



情報処理学会第 81回全国大会 (IPSJ2019)  
at 福岡大学 七隈キャンパス 2019/3/15

# 頑健な皮膚腫瘍診断支援のための body hair augmentation

北田 俊輔, 彌富 仁

法政大学 理工学研究科 応用情報工学専攻



# ■ 研究背景

悪性黒色腫 (メラノーマ): 悪性度の高い皮膚がんの1つ

アメリカ がん統計 [U.S. Cancer Statistics Working Group '14]

- アメリカ国内では毎年 **9,000** 人近くが死亡
- 2015年には世界中で **35** 万件以上の発症が推定  
6 万人以上が死亡している

## 診断方法

- 医師の目視検査がメイン
- 皮膚科医専用の偏光レンズつき拡大鏡である **ダーモスコピー** による診断

→ 診断精度は**75~84%**程度に留まる


[Vestergaard+ '08]



# ■ 研究背景

## Convolutional Neural Network (CNN) を用いた 皮膚画像解析を利用した自動診断支援手法

皮膚画像をCNNに入力することで高精度な診断を可能に



# ■ 研究背景

## Convolutional Neural Network (CNN) を用いた 皮膚画像解析を利用した自動診断支援手法

皮膚画像をCNNに入力することで**高精度**な診断を可能に

### 問題点

- 学習時に**大量**の訓練データが必要
  - **医療データ**の大規模データセット構築は**コストがかかる**

ImageNetで事前学習した深層学習モデルのfine-tuning  
診断精度の向上が報告 [Menegola+ '16]

- ダーモスコピー画像は多様な外観を持つ  
→ 依然として**過学習**を引き起こしやすい

[Esteva+ '17]

Confidence: 0.98

Pooling

# ■ 研究背景

## Convolutional Neural Network (CNN) を用いた 皮膚画像解析を利用した自動診断支援手法

皮膚画像をCNNに入力することで**高精度**な診断を可能に

### 問題点

- 画像中の体毛や陰影、コントラスト不良等が存在
  - 様々な悪条件画像に対して診断精度の**大幅な低下**
  - 頑健な識別器の構築は**容易ではない**

[Esteva+ '17]

Melanoma: 0.98



# ■ 研究背景

## Convolutional Neural Network (CNN) を用いた 皮膚画像解析を利用した自動診断支援手法

皮膚画像をCNNに入力することで**高精度**な診断を可能に

### 問題点

- 画像中の体毛や陰影、コントラスト不良等が存在
  - 様々な悪条件画像に対して診断精度の**大幅な低下**
  - 頑健な識別器の構築は**容易ではない**

ダーモスコピー上の体毛等は前処理で除去 [Lee+ '97]

→ 体毛が存在していた皮膚部分や腫瘍領域は  
補完されてしまい**擬似的なもの**に

[Esteva+ '17]


Melanoma: 0.98

Pooling

# ■ 本研究における貢献

## 撮影状況に頑健な深層学習に基づく識別システムの構築

- ベースラインとして  
最先端の画像認識モデル・半教師あり学習を使用
  - **SE-ResNet** [Hu+ ,18] ベースの識別モデル
  - **Mean teachers** [Tarvainen+ '17] による半教師あり学習
- **Body hair augmentationの提案**
  - **あえて疑似体毛**を付与することで頑健となるよう学習を行う
  - Data augmentationと同様の作用がありデータの多様性向上




深層学習技術に基づく識別システムに対して

提案手法を適用することで診断精度**2~4%**向上 (**90.6%**)

# ■ 関連研究 | 最先端の画像認識モデルと半教師あり学習

**Squeeze-and-excitation** block を持つ SE-ResNet [Hu+ ,18]

- ILSVRC優勝モデルであり、一般物体認識高い識別精度を誇る  
→ 皮膚腫瘍画像に対しても高い診断精度が出ることを期待
- Squeezeとexcitationによりチャンネルごとにattentionを適用  
結合加重の総数を減らすことで過学習を抑制  
→ 小規模な医療画像データに対して頑健性の向上

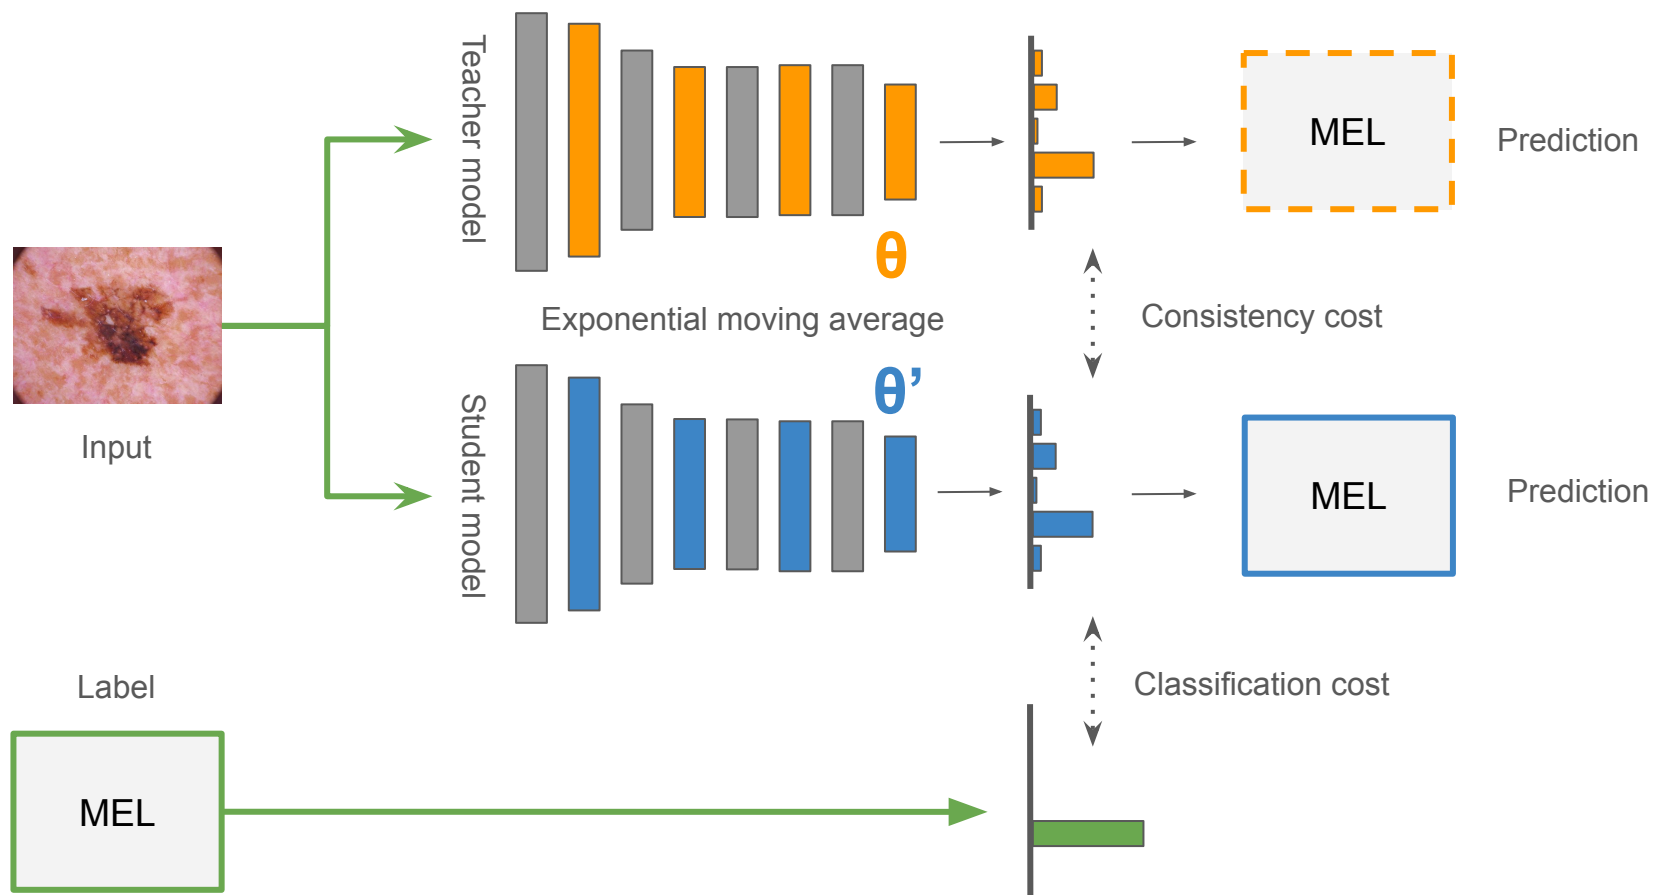




# ■ 関連研究 | 最先端の画像認識モデルと半教師あり学習

半教師あり学習の枠組み **Mean teachers** [Tarvainen+ '17]

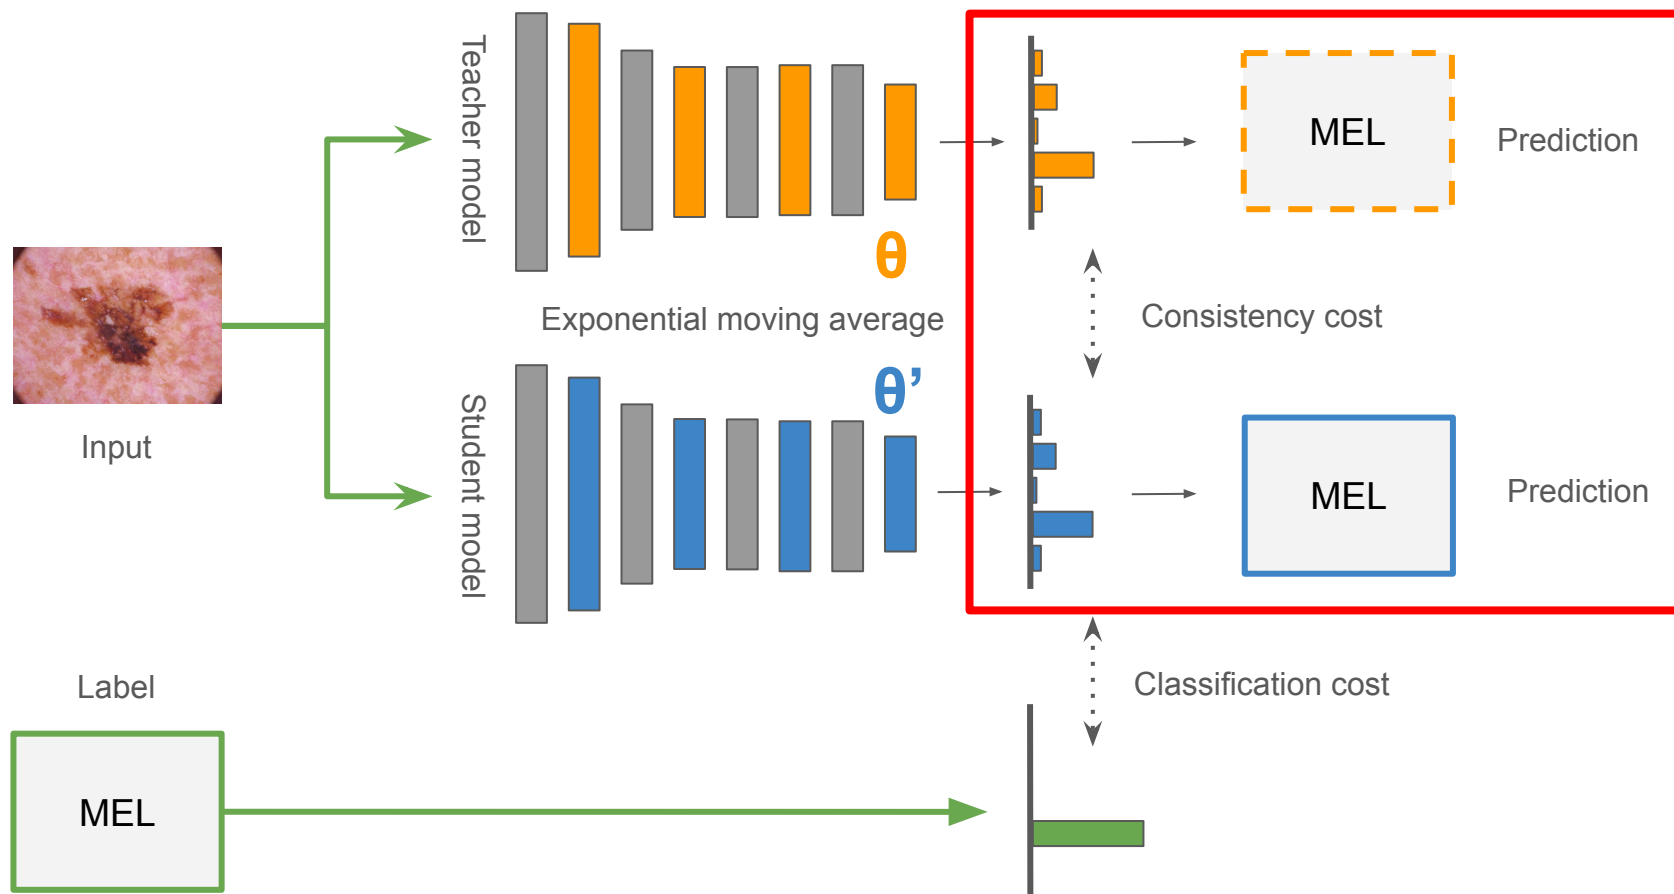
- 複数の識別器を組み合わせるnetwork ensemble
- 診断ラベルが付与されていない画像も使用できる



# ■ 関連研究 | 最先端の画像認識モデルと半教師あり学習

半教師あり学習の枠組み **Mean teachers** [Tarvainen+ '17]


- 複数の識別器を組み合わせるnetwork ensemble
- 診断ラベルが **付与されていない** 画像も使用できる



# ■ 提案手法

## Body hair augmentation

- あえて**疑似体毛**を付与することで頑健となるよう学習  
→ 患部付近の体毛がシステムの診断の妨げとなる点に着目
- 皮膚腫瘍診断にフォーカスしたdata augmentation
  - 規模の小さい医療データセットに対して多様性を向上
  - 自然な形で疑似体毛を付与することが可能







適用前 (左) と 適用後 (右)

# ■ 提案手法

## Body hair augmentation アルゴリズム

1. Buffonの針 [Buffon 1777] に基づいて擬似的に体毛を模倣する線を描画  
確率的に描画を行い、描画される線はベジェ曲線に従ってランダムに曲線とする
2. 描画した疑似体毛にガウシアンフィルタを適用しぼかす
3. 差分合成を用いてダーモスコーピー画像に合成

曲線の曲率や適用確率は  
識別精度を基に決定




# ■ 実験 | Body hair augmentationの効果確認

## 使用データセット

健全を含む7種類の皮膚腫瘍画像 HAM10000 [Tschandl+ '18] をベースとしたISIC2018 Challenge<sup>1</sup>のtask 3データセット

- NV (健全) が多く、悪性の症例画像が少ない
- 半教師あり学習で診断ラベルのない画像も学習に利用

			labeled				unlabeled		Total
MEL	NV	BCC	AKIEC	BKL	DF	VASC	validation	test	
1,113	6,705	514	327	1,099	115	142	193	1,512	11,720



# ■ 実験 | Body hair augmentationの効果確認

## 学習と予測

- Group 5-fold cross validation
  - 同一患者の皮膚画像が学習セットと評価セットに含まれないように分割する
  - Cross validationで得られた5つの予測結果のaveraging

## 評価方法

- ISIC2018公式評価セットに対する  
クラスごとの平均識別率 (balanced accuracy)  
→ 症例の少ないクラスに対して正確に予測する必要がある

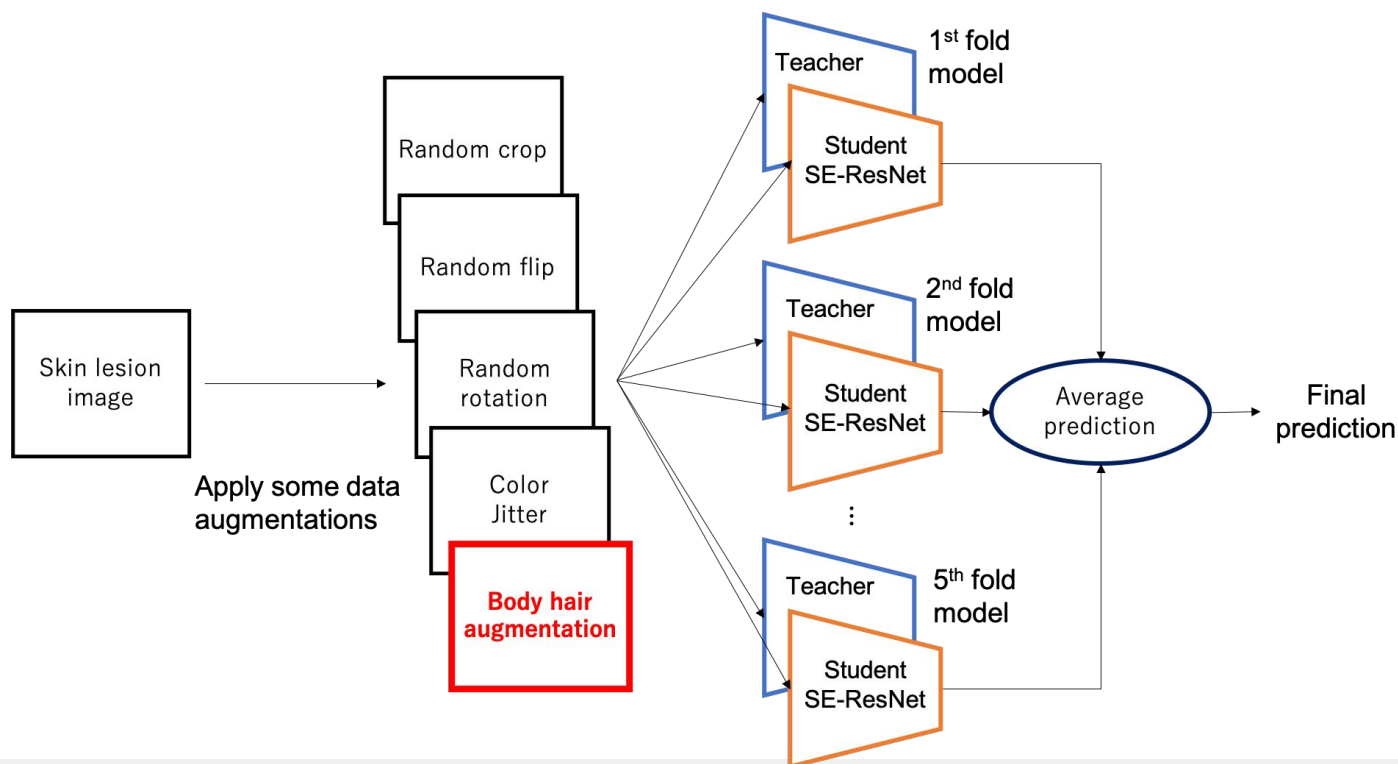
# ■ 実験設定 | 実験で用いたモデルアーキテクチャ

使用モデル: ImageNet事前学習済み ResNet101, SE-ResNet101

Data augmentation: random crop, flip, rotation, color jitter を使用

半教師あり学習 mean teachers を導入

このアーキテクチャに対して **body hair augmentation** を適用



# ■ 実験結果 | ISIC2018公式セットを用いた識別精度の比較

	Model	Balanced Accuracy [%]
SENet	[Zhuang+, '18] SoTA	89.8
ResNet101	Baseline	85.7
	+ Mean teachers	86.9
	+ <b>Body hair augmentation</b>	87.5
	+ Mean teachers + <b>Body hair augmentation</b>	88.5
SE-ResNet101	Baseline	86.4
	+ Mean teachers	87.3
	+ <b>Body hair augmentation</b>	88.4
	+ Mean teachers + <b>Body hair augmentation</b>	<b>90.6</b>



# ■ 実験結果 | ISIC2018公式セットを用いた識別精度の比較

	Model	Balanced Accuracy [%]
SENet	[Zhuang+, '18] SoTA	89.8
ResNet101	Baseline	85.7
	+ Mean teachers	86.9
	+ <b>Body hair augmentation</b>	87.5
	+ Mean teachers + <b>Body hair augmentation</b>	88.5
SE-ResNet101	Baseline	86.4
	+ Mean teachers	87.3
	+ <b>Body hair augmentation</b>	88.4
	+ Mean teachers + <b>Body hair augmentation</b>	<b>90.6</b>

# ■ 実験結果 | ISIC2018公式セットを用いた識別精度の比較

	Model	Balanced Accuracy [%]
SENet	[Zhuang+, '18] SoTA	89.8
ResNet101	Baseline	85.7
	+ Mean teachers	86.9
	+ <b>Body hair augmentation</b>	87.5
	+ Mean teachers + <b>Body hair augmentation</b>	88.5
SE-ResNet101	Baseline	86.4
	+ Mean teachers	87.3
	+ <b>Body hair augmentation</b>	88.4
	+ Mean teachers + <b>Body hair augmentation</b>	<b>90.6</b>

# ■ 実験結果 | ISIC2018公式セットを用いた識別精度の比較

	Model	Balanced Accuracy [%]
SENet	[Zhuang+, '18] SoTA	89.8
ResNet101	Baseline	85.7
	+ Mean teachers	86.9
	+ <b>Body hair augmentation</b>	87.5
	+ Mean teachers + <b>Body hair augmentation</b>	88.5
SE-ResNet101	Baseline	86.4
	+ Mean teachers	87.3
	+ <b>Body hair augmentation</b>	88.4
	+ Mean teachers + <b>Body hair augmentation</b>	<b>90.6</b>

+ 2.8 %

+ 4.2 %

# ■ 考察 | Body hair augmentationの効果

体毛が目立つサンプルに対する予測精度が向上



なし: AKIEC ×  
あり: NV ○



なし: BCC ×  
あり: NV ○




なし: NV ×  
あり: AKIEC ○



なし: NV ×  
あり: DF ○



なし: NV ×  
あり: VASC ○




なし: MEL ×  
あり: AKIEC ○

# ■ 結論

## 撮影状況に頑健な深層学習に基づく識別システムの構築

- ベースラインとして  
最先端の画像認識モデル・半教師あり学習を使用
  - **SE-ResNet** ベースの識別モデル
  - **Mean teachers** による半教師あり学習
- **Body hair augmentationの提案**
  - **あえて疑似体毛**を付与することで頑健となるよう学習が行われた
  - Data augmentationと同様の作用がありデータの多様性向上



深層学習技術に基づく識別システムに対して  
提案手法を適用することで診断精度**2~4%**向上 (**90.6%**)