

■ はじめに

近年、深層学習は画像識別、自然言語処理、音声認識など非常に幅広い分野に適用されている。深層学習は、人間の脳を模したニューラルネットワークを多層に結合し、表現力を高めた機械学習の手法である。深層学習は、基本的にニューラルネットワークの層の数を増やすことや層の組み合わせを複雑にすることでモデルを大きくすると精度は向上するが、ネットワークモデルの構造やパラメータの調整が精度に大きく影響を及ぼすため、調整を手作業で行うのは非常に困難である。そこで、自動で最適なネットワークアーキテクチャの構造自体を探索する最適化問題であるNeural Architecture Search (NAS)が盛んに研究されるようになった。しかし、NASは2016年に発表された比較的新しい技術であり、実問題への応用を考えたとき、未だ課題が多く存在する。そこで、実問題への応用を考慮したNASに関する2つの研究を行った。

■ 実行デバイスを考慮した多目的NAS手法

多くのNAS手法では、ニューラルネットワークのモデルサイズでは無く識別性能を重視する。しかし、携帯端末や組み込みシステムで実装する場合など搭載できるメモリ容量に制限がある環境では、軽量のモデルでないと実行することができないため、モデルサイズは深層学習において非常に重要な要素となっている。そこで、実用化を考えモデルサイズに制約を付けながら最適化するような、目的にあったモデル構造を探索可能なNAS手法を提案する。

既存のNAS手法に対して制約条件を満たしていない場合に、モデルサイズを考慮した計算式を用いて一部を最適化する仕組みや、構造が変化する頻度を高める仕組みを実装し、新しくモデルサイズの制約を課した手法を提案した。提案手法では、制約条件を設定することで精度だけではなくモデルサイズも最適化することが可能である。

$$\begin{aligned} \text{問題設定:} \\ \min_{\alpha} \mathcal{L}_{val}(w^*(\alpha), \alpha) \Rightarrow \begin{cases} \min_{\beta \in \alpha} \mathcal{L}_{val}^{MC}(w^*(\alpha), \beta), & M(w^*(\alpha)) \geq M_c \\ \min_{\alpha} \mathcal{L}_{val}(w^*(\alpha), \alpha), & M(w^*(\alpha)) < M_c \end{cases} \\ \text{where } \min_{\beta \in \alpha} \mathcal{L}_{val}^{MC} = \lambda(M(w^*(\alpha)) - M_c) \mathcal{L}_{val}(w^*(\alpha), \beta) \\ \text{s.t. } w^*(\alpha) = \underset{w}{\operatorname{argmin}} \mathcal{L}_{train}(w, \alpha) \end{aligned}$$

$M(w^*(\alpha))$:現在のモデルサイズ M_c :制約条件 $M(w^*(\alpha)) \geq M_c$

β : α の中でも畳み込みに対する構造重み γ :それ以外の構造重み

λ : \mathcal{L}_{val}^{MC} の重み更新の速度を制御するハイパーパラメータ

図1:提案手法の問題設定

提案手法に10クラスの画像識別データセットであるCIFAR10を使用し、NASの有効性を検証した。実験では、(1)制約なしの手法よりも小さなモデルサイズの構造を探索できているか、(2)モデルサイズの減少により識別精度は変化するかの2点を評価した。実験の結果、制約条件がない手法で探索したモデル構造に比べて提案手法は小さなモデル構造を探索できていることが明らかとなった。具体的には従来は2.97M、2.34Mのパラメータ数を1.42M、1.39Mに削減することができた。次に識別精度に着目すると、最も小さなモデルサイズであるモデルは識別精度が大幅に低下した。しかし、適度な大きさであるモデル構造は制約条件がない手法で探索したモデル構造以上の性能を実現しており、提案手法を用いることでより良い性能を持つモデル構造を探索でき、識別精度の向上に繋がることが明らかとなった。

■ Long Tailデータセットに対するNASの分析

深層学習は近年画像識別で広く応用されているが、クラス間でデータ数の均衡が取れているデータセットを作成することは非常に困難である。しかし、深層学習手法では均衡なデータセットを用いて最適化したネットワークを用いることが一般的である。そこで、不均衡であるLong Tail (LT)データセットに対してニューラルネットワークアーキテクチャの最適化を行い、ネットワークに対する分析を行った。

制約をつけていないNAS手法と1つ目の研究で提案した手法の2種類を用いて、各ネットワークモデルの特徴分析、およびLTデータセットに対するモデルサイズと精度のトレードオフを検証することを目的として画像識別問題を対象とした実験を行った。実験の結果、ネットワーク内の演算子の採用数などの傾向から、LTデータセットに対して得られたモデルは、データ数を一律に減らしたデータセットで得られるモデルと近いことが確認できた。最適なモデル構造が近いことからLTデータセットに対してNASを用いて最適化していることはUnder Samplingに近い動作であり、比較的少ないデータでも学習できる良いモデルを探していると考えられる。また、モデルサイズの制約を付けて探索範囲を狭めることで、LTデータといった通常よりもデータ数が減少しているデータセットに対して最適な構造を発見しやすいということも結果により明らかとなった。実験により、NAS手法で最適化したネットワークモデルの特徴がモデルサイズに大きく影響を及ぼす結果であることを確認した。

■キーワード: (1) AutoML
(2) Neural Architecture Search
(3) 多目的最適化

代表発表者 逸見 一喜(へんみ かずき)
所属 筑波大学
問合せ先 Mail: kazuki.onejack.work@gmail.com
TEL: 090-3132-2245