=0}^{N_p} \sum_{k=0}^N \{ (x[p][k] - \hat{x}[p][k])^2 + (y[p][k] - \hat{y}[p][k])^2 \} \quad (1)$$

ここで、 N_p は図形パターン数、 N は2次元時系列のデータ数である。この2乗誤差の総和 E を最小にするように結合係数 V_{jh} 、 W_{hi} および閾値 θ_j 、 σ_h を更新することによって、ネットワークを学習する。入力信号 $x[k], y[k] (k = 0, 1, \dots, N-1)$ のうち、

$$\{x[m]\}_{N_I} = \{x[m], \dots, x[m - (N_I - 1)]\} \quad (2)$$

$$\{y[m]\}_{N_I} = \{y[m], \dots, y[m - (N_I - 1)]\} \quad (3)$$

をそれぞれの入力層ユニットへの入力とする。ただし、 m は時間シフト数であり、 N_I は入力層のニューロン数である。このとき、結合係数 V_{jh} の更新式は次のように表される。

$$V_{jh}[l] = V_{jh}[l-1] + \Delta \tilde{V}_{jh}[l] \quad (4)$$

ここで、 $\Delta \tilde{V}_{jh}[l]$ は結合係数 V_{jh} の l 回目の更新量であり、修正量 $\Delta V_{jh}[l] = -\alpha \frac{\partial E}{\partial V_{jh}}$ ($\alpha > 0$, α は学習率)を用いて、

$$\Delta \tilde{V}_{jh}[l] = \beta \Delta \tilde{V}_{jh}[l-1] + \Delta V_{jh}[l] \quad (5)$$

と表される(モーメント法)。ただし、 $\Delta V_{jh}[l]$ は誤差 E より求めた結合係数 V_{jh} の l 回目の修正量、 β はモーメント係数である。図3に3つの図形パターン(円、三角、四角)の学習サイクルを示す。この学習サイクルでネットワークの結合係数 V_{jh} 、 W_{hi} 、および閾値 θ_j 、 σ_h を更新してゆき、2乗誤差の総和 E が誤差閾値以下になるまで学習が行われる。




図3: 図形パターンの学習サイクル

2.3 平行移動不変の学習

図4は、図形の平行移動に対しても不変的に想起できるようにしたネットワークを示す。入力層のそれぞれのニューロンに図形パターンの座標の差分 $\{\Delta x[k], \Delta y[k], \dots, \Delta x[k - (N_I - 1)], \Delta y[k - (N_I - 1)]\}$ を入力値とし、 $\{\Delta x[k+1], \Delta y[k+1]\}$ を教師信号として与えてネットワークに学




図 4: 平行移動不変ネットワークの構造

習させる。例えば、三角、四角、円などを学習させる。

図形の絶対座標を得るためには、想起の際の初期値に出力層で得られる差分値を加えて行くことによって求められる。すなわち、ある時刻 k における図形の絶対座標 $\{\hat{x}[k], \hat{y}[k]\}$ は次式で得られ、これを表示することにより図形パターンを想起できる。

$$\hat{x}[k] = \hat{x}[k-1] + \Delta\hat{x}[k], \quad \hat{x}[0] = x_0 \quad (6)$$

$$\hat{y}[k] = \hat{y}[k-1] + \Delta\hat{y}[k], \quad \hat{y}[0] = y_0 \quad (7)$$

2.4 図形パターンの認識と記号化

図形パターンの想起と共にそのパターンの認識ができれば便利である。そこで、出力層に識別用のカテゴリ層を追加したネットワークを図 5 に示す。この場合も図形パターンの座標の差分値を入力とし、 $\{\Delta x[k+1], \Delta y[k+1], c_k^1, c_k^2\}$ を教師信号として与えてネットワークを学習する。





図 5: 図形パターンの予測と認識をするネットワークの構造


これより、図形パターンの予測(復元)と共にパターンの認識(識別)が可能となる。

3 シミュレーションによる考察

図 6 に入力層 22、中間層 12、出力層 4 で一回に与える入力データ組数を 12 として学習したときの学習曲線(図 6(a))と想起結果(図 6(b))を示す。また、このときの図形パターンの認識結果を図 6(c) に示す。ただし、教師信号のデータ総組数 25、空間の次元 2、シグモイド関数の傾き 5.0、図形のパターン数 3、学習係数 $\alpha=0.4$ 、 $\beta=0.3$ 、モーメント(忘却)係数 0.6 とした。



(a) 学習曲線



(b) 想起結果

(c) 認識結果

図 6: 差分座標を用いカテゴリ層を加えたネットワークで図形パターンを学習させたときの学習曲線と想起結果と認識結果

学習曲線と想起結果と認識結果

1 回の入力で与えるデータの組数: 12、

想起の際与えるデータの組数: 10、

入力層: 22、中間層: 12、出力層: 4、

学習区間 $k=0 \sim 11$ 、非学習区間 $k=12 \sim 25$ 、

学習回数: 7274149、誤差: 0.0011999999

出力層にカテゴリ層を加えたことで、学習回数もカテゴリ層を加えないものより多く必要となり、誤差が収束するまでかなりの時間を要した。図 6 の入力ニューロン層 22 で入力信号に 12 ポイントを与えたときの学習曲線を見ると、振動せずに誤差は徐々に収束している。このとき、想起と共に認識も良好に行われている。また、学習した結合係数の重みを用いて平行移動した図形に対して想起させたときも良好に想起が行われていた。一方、認識結果をみるとどの図形パターンもほぼ一点に集中しており、初期の段階ですでに三角、四角、円が良好に認識されていることがわかる。

4 まとめ

平行移動不変な図形パターンの想起と認識が可能なニューラルネットワークを提案した。また、シミュレーションにより、図形パターンの半分程度の部分から全体が想起でき、かつ認識ができることを明らかにした。

参考文献

[1] 松岡 清利: ニューロコンピューティング, 朝倉書店(1992).
 [2] 西山, 八木: TDNN による時系列パターンの記憶と想起に関する一考察, 電子情報通信学会技術研究報告, NC(1997.3).