

逐次更新型重み付き Heterogeneous Multi-task Learning の提案

松井 涼*, 山下 隆義, 山内 悠嗣, 藤吉 弘亘 (中部大学)

Proposal of Weighted Heterogeneous Multi-task Learning with sequentially updating

Ryo Matsui, Takayoshi Yamashita, Yuji Yamauchi, Hironobu Fujiyoshi (Chubu University)

1. はじめに

深層学習において複数タスクを同時に学習する手法として, Task-wise early stopping が提案されている (1). この手法は, 1 つのタスクの識別精度を向上させるために, 他のタスクの学習を途中で停止する. そのため, 特定タスク以外の識別精度は向上しない. そこで, 本研究では複数タスクの精度向上を目的とする逐次更新型重み付き Heterogeneous Multi-task Learning を提案する. 評価実験では, 顔属性認識を対象として提案手法の有効性を示す.

2. Task-wise early stopping

複数のタスクを同時に学習する際, 1 つのタスクを基準タスク, 他のタスクをサブタスクとする. Task-wise early stopping は式 (1) を満たしたサブタスクの学習を停止する.

$$\frac{k \cdot \text{med}_{j=t-k}^t E_{tr}^a(j)}{\sum_{j=t-k}^t E_{tr}^a(j) - k \cdot \text{med}_{j=t-k}^t E_{tr}^a(j)} \cdot \frac{E_{val}^a(t) - \min_{j=1..t} E_{tr}^a(j)}{\lambda^a \cdot \min_{j=1..t} E_{tr}^a(j)} > \epsilon \quad (1)$$

ここで, med は中央値を算出する関数, E_{val}^a, E_{tr}^a はそれぞれ検証誤差と学習誤差の値, ϵ はしきい値を示す. しかし, 手法は基準タスクの識別精度が向上する一方, サブタスクは Fig.1 のように学習を途中で停止するため, 識別精度が向上しないという問題がある.

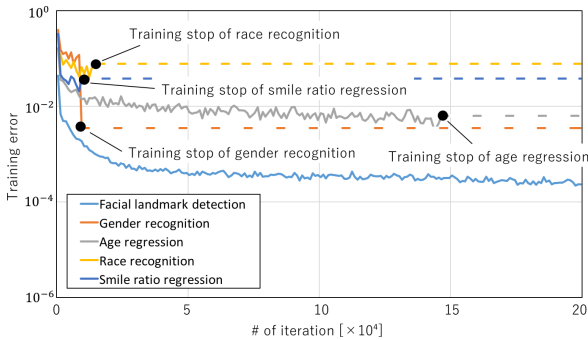


Fig. 1 Training error by Task-wise early stopping

3. 提案手法

本研究では学習誤差関数 E に重み $w_{t,e}$ を付与して複数タスクの同時学習を安定化させる逐次更新型重み付き Heterogeneous Multi-task Learning を提案する. 重み $w_{t,e}$ は, 学習過程で各タスクの学習誤差から算出し, 1 epoch 学習したときに更新する. 重み $w_{t,e}$ の算出過程を以下に示す. まず, 0 epoch から n epoch までの学習誤差から安定して学習しているかを基準に, 式 (2) のようにタスク毎に安定度 $N_{t,e}$ を算出する. ここで, e は更新回数, $\mu_{t,e}, \sigma_{t,e}$ はそれぞれタスク t における学習誤差の平均と標準偏差を示す.

$$N_{t,e} = \mu_{t,e} + 3\sigma_{t,e} \quad (2)$$

算出された各タスクの安定度 $N_{t,e}$ から, 式 (3) を満たすタスク t を基準タスク $T_{main,e}$ とし, 他のタスクをサブタスクとする.

$$T_{main,e} = \arg \min_t N_{t,e} \quad (3)$$

基準タスク $T_{main,e}$ に与える重みと安定度をそれぞれ $w_{main,e}, N_{main,e}$ とし, 式 (4) により各サブタスクに与える重み $w_{t,e}$ を算出する. ここで, $w_{t,0} = 1.0$ とする.

$$w_{t,e} = w_{main,e} \cdot \frac{N_{main,e}}{N_{t,e}} \quad (4)$$

算出された重み $w_{t,e}$ は, 式 (5) のように学習誤差関数 E に付与する. M はバッチサイズ, T はサブタスクの数, L は各タスクの教師信号, O は各タスクの出力値である.

$$E = \frac{1}{M} \sum_{m=1}^M \left(w_{main,e} \|L_{main,m} - O_{main,m}\|_2^2 + \sum_{t \neq main} w_{t,e} \|L_{t,m} - O_{t,m}\|_2^2 \right) \quad (5)$$

各サブタスクに重み $w_{t,e}$ を与えることで, 基準タスク $T_{main,e}$ への影響を軽減しながらサブタスクの学習を同時に行うことが可能となる.

4. 評価実験

評価実験では, 提案手法の有効性を調査する. データセットには, Web から収集した顔画像を使用する. 本研究では, 回帰タスクに顔器官点検出と年齢推定, 笑顔度推定, 認識タスクに性別認識と人種認識を行う. また, 本研究に用いるネットワーク構造を Fig.2 に示す.




Fig. 2 Network structure

各手法の識別精度を Fig.3 に示す. Fig.3 より, Task-wise early stopping と比較すると, 提案手法は全体精度が約 10% 向上した. タスク毎に比較すると, 顔器官点検出において識別率が約 4% 低下した. しかし, 他のタスクにおいては識別精度が大幅に向上し, 特に笑顔度推定は識別率が約 30% 向上している.




Fig. 3 Comparison of recognition accuracy

5. おわりに

本研究では, 逐次更新型重み付き Heterogeneous Multi-task Learning を提案した. 今後は, 顔属性認識のみならず歩行者の属性認識等への応用を検討する

文献

- (1) Z.Zhang, et al. "Facial landmark detection by deep multi-task learning." ECCV, 2014.