

## CNN への競合学習の統合による表現学習の強化

## Competitive Learning Accelerates Learning Representation in CNNs

篠崎隆志 \*1\*2

Takashi SHINOZAKI

\*1 国立研究開発法人 情報通信研究機構 脳情報通信融合研究センター

CiNet, National Institute of Information and Communications Technology

\*2 大阪大学大学院 情報科学研究科

Graduate School of Information Science and Technology, Osaka University

We propose a novel hierarchical competitive learning method for convolutional neural networks (CNNs). One of the most important characteristics of CNN is representation learning which obtains the optimum features for discriminating input data. Since CNN is usually learned by back propagation (BP) error, the power of representation learning is not enough strong especially in early layers. Weaker representation learning means less adaptability to input data, and it prevents applications to data with small sample numbers, for example, medical data. Instead of BP, some other neural networks, Neocognitron and self-organizing map, employ another method, competitive learning which exhibits much stronger representation learning. This study tries to unify competitive learning to conventional CNNs with hierarchical manner. The validation by a image recognition task shows that the proposed method performs strong representation learning with unsupervised competitive learning, and permits seamless switching to supervised BP learning.

## 1. はじめに

深層学習は脳における情報処理の仕組みを模した多層ニューラルネットワーク (以下 NN) による機械学習の仕組みで、画像認識 [Krizhevsky 12] をはじめとして、音声認識や、果ては囲碁までと、様々な分野で革新的な成果をあげている。このような深層学習の躍進の秘密は、入力データから認識に必要な情報の基底を獲得する表現学習 (Representation Learning) という特性にあると言われている。一方で現在の深層学習の主流である畳込みニューラルネットワーク (Convolutional Neural Network: 以下 CNN) [LeCun 89] は、表現学習という点では必ずしも十分に強力ではない。これに対してネオコグニトロン [Fukushima 80] や自己組織化マップ [Kohonen 82] といった NN では競合学習 (Competitive Learning) と呼ばれる手法によって強力な表現学習を実現している。しかしながら競合学習は教師なし学習のため、現在の CNN のようなファインチューニングを行うことが困難である。そこで本研究では競合学習を現在主流の CNN へと統合することによって、競合学習による強力な表現学習と、誤差逆伝播 (Back Propagation, 以下 BP) 学習によるファインチューニングを両立するような NN モデルを提案し、画像認識課題による検証を行った。

## 2. 競合学習

提案する NN モデルは、CNN の基本構成要素である畳込み層に、競合学習の要素を追加する。競合学習は単純な Winner Takes All (以下 WTA) を用いたものとし、畳込み層の順行伝播、重み勾配の両方に WTA を適用する。 $l-1$  層目の出力ベクトルを  $z_{l-1}$  とすると、 $l$  層目のユニット群への入力ベクトル  $u_l$  は、重み行列を  $W_l$  として  $u_l = W_l z_{l-1}$  のように表される。これに WTA を適用すると、活性化関数が単調増加であるならば、最大の出力をとるユニットは最大の入力をとる

ユニットとなるので、 $l$  層目の  $i$  番目のユニットの出力は、

$$z_{l,i} = \begin{cases} u_{l,i}, & \text{if } i = \operatorname{argmax}_k u_{l,k} \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

と表され、Winner ユニットののみが出力するという形をとる。この入力に対する競合学習は Winner ユニットのみに行われるので、 $l$  層目の  $i$  番目のユニットの重みベクトルの勾配は、

$$\Delta w_{l,i} = \begin{cases} -\rho z_{l-1}, & \text{if } i = \operatorname{argmax}_k u_{l,k} \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

のように表される。ここで  $\rho$  は学習係数で、本研究では 1 層目に  $0.5 \times 10^{-3}$ 、2 層目に  $1.0 \times 10^{-3}$  を用いた。

新規に学習する場合はまず競合学習による教師なし学習を行い、ラベルによらない入力データの基底 (例えば画像であれば 2 次元空間での連続性、音声であれば倍音構造など) を表現学習する。その後、通常の CNN と同様に BP 法による教師あり学習を適用し、目的の識別課題に対してのファインチューニングを行う。

## 3. 数値モデルによる検証

提案する学習法の効果を検証するために MNIST の手書き文字セット [LeCun 98] を用いた画像識別課題を行った。ネットワークには競合学習を統合した CNN を使い、 $28 \times 28$  ピクセルの画像を入力とし、2 セットの畳込み層と、さらに 2 層の全結合層からなる (図 1)。畳込み層のユニット数は  $24 \times 24$  と  $8 \times 8$ 、受容野はそれぞれ  $5 \times 5$  と  $2 \times 2$  で、フィルター数は 25 と 50、max-pooling はともに  $2 \times 2$  とした。全結合層のユニットはそれぞれ 500 と 100 とした。ネットワークは乱数で初期化され、60,000 サンプルの訓練用セットによって学習を行い、10,000 サンプルのテスト用セットによってエラー率を確認した。競合学習、BP 学習ともに訓練用サンプルを 10 回適用して合計 600,000




図 1: 検証実験に用いた CNN の構造の概要．2 セットの畳み込み層と 2 層の全結合層から構成される．




図 2: 各種学習で獲得された画像の基底．(a) 通常の CNN．(b) WTA のみを導入したもの．(c) WTA に競合学習を適用したもの．(d) (c) にさらに BP 学習を適用したもの．

サンプルで行った．重みの更新は通常の Stochastic Gradient Descent (SGD)[Amari 67] で行い，BP 法の損失関数には平均交差エントロピーを用いた．実装には Preferred Networks 社の Chainer[Tokui 15] を用いた．

図 2 にそれぞれの学習で獲得された 1 層目のフィルターの一覧を示す．通常の CNN では表現学習が弱いので明瞭なフィルターが獲得されていない(図 2(a))．WTA を導入しただけではフィルターの獲得能力に大きな変化は生じないが(図 2(b))，競合学習を適用することによって明瞭なフィルターが獲得されていることが見て取れる(図 2(c))．このフィルターはその後の BP 学習後も維持されている(図 2(d))．

図 3 に BP 学習時の識別のエラー率の変化を示す．WTA を導入した場合はフィルター利用のための制約が増えるためエラー率が増加するが，競合学習後に BP 学習を適用することで，良質なフィルターを利用した学習が可能となり，この傾向が抑えられていることがわかる．しかしながら WTA ではより明瞭な単一のフィルターしか使用できないため，通常の CNN と同等のフィルター数では表現力が不足し，学習が遅れる傾向がある．そこで 1 層目のフィルター数を 100 に，2 層目のフィルター数を 200 に増強し，表現を拡充した状態での検証も行った所，同じネットワーク構造を持つ CNN よりも高速な学習が実現され，競合学習の有効性が示された．それぞれの条件下で 600,000 サンプル学習後のエラー率はそれぞれ 2.5%, 2.0%, 4.6%, 3.5%, 3.3%であった．

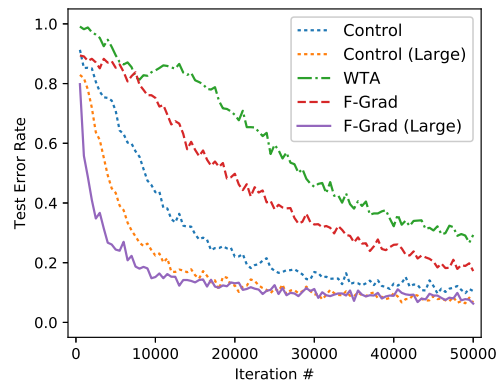


図 3: BP 学習によるエラー率の変化．それぞれ，通常の CNN，CNN のフィルターを増やしたもの(共に点線)，WTA のみを導入したもの(一点鎖線)，競合学習を適用したもの(破線)，競合学習でフィルター数を増やしたもの(実線)に対応する．

#### 4. まとめ

本研究では識別課題用の CNN において，表現学習の力を向上させることを目的に，競合学習の統合を行った．競合学習の基本メカニズムである WTA に加え，順方向に伝播する情報をもとに学習するメカニズムを導入することによって，効率の良い表現学習を実現した．特に十分な数のフィルターが確保できる場合には通常の CNN を超える性能を示した．

本手法で導入した競合学習は，CNN の通常の学習法である BP 法とシームレスに適用できることから，半教師あり学習として利用することも可能である．本手法を利用することによって，従来はサンプル数の問題から十分な表現学習が行われず，CNN の適用が困難であった医療データなどへの CNN の適用が可能となり，多方面での応用が期待される．

#### 参考文献

[Amari 67] Amari, S.: A Theory of Adaptive Pattern Classifiers, *IEEE Trans. on Electron. Comput.*, **EC-16**(3), pp. 299-307 (1967)

[Fukushima 80] Fukushima, K.: Neocognitron: a self organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, *Biol Cybern.*, **36**(4), pp. 193-202 (1980)

[Kohonen 82] Kohonen, T.: Self-organized formation of topologically correct feature maps, *Biol. Cybern.*, **43**, pp. 59-69 (1982)

[Krizhevsky 12] Krizhevsky, A., Sutskever, I & Hinton, G.E.: ImageNet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*, **25**, pp. 1106-1114 (2012)

[LeCun 89] LeCun, Y., Boser, B., Denker, J.S., Henderson, D., Howard R.E. & Jackel, L.D.: Backpropagation applied to hand-written zip code recognition, *Neural Computation*, **1**(4), pp. 541-551 (1989)

[LeCun 98] LeCun, Y., Cortes, C. & Barges, C.J.C.: *The MNIST database of handwritten digits*. (1998)

[Tokui 15] Tokui, S., Oono, K., Hido, S. and Clayton, J.: Chainer: a Next-Generation Open Source Framework for Deep Learning, *Proc. of Workshop on Machine Learning Systems (LearningSys)* (2012)