

# 深層学習モデル EfficientNet V2に基づく皮膚病分類システムの評価

趙 菁悦<sup>†</sup>      吉野 孝<sup>‡</sup>  
<sup>†</sup>和歌山大学

## 1 はじめに

2014 年時点で中国には約 25,000 箇所の病院があり、約 17,000 人の皮膚科医が勤務している。皮膚科医は 1 日当たり約 100 人の患者を診断している [1]。日本厚生労働省の調査によると、2019 年における皮膚科医の週平均労働時間は 53 時間 51 分であった。週 5 日の勤務日であれば、一日当たり 10 時間以上働く必要があり<sup>1</sup>、皮膚科医の負担が大きいことが分かる。医師が長時間にわたり多くの患者を診断することで、誤診をする可能性がある。

皮膚病は一般的によく見られる病気であり、疾患部位は皮膚である。また、皮膚病は視診だけで判断できる場合が多く、特徴は直観的で比較的分かりやすい。そのため、皮膚科医の仕事の負担を軽減するために、医師の診断を支援する AI が役立つと考えられる。

皮膚鏡と非皮膚鏡画像を用いた人工知能に基づく多くの関連研究は、皮膚病における患部の抽出と分類に人工知能を応用しようとしている。そこで本研究では、EfficientNet V2 深層学習モデルを用いて転移学習を行う。EfficientNet V2 モデルを修正し、アテンション・モジュールを追加することで、高精度の皮膚病分類システムを構築する。これにより、患者自身が診察前に大まかな病状を知り、医者も AI 出力の結果に基づいて診断することができるため、医者誤診や医者の仕事の負担を軽減できると考えられる。

画像分類の分野で多くの優れた深層学習モデルがある。本研究で改善された EfficientNet V2 モデルのほか、Alexnet[2], Vggnet[3], Googlenet[4], Resnet[5], Mobilenet[6], Shufflenet[7], Densenet[8], Regnet[9] などのモデルがある。本研究は改善したモデルと現存するモデルで比較する。

## 2 関連研究

劉らは、深層学習の畳み込みニューラルネットワークモデルに基づいて、新たに作成した皮膚疾患画像データセットを種類ごとに分類し、高精度なモデルを構築した [10]。作成したデータセットは皮膚科医が標定した皮膚鏡画像 13,603 枚で構成されており、皮膚科でよく見られる 14 種類の疾患が含まれている。EfficientNet-b4 をバックボーンとして使用し、転移学習を用いて CNN モデル構築を行った。その後、

Skin disease classification system based on deep learning model EfficientNet V2

Jingyue Zhao<sup>†</sup> Takashi Yoshino<sup>‡</sup>

<sup>†</sup>Wakayama University

<sup>1</sup>厚生労働省 <https://www.mhlw.go.jp/content/10800000/000677264.pdf>

構築された CNN モデルを、過去の文献で報告されている CNN モデルおよび皮膚科医 280 人の分類精度と比較した。結果として、構築された CNN モデルでは優れた分類レベルを実現し、作成したモデルの高い精度を示した。本研究では、改善した EfficientNet V2 を使用して、より高精度なモデルを構築することを目的とする。

## 3 提案手法

### 3.1 システム概要

本システムでは、深層学習モデル EfficientNet V2 をメインモデルとして用い、ISIC 2019 皮膚病データセットの分類を行った [11]<sup>2</sup>。モデルを修正することで、データセットに対してより適切な分類モデルを得ることができる。本システムの処理の流れを述べる。まず、ImageNet データセットを用いて事前学習を行い、学習済みのモデルを取得する。その後、転移学習の手法を用いて、ISIC 2019 皮膚病データセットで再学習を行う。EfficientNet V2 モデルに新しいアテンション・モジュールを追加することで、モデルの精度向上を目指す。最後に本研究のモデルと現存する深層学習モデルを用いて ISIC 2019 データセットを分類し、異なるモデルの分類結果を比較する。

### 3.2 転移学習

転移学習とは、新しいタスクのパフォーマンスを向上させるために、学習済みのモデルを新しいタスクに適用することである。多くのタスクでは、高い精度を達成するために複雑なモデルを使用する必要がある。しかし、複雑なモデルは多くのデータと計算量を必要とし、学習に多くの時間がかかる。このとき、転移学習を利用することで、学習済みのモデルを新しいタスクに適用し、新しいタスクのパフォーマンスを向上させることができる。転移学習の際に使用する ImageNet データセットは、現在世界最大の画像認識データベースであり、転移学習でモデルの精度を向上させるために広く使用されている。

### 3.3 使用するモデル

使用する深層学習のモデル、EfficientNet V2 は、Google チームによる EfficientNet [12] のアップグレード版であり、EfficientNet の上に Fused-MBConv を探索空間に導入し、漸近学習のための適応的な正則強度調整機構を備えている<sup>3</sup>。また、複数のベンチマークデータセットで高い性能を達成し、学習が高

<sup>2</sup>ISIC 2019 Challenge <https://challenge.isic-archive.com/data/#2019>

<sup>3</sup>EfficientNetV2: Smaller Models and Faster Training <https://arxiv.org/pdf/2104.00298.pdf>

表 1: 本研究モデルの 8 種類皮膚病の評価

評価指標	AK	BCC	BKL	DF	MEL	NV	SCC	VASC
Acc	97.7%	96.6%	89.1%	99.8%	85.4%	77.1%	97.9%	99.8%
Precision	78.8%	93.9%	45.1%	95.0%	72.4%	70.4%	55.7%	83.3%
Recall	47.1%	79.2%	26.3%	79.2%	29.0%	95.0%	69.8%	100.0%
F1-score	59.0%	85.9%	33.3%	86.4%	41.4%	80.8%	62.0%	90.9%

表 2: 異なる深層学習モデルの比較

評価指標	Reg	Dens	Shuffle	Alex	Vgg	Google	Mobile	Res	Efficient	本研究
Acc	57.4%	61.4%	61.5%	55.9%	51.6%	54.8%	55.1%	55.6%	31.2%	71.7%
Pre	52.0%	68.3%	58.1%	69.9%	59.0%	41.3%	48.7%	38.5%	49.9%	59.1%
Recall	57.4%	71.9%	61.5%	72.0%	64.9%	36.8%	55.1%	38.8%	44.1%	67.6%
F1-score	52.3%	68.6%	58.6%	70.9%	59.4%	37.0%	50.0%	38.7%	45.0%	61.9%

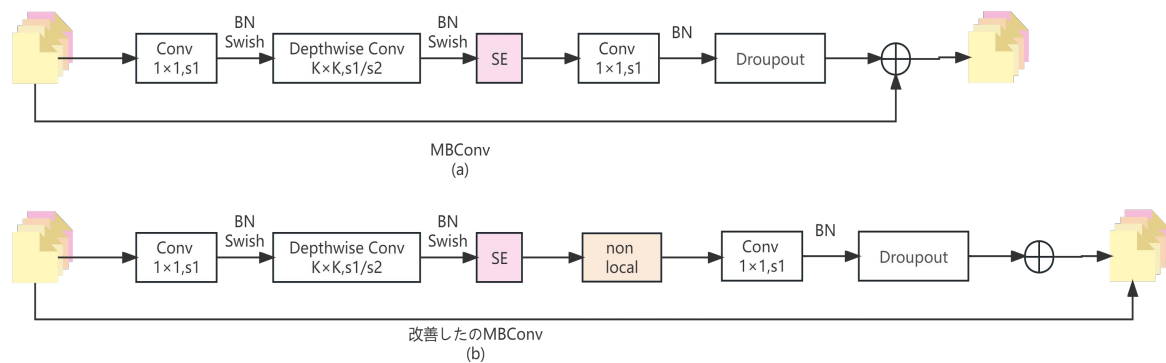


図 1: MBConv 構造と本研究で改善した MBConv 構造 (出典 : Efficientnet V2: Smaller models and faster training[12] を参考に作成)

速化されている。EfficientNet V2 深層学習モデルは MBConv と Fused-MBconv のブロック構造が含まれている。その中で、MBConv モジュールは SE アテンションモジュールを使用しているが、モデル精度をさらに向上させるために、本研究では、MBConv モジュールに Non-local アテンションモジュールを追加した。図 1(a) は MBConv の本来の構造、図 1(b) は本研究で MBConv を改善した構造である。

SENet モジュールで提案されている SE ブロックは、異なるチャンネルの重みを設定し、チャンネル依存性を調整するために、グローバルコンテキストを使用する [13]。Non-local モジュールは、このクエリポイントに関連するグローバルな特徴を取得するために、リモート依存関係をモデル化する自己注意メカニズムを使用する。本研究では、モデルの精度を向上させるため、両方のアテンションモジュールを使用する。

### 3.4 データ前処理

本研究で使用するデータ前処理について説明する。データセットをランダム水平反転、ランダム垂直反転、20度 [-10,10] の範囲でランダム回転、ランダムカラージッタを行う。次にデータセットをするために、入力データの平均値  $\mu$ 、標準偏差  $\sigma$  を得る。入力データは線形変換により平均値が 0、標準偏差 1

の標準正規分布に変換される。これにより、収束が加速され、演算速度が向上する。

## 4 実験と結果

### 4.1 使用するデータセット

本研究で使用する ISIC 2019 皮膚病データセットは、合計 25,331 枚の皮膚科学的画像で構成され、そのうち 80% はモデルの訓練に使用し、20% はテストセットとして使用した。また、学習データには 8 つのカテゴリの皮膚病が含まれており、テストデータには 8 つのカテゴリの皮膚病及び皮膚病ではない画像が含まれている。データセットには、メラノーマ、母斑、脂腺角化症、基底細胞癌、光線性角化症/ポーエン病、皮膚線維腫、血管病変、基底細胞癌などの皮膚疾患が含まれている。

本研究では ImageNet データセットを用いた転移学習を行い、モデル精度の向上を目指す [14]。

### 4.2 モデル評価

本研究で学習したモデルは Accuracy, Precision, Recall, F1-score を用いて評価を行った。モデルによる 8 種類の皮膚病分類の評価を表 1 に表す。モデル分類の効果が比較的が良い。本モデルの優位性を検証するために、本研究は同じデータセットで現存

する他のモデルの分類効果を比較した。異なるモデルの評価結果を表 2 に示す。本研究のモデルは改善前のモデルよりもはるかに性能が高く、現存する他のモデルと比較しても一定の優位性がある。

## 5 おわりに

本研究では、EfficientNet V2 モデルを用いて皮膚病分類モデルを構築し、8 種類の皮膚病画像を分類を行った。モデルの性能を Accuracy, Precision, Recall, F1-score で評価し、現存する他のモデルと比較した。

## 参考文献

- [1] Yi Zhou, Yujun Sheng, Jinping Gao and Xuejun Zhang : Dermatology in China, The Journal of Investigative Dermatology Symposium, Vol. 17, pp. 12–14 (2015).
- [2] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton : Imagenet classification with deep convolutional neural networks, Advances in neural information processing systems, Vol. 25 (2012).
- [3] Simonyan, Karen, and Andrew Zisserman : Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556 (2014).
- [4] Szegedy, Christian, et al : Going deeper with convolutions, Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1–9 (2015).
- [5] He, Kaiming, et al : Deep residual learning for image recognition, Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 770-778 (2016).
- [6] Howard, Andrew G., et al : Mobilenets: Efficient convolutional neural networks for mobile vision applications, arXiv preprint arXiv:1704.04861 (2017).
- [7] Zhang, Xiangyu, et al : Shufflenet: An extremely efficient convolutional neural network for mobile devices, Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 6848-6856 (2018).
- [8] Huang, Gao, et al : Densely connected convolutional networks, Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1031-1044 (2017).
- [9] Radosavovic, Ilija, et al : Designing network design spaces, Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, pp. 10428-10436 (2020).
- [10] Zhu, Chen-yu et al : A Deep Learning Based Framework for Diagnosing Multiple Skin Diseases in a Clinical Environment, Frontiers in Medicine 8 (2021).
- [11] Marc Combalia, Noel C. F. Codella, Veronica Rotemberg, Brian Helba, Veronica Vilaplana, Ofer Reiter, Allan C. Halpern, Susana Puig, Josep Malvehy : BCN20000: Dermoscopic Lesions in the Wild, arXiv:1908.02288 (2019).
- [12] TAN Mingxing, LE Quoc : Efficientnetv2: Smaller models and faster training. In: International conference on machine learning, PMLR, pp. 10096-10106 (2021).
- [13] Jun Fu, Jing Liu, Haijie Tian, Yong Li, Yongjun Bao, Zhiwei Fang, Hanqing Lu : Dual attention network for scene segmentation. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, pp. 3146-3154 (2019).
- [14] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li and L. Fei-Fei, ImageNet: A Large-Scale Hierarchical Image Database. IEEE Computer Vision and Pattern Recognition (CVPR), pp. 248-255 (2009).