

フィーチャに基づく深層学習モデル設計方法の提案と評価

太田 龍之介[†] 青山 幹雄[†]

南山大学 大学院 理工学研究科 ソフトウェア工学専攻[†]

1. 研究背景と研究課題

従来の深層学習モデル開発では、発見的な開発方法であるために、モデルを効率的、かつ、安定して開発することは困難である[2]. 本稿では、フィーチャ(特微量)に着目し、段階的に学習可能な学習モデル設計方法を提案する. 次の2点を研究課題とする.

- (1) フィーチャに基づく段階的に学習可能な深層学習モデル設計方法の確立.
- (2) 提案方法を実データへ適用することによる有効性と妥当性の評価.

2. 関連研究

2.1 フィーチャ工学[3]

機械学習の適用対象となるデータの本質を表現したフィーチャをデータから生成する技術体系.

2.2 フィーチャ抽出器を活用した深層学習モデル生成

学習済みモデルをフィーチャ抽出器として再利用し、抽出されるフィーチャに基づき学習を効率的に行う方法が提案されている[4].

2.3 インクリメンタル学習

学習モデルの性能を維持しながら新たな学習データに対して最適化を行うためのインクリメンタルな学習方法が提案されている[1].

3. アプローチ

3.1 反復型開発プロセスによる学習の制御

本稿では、学習を制御可能な段階的学習を行う反復型開発プロセスを提案する. 観測データのフィーチャとモデルの評価結果に基づき選択された少量データを反復的に学習することで、次の2点を実現する.

- (1) フィーチャ制御: 観測データから事前に抽出したフィーチャに基づいて学習データを選択することで、フィーチャを制御する. これにより、学習の収束を制御する.
- (2) フィードバック: 反復ごとに学習の収束を評価し、その結果を次のデータ選択へフィードバックする. これにより、学習の収束を改善する学習データ選択を可能とする.

3.2 フィーチャに基づく学習データ選択

本稿では、学習において類似度が高いフィーチャ集合に基づく学習では学習が偏り、冗長となる可能性が高いと仮定する. また、モデルの学習収束状態によって有効なフィーチャが異なる. そのため、モデ

ルの学習結果に応じて学習時に獲得するフィーチャが均一になるように制御することで、冗長な学習を回避できると考える. 本稿では、反復ごとに学習結果をフィードバックすることで、学習に有効なフィーチャを獲得可能な学習データを選択する.

4. 提案方法

4.1 フィーチャに基づく深層学習モデル開発プロセス

提案プロセスを図1に示す.

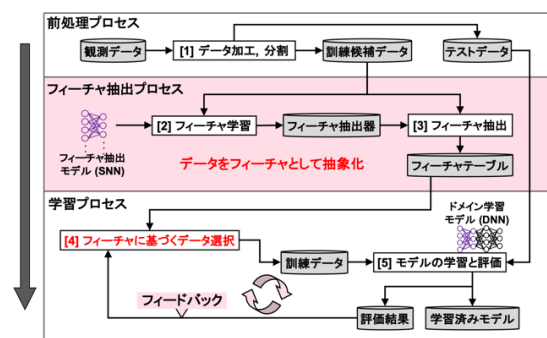


図1 提案プロセス

フィーチャ抽出プロセスによりデータを一度フィーチャとして抽象化することで、学習時に獲得するフィーチャを制御可能とする. フィーチャに基づいた学習データ選択により、学習の収束の改善を図る. フィーチャ抽出プロセスでは、Shallow Neural Networkを観測データに対して最適化し、フィーチャ抽出器として再利用する. フィーチャ抽出器の出力をGlobal Average Poolingによりベクトル化したものを、フィーチャとして学習データ選択に用いる. データから抽出したフィーチャを1対1で対応付けて格納する.

4.2 学習データの選択方法

図1の学習データ選択では、モデルの評価結果に基づき次の学習の収束に有効なフィーチャに対応するデータを学習データとして選択する. フィーチャの選択は、あるフィーチャベクトルをクエリとする近傍探索で行う. 学習収束状態に応じて反復ごとにクエリを更新し、獲得フィーチャを制御することで、学習の収束を改善する. 学習収束状態は訓練誤差収束速度 S が基準を満たすかどうかで評価する(詳細は4.3で述べる). S に応じたクエリ更新方法を以下に示す.

- (1) S が基準を満たす場合: 訓練データの特徴の獲得が十分であるため、直前に獲得したフィーチャと近傍のフィーチャの獲得は冗長である. そのため、次の学習では類似度が低いフィーチャを選択する.
- (2) S が基準を満たさない場合: 訓練データが学習不足であるため、類似度が高いフィーチャを選択する.

A Feature-Based Design Method of Learning Model for Deep Learning and its Evaluation

[†]Ryunosuke Ota, Mikio Aoyama, Graduate School of Science and Engineering, Nanzan University

4.3 学習の評価方法

図1のモデルの学習と評価では、モデルが訓練データの特徴を十分に獲得できたかの評価指標として、式(1)で定義する訓練誤差収束速度 S を評価する。

$$S = \sum_{k=1}^{\lfloor \frac{1}{n} epoch \rfloor} \frac{-a}{k} (E_{nk} - E_{nk-n+1}) \quad (1)$$

S では、学習開始から最大エポックまでの訓練誤差の推移を評価する。各 n エポック区間の訓練誤差推移の傾きの総和を収束速度として求める。学習開始の変化量ほど重要と考え、各項に a/k の重みを付与する。 S は訓練誤差の収束が速いほど高い値をとる。

5. プロトタイプの実装

プロトタイプの構成を図2に示す。

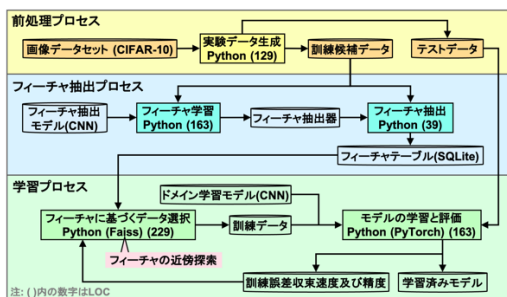


図2 プロトタイプの構成

6. 実データへの適用と評価

6.1 適用対象

提案方法を画像認識問題の3クラス分類に適用する。画像データセット CIFAR-10 のうち、automobile, bird, horse の3クラスのカラー画像を対象とする。

6.2 評価結果

提案方法と従来方法(無作為にデータを学習した場合)で学習データ数ごとに3回ずつ学習を行い、精度の平均値の推移を比較した結果を図3に示す。




図3 学習データ数ごとの精度の推移の評価

提案方法の精度の平均値が従来方法と比較して特に学習データ数600以上で上回り、平均で4.5%、最大で7.7%向上した。訓練誤差と汎化誤差の収束速度を式(1)で測定し、学習データ数ごとの推移とばらつきを評価した結果を表1と図4に示す。訓練誤差、汎化誤差ともに従来方法と比較して、学習データ数ごとで全体的に収束速度が向上した。また、表1と図4から、特に訓練誤差収束速度において学習データ数の増加と共に標準偏差が顕著に減少した。

表1 収束速度の平均値と標準偏差

比率 = (提案方法 / 従来方法)

	訓練誤差収束速度 (平均値, 標準偏差)			汎化誤差収束速度 (平均値, 標準偏差)		
	120-480	600-960	1080-1800	120-480	600-960	1080-1800
従来方法	11.7, 6.49	25.9, 6.87	37.4, 7.27	11.9, 4.16	19.7, 4.38	29.8, 4.64
提案方法	16.0, 10.5	35.4, 4.33	43.6, 2.07	11.4, 5.90	26.0, 4.82	35.7, 4.63
比率	1.37, 1.62	1.37, 0.63	1.17, 0.28	0.96, 1.42	1.32, 1.10	1.20, 1.00

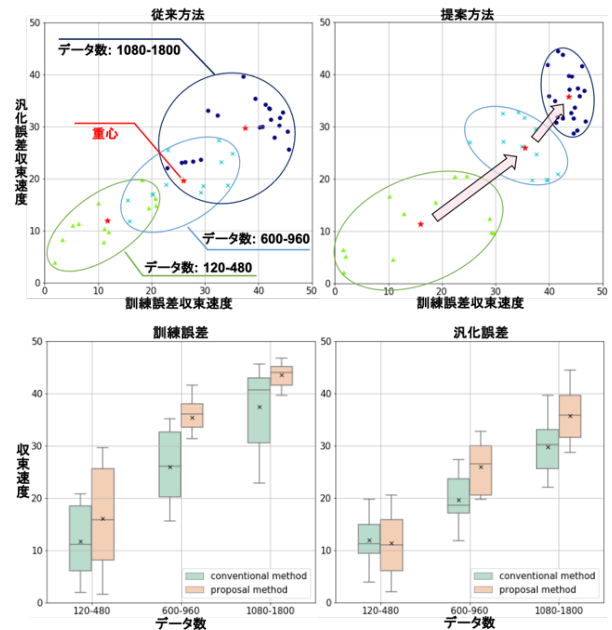


図4 収束速度の推移とばらつきの評価

7. 考察

7.1 評価結果の考察

図4の収束速度の推移とばらつきの結果は従来方法と比較して訓練誤差と汎化誤差ともに安定して減少できたことを示す。モデル評価結果のフィードバックをもとにフィーチャを制御するデータ選択により、学習の制御性が向上したといえる。

7.2 関連研究[1]との比較

関連研究[1]では、反復ごとに新たなクラスへの最適化を行うが、学習の制御は行なっていない。提案方法では、反復ごとに学習の制御を行うことで、モデルの学習の改善が可能である。

8. まとめ

従来の発見的な深層学習モデル開発プロセスを改善するために、フィーチャに基づく段階的に学習可能な反復型開発プロセスを提案した。学習を制御可能なインクリメンタル学習モデル開発方法を実現し、モデルの効率的、かつ、安定した開発が期待できる。

参考文献

[1] M. Castro, et al., End-to-End Incremental Learning, Proc. of ECCV 2018, LNCS Vol. 11205, Springer, Sep. 2018, pp. 233-248.
 [2] 丸山 宏, 城戸 隆, 機械学習工学へのいざない, 人工知能, Vol. 33, No. 2, Mar. 2018, pp. 124-131.
 [3] S. Ozdemir, et al., Feature Engineering Made Easy, Packt, 2018.
 [4] S. J. Pan, et al., Domain Adaptation via Transfer Component Analysis, IEEE Trans. Neural Networks, Vol. 22, No. 2, pp.199-210.