

新しい競合学習法を用いたネオコグニトロン

福島 邦彦[†] 林 勲^{††} 庄野 逸^{†††} 菊池 眞之^{††††} 牧野 裕樹^{†††††}

^{†, ††} 関西大学 総合情報学部 大阪府高槻市

^{†††} 電気通信大学 東京都調布市

^{††††, †††††} 東京工科大学 コンピュータサイエンス学部 東京都八王子市

E-mail: [†]fukushima@m.ieice.org, ^{††}ihaya@cbii.kutc.kansai-u.ac.jp, ^{†††}shouno@ice.uec.ac.jp,

^{††††}kikuchi@cs.teu.ac.jp, ^{†††††}iris_3kinds@hotmail.com

あらまし ネオコグニトロンは、階層構造を持つ多層の人工神経回路で、頑強な視覚パターン認識能力を学習によって獲得していく。本報告では、ネオコグニトロンに対するいくつかの改良を提案する: winner-kill-loser 則と名付けた新しい競合学習法を採用, C細胞(複雑型細胞)の受容野の周辺抑制に脱抑制機構を導入, C細胞に平方根型の非線形入出力特性を採用, などである。これらの改良の結果, ネオコグニトロンの認識率を大幅に向上させることが出来た。また回路設計に際して定めなければならないパラメータの数も減らした。

キーワード 競合学習, winner-kill-loser, 視覚パターン認識, ネオコグニトロン, 神経回路

Neocognitron Trained by a New Competitive Learning

Kunihiko FUKUSHIMA[†], Isao HAYASHI^{††}, Hayaru SHOUNO^{†††}, Masayuki KIKUCHI^{††††}, and
Yuki MAKINO^{†††††}

^{†, ††} Faculty of Informatics, Kansai University Takatsuki, Osaka, Japan

^{†††} University of Electro-Communications Chofu, Tokyo, Japan

^{††††, †††††} Tokyo University of Technology Hachioji, Tokyo, Japan

E-mail: [†]fukushima@m.ieice.org, ^{††}ihaya@cbii.kutc.kansai-u.ac.jp, ^{†††}shouno@ice.uec.ac.jp,

^{††††}kikuchi@cs.teu.ac.jp, ^{†††††}iris_3kinds@hotmail.com

Abstract The *neocognitron* is a hierarchical multilayered neural network capable of robust visual pattern recognition. It acquires the ability to recognize patterns through learning. This paper proposes several improvements made on the neocognitron: new competitive learning method with *winner-kill-loser* rule, dis-inhibition to the inhibitory surround of the receptive fields of C-cells (or complex cells), square-root shaped non-linearity in the input-to-output characteristics of C-cells, and so on. As a result of these improvements, the recognition rate of the neocognitron has been largely increased. We also reduced the number of parameters that have to be determined in designing a neocognitron.

Key words competitive learning, winner-kill-loser, visual pattern recognition, neocognitron, neural network

1. はじめに

ネオコグニトロンは変形に強い視覚パターン認識能力を持つ人工神経回路である [1]~[3]. その回路は、視覚神経系に関する Hubel-Wiesel の古典的階層仮説に類似した階層的な多層の回路構造を持ち、学習によってパターン認識能力を獲得していく。

ネオコグニトロンは、大脳視覚野の単純型細胞に類似した S 細胞の層と、複雑型細胞に類似した C 細胞の層とを交互に階層的に配置した多層神経回路である。つまり、S 細胞の層と C 細

胞の層とが組になってモジュールが、何段も従属的に接続されている。S 細胞の入力結合は学習によって変化する可変入力結合である。学習を終わると、S 細胞は特徴抽出細胞として働くようになり、入力層に与えられる刺激パターンの局所的な特徴を抽出する。C 細胞は固定した入力結合を持ち、その受容野内に呈示された刺激の位置ずれにはほぼ不変な反応を示す。C 細胞によるこの操作は、S 細胞層の反応を、それに続く C 細胞層でぼかしていると解釈することも出来る。最上位段の C 細胞は、パターン認識の結果を示す認識細胞として働く。学習終了後は

ネオコグニトロンは、入力パターン変形、サイズの変化、位置ずれなどのあまり影響を受けずに、頑強にパターンを認識する。

ここでは、従来よりも認識能力を高めた新しいネオコグニトロンについて報告する。新しいネオコグニトロンも、従来とほぼ同じ回路構造を持つが、以下のような新しいアイデアを取り入れている。(1) winner-kill-loser と名付けた新しい競合学習方式の採用。(2) S細胞からC細胞への結合の抑制性周辺領域に脱抑制機構を導入。(3) C細胞に平方根型の非線形入出力特性を採用。これらの改良の結果、ネオコグニトロンの認識率を大幅に向上させることが出来た。また回路設計時に定めなければならないパラメータ数を従来よりも減らして簡素化した。

2. 回路構造

ネオコグニトロンの回路構造を図1に示す。U₀は入力層で、ここに刺激パターンが与えられる。U_Gは網膜神経節細胞(あるいはLGNの細胞)に類似したコントラスト抽出細胞の層で、オン中心型と、オフ中心型の受容野を持つ細胞からなる。その後ろに、S細胞層U_{S_l}とC細胞層U_{C_l}が組になったモジュール($l = 1, 2, 3, 4$)が4段従属的に接続されている。




図1 ネオコグニトロンの回路構造[3].

回路の基本的な部分は、従来のネオコグニトロン[3]とほぼ同じなので、ここでは従来のネオコグニトロンと大きく異なる箇所を中心に論じる。

3. Winner-Kill-Loser 則

“winner-kill-loser” 則と名付けた新しい競合学習方式を提唱する。これは、winner-take-all 則に似た学習方式であるが、勝者は、全てを取るだけでなく、敗者を除去する。

この学習則を、ネオコグニトロンのU_{S2}とU_{S3}(すなわち第2段と第3段のS細胞層)の学習に用いる。本節では最初に、この学習則の基本的な考え方を、パターン認識システム全般に適用可能な形で説明する。次に、共有結合という制約の下で学習を進める必要があるネオコグニトロンへの導入法について論じる。

3.1 S細胞による特徴抽出

winner-kill-loser 則の説明を始める前に、S細胞の特性について簡単に述べる。S細胞は、学習終了後は、特徴抽出細胞として働く。S細胞に対して抑制入力信号は、図2の等価回路に示すように、割り算的に働く。




図2 S細胞の等価回路。

学習則の基本的な考え方を示すために、1個のS細胞に収束する回路だけを抜き出して、S細胞の反応特性を解析する。図3がその回路である。S細胞は、前層の一群のC細胞から直接、興奮性信号を受け取る。それと同時に、S細胞に付随しているV細胞を経由して、抑制信号を受け取る。V細胞は、この同じ一群のC細胞から興奮性固定結合を受け取っており、常にこれらのC細胞の出力の平均値(2乗平均値)で反応する。




図3 1個のS細胞(特徴抽出細胞)に収束する入力結合。破線は、回路内には、同じ一群のC細胞から入力を受け取っているS細胞がほかにもあることを示している。

ここで、 n 番目のC細胞の出力を x_n とし、そのC細胞からS細胞への興奮性可変結合の強度を a_n とする。また、ベクトル表記を用いて、このS細胞に興奮性信号を送っている全てのC細胞の反応をまとめて \mathbf{x} と表わすことにする。すなわち、

$$\mathbf{x} = (x_1, x_2, \dots, x_n, \dots) \quad (1)$$

さらに、V細胞の出力を v 、その細胞からS細胞への抑制性可変結合の強度を b と記す。

S細胞の出力 u は次式で与えられる。

$$u = \frac{1}{1-\theta} \cdot \varphi \left[\frac{\sum_n a_n x_n}{bv} - \theta \right] \quad (2)$$

ここに $\varphi[\]$ は $\varphi[x] = \max(x, 0)$ で定義される関数である。 θ はS細胞のしきい値である($0 < \theta < 1$)。V細胞の出力は、

$$v = \sqrt{\sum_n c_n x_n^2} \quad (3)$$

で与えられる。 c_n は、 n 番目のC細胞からの興奮性固定結合の強度である。

ここで、任意の2個のベクトル \mathbf{x} と \mathbf{y} の重み付き内積を次式で定義する。

$$(\mathbf{x}, \mathbf{y}) = \sum_n c_n x_n y_n \quad (4)$$

V 細胞の入力結合の強度 c_n が内積の重みとして用いられている。またこの重み付き内積をもとに、ベクトルの norm を定義する。

$$\|\mathbf{x}\| = \sqrt{(\mathbf{x}, \mathbf{x})} \quad (5)$$

このベクトル表記を用いると、式 (3) の V 細胞の出力は、次式のように表わすことも出来る。

$$v = \|\mathbf{x}\| \quad (6)$$

3.2 Winner-Kill-Loser 則による競合学習

3.2.1 学習法の概要

S 細胞の学習は、競合学習によって進んでいく。学習時には、その前段の C 細胞の出力 \mathbf{X} が、S 細胞に対する学習ベクトルになる。

S 細胞に対しては、2 重しきい値、すなわち学習時と認識時とで異なるしきい値を用いる [4]。つまり、競合学習時には高いしきい値 θ^L に設定し、認識時には低いしきい値 θ^R に設定する。ちなみに 2 重しきい値法は、ネオコグニトロンだけでなく、種々の競合学習法全般に対して有効である。

学習ベクトルが 1 個与えられる度に、S 細胞はほかの S 細胞と競合し、この学習ベクトルに対して最大出力で反応した S 細胞が、競合の勝者となる。勝者だけがその学習ベクトルを用いて、入力結合を更新する。それと同時に、敗者は回路から除去される。もし勝者がなければ、新しい S 細胞を 1 個生成して、生成した S 細胞の入力結合を、その学習ベクトルを用いて形成する。

しかしこの競合には、すべての S 細胞が参加するわけではない。学習ベクトルに対して、ゼロでない反応出力を出した S 細胞だけが競合に参加するのである。従って、ある S 細胞が、たとえ認識時の低いしきい値 θ^R のもとでゼロでない出力を出しうる状況であったとしても、学習時の高いしきい値 θ^L のもとで無反応ならば、その S 細胞は競合には参加せず、従って入力結合が更新されることはない^(注1)。競合に参加しないということは、無反応の S 細胞は、回路から除去されることもないということを意味している。

以下にこの学習法の詳細を述べる。

3.2.2 勝者の入力結合の更新

学習ベクトル \mathbf{X} に対して、ある S 細胞が競合の勝者になったとしよう。n 番目の興奮性入力結合 a_n は、その結合に信号を送り出している前段の C 細胞の出力 X_n に比例した値だけ増加させる。すなわち、

$$\Delta a_n = c_n X_n \quad (7)$$

ここに c_n は、抑制性 V 細胞への入力結合の強度である。

(注1)：ここでは、2 重しきい値法を用いることを前提に、学習法を説明した。しかし別の表現を用いて、この学習法を記述することも出来る。すなわち、S 細胞は学習時も認識時も常に同一のしきい値 θ^R を取り、反応出力が一定の値 θ を越した S 細胞だけが競合に参加すると仮定するのである。もし $\theta = (\theta^L - \theta^R)/(1 - \theta^L)$ と置くならば、この二つの表現は全く等価である。

S 細胞は通常、学習期間中に何回か勝者になる。この S 細胞を勝者にした学習ベクトルを $\mathbf{X}^{(1)}, \mathbf{X}^{(2)}, \dots, \mathbf{X}^{(t)}, \dots$ として、

$$\mathbf{X} = \sum_t \mathbf{X}^{(t)} \quad (8)$$

と書くことにする。

これらの学習ベクトルに対して勝者になった後には、入力結合 a_n は

$$a_n = \sum_t c_n X_n^{(t)} \quad (9)$$

となる。勝者の抑制性入力結合 b は、興奮性結合 a_n の強度に応じて、次式の値に更新される。

$$b = \sqrt{\sum_n \frac{a_n^2}{c_n}} \quad (10)$$

ベクトル表記と、式 (4) で定義した重み付き内積を用いると、

$$\sum_n a_n x_n = (\mathbf{X}, \mathbf{x}) \quad (11)$$

$$b = \|\mathbf{X}\| \quad (12)$$

を得る。式 (11), (12), (6) を (2) に代入すると、S 細胞の出力は

$$u = \frac{\varphi[s - \theta]}{1 - \theta}, \quad (13)$$

と表わすことが出来る。ここに

$$s = \frac{(\mathbf{X}, \mathbf{x})}{\|\mathbf{X}\| \cdot \|\mathbf{x}\|} \quad (14)$$

である。

多次元の特徴空間内で s は、 \mathbf{x} と \mathbf{X} との間の、ある種の類似度を表わしている (図 4)。ここで、学習ベクトルの和 \mathbf{X} を、この S 細胞の参照ベクトルと呼ぶことにする。また、この S 細胞への刺激 \mathbf{x} を、テストベクトルと呼ぶこともある。図 4 に示すように、テストベクトル \mathbf{x} が、参照ベクトルの周りの許容領域に入っている場合にのみ、S 細胞はゼロでない反応出力を出す。許容領域の大きさ、すなわち $s > \theta$ が成立する領域は、しきい値 θ の値によって制御することが出来る。しきい値 θ が高くなれば、許容領域は狭くなる。

前記のように、S 細胞は学習時には、高いしきい値 θ^L を取り、ゼロでない反応出力を出した S 細胞だけが競合に参加する。このことは、学習ベクトルとの類似度が $\theta^L (> \theta^R)$ よりも大きい参照ベクトルを持つ S 細胞だけが競合に参加するということを意味している。そして、勝者の参照ベクトル、すなわち最大類似度を示した参照ベクトルに、学習ベクトルが加算されていくのである。

3.2.3 敗者の除去

ある学習ベクトルに対して 2 個以上の S 細胞がゼロでない反応出力を出したとすると、これらの S 細胞は、類似した参照ベクトルを持っていて、回路内で冗長な存在になっていることを意味する。そこで競合の勝者だけを選んで、その学習ベクトル

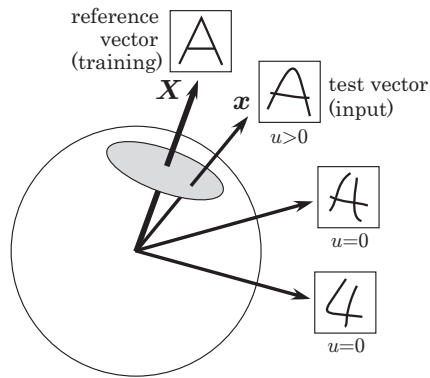


図4 多次元特徴空間内でのS細胞の反応。

によりよく適合するように入力結合を更新する一方、それ以外の冗長な細胞、すなわち競合の敗者は回路から除去してしまう。これが winner-kill-loser 則の基本的な考え方である。

無反応のS細胞（すなわち学習ベクトルに対する反応がゼロであるようなS細胞）は競合に参加しないので、たとえそれらのS細胞が認識時の低いしきい値 θ^R のもとでは学習ベクトルに対して反応する可能性があったとしても、回路から除去されることはない。これらの細胞は、別の特徴を抽出するときに働くことを期待されているのである。

3.2.4 新しい細胞の生成

ある学習ベクトルに対して、勝者が無かった場合には、新しいS細胞を生成する。新しく生成するS細胞の興奮性入力結合の初期値は、

$$a_n = c_n X_n \quad (15)$$

とする。これは式(7)で作られるのと同じ結合強度である。抑制性入力結合 b の値は、興奮性結合値 a_n にもとづいて式(10)によって定める。

3.2.5 Winner-Kill-Loser 則の利点

学習時には回路に、多数の学習ベクトルが順次呈示される。この過程で、新しい細胞の生成と、冗長な細胞の除去とが繰り返される。多次元特徴空間内で特徴抽出細胞が欠けている箇所には、新しい細胞が作られる。同じような細胞が重複して存在する箇所では、冗長な細胞が除去される。この過程を繰り返していくうちに、細胞の参照ベクトルは次第に、多次元特徴空間内に均一に分布するようになっていく。

3.3 Winner-Kill-Loser 則のネオコグニトロンへの適用

この学習則をネオコグニトロンに適用するためには、多少の補正が必要になる。これは、入力層 U_0 に1個の学習パターンが与えられる毎に、入力層上の異なる位置に受容野を持つ複数のS細胞が同時に学習しなければならないからである。また、ネオコグニトロンが共有結合を持つ回路であるための補正も必要になる。

新しいネオコグニトロンでは、winner-kill-loser 則を中間層 (U_{S2} と U_{S3}) の学習に用いる。今学習しようとしているのは l 段階目 ($l=2$ あるいは 3) のS細胞層であるとする。前段階までの学習はすでに完全に終了している状態を考える。 U_{Sl} 層のS細胞は学習時の高いしきい値 θ^L をとる。これに対して、前段の

S細胞は、認識時の低いしきい値 θ^R をとる。

ネオコグニトロンでは、各細胞層は複数の細胞面に分けられている。一つの細胞面の細胞は、すべて同一の入力結合を共有する。この共有結合の条件は、学習時に入力結合が更新される時にも常に保たなければならない。この条件を満たすために、競合によって“seed-cells”を選んで、学習を進めていく[2]。

その層のS細胞は、学習パターンが入力層 U_0 に呈示される毎に、互いに競合する。層内には複数の細胞面が存在し、また異なる位置に受容野を持つS細胞が存在するので、1回のパターン呈示に対して通常複数個の seed cell が選ばれる。seed cell は入力結合を更新し、競合の敗者はその層から取り除かれる。

学習パターンに対してゼロでない反応出力を出したS細胞だけが、この競合に参加する。seed cell の入力結合更新と、敗者の除去とは、勝者（条件を満たせば seed cell になる細胞）の反応出力が大きい順に、以下のような手順で一步一步進めていく。

まず最初は、層内で最大反応出力を出した細胞を seed cell とする。seed cell は、その細胞に対する学習ベクトルの値に応じて入力結合を更新する。seed cell の入力結合が更新されれば、その seed cell が選出された細胞面に含まれるほかのすべての細胞も、入力結合を共有しているので、seed cell と同一の入力結合を持つことになる。

もし seed cell と同じ位置にゼロでない出力を出している細胞があったら、それらは敗者である。敗者が属する細胞面はその層から除去する。しかし前述のように、無反応の細胞は、競合に参加しないので、敗者として扱われることもない。

seed cell が1個選ばれてその入力結合が更新されると、ほかの seed cell を選ぶために以下の操作を繰り返す。seed cell が選ばれたことのある細胞面の細胞は除外して、残りの細胞の中から最大出力細胞を探し、次の seed cell の候補とする。もしその候補の周辺の半径 D の超コラム型の競合範囲内に、候補よりも大きな反応出力を出している細胞がなければ、その候補を次の seed cell とする[1],[2]。もしその候補が、競合範囲内のほかの細胞に負けた場合は、その負けた候補を除外して、再び最大出力細胞を探して、次の候補とする。ちなみに、候補よりも大きい出力を出す細胞があるとすれば、それは、すでに seed cell を選出したことのある細胞面に属する細胞である。

このようにして seed cell を選出する毎に、seed cell と同じ位置に敗者があれば、その敗者を含む細胞面を除去する。しかし、すでに seed cell を選出したことのある細胞面の細胞は、今回の学習パターン呈示に際しては再度競合に参加することはないので、その反応出力がどのような値であっても敗者にはしない。

このようにして seed cell が選ばれる毎に、その seed cell に対する学習ベクトルの値に応じて、seed cell の入力結合を更新する。最初の seed cell 選出の場合と同様に、seed cell の入力結合が更新されれば、その seed cell が選出された細胞面に含まれるほかのすべての細胞も、入力結合を共有しているので、seed cell と同一の入力結合を持つことになる。

seed cell の選出、その入力結合の更新、敗者を含む細胞面の除去、が終了すると、新しい細胞面生成の操作に取りかかる。

入力信号が来ているのに S 細胞が 1 個も反応していない場所があると、新しい細胞面を生成する。換言すれば、前層の C 細胞の出力がゼロでないのに（厳密には、ある小さなしきい値以上であるのに）、その周りの半径 D_0 の超コラム内の S 細胞すべてが無反応ならば、新しい細胞面を生成する。

この操作を簡単に行なうために、“seed-selecting-plane”と名付ける仮想的な細胞面を 1 個用意する。前層のすべての細胞面の C 細胞の出力を加算して、この seed-selecting-plane の値とする。このとき、seed-selecting-plane の出力の最大値の何パーセントかの値をしきい値として、seed-selecting-plane の各細胞の出力から引き算をする。引き算された値が負であれば、その細胞の出力はゼロとする。さらに、既存の細胞面の中にゼロでない反応出力を出している S 細胞があれば、その周りの半径 D_0 以内にある seed-selecting-plane の細胞の出力を抑制してゼロにする。

このような準備をした後に、seed-selecting-plane の中から最大出力細胞を探し、その位置を seed cell の位置として、新しく生成する細胞面の入力結合を定める。その後、新しく生成した細胞面の、学習パターンに対する反応を計算する。新しく生成した細胞面内の中にゼロでない反応出力を出している S 細胞があれば、その周りの半径 D_0 以内にある seed-selecting-plane の細胞の出力をゼロに抑制する。この操作を繰り返し、seed-selecting-plane のすべての細胞の反応がゼロになるまで細胞面の生成を続ける。

以上の操作がすべて終わった後に、次の学習パターンの呈示に移る。

4. C 細胞層

最上位段以外の各段 ($l \leq 3$) では、C 細胞の細胞層 U_{Cl} は、S 細胞の細胞層 U_{Sl} と同一個数の細胞面を持っている。すなわち、同一段の二つの細胞層の細胞面間には、1:1 の対応関係がある。

C 細胞は、基本的には、対応する S 細胞の細胞面の一団の S 細胞から興奮性固定結合を受け取っている。この結合によって、S 細胞の細胞面の反応は、それに続く C 細胞の細胞面で空間的にぼかされることになる。ぼかしの操作は、頑強なパターン認識を行うために欠くことのできない重要な操作である。しかしぼかしの重要性については、すでにこれまでに多くの論文で述べられているので（例えば [5]）、ここでは割愛する。

4.1 周辺抑制

U_{C1} 層と U_{C2} 層では、図 5(a) に示すように、C 細胞の興奮性入力結合の周辺に、抑制性周辺領域を導入している [3]。この抑制性結合を介して、各 C 細胞は一つ前の細胞面の S 細胞（すなわち、同じ最適方位を持つ S 細胞）から、興奮性と抑制性の信号を受け取る。

同心円状の抑制性周辺結合によって、C 細胞は end-stopped cell に似た性質を示すようになる。線やエッジが曲がっている箇所や端点は、パターン認識を行なうための重要な特徴になる。入力結合に周辺抑制を持つ C 細胞は、ぼかし操作を行ないながら、同時に曲がり点や端点の抽出を行なうのである。その結果




図 5 C 細胞への結合。S 細胞の最適方位を、ハッチの方位で示している。




図 6 垂直の最適方位を持つ C 細胞の受容野中心部と周辺部に与えられた種々の刺激パターン。受容野中心部に与えられた最適方位の刺激に対する反応が、周辺部に与えられる刺激によって変化する。

C 細胞は、図 6(a) のような刺激よりも、図 6(b) のような刺激に対して大きな反応を示すようになる。つまり、線分の中央部に対する反応よりも、端点に対する反応が大きくなる。その結果、その次の段の S 細胞は、線の端点の特徴を、より容易に抽出できるようになる。

周辺抑制には、また別の利点もある。C 細胞によるぼかし操作は、通常は変形に強いパターン認識に役立つが、同種の特徴が 2 個隣接して存在するような場合には、ぼかされた反応を観察しただけでは、それが、単一の特徴がぼかされたものなのか、それとも隣接した 2 個の特徴がぼかされたものなのかの判別が困難になることがある。例えば、1 本の直線と、近接した 2 本の平行線とは、ぼかしの結果、どちらも同じような反応になってしまうことがある。しかし C 細胞の結合に周辺抑制があると、ぼかされた 2 個の反応の間に、無反応の領域が作り出される。この無反応領域があると、次段の S 細胞は、ぼかされた反応からでも、もとの特徴の個数を容易に検出することが出来る。

4.2 周辺抑制に対する脱抑制

第 1 段目の C 細胞も入力結合に周辺抑制を持つが、周辺領域への抑制が、直交する最適方位を持つ S 細胞からの信号による脱抑制によって取り除かれる（図 5(b)）。ちなみに第 1 段目の各 S 細胞は、特定方位のエッジを抽出するように学習済である。

ところで、その細胞の最適方位と大きく異なる方位の刺激を古典的受容野の周辺領域に与えると、受容野中心部に与えられた最適方位の刺激に対する反応が強められることが、多くの生理実験によって報告されている。このメカニズムを説明するモデルも数多く提唱されており、そのいくつかのモデルでは脱抑制機構の存在を仮定している。このネオコグニトロン回路も、そのような神経生理学的実験結果にヒントを得たものである。

図 6(c) のような刺激が、垂直の最適方位を持つ C 細胞の受容野に与えられたとしよう。周辺領域に存在する垂直刺激によって引き起こされる抑制は、周辺部に与えられた水平刺激によ

て脱抑制される。その結果、図 (c) の刺激のほうが、図 (b) の刺激よりも大きな反応を引き起こすことになる。線の折れ曲がり点はパターン認識において重要な特徴であるが、脱抑制は、折れ曲がり点を、より目立たせる効果をもたらす。

また、図 6(d) のような刺激が与えられた場合を考えてみよう。C 細胞と同じ垂直の最適方位を持つ前シナプス側の S 細胞の反応は、受容野内に水平の直線成分があるために大きく減少するので、もし脱抑制がなければ、C 細胞の反応も図 6(a) のような刺激が与えられた場合に比して大幅に減少する。しかし、C 細胞の周辺部に与えられた垂直直線成分による抑制は、周辺部に存在する水平直線成分による脱抑制のために取り除かれる。その結果、直線の交点で生じていた S 細胞の反応の減少が、C 細胞の反応においては回復することになる。このような反応も、認識率上昇に貢献する。

4.3 C 細胞の非線形特性

C 細胞の役割の一つは、その前シナプス側の S 細胞の少なくとも一つ反応しているかどうかを検出することである。そのため、C 細胞の入出力特性に飽和特性を持たせることが望ましい。新しいネオコグニトロンでは、この非線形の飽和特性として、平方根関数を採用している。

n 番目の C 細胞への入力の総和、すなわち前シナプス側の S 細胞の出力の加重和を ξ_n としよう。この C 細胞の出力は、 $x_n = \sqrt{\varphi[\xi_n]}$ で与えられる。

すべての C 細胞への入力がある一定の割合、例えば β 倍に増加したとしよう。すなわち、 ξ が β 倍に増加したとする。その結果 C 細胞の出力 x は $\sqrt{\beta}$ 倍に増加することになる。しかし式 (14) の中の類似度 s は、 ξ のレベル、すなわち β の影響を受けないので、S 細胞の出力 u は変化しない。

従来のネオコグニトロン (例えば [3]) では、C 細胞の出力は $x_n = \varphi[\xi_n]/(\alpha + \varphi[\xi_n])$ で与えられていたので、 α の最適値は入力レベルに応じて変化することになる。しかし新しいネオコグニトロンでは、このようなパラメータ α は不要になっている。

5. 計算機シミュレーション

5.1 回路規模とパラメータ

各細胞層の 1 個の細胞面内の細胞数は、 U_0 : 65×65 , U_G : 71×71 , U_{S1} : 71×71 , U_{C1} : 37×37 , U_{S2} : 37×37 , U_{C2} : 21×21 , U_{S3} : 21×21 , U_{C3} : 13×13 , U_{S4} : 5×5 , U_{C4} : 1×1 に選び、細胞密度は、最上位段を除く各段の S 細胞層と C 細胞層の間で 2:1 の間引きを行なった。

コントラスト抽出層 U_G の細胞の入力結合の広がり半径は、受容野中心部が $A_{G0}=1.5$, 周辺部が $A_G=3.3$ である。また C 細胞の入力結合は、 U_{C1} と U_{C2} でそれぞれ、中心の興奮性領域の半径が $A_{C01}=A_{C02}=3.5$, 抑制性周辺領域の半径が $A_{C1}=9.5$, $A_{C2}=6.9$ である。なおこれらの値は、前シナプス側の細胞面で隣接する細胞間の距離を単位に表わしている。 U_{C3} では周辺抑制がないので $A_{C03}=A_{C3}=4.9$, また U_{C4} では、前層の細胞面のすべての S 細胞から入力を受け取るようになっている。

S 細胞の入力結合の広がり半径は、 $A_{S1}=A_{S2}=A_{S3}=3.5$, $A_{S4}=4.5$ である。また、学習時の競合範囲の半径は、

$D_2=D_2=3.5$, $D_{02}=D_{03}=2.5$ に選んだ。

S 細胞の認識時のしきい値は、 $\theta_1^R=0.50$, $\theta_2^R=0.49$, $\theta_3^R=0.50$ に、学習時のしきい値は、 $\theta_2^L=0.71$, $\theta_3^L=0.68$ に選んだ。最上位段は $\theta_4^R=\theta_4^L=0$ である。

5.2 認識率

手書き数字の大規模データベース ETL1 [6] を用いて、新しいネオコグニトロンと従来のネオコグニトロン [3] の認識率を比較した。このデータベースには、約 1400 人の異なる筆者が書いた '0'~'9' の手書き数字が納められている。

学習パターン数を 1000 個, 2000 個, ..., 5000 個にした場合について、認識率を調べた。実験は以下のような手順で行なった。ETL1 データベースから、ランダムに 1000 個 (100 人の筆者) をサンプルしたパターンセットを m ブロック用意する。そのうちの $m-1$ ブロックを学習に、残りの 1 ブロックを認識率の測定に用いる。測定に用いるブロックを順次変更して m 回実験を繰り返し、その平均値を認識率とする。1000 個, ..., 5000 個学習の場合は、それぞれ $m=2, \dots, 6$ である。

以上の実験を、それぞれの学習個数について、異なるランダムサンプルで作製したパターンセットを用いて、3 回ずつ繰り返した。3 回の実験の誤認識率 (棄却はないので、認識率 = 100% - 誤認識率) の平均と標準偏差を、新しいネオコグニトロンと従来のネオコグニトロンに対して測定した結果を図 7 に示す。このグラフからも、新しいネオコグニトロンの優位性が確認できる。




図 7 新しいネオコグニトロン (実線) と、従来のネオコグニトロン (破線) の誤認識率とその標準偏差。

謝辞 本研究の一部は、文部科学省私立大学戦略的研究基盤形成支援事業 (平成 20 年度~平成 24 年度) によって行った。

文献

- [1] K. Fukushima: "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position", *Biological Cybernetics*, **36**[4], pp. 193-202 (April 1980).
- [2] K. Fukushima: "Neocognitron: a hierarchical neural network capable of visual pattern recognition", *Neural Networks*, **1**[2], pp. 119-130 (1988).
- [3] K. Fukushima: "Neocognitron for handwritten digit recognition", *Neurocomputing*, **5**[1], pp. 161-180 (April 2003).
- [4] K. Fukushima, M. Tanigawa: "Use of different thresholds in learning and recognition", *Neurocomputing*, **11**[1], pp. 1-17 (May 1996).
- [5] K. Fukushima: "Analysis of the process of visual pattern recognition by the neocognitron", *Neural Networks*, **2**[6], pp. 413-420 (1989).
- [6] ETL1 database: <http://www.is.aist.go.jp/etl1cdb/>