

深層学習による裂紋舌画像の自動認識

Automatic Recognition of Fissured Tongue Images by Deep Learning

安 振 宇*

AN Zhenyu

呉 韜**

WU Ren

中 田 充***

NAKATA Mitsuru

葛 崎 偉****

GE Qi-Wei

(摘要)

東洋医学の診察は、四診（望診、聞診、問診および切診）と呼ばれる4種類の診察法で構成されている。この中で望診は、患者の顔色、表情、皮膚、爪、頭髮、舌などを注意深く観察する診察法であるが、これらのうちでも舌を見る舌診が特に重要とされている。舌診とは、舌の色・乾燥度・舌の苔（舌苔）などを診ることにより、五臓六腑の状態を診断する手法である。本研究では、東洋医学の舌診に基づき、人工知能技術を活用して、舌表面状態の画像識別による裂紋舌の自動診断法を提案する。裂紋舌は舌の肉部分（舌質）の表面が割れている状態にある舌であり、体が虚している病理状態（運動不足や栄養不足）を示している。また、裂紋舌の亀裂にはその深さと位置によって症状の度合いと病気のある臓器が異なる。なお、亀裂が深ければ深いほど、より深刻な酷い症状を示し、浅い亀裂はより軽い症状を示している。本研究で提案する診断法は、まず与えられた画像から人工知能の画像認識技術の一種であるMask R-CNN手法を用いて舌の部分を検出・抽出する。次に、抽出した画像を裂紋舌画像と非裂紋舌画像の2種類に分類する。最後に、裂紋舌画像から症状の度合いを診断する。本論文では、まず深層学習を用いた裂紋舌の自動診断の処理手順について説明する。次に、5つの画像認識モデル（LeNet, ResNet50, ResNet101, DenseNet169, ConvNeXt-Tiny）を用いて、裂紋舌の自動認識学習と裂紋舌の裂紋状態判定学習に対する画像分類の精度を調べ、これらのモデルに関する評価を行う。さらに、各々の学習で判定する正解率を高めるために、5つの画像認識モデルを融合するアンサンブル学習を行う。実験結果より、アンサンブル学習は5つの個別の画像認識モデルによる学習の正解率よりも優れており、どれも85%以上に達している。これらの結果から、本研究で活用した5つの画像認識モデルによるアンサンブル学習は裂紋舌の自動診断に効果的である。

キーワード：東洋医学、舌診、深層学習、裂紋舌、アンサンブル学習

* 山口大学大学院東アジア研究科博士課程（The Graduate School of East Asian Studies, Yamaguchi University）

** 山口短期大学情報メディア学科（Department of Informatics and Media, Yamaguchi Junior College）

*** 山口大学教育学部（Faculty of Education, Yamaguchi University）

**** 山口大学大学院東アジア研究科（The Graduate School of East Asian Studies, Yamaguchi University）

1. はじめに

東洋医学における鍼灸治療は、古代から伝承されてきた伝統的な治療法であり、治療師が患者に対して四診と呼ばれる独特の診察法を用いて病因を推定した上で、鍼や灸を用いて経穴を刺激し、身体のバランスを調整する治療法である。四診は、視覚による望診、聴覚と嗅覚を用いる聞診、会話による問診、患者の体に触れる切診（脈診、腹診、触診など）で構成される。この中で望診は、患者の顔色、表情、皮膚の状態、爪の形状、頭髮の様子、舌などを細心の注意を払って観察する診察法であるが、これらのうちでも舌を見る舌診が特に重要とされている。舌診は、舌の色・乾燥度・舌の苔（舌苔：ぜったい）などの状態を視覚で確認することで、五臓六腑の状態を診断する手法である[1]。鍼灸治療は副作用が少なく病気の予防や難病の治療などにも有効であることから、1989年にWorld Health Organization (WHO) に認められて以来、急速に世界に浸透してきている。しかし、鍼灸治療やその前提となる四診は未だ経験的・臨床的に行われており、その仕組みや過程も科学的に解明されていない。そのため、現代の西洋医学や科学的な観点も取り入れた客観的・統一的な研究方法や評価基準・評価方法の確立が求められている[2]。

我々はこのような東洋医学の現状を踏まえ、深層学習というArtificial Intelligence (AI) 技術を活用して、四診から鍼灸治療における治療方針の決定までを総合的に支援する鍼灸治療支援システムの開発を目指している[3]。このシステムは主に、四診を支援してその結果を解析する機能（機能1）、治療用経穴の候補を抽出する機能（機能2）、治療用経穴の候補を評価する機能（機能3）の3つから構成されている。

これまでに筆者らの研究グループでは、カラーペトリネットを用いて人体における経穴・経絡のモデルを構築し、カラーペトリネット解析ツール (CPN-Tools) を用いた鍼灸治療シミュレーション実験を通じて、治療現場では観測できない臓腑状態の変化の過程を数値的に提示する仕組みを実現してきた[4-6]。このモデルは機能3の基盤となるものである。本研究では、鍼灸治療支援システムの機能1として舌診を取り上げ、深層学習を舌診に活用し、舌画像の識別による裂紋舌の自動診断法を提案する。

これまでに舌画像の自動認識に関連する研究として、舌を自動認識するためのTongueNetの提案[7]、舌の観察結果に基づいたファジィ処理の研究[8]、舌領域からの舌苔領域のみの抽出に関する研究[9]、舌画像の精度向上のためのシステム開発[10]などが行われている。また深層学習を用いた舌診に関する研究としては、新型コロナウイルス感染症 (COVID-19) の診断支援のためにConvolutional Neural Network (CNN) 技術を活用して舌苔の種類を自動認識するGreasyCoatNet モデルを開発する研究[11]や、Faster R-CNN手法を活用して、裂紋舌（れつもんぜつ）、歯痕舌（しこんぜつ）、お点舌（おてんぜつ）、お斑舌（おはんぜつ）、膩苔（じたい）、剥落苔（はくらくたい）、腐苔（ふたい）の7種類の舌画像を分類し、それぞれの舌象（舌の変化）の特徴と性別、年齢、代謝性疾患との関係を解明する研究[12]および、舌画像解析における舌領域分割と舌特徴抽出の定量化および自動化のため、ソフトウェアを開発する研究[13]などが試みられている。しかしこれらの研究は、東洋医学の舌診における裂紋舌の裂紋状態を深層学習を用いて自動診断するまでには至っていない。

本研究では、裂紋舌に基づく裂紋状態の自

動診断技術の実現を目指して、画像に含まれる舌を自動で認識して切り抜き、舌画像を裂紋舌画像と非裂紋舌画像の2種類に分類した上で裂紋舌画像から酷い裂紋状態と軽い裂紋状態を識別する自動診断法を提案する。

以降本論文では、まず東洋医学における舌と五臓六腑の関係および本研究で用いる深層学習について説明する。次に、それらを活用した裂紋舌の自動診断手順として、LeNet[14]、ResNet50[15]、ResNet101[15]、DenseNet169[16]、ConvNeXt-Tiny[17]の5つの画像認識モデルを用いた裂紋舌の自動認識と裂紋舌の裂紋状態判定学習を説明する。なお、各々の学習結果を評価するために、5つの画像認識モデルを用いた時の舌診（画像分類）の性能を調べることで各モデルの評価を行う。また、裂紋舌画像に対する水増し手法の活用、アンサンブル学習の活用、および学習結果の比較に基づき、裂紋舌の自動診断の精度向上について考察する。

2. 東洋医学と深層学習

2.1 東洋医学について

五臓の相互関係を五行説に基づいて理解する考え方がある。具体的には、肝・心・脾・肺・腎の五臓を、それぞれ木・火・土・金・水の5つの要素に対応させて表現する。また、図1に示すように、五臓の間には相生と相克という関係が存在する。相生の関係とは相手を生み育てる母子関係のことであり、木→火→土→金→水の順で働きを促進する。相克の関係とは相手を抑制する関係であり、木→土→水→火→金の順で働きを抑制する[1]。

健康が維持される状態は、相生相克の関係が均衡している状態であると考えられる。また、五臓（肝・心・脾・肺・腎）と六腑（胆・小腸・胃・大腸・膀胱・三焦）は、お互いに

影響し合い、表裏一体の関係にある。具体的には、肝は胆に、心は小腸に、脾は胃に、肺は大腸に、腎は膀胱にそれぞれ影響を与えるとされている（三焦については省略）。これらの相互関係により、五臓と六腑は調和を保ちながら機能し、全体的な健康を維持する。

舌は直接的または間接的に多くの臓腑と繋がっている。一般的に、舌表面は舌尖部、舌辺部（左右）、舌中部、舌根部の5つの部位に分けられ、それぞれが心肺、肝胆、脾胃、腎に対応している（図2）。舌の各部位の変化は、内臓の気血の盛衰が舌に影響して現れる症状と関連していると考えられている。よって、舌の表面の変化を捉えることで内臓の状態の変化を把握することができる。

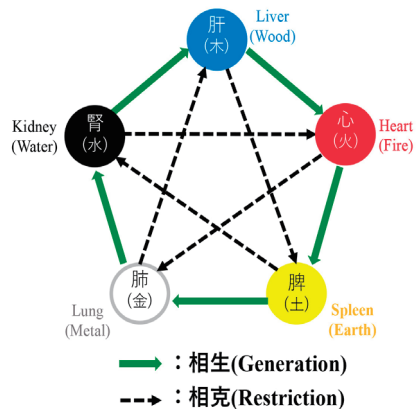


図1 五臓間の相生相克および五臓と腑の対応関係

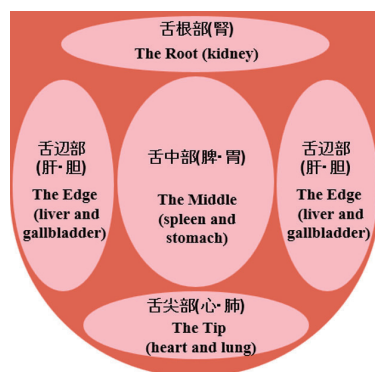


図2 舌表面の部位と臓腑の対応

舌診では、裂紋舌を舌質（舌の肉部分）の表面が割れている状態として定義されており、体が虚している病理状態（運動不足・栄養不足）を示唆するとされている。また、裂紋舌の亀裂にはその深さと位置によって症状の度合いと病気のある臓器が異なる。例えば、裂紋舌の亀裂が左側の舌辺部から右側の舌辺部まで横一列に広がっている場合、舌辺部と舌中部に対応する肝・胆と脾・胃に病気が存在すると言える。なお、亀裂が深ければ深いほど、酷い症状を示し、浅い亀裂は軽い症状を示している[18]。

2.2 本研究で用いる深層学習

本研究では、舌の自動認識を進めるに当たり、性能も高く、ソースコードも公開されている機械学習のMask R-CNN手法[19]を活用する。また、裂紋舌の自動認識と裂紋状態を判定するために、画像認識モデルであるLeNet, ResNet50, ResNet101, DenseNet 169およびConvNeXt-Tinyによる画像分類の機械学習を行う。なお、ConvNeXt-Tiny以外のモデルの詳細については、文献[20]を参照されたい。

ConvNeXtについては、Swin Transformerなど2021年代のViT系モデルの構造設計によってResNetを書き換えたモデルとして2022年に提案されたものである。ConvNeXtのモデル構造は、必要に応じて容易に拡張や変更が行えるように設計されており、スケラビリティが特徴的となっている。よって、提供されるデータが増えると正解率が向上する。なお、ConvNeXt-TinyとConvNeXt-BaseはそれぞれResNet50とResNet200をベースとして作られたモデルである。また、図3に示すように、ImageNetにおいて、ConvNeXt-Tinyの正解率は82.00%で、ResNet50の78.80%より大幅に改善されており、同等計算




図3 ResNetからConvNeXtに変更する流れ (文献^[17]のFig.2より引用)

量のSwin Transformer-Tinyの81.30%よりも正解率が高いことが分かる。従って、ConvNeXtは画像分類において最適化され、より優れた結果を達成している[17]。

さらに、裂紋舌の自動認識と裂紋状態を判定する割合を高めるために、LeNet, ResNet50, ResNet101, DenseNet169と以上紹介したConvNeXt-Tinyを含む5つのモデルを融合したアンサンブル学習を行う。ここで、アンサンブル学習とは、「複数の機械学習モデルを組み合わせるタイプ」の機械学習アルゴリズムのこと[21]である。これにより、単独では精度の高くないモデルを多数用いることで高い精度をたたき出すことが可能となり、未学習のデータに対する予測能力の向上が図られる。なお、アンサンブル学習の手法として、具体的に推測値のばらつきとなるバリエーションを抑えることを可能とするバギングを採用する。

3. 深層学習を活用した裂紋舌の自動診断法

3.1 裂紋舌の自動診断の処理手順

文献[20]で提案した5分割診断法は舌の5部位に対応する臓腑が病気状態と健康状態だけを判定していたのに対して、本研究では、病気のある臓腑に適切な水分や潤いが欠如しているか、さらにその病気の度合いまで判定するために、新たに図4のような裂紋舌の自動診断を目指している。この診断は、次の(1)～(3)の処理からなっている。(1) まず舌を含む写真が入力されると、図5に示すように、その舌を自動的に認識・切抜するように舌のみの画像データを生成する(図4②③)。(2) 次に、生成された舌画像において、「裂紋舌の自動認識用モデル」を適用して、裂紋舌の画像データと非裂紋舌の画像データを生成する(図4⑤⑥)。(3) 最後に、生成された裂紋舌の画像データに対して、「裂紋舌の裂紋状態判定用モデル」を適用して、裂紋舌の裂紋状態を自動診断する(図4⑨⑩)。以降3.2節および3.3節にて、(2)(3)の学習とハイパーパラメータの設定について述べる。なお、(1)の具体的な処理方法の詳細については文献[20]を参照されたい。

3.2 裂紋舌の自動認識と裂紋状態判定

裂紋舌の自動認識を行うために、画像データを次のように用意する。文献[18],[22]～[26]からの画像のみで裂紋舌を自動認識する実験を行うとすると、裂紋舌と記されている画像の枚数が少なく、高精度な学習結果を得ることが困難であると判断した。そこで、新たに文献[27]～[29]から491枚の画像を収集して、合計1717枚の画像から180枚の裂紋舌画像を選び出して用いることにした。

学習の方法としては、裂紋舌の自動認識学

表1 裂紋舌の自動認識学習に用いる画像の内訳 (水増しなし)

画像データ クラス	学習用画像 (枚)	検証用画像 (枚)	テスト用画像 (枚)
裂紋舌	153	17	10
非裂紋舌	153	17	10

表2 裂紋舌の裂紋状態判定学習に用いる画像の内訳 (水増しあり)

画像データ クラス	学習用画像 (枚)	検証用画像 (枚)	テスト用画像 (枚)
裂紋状態が酷い	135	15	10
裂紋状態が軽い	135	15	10

習は裂紋舌か非裂紋舌かを予測する2クラス分類問題に属しているため、裂紋舌のクラスと非裂紋舌のクラスの2つのクラスに分けて行うこととする。具体的には、非裂紋舌のクラスの画像は、1717枚の画像から裂紋舌であるクラスに属している画像を除き、非裂紋舌であると思われる画像を目視により選び出した。なお、この学習では、裂紋舌と非裂紋舌を区別する特徴を自動的に学習し、新たな舌画像に対しても適切な分類を行えるようになる。これにより、裂紋舌の自動認識において高い信頼性が確保され、さまざまな応用領域で有用な成果が期待される。

次に、裂紋舌の裂紋状態判定学習の方法としては、裂紋舌の裂紋状態を裂紋が酷いクラスと裂紋が軽いクラスの2つのクラスに分けて行うこととする。また、学習の準備として、裂紋舌の自動認識学習に用いた180枚の裂紋舌画像から裂紋状態が酷いものを40枚選び出し、それらを除いた120枚から裂紋状態が軽いと思われる40枚の画像を目視により選び出した。しかしこれらの画像の枚数は極めて少ないため、今回はデータを拡張するという水増し手法を取り入れる学習を行う。具体的には、それぞれのクラスの画像に対して、画像処理ライブラリであるOpenCVのflip関数による「上下反転」、「左右反転」および「上下反転+左右反転」の3種類の変換を施す

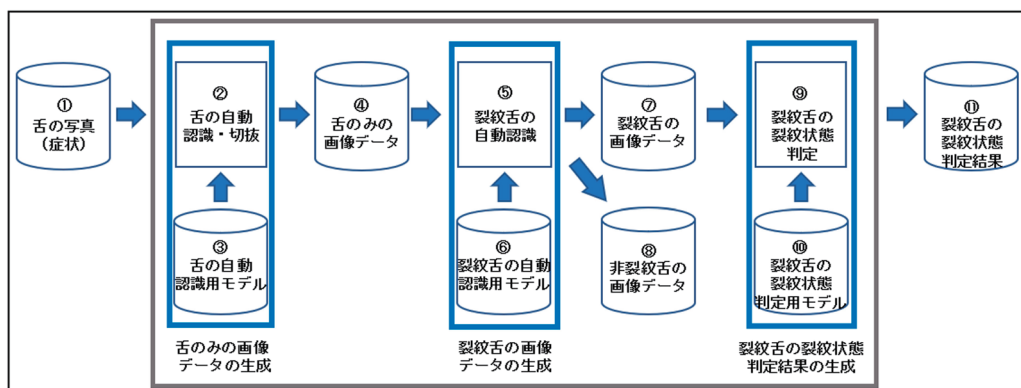


図4 深層学習を用いた裂紋舌の診断の流れ




図5 舌の自動認識と切り抜き

ことでデータを水増しして、5つの画像認識モデルを個別に用いた学習およびアンサンブル学習に活用する。この水増し手法により、多種多様な画像を学習用データとして用意することができ、それぞれの変換によって生じる画像の違いは、表現のバリエーションをカバーするのに有効的である。

以上のような学習方法に基づいて分類した学習用、検証用とテスト用画像の枚数の内訳をそれぞれ表1と表2に示す。

3.3 ハイパーパラメータの設定

本研究では、LeNet, ResNet50, ResNet101, DensNet169, ConvNeXt-Tinyの5つの画像認識モデルを用いて「裂紋舌の自動認識用モデル」(図4⑥)と「裂紋舌の裂紋状態判定用モデル」(図4⑩)を生成するための学習を行う。また、裂紋舌の自動認識と裂紋舌の裂紋状態を判定する正確さを高めるために、複数の画像認識モデルを融合したアンサンブル

も行う。

これらの学習においては、epoch数(1つの学習データを繰り返し学習する数[30])とパラメータ更新ごとに用いるサンプルの数(Batch size)[31]をそれぞれ“epoch 100”と“4”と設定している。なお、過学習を防ぐ手段として、5つの画像認識モデルを学習する際には、検証用画像を2クラスに正しく分類できた割合(Validation accuracy)(以降、検証正解率と呼ぶ)を確認し、最良となるepochで学習を停止するEarly Stopping[32]を適用する。一方で、アンサンブル学習を行う際には、重み付けを5000回行い、そのうち最も高い検証正解率を持つモデルを出力結果として評価する。学習結果の中で、テスト用画像に対して正しく識別した割合の最も高いモデルが判定した結果を裂紋舌の裂紋状態の最終判定結果として採用する。これら裂紋舌の裂紋状態判定における全ての学習において、よく使われている機械学習の最適化アルゴリズムの1つであるAdam[33]を学習率の値を0.001から0.01まで0.003刻みで増やしながら適用している。学習率は、機械学習の最適化において1回の学習で重みパラメータをどのくらい変化させるのかを定める指標であり、学習率が大きくなりすぎるとLossの値が発散し、小さくなりすぎるとLossの値の

収束が遅くなる[34]. よって効率的なパラメータ探索処理の実現には最適な学習率を見つけ出すことが重要である.

2クラス分類問題に関する評価指標として定義されている混同行列とその指標および本研究で取り扱う3つの評価指標をそれぞれ表3, 表4および表5に示す[35, 36]. なお, 裂紋舌の自動認識学習では, 正クラスと負クラスはそれぞれ裂紋舌の画像と非裂紋舌の画像を指しており, 裂紋舌の裂紋状態判定学習における正クラスと負クラスはそれぞれ裂紋舌の裂紋状態が酷い画像と裂紋状態が軽い画像を表している. 以降, 4章の学習結果の評価においては, これらの用語を用いることとする.

表3 混同行列

		モデルが予測したクラス	
		正 (Positive)	負 (Negative)
実際のクラス	正 (Positive)	TP (True Positive)	FN (False Negative)
	負 (Negative)	FP (False Positive)	TN (True Negative)

表4 混同行列の指標

指標	説明
TN (True Negative)	実際の負クラスを正しく負クラスと予測された数
FN (False Negative)	実際の正クラスを間違えて負クラスと予測された数
FP (False Positive)	実際の負クラスを間違えて正クラスと予測された数
TP (True Positive)	実際の正クラスを正しく正クラスと予測された数

表5 テスト結果の評価指標

評価指標	意味	計算式
再現率 (Recall)	実際の正クラスの内, 正しく正クラスと分類出来た割合	$TP / (TP + FN)$
特異度 (Specificity)	実際の負クラスの内, 正しく負クラスと分類出来た割合	$TN / (FP + TN)$
正解率 (Accuracy)	予測クラス総数の内, 正しく分類出来たクラスの割合	$(TP + TN) / (TP + FP + FN + TN)$

4. 学習結果と評価

これまで述べてきた裂紋舌の自動認識と裂紋舌の裂紋状態判定のための学習結果を評価するために, 5つの画像認識モデルそれぞれについて, テスト用画像を分類するテストを実施し, 分類結果の正解率を比較評価する.

さらに正解率の向上を目指して, 複数のモデルを組み合わせたアンサンブル学習を行い, そのテスト結果を評価する. これらの結果で最良のモデルを, それぞれ「裂紋舌の自動認識用モデル」(図4⑥)と「裂紋舌の裂紋状態判定用モデル」(図4⑩)として採用する.

実験に用いた画像認識モデルのうち, LeNet は文献[14]で示された構造に基づいてモデルを構築・初期化してから利用しており, Resnet50, Resnet101, DenseNet169およびConvNeXt-Tinyは, Tensorflow のパッケージであるkeras.applicationsからダウンロードした事前学習済みモデルを利用している. また, 各々の事前学習済みモデルはファインチューニングにより, 全結合層を2クラス分類用に変更し, 再学習は後半の層から行うようにしている.

4.1 5つの画像認識モデルによる結果

ここでは, LeNet, ResNet50, ResNet101, DenseNet169, ConvNeXt-Tinyによる表1と表2のテスト用画像を分類する実験を行い, その結果を比較する. 実験の手順は以下のとおりである.

【実験手順】裂紋舌の自動認識学習と本研究で使用する3種類の水増し手法を適用した裂紋舌の裂紋状態判定学習に対して, 5つの個別の画像認識モデルによる学習ごとに以下を繰り返す.

1. 設定した4つの学習率ごとに, 学習して得られたモデルに検証用画像を用いて検証した結果, 検証正解率の値が最も高いモデルを選ぶ.
2. 選び出された4つのモデルから, テスト用画像を用いた正解率が最も高いモデルを, その画像認識モデルによる学習に適用したモデルとして採用する.

5つの画像認識モデルについて, 採用され

表6 5つのモデルによる裂紋舌の自動認識学習の結果 (水増しなし)

モデル (学習率)	テスト結果	再現率	特異度	正解率
LeNet (0.004)		80%	60%	70%
ResNet50 (0.007)		80%	80%	80%
ResNet101 (0.01)		80%	80%	80%
DenseNet169 (0.001)		70%	100%	85%
ConvNeXt-Tiny (0.007)		80%	90%	85%

表7 5つのモデルによる裂紋舌の裂紋状態判定学習の結果 (水増しあり)

モデル (学習率)	テスト結果	再現率	特異度	正解率
LeNet (0.004)		40%	100%	70%
ResNet50 (0.004)		70%	90%	80%
ResNet101 (0.01)		60%	40%	50%
DenseNet169 (0.001)		60%	80%	70%
ConvNeXt-Tiny (0.001)		30%	100%	65%

たモデルによる裂紋舌の自動認識学習と本研究で使用する3種類の水増し手法を適用した裂紋舌の裂紋状態判定学習のテスト結果を表6と表7に示す。

表6より、裂紋舌の自動認識学習において、正解率が最も高いものは85%であり、学習に用いた画像認識モデルと学習率では“DenseNet169と0.001”と“ConvNeXt-Tinyと0.007”の2つが存在するが、後者の方の再現率と特異度の差が前者より小さいため、“ConvNeXt-Tiny”は裂紋舌の自動認識学習において、裂紋舌のクラスと非裂紋舌のクラスの両方に対してより均衡して高い性能を示していると考えられる。

また、表7に示すように、本研究で使用する3種類の水増し手法を適用した裂紋舌の裂紋状態判定学習において、正解率が最も高いものは80%であり、学習に用いた画像認識モデルと学習率は“ResNet50と0.004”であった。しかし、表7において、正解率が最も高いもの以外の画像認識モデルによる学習の正解率はすべて70%以下と比較的低い結果となっており、これらのモデルを個別に用いて学習した結果は全般的に正解率が十分とは言

えない。そこで、複数の画像認識モデルを用いたアンサンブル学習を活用することで正解率の向上を図る。

4.2 アンサンブル学習を用いた実験

裂紋舌の自動認識と裂紋状態判定の正解率を高めるために、4.1節で述べた5つの画像認識モデルを用いてアンサンブル学習を行う。この処理では、(1) 5つの画像認識モデルそれぞれについて、学習用画像と検証用画像を用いて学習および検証を行い、最も高い検証正解率をもつモデル M_1, M_2, M_3, M_4, M_5 を取得し、(2) 得られた5つのモデルから加重平均を用いたアンサンブル学習[37]により新たなモデルを得る、という手順で実行される。手順(2)では、重み付けされたモデルに対して、検証正解率が最も高いモデルを出力させるために、5000回の探索を行う。その詳細は次の通りである。

- (a) M_1, \dots, M_5 に対して、重み $W_{M_1}, W_{M_2}, W_{M_3}, W_{M_4}, W_{M_5}$ の値を均等に割り振り、かつ合計値が1となるように設定し、アンサンブル学習で得られたモデルを h_0 とする。
- (b) i を0に初期化する。
- (c) M_1, \dots, M_5 に対して、新たな重み $W_{M_1}, W_{M_2}, W_{M_3}, W_{M_4}, W_{M_5}$ を合計値が1となるようにランダムに設定し、アンサンブル学習で得られたモデルを h_i とする。
- (d) もし h_i の検証正解率が h_0 の検証正解率より大きい場合、 h_i の検証正解率を h_0 に代入し、 i を1増やして (e) へ。そうでなければ、 i を1増やして (e) へ。
- (e) $i < 5000$ であれば (c) へ。そうでなければ h_0 をアンサンブル学習の結果として出力して終了。

表8と表9は、LeNet, ResNet50,

ResNet101, DenseNet169およびConvNeXt-Tinyに対して, 上記のアンサンブル学習を裂紋舌の自動認識と3種類の水増し手法を取り入れた裂紋舌の裂紋状態判定に適用した各々のテスト結果である. これらの表には, 学習率を0.001から0.01まで0.003刻みで増やして実験した中で, 最も高い正解率とその時の学習率を示している. 例えば, 表8においては, 本研究で設定した4つの学習率に対する正解率はどれも90%で一貫しており, 同時にこれらのテスト結果は裂紋舌の自動認識における最も高い正解率となっている. 同様に, 表9のアンサンブル学習による3種類の水増し手法を取り入れた裂紋舌の裂紋状態判定の場合は, 学習率が0.007の時に最も高い正解率85%が得られている.

さらに, 比較的新しい画像認識モデルであるConvNeXt-Tinyによる効果を確認するために, LeNet, ResNet50, ResNet101およびDenseNet169の4つの画像認識モデルに対しても, 前述と同様の学習を行った. 表10に示したとおり, 4つの画像認識モデルを対象としたアンサンブル学習によるテスト結果は, ConvNeXt-Tinyを含めた5つの画像認識モデルを対象としたアンサンブル学習の最も高い正解率とすべて同じであることが分かる. ただし, 水増し手法を取り入れた裂紋舌の裂紋状態判定においては, 表10に示すように, 5つの画像認識モデルを対象としたアンサンブル学習の方の再現率と特異度の差が4つの画像認識モデルを対象としたアンサンブル学習より20%小さいため, “ConvNeXt-Tiny”は水増し手法を活用した裂紋舌の裂紋状態判定において, 裂紋舌の裂紋状態が酷いクラスと裂紋状態が軽いクラスの両方に対してより均衡して高い性能を示していると言える. 従って, 比較的新しい画像認識モデルであるConvNeXt-Tinyも効果があると言える. な

表8 アンサンブル学習による裂紋舌の自動認識テスト結果 (水増しなし)

学習率 \ テスト結果	再現率	特異度	正解率
0.001	80%	100%	90%
0.004	80%	100%	90%
0.007	80%	100%	90%
0.01	80%	100%	90%

表9 アンサンブル学習による裂紋舌の裂紋状態判定テスト結果 (水増しあり)

学習率 \ テスト結果	再現率	特異度	正解率
0.007	80%	90%	85%

表10 4つの画像認識モデルを対象としたアンサンブル学習のテスト結果

対象のモデル	LeNet, ResNet50, ResNet101, DenseNet169		
裂紋舌の自動認識テスト結果 (水増しなし)			
学習率 \ テスト結果	再現率	特異度	正解率
0.001	80%	100%	90%
0.007	80%	100%	90%
0.01	80%	100%	90%
裂紋舌の裂紋状態判定テスト結果 (水増しあり)			
0.001	70%	100%	85%
0.004	70%	100%	85%
0.007	70%	100%	85%

お, 古典的と言われるLeNet, および, 効果や特性が似通ったResNet50とResNet101とをアンサンブル学習の組み合わせ対象として併用することによる効果や有用性については文献[20]を参照されたい.

加えて, 表6と表7に示したモデルを個別に用いた際の正解率と表8と表9のアンサンブル学習による正解率とを比較すると, アンサンブル学習の正解率はLeNet, ResNet50, ResNet101, DenseNet169およびConvNeXt-Tinyを個別に用いた際の正解率を上回ることが分かる. よって, アンサンブル学習は5つの個別の画像認識モデルによる学習より優れていると言える. また, 表7と表9において, 3種類の水増し手法を適用した裂紋舌の裂紋状態判定学習の最も高い正解率はそれぞれ80%と85%であることから, 本研究で数少

ない裂紋舌の画像データに対して使用した3種類の水増し手法は、データの多様性を向上させ、データ不足を補うのに適切かつ有効的であると言える。

5. おわりに

本論文ではAI技術の深層学習を活用して、LeNet, ResNet50, ResNet101, DenseNet169, ConvNeXt-Tinyの5つの画像認識モデルおよびこれらのアンサンブルを活用した舌表面状態の画像識別による裂紋舌の自動診断法を提案した。

舌表面状態の画像識別による裂紋舌の自動診断法では、Mask R-CNNを用いて舌画像の認識と切り抜きを行い、その結果を裂紋舌の自動認識学習に適用して、裂紋舌のみの画像データを抽出した上で、裂紋舌の裂紋状態を判定する。裂紋舌の自動認識と裂紋舌の裂紋状態の判定には、LeNet, ResNet50, ResNet101, DenseNet169, ConvNeXt-Tinyの5つの画像認識モデルによるアンサンブル学習を用いる。

提案した舌表面状態の画像識別による裂紋舌の自動診断法を評価するために、まず9冊の書籍にある1717枚の画像から選び出した360枚を対象に、裂紋舌の自動認識学習を行った。次に収集した180枚の裂紋舌画像から選び出した80枚を対象に、“上下反転”、“左右反転”および“上下反転+左右反転”の3種類の水増し手法で画像データを4倍に拡張して5つのモデルおよびこれらのアンサンブルの評価実験を行った。これらの実験結果より次のことが明らかになった。なお、アンサンブル学習では比較的新しい画像認識モデルであるConvNeXt-Tinyも取り入れて活用するがその効果と有用性も確認された。

(i) 裂紋舌の自動認識学習については、5

つの画像認識モデルの学習における最良のテスト結果として、いずれも正解率が70%以上である。また、アンサンブル学習を用いた場合、設定した4種類の学習率において、いずれも正解率が90%であり、5つの個別の画像認識モデルの学習における最良の正解率より20%高くなっていることから、アンサンブル学習を用いた方が効果的である。

(ii) 裂紋舌の裂紋状態判定学習については、5つの個別の画像認識モデルの学習とアンサンブル学習を用いた場合、それらの最良のテスト結果として、各々の最高な正解率が80%と85%であることから、アンサンブル学習を利用した方がより効果的であり、本研究で裂紋舌の画像データに対して使用した3種類の水増し手法も有効的であると言える。

今後の課題として、(1) 学習効果を上げるために、更なる裂紋舌画像の収集や新たな水増し手法の適用を行うこと、(2) 裂紋舌の自動診断の精度を向上させるために、より多くの画像認識モデルを取り入れたアンサンブル学習を試みること、(3) 舌の色や舌質・舌苔の状態等に基づいた更なる詳細な基準を設けて、画像を病気別により精度の高い割り振りの方法を検討すること、などが挙げられる。

謝辞

本研究はJSPS科研費（基盤研究B）20H04284の助成を受けたものであり、また、裂紋舌画像と裂紋状態の酷い画像の選出については中国山東中医薬大学の楊佃会教授・主任医師からご協力をいただいた。ここで謝意を表する。

文献

- [1] 兵頭明, 『東洋医学のしくみ』, 新星出版社, 2012.
- [2] 篠原昭二, 他, “第二次日本経穴委員会の提言”, 医道の日本, vol.71, no.5, pp.142-154, 2012.
- [3] 甘泉, 呉靱, 中田充, 葛崎偉, “東洋医学における鍼灸治療に向けた支援システムの提案”, 信学技報, vol.120, no.246, pp.40-43, 2020.
- [4] 甘泉, 呉靱, 中田充, 葛崎偉, “カラーペトリネットによる東洋医学の人体モデルの構築”, IEICE Trans. Inf.&Syst., vol.J104-D, no.04, pp.217-227, 2021.
- [5] Q. Gan, R. Wu, M. Nakata and Q.W. Ge, “Construction of a human body model for acupuncture and moxibustion treatment by colored petri nets”, BioSystems, vol. 210, no.104526, pp.1-11, 2021 (<https://doi.org/10.1016/j.biosystems.2021.104526>).
- [6] 甘泉, 呉靱, 葛崎偉, “気・血・津液を考慮した東洋医学の人体モデルの構築”, 東アジア研究, no.20, pp.85-98, 2021.
- [7] C. Zhou, H. Fan and Z. Li, “Tonguenet : Accurate localization and segmentation for tongue images using deep neural networks”, IEEE Access, vol.7, pp.148779-148789, 2019.
- [8] 和辻直, “ファジィ理論を応用した舌診断支援システムの構築と検証”, 明治鍼灸医学, no.33, pp.11-33, 2003.
- [9] G. Nambu, T. Namiki, T. Nakaguchi and T. Tanaka, “Extraction of tongue coating area from tongue image for automated tongue diagnosis”, Journal of Ergonomic Technology, vol.20, no.1, pp.1-9, 2020.
- [10] 三宅洋一, “伝統医学への期待”, Journal of Image & Information Management, no.5, p.36, 2018.
- [11] X. Wang et al., “Constructing tongue coating recognition model using deep transfer learning to assist syndrome diagnosis and its potential in noninvasive ethnopharmacological evaluation”, Journal of Ethnopharmacology, vol.285, no.114905, pp.1-8, 2021 (<https://doi.org/10.1016/j.jep.2021.114905>).
- [12] T. Jiang et al., “Deep learning multi-label tongue image analysis and its application in a population undergoing routine medical checkup”, Hindawi, vol.2022, no.3384209, pp.1-12, 2022.
- [13] 石川堅也, 他, “舌診断支援のための深層学習を用いた舌特徴抽出ソフトウェアの開発”, IEICE Technical Report, vol.122, no. MI-188, pp.47-48 (MI), 2022.
- [14] Y., LeCun, P., Haffner, L., Bottou and Y., Bengio, “Object recognition with gradient-based learning”, Shape, Contour and Grouping in Computer Vision, Lecture Notes in Computer Science, vol.1681, pp.319-345, 1999.
- [15] K. He, X. Zhang, S. Ren and J. Sun, “Deep residual learning for image recognition”, Proc. ICLR, pp.770-778, 2015.
- [16] G. Huang, Z. Liu, L. Van Der Maaten and K.Q. Weinberger, “Densely connected convolutional networks”, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.2261-2269, 2017.
- [17] Z. Liu et al., “A ConvNet for the 2020s”, 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), New Orleans, LA, USA, 2022, pp.11966-11976, (<https://doi.org/10.1109/CVPR52688.2022.01167>).
- [18] 陳勇, 『舌診論』, 合同会社花乱社, 2018.
- [19] K. He, G. Gkioxari, P. Dollár and R. Girshick, “Mask r-cnn”, Proc.2017 IEEE ICCV, pp.2980-2988, 2017.
- [20] 安振宇, 呉靱, 中田充, 葛崎偉, “舌画像の深層学習による臓腑健康状態の自動診断”, Journal of Signal Processing, vol.27, no.5, 2023.
- [21] 坂本俊之, 『作ってわかる! アンサンブル学習アルゴリズム入門』, シーアンドアール研究所, p.12, 2019.
- [22] 許家佗, 『中医舌診臨床図解』, 化学工業出版社, 2017. (in Chinese)
- [23] 王彦暉, 『舌象図鑑-臨床実用』, 化学工業出版社, 2018. (in Chinese)
- [24] 周幸来, 『舌診快速入門第2版』, 遼寧科学技術出版社, 2016. (in Chinese)
- [25] 黄英儒, 黄国東, 黄曉, 『舌診-名老中医』, 化学工業出版社, 2018. (in Chinese)
- [26] 羅大倫, 『図解舌診』, 江西科学技術出版社, 2015. (in Chinese)
- [27] 藤本連風, 平田耕一, 山本哲斎, 『針灸舌診アトラス』, 緑書房, 2012.
- [28] 費兆馥, 顧亦棣, 『舌診カラーガイド(新装版)』, エルゼビア・ジャパン, 2016.
- [29] 王憶勤, 『漢英対照中医舌診図譜』, 上海科学技術出版社, 2007. (in Chinese)
- [30] F. Chollet, 『PythonとKerasによるディープラーニング』, マイナビ出版社, 2018.
- [31] 斎藤康毅, 『ゼロから作るDeep Learning-

- Pythonで学ぶディープラーニングの理論と実装』, 株式会社トップスタジオ, 2019.
- [32] 瀧雅人, 『機械学習スタートアップシリーズこれならわかる深層学習入門』, 講談社, 2017.
- [33] D.P. Kingma and J.L. Ba, "ADAM: A method for stochastic optimization", Proc.ICLR 2015.
- [34] L.N. Smith, "Cyclical learning rates for training neural networks", Proc.IEEE Winter Conference on Applications of Computer Vision (WACV), pp.464-472, 2017.
- [35] アンドレアス・C・ミュラー, サラ・グイド 『Python ではじめる機械学習』, 株式会社オライリー・ジャパン, pp.270-298, 2020.
- [36] 松岡勝也, Mhd Irvan, 小林良輔, 山口利恵, "多要素認証におけるスコアフュージョンへのニューラルネットの適用", Information Processing Society of Japan, vol.2019, pp.734-739, 2019.
- [37] Z.H. Zhou, 『アンサンブル法による機械学習: 基礎とアルゴリズム』, 近代科学社, 2017.