

混合余事象分布に基づく未学習推定畳込みニューラルネット

三苦 凌[†] 迎田 隆幸[‡] 島 圭介[§]
 横浜国立大学[†] 神奈川県立産業技術総合研究所[‡] 横浜国立大学[§]

1 はじめに

近年、機械学習を用いた高精度な画像分類モデルが数多く提案されているが、それらの多くには学習時と推論時のデータ分布が同じであるという仮定が存在する。このような画像分類モデルを実応用する際、学習時には想定されない分布外データが入力されると必然的に誤識別が発生してしまうという問題がある。この問題に対し、異常データを検知しつつクラス分類を行うオープンセット認識 (OSR: Open-Set Recognition) の概念を取り入れ、分布外データの存在を考慮できる信頼性の高い画像分類モデルの開発が行われている [1]。しかしながら、それらの手法は学習に大量のデータが必要である点や、その出力の過程がブラックボックス化されている点が問題となっているそのため、少量のデータで学習ができ、その判断の根拠を説明できる説明性や納得性の高い機械学習モデルが必要である。

OSR 手法の一つである NACGMN (Normal and Complementary Gaussian Mixture Network) [2] は、混合正規分布とその余事象にあたる確率分布をニューラルネットに展開した確率ニューラルネットであり、少ないデータで学習が可能で、出力結果を確率的に解釈することができる説明性の高いモデルである。しかしながら、NACGMN は内包する確率モデルが有する統計的制約により、画像などの高次元なデータに対する応用が困難となる課題を有する。

そこで本稿では、高次元な画像データにも対応した NACGMN に基づく新しい OSR 手法を提案する。提案法は CNN による特徴抽出層と NACGMN による OSR 層から構成され、距離学習や未知クラスに対する正則化項を導入することで深層確率ニューラルネットの学習を実現した。

2 提案モデルの構成と学習方法

図 1 に提案モデルのネットワーク構造を示す。提案法のネットワークは CNN 部と NACGMN 部の二部で構成され、それぞれ CNN 部が特徴抽出を、NACGMN 部が OSR を担っている。CNN 部で入力データの次元を圧縮した特徴表現を獲得し、その特徴表現を基に NACGMN 部で分類を行うことで高次元データでの OSR を実現する。CNN

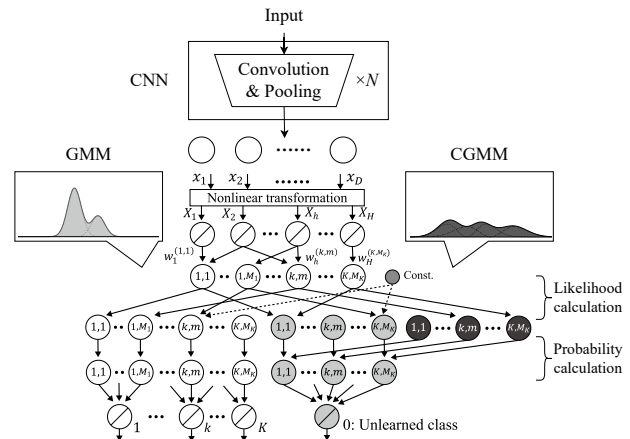


図 1 提案モデルの構造.

部については特定のモデルである必要はないため、求める精度や計算リソースに応じたモデルを使用可能である。NACGMN が出力する各クラスの事後確率 $p(k|x)$ は、既知クラス ($k \neq 0$) と未知クラス ($k = 0$) でそれぞれ次式によって表される。

$$p(k|x) = \begin{cases} \frac{1-p_0}{F(\mathbf{x})} \sum_{m=1}^{M_k} \alpha_{k,m} g(\mathbf{x}; k, m) & (k \neq 0) \\ \frac{p_0}{F(\mathbf{x})} \sum_{k'=1}^K \sum_{m'=1}^{M_{k'}} \beta_{k',m'} h(\mathbf{x}; k', m') & (k = 0) \end{cases} \quad (1)$$

ただし、 p_0 は未知データの事前確率、 K は既知クラス数、 M_k はクラス k が表す GMM のコンポーネント数、 $\alpha_{k,m}$ 、 $\beta_{k,m}$ は混合度であり、コンポーネントの平均 $\mu_{k,m}$ と共分散行列 $\Sigma_{k,m}$ 、入力の次元数 D を用いて

$$F(\mathbf{x}) = (1-p(k=0)) \sum_{k'=1}^K \sum_{m'=1}^{M_{k'}} \alpha_{k',m'} g(\mathbf{x}; k', m') + p(k=0) \sum_{k'=1}^K \sum_{m'=1}^{M_{k'}} \beta_{k',m'} h(\mathbf{x}; k', m') \quad (2)$$

$$g(\mathbf{x}; k, m) = (2\pi)^{-\frac{D}{2}} |\Sigma^{(k,m)}|^{-\frac{1}{2}} \exp[q(\mathbf{x})] \quad (3)$$

$$h(\mathbf{x}; k, m) = -\frac{2}{D} (2\pi)^{-\frac{D}{2}} \varepsilon_{k,m}^{-1} |\varepsilon_{k,m} \Sigma^{(k,m)}|^{-\frac{1}{2}} \times q(\mathbf{x}) \exp[\varepsilon_{k,m}^{-1} q(\mathbf{x})] \quad (4)$$

$$q(\mathbf{x}) = -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}^{(k,m)})^T (\Sigma^{(k,m)})^{-1} (\mathbf{x} - \boldsymbol{\mu}^{(k,m)}) \quad (5)$$

である。 $g(\mathbf{x}; k, m)$ と $h(\mathbf{x}; k, m)$ はそれぞれ既知クラスと未知クラスに対応する確率分布であり、 $g(\mathbf{x}; k, m)$ の余事

A Novel Probabilistic Convolutional Neural Network for Open-Set Recognition Based on Normal and Complementary Gaussian Mixture Models

[†] Ryo Mitoma, Yokohama National University

[‡] Takayuki Mukaeda, Kanagawa Institute of Industrial Science and Technology

[§] Keisuke Shima, Yokohama National University

象を表す $h(\mathbf{x}; k, m)$ は多変量正規分布と多変量二次関数の積によって表される。これらの確率分布のパラメータを対数線形化 [3] し、統計的制約を緩和した重みへと変換することで、 $g(\mathbf{x}; k, m)$ や $h(\mathbf{x}; k, m)$ が持つ統計的パラメータをニューラルネットの重み係数として最適化することができる。

提案法の学習は、CNN 単体で特徴表現の学習、NACGMN の初期値の獲得、CNN と NACGMN を連結させたクラス分類の学習の3段階で行われる。1段階目では CNN 単体に距離学習を適用する。距離学習を用いることにより、特徴空間におけるデータの分布を制御し、後段の NACGMN が内包する混合余事象分布として捉えやすくなることが期待できる。提案法では Triplet Loss [4] を用いて距離学習を行った。2段階目の NACGMN の初期値の獲得では、1段階目で学習した CNN の特徴表現を用いる。この特徴表現とデータの正解ラベルを用いて従来手法 [2] と同様の手順で k -means 法に基づく NACGMN の初期化を行い、クラス K 、コンポーネント M ごとに、平均 μ 、共分散行列 Σ 、混合度 α を得る。最後に3段階目では、CNN と NACGMN を連結させクラス分類の学習を行う。クラス分類の学習では、次式で表されるような、交差エントロピー誤差 \mathcal{L}_{ce} に対して正則化項が追加された損失関数 \mathcal{L}_{reg} を用いる。

$$\mathcal{L}_{reg} = \mathcal{L}_{ce} + \beta \times \sum_k \sum_m w_c^{(k,m)} \quad (6)$$

3 分類精度の評価実験

3.1 実験設定

画像データセットの MNIST と CIFAR-10 を利用して評価実験を実施した。いずれも分類対象クラス数が 10 クラスのデータであり、従来手法 [5] と同様に 4 クラスを学習に用いない未知クラスとして抽出することで OSR の精度を評価した。また、学習に用いるサンプル数が分類精度へ与える影響を検証するため、1クラス当たり 100 個、または 500 個の学習データを無作為に抽出する 2 つの条件を用意した。提案法においては、正則化を用いた場合と用いなかった場合のそれぞれについて検証し、前者の場合は $\beta = 1$ とした。学習はバッチサイズ 128 で 300 エポック行い、学習率 10^{-2} で Adam によって最適化を行った。提案法の評価には、既知クラスの分類に対する正解率と未知クラスに対する予測の AUROC のそれぞれについて、データセットの分割を変えて 5 回実験した平均値を用いた。比較手法には提案法と同様に特徴抽出部と OSR 部で構成されるシンプルなもの [5] を選択した。同論文では CNN で特徴抽出をした後、ソフトマックス関数の入力値であるロジットに閾値を設けて OSR を行っている。本実験における提案法の CNN 部には同論文で定義されたものと同じのものをを用い、特徴ベクトルの次元は 16 とした。

3.2 実験結果と考察

正解率と AUROC の比較を表 1 に示す。表より、提案法は MNIST でデータ数 500 の場合は比較手法と同等の精度

表 1 既知クラスの正解率と未知クラスの AUROC。Proposed_noreg は、提案法で正則化を行わない場合を表す。

Metric	Accuracy				AUROC			
	MNIST		CIFAR-10		MNIST		CIFAR-10	
Dataset	500	100	500	100	500	100	500	100
# of data per class	500	100	500	100	500	100	500	100
MLS [5]	98.5	95.9	83.4	70.2	97.9	92.2	80.5	71.7
Proposed	99.2	82.8	72.2	22.8	96.4	90.4	63.7	45.0
Proposed_noreg	99.2	82.8	69.8	21.6	96.3	90.4	64.5	46.3

を示すことが確認された。しかしながら、1クラス当たりのデータ数が少なくなった場合や CIFAR-10 の場合に比較手法と比較して精度が低下してしまうことが確認された。NACGMN 単体で低次元のデータを学習させた場合は少量のデータでも学習できていることから [2]、Triplet Loss を用いた距離学習では少量データや複雑なデータに十分対応できない可能性がある。また、本実験では正則化を用いた影響を確認できなかった。低次元データを用いた予備実験においては正則化の影響が確認できているため、正則化が距離学習の出力に対して機能するように対応する必要がある。

4 まとめ

本稿では、距離学習と確率ニューラルネットを組み合わせた OSR 手法の提案を行った。評価実験により、学習データ数が各クラス 500 個の時点では比較手法と同等の精度を示すことが確認できたが、データ数が少なくなるに従って精度が大幅に低下してしまう傾向が確認された。少量データにも対応した距離学習などの手法を組み合わせ、解釈性と精度を両立することが今後の課題である。

参考文献

- [1] Walter J. Scheirer, Anderson de Rezende Rocha, Archana Sapkota, and Terrance E. Boult. Toward Open Set Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 35, No. 7, pp. 1757–1772, 2013.
- [2] 迎田隆幸, 島圭介. 混合余事象分布に基づく未学習クラス推定確率ニューラルネット. 計測自動制御学会論文集, Vol. 56, No. 12, pp. 532–540, 2020.
- [3] T. Tsuji, O. Fukuda, H. Ichinobe, and M. Kaneko. A log-linearized Gaussian mixture network and its application to EEG pattern classification. *IEEE Transactions on Systems, Man and Cybernetics, Part C (Applications and Reviews)*, Vol. 29, No. 1, pp. 60–72, 1999.
- [4] Elad Hoffer and Nir Ailon. Deep Metric Learning Using Triplet Network. In *Similarity-Based Pattern Recognition*, Lecture Notes in Computer Science, pp. 84–92, 2015.
- [5] Sagar Vaze, Kai Han, Andrea Vedaldi, and Andrew Zisserman. Open-Set Recognition: A Good Closed-Set Classifier is All You Need. In *International Conference on Learning Representations*, 2022.