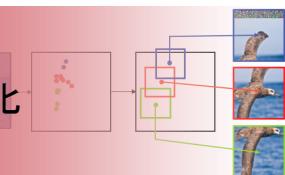


2020年度 藤吉研究室 卒業論文発表 アブストラクト

Deep Learning Fine-Grained Object Classification

視線情報を用いたアンサンブル推論による詳細画像識別の高精度化
谷中 亮佑



Deep Learning Object Detection Compositional models

2段階判定によるオクルージョンに対応した歩行者検出
秋山 賢樹



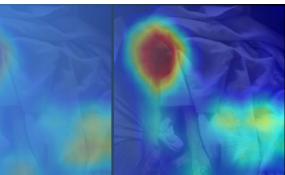
Deep Learning Attention Branch Network Data Augmentation

Mixup拡張に対するABNによるアテンションの獲得と認識精度への影響
家崎 晃



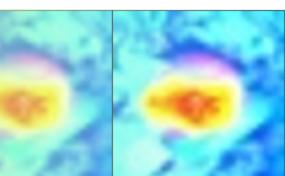
Deep Learning Attention Branch Network Attention Mining

Attention mining branchを導入したABNによるアテンションマップの最適化
岩吉 孝明



Deep Learning Attention Branch Network Adversarial Examples

Attention branchの匿名化によるAdversarial Examplesに頑健なABN
山川 翔太郎



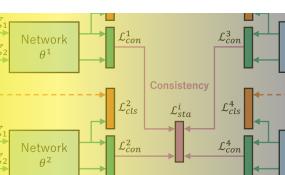
Deep Learning Knowledge Distillation

知識蒸留におけるMultiple Teacher Networkの選択
中島 優佑



Deep Learning Semi-Supervised Learning

Refined Consistencyによる知識蒸留を用いた半教師あり学習
村本 佳隆



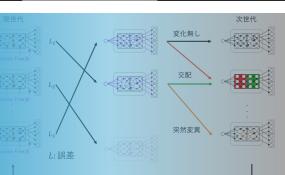
Deep Learning Reinforcement Learning Machine Learning

深層強化学習における価値・方策ベースの有効性の傾向調査
村上 遥



Deep Learning Echo State Network Hessian-Free

Hessian-Free法を用いたEcho State Networkの構造探索
濱地 優輝



1.はじめに

詳細画像識別は、同一カテゴリ内において、視覚的・意的類似している物体の種類を識別するタスクである。詳細画像識別の対象クラスは、人間が認識することさえ困難なほど視覚的差異がない場合がある。そのため、詳細画像識別では、対象物体の全体ではなく、特徴的な領域を捉える必要がある。そこで、本研究では、視線情報を用いたアンサンブル推論法について提案する。

2.アンサンブル推論

アンサンブル推論は複数の出力を加算し平均することにより汎化性能を向上させる手法である。推論時に複数の画像を入力し、それらの結果を統合して最終結果を出力する手法はTest Time Augmentation(TTA)と呼ばれる。TTAによるアンサンブル推論は式(1)のようになる。

$$y = \frac{1}{M} \sum_{m=1}^M p_m(x) \quad (1)$$

ここで、 M はデータ数、 p_m はネットワークの事後確率、 x は入力データを表す。一般物体認識では、ランダムに画像をクロップしたりコントラストを変えたりして、TTAを行う。しかし、詳細画像識別の場合、異なるクラス間で特徴が類似していることが多く、ランダムクロップによるTTAは効果が低いという問題がある。

3.提案手法

本研究では、アンサンブル推論時に人間の視線情報を用いたTTAを導入した詳細画像識別手法を提案する。

3.1 視線情報によるサンプリング

詳細物体識別において、人の知見を用いて重要となる特徴領域を与えることは有効であると考える。そこで本手法では人間の視線情報を利用する。あらかじめアイトラッカーを用いてデータセットの各画像に対し、視線情報を取得する。次に、得られた視線情報からサッケードを除外し、対象物体に対する画像上の注目座標データを求める。学習時及び推論時、注目座標データに対しMean Shiftクラスタリングを行い注視点クラスタを求め、クラスタの極大位置をクロップの中心位置とする。これらのクロップ画像を用いることで詳細物体識別に重要な特徴領域を捉えた学習及び推論を可能にする。画像のクロップ時に入力画像外にはみ出す場合、領域外を[0,255]の値で埋めるerasing、及び領域内をリサイズするresizeの2種類のいずれかを行う。これにより、画像クロップ時に発生するゼロパディングによる精度低下を抑える。視線情報を用いた固視点の密度に応じた画像のクロップを図1に示す。

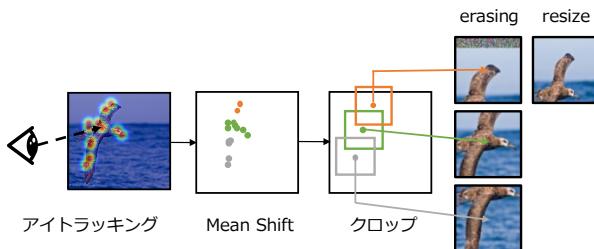


図1：固視点の密度に応じた画像のクロップ

3.2 Mean Shift クラスタリング

Mean Shiftとは、近傍の点群の平均位置に移動を繰り返し、集合の極大点を求める方法である。繰り返しステップにおける極大点探索を式(2)に示す。

$$s(x) = m(x) - x = \frac{\sum_{i=1}^n K(x_i; x, h)x_i}{\sum_{i=1}^n K(x_i; x, h)} - x \quad (2)$$

ここで、 K はカーネル関数、 x_i は点の集合、 h はバンド幅を表し。 $s(x)$ は極大点に近づくほど値が小さくなる。各点 x_i を収束先の極大点ごとにラベル付けすることでクラスタ

に分割し、それらのクラスタの極大位置を取得する。

3.3 視線情報を用いた学習とTTA

本手法では、視線情報を用いてクロップした画像を学習データとする。そして、推論では図2に示すように、視線情報を用いてTTAを行う。本手法でのクロップ枚数は4枚とする。アンサンブル推論は、式(1)に従いCNNの出力から平均クラス確率を求める。

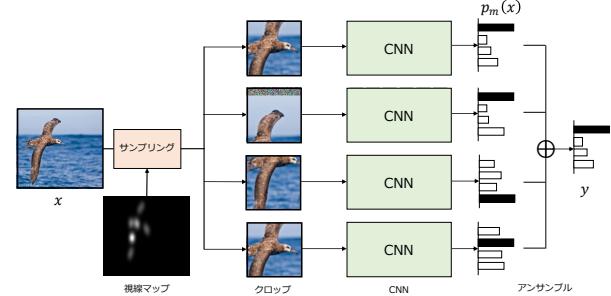


図2：視線情報を用いたTTAの概要

4.評価実験

提案手法の有効性を検証するために評価実験を行う。

4.1 実験条件

本実験では、Caltech-UCSD Birds(CUB-200-2011)[1]データセットに、視線情報を付与し、50クラス、2,880枚を用いて実験を行う。学習用に2,015枚、評価用に865枚を用いる。画像サイズは256×256画素にリサイズした後、視線情報をもとに112×112画素にクロップする。学習モデルにはResNet18を使用する。

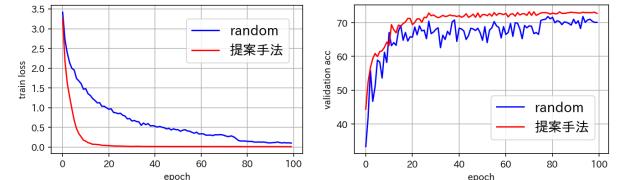
4.2 実験結果

表1に視線情報とランダムなTTAを比較対象とした結果を示す。TTAの各結果は5回試行したときの正解率の平均値と標準偏差である。表1より提案手法は、ランダムなTTAと比較して、1.71ポイント精度が向上した。

表1：クロップサイズ変更による認識精度[%]

TTAなし	TTAあり		
	ランダム	視線情報	
	erasing	resize	
71.52	72.85 ± 0.93	74.56 ± 0.73	73.86 ± 0.71

また、ランダムと視線情報を用いた場合の学習曲線を図3に示す。図3より、視線情報を用いた提案手法は学習の早期で収束している。これより、提案手法は少ないエポックでクラス特有の詳細な特徴を効率的に学習できていることがわかる。



(a) 損失の推移

(b) 認識率の推移

図3：学習曲線

5.おわりに

本研究では、視線情報を用いたアンサンブルによる詳細物体識別法を提案した。今後の展望として、視線推定モデルを用いた一貫学習によるTTAを検討する。

参考文献

- [1] Wah, C., et al. "The Caltech-UCSD Birds-200-2011 Dataset", Technical Report CNS-TR-2011-001, Caltech, 2011.

1.はじめに

歩行者検出は、画像内から歩行者の位置と大きさを推定する技術であり、自動運転において重要な機能となる。歩行者検出の代表的な手法である、Center and Scale Prediction(CSP)[1]は、Convolutional Neural Network(CNN)をベースとし、高精度に歩行者の中心点とスケールを推定する。一方で、自動運転では、歩行者の一部にオクルージョンが生じているケースでも正しく検出する必要がある。CSPはオクルージョンが発生すると、歩行者の確信度が低下し、未検出となる。そこで本研究では、CSPを用いて歩行者候補領域を検出した後、Compositional Nets[2]によるオクルージョンを考慮した最終判定を行う2段階の歩行者検出手法を提案する。

2.関連研究

本研究で用いる、CSPとCompositional Netsの構造について述べる。

2.1 Center and Scale Prediction

CSPのネットワーク構造を図1に示す。CSPは歩行者の中心点と縦横のスケールをヒートマップで推定するkeypoint型の検出手法である。ヒートマップ内の極大値を歩行者の中心点とし、極大値が歩行者の確信度となる。CSPはオクルージョンが発生していても可視部分の歩行者の特徴から中心位置を特定し、検出領域の推定が可能である。しかしながら、オクルージョンが発生している歩行者に対する確信度は低く、検出できないケースもある。

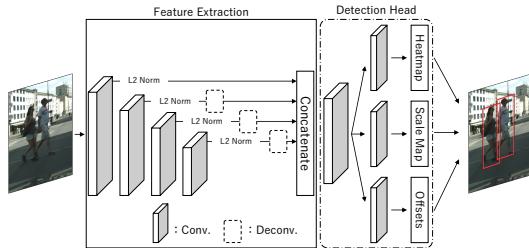


図1: Center and Scale Prediction

2.2 Compositional Nets

Compositional Netsはオクルージョンが発生している度合をヒートマップとして出力する。また、物体らしさも合せて出力する。そのため、物体の判定とオクルージョン発生の度合を同時に捉えることができる。Compositional NetsはDCNNで畠み込み処理を行い、画像の特徴を抽出する。そして、抽出した特徴マップをvMF kernelsに入力し特徴ベクトルに確率を付与する。Occluder kernelsでは、その確率を基にオクルージョン部分とそれ以外の部分に分類したオクルージョンマップを出力する。Class mixturesでは、コンテキスト情報とオブジェクト情報を合わせた物体マップを出力する。オクルージョンマップと物体マップを統合し、最終的なクラススコアとオクルージョンマップを出力する。

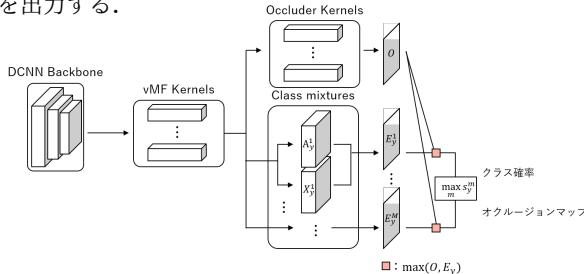


図2: Compositional Nets

3.提案手法

本研究では、CSPを用いて歩行者候補領域を検出した後、Compositional Netsによるオクルージョンを考慮した

最終判定を行う2段階の歩行者検出手法を提案する。提案手法の流れを図3に示す。1段階目では、入力画像をCSPに入力し、歩行者の確信度マップを求める。このとき、確信度のマップに対して、閾値を低く設定して多くの候補領域を出力する。次の、2段階目では、歩行者候補領域を1つずつCompositional Netsに入力し、候補領域のクラス確率とオクルージョンマップを出力する。クラス確率を基に候補領域を歩行者か否かを判定する。

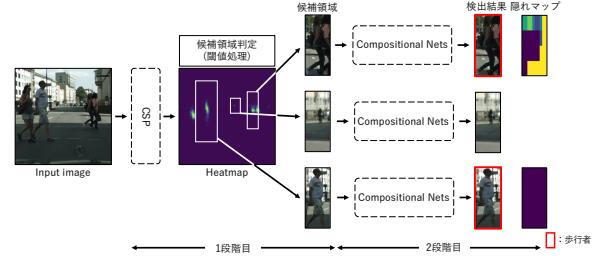


図3: 提案手法の2段階判定

4.評価実験

本実験では、従来のCSPと提案手法を比較し、その有効性を評価する。

4.1 実験概要

学習、評価にはCityPersonsデータセットを用いる。評価指標にはMiss Rate(未検出率)を用いる。評価は、Bare, Partial, Heavy, Reasonableのオクルージョン度合ごとにMiss Rateを算出し、従来手法(CSP単体)との比較を行う。

4.2 実験結果

従来手法と提案手法を比較した結果を表1に示す。表1より、提案手法を従来手法と比較して、Heavyにおいてしきい値0.25とした時、Miss Rateの精度を6.76ポイント向上させることができた。提案手法の検出結果とオクルージョンマップを図4に示す。図4から提案手法は、歩行者のオクルージョン領域の推定に成功し、正しい判定結果を出力することができ、検出できていることが分かる。

表1: 実験結果(Miss Rate)

	閾値	Reasonable	Bare	Partial	Heavy
従来法	0.5	20.28	15.49	21.03	60.90
	0.1	17.93	13.30	18.03	55.55
提案手法	0.25	16.82	12.37	16.48	54.14
	0.5	18.65	13.96	19.10	58.65

ジョーンマップを図4に示す。図4から提案手法は、歩行者のオクルージョン領域の推定に成功し、正しい判定結果を出力することができ、検出できていることが分かる。



図4: 定性的結果

5.おわりに

本研究では評価実験からオクルージョンの考慮をした2段階の判断により精度が向上することを確認した。今後は、本提案手法の更なる高精度化を目指す。

参考文献

- [1] W. Liu *et al.*, “Center and Scale Prediction:A Box -free Approach for Pedestrian and Face Detection”, CVPR 2019.
- [2] A. Kortylewsk, *et al.*, “Compositional Convolutional Neural Networks:A Deep Architecture with Innate Robustness to Partial Occlusion”, CVPR 2020.

1.はじめに

深層学習のホワイトボックス化として、認識時に判断根拠を可視化し視覚的説明を行うことは重要である。Attention Branch Network(ABN)[1]は、視覚的説明だけではなく、判断根拠をアテンションとしてアテンション機構に応用することで可視化に貢献している。一方で、物体認識では学習データとそのバリエーションを確保するために画像合成して水増しするデータ拡張が活用されている。特に画像を合成するアプローチは精度向上に大きく寄与している。しかしながら ABNにおいて、画像合成を行うデータ拡張の影響が十分に考慮されていない。そこで、本研究では画像合成を行うデータ拡張を追加することで、ABNの判断根拠および精度に対してどのような影響が出るのかを調査する。

2. Attention Branch Network(ABN)

ABNは、物体認識時の判断根拠となる注目領域をアテンションマップとして可視化しつつ、認識を利用する手法である。図1のようにABNは、Feature extractor, Attention branch, Perception branchの3つのモジュールから構成されている。Feature extractorは、入力画像に対する特徴マップを抽出する。抽出した特徴マップをAttention branchに与え、アテンションマップを獲得する。アテンションマップは入力画像に対する注視領域を示し、Feature extractorの特徴マップに乗算し、Perception branchに与える。Perception branchは認識結果を出力する。

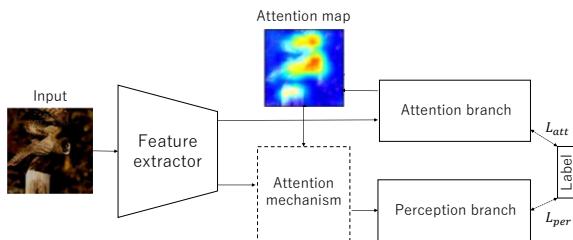


図 1: Attention Branch Network の構成

3. データ拡張

データ拡張には、平行移動・拡大縮小などの幾何学変換を加える方法、明るさやノイズを加える方法、画像を合成する方法がある。画像を合成する方法には、2つの画像とラベルを混合するmixup、画像内のある領域をランダムに黒く塗りつぶすcutout、画像の一部にランダムな画像をはめ込むcutmixがある。合成したデータを学習用データに追加することで過学習を抑制でき、性能の向上が期待できる。図2に各手法の例を示す。



(a) mixup (b) cutout (c) cutmix

図 2: データ拡張の例

4. 調査

ABNは、アテンションマップを特徴マップに反映させることで認識に重要な領域に注目した認識結果となる。そのため、データ拡張により合成された画像を用いると、アテンションマップに悪影響を及ぼすことが考えられる。本研究では、mixup, cutout, cutmixの3つのデータ拡張手法をABNの学習に用いて、それらの影響を調査する。

4.1. 実験条件

本実験では、データセットにCIFAR100とImageNetを用いる。学習パラメータはバッチサイズを128、epoch数をCIFAR100では300、ImageNetでは200とする。学

習係数を0.1に設定し、CIFAR100では150と225epoch、ImageNetでは100と150epochの時に学習係数を0.1倍する。Top1精度に加え、判断根拠の定量的評価にはinsertionとdeletionを用いる。insertionは重要な領域を追加していく、その時の認識精度がわずかな領域でも向上すると良い。deletionは重要な領域を削除していく、その時の認識精度が領域でも低下すると良い。これらの領域を追加または削除する割合を変え、その時のArea Under Curve (AUC)で評価する。

4.2. 実験結果

CIFAR100とImageNetでの評価結果を表1に示す。CIFAR100では、ResNet20とResnet152どちらもデータ拡張を用いることで精度が向上していることが確認できる。また、ネットワークモデルによって最も性能の良いデータ拡張手法が異なることがわかった。ImageNetでは、ResNet18においてcutoutの精度向上が見られたが、mixupとcutmixでは精度の向上が見られなかった。ResNet152においては、どのデータ拡張を用いても精度が向上していることが確認できた。これらの結果から、大規模なデータセットを対象とする場合ネットワークサイズの小さいモデルに対しては、画像データのラベルを変えないcutoutが有効的であり、ネットワークサイズの大きいモデルに対しては、2枚の画像を合成するようなmixupやcutmixが有効であると考えられる。

表 1: 実験結果

データセット	CIFAR100		ImageNet		
	ネットワーク	ResNet20	ResNet152	ResNet18	ResNet152
DAなし		69.32	76.78	70.34	77.87
+mixup		70.19	79.71	67.64	77.90
+cutout		72.58	78.79	70.87	78.74
+cutmix		71.05	80.80	68.07	79.32

ImageNetでのアテンションマップの可視化結果を図3に示す。図3より、データ拡張を用いることで精度は向上したが、mixupとcutmixでは注視する領域が増えている。一方、cutoutでは注視領域が限定されている。

アテンションマップの評価結果を表2に示す。表2より、データ拡張前と比較して精度向上は見られない。これより、mixupベースのデータ拡張は、精度向上に貢献するが、アテンションマップに悪影響を及ぼすことが分かった。



(a) 画像 (b)ResNet152(c)+mixup (d)+cutout (e)+cutmix

図 3: アテンションマップの比較

表 2: insertion と deletion による定量的評価 (AUC)

ネットワーク	insertion ↑	deletion ↓
ResNet152	0.267	0.426
+ mixup	0.224	0.452
+ cutout	0.261	0.451
+ cutmix	0.271	0.474

5. おわりに

今回は、ABNにデータ拡張を用いた際の精度比較を行った。ネットワークサイズの変化により、最も性能の良いデータ拡張手法が異なるということが分かった。今後は、これらのデータ拡張手法を組み合わせた際の影響について調査する。

参考文献

- [1] H. Fukui, et al., “Attention Branch Network: Learning of Attention Mechanism for Visual Explanation”, CVPR, 2019.

1.はじめに

Attention Branch Network (ABN)[1] は、認識時におけるネットワークの注視領域を可視化し、認識処理に活用することで、高精度化を実現している。認識対象の物体以外に注視領域が発生すると、誤認識を誘発することがある。これを解決する手法として、人の知見により修正したアテンションマップを用いて ABN を再学習する手法 [2] が提案されている。しかしながら、本手法はアテンションマップを人が修正するため人的コストが掛かる。本研究では、ABN に Attention mining branch を導入し、アテンションマップを自動で最適化する手法を提案する。

2. Attention Branch Network

ABN は、Feature extractor, Attention branch, Perception branch から構成される。Feature extractor は入力画像から特徴マップを抽出する。これを Attention branch に与え、アテンションマップを獲得する。アテンションマップを特徴マップに乗算し、Perception branch に与えることで認識結果を出力する。ABN を応用した研究として、人の知見を導入する手法がある。この手法では、ABN で誤認識が発生した画像のアテンションマップを人の知見に基づいてすべて修正する。その後、それらを学習データに追加して再学習することにより認識精度が向上する。

3. 提案手法

本研究では、ABN に Attention mining branch を導入したアテンションマップの最適化手法を提案する。提案手法のネットワーク構造を図 1 に示す。

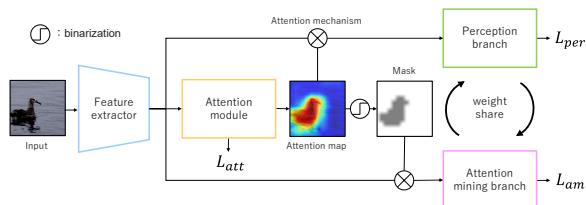


図 1：提案手法

提案手法では、ABN に Perception branch と重みを共有した Attention mining branch を追加する。Attention mining branch には、Mask を適用した特徴マップを入力し、クラス確率を出力する。ここで、Mask は Attention module で獲得したアテンションマップを 2 値化して生成する。この Mask を特徴マップに乗算することで注視した領域を隠した特徴マップを獲得できる。Mask 適用後の特徴マップ F^{*c} は、特徴マップを F 、Mask を $T(A^c)$ とすると式 (1) のように表される。

$$F^{*c} = F - (T(A^c) \odot F) \quad (1)$$

提案手法では、Attention mining branch から出力した各サンプルのクラス確率の総和を新たな損失とする。これにより、Mask を適用していない領域のクラス確率を最小化するように学習し、認識対象の物体のみを注視するようにアテンションマップを最適化する。Attention mining branch の損失 L_{am} は、クラス確率を $S_i^c(F^{*c})$ 、サンプル数を n とすると式 (2) のように表される。

$$L_{am} = \sum_{i=1}^n S_i^c(F^{*c}) \quad (2)$$

Attention module の出力と正解クラスのクロスエントロピー誤差を L_{att} 、Perception branch の出力と正解クラスのクロスエントロピー誤差を L_{per} 、 L_{am} の重みを α とすると、提案手法の損失関数 L は式 (3) のように表される。

$$L = L_{att} + L_{per} + \alpha L_{am} \quad (3)$$

提案手法では、段階的に学習する。まず ABN のみを事前学習する。そして、Attention mining branch を追加してアテンションマップの最適化となる再学習を行う。

4. 評価実験

提案手法の有効性を評価するために評価実験を行う。

4.1 実験条件

本実験では、Caltech-UCSD Birds 200-2010 (CUB-200-2010) データセットと、Stanford Dogs データセットを用いる。ベースネットワークとして ResNet-50 を使用し、バッチサイズは 16 とする。Mask の閾値は CUB-200-2010 データセットで 0.83、Stanford Dogs データセットで 0.40 とする。 L_{am} の係数 α は 0.0001 に設定する。学習の更新回数は ABN の事前学習、提案手法それぞれで 300epoch とする。

4.2 実験結果

各データセットにおける認識精度の比較を表 1 に示す。表 1 より、CUB-200-2010 データセットにおいて、提案手法は、人の知見を導入する手法よりも Top-1 の認識精度が低くなっているが、ABN よりも向上していることが確認できる。また、Stanford Dogs データセットにおいて、提案手法が ABN よりも、Top-1 の認識精度が向上していることが確認できる。

表 1：認識精度の比較 [%]

Model	CUB-200-2010		Stanford Dogs	
	Top-1 acc.	Top-5 acc.	Top-1 acc.	Top-5 acc.
ABN	31.68	57.01	71.81	93.02
提案手法	33.33	58.56	71.99	92.80
人の知見	37.42	62.08	-	-

4.3 アテンションマップの可視化

ABN、提案手法、人の知見を導入する手法の Attention map の比較を図 2 に示す。図 2 (a), (b) より、人の知見を導入する手法は、より局所的な領域に着目してクラス識別ができる。一方で、図 2 (c) のように、人の知見を反映させすぎると誤認識を誘発する事がある。これに対し、提案手法は広範囲を注視できているため正しく認識している。

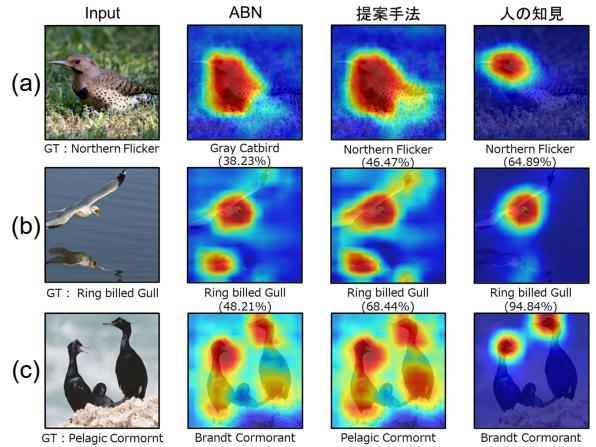


図 2：アテンションマップの可視化例

5. おわりに

本研究では、Attention mining branch を追加した ABN を提案した。評価実験では、提案手法を用いることにより、認識精度が向上した。また、注視領域についても改善されていることが確認できた。今後は、他のデータセットに対して提案手法の評価を行う。

参考文献

- [1] H. Fukui, et al., “Attention Branch Network: Learning of Attention Mechanism for Visual Explanation”, CVPR, 2019.
- [2] M. Mitsuhashi, et al., “Embedding Human Knowledge into Deep Neural Network via Attention Map”, VISAPP, 2021.

1.はじめに

Attention branch network (ABN) [1] は、学習時または推論時にネットワークの注視領域を利用することで、高精度な認識かつ判断根拠の視覚的な説明が可能である。しかし、人工的な摂動を付与した画像である Adversarial examples (AEs) をネットワークへ入力すると、高い信頼度で誤認識する。そこで、本研究では ABN の Attention branch を匿名化することにより、AEs に対して誤認識を緩和する手法を提案する。

2.関連研究

ABN は、入力から特徴を抽出する Feature extractor (FE), 注視領域を出力する Attention branch (AB), 注視領域を反映した特徴マップから最終的な出力をする Perception branch (PB) で構成されている。注視領域を学習時、及び推論時に利用することで、高精度な認識が可能である。また、注視領域は入力画像の認識結果に対する視覚的理験の促進につながる。

Adversarial attack は、人が知覚困難な摂動を画像に付与することで、Convolutional neural network (CNN) の誤認識を誘発する。Fast Gradient Sign Method (FGSM) [2] は、CNN の認識誤差 $\mathcal{L}(x, y, \theta)$ を入力画像 x の各画素に関して微分することで勾配を求める。そして、求めた各画素の勾配を Sign 関数によって符号を抜き出すことで、摂動の単位ベクトルを獲得する。AEs である \hat{x} を作成するには、単位ベクトルに摂動の強度を表す $\epsilon \in [0, 255]$ を乗算して x に加算する。摂動を加算することで、誤差を最大化する AEs を作成することが可能となる。FGSM の一連の流れは、式 (1) によって表現することができる。

$$\hat{x} := x + \epsilon \cdot \text{sign}(\nabla_x \mathcal{L}(x, y, \theta)) \quad (1)$$

3.提案手法

ABN は Adversarial attack を想定した設計でないため、AEs を入力すると著しく性能が劣化する。そこで本研究では、AB を匿名化する。そして、FE と PB を攻撃対象として AEs を作成する。AEs の推論時は AB を追加して最終結果を求める。提案手法は以下に示す 3 ステップから成る。

Step1 ABN を通常の学習データを用いて訓練して、優秀になった AB を切り離して匿名化する。

Step2 PB の出力と教師信号との誤差を入力画像に関して微分することで誤差を最大にする単位ベクトルを求める。

Step3 匿名化した AB を付け足したネットワークに、AEs を入力し、注視領域を求める。そして、注意領域を重み付した特徴マップを PB に入力して推論を行う。

図 1 に Step2 と Step3 の一連の流れを示す。

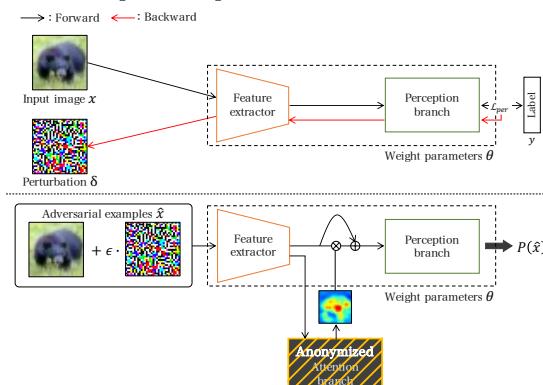


図 1 : 提案手法の流れ

4.評価実験

提案手法の有効性を示すために、定量的な認識性能の評価及び定性的な注視領域の評価をする。

4.1.実験条件

本実験では、データセットとして 100 クラスの自然画像を含む CIFAR-100 を用いる。CIFAR-100 は画像サイズが 32×32 ピクセルの RGB 画像で、5 万枚が学習用、1 万枚が推論用である。ABN のベースネットワークとして 110 層の ResNet を使用する。ミニバッチサイズは 128 として 300 epoch 学習する。摂動の作成手法は、 $\epsilon = 8$ の FGSM とする。比較手法は通常の ABN の推論結果及び、ABN を AEs で攻撃した結果とする。

4.2.実験結果

表 1 に示すように、ABN は AEs の影響により認識性能が著しく低下した。一方、提案手法は、匿名化した AB が出力した注視領域を特徴マップに反映することで、60 ポイント以上の性能向上を確認した。AEs を用いない場合 (ABN) の推論結果と比較すると、提案手法は 11 ポイント程度の劣化に留めることを可能とした。

表 1 : 認識精度の比較 (%)

	ABN	ABN+AEs	Ours
top-1	77.18	1.82	65.22
top-5	93.54	9.12	87.49

注視領域を図 2 に示す。図 2 より、提案手法は AEs を入力しているにも関わらず、発火する領域は ABN とほぼ同じであることが確認できる。この結果から、AB は AEs によって外部から攻撃されても、入力画像に対して正しい領域を注視することができる。また、AEs により FE が変動した特徴量を計算しても、正しい注視領域を強調することで、性能を維持できることができた。

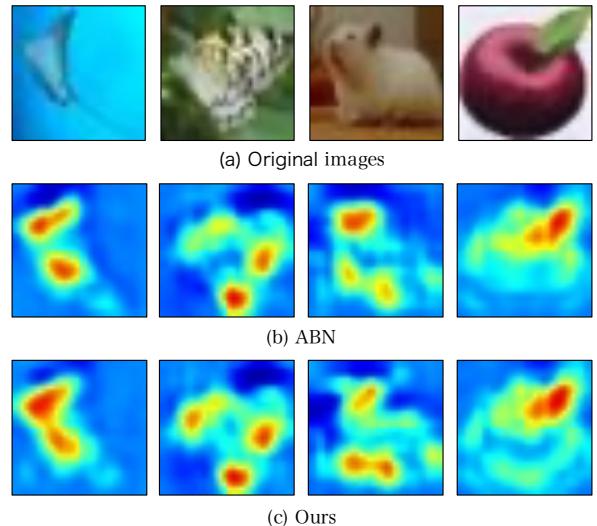


図 2 : 注視領域の例

5.おわりに

本研究では、人工的な摂動である Adversarial examples(AEs) に頑健な Attention branch network(ABN) を提案した。実験より、AEs が入力されても注視領域の変動が微小であることを確認した。また、認識結果は入力画像に対して正確な領域を強調することで、ある程度維持できることが判明した。今後は、本提案手法の更なる分析をする予定である。

参考文献

- [1] H. Fukui, et al., “Attention Branch Network: Learning of Attention Mechanism for Visual Explanation”, CVPR, 2019.
- [2] I. Goodfellow, et al., “Explaining and Harnessing Adversarial Examples”, ICLR, 2014.

1.はじめに

知識蒸留は Teacher Network の知識を Student Network に伝えることで、精度低下を抑制しつつモデルサイズを圧縮する手法である。Teacher Network と Student Network のモデルサイズに大きなギャップがあると、Student Network の精度が向上しない問題がある。本研究では、サイズの異なる複数の Teacher Network を用いる Multiple Teacher Network を提案し、知識蒸留の高精度化を目的とする。

2.知識蒸留と問題点

知識蒸留には、Teacher Network の出力を利用する Knowledge Distillation (KD)[1] と、中間情報を利用する Contrastive Representation Distillation(CRD)[2] がある。表 1 に Student Network を ResNet20 にした場合の KD による蒸留後の精度と Teacher Network のモデルサイズ(パラメータ数)を示す。Teacher Network が WRN40_2 より大きなモデルサイズになると、大幅な精度低下を招くことがわかる。本研究では、この問題が発生する Teacher Network を Large Teacher Network(LTN)，発生しない Teacher Network を Medium Teacher Network(MTN) と呼称する。この問題を解決する手法として、Teacher Network と Student Network 間に Teacher Assistant(TA) と呼ぶモデルを配置し、段階的に蒸留する手法 [3] が提案されているが、段階的な学習を必要とする。

表 1: ResNet20 に対する蒸留後精度

Teacher Network	WRN28_1	ResNet32	WRN28_2	WRN40_2	WRN28_6	WRN28_10
パラメータ数	371,347	466,457	1,147,251	2,248,991	13,155,603	36,497,171
精度	71.27	71.12	70.98	70.25	70.14	69.60

3.提案手法

本研究では、図 1 に示すように複数の Teacher Network から蒸留する Multiple Teacher Network を提案する。このとき、どのように Teacher Network を選択すると効果的であるか調査する。提案手法では、Teacher Network の組み合わせを MTN+LTN とし、MTN に Student Network と LTN の橋渡し的な役割を期待する。また、MTN のみで蒸留を行った場合よりも、LTN を含めて蒸留することで、その知識も活用できると考える。

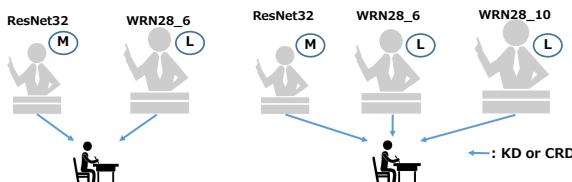


図 1: 提案手法の概念図

本研究での Student Network と Teacher Network 間の蒸留手法には、KD, CRD のいずれかを用いる。KD の損失関数を式 (1) に示す。

$$L_{KD} = \alpha L_{hard} + (1 - \alpha) \tau^2 L_{soft} \quad (1)$$

ここで、 α は係数、 τ は温度パラメータを示す。CRD の損失関数を式 (2) に示す。

$$\begin{aligned} L_{CRD} &= \mathbb{E}_{q(g^T, g^S | C=1)} [\log \frac{e^{g^T g^S / \tau}}{e^{g^T g^S / \tau} + \frac{N}{M}}] \\ &+ N \mathbb{E}_{q(g^T, g^S | C=0)} [1 - \log \left(\frac{e^{g^T g^S / \tau}}{e^{g^T g^S / \tau} + \frac{N}{M}} \right)] \end{aligned} \quad (2)$$

ここで、 τ は温度パラメータ、 M はデータセットのカーディナリティで、データの種類がどのくらいあるかの度合いを表している。 N は入力データの非類似ペアの数である。 g^S と g^T は各ネットワークの出力層手前から抽出した出力を線形変換させ、L2 ノルムで正規化したものである。

また、最終的な損失は式 (3) に示す通り、全ての損失を総和した値になる。

$$L_{total} = \sum_{i=0}^n L_{iKD \text{ or } CRD} \quad (3)$$

4.評価実験

提案手法の有効性を評価するため、評価実験を行う。TA とも比較し評価する。

4.1. 実験概要

データセットには CIFAR-100 を使用し、学習時のエポック数は 200、バッチサイズは 64 とする。学習モデルは Student Network に ResNet20、LTN に WRN40_2～WRN28_10、MTN に WRN28_1～WRN28_2 を用いる。

4.2. 実験結果

表 2 は 2 つの Teacher Network を用いて蒸留した精度を示す。TN1, 2, 3 にはそれぞれ異なるモデルを使用し、TN3 は TN2 や TN1 より大きく、TN2 は TN1 より大きいモデルである。Teacher Network の組み合わせは、MTN のみ、MTN+LTN、LTN のみの 3 種類ある。

表 2: 2 つの Teacher Network で蒸留した精度

Teacher Network	提案手法				
	TN1	TN2	TA	KD	CRD
MTN のみ	ResNet32	WRN28_2	71.12	71.26	72.13
MTN+LTN	ResNet32	WRN28_6	70.83	71.24	71.73
MTN+LTN	ResNet32	WRN28_10	70.24	71.37	71.61
LTN のみ	WRN28_6	WRN28_10	69.37	69.92	70.75

表 2 から、MTN のみの場合が最も精度が高く、LTN のみの場合が最も低くなった。MTN+LTN の場合は、LTN のみより精度が高い。以上より、2 つの Teacher Network のうち 1 つを MTN にすることで、Student Network と LTN 間の蒸留で生じる問題を回避することができる。

表 3: 3 つの Teacher Network で蒸留した精度

Teacher Network	提案手法					
	TN1	TN2	TN3	TA	KD	CRD
MTN のみ	WRN28_1	ResNet32	WRN28_2	71.18	71.92	72.19
MTN+LTN	ResNet32	WRN28_2	WRN28_6	70.24	71.06	71.83
MTN+LTN	WRN28_2	WRN28_6	WRN28_10	68.87	70.15	71.00
LTN のみ	WRN40_2	WRN28_6	WRN28_10	68.99	70.01	70.55

表 3 は 3 つの Teacher Network を用いて蒸留した精度を示す。表 3 から、MTN+LTN の場合、精度低下を抑制することができないことがわかる。MTN のみの場合が最も高精度である。以上より、Teacher Network 数を増やしても LTN がある場合、高精度化が難しいことが判明した。

5.おわりに

本研究では、能力差のある Student Network と Teacher Network 間の蒸留の際に、MTN+LTN の組合せを含めてそれらを同時に蒸留させることを提案した。これにより、Teacher Network を 2 つ使用する場合は精度の低下を抑え、MTN のみの精度に匹敵し、さらに Teacher Network が 1 つのみで蒸留を行った場合よりも精度が向上することを確認した。また、TA と異なり段階的な学習を必要とせず、その分学習時間を短縮できることも確認した。

参考文献

- [1] G. Hinton, et al., “Distilling the knowledge in a neural network”, NeurIPS Workshop, 2015.
- [2] Y. Tian, et al., “Contrastive Representation Distillation”, ICLR, 2020.
- [3] S. Mirzadeh, et al., “Improved Knowledge Distillation via Teacher Assistant”, AAAI, 2020.

1.はじめに

半教師あり学習は、ラベルありデータとラベルなしデータの双方を用いた学習法である。半教師あり学習手法として、2つのネットワーク間で知識を転移する Dual Student(DS) [1]、DS のネットワーク数を4つ以上に拡張した Multiple Student(MS) [1] が提案されている。MS は DS に比べて高い精度であるが、全てのネットワーク間での知識転移を一度に行うことができないため、学習効率が悪い。そこで本研究では、効率的な知識転移方法による精度向上を目的として、1度に全てのネットワーク間で知識を転移する Refined Consistency を提案する。また、一貫性に基づいた半教師あり学習手法に利用されるデータ拡張手法を適用し、精度変化を評価する。

2. Dual Student

DS は、2つのネットワークを用いた半教師あり学習手法である。各ネットワークには、同じ入力に対して異なる摂動を加えた2つの入力を与える。そして、摂動に対して頑健になるよう学習する。さらに、安定性という指標を用いてネットワーク出力の一貫性を評価し、安定性が高いネットワークから優れた知識を転移させている。知識は多くのネットワークから転移させる方が高い精度を達成できる。MS は DS を拡張し、4つのネットワークを用いている。MS は、1度にランダムな2つのネットワークを用いて、DS と同様の方法で学習する。

3. 提案手法

本研究では、1度に全てのネットワーク間で知識を転移する Refined Consistency を提案する。MS と提案手法について、1イタレーションごとの知識転移の方向を図1に示す。提案手法の学習方法を図2に示す。

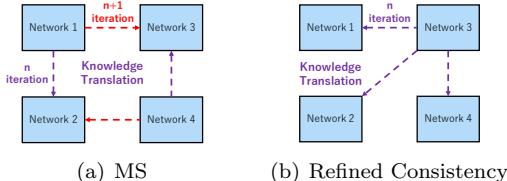


図1: 知識転移方向の例 (ネットワーク数4)

入力 x に対するネットワーク i の損失関数 $\mathcal{L}^i(x)$ を式(1)に示す。

$$\mathcal{L}^i(x) = \mathcal{L}_{cls}^i + \lambda_1 \mathcal{L}_{con}^i + \lambda_2 \mathcal{L}_{sta}^i \quad (1)$$

ここで、 λ_1, λ_2 は重み係数であり、 \mathcal{L}_{cls} は推測値とラベル間の交差エントロピーであり、 x がラベルありデータである場合のみ計算する。 \mathcal{L}_{con} は一貫性損失、 \mathcal{L}_{sta} は安定化損失を表す。安定化損失は、各ネットワークの一貫性損失を用いて計算する。

一貫性損失は、異なる摂動を入力に与えたときの事後確率間の誤差であり、値が小さいほどネットワークが摂動に頑健であることを表す。一貫性損失を式(2)に示す。

$$\mathcal{L}_{con}(x) = \mathbb{E}_{x \in \mathcal{D}} \|f(\theta^i, x + \zeta_1) - f(\theta^i, x + \zeta_2)\|^2 \quad (2)$$

ここで、 \mathcal{D} はデータセット、 ζ_1, ζ_2 はランダム性のある摂動、 $f(\theta, x)$ は重み θ をもつネットワークの事後確率を表す。

安定化損失は、一貫性損失を知識の指標として、最も一貫性損失が小さいネットワーク θ^s から他の全てのネットワークに知識を転移する。転移先のネットワークを θ^i とすると、知識は、事後確率を近づけるように学習することで転移させる。安定化損失を式(3)に示す。

$$\mathcal{L}_{sta}(x) = \begin{cases} 0 & (\mathbf{A} = \emptyset) \\ \|f(\theta^i, x) - f(\theta^s, x)\|^2 & (\text{otherwise}) \end{cases} \quad (3)$$

ここで、 $\mathbf{A} = \{i \mid \mathcal{R}(f(\theta^i, x + \zeta_1), f(\theta^i, x + \zeta_2)) = \text{True}\}$ であり、 \mathcal{R}_x^i は入力 x に対し、摂動を付与した際の出力

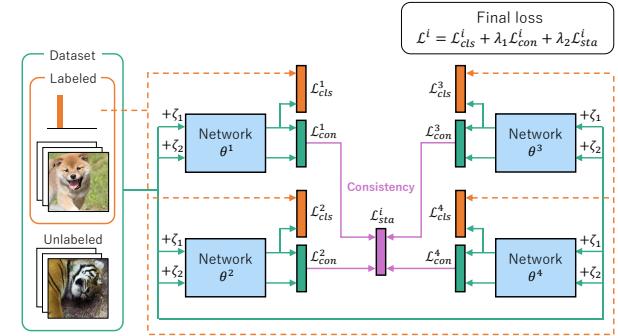


図2: Refined Consistency の学習方法
(ネットワーク数4)

$f(\theta^i, x + \zeta_1)$ と $f(\theta^i, x + \zeta_2)$ のクラスが一致した場合に真となる。

4. 評価実験

4.1. 実験概要

提案手法と MS の精度を比較する。データセットに CIFAR-100、ベースモデルに13層のCNNを使用する。学習回数は350 epoch、ネットワーク数は4, 8とする。データ拡張として、左右反転、ランダムな画素数平行移動したのちに反射パディングを行う。CIFAR-100は、クラス数が100であり、学習用に50,000枚、推論用に10,000枚の画像で構成される。本実験では、学習用画像のうち10,000枚をラベルありデータ、他40,000枚をラベルなしデータとする。

一貫性に基づいた半教師あり学習手法では、RandAugment(RA) [2]などの大きな摂動を付与するデータ拡張手法を扱うことによって精度が向上する[3]。そこで、RAの有無による精度変化を評価する。

4.2. 実験結果

提案手法およびMSの精度、各手法に対してRAを適用した精度を表1に示す。各結果は5回試行した時の正解率の平均値と標準偏差である。表1から、提案手法はMSと比べて、ネットワーク数4で0.26 pt、ネットワーク数8で0.31 pt 精度が高い。よって、提案手法における知識転移は有効であると言える。さらに、RAと提案手法を組み合わせることで、その効果は最大となり68.18%まで向上した。

表1: CIFAR-100 を用いた精度比較 [%]

手法	拡張	ネットワーク数	
		4	8
MS	-	66.70±0.15	66.93±0.09
	RA	66.43±0.14	66.34±0.10
提案手法	-	66.96±0.12	67.24±0.06
	RA	66.96±0.04	68.18±0.10

5. おわりに

本研究では、1度に全てのネットワーク間で知識を転移する Refined Consistency を提案した。評価実験では、提案手法が MS に比べて高精度であることを示した。今後は、知識転移グラフへの応用を行う予定である。

参考文献

- [1] K. Zhanghan, et al., “Dual Student: Breaking the Limits of the Teacher in Semi-supervised Learning”, ICCV, 2019.
- [2] E. Cubuk, et al., “RandAugment: Practical automated data augmentation with a reduced search space”, NeurIPS, 2019.
- [3] K. Sohn, et al., “FixMatch: Simplifying Semi-Supervised Learning with Consistency and Confidence”, NeurIPS, 2020.

1.はじめに

深層強化学習は、深層学習と強化学習を組み合わせた学習方法である。強化学習は、ある環境から獲得できる報酬の最大化を目的とし、最適な行動を獲得する学習方法である。深層強化学習手法には、大別して価値ベースと方策ベースがある。深層強化学習は人の性能を超えることもあるが、手法ごとに学習環境や学習条件が異なるため、各手法にどのような傾向があるか明確でない。そこで本研究では、価値ベース・方策ベースで代表的なアルゴリズムの傾向の調査を行う。

2.深層強化学習

深層強化学習は、深層学習と強化学習を組み合わせた学習方法である。以下に、価値ベースと方策ベースの手法について述べる。

2.1.価値ベース

価値ベースは、行動の価値の最大化することを目的として、Q学習を用いて学習する。Q学習はTD誤差により、行動の価値を更新する。TD誤差 δ はある状態 s で行動 a を行うときの行動の価値 $V(s)$ と、行動後の状態 s' における行動の価値 $V(s')$ の差をもとに式(1)のように算出する。TD誤差が大きいほど状態 s での行動の価値が高くなる。

$$\delta = r + \gamma V(s') - V(s) \quad (1)$$

ここで、式(1)の、 r は報酬、 γ は、割引率である。

Deep Q-Network(DQN)[1]：行動の価値(Q値)を畳み込みニューラルネットワークによる近似関数で表現した強化学習手法である。また、Experience ReplayやTarget Q-Network、Reward Clippingを導入して、膨大な状態数の画像入力に対応している。

Categorical DQN[2]：DQNを基とし、行動価値を分布として表現する強化学習手法である。

2.2.方策ベース

方策ベースは、行動の規範となる方策を最適化することを目的として、方策勾配法を用いて学習する。方策勾配法は方策 π_θ のパラメータ θ で、収益(報酬の総和)の期待値を微分して勾配を算出し式(2)のように更新する。式(2)の α は学習率を、 J は期待収益を示す。

$$\theta^{t+1} \leftarrow \theta^t + \alpha \nabla_\theta J(\theta) \quad (2)$$

Asynchronous Advantage Actor-Critic(A3C)[3]：複数のworkerを用いて非同期的にパラメータ更新を行うAsynchronous、2ステップ以上先の報酬を考慮するAdvantage、現在の状態における行動選択と行動を評価を同時にActor-Criticの3つを合わせた強化学習手法である。

Trust Region Policy Optimization(TRPO)[4]：更新前と更新後の方策 $\pi_{\theta_{old}}$ とのKLダイバージェンスをしきい値 δ 以下に抑える制約を用いて、方策を改善する強化学習手法である。

Proximal Policy Optimization(PPO)[5]：TRPOを基に更新前と更新後の方策 $\pi_{\theta_{old}}$ の変化量を一定の範囲内にクリッピングことで学習を安定させる強化学習手法である。

3.価値・方策ベースの有効性調査

複数のタスクにおいて強化学習手法の傾向を調査する。本実験では、使用する強化学習手法として、DQN・Categorical DQN・A3C・TRPO・PPOを用いる。

3.1.調査環境

環境には、Open AIが提供するAtari 2600のゲームタスクのうちBreakout、Ms.Pacman、Pong、Qbert、Spaceinvadersを使用する。これらの環境は報酬の種類や、難易度が異なるように選択した。Breakoutは、パドルでボールを打ち返しブロックを崩すゲームである。Ms.Pacmanは、ゴーストを回避しながらクッキーを食べるゲームである。Pongは、CPUとホッケーを行うゲームである。Qbertは、ジャンプしてブロックの色を変更するゲームである。Spaceinvadersは、インベーダーを打ち抜くゲームである。各手法は 1.0×10^7 エピソードの学習を行い、1000回テストした時の平均スコアを算出する。また、ランダムに行動を選択した場合のスコアとも比較する。

3.2.調査結果

表1に各ゲームにおける各手法の平均スコアを示す。表1から、Breakout・Qbert・Spaceinvadersでは、Categorical DQN、PPOが高スコアを獲得した。Categorical DQNは行動価値を分布で表現することにより、学習に含まれない状態に対する行動価値を正しく求めることができたため、スコアが向上したと考えられる。PPOは方策の変化量のクリッピング効果により学習に含まれる状態にオーバーフィットしないため、スコアが向上したと考えられる。この3つのゲームでは、価値ベース・方策ベースのどちらも有効である。

Ms.Pacmanでは価値ベースの手法の方が高いスコアを獲得した。これは、Ms.Pacmanがエピソード後半で獲得できる報酬が少なくなると時、ゲームの進行に合わせて獲得できる報酬が減るため、方策ベースでは適切な行動を得ることができない。Pongは、全ての手法において高スコアを獲得できている。これは、環境のタスクが容易であるため、手法による大きな差が出なかったためであると考えられる。

表1：1000エピソード間の平均スコア

		Breakout	Qbert	Spaceinvaders	Ms.Pacman	Pong
価値ベース	Random	2.2	375.0	75.0	218.4	0.0
	DQN	89.2	4325.6	803.5	4226.5	19.3
	Categorical DQN	406.5	14099.5	1483.5	3995.2	21.0
方策ベース	A3C	2.5	4353.2	486.2	1941.6	18.7
	TRPO	2.6	4401.2	876.6	1698.2	21.0
	PPO	427.5	15897.6	1128.5	1680.4	21.0

4.おわりに

本研究では、Atari 2600における様々な強化学習手法の有効性調査を行った。報酬を獲得できない環境には価値ベース、反対に常に一定の報酬を獲得できる環境にはCategorical DQN、PPOが有効であることがわかった。この傾向をもとに、既存の強化学習手法を組み合わせたアンサンブル強化学習手法の開発が期待できる。今後は複数の強化学習手法の更なる調査を行う。

参考文献

- [1] V. Mnih, et al., “Playing Atari with Deep Reinforcement Learning”, NIPS Deep Learning Workshop, 2013.
- [2] M. G. Bellemare, et al., “A Distributional Perspective on Reinforcement Learning”, ICML, 2017.
- [3] V. Mnih, et al., “Asynchronous Methods for Deep Reinforcement Learning”, ICML, 2016.
- [4] J. Schulman, et al., “Trust Region Policy Optimization”, ICML, 2015.
- [5] J. Schulman, et al., “Proximal Policy Optimization Algorithms”, arXiv:1707.06347, 2017.

1.はじめに

人間の脳には役割により機能する箇所が分かれていく機能分化と呼ばれる現象がある。一方、人工ニューラルネットワークでも、Echo State Network (ESN)[1] を用いた機能分化の手法が提案されており、特定の時間または空間パターンに反応するニューロンを学習することが確認されている[2]。この手法では、Genetic Algorithm (GA) を用いて ESN の Reservoir 層のニューロンの構造と重みを探索する。探索の結果から Reservoir 層のニューロンの出力と正解ラベルから相互情報量を算出し、機能分化を確認している。しかし、GA による最適な重みの探索には膨大な時間が必要になる。そこで本研究では、Hessian-Free 法を用いたより効率的な探索方法を提案する。

2.先行研究

ESN は、入力層、Reservoir 層、出力層の 3 層で構成され、出力層のみを学習する。入力層と Reservoir 層の重みは 0 から 1 の間でランダムに決定する。Yamaguti ら [2] は、図 1 のように Reservoir 層のニューロンを Input Neurons と Output Neurons に分けた拘束条件付き ESN で空間・時間パターンの分類を行っている。出力層の学習後、GA を用いて Reservoir 層の構造と重みを探索する。その際の各ニューロンの相互情報量から、ネットワークの機能分化を確認している。しかし、全ニューロンの重みの組み合わせは膨大なため、GA による最適な構造と重みの両者を十分に探索することは困難である。

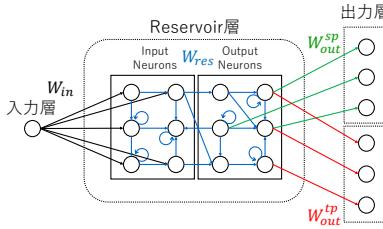


図 1. 拘束条件付き ESN のネットワーク構造

3.提案手法

本研究では、ニューロンの重み最適化と ESN の構造探索を段階的に行う手法を提案する。全ニューロンの重みを Hessian-Free 法による重みの最適化と、GA による Reservoir 層の構造探索を繰り返すことで、効率的に探索することが可能となる。

3.1. Hessian-Free 法を用いた ESN の学習

Hessian-Free 法は、再帰型ニューラルネットワークの学習における勾配消失・爆発問題を解決しつつ、長期的なデータの特徴抽出が可能な学習法である[3]。Hessian-Free 法はニューロンの重みの更新値が閾値以下の時は重みの探索を共役勾配法で行う。共役勾配法を用いた場合の重みの更新式を式(1)に示す。

$$W_{k+1} = W_k - T_k M_k \quad (1)$$

ここで、 W_k は現在の重みの集合であり、 W_{k+1} は更新後の更新後の重みの集合である。式(1)の T_k は接ベクトル、 M_k は共役勾配である。一方で、更新値が閾値以上の時は重みの探索をガウスニュートン法で行う。ガウスニュートン法を用いた場合の重みの更新式を式(2)に示す。

$$W_{k+1} = W_k - (\nabla F_k^T \nabla F_k)^{-1} \nabla F_k \quad (2)$$

ここで、式(2)の F_k は誤差の値、 ∇F_k は勾配ベクトルである。

3.2. GA による構造の探索

Reservoir 層のニューロンの構造を決定するために、GA による探索を行う。図 2 に提案手法による構造探索の流れを示す。まず、step1 にて、全ニューロンの重みを Hessian-Free 法で最適化する。step2 は、GA を用いて Reservoir

層のニューロンの接続構造を探索する。step3 では、GA によって生成される個体の精度が収束するまで、step1 と step2 を繰り返す。図 2 のオレンジ色の矢印は探索により優れていると発見された構造を示す。

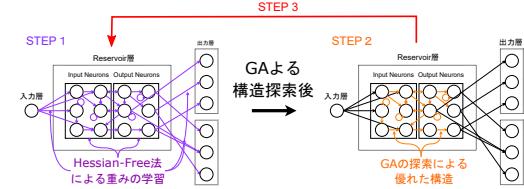


図 2. ESN の構造探索の流れ

4.実験概要

Reservoir 層の構造と重みの探索について、従来手法と提案手法の比較実験を行う。実験には Reservoir 層に 32 個のニューロンを持つ拘束条件付き ESN を用いて、cos 波の周波数と分割数を組み合わせたパターンの分類を行う。提案手法における Hessian-Free 法の学習回数は 20Epoch である。GA のパラメータは、個体数を 200、淘汰する数を 180、世代数を従来手法で 500 世代、提案手法で 5 世代とする。GA による探索後、提案手法と従来手法で Reservoir 層のニューロンと正解ラベルから相互情報量を求め機能分化を確認する。

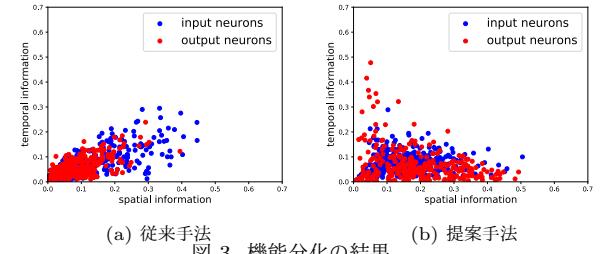
5.実験結果

表 1 に精度比較の結果を示す。表 1 より時間情報と空間情報の両方で提案手法の精度が高い。これにより、Hessian-Free 法を用いることで構造と重みの効率的な探索が可能である。

表 1. 従来手法と提案手法の比較精度 [%]

分類種類	従来手法	提案手法
空間情報	85.6	100.0
時間情報	55.3	91.2

図 3(a) に従来手法、図 3(b) に提案手法の時間と空間の相互情報量の結果を示す。図 3(a) から、空間、時間情報量の両者ともに高くなるように進化していることが分かる。一方、提案手法では空間、時間情報のどちらかが高くなるように進化している。以上より、提案手法は、ニューロンの機能分化を誘発することが可能である。



6.おわりに

本研究では効率的に重みを決定する方法を提案し、少ない世代数で機能分化を誘発することが出来た。今後の予定としては、探索後の Reservoir 層のニューロンが時間と空間パターンの情報をどのように処理しているのかについての分析、考察などが挙げられる。

参考文献

- [1] H. Jaeger, et al., “Harnessing Nonlinearity: Predicting Chaotic Systems and Saving Energy in Wireless Communication”, Science, 2004.
- [2] Y. Yamaguti, et al., “Functional differentiations in evolutionary reservoir computing networks”, Chaos 2021.
- [3] J. Martens, et al., “Learning recurrent neural networks with hessian-free optimization”, ICML, 2011.