

健康・農業分野への社会実装を目指した 画像診断技術の開発

住友化学株式会社 バイオサイエンス研究所

河 合 駿
中 川 博 之
味 方 和 樹
富 永 幸 雄*



はじめに

近年、画像認識技術の発展が著しい。画像認識技術は、画像に映る情報を抽出し、その情報から被写体を識別する技術である。2010年代に入り、深層学習の発展とコンピュータの計算能力の向上に伴い、画像上の特徴を網羅的に取り出す手法（畳み込み）の活用により画像認識能力が飛躍的に向上した。ヒトの認識能力を凌駕する事例^{1), 2)}も報告されており、従来の目視による診断の一部が、“AI画像診断”によって置き換えられようとしている。例えば2018年に、内視鏡画像から“がん部位”を検出するAIソフトウェアが、国内初となる医薬品医療機器等法に基づく承認を取得し、社会実装されつつある³⁾。

農業分野においても、画像診断技術の応用が期待されている（Fig. 1）。圃場では、栄養状態・病害虫・収穫時期など作物の状態を目視で見極めることが多い。しかし、熟練の農業従事者であっても詳細な判断は難しい場合があり、病害虫では対応が遅れて損害

を大きくしてしまうことがある。適切な処置をタイムリーに施すための正確な診断を専門家に仰ぐには時間を要することから、深層学習を用いた画像診断技術が応用されつつある^{4), 5)}。しかしながら、生物画像を対象とする深層学習では、画像認識における学習モデル（画像情報パターンを数式化したもの）の最適化が難しいという大きな技術課題がある。生物は同一種でも外観上の個体差が大きく（高多様性）、異なる種類の画像の収集が困難（少サンプル）である。一方で、多種類の対象を分類する“多群分類モデル”には高い複雑性が求められ、その最適化には数万から数十万種類以上の膨大な画像データと、それに比例した長大な学習時間が必要である。サンプルが不足した状況では、“過学習”と呼ばれる状態に陥り、汎用性の低いモデルしか得られない。このような課題に対して、新規学習手法を開発し、実際に植物・農作物の病害虫診断の社会実装を実現したので紹介する。




Fig. 1 Application of imaging technology in agriculture

* 現所属：技術・研究企画部

生物を対象とした高精度画像診断技術の開発

1. 多群分類問題における問題の単純化

前述の通り、生物画像の深層学習による多群分類問題では学習の最適化は容易ではない。当社では、この課題に対して、与える問題を分割・単純化することにより解決した。すなわち、非常に複雑な多群分類問題をできるだけ単純な複数の2群分類問題に分解し、各問題に対する学習モデル（2群分類モデル）を構築した後、その組み合わせによって元の問題を解くという方法である。この方法では、各モデルに求められる複雑性が下がることで過学習が起き難くなり、結果として汎用性の向上が見込める。例えばn種類の画像を分類するとき、一般的には一つの多群分類モデルによって画像分類を行うところ、本手法では nC_2 通りの2群分類モデルを構築し、これらを組み合わせることで多群分類を行う（Fig. 2）。

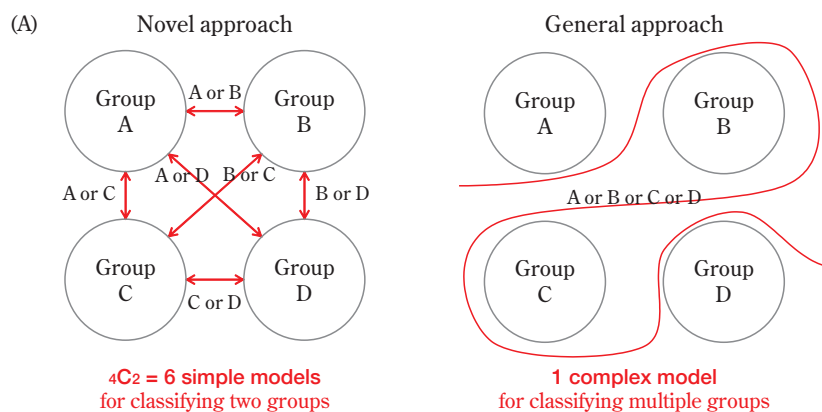
次章では、病害虫の多群分類問題に対して実際に本手法を適用し、より高性能な分類モデルが開発できるか検討した事例を紹介する。病害虫診断におい

て一般的な手法を用いた場合、診断の汎用性の低さや診断可能な対象が限定されるといった課題も指摘されている⁴⁾。

2. 植物病害虫への応用

(1) バラ病害虫の事例

バラの主要病害であるべと病（Downey mildew）、黒星病（Black spot）、さび病（Rust）、および、うどんこ病（Powdery mildew）を対象として、診断モデルの構築を試みた（Fig. 3(A)）。ここでは、各病害について約50~100枚の学習用の画像データ（学習データ）と学習に未使用の画像データ約20枚（検証データ）を与えて、学習モデルの構築と評価を行った。まず一般的な手法により4群分類の学習モデル（多群分類モデル）を構築したところ、学習データにおける正答率（以下、学習精度）は98.6%であったが、検証データにおける正答率（以下、検証精度）は66.3%に過ぎなかった。検証データは生育条件が異なる場合の画像であり、多群分類モデルの汎用性の低さが確認された。



(B)

Membership probability (%)	Group A	Group B	Group C	Group D	Total score
Group A	-	70	100	100	270
Group B	30	-	70	60	160
Group C	0	30	-	60	90
Group D	0	40	40	-	80

Fig. 2 Novel approach to the high-complexity classification problem in bioimaging

(A) Characteristic of the learning approach in our method. Six simple learning models are constructed in our novel approach, while one complex learning model is constructed in the general approach. Each red line and arrow indicate an individual learning model for distinction between or among groups. (B) Diagnostic method in our approach. Each total score equals the sum of membership probabilities obtained from multiple models. The scores indicate the expectation of a belonged group.

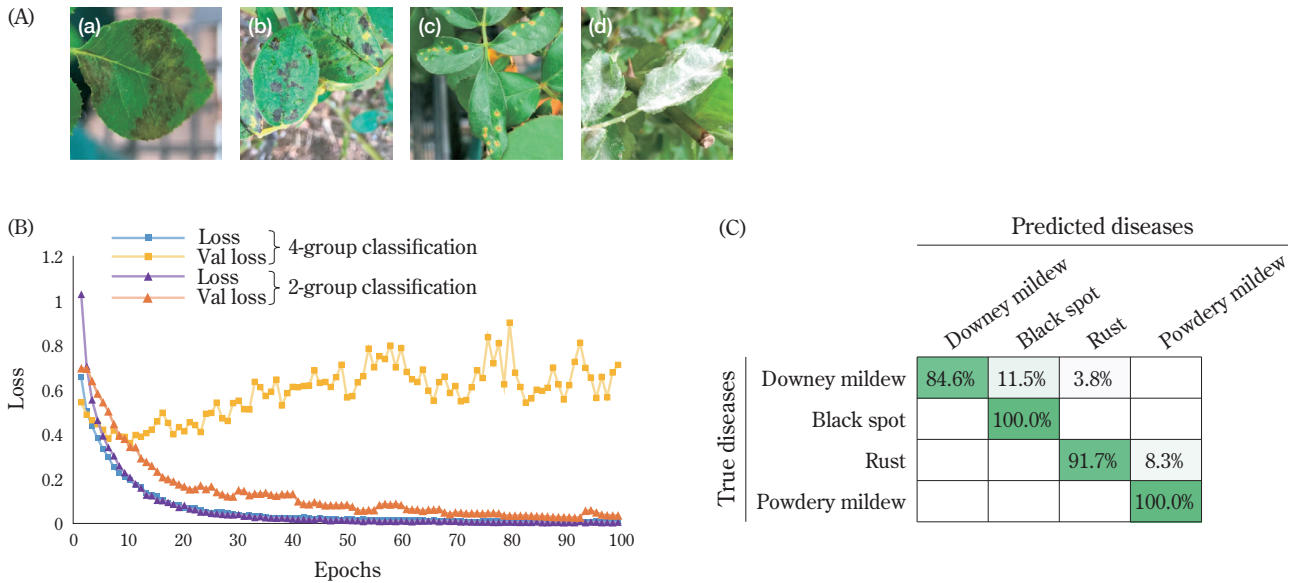


Fig. 3 Sample images and classification results for four rose diseases (A) Images of four types of pests: (a) Downey mildew, (b) Black spot, (c) Rust, (d) Powdery mildew. (B) Difference of training and validation loss in the training process. (C) Confusion matrix of the predicted result. The diagonal cells indicate classification accuracy, and the other cells show the percentage of misclassification. Blank cells indicate 0.0%.

また損失（真の答えと予測結果の差）の推移を確認すると、4群分類では検証データに対する損失が0.4付近から低下をせず過学習を起こしている（Fig. 3(B)）。一方、本手法により6通り（= $4C_2$ ）の2群分類モデルを構築し、検証データを評価した結果をFig. 3(C)に示す。ここでは、検証データを各分類モデルに当てはめ、Fig. 2(B)のようにMembership Probabilityを算出し、Total Scoreが最大値となったグループを予測病害群とした。またFig. 3(C)では、真の答えと一致した割合を対角線上（検証精度）に示しており、不一致の割合を他のセルに示している。病害ごとの検証精度は84.6~100.0%であり、全病害に対する検証精度は94.1%（正答枚数/全検証画像枚数）となった。一般的な手法による結果と比較して本手法による診断性能は大きく向上しており、その有効性が示唆された。

続いて、バラの害虫13種を対象として同様の検討を行った（Fig. 4(A)）。13群分類モデルの分類性能は検証精度が65.2%（学習精度96.6%）となった。次に本手法により分類モデルを構築した。ここでは組み合わせの数の増大を抑制するために、画像をイモムシ

様と非イモムシ様の二つのカテゴリに分類するモデルをまず構築し、分類された各カテゴリ内で2群分類モデルを構築して結果を統合した（イモムシ様： $4C_2 = 6$ 通り、非イモムシ様： $9C_2 = 36$ 通り、Fig. 4(B)）。本手法によって害虫ごとの検証精度は75.0~100.0%となり、全害虫に対する検証精度は93.8%（正答枚数/全検証画像枚数）と大幅に改善された（Fig. 4(C)）。以上のことから、本手法は、多群分類において一般的に使われる手法と比較して、より高精度な学習モデルを構築できることが示された。

(2) キャベツ害虫の事例

さらに本技術の汎用性を確認するため、キャベツ害虫（学習データ：約50~100枚、検証データ：約10~30枚）に対して同様の検討を行った。鱗翅目系害虫の幼虫6種、小型害虫5種を対象（Fig. 5(A)）として一般的な多群分類モデルを構築すると、検証精度は69.1%（学習精度99.5%）となり高精度とは言えない結果となった。一方、本手法により分類を行うと、害虫ごとの検証精度は75.0~100.0%、全害虫に対する検証精度は94.5%（正答枚数/全検証画像枚数）と

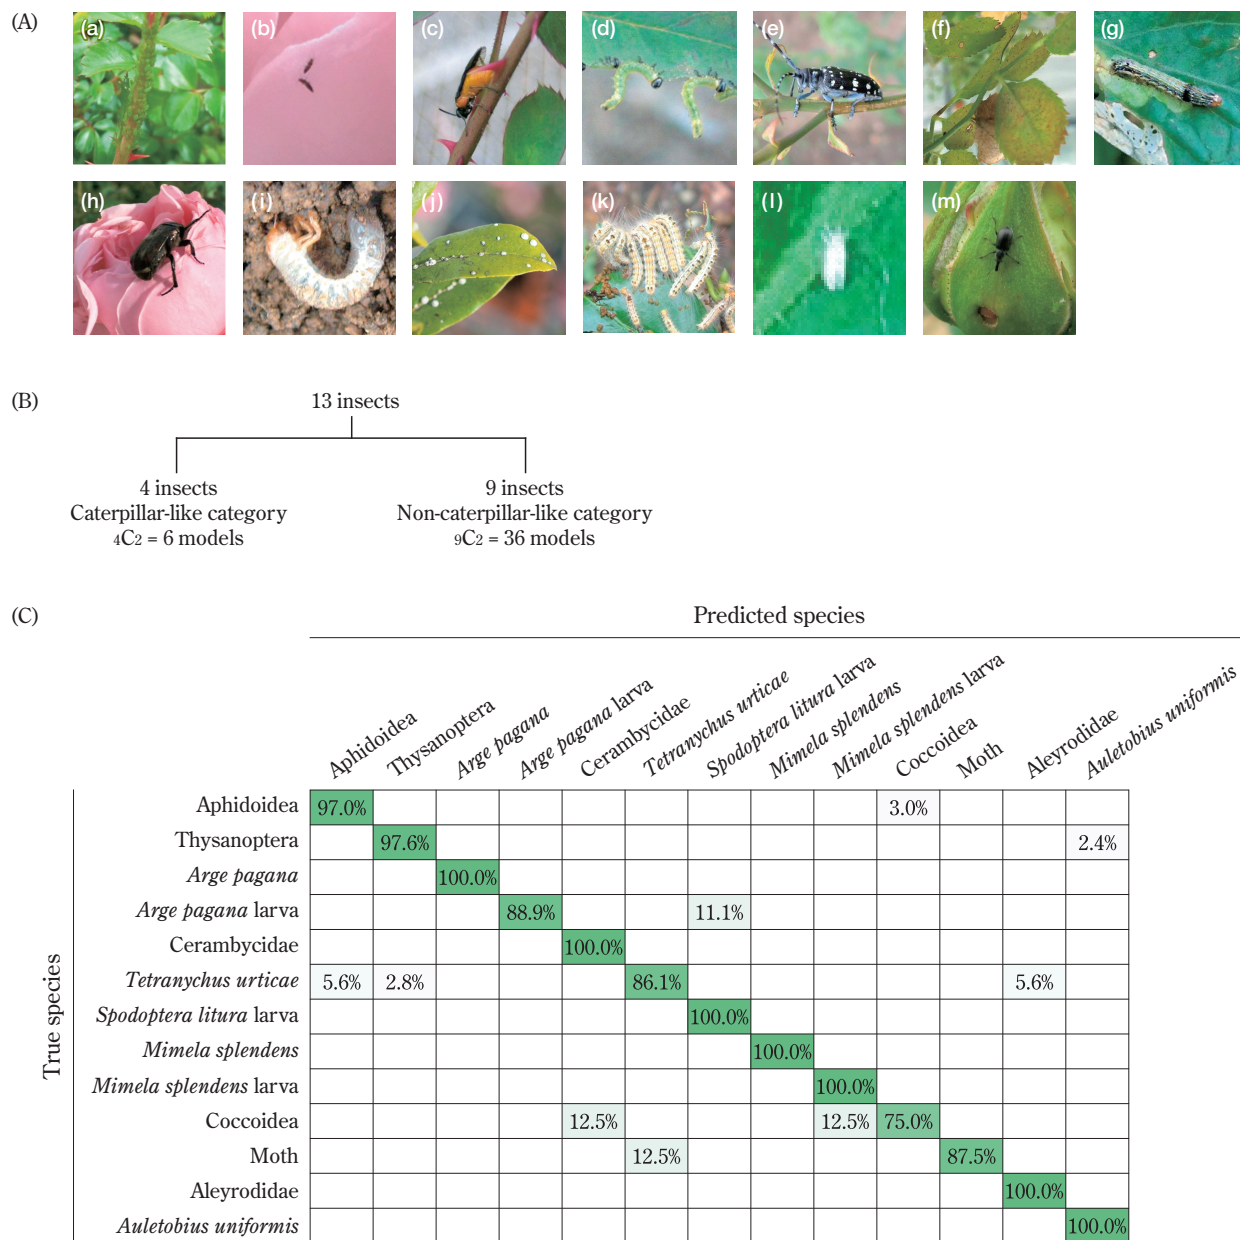


Fig. 4 Sample images and classification result for thirteen rose pests
 (A) Images of 13 types of pests: (a) Aphidoidea, (b) Thysanoptera, (c) *Arge pagana*, (d) *Arge pagana* larva, (e) Cerambycidae, (f) *Tetranychus urticae*, (g) *Spodoptera litura* larva, (h) *Mimela splendens*, (i) *Mimela splendens* larva, (j) Coccoidea, (k) Moth, (l) Aleyrodidae, (m) *Auletobius uniformis*. (B) Concept of categorization. (C) Confusion matrix of the predicted result. The diagonal cells indicate classification accuracy, and the other cells show the percentage of misclassification. Blank cells indicate 0.0%.

なった (Fig. 5(B))。本手法により誤分類した事例には、診断対象である害虫が小さくしか映っていない画像や、画像の大部分が背景であることが影響していると思われる画像が含まれていた。この問題につ

いては、診断前に画像の切り出しによって診断領域を絞り込むことで解決することが確認された。

以上の各検討において一般的な手法と比べ約20~30%高い精度での診断が可能という結果は、本手法で

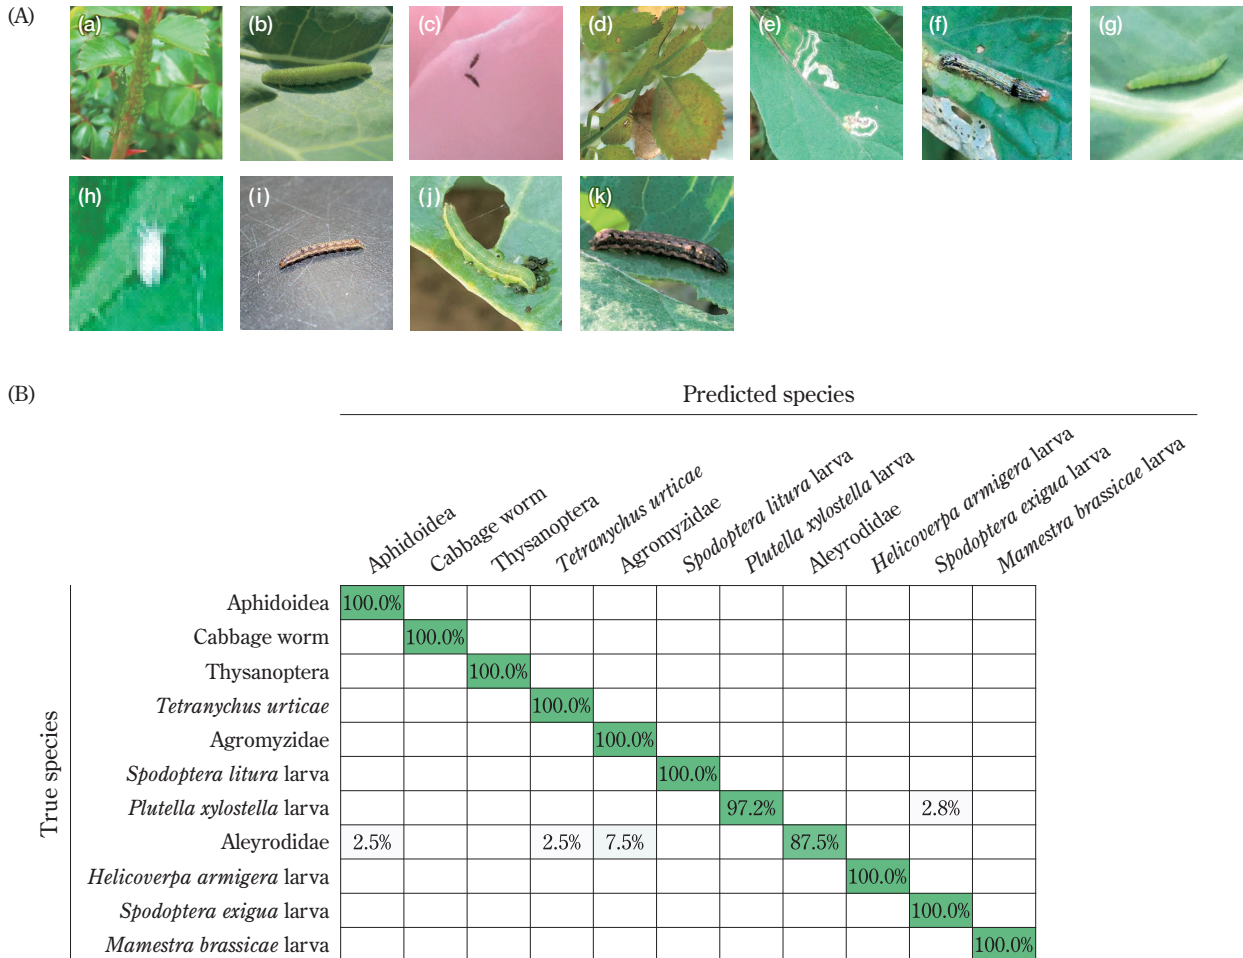


Fig. 5 Sample images and classification result for eleven pests

(A) Images of 11 types of pests: (a) Aphidoidea, (b) Cabbage worm, (c) Thysanoptera, (d) *Tetranychus urticae*, (e) Agromyzidae, (f) *Spodoptera litura* larva, (g) *Plutella xylostella* larva, (h) Aleyrodidae, (i) *Helicoverpa armigera* larva, (j) *Spodoptera exigua* larva, (k) *Mamestra brassicae* larva. (B) Confusion matrix of the predicted result. The diagonal cells indicate classification accuracy, and the other cells show the percentage of misclassification. Blank cells indicate 0.0%.

は各モデルが対象物の特徴を正確に認識し、その特徴が画像診断に利用されていることを示唆している。複雑な問題を分割することで適切に最適化が為されており、汎用性の高い実用的な学習モデルが構築できる手法であると考えている。

まとめ

本稿では、生物の画像診断における多群分類問題を単純な2群分類問題の組み合わせに帰着し、複数の2群分類モデルを統合することで、一般的な手法と比較して高精度に診断できる技術を紹介した。モデル

ケースとして、少サンプル・高多様性を有する病害虫の画像診断に適用した場合、一般的な多群分類モデルと比較して診断精度が約20~30%程度向上した。生物の画像診断において、多群分類問題を2群分類へ帰着させる分類問題の単純化は、結果として最適な学習モデルの構築に繋がることを示している。

おわりに

本技術の課題として、分類カテゴリの増加に応じて、組み合わせの数が増大するため、診断に時間を要することが分かっている。現在は、使用するCPU

数を増やすなどにより対応しているが、今後はアルゴリズムを改良し、計算機性能に頼り過ぎない技術にしたい。一方で、当社アグロ事業部は本技術を利用し、農家による利用を想定したスマホアプリ病害虫診断EXPESTSの配信を開始した⁶⁾。また、本技術は社外にもライセンスされており、園芸愛好家のような一般ユーザーを対象にした画像診断サービスが開始された。

画像診断技術は、農作物の病害虫診断のみならず、健康・農業分野において熟練者が保有するノウハウの伝承や生産性向上のためのソリューションとして幅広く活用されていくものと期待される。当社で開発した技術は画像データ全般に利用可能な概念であり、当該分野におけるさまざまな課題解決に応用していきたいと考えている。

引用文献

- 1) A. Krizhevsky *et al.*, “ImageNet Classification with Deep Convolutional Neural Networks”, Neural Information Processing Systems (2012).
- 2) K. He *et al.*, “Deep residual learning for image recognition”, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (2016), p. 770.
- 3) サイバネットシステム(株), “AIを搭載した大腸内視鏡診断支援ソフトウェア医薬品医療機器等法(薬機法)承認のお知らせ”, <https://www.cybernet.jp/company/about/news/press/2018/20181210.html> (参照 2021/3/22).
- 4) J. Liu and X. Wang, Plant Methods, 17, 22 (2021).
- 5) (国研)農業・食品産業技術総合研究機構, “(研究成果) AI病害虫画像診断システムをWAGRIで提供開始”, https://www.naro.go.jp/publicity_report/press/laboratory/rcait/138806.html (参照2021/4/16).
- 6) 住友化学(株), “病害虫診断EXPESTS”, https://www.i-nouryoku.com/link/expests_top.html (参照 2021/3/22).