

平成 30 年 5 月 23 日現在

機関番号：77103

研究種目：基盤研究(C) (一般)

研究期間：2013～2017

課題番号：25330300

研究課題名(和文) 視覚情報処理を行なう階層型神経回路の新しい学習手法の研究

研究課題名(英文) New Learning Rules for Hierarchical Neural Networks for Visual Pattern Recognition

研究代表者

福島 邦彦 (FUKUSHIMA, KUNIHICO)

一般財団法人ファジィシステム研究所・研究部・特別研究員

研究者番号：90218909

交付決定額(研究期間全体)：(直接経費) 3,700,000円

研究成果の概要(和文)：視覚パターン認識能力を持つ多層神経回路「ネオコグニトロン」の新しい学習手法を開発した。中間層に対しては、Add-if-Silent則と負のフィードバック信号を組み合わせた教師なし学習則を完成させた。最上位層に対しては、「内挿ベクトル法」を用いると高い認識率を得られるが、その計算量は参照ベクトル数が増えると急激に増加する。そのため、学習ベクトルの集合全体を少数の参照ベクトルで忠実に表現できる新しい学習法mWTA (marginated Winner-Take-All) を提唱した。

研究成果の概要(英文)：We developed new learning rules for the neocognitron, which is a deep convolutional neural network for visual pattern recognition.

For training intermediate layers, the learning rule named AiS (Add-if-Silent) is used. Under the AiS, a new cell is generated and added to the network if all postsynaptic cells are silent in spite of non-silent presynaptic cells. Once a cell is generated, its input connections do not change any more. Thus the training process is very simple and does not require time-consuming repetitive calculation.

For training the deepest layer, we proposed a supervised learning rule called mWTA (marginated Winner-Take-All). Every time when a training pattern is presented during the learning, if the result of classification by the WTA is an error, a new cell is generated. Here we put a certain amount of margin to the WTA. The mWTA produces a compact set of cells, with which a high recognition rate can be obtained with a small computational cost.

研究分野：人工神経回路

キーワード：視覚パターン認識 多層神経回路 deep CNN ネオコグニトロン 学習手法 内挿ベクトル法 Add-if-Silent marginated WTA

### 1. 研究開始当初の背景

文字認識をはじめとする視覚パターン認識は、これまでも種々の手法が提唱され、研究が進められてきた。実用的なシステムもすでに作られ種々の用途に用いられてはいるが、変形したパターンなどを人間なみに柔軟に認識することのできるシステムはまだ実現されていない。そこで、生物の視覚系のメカニズムを調べ、そのメカニズムを参考にして新しい発想でのシステムを実現しようとするアプローチが重要になってくる。

脳の視覚神経系では、網膜で捕えられた視覚パターンは、神経回路内で階層的に処理され、次第に複雑な情報が抽出されていくことがわかっている。筆者は以前、このような脳の視覚神経系からヒントを得て多層型の人工神経回路「ネオコグニトロン」を発表した。このネオコグニトロンの考えは、多くの研究者に影響を与え、これと類似したシステムが数多く発表された。最近人工知能分野で広く用いられるようになった deep CNN (deep Convolutional Neural Network) もその一例である。最初の発表は古いが、ネオコグニトロンは、その後も現在に至るまで発展を続けている。筆者は、その後もネオコグニトロンに数々の改良を加え、新しい機構を取り入れ続けている。

ネオコグニトロンは、学習によって回路を自己組織的に作り上げていく。

階層型神経回路の中間層に適用できる学習法として研究開始当時広く使われていたのは、Hebb 則や、WTA 則 (winner-take-all) であった。初期のネオコグニトロンでも、この WTA 則を用いていた。

筆者は、従来の学習則よりも、より安定した学習を行なわせることのできる新しい学習則 AiS (add-if-silent 則) を提唱した。これは、一旦形成された細胞の入力結合は、その後はどのような学習パターンが与えられても変化させないという学習則である。この学習法に対しては、すでに予備実験を開始しており、従来の学習法よりも安定して学習を進めることができ、より小さい回路で、より高い認識率を得ることができていることを確認していた。そこで、この AiS 則を発展させ完成させることを一つの目標とした。

また筆者は、多層回路の最上位段に対して有効な、新しい認識 (識別) 方式「内挿ベクトル法」をすでに開発していた。内挿ベクトル法を用いると、従来よりも小さい回路規模 (少ない計算量) で、従来よりも高い認識率を実現できる。そこで、この認識法を更に発展させ、この方式に適した学習法の開発を目指した研究も、並行して進めることにした。

### 2. 研究の目的

階層型多層構造を持つ人工神経回路、すなわち deep CNN に適した新しいパターン認識方式や学習方式を開発する。また同時に、多層

神経回路を効率的に設計するための指針を導き出すことを目標とする。

具体的には、ネオコグニトロンを用いて、(1) その中間層を効率的に学習できる手法として、筆者が提唱した AiS 則を対象に、学習速度と認識精度を向上するための改良を加え、発展させる。

(2) また最上位層に適した認識手法「内挿ベクトル法」を発展させるとともに、新しい効率的な教師あり学習法を開発する。

### 3. 研究の方法

階層型神経回路、すなわち deep CNN に適した学習ならびに認識の新しい方式を開発する。提案した方式の効果を、ネオコグニトロンを用いた計算機シミュレーションによって確認しながら、改良を加えていく。シミュレーションには、大規模な手書き数字のデータベースを用いる。

ネオコグニトロンは、これまでも各種の改良が加えられ、種々の回路構造を持ったものが提唱されている。次節での研究成果の説明のために必要になるので、ここで、実験に用いたネオコグニトロンの基本的な回路構造と動作原理について簡単に述べておく。

ネオコグニトロンは図 1 に示すように、入力層  $U_0$  の後ろに、特徴抽出を行なう S 細胞の層  $U_s$  と、位置ずれを許容する働きを持つ C 細胞の層  $U_c$  (pooling 層) とを交互に階層的に配置した多層神経回路である。各層は、複数の細胞面 (sub-layer) から構成されている。細胞面内の細胞は、同一の入力結合を共有している。

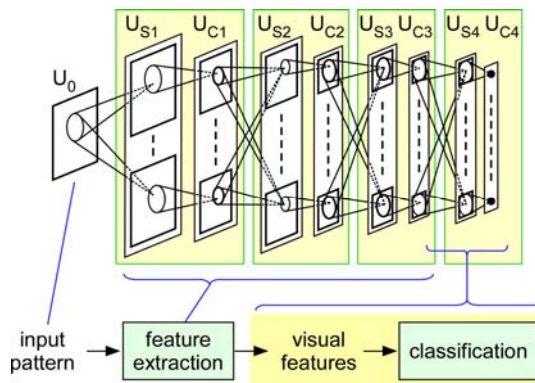


図 1. ネオコグニトロンの回路構造

ネオコグニトロンでは、個々の細胞は一つ前の層の比較的狭い範囲にある細胞だけから結合を受け取っている。しかも、信号を送り出している細胞と、信号を受け取っている細胞とは、それぞれの層の中でほぼ同じような位置を占めている。その結果、下位の層の S 細胞は小さい受容野を持ち、入力パターンの局所的な特徴を抽出する。

ネオコグニトロンでは、個々の細胞は一つ前の層の比較的狭い範囲にある細胞だけから結合を受け取っている。しかも、信号を送

り出している細胞と、信号を受け取っている細胞とは、それぞれの層の中でほぼ同じような位置を占めている。その結果、下位の層の S 細胞は小さい受容野を持ち、入力パターンの局所的な特徴を抽出する。

このような局所的特徴を抽出する S 細胞が、どのような組合せで反応しているかを見ているのが、その次の層の S 細胞である。この細胞は、前層の S 細胞に比して、もう少し大きな受容野を持っていて、大局的な特徴を抽出している。そのもう一段上には、この大局的な特徴を抽出する細胞の出力を集めて、もっと大きい特徴をみている細胞がある。つまり、この細胞は、大局的な特徴をみる前層の細胞の反応を介して、間接的に入力層全体の情報を捕らえていることになる。

C 細胞は、いくつかの S 細胞から固定結合を受け取っていて、そのうちのどれか一つの S 細胞が出力を出せば、C 細胞も出力を出す。これらの S 細胞はいずれも同じ形の特徴を抽出するが、特徴を抽出してくる場所は S 細胞ごとに少しずつ異なる。つまり 1 個の C 細胞は、同じ特徴をわずかに違う位置から抽出する一群の S 細胞の出力を受け取っている。従って、入力パターンの位置ずれや変形のために、ある特徴の位置が入力層上で移動すると、最初とは異なる別の S 細胞がその特徴を捕らえて反応するかもしれないが、これらの S 細胞の出力を全部まとめて受け取っている C 細胞は、出力を出し続ける。このようにして C 細胞は、S 細胞が抽出した特徴の、位置ずれの影響を吸収するのである。

多層回路内には S 細胞の層と C 細胞の層とが交互に繰り返して階層的に結合されているので、入力パターンの情報は、多層回路内の各段で S 細胞による特徴の抽出と C 細胞による特徴の位置ずれの許容化を繰り返しながら上位段に送られていく。この過程で、下位段で抽出された局所的な特徴は、次第に大局的な特徴に組み上げられていく。このとき、入力パターンの拡大や縮小をはじめとする種々の変形にともなう局所的特徴の相対的な位置ずれの影響は、C 細胞の働きによって少しずつ吸収されるので、最終的には入力パターンのかんりの変形に対しても影響されない出力を得ることができるのである。

C 細胞によるこのような操作は、CNN で pooling と呼んでいる操作とほぼ同じである。しかしネオコグニトロンでは、max-pooling ではなく、平均化操作によって pooling を行なっている。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 細胞層で空間的にぼかしていると解釈できる。ぼかしによって、変形や位置ずれの影響を受けにくくしているのである。またネオコグニトロンの各段では、演算コスト削減のために細胞の間引き (down sampling) を行なっているが、ぼかし操作は空間周波数の高周波成分を除去する low-pass filter の役割も果たし、粗い間引きによって発生する aliasing noise の抑制

にも貢献している。また、平均化操作によってランダムノイズを軽減する働きも生じる。

## 4. 研究成果

### (1) 中間層の新しい学習手法の開発

#### (1-1) AiS 則による中間層の学習

学習は、下位の層から順次進めていく。その中間層の S 細胞の学習に適した新しい学習則 AiS 則 (Add-if-Silent 則) を提唱した。

もし、前シナプス側の C 細胞が出力を出しているにもかかわらず、後シナプス側のすべての S 細胞が無反応であれば、新しい S 細胞を作成して回路に追加する。新しく追加した S 細胞の入力結合は、前シナプス側の細胞の出力に比例した強度とする。従って、その時点の前シナプス側細胞の反応に対して選択的に反応する S 細胞が作られる。

S 細胞が一旦形成されて細胞層に追加された後は、その後どのような学習パターンが与えられても、その入力結合は変化させない。すなわち、AiS 則による学習は、多数の学習ベクトルの集合の中から、参照ベクトルを選び出す操作である。学習パターンの集合に含まれる各パターンを 1 回ずつ提示するだけで学習は完了する。このように AiS 則は、多くの深層学習で用いられている手法とは異なり、繰り返し演算で結合強度を補正する必要がなく、高速に学習を進めることができる。

ベクトル空間内で考えると、AiS 則のもとでは、すでに存在する S 細胞の反応許容領域内に新しい細胞が形成されることはない。従って学習時に十分多数の学習ベクトルが提示されたならば、S 細胞は、その参照ベクトルがベクトル空間内に一様に分布するように作られる。

このように簡単な AiS 則で、なぜ高い認識率が得られるのであろうか。入力パターンを最終的に識別するのは、多層回路の中間層ではなく最上位層である。中間層は、入力層に提示されたパターンを、単一細胞の反応によってではなく、多数の細胞の反応の集合によって、正確に表現していれば十分である。従って個々の学習パターンに応じた tuning は必ずしも必要でないのである。

AiS では、学習時に、一つの特徴に対して 1 個 (あるいはごく少数) の細胞だけしか反応しない状態を作ることによって冗長な細胞の発生を防いでいる。しかし学習終了後の認識時にもこのような状態が保たれていると、回路は変形パターンに対して汎化能力を発揮できない。そこで認識時には、閾値を学習時よりも低い値に設定して、population coding のような状態を作る。入力パターンの状態を、多数の細胞の集合で表現することになるので、入力パターンが多少変形しても、細胞の集合としての反応状態はあまり変動せず、変形パターンに対しても頑強な認識が可能になる。

## (1-2) フィードバックを導入した AiS

AiS 則をネオコグニトロンに適用するためには、多少の修正が必要になる。ネオコグニトロンは convolutional network であり、各細胞面内の S 細胞は入力結合を共有している。この共有結合の条件は、S 細胞の結合の発生時や更新時にも、常に保たれていなければならない。学習時にも共有結合の条件を保つために、学習パターンが提示される毎に、seed cell と呼ばれる細胞を細胞面の中から選ぶ。seed cell は、結晶成長における核 (seed) のような働きをする細胞である。seed cell は、自分自身に提示された学習刺激を学習して入力結合を変更する。一つの細胞面内の細胞はすべて同一の入力結合を共有しているので、細胞面内のほかの細胞も seed cell と同一の入力結合を持つようになる。

学習時に新たな seed cell を置く位置は、前シナプス側の C 細胞は出力を出しているのに、すべての S 細胞が無反応である位置とする。このような位置が複数箇所存在した時には、前シナプス側の C 細胞の出力の総和が極大になる位置を順番に選んでいく。

この時、類似した特徴が複数個存在した場合はどうであろうか。互いに類似した特徴は、別々の細胞面ではなく、同一の細胞面で抽出するように学習すべきである。そのために、以下のような方法を用いて seed cell の位置を決める。まず、前シナプス側の各 C 細胞が、後シナプス側の S 細胞の反応にどの程度関与しているかを調べるために、S 細胞から、その入力結合に比例した強度の抑制性結合を介してフィードバック信号を前シナプス側の C 細胞に送る。C 細胞の反応はこのフィードバック信号によって、S 細胞の反応に寄与した程度に応じて抑制されるはずである。このような抑制性フィードバック信号を、すべての S 細胞から、前シナプス側の C 細胞に向けて送る。抑制されずに残っている C 細胞があれば、その位置に存在する特徴を抽出する S 細胞はまだ作られていないことになる。そこでその位置に、seed cell を置く。しかしその seed cell が学習するのは、フィードバックで抑制された C 細胞の反応ではなく、抑制される以前の C 細胞の反応パターンである。この考え方は、前シナプス側の C 細胞層の反応を再現できるように後シナプス側の S 細胞を学習させるという意味で、autoencoder の考え方と類似したところがある。

## (2) 最上位層での新しい認識手法の開発

### (内挿ベクトル法によるパターン識別)

ネオコグニトロンでは、入力層に与えられた視覚パターンの情報は、多層回路の中を伝わる過程で、特徴の抽出と統合が繰り返されて、次第に高次の特徴が抽出されていく。

最上位層 (すなわち最深層) では、中間層で抽出された特徴をもとに、入力パターンを認識 (識別) する。最上位層の S 細胞は後述するように教師あり学習によって作られる

のであるが、学習終了後は各 S 細胞 (すなわちその参照ベクトル) には、その細胞が学習したパターンのクラス名を表わすラベルが付けられる。

初期のネオコグニトロンでは、テストベクトル (認識すべきベクトル) に最も近い参照ベクトル (つまり最大出力 S 細胞) のラベルを認識結果としていた。すなわち、WTA 則 (winner-take-all 則) を用いてパターンを認識していた。

しかし認識率を更に向上させるために、内挿ベクトル法 (interpolating-vector) と名付けた新しい手法を提唱した。内挿ベクトル法では、複数の細胞の反応を組み合わせることによって認識結果を決定する。図 2 のように、同一のラベルを持つ参照ベクトルの対 (ついで) を結ぶすべての直線の中で、テストベクトルとの距離が最も近いもの (すなわち類似度が最も大きいもの) を選び、その直線のラベルを認識結果とするのである。その結果、小さな規模の回路で、従来よりも高い認識率を得ることができるようになった。

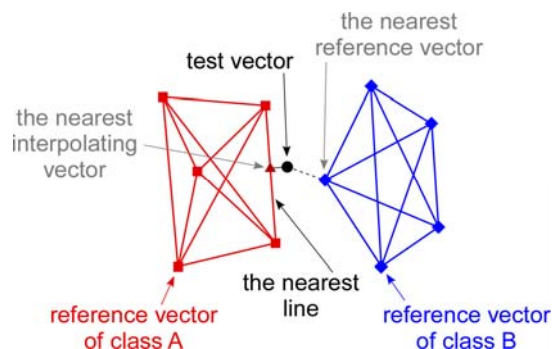


図 2. 内挿ベクトル法 (Int-2) の原理

内挿ベクトル法では、ベクトルの対 (ついで) を結ぶ直線の代わりに、三つ組みで形成される平面を用いることもできる。両者を区別するために、前者を Int-2、後者を Int-3 と記す。Int-3 のほうが Int-2 に比して計算量は増加するが認識率が大幅に向上するので、通常 Int-3 を用いている。ちなみに、Int-2 さえも、現在パターン認識の分野で広く用いられている WTA や SVM (support vector machine) よりも、はるかに高い認識率を達成できる。

これを更に拡張して、ベクトルの四つ組みを用いる Int-4 の具体的な計算手法も確立した。計算コストの増加をいとわなければ、認識率を Int-3 よりも更に改善することができることを明らかにした。

## (3) 最上位層の学習法の提唱

### (3-1) mWTA

最上位層の S 細胞は教師あり学習によって学習させ、各 S 細胞 (参照ベクトル) には、その細胞が学習したパターンのクラス名を表わすラベルを付ける。ところで、内挿ベクトル法での認識に要する計算量は、参照ベク



トル数が増えると急激に増加する。従って、できるだけ少ない数の参照ベクトルで高い認識率を得られるような学習法が求められる。この目的に適した新しい学習法を提唱し、mWTA (marginized Winner-Take-All) と名付けた。

mWTA では、中間層の学習と同様に、S 細胞を学習時に発生させる。学習ベクトルに対して最大出力を出した S 細胞が、学習ベクトルと異なるラベルを持っていれば、識別は間違いであると判定し、新しい S 細胞を発生させる。但し最大出力細胞 (すなわち学習ベクトルに最も近い参照ベクトル) の探索において、学習ベクトルとは異なるラベルをもつ参照ベクトル (S 細胞) にハンディキャップを持たせて、実際の距離よりも一定割合だけ近くにありと仮定して探索を行なうのである。このようなハンディキャップのもとでも、最も近い参照ベクトルが学習ベクトルと同じラベルを持つ場合にのみ、mWTA による識別が正しいと定義する。

すなわち、学習時には、学習ベクトルが提示されるごとに mWTA で識別してみて、もし識別結果に誤りがあれば、新しい S 細胞 (参照ベクトル) を発生させ、その学習ベクトルを新しい S 細胞の参照ベクトルとする。

ベクトル空間内で、学習ベクトルが、分類すべきクラス毎にクラスターを作って分布しているとしよう。学習ベクトルから参照ベクトルを選び出す時に mWTA を用いると、クラスターの周辺部 (つまり他のクラスのクラスターとの境界付近) で、参照ベクトルが密に選ばれることになる。ちょうど SVM で、クラスターの境界付近のベクトルを選ぶのと、ある意味類似した状況が作られることになるのである。

### (3-2) 2段階学習

中間層とは異なり最上位層では、参照ベクトルの tuning が有効である。tuning では、mWTA による識別結果が正しかった場合に、内挿ベクトル法 Int-3 で選ばれた平面 (最も距離の近い平面) を形成する 3 個の参照ベクトルを、いずれも学習ベクトルに近づける方向に移動させる。(ここでは、内挿ベクトル法として Int-3 を用いることを前提にして説明しているが、Int-2 を用いる場合には、平面の代わりに最も距離の近い直線を用いる)。ちなみに、参照ベクトルを学習ベクトルに近づけるためには、参照ベクトルに学習ベクトルを少量だけ加算すれば良い。

しかし学習を開始したばかりで、まだ十分な数の参照ベクトルが発生していない状態では、たとえある学習ベクトルが正しく認識されたとしても、そのときに使用された参照ベクトルと学習ベクトルの類似度が高いとは、必ずしも言えない。この段階で tuning を行なおうとして参照ベクトルに学習ベクトルを加算してしまうと、類似度の低いベクトルが加算されて、あまり役に立たない参照

ベクトルが作られる恐れがある。そこで、学習過程を 2 段階に分けて、第 1 段階では tuning は行わず、mWTA によって S 細胞 (参照ベクトル) の発生だけを行ない、学習がある程度進んだ第 2 段階目になって始めて tuning を開始することによって、学習を効果的に進めることができる。

## 5. 主な発表論文等

〔雑誌論文〕 (計 4 件)

- ① K. Fukushima: "Marginized winner-take-all: new learning rule for pattern recognition", *Neural Networks*, vol.97, 2018, pp.152–161, 査読有  
DOI: 10.1016/j.neunet.2017.10.005
- ② J. Léveillé, I. Hayashi, K. Fukushima: "A probabilistic WKL rule for incremental feature learning and pattern recognition", *JACIII (Journal of Advanced Computational Intelligence and Intelligent Informatics), Special Issue on "SCIS-ISIS2012"*, vol.18, no.4, 2014, pp.672–681, 査読有  
DOI: 10.20965/jaciii.2014.p0672
- ③ K. Fukushima, I. Hayashi, J. Léveillé: "Neocognitron trained by winner-kill-loser with triple threshold", *Neurocomputing*, vol.129, 2014, pp.78–84, 査読有  
DOI: 10.1016/j.neucom.2012.05.038
- ④ K. Fukushima: "Training multi-layered neural network neocognitron", *Neural Networks*, vol.40, 2013, pp.18–31, 査読有  
DOI: 10.1016/j.neunet.2013.01.001

〔学会発表〕 (計 26 件)

- ① K. Fukushima: "Artificial vision by deep CNN neocognitron", *TDLW 2018 (Workshop on Deep Learning: Theory, Algorithms, and Applications)*, 2018.
- ② 鎌田理詩, 菊池眞之, 庄野逸, 林勲, 福島邦彦: "U-Net による CT 画像における脊椎の自動検出", 電子情報通信学会 ニューロコンピューティング研究会, 2018.
- ③ M. Kamata, K. Fukushima, H. Shouno, I. Hayashi, M. Kikuchi: "Automatic detection of spine in CT image by U-Net", *NCSP2018 (RISP International Workshop on Nonlinear Circuits, Communications and Signal Processing)*, 2018.
- ④ 福島邦彦: "ネオコグニトロンと畳み込みニューラルネットワーク --- 頑強な視覚パターン認識を目指して ---", 電子情報通信学会 東海支部 度専門講習会「ディープラーニングとその医用画像応用」, 2018.
- ⑤ K. Fukushima: "Artificial vision by

- deep CNN neocognitron”, *ELM 2017* (International Conference on Extreme Learning Machines), 2017.
- ⑥ 毬山利貞, 福島邦彦, 遠藤覚, 松本渉: “ネオコグニトロンにおける中間素子数と認識性能との関係性” *JNNS 2017* (日本神経回路学会全国大会), 2017.
- ⑦ 福島邦彦: “deep CNN ネオコグニトロンと視覚情報処理”, *DICOM 2017* (情報処理学会 マルティメディア, 分散, 強調とモバイル シンポジウム), 2017.
- ⑧ 福島邦彦: “視覚の人工神経回路”, 日本知能情報ファジィ学会 BSB (しなやかな行動の脳工学研究部会研究会), 2017.
- ⑨ 福島邦彦: “視覚パターン認識とネオコグニトロン”, 日本視覚学会 2017 冬季大会, 大会企画シンポジウム「視覚と深層学習」, 2017.
- ⑩ K. Fukushima: “Artificial vision by deep CNN neocognitron”, *NBNI 2016* (Japan-China-Korea Joint Workshop on Neurobiology and Neuroinformatics), 2016.
- ⑪ T. Mariyama, K. Fukushima, W. Matsumoto: “Automatic design of neural network structures using AiS”, *ICONIP 2016* (International Conference on Neural Information Processing), 2016.
- ⑫ W. Matsumoto, M. Hagiwara, P.T. Boufounos, K. Fukushima, T. Mariyama, Z. Xiongxin: “A deep neural network architecture using dimensionality reduction with sparse matrices”, *ICONIP 2016* (International Conference on Neural Information Processing), 2016.
- ⑬ K. Fukushima: “Deep CNN neocognitron for visual pattern recognition”, *ICONIP 2016* (International Conference on Neural Information Processing), 2016.
- ⑭ 福島邦彦: “Deep CNN ネオコグニトロンと視覚パターン認識” 視覚科学技術コンソーシアム (VSAT), 2016.
- ⑮ K. Fukushima: “Margined winner-take-all: new learning rule for pattern recognition”, *IJCNN 2016* (International Joint Conference on Neural Networks), 2016.
- ⑯ 福島邦彦: “Deep CNN ネオコグニトロン学習”, *JSAI 2016* (人工知能学会全国大会), 2016.
- ⑰ K. Fukushima: “Artificial vision: Learning from biological brain”, *IWCcS 2015* (International Workshop on Community centric Systems), 2015.
- ⑱ 福島邦彦: “Deep Convolutional Network と視覚パターン認識”, *JNNS 2015* (日本神経回路学会全国大会), 2015.
- ⑲ 佐藤翔一郎, 菊池眞之, 福島邦彦, 林勲, 庄野逸: “ネオコグニトロンにおける識別率と細胞反応分布の関係について”, *JNNS*

- 2015 (日本神経回路学会全国大会), 2015.
- ⑳ K. Fukushima, H. Shouno: “Deep convolutional network neocognitron: improved interpolating-vector”, *IJCNN 2015* (International Joint Conference on Neural Networks), 2015.
- ㉑ 福島邦彦: “畳み込み型多層神経回路ネオコグニトロンとその発展”, 電子情報通信学会 ニューロコンピューティング研究会・情報論的学習理論と機械学習研究会, 2015.
- ㉒ K. Fukushima: “Add-if-silent rule for training multi-layered convolutional network neocognitron”, *ICONIP 2014* (International Conference on Neural Information Processing), 2014.
- ㉓ 福島邦彦: “Deep convolutional network ネオコグニトロンによる視覚パターン認識: その原理と学習手法”, *IBIS2014* (情報論的学習理論ワークショップ), 2014.
- ㉔ K. Fukushima: “One-shot learning with feedback for multi-layered convolutional network”, *ICANN 2014* (International Conference on Artificial Neural Networks), 2014.
- ㉕ 福島邦彦: “多層神経回路ネオコグニトロン学習”, *FSS2014* (ファジィシステムシンポジウム), 2014.
- ㉖ K. Fukushima: “How to design multi-layered neural networks for vision”, *ICONIP 2013* (International Conference on Neural Information Processing), 2013.

〔図書〕 (計 0 件)

〔産業財産権〕

- 出願状況 (計 0 件)
- 取得状況 (計 0 件)

〔その他〕

ホームページ等  
<http://personalpage.flsi.or.jp/fukushima/>

## 6. 研究組織

- (1) 研究代表者  
 福島 邦彦 (FUKUSHIMA KUNHIKO)  
 一般財団法人ファジィシステム研究所・  
 研究部・特別研究員  
 研究者番号: 90218909
- (2) 研究分担者  
 なし
- (3) 連携研究者  
 なし
- (4) 研究協力者  
 なし